

EDB Postgres Distributed -PGD

リリース *5.3.0*

EnterpriseDB Corporation.

2023 年 12 月 07 日

目 次

第 1 章 Introduction **3**
1.1 互換性 . . . 3
1.2 互換性マトリックス . . . 3

第 2 章 EDB Postgres Distributed Release notes **7**
2.1 EDB Postgres Distributed 5.3.0 release notes . . . 7
2.1.1 EDB Postgres Distributed 5.3.0 のハイライト . . . 7
2.1.2 互換性 . . . 8
2.1.3 機能強化 . . . 8
2.1.4 バグ修正 . . . 8
2.2 EDB Postgres Distributed 5.2.0 release notes . . . 10
2.2.1 EDB Postgres Distributed 5.2.0 のハイライト . . . 10
2.3 EDB Postgres Distributed 5.1.0 release notes . . . 12
2.3.1 EDB Postgres Distributed 5.1 のハイライト . . . 13
2.4 EDB Postgres Distributed 5.0.1 release notes . . . 16
2.5 EDB Postgres Distributed 5.0.0 release notes . . . 16

第 3 章 Known issues **21**

第 4 章 Quick Start **23**
4.1 クイックスタート . . . 23
4.2 PGD と TPA の紹介 . . . 23
4.3 Docker、Linux ホスト、または AWS クイックスタートの選択 . . . 24
4.3.1 Docker クイックスタート . . . 24
4.3.2 Linux ホストのクイックスタート . . . 24
4.3.3 AWS クイックスタート . . . 24
4.4 クラスターを使用したさらなる探索 . . . 25
4.4.1 Deploying an EDB Postgres Distributed example cluster on Docker . . . 25
4.4.2 Deploying an EDB Postgres Distributed example cluster on Linux hosts . . . 32
4.4.3 Deploying an EDB Postgres Distributed example cluster on AWS . . . 41
4.4.4 Deploying an EDB Postgres Distributed example cluster on Azure and Google cloud platforms . . . 47
4.4.5 Connecting to your database . . . 48
4.4.6 Exploring failover handling with PGD . . . 53
4.4.7 Exploring conflict handling with PGD . . . 62
4.4.8 Next Steps with PGD . . . 67

第 5 章 Concepts **69**
5.1 クイックスタート . . . 69
5.2 PGD と TPA の紹介 . . . 69
5.3 Docker、Linux ホスト、または AWS クイックスタートの選択 . . . 70

5.3.1 Docker クイックスタート . . . 70
5.3.2 Linux ホストのクイックスタート . . . 70
5.3.3 AWS クイックスタート . . . 70
5.4 クラスターを使用したさらなる探索 . . . 71
5.4.1 PGD overview . . . 71
5.4.2 Terminology . . . 75

第 6 章 Planning **81**
6.1 Choosing your architecture . . . 81
6.1.1 標準の EDB Always On アーキテクチャ . . . 81
6.1.2 アーキテクチャの詳細 . . . 82
6.1.3 アーキテクチャの選択 . . . 83
6.1.4 標準アーキテクチャに柔軟性を追加する . . . 84
6.2 Choosing a Postgres distribution . . . 85
6.3 Choosing your deployment method . . . 86
6.4 Other considerations . . . 87
6.4.1 データの一貫性 . . . 87
6.4.2 展開 . . . 87
6.4.3 サイズ設定の考慮事項 . . . 87
6.4.4 時計とタイムゾーン . . . 88
6.5 Limitations . . . 88
6.5.1 ノード . . . 88
6.5.2 単一のインスタンス上の複数のデータベース . . . 89
6.5.3 CAMO . . . 90
6.5.4 グループコミット . . . 91
6.5.5 Eager . . . 91
6.5.6 その他の制限 . . . 91

第 7 章 Installing **93**
7.1 Upgrading . . . 93
7.1.1 PGD のアップグレード . . . 93
7.1.2 その他のアップグレード . . . 94
7.2 Deploying EDB Postgres Distributed using Trusted Postgres Architect . . . 108
7.2.1 前提条件 TPA のインストール . . . 108
7.2.2 構成 . . . 109
7.2.3 プロビジョニング . . . 113
7.2.4 Deploy . . . 113
7.2.5 テスト . . . 114

第 8 章 Using **115**
8.1 Application use . . . 115
8.1.1 Application behavior . . . 115
8.1.2 DML and DDL replication and nonreplication . . . 118
8.1.3 Nodes with differences . . . 120
8.1.4 General rules for applications . . . 122
8.1.5 Timing considerations and synchronous replication . . . 122
8.1.6 Use of table access methods (TAMs) in PGD . . . 123
8.2 Node management . . . 123

8.2.1 Node types . . . 124
8.2.2 Groups and subgroups . . . 125
8.2.3 Creating and joining PGD groups . . . 125
8.2.4 Witness nodes . . . 127
8.2.5 Logical standby nodes . . . 128
8.2.6 Physical standby nodes . . . 130
8.2.7 Subscriber-only nodes and groups . . . 131
8.2.8 Viewing PGD topology . . . 133
8.2.9 Removing nodes and groups . . . 135
8.2.10 Joining a heterogeneous cluster . . . 136
8.2.11 Connection DSNs and SSL (TLS) . . . 136
8.2.12 Decoding worker . . . 137
8.2.13 Replication slots created by PGD . . . 138
8.2.14 Node restart and down node recovery . . . 140
8.3 Postgres configuration . . . 141
8.3.1 Postgres 設定 . . . 141
8.3.2 時間ベースのスナップショット . . . 142
8.3.3 準備されたトランザクションの最大数 . . . 142
8.4 DDL replication . . . 143
8.4.1 DDL レプリケーションオプション . . . 143
8.4.2 PGD システムでの DDL の実行 . . . 144
8.4.3 DDL ロックの詳細 . . . 145
8.4.4 DDL のインパクトの最小化 . . . 147
8.4.5 ダウンしたノードでの DDL の処理 . . . 148
8.4.6 ステートメント固有の DDL レプリケーションの問題 . . . 148
8.4.7 PGD DDL コマンド処理マトリックス . . . 149
8.5 Security and roles . . . 165
8.5.1 Roles . . . 165
8.5.2 Role management . . . 166
8.5.3 PGD predefined roles . . . 167
8.5.4 Roles and replication . . . 170
8.5.5 Access Control . . . 172
8.6 Sequences . . . 174
8.6.1 PGD グローバルシーケンス . . . 174
8.6.2 UUID、KSUUID、およびその他のアプローチ . . . 181
8.6.3 関連項目 . . . 183
8.7 Durability . . . 183
8.7.1 概要 . . . 183
8.7.2 用語と定義 . . . 184
8.7.3 比較 . . . 184
8.7.4 操作の内部タイミング . . . 186
8.7.5 構成 . . . 187
8.7.6 計画的なシャットダウンと再起動 . . . 188
8.7.7 PGD を使用したレガシー同期レプリケーション . . . 188
8.8 Consistency . . . 210
8.8.1 Conflicts . . . 210
8.8.2 Column-level conflict detection . . . 235

8.8.3 Conflict-free replicated data types . . . 241
8.8.4 Eager conflict resolution . . . 253
8.9 Parallel Apply . . . 255
8.9.1 パラレル適用とは何ですか? . . . 255
8.10 Replication sets . . . 257
8.10.1 レプリケーションセットを使用する . . . 257
8.10.2 パーティション分割テーブルの動作 . . . 258
8.10.3 外部キーを使用した動作 . . . 259
8.10.4 レプリケーションセットのメンバーシップ . . . 260
8.10.5 レプリケーションセットのリスト . . . 260
8.10.6 DDL レプリケーションフィルタリング . . . 261
8.10.7 選択的レプリケーションの例 . . . 262
8.11 Application connection management . . . 267
8.11.1 構成 . . . 267
8.12 Backup and recovery . . . 282
8.12.1 バックアップ . . . 282
8.12.2 リストア . . . 286
8.13 Monitoring . . . 287
8.13.1 OpenTelemetry integration . . . 288
8.13.2 Monitoring through SQL . . . 291
8.14 EDB Postgres Distributed Command Line Interface . . . 305
8.14.1 Installing PGD CLI . . . 306
8.14.2 Using PGD CLI . . . 307
8.14.3 Configuring PGD CLI . . . 309
8.14.4 Discovering connection strings . . . 310
8.14.5 Command reference . . . 313
8.15 Transaction streaming . . . 346
8.15.1 PGD の機能強化 . . . 346
8.15.2 構成 . . . 347
8.15.3 モニタリング . . . 349
8.16 Testing and tuning PGD clusters . . . 349
8.16.1 Trusted Postgres アーキテクト . . . 349
8.16.2 pgd_bench . . . 350
8.16.3 pgd_bench の使用に関する注意事項 . . . 351
8.17 Stream triggers . . . 352
8.17.1 適用中のトリガー実行 . . . 353
8.17.2 行型の用語 . . . 354
8.17.3 競合トリガー . . . 354
8.17.4 Transform トリガー . . . 356
8.17.5 行の内容 . . . 356
8.17.6 実行オーダー . . . 357
8.17.7 ストリームトリガーの例 . . . 357
8.18 AutoPartition . . . 359
8.18.1 パーティションの自動作成 . . . 360
8.18.2 オートパーティションの例 . . . 360
8.18.3 RANGE パーティションテーブル . . . 361
8.18.4 パーティションの自動作成の停止 . . . 362

8.18.5 パーティションの作成を待機しています . . . 362
8.18.6 パーティションの検索 . . . 362
8.18.7 AutoPartitioning の有効化または無効化 . . . 362
8.19 Explicit two-phase commit (2PC) . . . 363
8.19.1 使用する . . . 363
8.20 Timestamp-based snapshots . . . 364

第 9 章 PGD Reference **367**
9.1 ストリームトリガーリファレンス . . . 376
9.1.1 User visible catalogs and views . . . 379
9.1.2 System functions . . . 413
9.1.3 PGD settings . . . 434
9.1.4 Node management . . . 448
9.1.5 Node management interfaces . . . 451
9.1.6 Routing functions . . . 464
9.1.7 Replication set management . . . 465
9.1.8 Replication set membership . . . 470
9.1.9 DDL replication filtering . . . 472
9.1.10 Testing and tuning commands . . . 475
9.1.11 Global sequence management interfaces . . . 478
9.1.12 Autopartition . . . 487
9.1.13 Stream Triggers Reference . . . 492
9.1.14 Internal catalogs and views . . . 499
9.1.15 Internal system functions . . . 503

EDB Postgres 分散 PGD は、高度な競合管理、データ損失保護、およびネイティブ論理レプリケーションより最大 5 倍高速のスループットを備えたマルチマスターレプリケーションとデータ分散を提供します。最大ファイブナインの高可用性を備えた分散 Postgres クラスターが有効になります。

デフォルトでは、 EDB Postgres 分散は非同期レプリケーションを使用し、ローカルコミットの後にのみピアノードに変更を適用します。

> **グループコミット** 、 *CAMO* **またはコミット・アット・モスト・ワンス** 、または**熱心な** レプリケーションを構成することにより、異なるノード、ノードのグループ、またはすべてのノード間の追加レベルの同期性を構成できます。

第1章　Introduction

1.1 互換性

EDB Postgres Distributed 5 は以下と互換性があります

パッケージ |バージョン ——– | ——— コミュニティ　PostgreSQL | 12-16 EDB Postgres 拡張サーバー| 12-16 EDB Postgres Advanced Server | 12-16

以前のバージョンについては、 **互換性マトリックス** を参照してください

1.2 互換性マトリックス

EDB Postgres Distributed	Community PostgreSQL	EDB Postgres Extended Server	EDB Postgres Advanced Server	PGD CLI	PGD-Proxy	BDR Extension	pgLogical3 Extension	HARP
5	12-16*	12-16*	12-16*	5	5	5	n/a	n/a
4	12-14	12-14	12-14	1**	n/a	4	n/a	2***
3.7	11-13	11r2-13	11-13	n/a	n/a	3.7	3.7	2***

*バージョン 16 は、PGD 5.3 以降でのみサポートされています。 *　*PGD CLI 1 は、 BDR 4.1 以降でサポートされています。 *　** HARP 2 の BDR DCS は、BDR 3.7.15 以降および 4.0.1 以降でサポートされています。

第2章　EDB Postgres Distributed Release notes

EDB Postgres Distributed ドキュメントでは、マイナーリリースとパッチを含む EDB Postgres Distributed 5 の最新バージョンについて説明しています。リリースノートは、各リリースの新機能に関する情報を提供します。マイナーまたはパッチリリースで導入された新機能の場合、コンテンツには、機能を導入したリリースも示されます。

Release Date	EDB Postgres Distributed	BDR extension	PGD CLI	PGD Proxy
14 Nov 2023	*EDB Postgres Distributed 5.3.0 release notes*	5.3.0	5.3.0	5.3.0
4 Aug 2023	*EDB Postgres Distributed 5.2.0 release notes*	5.2.0	5.2.0	5.2.0
16 May 2023	*EDB Postgres Distributed 5.1.0 release notes*	5.1.0	5.1.0	5.1.0
21 Mar 2023	*EDB Postgres Distributed 5.0.1 release notes*	5.0.0	5.0.1	5.0.1
21 Feb 2023	*EDB Postgres Distributed 5.0.0 release notes*	5.0.0	5.0.0	5.0.0

2.1 EDB Postgres Distributed 5.3.0 release notes

リリース日 2023 年 11 月 14 日

EDB Postgres Distributed バージョン 5.3.0 は、 EDB Postgres Distributed のマイナーバージョンです。

2.1.1 EDB Postgres Distributed 5.3.0 のハイライト

- PostgreSQL 16 サーバー、 EDB Postgres Extended Server 16、および EDB Postgres Advanced Server 16 のサポート

2.1.2 互換性

Debian、RHEL、および SLES のパッケージマネージャーは、EDB Postgres Distributed のアップグレードを含む必要な EDB Postgres Advanced Server または EDB Postgres Extended のアップグレードをプルします。

Component	Version	Description	Addresses
PGD	5.3.0	PostgreSQL 16 サーバー、EDB Postgres Extended Server 16、および EDB Postgres Advanced Server 16 のサポートを追加しました。	

2.1.3 機能強化

Component	Version	Description	Addresses
Proxy	5.3.0	デフォルトのサービスユニットファイルをパッケージに追加しました	
BDR	5.3.0	EDB Postgres Advanced Server または EDB Postgres Extended への依存関係がパッケージに反映されるようになりました。	

2.1.4 バグ修正

Component	Version	Description	Addresses
BDR	5.3.0	WalSender プロセスがパーティションのロックを要求しないことを確認して、同期コミットを待機しているユーザープロセスによるデッドロックを回避します。	RT97952
BDR	5.3.0	CAMO セットアップがローカルモードに低下した場合、CAMO トランザクションのみが非同期であることを検討します。これにより、フェールオーバー中に発生したトランザクションの運命を決定する際のスプリットブレイン問題が解決されます。	RT78928
BDR	5.3.0	バッチ挿入時に異なる属性番号を持つパーティションを処理します。	RT99115
BDR	5.3.0	remote_write モードでの安全でない CAMO 決定を修正しました。	
BDR	5.3.0	Taskmgr プロセスは SIGINT を尊重するようになりました。	
BDR	5.3.0	コミット決定をロードするために読み取られる WAL の量を制限することにより、マネージャープロセスのスタートアップが高速化されました。	

次のページに続く

表 4 – 前のページからの続き

Component	Version	Description	Addresses
BDR	5.3.0	物理的結合は、`bdr.taskmgr_local_work_queue`の古いレコードをクリーンアップするようになりました。	
BDR	5.3.0	論理結合中の `bdr.autopartition_rules`のコピーのバグを修正しました。	
BDR	5.3.0	taskmgrworker のワーカーをオーバーライドします。	
BDR	5.3.0	`bdr.autopartition_wait_for_partitions()`と taskmgr 間の潜在的なデッドロックを回避します。	
BDR	5.3.0	TDE が有効になっているストリーミングモードでのライタの欠落更新を修正しました。	
BDR	5.3.0	PGD クラスターで新しい EDB Postgres Advanced Server の自動パーティショニングをブロックします。	
BDR	5.3.0	クラスターの作成またはアップグレード時に、既存の自動的にパーティション化されたテーブルを許可します。	
BDR	5.3.0	EDB Postgras Advanced Server の INTERVAL パーティションテーブルのブロック PGD 自動パーティション。	
BDR	5.3.0	3.7.23 および 4.3.3/5.3 で実行されている混合バージョンクラスターで`bdr.autopartition()`が呼び出されたときに、レプリケーションが中断しないことを確認	
BDR	5.3.0	データグループのデフォルトの選択的レプリケーション動作を修正しました。データグループは、デフォルトでグループまたは親グループのレプリケーションセットのみを公開することになっており、サブスクライブするものをミラーします。	
BDR	5.3.0	LCR ファイル TDE 暗号化のメモリリークを修正しました。	
BDR	5.3.0	ストリーミングトランザクション処理のメモリリークを修正しました。	
BDR	5.3.0	既に通常に分離されているノードの強制分離を許可します。	
BDR	5.3.0	PART_CATCHUP は、レプリケーションスロットと node_catchup_info の競合に対する復元力が向上しました。	
BDR	5.3.0	テーブル列が削除された後に作成されたパーティションの行フィルタの失敗を修正しました。	RT95149
BDR	5.3.0	最初の中止応答を受け取ったときに、グループコミットトランザクションを中止しないようにします。他のノードには応答する機会が与えられ、必要な応答が受信された場合、トランザクションは成功できます。	
BDR	5.3.0	`pg_reload_conf()`が呼び出されたときに、レプリケーションレシーバーワーカーが構成を正しくリロードすることを確認します。	

次のページに続く

表 4 – 前のページからの続き

Component	Version	Description	Addresses
BDR	5.3.0	レプリケーションを中断する可能性のある重複した Raft 要求 ID 生成を防ぎます。	
BDR	5.3.0	ワーカーのクラッシュを引き起こす可能性のあるいくつかのまれなメモリアクセスの問題を修正しました。	
BDR	5.3.0	競合が発生した場合に、明示的な 2PC トランザクションが早期に中止される問題を修正しました。	RT92897
CLI	5.3.0	*shared_preload_libraries* GUC にファイルパスが含まれる場合の `verify-settings`コマンドを修正しました。	
CLI	5.3.0	PGD クラスターが監視ノードのみに削減される場合、`check-health`コマンドで `Critical`として show replslots ステータスを表示します。	
Proxy	5.3.0	常にサーバー接続のクローズ動作 setLinger(0) を設定します。以前は、クライアントエラーの場合にのみ設定されていました。	
Proxy	5.3.0	PGD クラスターですべてのノードがダウンしている場合のログがいっぱいになる問題を修正しました	
Utilities	1.2.0	データベースレベルで CONNECTION LIMIT を 0 に設定する `bdr_pg_upgrade`のアップグレード前ステップを削除しました	

2.2 EDB Postgres Distributed 5.2.0 release notes

リリース日 2023 年 8 月 4 日

EDB Postgres Distributed バージョン 5.2.0 は、 EDB Postgres Distributed のマイナーバージョンです。

2.2.1 EDB Postgres Distributed 5.2.0 のハイライト

- Parallel apply が、PGD のコミットアットモストワンス CAMO 同期コミットスコープで利用できるようになり、レプリケーションパフォーマンスが向上します。

*ネイティブ Postgres の非同期および同期レプリケーションのパラレル適用は、コミットシーケンスを維持し、デッドロックを回避するために、複数のトランザクションによって同じキーが同時に変更されているワークロードに対して改善されました。

- PGD プロキシは HTTP(S) API を追加して、プロキシの状態を直接監視して、準備状況とライブネスを直接監視できます。**プロキシのヘルスチェック** を参照してください。

Component	Version	Type	Description
BDR	5.2.0	Feature	CAMO を使用した同期コミットスコープのパラレル適用を追加しました。
BDR	5.2.0	Feature	コミットスコープルールで複数の SYNCHRONOUS_COMMIT 句を許可します。
BDR	5.2.0	Enhancement	BDR 拡張機能では、SYNCHRONOUS_COMMIT および LAG CONTROL コミットスコープを使用したトランザクションストリーミングが許可されるようになりました。
BDR	5.2.0	Enhancement	Parallel apply による同時ワークロードの処理が向上しました。
BDR	5.2.0	Enhancement	新しい列用に `bdr.stat_subscription`を変更しました。
BDR	5.2.0	Bug fix	外部キーコンストレイン違反がある場合にノードの論理参加を許可することにより、問題を修正しました。RT91745
BDR	5.2.0	Bug fix	デッドロックの可能性を回避するために `group_raft_details`ビューを変更しました。
BDR	5.2.0	Bug fix	拡張機能のアップグレードをログに記録する機能を追加することにより、問題を修正しました。
BDR	5.2.0	Bug fix	競合するノード名のチェックを追加しました。
BDR	5.2.0	Bug fix	Raft の手動スナップショット復元中のクラッシュを修正しました。
BDR	5.2.0	Bug fix	BDR 拡張機能が分割または分割されたノードへのコンセンサス接続を確立しようとした問題を修正しました。
BDR	5.2.0	Bug fix	正しい単位を使用するように `tcp_user_timeout` GUC を修正しました。
BDR	5.2.0	Bug fix	PGD 3.7 とのコンセンサススナップショットの互換性を修正しました。 RT93022
BDR	5.2.0	Bug fix	pgaudit で BDR 拡張機能を使用するとクラッシュが発生する問題を修正しました。
BDR	5.2.0	Bug fix	監視ノードへの分割同期をスキップすることにより、問題を修正しました。
BDR	5.2.0	Bug fix	接続文字列で正しいキープアライブパラメーターを生成するようにした問題を修正しました。
BDR	5.2.0	Bug fix	グループとそのサブグループ間でノードを切り替えるさまざまなシナリオを有効にしました。たとえば、ノードをグループからネストされたサブグループに移行します。
BDR	5.2.0	Bug fix	アイドルサーバーでコンセンサスによって生成される WAL の量が削減されました。
BDR	5.2.0	Bug fix	コンカレント `DROP EXTENSION`が実行中の場合の自動パーティションカタログのデッドロックを修正しました。

次のページに続く

表 5 – 前のページからの続き

Component	Version	Type	Description
BDR	5.2.0	Bug fix	ノード再起動後に拡張機能をドロップする際の散発的な障害を修正しました
BDR	5.2.0	Bug fix	pgaudit のバグによるクラッシュの回避策を追加しました。
BDR	5.2.0	Bug fix	コンセンサスクエリーとグローバルモニタリングクエリー間のデッドロックを修正しました。
BDR	5.2.0	Bug fix	`bdr.run_on_all_nodes`全体のクエリキャンセルの伝播を修正しました。
BDR	5.2.0	Bug fix	分割されたノードで `bdr.run_on_nodes()`、*bdr.run_on_group()*、および `bdr.run_on_all_nodes()`を呼び出すことを禁止することにより問題を修正しました。
CLI	5.2.0	Enhancement	`verify-settings`コマンドに新しい GUC 検証を追加しました。
CLI	5.2.0	Bug fix	`verify-settings`の表形式出力で GUC の長い値を切り捨てることにより問題を修正しました。
CLI	5.2.0	Bug fix	データベースドライバーライブラリのバージョンをアップグレードすることにより、`sslmode=allow`または`sslmode=prefer`の場合の `connect_timeout`問題を修正しました。
Proxy	5.2.0	Feature	プロキシヘルスチェック用の HTTP(S) API を追加しました。
Proxy	5.2.0	Enhancement	ルート変更イベント処理メカニズムの向上。
Proxy	5.2.0	Enhancement	コンセンサスクエリエラーに関する再試行メカニズムを追加しました。
Proxy	5.2.0	Bug fix	データベースドライバーライブラリのバージョンをアップグレードすることにより、`sslmode=allow`または`sslmode=prefer`の場合の `connect_timeout`問題を修正しました。

2.3 EDB Postgres Distributed 5.1.0 release notes

リリース日 2023 年 5 月 16 日

EDB Postgres Distributed バージョン 5.1.0 は、 EDB Postgres Distributed のマイナーバージョンです。このバージョンは、PGD プロキシおよび PGD CLI の依存関係のセキュリティ脆弱性を解決します。

2.3.1 EDB Postgres Distributed 5.1 のハイライト

*** 同期コミット**が、PGD の統一された COMMIT SCOPE 構文で利用できるようになりました。Postgres の古い同期コミットオプションをモデルに、PGD Synchronous Commit を使用すると、DBA はより詳細なコミットと同期管理を利用できます。この追加は、既存の Group Commit 、 CAMO、および Lag Control コミットスコープオプションを補完します。

*** 優先度ベースのプロキシルーティング**の修正により、フェールオーバーの処理が適切になりました。PGD CLI を介してプロキシの猶予期間を構成できるようになったため、Raft リーダーの喪失に対するプロキシ応答を調整できます。これに加えて、Raft イベントは PGD CLI の `show-events` コマンドで表示され、イベント、ソース、およびサブタイプを表示します。

*** `bdr.drop_node_group()` ** PGD SQL インターフェイスを使用して空のノードグループを削除するサポートを追加します。

Component	Version	Type	Description
BDR	5.1.0	Feature	ライタプロセスの終了時に出力されるログメッセージに pid を追加しました。
BDR	5.1.0	Feature	bdr.event_summary ビューにグループ名を追加しました。
BDR	5.1.0	Feature	SLES のサポートを追加しました。 SLES 15sp4 がサポートされるようになりました。
BDR	5.1.0	Feature	グループサブスクリプションの概要ビューにサブスクリプションステータス列を追加しました。この機能を使用すると、NULL 値の原因がノードのダウンによるものなのか、サブスクリプションの無効化によるものなのかを区別できます。
BDR	5.1.0	Feature	NOT グループフィルタをグループコミットに追加しました。この機能を使用すると、グループフィルタの意味を反転して、指定されたグループ内のノードを除くすべてのノードを含めることができます。
BDR	5.1.0	Feature	`bdr.drop_node_group`を追加しました。空のノードグループをドロップできるようになりました。
BDR	5.1.0	Feature	コミットスコープに SYNCHRONOUS_COMMIT を追加しました。この機能により、レプリケーションの動的な synchronous_commit のような動作が可能になります。
BDR	5.1.0	Feature	Event_node_name 列を `bdr.event_summary`に追加しました。
BDR	5.1.0	Feature	イベント履歴に書き込みリーダー選挙を追加しました。Event_history カタログの各グループの書き込みリーダーとして選択されたノードに関する情報を追加しました。Event_history の event_detail での raft インスタンス ID のレポートも改善しました。

次のページに続く

表 6 – 前のページからの続き

Component	Version	Type	Description
BDR	5.1.0	Feature	他の Raft インスタンスのスナップショットのエクスポートとインポートを許可する機能を追加しました。この機能を使用すると、トップの Raft インスタンスだけでなく、他のインスタンスのスナップショットをエクスポートおよびインポートできます。
BDR	5.1.0	Bug fix	コンセンサスプロセスのメモリリークを修正しました。RT91830
BDR	5.1.0	Bug fix	再参加後にノードがグループと一貫性がない場合がある問題を修正しました。ノードがサブグループの一部であり、分離されて、グループに再参加した場合、グループと一貫性がなくなる可能性があります。グループの一部のノードからの変更が間違った開始点から再生され、潜在的なデータ損失が発生しました。
BDR	5.1.0	Bug fix	SDW および standby_slot_names が設定されている場合のジョインとレプリケーションを修正しました。(RT89702、RT89536)
BDR	5.1.0	Bug fix	シーケンスオプションを処理する際の誤った警告を修正しました。 RT90668
BDR	5.1.0	Bug fix	CRDT を使用するノードのアップグレードを修正しました。
BDR	5.1.0	Bug fix	pg_stat_replication からの LCR の遅延追跡パラメーターを調整しました。
BDR	5.1.0	Bug fix	調整されたノードルーティングオプションのデフォルトは、ノードの種類に基づいて設定されます。この変更は情報の表示にのみ関係しており、動作には関係ありません。たとえば、監視ノードは、書き込みを受信する候補としてマークされません。
BDR	5.1.0	Bug fix	ノードの作成中に、すべてのシーケンスが「分散」に変換されるようになりました。
BDR	5.1.0	Bug fix	`standby_slot_names`を使用したストリーミングトランザクションを修正しました。これにより、サブスクライバ専用ノードがデータノードに先んじた可能性があります。
BDR	5.1.0	Bug fix	ルーティング選択時に優先順位が適切に動作するようにしました。以前は、ノード優先度は、以前のリーダーが存在しない場合にのみ機能していましたが、フェールオーバーには決して当てはまりません。
BDR	5.1.0	Bug fix	最初のノードで完了したとして、その結合の記録を修正しました。
BDR	5.1.0	Bug fix	デフォルトでトレースは無効になっています。トレースは初期デバッグの場合にのみ有効であり、5.0 リリース前に無効になることになっていました。

次のページに続く

表 6 – 前のページからの続き

Component	Version	Type	Description
BDR	5.1.0	Bug fix	pglogical レシーバーのリロード構成のサポートを追加しました。サーバーがリロード信号を受信すると、pglogical レシーバーがリロードして構成変更を適用します。
BDR	5.1.0	Bug fix	`bdr.monitor_group_raft()`の欠落インスタンスエラーメッセージを改善しました。
BDR	5.1.0	Bug fix	すべての BDR 接続にわたって TCP キープアライブの一貫した使用を実装しました。この変更により、次の GUC が追加されました。*bdr.global_connection_timeout bdr.global_keepalives bdr.global_keepalives_idle bdr.global_keepalives_interval bdr.global_keepalives_count bdr.global_tcp_user_timeout* デフォルトはかなり保守的な値に設定されており、将来のパッチで調整の対象となります。
BDR	5.1.0	Bug fix	タイムアウト後にアクティビティがないときに閉じた Raft 接続。これは、その下で wal_sender_timeout / wal_receiver_timeout を使用します。
BDR	5.1.0	Bug fix	Raft メッセージを受信するバックエンドを簡単に識別できるようにしました。 Raft バックエンドに関連するログメッセージに情報を追加しました。
BDR	5.1.0	Bug fix	並列適用が高負荷になると速度が低下する場合がある問題を修正しました。
BDR	5.1.0	Enhancement	同期ワーカーの再起動が回避されるようになりました。この修正は、サブスクリプションワーカーの再起動を通知する構成変更が行われたときにノード参加が失敗するのを防ぐことです。
PGD Proxy	5.1.0	Enhancement	内部 DB 接続の接続文字列でユーザーが設定していない場合、`application_name`がプロキシ名に設定されるようになりました。
PGD Proxy	5.1.0	Enhancement	新しい`consensus_grace_period`プロキシオプションを実装しました。これは、Raft リーダーが失われたときにプロキシが現在の書き込みリーダー利用可能な場合にルーティングし続ける期間です。この期間中に新しい Raft リーダーが選出されない場合、プロキシはルーティングを停止します。`0s`に設定されている場合、プロキシはルーティングをすぐに停止します。
PGD Proxy	5.1.0	Bug fix	書き込みリーダーが使用できない場合のブロックから、新しいクライアント接続を閉じることに変更しました。
CLI	5.1.0	Enhancement	Raft イベント、イベントソース、サブタイプを表示するように`show-events`コマンドを強化しました。
CLI	5.1.0	Enhancement	`show-clockskew`および`check-health`コマンドのクロックスキュー推定が向上しました。

次のページに続く

表 6 – 前のページからの続き

Component	Version	Type	Description
CLI	5.1.0	Feature	`consensus_grace_period`プロキシオプションの表示および設定のサポートを追加しました。
Utilities	1.1.0	Bug fix	初期化されていない物理レプリケーションスロットの問題の処理を実装しました。

2.4 EDB Postgres Distributed 5.0.1 release notes

リリース日 2023 年 3 月 21 日

EDB Postgres Distributed バージョン 5.0.1 は、EDB Postgres Distributed のパッチバージョンです。このバージョンは、PGD-Proxy および PGD-CLI の依存関係のセキュリティ脆弱性を解決します。

Component	Version	Type	Description
CLI	5.0.1	Change	サードパーティの依存関係をアップグレードして Github dependabot アラートを修正する
Proxy	5.0.1	Change	サードパーティの依存関係をアップグレードして Github dependabot アラートを修正する

2.5 EDB Postgres Distributed 5.0.0 release notes

リリース日 2023 年 2 月 21 日

EDB Postgres Distributed バージョン 5.0.0 は、 EDB Postgres Distributed の新しいメジャーバージョンです。このバージョンには、主要な新機能と互換性の変更が含まれます。

このリリースのハイライトは次のとおりです。

柔軟な展開アーキテクチャ 強化されたルーティング機能**統合されたレプリケーション持続性構成** EDB Advanced Storage Pack のサポート *EDB Postgres Advanced 15* **および** *EDB Postgres Extended 15* **での** *TDE* **のサポート** OpenTelemetry との統合 * トランザクション追跡パフォーマンスの向上 グループコミット、CAMO) Postgres 12〜15 の互換性

Component	Version	Type	Description
PGD	5.0.0	Feature	柔軟な展開アーキテクチャ Always-ON を再定義して、より幅広い展開をサポートします。

次のページに続く

表 8 – 前のページからの続き

Component	Version	Type	Description
BDR	5.0.0	Feature	ルーティング機能の強化 BDR クラスターは、グループでルーティングが有効になっている場合、グループごとの Raft を使用して、すべてのグループおよび関連する場所の書き込みリーダーを選択します。書き込みリーダーのフェイルオーバーを処理し、書き込みリーダーを変更する SQL コマンドを提供します。
BDR	5.0.0	Feature	EDB Advanced Storage Pack のサポート EDB Advanced Storage Pack は、テーブルアクセス方法 TAM 拡張機能の形式で PostgreSQL データベースの高度なストレージオプションを提供します。これらのストレージオプションは、アプリケーションの変更を必要とせずにデータベースのパフォーマンスと信頼性を強化できます。
BDR	5.0.0	Feature	統合されたレプリケーションの耐久性構成 Group Commit、 CAMO、 Eager Replication 、Lag Control などの耐久性オプションは、すべてコミットスコープ構成を介して構成されるようになりました。
BDR	5.0.0	Feature	EDB Postgres Advanced および EDB Postgres Extended TDE サポート EDB Postgres Distributed 5 は、EDB Postgres Advanced および EDB Postgres Extended の Transparent Data Encryption 機能を完全にサポートしています。
BDR	5.0.0	Feature	OpenTelemetry との統合 BDR 拡張機能は、モニタリングメトリックとトレースを OpenTelemetry コレクターに送信して、既存の監視ソリューションとの統合を強化できるようになりました。
BDR	5.0.0	Feature	Postgres 15 の互換性 EDB Postgres Distributed 5 は、Postgres 12〜15 と互換性があります。
BDR	5.0.0	Feature	クラスターイベント管理の向上 `bdr.worker_errors`および `bdr.state_journal_details`ビューは、統合された`bdr.event_summary`に置き換えられました。これには、ローカルノードの Raft ロールの変更も含まれます。将来的には、さらにイベントが追加される可能性があります。
BDR	5.0.0	Change	トランザクション追跡のパフォーマンスの向上 トランザクション追跡は、`bdr.internal_node_pre_commit`カタログの代わりに共有メモリを使用するようになりました。これにより、追加の I/O が発生しないため、パフォーマンスが大幅に向上します。
BDR	5.0.0	Feature	デコーディングワーカーによるデフォルト以外のレプリケーションセットのサポート 非対称レプリケーションセットアップのようなデフォルト以外のレプリケーションセットを使用するクラスターでデコーディングワーカー機能を使用できます。

次のページに続く

表 8 – 前のページからの続き

Component	Version	Type	Description
BDR	5.0.0	Feature	自動パーティションでの HASH パーティショニングのサポートを追加します HASH パーティショニングをサポートするように自動パーティション/自動スケールを拡張します。 RANGE パーティショニングに必要な多くのことは、 HASH パーティショニングには必要ありません。たとえば、すべての HASH パーティションを一度に作成する予定です少なくとも現在の作業では、後でこれを変更する可能性があります。 HASH パーティションが別のテーブルスペースに移動または削除されることは想定していません。したがって、データ保持ポリシーは HASH パーティショニングには適用されません。
BDR	5.0.0	Feature	新しいベンチマークユーティリティを追加します *pgd_bench* このユーティリティは、 CAMO トランザクションのベンチマークをサポートし、将来のリリースは PGD 特定のワークロードのベンチマークに使用されます。
BDR	5.0.0	Change	ノードにノード種類が追加されました。これにより、データ、監視、サブスクライバ専用、スタンバイなどのさまざまな種類のノードをより明確に区別できます。
BDR	5.0.0	Change	自動パーティションからの個別のタスク管理 このリリースでは、自動パーティションのワークキューメカニズムがタスクマネージャー taskmgr と呼ばれる別のモジュールに移動されました。タスクマネージャーは、新しいタスクを作成し、ローカルノードまたはタスクマネージャーリーダーノードによって作成されたタスクを実行します。したがって、autopartition ワーカーは、このリリースでは tacmgr ワーカープロセスに名前が変更されます。古い PGD リリースでは、Raft リーダーが新しい作業項目の作成を担当していました。しかし、監視ノードはクラスターオブジェクトの完全なビューを持たないときに Raft リーダーになる可能性があるため、問題が発生します。このリリースでは、タスクマネージャーリーダーノードの概念を導入しました。ノードは PGD によって自動的に選択されますが、アップグレードされたクラスターの場合、クラスター内のすべてのノードの `node_kind`プロパティを設定することが重要です。ユーザーは、最新の PGD バージョンにアップグレードした後、ノードごとに bdr.alter_node_kind() SQL ファンクションを呼び出すことにより、これを手動で行うことが求められます。
BDR	5.0.0	Deprecation	`bdr.assess_lock_statement`および`bdr.assess_update_replica_identity`は非推奨です。

次のページに続く

表 8 – 前のページからの続き

Component	Version	Type	Description
Proxy	5.0.0	Feature	PGD ビルトインプロキシ TCP レイヤー 4、BDR のルーティング機能を使用する PGD クラスターのパススループロキシ。
CLI	5.0.0	Feature	PGD クラスター検証 CLI は 2 つの新しいコマンド *verify-settings* および `verify-cluster`をサポートします。`verify-settings`は、推奨事項と比較して、PGD クラスター内の各ノードの PostgreSQL 構成を検証します。`verify-cluster`は、フレキシブルアーキテクチャ展開の推奨事項と比較して PGD クラスターアーキテクチャを検証します。
CLI	5.0.0	Feature	プロキシ管理と構成 *pgd* `は、`*create-proxy*、*delete proxy*、*set-group-options*、*set-node-options*、*set-proxy-options*、*show-proxies*、*show-groups*、および `switchover`をサポートして、グループごとにプロキシを構成および管理します。
CLI	5.0.0	Change	`show-camo`コマンドを削除し、`check-health`コマンドから CAMO チェックを削除します。 CLI での `commit scopes`のサポートは、将来のリリースで追加される予定です。
CLI	5.0.0	Change	ルーティング機能に対応するように `show-nodes`および `show-raft`コマンドの出力を変更します。

第3章　Known issues

これらは EDB Postgres Distributed 5 の現在の既知の問題です。これらの既知の問題は PGD のチケットシステムで追跡され、将来のリリースで解決される予定です。

- `update_origin_change` 競合のリゾルバーが `skip` に設定され、`synchronous_commit=remote_apply` が使用され、同じ行の同時更新が 2 つの異なるノードに繰り返し適用される場合、PGD ライタとのデッドロックが原因で更新ステートメントの 1 つがハングする場合があります。**競合** で述べたように、 `skip` は `update_origin_change` 競合のデフォルトのリゾルバーではなく、この組み合わせは運用環境で使用することを目的としていません。そのノードへの到着順序に基づいて、2 つの競合する更新のうちの 1 つを破棄します。これにより、発散クラスターが発生する可能性があります。`skip` 競合リゾルバーの使用を選択するまれな状況では、`remote_apply` モードの使用に関する問題に注意してください。

- Decoding Worker 機能は、CAMO/Eager/Group Commit では動作しません。CAMO/Eager/Group コミットを使用したインストールでは、`enable_wal_decoder` を無効のままにする必要があります。

- Lag Control は、完全に分離されたノード、つまり、他のすべてのノードが到達不能または動作していない場合、コミット遅延を調整しません。少なくとも 1 つのノードが接続されると、レプリケーションラグ制御はその作業を取得し、PGD コミット遅延を再度調整します。

- 時間ベースのラグ制御の場合、PGD は現在適用レートの履歴に基づいた推定キャッチアップ時間ではなく、遅延時間コミットタイムスタンプで測定を使用します。

- CAMO ペアの CAMO パートナーを変更することは現在不可能です。ペアを追加または削除することのみが可能です。ペアの追加または削除には、Postgres の再起動や構成のリロードも必要ありません。

- グループコミットは、*CAMO* **またはコミット・アット・モスト・ワンス** または Eager All-Node Replication と組み合わせることはできません。現在、Eager Replication は、グローバル PGD コミットスコープを使用する場合にのみ機能します。

- Eager Replication を使用するトランザクションは、まだ DDL を実行できません。TRUNCATE コマンドが使用できます。

- パラレル適用は、グループコミットとの組み合わせで現在サポートされていません。グループコミットを使用するときは、次のいずれかによって必ず無効にしてください。- *bdr.alter_node_group_config()* **を使用したグループ構成** を使用してノードグループの `num_writers` を 1 に設定します。 - GUC `bdr.writers_per_subscription` を使用する。*Configuration of generic replication* を参照してください。

- 現在、コミットスコープの変更または削除に対する保護はありません。同時に変更または削除されるコミットスコープでトランザクションを実行すると、トランザクションを適用しようとしているダウンストリームノードでのエラーが原因で、トランザクションブロックまたはレプリケーションが完全に停止する可能性があります。特定のコミットスコープを使用するトランザクションが変更または削除される前に、終了していることを確認します。

- *Configuring PGD CLI* は、クラスターから分離されたノードにまだ接続している場合、クラスターの状態に関する古いデータを返すことができます。*pgd-cli-config.yml* ファイルを編集するか、 *--dsn* 設定を変更して、クラスター内のアクティブなノードのみが接続用にリストされるようにします。

他のデザインまたは実装 *Limitations* の詳細も利用できます。

第4章　Quick Start

4.1 クイックスタート

EDB Postgres 分散 PGD は、高いパフォーマンスと可用性を目指して設計された Postgres のマルチマスター複製実装です。多数の双方向同期データベースノードで構成されるデータベースクラスターを作成できます。クラスターには、クエリトラフィックを最も利用可能なノードに転送する多数のプロキシサーバーを含めることができ、クラスター構成の復元力をさらに高めます。

- Trusted Postgres ArchitectTPA の簡単な紹介と、 EDB Postgres Distributed の構成、展開、および管理にどのように役立つか

Docker、*Linux* **ホスト、または** *AWS* **クイックスタートを選択するためのガイド** Docker クイックスタート *Linux* **ホストのクイックスタート** AWS クイックスタート

- アプリケーションをクラスターに接続する

競合 フェールオーバーを含むクラスターでのさらなる探索

4.2 PGD と TPA の紹介

PGD は、高いパフォーマンスと可用性を実現するように設計された Postgres のマルチマスター複製実装です。PGD のインストールは、TPA によって調整されます。

私たちは、さまざまな Postgres 構成のインストールと管理を簡単に再現可能にするために TPA を作成しました。TPA は、Postgres の作成と展開を調整します。

これらのクイックスタートは、単一のリージョンクラスターをすばやく取得できるように設計されています。

これらのクイックスタートでは、最初に TPA をインストールします。既に TPA をインストールしている場合、これらの手順をスキップできます。TPA は、単純なインストーラーというよりはツールです。TPA の同じインストールを使用して、Postgres クラスターの多くの異なる構成を展開できます。

TPA を使用して、PGD デモクラスターの構成ファイルを生成します。このクラスターには、3 つの複製データベースノードがあり、3 つの高可用性プロキシと 1 つのバックアップノードをコホストします。

次に、TPA を使用して、必要な構成とソフトウェアを各ノードにプロビジョニングおよび展開します。

4.3 Docker、Linux ホスト、または AWS クイックスタートの選択

現在、3 つのクイックスタートが利用できます。

- Docker—単一のマシン上の Docker コンテナでクラスターをプロビジョニング、展開、およびホストします。
- Linux ホスト—オペレーティングシステムと SSH 接続で既にプロビジョニングした Linux サーバーにクラスターを展開およびホストします。これらは、オンプレミスまたはクラウドに展開された実際の物理サーバーまたは仮想マシンです。
- AWS — AWS でクラスターをプロビジョニング、展開、およびホストします。

4.3.1 Docker クイックスタート

Docker クイックスタートは、最初に PGD とその機能を探索しようとしている人に最適です。PGD のこの構成は実稼働使用には適していませんが、PGD クラスターの機能と動作をテストする場合に価値があります。PGD コマンドと API に慣れ、クラウド、VM、または Linux ホストへの展開の準備をする場合にも役立つ場合があります。

- *Begin the Docker quick start*

4.3.2 Linux ホストのクイックスタート

Linux ホストのクイックスタートは、ハードウェアとソフトウェアを完全に制御できる独自のホスト、またはプライベートクラウドに PGD をインストールしようとしている人に適しています。全体的な構成は Docker 構成に似ていますが、システム再起動後より永続的で、PGD のシングルリージョンの運用展開に似ています。

- *Begin the Linux host quick start*

4.3.3 AWS クイックスタート

AWS クイックスタートはより広範囲で、Amazon のクラウド上の EC2 ノードに PGD クラスターを展開します。クラスターの全体的な構成は、Docker クイックスタートに似ています。ただし、Docker コンテナを使用する代わりに、Amazon EC2 の t3.micro インスタンスを使用してコンピューティング能力を提供します。AWS 展開はより永続的で、Docker クイックスタート展開の制限の影響を受けません。ただし、AWS CLI を構成するには、より多くの初期設定が必要です。

- *Begin the AWS quick start*

4.4 クラスターを使用したさらなる探索

- *Connect applications to your PGD cluster*
- *Find out how a PGD cluster stands up to downtime of data nodes or proxies*
- *Learn about how EDB Postgres Distributed manages conflicting updates*
- *Moving beyond the quick starts*

4.4.1 Deploying an EDB Postgres Distributed example cluster on Docker

このクイックスタートでは、TPA を使用して、ローカルの Docker コンテナを使用する Always On Single Location アーキテクチャで PGD をセットアップします。

TPA と PGD の紹介

私たちは、さまざまな Postgres 構成のインストールと管理を簡単に再現可能にするために TPA を作成しました。TPA は、Postgres の作成と展開を調整します。このクイックスタートでは、最初に TPA をインストールします。既に TPA をインストールしている場合、これらの手順をスキップできます。TPA を使用して、さまざまな構成の Postgres クラスターを展開できます。

PGD は、高いパフォーマンスと可用性を実現するように設計された Postgres のマルチマスター複製実装です。PGD のインストールは、TPA によって調整されます。TPA を使用して、PGD デモクラスターの構成ファイルを生成します。

このクラスターは、ローカルの Docker コンテナを使用して、クラスターのノードをホストします。3 つの複製データベースノード、3 つの共同ホスト接続プロキシ、および 1 つのバックアップノード。次に、TPA を使用して、必要な構成とソフトウェアを各ノードにプロビジョニングおよび展開できます。

PGD のこの構成は実稼働使用には適していませんが、PGD クラスターの機能と動作をテストする場合に価値があります。PGD コマンドと API に慣れて、クラウド、VM、または Linux ホストへの展開の準備をする場合にも役立つ場合があります。

注釈: このセットの手順は、Intel / AMD プロセッサー上の Ubuntu 22.04 LTS 専用です。 !!!

前提条件

この例を完了するには、十分な RAM と空きストレージを備えたシステムが必要です。`curl` と Docker のインストールも必要です。

RAM 要件

システムには少なくとも 4GB の RAM が必要です。4 つのコンテナを実行し、そのうち 3 つが Postgres データベースをホストするため、この量の RAM が必要です。

空きディスク領域

この例で説明しているクラスターを展開するには、Docker からアクセスできる少なくとも 5GB の無料ストレージが必要です。もう少し多くすることがおそらく賢明です。

カールユーティリティ

このクイックスタートでは、 `curl` ユーティリティを使用してスクリプトをダウンロードして実行します。デフォルトではインストールされない場合があります。`curl` がインストールされていることを確認するには、次のコマンドを実行します。

```
sudo apt update
sudo apt install curl
```

Docker エンジン

この PGD 展開のターゲットプラットフォームとして Docker コンテナを使用します。Docker エンジンをインストールします。

```
sudo apt update
sudo apt install docker.io
```

```
sudo usermod -aG docker <username>
newgrp docker
```

準備

EDB アカウント

TPA と PGD の両方をインストールするには、EDB アカウントが必要です。

> Sign up for a free EDB account

まだお持ちでない場合。サインアップすると、EDB のソフトウェアリポジトリのトライアルサブスクリプションが提供されます。

登録したら、 EDB Repos 2.0 ページに移動し、リポトークンを取得します。

このページに最初にアクセスしたときに、 **Request Access** を選択してリポトークンを生成します。 **Copy Token** アイコンを使用してトークンをコピーし、安全に保存します。

環境変数の設定

最初に、 EDB_SUBSCRIPTION_TOKEN 環境変数を *EDB アカウント* ステップで取得した EDB リポトークンの値に設定します。

```
export EDB_SUBSCRIPTION_TOKEN=<your-repo-token>
```

これを.bashrc スクリプトまたは同様のシェルプロファイルに追加して、常に設定されるようにできます。

リポジトリの構成

この例に必要なソフトウェアはすべて、EDB Postgres Distributed パッケージリポジトリから入手できます。次のコマンドは、 EDB Postgres 分散リポジトリを構成するスクリプトをダウンロードして実行します。このリポジトリには、TPA パッケージも含まれています。

```
curl -1sLf "https://downloads.enterprisedb.com/$EDB_SUBSCRIPTION_TOKEN/postgres_
↪distributed/setup.deb.sh" | sudo -E bash
```

edb_notranlate_5 出力またはエラーが生成されない場合は、トークンを正しく入力したことを再確認します。問題が解決しない場合は、

> contact Support サポートしてください。

Trusted Postgres ArchitectTPA のインストール

TPA を使用して、PGD をプロビジョニングおよび展開します。以前に TPA をインストールしている場合は、
> *Next Steps with PGD* に進むことができます。

TPA をインストールするための完全な手順は、 *Trusted Postgres Architect documentation* にあります。これもここに含まれています。

Linux 環境

ホストプラットフォームとしての *TPA supports several distributions of Linux* 。これらの例は、Ubuntu 22.04 用に書かれていますが、サポートされている他のプラットフォームでも手順は同様です。

重要: 使用している Linux ホストプラットフォームが cgroups v2 を実行している場合、TPA を使用して Docker に展開している間、それを無効にし、cgroups v1 を有効にする必要があります。 cgroup v2 を確認するには、次を実行します。

```
mount | grep cgroup | head -1
```

しない場合、次の行が表示されます。`tmpfs on /sys/fs/cgroup type tmpfs`

次に、 cgroup v2 を無効にする必要があります。これを行うには、次を実行します。

```
echo GRUB_CMDLINE_LINUX=systemd.unified_cgroup_hierarchy=false | sudo tee /etc/
↪default/grub.d/cgroup.cfg
```

次に、 grub ブートローダーを更新し、次を実行してリブートします。

```
sudo update-grub
sudo reboot
```

TPA パッケージをインストールする

```
sudo apt install tpaexec
```

TPA の設定

次に、TPA の Python 環境を構成する TPA を構成する必要があります。次のコマンドで tpaexec を呼び出します setup

```
sudo /opt/EDB/TPA/bin/tpaexec setup
export PATH=$PATH:/opt/EDB/TPA/bin
```

export コマンドをシェルのプロファイルに追加できます。

TPA インストールのテスト

selftest を実行して、TPA が正しくインストールされたことを確認できます。

```
tpaexec selftest
``` TPA がインストールされました。

##  TPA を使用した PGD のインストール

###  構成ファイルの生成

:ref:`tpaexec configure <Deploying EDB Postgres Distributed using Trusted Postgres␣
↪Architect>` コマンドを実行して、構成フォルダーを生成します。

```shell-session
tpaexec configure democluster \
  --architecture PGD-Always-ON \
  --platform docker \
  --edb-postgres-advanced 15 \
  --redwood \
  --location-names dc1 \
```

(次のページに続く)

(前のページからの続き)

```
  --pgd-proxy-routing local \
  --no-git \
  --hostnames-unsorted
```

PGD-Always-ON アーキテクチャ `--architecture PGD-Always-ON` を指定します。これは、 PGD 5's Always On architectures の構成をセットアップします。デフォルトアーキテクチャの一部として、3 つのデータノードでクラスターを構成し、3 つの PGD Proxy サーバーと *Barman* をコホストします

バックアップ用のノード。

Docker `--platform docker` を使用していることを指定します。デフォルトでは、TPA は Rocky Linux をすべてのノードのデフォルトイメージとして構成します。

TPA の実行に使用しているのと同じプラットフォームに PGD を展開する必要がないことに注意してください。

データノードが Oracle 互換性`--redwood` を備えた EDB Postgres Advanced Server v15 `--edb-postgres-advanced 15` を実行することを指定します。

`--location-names` を使用して、ノードの概念的なロケーションを `dc1` に設定します。次に、プロキシルーティングが各ロケーション内のすべてのノードにトラフィックをルーティングできるように、`--pgd-proxy-routing` を `local` に設定します。

デフォルトでは、TPA は構成変更を Git リポジトリにコミットします。この例では、それをする必要がないため、`--no-git` フラグを渡します。

最後に、`--hostnames-unsorted` を渡すことにより、ノードの反復可能なホスト名を生成するように TPA に依頼します。それ以外の場合、適切なワードの事前定義されたリストからホスト名をランダムに選択します。

このコマンドは、現在の作業ディレクトリに `democluster` という名前のサブディレクトリを作成します。これには、TPA がクラスターの作成に使用する `config.yml` 構成ファイルが含まれています。次を使用して表示できます。

```
less democluster/config.yml
```

edb_notranlate_14 - *Deploying with TPA* の PGD-Always-ON 構成オプションの詳細

- Trusted Postgres Architect ドキュメントの *PGD-Always-ON* - Trusted Postgres Architect ドキュメントの *tpaexec configure* - Trusted Postgres Architect ドキュメントの *Docker platform*

クラスターのプロビジョニング

次に、

tpaexec provision コマンドを使用して作成した構成を実行するために必要なリソースを割り当てます。

```
tpaexec provision democluster
```

プラットフォームとして Docker を指定したため、TPA は Docker イメージ、コンテナ、ネットワークなどを作成します。

クラスターの展開

構成が配置され、インフラストラクチャがプロビジョニングされると、分散クラスターを *Deploying EDB Postgres Distributed using Trusted Postgres Architect* できるようになります。

```
tpaexec deploy democluster
```

TPA は構成を適用し、必要なパッケージをインストールし、実際の EDB Postgres 分散クラスターをセットアップします。

これで、SSH を使用してクラスターのノードのいずれかにログインし、データベースに接続する準備が整いました。構成プロセスの一部では、すべてのノードの SSH ログインをセットアップし、キーを完了します。SSH 構成を使用するには、前に `tpaexec configure` コマンドで作成した `democluster` ディレクトリにいる必要があります。

```
cd democluster
```

そこから、 `ssh -F ssh_config <hostname>` を実行して SSH 接続を確立できます。クラスター内の最初のデータベースノードである kaboom に接続します。

```
ssh -F ssh_config kaboom
__OUTPUT__
[root@kaboom ~]#
```

`kaboom` に `root` としてログインしていることに注意してください。

次に、enterprisedb ユーザーの ID を採用する必要があります。このユーザーは事前構成され、クラスターのノードに接続することが許可されています。

```
sudo -iu enterprisedb
__OUTPUT__
enterprisedb@kaboom:~ $
```

`psql` コマンドを実行して、`bdrdb` データベースにアクセスできるようになりました。

```
psql bdrdb
__OUTPUT__
psql (15.2.0, server 15.2.0)
Type "help" for help.

bdrdb=#
```

kaboom ノードで実行されている Postgres データベースに直接接続され、SQL コマンドの発行を開始できます。

SQL クライアントを終了するには、`exit` と入力します。

PGD CLI を使用する

PGD CLI としても知られる pgd ユーティリティを使用すると、 EDB Postgres 分散クラスターを制御および管理できます。ノードには既にインストールされています。

pgd check-health を実行することにより、クラスターの状態を確認できます。

```
pgd check-health
__OUTPUT__
Check      Status Message
- ----      ------ -------
ClockSkew  Ok     All BDR node pairs have clockskew within permissible limit
Connection Ok     All BDR nodes are accessible
Raft       Ok     Raft Consensus is working correctly
Replslots  Ok     All BDR replication slots are working correctly
Version    Ok     All nodes are running same BDR versions
enterprisedb@kaboom:~ $
```

または、 pgd show-nodes を使用して、クラスター内のデータ保持ノードを表示するように PGD に依頼できます。

```
pgd show-nodes
__OUTPUT__
Node   Node ID    Group        Type Current State Target State Status Seq ID
- ---   -------    -----        ---- ------------- ------------ ------ ------
kaboom 2710197610 dc1_subgroup data ACTIVE        ACTIVE       Up     1
kaftan 3490219809 dc1_subgroup data ACTIVE        ACTIVE       Up     3
kaolin 2111777360 dc1_subgroup data ACTIVE        ACTIVE       Up     2
enterprisedb@kaboom:~ $
```

同様に、 pgd show-proxies を使用してプロキシ接続ノードを表示します。

```
pgd show-proxies
__OUTPUT__
Proxy  Group        Listen Addresses Listen Port
- ----  -----        ---------------- -----------
kaboom dc1_subgroup [0.0.0.0]        6432
kaftan dc1_subgroup [0.0.0.0]        6432
kaolin dc1_subgroup [0.0.0.0]        6432
```

プロキシは、アプリケーションのデータノードのクラスターへの高可用性接続を提供します。psql -h kaboom,kaftan,kaolin -p 6432 bdrdb コマンドを使用して、プロキシに接続し、データベースに接続できます。

```
psql -h kaboom,kaftan,kaolin -p 6432 bdrdb
__OUTPUT__
psql (15.2.0, server 15.2.0)
```

(次のページに続く)

(前のページからの続き)

```
SSL connection (protocol: TLSv1.3, cipher: TLS_AES_256_GCM_SHA384, compression: off)
Type "help" for help.

bdrdb=#
```

クラスターを探索する

- *Connect to your database* からアプリケーションへ
- *Explore failover* 実践演習付き
- *Understand conflicts* 作成とモニタリング
- クラスターでの作業における *Next Steps with PGD*

4.4.2 Deploying an EDB Postgres Distributed example cluster on Linux hosts

TPA と PGD の紹介

私たちは、さまざまな Postgres 構成のインストールと管理を簡単に再現可能にするために TPA を作成しました。TPA は、Postgres の作成と展開を調整します。このクイックスタートでは、最初に TPA をインストールします。既に TPA をインストールしている場合、これらの手順をスキップできます。TPA を使用して、さまざまな構成の Postgres クラスターを展開できます。

PGD は、高いパフォーマンスと可用性を実現するように設計された Postgres のマルチマスター複製実装です。PGD のインストールは、TPA によって調整されます。TPA を使用して、PGD デモクラスターの構成ファイルを生成します。

TPA Linux ホストオプションを使用すると、クラウドまたは VM プラットフォームのユーザーが TPA を使用して EDB Postgres 分散を構成できます。TPA に必要なのは、ターゲットシステムを Linux オペレーティングシステムで構成し、SSH を使用してアクセスできることだけです。他の TPA プラットフォーム Docker および AWS とは異なり、Linux ホスト構成はターゲットマシンをプロビジョニングしません。展開する場所にそれらをプロビジョニングするのは自分自身です。

このクラスターは、Linux サーバーインスタンスを使用してクラスターのノードをホストします。ノードには、3 つの複製データベースノード、3 つのコホスト接続プロキシ、および 1 つのバックアップノードが含まれます。TPA は、必要な EDB Postgres 分散ソフトウェアと構成を各ノードにプロビジョニング、準備、および展開できます。

前提条件

Linux ホストを構成する

このクイックスタートには、4 つのホストをプロビジョニングする必要があります。各ホストには *supported Linux operating system* をインストールする必要があります。パスワードのプロンプトを排除するには、証明書キーペアを使用して各ホストに SSH アクセスできることも必要です。

どのクラウドまたは VM プラットフォームを使用するかにかかわらず、各インスタンスに SSH でアクセスでき、各インスタンスが他のインスタンスに接続できることを確認する必要があります。パブリックネットワークまたはクラウドプラットフォームの VPC を介して接続できます。オンプレミス VM のローカルネットワークを介して接続できます。

これができない場合は、Docker または AWS クイックスタートを検討することをお勧めします。これらの構成は、セットアップが簡単で、すぐに破棄します。たとえば、
Docker、*Linux* ホスト、または *AWS* クイックスタートの選択 は、コンピューティングインスタンスを自動的にプロビジョニングし、これらのインスタンスの VPC を作成します。

Host name	Public IP	Private IP
linuxhost-1	172.19.16.27	192.168.2.247
linuxhost-2	172.19.16.26	192.168.2.41
linuxhost-3	172.19.16.25	192.168.2.254
linuxhost-4	172.19.16.15	192.168.2.30

これらは IP アドレスの例です。クイックスタートを進めながら、これらを独自のパブリックおよびプライベート IP アドレスに置き換えます。

ホスト管理ユーザーを設定する

各マシンには、インストールに使用するユーザーアカウントが必要です。簡単にするために、すべてのホストで同じ名前のユーザーを使用します。各ホストで、パスワードの入力を求められずにホストに SSH で接続できるようにユーザーも構成します。そのユーザーにホストでの sudo 特権を必ず付与してください。4 つのホストでは、ユーザー rocky は既に sudo 特権で構成されています。

準備

EDB アカウント

TPA と PGD の両方をインストールするには EDB アカウントが必要です。

Sign up for a free EDB account

まだお持ちでない場合。サインアップすると、EDB のソフトウェアリポジトリのトライアルサブスクリプションが提供されます。

登録したら、 EDB Repos 2.0 ページに移動し、リポトークンを取得します。

このページに最初にアクセスしたときに、 **Request Access** を選択してリポトークンを生成します。 **Copy Token** アイコンを使用してトークンをコピーし、安全に保存します。

環境変数の設定

最初に、 EDB_SUBSCRIPTION_TOKEN 環境変数を *EDB アカウント* ステップで取得した EDB リポトークンの値に設定します。

```
export EDB_SUBSCRIPTION_TOKEN=<your-repo-token>
```

これを.bashrc スクリプトまたは同様のシェルプロファイルに追加して、常に設定されるようにできます。

リポジトリの構成

この例に必要なソフトウェアはすべて、EDB Postgres Distributed パッケージリポジトリから入手できます。スクリプトをダウンロードして実行して、EDB Postgres 分散リポジトリを構成します。このリポジトリには、TPA パッケージも含まれています。

```
curl -1sLf "https://downloads.enterprisedb.com/$EDB_SUBSCRIPTION_TOKEN/postgres_
↪distributed/setup.deb.sh" | sudo -E bash
``` ## Trusted Postgres ArchitectTPA のインストール

TPA を使用して、PGD をプロビジョニングおよび展開します。以前に TPA をインストールしている場合は、
 :ref:`Next Steps with PGD <Next Steps with PGD>` に進むことができます。 TPA をインストールするための完全な手順については、 :ref:`Trusted Postgres Architect documentation
↪<Deploying EDB Postgres Distributed using Trusted Postgres Architect>` にあります。これもここに含まれています。

Linux 環境

ホストプラットフォームとしての :ref:`TPA supports several distributions of Linux
↪<Deploying EDB Postgres Distributed using Trusted Postgres Architect>` 。これらの例は、Ubuntu 22.04 用に書かれていますが、サポートされている他のプラットフォームでも手順は同様です。

TPA パッケージをインストールする

```shell
sudo apt install tpaexec
```

TPA の設定

次に、TPA の Python 環境を構成する TPA を構成する必要があります。次のコマンドで tpaexec を呼び出します setup

```
sudo /opt/EDB/TPA/bin/tpaexec setup
export PATH=$PATH:/opt/EDB/TPA/bin
```

export コマンドをシェルのプロファイルに追加できます。

TPA インストールのテスト

selftest を実行して、TPA が正しくインストールされたことを確認できます。

```
tpaexec selftest
``` TPA がインストールされました。

##  TPA を使用した PGD のインストール

###  構成ファイルの生成

:ref:`tpaexec configure <Deploying EDB Postgres Distributed using Trusted Postgres␣
↪Architect>` コマンドを実行して、構成フォルダーを生成します。
```

tpaexec configure democluster

–architecture PGD-Always-ON

–platform bare

–edb-postgres-advanced 15

–redwood

–no-git

–location-names dc1

–pgd-proxy-routing local

–hostnames-unsorted

```
PGD-Always-ON アーキテクチャ `--architecture PGD-Always-ON` を指定します。これは、
 :ref:`PGD 5's Always On architectures <Choosing your architecture>` の構成をセットアップします。デフォルトアーキテクチャの一部として、3 つのデータノードでクラスターを構成し、3 つの␣
↪`PGD Proxy <https://www.enterprisedb.com/docs/pgd/latest/routing/proxy/>`_ サーバーとバックアップ用の :ref:`Barman <Backup and recovery>` ノードをコホストします。

Linux ホストの場合、「ベア」プラットフォーム `--platform bare` をターゲットとしていることを指定します。 TPA は、展開中に各ホストで実行されている Linux バージョンを決定します。サポートされ
```

(次のページに続く)
```

(前のページからの続き)

```
ているオペレーティングシステムの詳細については、 :ref:`the EDB Postgres Distributed␣
↪compatibility table <Compatibility changes>` を参照してください。

データノードが Oracle 互換性 `--redwood` を備えた `EDB Postgres Advanced Server v15
↪<https://www.enterprisedb.com/docs/epas/latest/>`_ `--edb-postgres-advanced 15` を
実行することを指定します。

`--location-names` を使用して、ノードの概念的なロケーションを `dc1` に設定します。次に、プロ
キシルーティングが各ロケーション内のすべてのノードにトラフィックをルーティングできるように、␣
↪`--pgd-proxy-routing` を `local` に設定します。

デフォルトでは、TPA は構成変更を Git リポジトリにコミットします。この例では、それをする必要がな
いため、`--no-git` フラグを渡します。

最後に、 `--hostnames-unsorted` を渡すことにより、ノードの反復可能なホスト名を生成するように
TPA に依頼します。それ以外の場合、適切なワードの事前定義されたリストからホスト名をランダムに選
択します。

このコマンドは、現在の作業ディレクトリに `democluster` という名前のサブディレクトリを作成しま
す。これには、TPA がクラスターの作成に使用する `config.yml` 構成ファイルが含まれています。次を
使用して表示できます。

```shell
less democluster/config.yml
```

次に、構成ファイルを編集して、管理ユーザー名、パブリックおよびプライベート IP アドレスなど、Linux ホストに関連する詳細を追加する必要があります。

構成の編集

好みのエディターを使用して、democluster/config.yml を開きます。

ansible_user: root を含む行を検索します。 root を、SSH アクセスと sudo 特権で構成したユーザーの名前に変更します。これに次の行を続けます。

```
manage_ssh_hostkeys: yes
```

instance_defaults セクションは次のようになります。

edb_notranlate_8 次に、最初のノード kaboom の構成設定である node: 1 を検索します。

node: 1 行の後に、ノードのパブリックおよびプライベート IP アドレスを追加します。このノードのホストとして linuxhost-1 を使用します。次をファイルに追加し、IP アドレスを置き換えます。各行の先頭を node: 行の先頭に位置合わせします。
```

```
public_ip: 172.19.16.27
private_ip: 192.168.2.247
```

kaboom のエントリ全体は次のようになりますが、独自の IP アドレスを使用します。

```
- Name: kaboom
  backup: kapok
  location: dc1
  node: 1
  public_ip: 172.19.16.27
  private_ip: 192.168.2.247
  role:
  - bdr
  - pgd-proxy
  vars:
    bdr_child_group: dc1_subgroup
    bdr_node_options:
      route_priority: 100
``` 他の 3 つのノードに対してこのプロセスを繰り返します。

ノード kaftan の構成設定である `node: 2` を検索します。このノードには `linuxhost-2` を使用します。 IP アドレスを置き換えて、次を追加します。

```yaml
  public_ip: 172.19.16.26
  private_ip: 192.168.2.41
```

ノード kaolin の構成設定である node: 3 を検索します。このノードには linuxhost-3 を使用します。IP アドレスを置き換えて、次を追加します。

```
public_ip: 172.19.16.25
private_ip: 192.168.2.254
```

最後に、ノード kapok の構成設定である node: 4 を検索します。このノードには linuxhost-4 を使用します。IP アドレスを置き換えて、次を追加します。

```
public_ip: 172.19.16.15
private_ip: 192.168.2.30
```

クラスターのプロビジョニング

次を実行できるようになりました。

```
tpaexec provision democluster
```

このコマンドは、クラスターを展開する準備をします。Docker や AWS などの他のプラットフォームでは、このコマンドは必要なホストも作成します。Linux ホストを使用する場合、ホストは既に構成されている必要があります。

Linux ホストのこのプロセスの一部は、後で SSH 操作のためのホストのキーペアを作成することです。これらのキーペアを作成したら、キーペアの公開部分をホストにコピーする必要があります。これは、ssh-copy-id で行うことができ、デモクラスター ID -i と各ホストへのログインを提供します。この例では、これらは次のコマンドです。

```
ssh-copy-id -i democluster/id_democluster rocky@172.19.16.27
ssh-copy-id -i democluster/id_democluster rocky@172.19.16.26
ssh-copy-id -i democluster/id_democluster rocky@172.19.16.25
ssh-copy-id -i democluster/id_democluster rocky@172.19.16.15
```

tpa_known_hosts ファイルを作成できるようになりました。これにより、ホストを検証できます。各ホスト-H で ssh-keyscan を使用し、その出力を tpa_known_hosts に追加します。

```
ssh-keyscan -H 172.19.16.27 >> democluster/tpa_known_hosts
ssh-keyscan -H 172.19.16.26 >> democluster/tpa_known_hosts
ssh-keyscan -H 172.19.16.25 >> democluster/tpa_known_hosts
ssh-keyscan -H 172.19.16.15 >> democluster/tpa_known_hosts
```

クラスターを展開する

これで、クラスターを展開する準備がすべて整いました。デプロイするには、次を実行します。

```
tpaexec deploy democluster
```

TPA は構成を適用し、必要なパッケージをインストールし、実際の EDB Postgres 分散クラスターをセットアップします。

クラスターへの接続

これで、SSH を使用してクラスターのノードのいずれかにログインし、データベースに接続する準備が整いました。構成プロセスの一部では、すべてのノードの SSH ログインをセットアップし、キーを完了します。SSH 構成を使用するには、前に tpaexec configure コマンドで作成した democluster ディレクトリにいる必要があります。

```
cd democluster
```

そこから、 ssh -F ssh_config <hostname> を実行して SSH 接続を確立できます。クラスター内の最初のデータベースノードである kaboom に接続します。

```
ssh -F ssh_config kaboom
__OUTPUT__
[rocky@kaboom ~]#
```

kaboom に、以前に構成した管理ユーザーと ansible ユーザーである rocky としてログインしていることに注意してください。

次に、enterprisedb ユーザーの ID を採用する必要があります。このユーザーは事前構成され、クラスターのノードに接続することが許可されています。

```
sudo -iu enterprisedb
__OUTPUT__
enterprisedb@kaboom:~ $
```

psql コマンドを実行して、bdrdb データベースにアクセスできるようになりました。

```
psql bdrdb
__OUTPUT__
psql (15.2.0, server 15.2.0)
Type "help" for help.

bdrdb=#
```

kaboom ノードで実行されている Postgres データベースに直接接続され、SQL コマンドの発行を開始できます。

SQL クライアントを終了するには、exit と入力します。

PGD CLI を使用する

PGD CLI としても知られる pgd ユーティリティを使用すると、 EDB Postgres 分散クラスターを制御および管理できます。ノードには既にインストールされています。

pgd check-health を実行することにより、クラスターの状態を確認できます。

```
pgd check-health
__OUTPUT__
Check      Status Message
- ----      ------ -------
ClockSkew  Ok     All BDR node pairs have clockskew within permissible limit
Connection Ok     All BDR nodes are accessible
Raft       Ok     Raft Consensus is working correctly
Replslots  Ok     All BDR replication slots are working correctly
Version    Ok     All nodes are running same BDR versions
enterprisedb@kaboom:~ $
```

または、 pgd show-nodes を使用して、クラスター内のデータ保持ノードを表示するように PGD に依頼できます。

```
pgd show-nodes
__OUTPUT__
Node    Node ID    Group        Type Current State Target State Status Seq ID
- ---    --------    -----        ---- ------------- ------------ ------ ------
kaboom 2710197610 dc1_subgroup data ACTIVE        ACTIVE       Up     1
kaftan 3490219809 dc1_subgroup data ACTIVE        ACTIVE       Up     3
kaolin 2111777360 dc1_subgroup data ACTIVE        ACTIVE       Up     2
enterprisedb@kaboom:~ $
```

同様に、 pgd show-proxies を使用してプロキシ接続ノードを表示します。

```
pgd show-proxies
__OUTPUT__
Proxy  Group        Listen Addresses Listen Port
- ----  -----        ---------------- -----------
kaboom dc1_subgroup [0.0.0.0]        6432
kaftan dc1_subgroup [0.0.0.0]        6432
kaolin dc1_subgroup [0.0.0.0]        6432
```

プロキシは、アプリケーションのデータノードのクラスターへの高可用性接続を提供します。psql -h kaboom,kaftan,kaolin -p 6432 bdrdb コマンドを使用して、プロキシに接続し、データベースに接続できます。

```
psql -h kaboom,kaftan,kaolin -p 6432 bdrdb
__OUTPUT__
psql (15.2.0, server 15.2.0)
SSL connection (protocol: TLSv1.3, cipher: TLS_AES_256_GCM_SHA384, compression: off)
Type "help" for help.

bdrdb=#
```

クラスターを探索する

- *Connect to your database* からアプリケーションへ
- *Explore failover* 実践演習付き
- *Understand conflicts* 作成とモニタリング
- クラスターでの作業における *Next Steps with PGD*

4.4.3 Deploying an EDB Postgres Distributed example cluster on AWS

このクイックスタートでは、Amazon EC2 を使用して Always On Single Location アーキテクチャで EDB Postgres 分散をセットアップします。

TPA と PGD の紹介

私たちは、さまざまな Postgres 構成のインストールと管理を簡単に再現可能にするために TPA を作成しました。TPA は、Postgres の作成と展開を調整します。このクイックスタートでは、最初に TPA をインストールします。既に TPA をインストールしている場合、これらの手順をスキップできます。TPA を使用して、さまざまな構成の Postgres クラスターを展開できます。

PGD は、高いパフォーマンスと可用性を実現するように設計された Postgres のマルチマスター複製実装です。PGD のインストールは、TPA によって調整されます。TPA を使用して、PGD デモクラスターの構成ファイルを生成します。このクラスターは Amazon EC2 インスタンスを使用します

バックアップ用のノード。次に、TPA を使用して、必要な構成とソフトウェアを各ノードにプロビジョニングおよび展開できます。

準備

注釈: このセットの手順は、Intel / AMD プロセッサー上の Ubuntu 22.04 LTS 専用です。 !!!

EDB アカウント

TPA と PGD の両方をインストールするには、EDB アカウントが必要です。

> Sign up for a free EDB account

まだお持ちでない場合。サインアップすると、EDB のソフトウェアリポジトリのトライアルサブスクリプションが提供されます。

登録したら、 EDB Repos 2.0 ページに移動し、リポトークンを取得します。

このページに最初にアクセスしたときに、 **Request Access** を選択してリポトークンを生成します。 **Copy Token** アイコンを使用してトークンをコピーし、安全に保存します。

カールのインストール

curl コマンドを使用して、リポジトリからインストールスクリプトを取得します。Ubuntu では、curl はデフォルトではインストールされません。存在するかどうかを確認するには、ターミナルで curl を実行します。

```
$ curl
Command curl not found, but can be installed with:
sudo apt install curl
```

見つからない場合は、次を実行します。

```
sudo apt -y install curl
```

環境変数の設定

最初に、 EDB_SUBSCRIPTION_TOKEN 環境変数を *EDB アカウント* ステップで取得した EDB リポトークンの値に設定します。

```
export EDB_SUBSCRIPTION_TOKEN=<your-repo-token>
```

これを.bashrc スクリプトまたは同様のシェルプロファイルに追加して、常に設定されるようにできます。

リポジトリの構成

この例に必要なソフトウェアはすべて、EDB Postgres Distributed パッケージリポジトリから入手できます。次のコマンドは、 EDB Postgres 分散リポジトリを構成するスクリプトをダウンロードして実行します。このリポジトリには、TPA パッケージも含まれています。

```
curl -1sLf "https://downloads.enterprisedb.com/$EDB_SUBSCRIPTION_TOKEN/postgres_
↪distributed/setup.deb.sh" | sudo -E bash
```

edb_notranlate_4 出力またはエラーが生成されない場合は、トークンを正しく入力したことを再確認します。問題が解決しない場合は、

> contact Support サポートしてください。

Trusted Postgres ArchitectTPA のインストール

TPA を使用して、PGD をプロビジョニングおよび展開します。以前に TPA をインストールしている場合、
Next Steps with PGD に進むことができます。

TPA をインストールするための完全な手順については、 *Trusted Postgres Architect documentation* にあります。これもここに含まれています。

Linux 環境

ホストプラットフォームとしての *TPA supports several distributions of Linux* これらの例は、Ubuntu 22.04 用に書かれていますが、サポートされている他のプラットフォームでも手順は同様です。

TPA パッケージをインストールする

```
sudo apt install tpaexec
```

TPA の設定

TPA の Python 環境を構成する TPA を構成する必要があります。次のコマンドで tpaexec を呼び出します setup

```
sudo /opt/EDB/TPA/bin/tpaexec setup
export PATH=$PATH:/opt/EDB/TPA/bin
```

export コマンドをシェルのプロファイルに追加できます。

TPA インストールのテスト

selftest を実行して、TPA が正しくインストールされたことを確認できます。

```
tpaexec selftest
``` TPA がインストールされました。

###  AWS CLI

TPA は、AWS CLI を使用してプロビジョニングと展開を行います。 `Install the CLI <https://
↪docs.aws.amazon.com/cli/latest/userguide/getting-started-install.html>`_ 、十分なアクセス権限を持つ IAM ユーザーの場合は `configure credentials <https://docs.aws.amazon.com/
↪cli/latest/userguide/cli-configure-files.html>`_ 。 :ref:`TPA AWS platform
↪<Deploying EDB Postgres Distributed using Trusted Postgres Architect>` は、必要な権限の詳細を示します。

##  TPA を使用した PGD のインストール

###  構成ファイルの生成

:ref:`tpaexec configure <Deploying EDB Postgres Distributed using Trusted Postgres␣
↪Architect>` コマンドを実行して、構成フォルダーを生成します。

```shell-session
tpaexec configure democluster \
```

(次のページに続く)

(前のページからの続き)

```
  --architecture PGD-Always-ON \
  --platform aws \
  --region eu-west-1 \
  --edb-postgres-advanced 15 \
  --redwood \
  --location-names dc1 \
  --pgd-proxy-routing local \
  --no-git \
  --hostnames-unsorted
```

PGD-Always-ON アーキテクチャ `--architecture PGD-Always-ON` を指定します。これは、

> *PGD 5's Always On architectures* の構成をセットアップします。デフォルトアーキテクチャの一部として、これは 3 つのデータノードでクラスターを構成し、3 つの *HARP* から *PGD* プロキシへの移動 サーバーとバックアップ用の *Barman* ノードをコホストします。

AWS `--platform aws` と eu-west-1 をリージョン `--region eu-west-1` として使用していることを指定します。

TPA は、AWS の t3.micro インスタンスにデフォルトします。このデモにはこれで十分であり、
AWS free tier アカウントでの使用にも適しています。

デフォルトでは、TPA は AWS のすべてのノードのデフォルト OS として Debian を構成します。

TPA の実行に使用しているのと同じプラットフォームに PGD を展開する必要がないことに注意してください。

データノードが Oracle 互換性`--redwood` を備えた EDB Postgres Advanced Server v15 `--edb-postgres-advanced 15` を実行することを指定します。

`--location-names` を使用して、ノードの概念的なロケーションを `dc1` に設定します。次に、プロキシルーティングが各ロケーション内のすべてのノードにトラフィックをルーティングできるように、`--pgd-proxy-routing` を `local` に設定します。

デフォルトでは、TPA は構成変更を Git リポジトリにコミットします。この例では、それをする必要がないため、`--no-git` フラグを渡します。

最後に、`--hostnames-unsorted` を渡すことにより、ノードの反復可能なホスト名を生成するように TPA に依頼します。それ以外の場合、適切なワードの事前定義されたリストからホスト名をランダムに選択します。

このコマンドは、現在の作業ディレクトリに `democluster` という名前のサブディレクトリを作成します。これには、TPA がクラスターの作成に使用する `config.yml` 構成ファイルが含まれています。次を使用して表示できます。

```
less democluster/config.yml
```

edb_notranlate_10 - *Deploying with TPA* の PGD-Always-ON 構成オプションの詳細

- Trusted Postgres Architect ドキュメントの *PGD-Always-ON* - Trusted Postgres Architect ドキュメントの *tpaexec configure* - Trusted Postgres Architect ドキュメントの *AWS platform*

クラスターのプロビジョニング

次に、

tpaexec provision コマンドを使用して作成した構成を実行するために必要なリソースを割り当てます。

```
tpaexec provision democluster
```

プラットフォームデフォルトプラットフォームとして AWS を指定したため、TPA は EC2 インスタンス、VPC、サブネット、ルーティングテーブル、インターネットゲートウェイ、セキュリティグループ、EBS ボリューム、Elastic IP などをプロビジョニングします。

構成時に既存のバケットを指定しなかったため、TPA は S3 バケットの作成を確認するように求めます。

クラスターの展開

構成が配置され、インフラストラクチャがプロビジョニングされると、分散クラスターを *Deploying EDB Postgres Distributed using Trusted Postgres Architect* できるようになります。

```
tpaexec deploy democluster
```

TPA は構成を適用し、必要なパッケージをインストールし、実際の EDB Postgres 分散クラスターをセットアップします。

クラスターへの接続

これで、SSH を使用してクラスターのノードのいずれかにログインし、データベースに接続する準備が整いました。構成プロセスの一部では、すべてのノードの SSH ログインをセットアップし、キーを完了します。SSH 構成を使用するには、前に `tpaexec configure` コマンドで作成した `democluster` ディレクトリにいる必要があります。

```
cd democluster
```

そこから、 `ssh -F ssh_config <hostname>` を実行して SSH 接続を確立できます。クラスター内の最初のデータベースノードである kaboom に接続します。

```
ssh -F ssh_config kaboom
__OUTPUT__
[admin@kaboom ~]#
```

kaboom に管理者としてログインしていることに注意してください。

次に、enterprisedb ユーザーの ID を採用する必要があります。このユーザーは事前構成され、クラスターのノードに接続することが許可されています。

```
sudo -iu enterprisedb
__OUTPUT__
enterprisedb@kaboom:~ $
```

psql コマンドを実行して bdrdb データベースにアクセスできるようになりました。

```
psql bdrdb
__OUTPUT__
psql (15.2.0, server 15.2.0)
Type "help" for help.

bdrdb=#
```

kaboom ノードで実行されている Postgres データベースに直接接続され、SQL コマンドの発行を開始できます。

SQL クライアントを終了するには、exit と入力します。

PGD CLI を使用する

PGD CLI としても知られる pgd ユーティリティを使用すると、 EDB Postgres 分散クラスターを制御および管理できます。ノードには既にインストールされています。

pgd check-health を実行することにより、クラスターの状態を確認できます。

```
pgd check-health
__OUTPUT__
Check      Status Message
- ----      ------ -------
ClockSkew  Ok     All BDR node pairs have clockskew within permissible limit
Connection Ok     All BDR nodes are accessible
Raft       Ok     Raft Consensus is working correctly
Replslots  Ok     All BDR replication slots are working correctly
Version    Ok     All nodes are running same BDR versions
enterprisedb@kaboom:~ $
```

または、 pgd show-nodes を使用して、クラスター内のデータ保持ノードを表示するように PGD に依頼できます。

```
pgd show-nodes
__OUTPUT__
Node   Node ID    Group        Type Current State Target State Status Seq ID
- ---   -------    -----        ---- ------------- ------------ ------ ------
kaboom 2710197610 dc1_subgroup data ACTIVE        ACTIVE       Up     1
kaftan 3490219809 dc1_subgroup data ACTIVE        ACTIVE       Up     3
kaolin 2111777360 dc1_subgroup data ACTIVE        ACTIVE       Up     2
enterprisedb@kaboom:~ $
```

同様に、 pgd show-proxies を使用してプロキシ接続ノードを表示します。

```
pgd show-proxies
__OUTPUT__
Proxy  Group        Listen Addresses Listen Port
- ----  -----        ---------------- -----------
kaboom dc1_subgroup [0.0.0.0]        6432
kaftan dc1_subgroup [0.0.0.0]        6432
kaolin dc1_subgroup [0.0.0.0]        6432
```

プロキシは、アプリケーションのデータノードのクラスターへの高可用性接続を提供します。psql -h kaboom,kaftan,kaolin -p 6432 bdrdb コマンドを使用して、プロキシに接続し、データベースに接続できます。

```
psql -h kaboom,kaftan,kaolin -p 6432 bdrdb
__OUTPUT__
psql (15.2.0, server 15.2.0)
SSL connection (protocol: TLSv1.3, cipher: TLS_AES_256_GCM_SHA384, compression: off)
Type "help" for help.

bdrdb=#
```

クラスターを探索する

- *Connect your database* からアプリケーションへ
- *Explore failover* 実践演習付き
- *Understand conflicts* 作成とモニタリング
- クラスターでの作業における *Next Steps with PGD*

4.4.4 Deploying an EDB Postgres Distributed example cluster on Azure and Google cloud platforms

Azure および Google クラウドへの展開

Azure や Google Cloud Platform などのほとんどのクラウドプラットフォームでは、使用しているクラウドプラットフォームに Linux ホストを作成します。

Deploying on Linux hosts クイックスタートを使用して、これらの Linux ホストに PGD を展開できます。

- Azure ユーザーは、Linux がロードされた Azure VM をプロビジョニングする方法について a Microsoft guide をフォローできます。
- Google Cloud Platform ユーザーは、Linux をロードした GCP VM をプロビジョニングする方法について a Google guide をフォローできます。

Deploying on Linux hosts に進みます

- AWS ユーザーは *Deploying on AWS* クイックスタートに移動する必要があります。ここでは、TPA がクラスターを作成するために必要なホストを自動的にプロビジョニングします。

4.4.5 Connecting to your database

アプリケーションの接続、または新しい EDB Postgres 分散クラスターへのリモート接続には、以下が含まれます。

*資格情報の取得とオプションで.pgpass ファイルの作成

- 接続する PGD プロキシホストの IP アドレスの確立

*その IP アドレスに接続できることの確認

*適切な Postgres クライアントの取得

- クライアントをクラスターに接続する

資格情報の取得

デフォルトユーザーの enterprisedb は、tpaexec によってクラスターに作成されました。また、プロビジョニングの一部として、そのユーザーのパスワードも生成しました。パスワードを取得するには、次を実行します。

```
tpaexec show-password democluster enterprisedb
```

このコマンドは、enterprisedb ユーザーのパスワードである文字列を結果ます。必要に応じて、パスワードの入力を求められたときにその文字列を使用できます。

.pgpass ファイルの作成

ホームディレクトリに a `.pgpass file <Monitoring through SQL>` を作成することにより、psql およびその他の Postgres クライアントのパスワードの入力を回避できます。これには、接続時にアプリケーションが検索できるパスワードの詳細が含まれています。パスワードを取得した後

資格情報の取得 を参照して、好みのエディターを使用して.pgpass

ファイルを開くことができます。

ファイルに、次のように入力します。

```
*:* :bdrdb:enterprisedb:<your password>
```

ファイルを保存してエディターを終了します。ファイルを保護するには、次のコマンドを実行します。このコマンドは、自分自身にのみ読み取りおよび書き込みアクセスを付与します。

```
chmod 0600 ~/.pgpass
```

IP アドレスの確立

Docker

Docker クイックスタートクラスターは、デフォルトで、IP アドレス 172.17.0.2kaboom、172.17.0.3kaftan、172.17.04kaolin、および 172.17.0.5kapok でアクセスできます。Docker はこれらのアドレスを生成します。

AWS

democluster/ssh_config の IP アドレスを参照できます。または、次を実行します。

```
aws ec2 --region eu-west-1 describe-instances --query Reservations[ *].Instances[* ].
↪{PublicIpAddress:PublicIpAddress,Name:Tags[?Key==`Name`]|[0].Value}
__OUTPUT__
[
    [
        {
            "PublicIpAddress": "54.217.130.13",
            "Name": "kapok"
        }
    ],
    [
        {
            "PublicIpAddress": "54.170.119.101",
            "Name": "kaolin"
        }
    ],
    [
        {
            "PublicIpAddress": "3.250.235.130",
            "Name": "kaftan"
        }
    ],
    [
        {
            "PublicIpAddress": "34.247.188.211",
            "Name": "kaboom"
        }
    ]
]
```

このコマンドは、クラスターインスタンスの EC2 のパブリック IP アドレスのリストを表示します。

Linux ホスト

クイックスタートでクラスターを構成するときに、Linux サーバーの IP アドレスを設定します。それらのアドレスを使用します。

IP アドレスに接続できることを確認します

Linux ホストと Docker

これらを接続するための構成を実行する必要はありません。

AWS

AWS は、SSH エンドポイントへの外部アクセスのみを許可するように構成されています。Postgres クライアントが AWS クラウドの外部から接続できるようにするには、ポート 6432 でのトラフィックの転送を有効にする必要があります。

独自の外部 IP アドレス、またはクラスターに接続するシステムの外部 IP アドレスを取得します。これを行う 1 つの方法は、次を実行することです。

```
curl https://checkip.amazonaws.com
__OUTPUT__
89.97.100.108
```

クラスターのセキュリティグループ ID も必要です。実行します

```
aws ec2 --region eu-west-1 describe-security-groups --filter Name=group-name,Values="␣
↪*democluster* " | grep GroupId
__OUTPUT__
            "GroupId": "sg-072f996360ba20d5c",
```

クラスターの正しいリージョンを入力します。これは、構成時に設定したものです。

```
aws ec2 authorize-security-group-ingress --group-id <SECURITYGROUPID> --protocol tcp -
↪-port 6432 --cidr <YOURIP>/32 --region eu-west-1
```

繰り返しますが、クラスターに正しいリージョンを入力していることを確認します。

このコマンドの詳細については、AWS CLI ガイドの Add rules to your security group で読むことができます。

適切な Postgres クライアントの取得

ローカルシステムに Postgres をインストールしていない限り、おそらく psql などのクライアントアプリケーションをインストールして、データベースクラスターに接続する必要があります。

たとえば、Ubuntu では、次のことを実行できます。

```
sudo apt install postgresql-client
```

このコマンドは、 psql および他のツールをインストールしますが、Postgres データベースをローカルにインストールしません。

クライアントをクラスターに接続する

psql または同様のクライアントをインストールした後、クラスターに接続できます。実行します

```
  psql -h <ipaddressofnode> -p 6432 -U enterprisedb bdrdb
  __OUTPUT__
  psql (15.2, server 15.2.0 (Debian 15.2.0-2.buster))
  SSL connection (protocol: TLSv1.3, cipher: TLS_AES_256_GCM_SHA384, bits: 256,␣
↪compression: off)
  Type "help" for help.

  bdrdb=#
```

:ref:`Use the `.pgpass` file <#creating-a-pgpass-file>` をサポートするクライアントと接続するか、ホスト、ポート、ユーザー、パスワード、およびデータベース名を使用して他のアプリケーションに接続します。

プロキシフェイルオーバーを使用してクライアントをクラスターに接続する

プロキシのすべてのアドレスをホストとしてリストすることにより、プロキシに障害が発生した場合にクライアントが常にフェールオーバーし、最初に使用可能なプロキシに接続するように保証できます。

```
psql -h <ipaddressofnode1>,<ipaddressofnode2>,<ipaddressofnode3> -U enterprisedb -p␣
↪6432 bdrdb
__OUTPUT__
psql (15.2, server 15.2.0 (Debian 15.2.0-2.buster))
SSL connection (protocol: TLSv1.3, cipher: TLS_AES_256_GCM_SHA384, bits: 256,␣
↪compression: off)
Type "help" for help.

bdrdb=#
```

接続 URL の作成

多くのアプリケーションは、

Connection URL を使用してデータベースに接続します。接続 URL を作成するには、次の形式で文字列をアセンブルする必要があります。

```
postgresql://<user>@<ipaddressofnode1>:6432,<ipaddressofnode2>:6432,<ipaddressofnode3>
↪:6432/bdrdb
```

このフォーマットの文字列は `psql` コマンドで使用できるため、データベースノードが IP アドレス 192.168.9.10、192.168.10.10 および 192.168.10.11 上にある場合、次を使用できます。

```
psql postgresql://enterprisedb@192.168.9.10:6432,192.168.10.10:6432,192.168.11.
↪10:6432/bdrdb
```

作成した URL にパスワードを埋め込むこともできます。enterprisedb ユーザーを使用し、enterprisedb ユーザーのパスワードが `notasecret` である場合、URL は次のようになります。

```
psql postgresql://enterprisedb:notasecret@192.168.9.10:6432,192.168.10.10:6432,192.
↪168.11.10:6432/bdrdb
```

実際のパスワードはそれより複雑で、特殊文字が含まれる場合があります。パスワードを url コード化して、使用しているシェル、コマンド、またはドライバーをトリップしないことを確認する必要があります。

Java 接続 URL の作成

最後に、作成した URL は多くの Postgres アプリケーションとクライアントに適していますが、Java ベースのものは、Java が適切なドライバーを呼び出せるように 1 つの変更を必要とします。URL の前に `jdbc:` を付けて、Java 互換の URL を作成します。

```
jdbc:postgresql://enterprisedb@192.168.9.10:6432,192.168.10.10:6432,192.168.11.
↪10:6432/bdrdb
```

Moving On

これで、必要なすべての接続資格情報と URL を使用して、アプリケーションをクラスターに接続する準備が整いました。

4.4.6 Exploring failover handling with PGD

高可用性クラスターでは、フェールオーバー機能がクラスター全体の復元力にとって重要です。リードデータノードが何らかの理由で動作を停止した場合、アプリケーションはほとんどまたはまったく中断せずにデータベースでの作業を継続できる必要があります。PGD の場合、それはアプリケーションを新しいリードデータノードに転送することを意味します。これは、自動的に引き継ぎます。ここで PGD プロキシが役立ちます。クラスターと連携し、トラフィックをリードデータノードに自動的に転送します。

この演習では、データベースにデータを定期的に送信するアプリケーションを作成します。次に、PGD CLI を介して変更を要求することにより、リードデータノードをソフトに切り替えます。次に、データベースインスタンスを強制的にシャットダウンし、PGD がそれを処理する方法を確認します。

すぐに始められる構成

この探索では、*quick start for Docker* 、*quick start for AWS* または *quick start for Linux hosts* を使用して PGD クラスターを作成したことを前提としています。

各クイックスタートの最後に、4 つのノードと次のロールを含むクラスターが作成されます。

Host name	Host role
kaboom	PGD data node and pgd-proxy co-host
kaftan	PGD data node and pgd-proxy co-host
kaolin	PGD data node and pgd-proxy co-host
kapok	Barman backup node

この演習では、これらのホスト名を使用します。

xpanes のインストール

xpanes は、簡単に切り替えることができる複数のターミナルセッションをすばやく作成できるユーティリティを使用します。デフォルトではインストールされないため、インストールする必要があります。この演習では、tpaexec を実行してクイックスタートクラスターを構成したシステムから xpanes を起動します。

システムが Ubuntu を実行している場合は、これを実行します。

```
sudo apt install software-properties-common
sudo add-apt-repository ppa:greymd/tmux-xpanes
sudo apt update
sudo apt install tmux-xpanes
```

これらは、 the xpanes repository からのインストール手順です。Ubuntu を使用していない場合、リポジトリには他のシステムのインストール手順も含まれています。

4 つのサーバーに接続する

xpanes がインストールされている場合、次を実行して 4 つのサーバーすべてとの SSH セッションを作成できます。

```
cd democluster
xpanes -d -c "ssh -F ssh_config {}" "kaboom" "kaolin" "kaftan" "kapok"
```

これらのコマンドを実行すると、4 つのペインが表示されます。4 つのペインは kaboom、kaolin、kaftan、および kapok に接続され、それぞれに root ユーザーとしてログインしています。この特権は、運動中に後でサービスを簡単に停止および開始できるようにするために必要です。

Control-b に続いて **q** を押して、各ペインの数値を一時的に表示します。

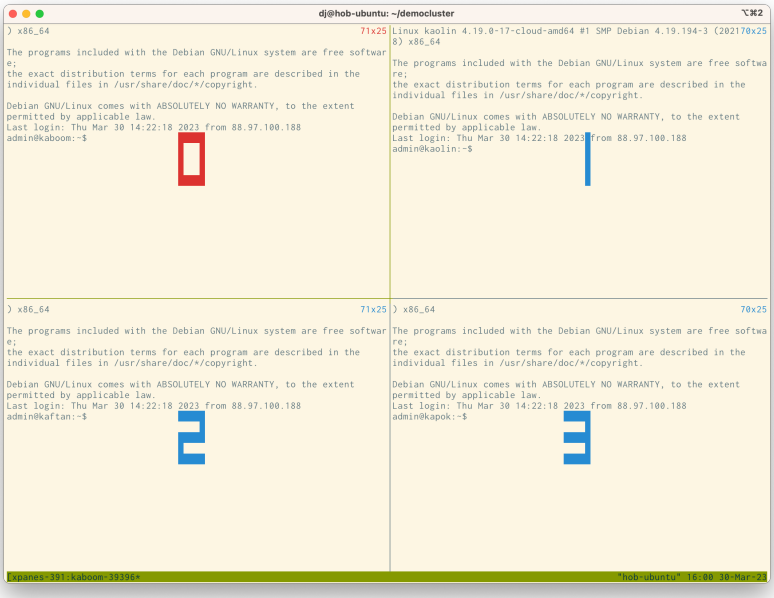


図 1: 4 SSH Sessions showing numbers

ペイン間でフォーカスを切り替えるには、 **Control-b** とカーソルキーを使用してペイン間を移動できます。または、 **Control-b** に続いて **q** とフォーカスするペインの番号を使用できます。両方の方法を紹介します。

Control-b &darr を使用します Control-b → または **Control-b q 3** は、カポックホストである右下のペインにフォーカスを移動します。このサーバーは、バックアップを実行します。これを、デモアプリケーションの操作のベースとして使用します。Barman 資格情報を使用して、データベースサーバーとプロキシに接続できます。

```
sudo -iu barman
psql -h kaboom -p 6432 bdrdb
```

このコードは、kaboom ホスト上のプロキシに接続します。これも、クラスターの一部として Postgres インスタンスを実行します。

次のステップは、アプリケーションが書き込むテーブルを作成することです。

```
drop table if exists ping cascade;
CREATE TABLE ping (id SERIAL PRIMARY KEY, node TEXT, timestamp TEXT) ;
```

このコードは、最初に ping テーブルをドロップします。次に、ID 主キーと、ノードとタイムスタンプの 2 つのテキストフィールドを使用して ping テーブルを再作成します。これで、テーブルの準備が整ったはずです。確認するには、**Control-b ←を使用します。 Control-b ↑** または **Control-b q 0** を押して左上のペインに移動し、kaboom サーバーに移動します。このペインで、enterprisedb ユーザーになるように、データベースに簡単に接続できます。

```
sudo -iu enterprisedb
```

次を実行して、ローカルデータベースに接続できるようになりました。

```
psql bdrdb
```

このコマンドは、kaboom のローカルデータベースインスタンスに直接接続します。\dt を使用して、使用可能なテーブルを表示します。

```
bdrdb=# \dt
       List of relations
 Schema | Name | Type  | Owner
- -------+------+-------+--------
 public | ping | table | barman
(1 row)
```

\d ping を実行すると、ping を作成する DDL が kaboom サーバー上にあることが示されます。

edb_notranlate_7 このテーブルがレプリケートされていることを確認したい場合は、クラスター内の別のノードに接続して確認できます。psql の\c コマンドを使用すると、別のサーバーに接続できます。kaftan ノードに接続するには、次を実行します。

```
\c - - kaftan
```

これに似たログインメッセージが表示されます。

```
psql.bin (15.2.0 (Debian 15.2.0-2.buster), server 15.2.0 (Debian 15.2.0-2.buster))␣
↪SSL connection (protocol: TLSv1.3, cipher: TLS_AES_256_GCM_SHA384, compression: off)
You are now connected to database "bdrdb" as user "enterprisedb" on host "kaftan"␣
↪(address "10.33.25.233") at port "5444".
bdrdb=#
```

\dt および\d ping を実行すると、kaftan ノードで同じ結果が表示されます。

kaboom ノードに再接続するには、次のコマンドを実行します。

```
\c - - kaboom
```

モニターのセットアップ

次に、ping テーブルのアクティビティを監視します。最新の 10 エントリを表示するには、次の SQL を入力します。

```
select * from ping order by timestamp desc limit 10;
```

このコマンドを複数回実行するには、シェルで\watch コマンドを使用します。これは、定期的な間隔で最後の照会を実行します。1 秒ごとに更新するには、次のように入力します。

```
\watch 1
```

これまでのところ、見るものは何もありません。すぐにアクティビティを追加します。

ping の作成

Control-b ↓を使用して、 Barman ホストカポックに戻ります。 Control-b → または **Control-b q 3** 。

このセッションはまだ psql セッションにログインしています。次にシェルスクリプトを実行するため、psql を終了する必要があります。 **Control-d** を押します。

シェルプロンプトは次のようになります。

barman@kapok:~$

admin@kapok または root@kapok と表示されている場合は、sudo -iu barman を実行して Barman ユーザーに戻ります。

作成するアプリケーションは簡単です。書き込むノードと ping のタイムスタンプを取得します。次に、できるだけ早く新しい ping を ping テーブルに書き込みます。

シェルに、次のように入力します。

```
while true; do psql -h kaftan,kaolin,kaboom -p 6432 bdrdb -c "INSERT INTO ping(node,␣
↪timestamp) select node_name, current_timestamp from bdr.local_node_summary;"; done
```

より読みやすい形式、つまり

```
while true;
    do psql -h kaftan,kaolin,kaboom -p 6432 bdrdb -c \
        "INSERT INTO ping(node, timestamp) select node_name, current_timestamp from␣
↪bdr.local_node_summary;"
    done
```

定数ループでは、psql コマンドを呼び出し、3 つのプロキシのいずれかにホストとして接続するように指示し、プロキシポートを指定して、bdrdb データベースを選択します。また、2 つの値を ping テーブルに挿入するコマンドも渡します。値の 1 つは bdr.local_node_summary からのもので、これには、実際に接続しているノードの名前が含まれています。もう 1 つの値は現在時刻です。

ループが実行されると、新しいエントリがテーブルに表示されます。モニタを設定する左上のペインに表示されます。

これで、フェイルオーバーのテストを開始できます。

書き込みリーダーの表示

プロセスのこの部分では、左下隅にあるホスト kaftan に切り替えます。**Control-b ←** または **Control-b q 2** を使用して、フォーカスを切り替えます。

pgd を実行するための適切な特権を取得するには、PGD コマンドラインインターフェイスで、次のコマンドを実行します。

```
sudo -iu enterprisedb
```

クラスターの状態を確認するには、次のコマンドを実行します。

```
pgd show-groups
```

次のような出力が表示されます。

```
Group        Group ID   Type   Parent Group Location Raft Routing Write Leader
- ----        --------   ----   ------------ -------- ---- ------- ------------
democluster  1935823863 global                       true false
dc1_subgroup 1302278103 data   democluster  dc1      true true    kaboom
```

グローバルグループ democluster には、すべてのサブグループが含まれます。 dc1_subgroup は、作業しているデータクラスターです。そのグループ名の値は、このクラスターを構成するときにクイックスタートで指定された場所から取得されます。各ロケーションは独自のサブグループを取得するため、他のロケーションまたはクラスターとは無関係に管理できます。

テーブルの右側にスキップすると、グループの現在の書き込みリーダー-すべてのプロキシが更新を送信するサーバー-が kaboom であることがわかります。

switchover コマンドをクラスターグループに送信して、リーダーを変更します。次のコマンドを実行します。

edb_notranlate_33 ノード名は、dc1_subgroup グループ内の別のデータノードのホスト名です。

2 つの応答のいずれかが表示されます。 show-groups コマンドを実行したときに、書き込みリーダーとして kaolin が表示された場合、次の情報が表示されます。

```
Error: "kaolin" is already a write leader
```

これは、カオリンが既に書き込みリーダーに選出されているため、切り替えは効果がないことを意味します。この演習では、ノード名として kaboom または kaftan に置き換えて、別のホストへのスイッチオーバーを再試行します。

現在の書き込みリーダーではないホストを選択すると、他の応答が表示されます。

```
switchover is complete
```

左上のペインを見ると、スクリプトからの挿入が切り替わり、切り替えたばかりのノードに書き込まれているのがわかります。

!!!情報 ID 番号を観察します生成される ID 番号も、完全に異なる値の範囲であることに注意してください。これは、システムが ID を生成するシーケンスを透過的にグローバルシーケンスにしたためです。グローバルシーケンスとそれらが シークエンス でどのように動作するかについての詳細を読んでください。

ノードの損失

リーダーを切り替えられることは、計画的なメンテナンスに役立ちます。クラスターに構成を変更するように指示します。予期せぬ変化が起こったらどうしますか？これからそのシナリオを作成します。

左下のペインで、リーダーを kaolin に設定します。

```
pgd switchover --group-name dc1_subgroup --node-name kaolin
```

次に、 **Control-b &uar; を使用してフォーカスを右上ペインに変更します。Control-b** → または **Control-b q 1** 、これはカオリンホスト上のセッションです。

次のコマンドを実行して、Postgres サーバーの電源をオフにします。

```
sudo systemctl stop postgres.service
```

左上のペインには、クラスターサブグループが新しいリーダーを選択すると、監視対象テーブルがカオリンから別のノードに切り替わるのが表示されます。更新がキャンセルされると、右下ペインのスクリプトにいくつかのエラーが表示される場合があります。ただし、新しいリーダーが選出されると、そのリーダーへのトラフィックのルーティングを開始します。

ノードの状態の表示

Control-b ↓を使用して左下のペインに切り替えます。 Control-b ← または **Control-b q 2** を押して、次を実行します。

```
pgd show-nodes
```

次のようなものが表示されます。

```
Node   Node ID    Group        Type Current State Target State Status      Seq ID
- ---   -------    -----        ---- ------------- ------------ ------      ------
kaboom 2710197610 dc1_subgroup data ACTIVE        ACTIVE       Up          3
kaftan 3490219809 dc1_subgroup data ACTIVE        ACTIVE       Up          2
kaolin 2111777360 dc1_subgroup data ACTIVE        ACTIVE       Unreachable 1
```

カオリンノードはダウンしており、更新は別の書き込みリーダーに送られます。

モニタリングラグ

カオリンがダウンしている間、PGD の中心部の論理レプリケーションは、カオリンがクラスターとどの程度同期していないかを追跡しています。それを自分の目で確認するには、次を実行します。

```
psql bdrdb -c "select * from bdr.node_replication_rates;"
```

このコマンドは、サーバー間の現在のレプリケーションレートを表示します。

```
 peer_node_id | target_name | sent_lsn   | replay_lsn |   replay_lag    | replay_lag_
↪bytes | replay_lag_size | apply_rate | catchup_interval
- -------------+-------------+-----------+------------+-----------------+-------------
↪-----+-----------------+------------+------------------
   2710197610 | kaboom      | 0/769F650 | 0/769F650  | 00:00:00        |
  0 | 0 bytes         |       1861 | 00:00:00
              | kaolin      | 0/7656648 | 0/7656648  | 00:03:07.252266 |          ␣
↪299016 | 292 kB          |            |
(2 rows)
```

この出力を見ると、kaolin には 3 分の再生ラグと、今戻った場合にキャッチアップする約 292KB のデータがあることがわかります。カオリンのダウンが長くなると、再生遅延が大きくなります。モニタリングコマンドを再実行すると、数値が増加したことがわかります。

```
 peer_node_id | target_name | sent_lsn   | replay_lsn |   replay_lag    | replay_lag_
↪bytes | replay_lag_size | apply_rate | catchup_interval
- -------------+-------------+-----------+------------+-----------------+-------------
↪-----+-----------------+------------+------------------
   2710197610 | kaboom      | 0/76B1D28 | 0/76B1D28  | 00:00:00        |
  0 | 0 bytes         |       1743 | 00:00:00
              | kaolin      | 0/7656648 | 0/7656648  | 00:03:53.045704 |          ␣
↪374496 | 366 kB          |            |
(2 rows)
```

さらに 46 秒が経過し、遅延は 74KB 増加しました。次に、ノードを元に戻し、システムがどのように復旧するかを確認します。

ノードの再起動

kaolin に Postgres サービスを戻すことができます。 **Control-b &uar; を使用して、右上ペインに戻ります。** **Control-b** → または **Control-b q 1** を押して、次を実行します。

```
sudo systemctl start postgres.service
```

変化は表示されません。データベースサービスはバックアップして実行されていますが、クラスターは選挙を行っていないため、リーダーはそのままです。**Control-b ↓を使用して左下のペインに切り替えます。** **Control-b** ← または **Control-b q 2** を押して、次を実行します。

```
pgd show-nodes
```

これで、次のものが表示されます。

```
Node   Node ID    Group        Type Current State Target State Status Seq ID
- ---   --------    -----        ---- ------------- ------------ ------ ------
kaboom 2710197610 dc1_subgroup data ACTIVE        ACTIVE       Up     3
kaftan 3490219809 dc1_subgroup data ACTIVE        ACTIVE       Up     2
kaolin 2111777360 dc1_subgroup data ACTIVE        ACTIVE       Up     1
```

カオリンがクラスターに戻ると、クラスターとの同期が開始されます。これは、リプレイデータをキャッチすることにより行われます。実行します

```
psql bdrdb -c "select * from bdr.node_replication_rates;"
```

出力は次のとおりです。

```
 peer_node_id | target_name | sent_lsn  | replay_lsn | replay_lag | replay_lag_bytes␣
↪| replay_lag_size | apply_rate | catchup_interval
- -------------+-------------+-----------+------------+------------+------------------
↪+-----------------+------------+------------------
   2710197610 | kaboom      | 0/8092938 | 0/8092938  | 00:00:00   |                0␣
↪| 0 bytes         |       2321 | 00:00:00
   2111777360 | kaolin      | 0/8092938 | 0/8092938  | 00:00:00   |                0␣
↪| 0 bytes         |     337426 | 00:00:00
(2 rows)
```

ご覧のとおり、カオリンは完全に自動的に追いついたため、再生ラグはありません。

カオリンが完全にサービスに戻ったので、すべてをそのままにしておくことができます。書き込みリーダーであるサーバーを変更する必要はありません。フェールオーバーメカニズムは、必要に応じて別のサーバーを書き込みリーダーに起動する準備が常にできています。

必要に応じて、次のコマンドを実行してカオリンリーダーを再度作成できます。

```
pgd switchover --group-name dc1_subgroup --node-name kaolin
```

このコマンドは、書き込みリードにカオリンを結果ます。プロキシが書き込みリーダーを追跡すると、アプリケーションの更新が続きます。

プロキシフェイルオーバー

プロキシもフェイルオーバーできます。これを体験するには、フォーカスがまだ左下のペインにあることを確認し、実行します。

```
pgd show-proxies
```

次のものが表示されます。

```
Proxy  Group        Listen Addresses Listen Port
- ----  -----        ---------------- -----------
kaboom dc1_subgroup [0.0.0.0]        6432
kaftan dc1_subgroup [0.0.0.0]        6432
kaolin dc1_subgroup [0.0.0.0]        6432
```

`exit` と入力して enterprisedb ユーザーを終了し、admin/root シェルに戻ります。次のコマンドを実行して、このノードのプロキシサービスを停止できるようになりました。

```
systemctl stop pgd-proxy.service
```

スクリプトが別のプロキシに切り替わると、右下のウィンドウに簡単なエラーが表示されます。ただし、書き込みリーダーは変更されないため、プロキシのスイッチは、監視クエリが実行されている左上のペインに表示されません。

次のコマンドを実行して、kaftan のプロキシサービスを元に戻します。

```
systemctl start pgd-proxy.service
```

!!!ヒント Tmux の終了 Tmux および関連するすべてのセッションをすばやく終了できます。最初に実行中のプロセスを終了します。それ以外の場合、セッションが強制終了された後も実行を継続します。**Control-B** を押して、 `:kill-session` と入力します。このアプローチは、 **Control-D** または `exit` を使用して各ペインのセッションを 1 つずつ終了するよりも簡単です。

この例では、3 つのデータノードと 1 つのバックアップノードのクイックスタート構成を使用します。2 つのデータノードと 1 つの監視ノードを持つようにクラスターを構成できます。監視ノードは、ノードに障害が発生した場合の復元力が低くなります。または、5 つのデータノードを構成することもできます。これにより、ノードに障害が発生した場合の復元力が大幅に向上します。この構成では、アプリケーションのフェイルオーバーがどのように動作するかを調べることができます。複数の場所を持つクラスターの場合、同じ基本的なルールが適用されます。サーバーをダウンすると、プロキシがポイントする新しい書き込みリーダーが選択されます。

さらに読む

- *Configuring PGD CLI* の管理機能の詳細をご覧ください。
- *monitoring replication using SQL* の詳細についてはこちらをご覧ください。

4.4.7 Exploring conflict handling with PGD

PGD のようなマルチマスターアーキテクチャでは、競合が発生します。PGD は、それらを処理するように構築されています。

競合は、1 つのデータベースノードにアプリケーションから行への更新があり、別のノードに同じ行への別の更新がある場合に発生する可能性があります。このタイプの競合は、**行レベルの競合**と呼ばれます。競合はエラーではありません。それらを効果的に解決することは、Postgres Distributed が一貫性を維持する方法の中核となります。

競合を処理する最善の方法は、最初に競合を発生させないことです。プロキシで PGD の Always-On アーキテクチャを使用して、アプリケーションがクラスター内の同じサーバーに書き込むようにします。

ただし、競合が発生した場合、PGD が競合を解決する方法、その解決を制御する方法、および競合が発生していることを確認する方法を知っていると役立ちます。行挿入と行更新は、競合を発生する可能性のある 2 つのアクションです。

それがどのように動作するかを確認するには、すべてのサーバーのコマンドラインビューを開く必要があります。

クイックスタート構成

この探索では、 *quick start for Docker* 、 *quick start for AWS* 、または *quick start for Linux hosts* を使用して PGD クラスターを作成したことを前提としています。

各クイックスタートの最後に、4 つのノードと次のロールを含むクラスターが作成されます。

Host name	Host role
kaboom	PGD data node and pgd-proxy co-host
kaftan	PGD data node and pgd-proxy co-host
kaolin	PGD data node and pgd-proxy co-host
kapok	Barman backup node

この演習では、これらのホスト名を使用します。

xpanes のインストール

xpanes は、簡単に切り替えることができる複数のターミナルセッションをすばやく作成できるユーティリティを使用します。デフォルトではインストールされないため、インストールする必要があります。まず、ssh を使用して kaboom ノードに接続します。

```
cd democluster && ssh -F ssh_config kaboom
```

Docker でクイックスタートを実行している場合、Red Hat の派生品である Rocky Linux を使用することになります。xpanes のインストールを実行するには、次のコマンドを実行します。

```
dnf -y install xpanes
```

AWS でクイックスタートを実行している場合、Debian Linux を使用することになります。xpanes のインストールを実行するには、次のコマンドを実行します。

```
wget https://github.com/greymd/tmux-xpanes/releases/download/v4.1.4/tmux-xpanes_v4.1.
↪4.deb
sudo apt -y install ./tmux-xpanes*.deb
rm tmux-xpanes*.deb
```

4 つのサーバーに接続する

認証が機能するようにするには、enterprisedb ユーザーとしてログインする必要があります。

```
sudo -iu enterprisedb
```

次に、次のコマンドを実行して、3 つのデータベースサーバーと 1 つのプロキシサーバーに接続します。

```
xpanes -d -c "psql postgresql://enterprisedb@{}/bdrdb?sslmode=require" "kaboom:5444"
↪"kaftan:5444" "kaolin:5444" "kaboom:6432"
```

xpanes は-c の後のコマンドを取得し、後続の引数の値を使用して実行するコマンドを作成します。これは、実行後に 4 つのペインが存在することを意味します。3 つのペインは、ポート 5444 でデータベースノード kaboom、kaftan、および kaolin に接続されます。1 つは、ポート 6432 で kaboom で実行されている pgd-プロキシに接続されます。それぞれは enterprisedb としてデータベースにログされます。

Control-b に続いて **q** を押して、各ペインの数値を一時的に表示します。

ペイン間でフォーカスを切り替えるには、 **Control-b** とカーソルキーを使用してペイン間を移動できます。または、 **Control-b** に続いて **q** とフォーカスするペインの番号を使用できます。両方の方法を紹介します。

Control-b ↓を使用して左下のペインに移動します。 Control-b → または Control-b q 3**。

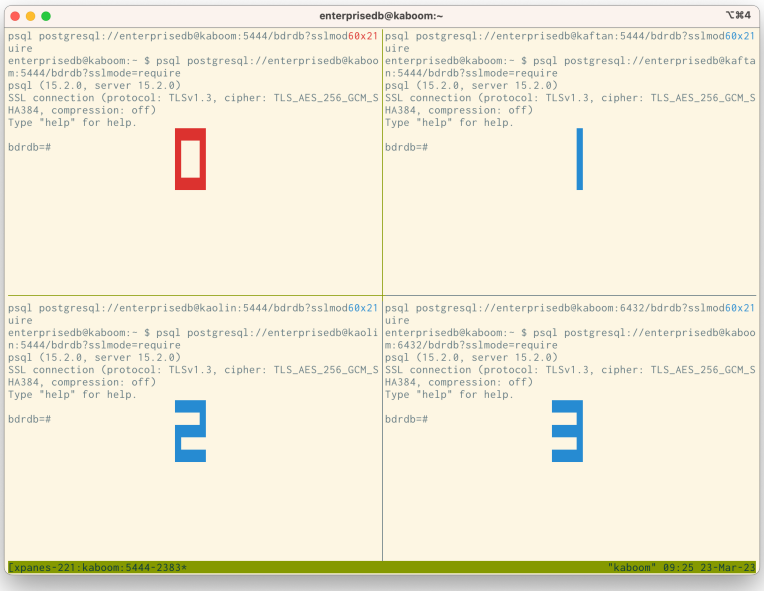


図 2: 4 Sessions showing numbers

競合の準備

競合を行うには、最初に単純なテーブルが必要です。現在フォーカスされているペインに、次のように入力します。

```
drop table if exists test_conflict;
create table test_conflict(
  id integer primary key ,
  value_1 text);
```

競合のモニタリング

現在フォーカスされているペインに、次のように入力します。

```
select * from bdr.conflict_history_summary
\watch 1
```

`select` コマンドは、クラスターの競合履歴を表示します。 `\watch 1` コマンドは、前述のコマンドを毎秒再実行する psql コマンドです。

これで、競合を生成する準備が整いました。

競合の作成

競合の最も基本的な形式は、2 つの異なるノード上のテーブルに挿入が発生し、両方が同じ主キーを持つ場合です。そのシナリオを作成し、観察できるようになりました。

Control-b &uar; を使用して左上のペインに移動します。 Control-b ←または Control-b q 0 。このペインは kaboom ノードです。そこでトランザクションを開始し、行を挿入します。

```
start transaction;
insert into test_conflict values (1, from kaboom);
```

次に、 **Control-b →** または **Control-b q 1** を使用して右上ペインに移動します。このペインは kaftan ノードです。ここでも、トランザクションを開始し、異なるデータを同じ行に挿入します。

```
start transaction;
insert into test_conflict values (1, from kaftan);
```

これで、別のサーバーで 2 つのトランザクションが開き、挿入操作は既に正常に実行されました。この時点で両方のトランザクションをコミットする必要があります。

*** Control-b ← **または** Control-b q 0**を使用し、`commit;` と入力します。

*** Control-b → **または** Control-b q 1**を使用し、 `commit;` と入力します。

両方のコミットが機能していることがわかります。ただし、右下のペインには、検出中の競合が表示されます。



図 3: 4 Sessions showing conflict detected

競合履歴の行には、`insert_exists` が存在するテーブルの競合が示されます。また、この競合の解決策は、コミットのタイミングに基づいて、新しいレコードが保持されることであるにも注意します。この競合は、INSERT/INSERT 競合と呼ばれます。このタイプの競合の詳細については、

INSERT/INSERT の競合 を参照してください。

更新の競合の作成

同じレコードへのさまざまな更新が別のノードで発生すると、競合が発生します。現在の構成でそのシナリオを作成することもできます。右下のペインで`\watch 1`を実行したままにします。

Control-b ← または **Control-b q 0** を使用して、左上のペインに移動します。このペインは kaboom ノードです。ここで、トランザクションを開始し、行を更新します。

```
start transaction;
update test_conflict set value_1 = update from kaboom where id = 1;
```

次に、 **Control-b →** または **Control-b q 1** を使用して右上ペインに移動します。このペインは kaftan ノードです。ここでも、トランザクションを開始し、同じ行を別のデータで更新します。

```
start transaction;
update test_conflict set value_1 = update from kaftan where id = 1;
```

これで、別のサーバーで 2 つのトランザクションが開き、更新操作は既に正常に実行されました。この時点で両方のトランザクションをコミットする必要があります。

*** Control-b rotation-left **または** Control-b q 0**を使用し、`commit;`と入力します。

*** Control-b rotation-right **または** Control-b q 1**を使用し、`commit;`と入力します。

再度、両方のコミットが機能しているのが表示されます。そして、同様に、右下のペインで、更新の競合が検出されているのが確認できます。

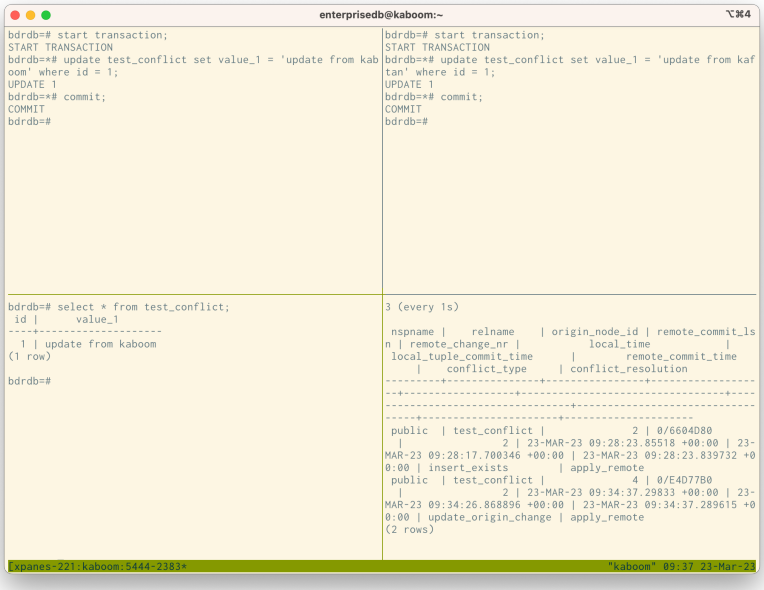


図 4: 4 Sessions showing update conflict detected

競合履歴の追加行は、`update_origin_change` 競合が発生し、解決が `apply_remote` であったことを示しています。この解決策は、リモート変更が適用され、レコードが更新されたことを意味します。この競合は UPDATE/UPDATE 競合と呼ばれ、 *UPDATE/UPDATE の競合* で詳細に説明します。

!!!ヒント Tmux の終了 Tmux および関連するすべてのセッションをすばやく終了できます。最初に実行中のプロセスを終了します。そうしないと、セッションが強制終了された後も実行が継続されます。**Control-b** を押して、 `:kill-session` と入力します。このアプローチは、 **Control-D** または `exit` を使用して各ペインのセッションを 1 つずつ終了するよりも簡単です。

これで、発生する可能性のあるすべての競合シナリオと解決策を検討する準備が整いました。競合の管理方法の詳細については、ドキュメントの 競合 を参照してください。競合は回避するのが理想ですが、競合が発生すると、Postgres Distributed の統合された構成可能な競合リゾルバーによって記録および管理されることを知ることが重要です。

4.4.8 Next Steps with PGD

PGD クラスターをさらに活用する

アーキテクチャ

このクイックスタートでは、高可用性 Postgres データベースの単一リージョンクラスターを作成しました。これは、Always On Single Location アーキテクチャであり、さまざまな使用可能な PGD アーキテクチャの 1 つです。他のアーキテクチャには、マルチプルのデータセンターのクラスターが連携する Always On Multi-location、および復元力を強化する監視ノードを使用した両方のバリエーションが含まれます。詳細は

> アーキテクチャオプションとパフォーマンス を参照してください。

Postgres バージョン

このクイックスタートでは、EDB Postgres Advanced Server ServerEPAS をデータベースノードに展開しました。PGD は、3 つの異なる種類の Postgres ディストリビューション、EPAS、EDB Postgres Extended Server、およびオープンソースの PostgreSQL を展開できます。データベースの選択は PGD に影響し、サーバーに応じて *different capabilities* を提供します。

*オープンソースの PostgreSQL は CAMO をサポートしていません

- EDB Postgres Extended Server は CAMO をサポートしていますが、Oracle との互換性は提供していません
- EDB Postgres Advanced Server は CAMO をサポートし、オプションの Oracle 互換性を提供します

続きを読む

- PGD の *Terminology* を学ぶ-非同期レプリケーションから書き込みスケーラビリティまで
- PGD を使用した applications work の方法と、 シークエンス のような一般的な Postgres 機能がどのようにグローバルに分散されているかを確認します
- PGD がクラスターの rolling upgrades をサポートする方法を確認します
- 接続ルーティング の制御を取得し、 SQL を使用して PGD プロキシを制御します
- *Configuring PGD CLI* と連携して、クラスターを管理およびモニタします

クラスターのプロビジョニング解除

クラスターのテストが終了したら、プロビジョニングを解除します。

```
tpaexec deprovision democluster
```

- Docker 展開では、プロビジョニング解除により Docker コンテナ、ネットワーク、およびその他のローカル構成が破棄されます。
- AWS 展開の場合、EC2 インスタンス、VPC 構成、およびその他の関連リソースが削除されます。作成した S3 バケットは残すことに注意してください。これは手動で削除する必要があります。

第5章　Concepts

5.1 クイックスタート

EDB Postgres 分散 PGD は、高いパフォーマンスと可用性を目指して設計された Postgres のマルチマスター複製実装です。多数の双方向同期データベースノードで構成されるデータベースクラスターを作成できます。クラスターには、クエリトラフィックを最も利用可能なノードに転送する多数のプロキシサーバーを含めることができ、クラスター構成の復元力をさらに高めます。

- Trusted Postgres ArchitectTPA の簡単な紹介と、 EDB Postgres Distributed の構成、展開、および管理にどのように役立つか

Docker、*Linux* **ホスト、または** *AWS* **クイックスタートを選択するためのガイド** Docker クイックスタート *Linux* **ホストのクイックスタート** AWS クイックスタート

- アプリケーションをクラスターに接続する

競合 フェールオーバーを含むクラスターでのさらなる探索

5.2 PGD と TPA の紹介

PGD は、高いパフォーマンスと可用性を実現するように設計された Postgres のマルチマスター複製実装です。PGD のインストールは、TPA によって調整されます。

私たちは、さまざまな Postgres 構成のインストールと管理を簡単に再現可能にするために TPA を作成しました。TPA は、Postgres の作成と展開を調整します。

これらのクイックスタートは、単一のリージョンクラスターをすばやく取得できるように設計されています。

これらのクイックスタートでは、最初に TPA をインストールします。既に TPA をインストールしている場合、これらの手順をスキップできます。TPA は、単純なインストーラーというよりはツールです。TPA の同じインストールを使用して、Postgres クラスターの多くの異なる構成を展開できます。

TPA を使用して、PGD デモクラスターの構成ファイルを生成します。このクラスターには、3 つの複製データベースノードがあり、3 つの高可用性プロキシと 1 つのバックアップノードをコホストします。

次に、TPA を使用して、必要な構成とソフトウェアを各ノードにプロビジョニングおよび展開します。

5.3 Docker、Linux ホスト、または AWS クイックスタートの選択

現在、3 つのクイックスタートが利用できます。

- Docker—単一のマシン上の Docker コンテナでクラスターをプロビジョニング、展開、およびホストします。
- Linux ホスト—オペレーティングシステムと SSH 接続で既にプロビジョニングした Linux サーバーにクラスターを展開およびホストします。これらは、オンプレミスまたはクラウドに展開された実際の物理サーバーまたは仮想マシンです。
- AWS — AWS でクラスターをプロビジョニング、展開、およびホストします。

5.3.1 Docker クイックスタート

Docker クイックスタートは、最初に PGD とその機能を探索しようとしている人に最適です。PGD のこの構成は実稼働使用には適していませんが、PGD クラスターの機能と動作をテストする場合に価値があります。PGD コマンドと API に慣れ、クラウド、VM、または Linux ホストへの展開の準備をする場合にも役立つ場合があります。

- *Begin the Docker quick start*

5.3.2 Linux ホストのクイックスタート

Linux ホストのクイックスタートは、ハードウェアとソフトウェアを完全に制御できる独自のホスト、またはプライベートクラウドに PGD をインストールしようとしている人に適しています。全体的な構成は Docker 構成に似ていますが、システム再起動後より永続的で、PGD のシングルリージョンの運用展開に似ています。

- *Begin the Linux host quick start*

5.3.3 AWS クイックスタート

AWS クイックスタートはより広範囲で、Amazon のクラウド上の EC2 ノードに PGD クラスターを展開します。クラスターの全体的な構成は、Docker クイックスタートに似ています。ただし、Docker コンテナを使用する代わりに、Amazon EC2 の t3.micro インスタンスを使用してコンピューティング能力を提供します。AWS 展開はより永続的で、Docker クイックスタート展開の制限の影響を受けません。ただし、AWS CLI を構成するには、より多くの初期設定が必要です。

- *Begin the AWS quick start*

5.4 クラスターを使用したさらなる探索

- *Connect applications to your PGD cluster*
- *Find out how a PGD cluster stands up to downtime of data nodes or proxies*
- *Learn about how EDB Postgres Distributed manages conflicting updates*
- *Moving beyond the quick starts*

5.4.1 PGD overview

EDB Postgres 分散 PGD は、高度な競合管理、データ損失保護、およびネイティブ論理レプリケーションより最大 5 倍高速のスループットを備えたマルチマスターレプリケーションとデータ分散を提供します。また、最大ファイブナインの高可用性を備えた分散 Postgres クラスターも有効にします。

PGD は、メッシュトポロジを使用して、疎結合のマルチマスター論理レプリケーションを提供します。これは、任意のサーバーに書き込むことができ、変更は行ごとに、同じ PGD グループの一部である他のすべてのサーバーに直接送信されることを意味します。

デフォルトでは、PGD は非同期レプリケーションを使用し、ローカルコミットの後にのみピアノードに変更を適用します。複数の同期レプリケーションオプションも使用できます。

基本アーキテクチャ

複数のグループ

PGD ノードは、少なくとも 1 つの **ノードグループ**のメンバーです。最も基本的なアーキテクチャでは、PGD クラスター全体に対応する単一のノードグループがあります。

マルチプルのマスター

PGD グループに参加する各ノードデータベースは、他のメンバーから変更を受け取り、ユーザーが直接書き込むことができます。

これは、1 つのマスターサーバーのみが書き込みを受け入れ、他のすべてのノードがマスターまたは別のスタンバイから複製するスタンバイであるホットまたはウォームスタンバイとは異なります。

すべてのマスターに常に書き込む必要はありません。頻繁な構成では、ほとんどの書き込みが
ライトリーダー と呼ばれる 1 つのマスターに転送されます。

デフォルトで非同期

1 つの PGD ノードで行われた変更は、ローカルにコミットされるまで他のノードに複製されません。その結果、データは常にすべてのノードで完全に同じではありません。一部のノードには、他のノードにまだ到着していないデータがあります。PostgreSQL のブロックベースのレプリケーションソリューションも、デフォルトで非同期レプリケーションになります。PGD には、複数のマスターがあり、その結果、複数のデータストリームが存在します。したがって、`synchronous_commit` および `synchronous_standby_names` を使用する場合でも、異なるノード上のデータは異なる場合があります。

メッシュトポロジ

PGD は、すべてのノードが他のすべてのノードに接続し、すべてのノードが互いに直接データを交換するメッシュネットワークを中心に構造化されています。ノードの追加や削除などの特別な状況を除き、PGD にはデータの転送はありません。データは EDB Postgres 分散クラスターの外部から到着するか、ネイティブの PostgreSQL 論理レプリケーションを使用して転送できます。

論理レプリケーション

論理レプリケーションは、レプリケーション ID 通常は主キーに基づいて、データ行とその変更をレプリケートする方法です。正確なブロックアドレスとバイトごとのレプリケーションを使用する物理的レプリケーションとは対照的に、論理的という用語を使用します。インデックスの変更はレプリケートされないため、書き込み増幅を回避し、帯域幅を削減します。

論理レプリケーションは、ソースノードからデータのスナップショットをコピーすることから始まります。それが完了すると、後のコミットはリアルタイムで発生すると他のノードに送信されます。変更は SQL を再度実行せずにレプリケートされるため、書き込まれた正確なデータが迅速かつ正確にレプリケートされます。

ノードは、ソースノードでコミットが行われた順序でデータを適用し、単一ノードからの変更に対してトランザクションの一貫性が保証されます。さまざまなノードからの変更は他のノードとは無関係に適用され、変更の迅速なレプリケーションが保証されます。

レプリケートされたデータは、安全な場合にはバイナリ形式で送信されます。

接続管理

> **接続管理** は、コンセンサス駆動クォーラムを活用して、半排他的な方法で正しい接続エンドポイントを決定し、アプリケーションからの意図しないマルチノード書き込みを防止します。このアプローチにより、データの競合の可能性が減少します。任意の時点で、正しい接続エンドポイントとして選択されたノードは、**ライトリーダー** と呼ばれます。
>
> *HARP から PGD プロキシへの移動* は、 EDB Postgres

Distributed の一部として提供されるアプリケーション接続管理のためのツールです。

高可用性

各マスターノードは 1 つ以上のスタンバイノードで保護できるため、ダウンしたノードはすぐに置き換えて続行できます。各スタンバイノードは、論理スタンバイノードまたは物理スタンバイノードのいずれかです。

1 つ以上のノードが現在使用できない場合でも、現在接続されているノード間でレプリケーションは続行されます。ノードが復旧すると、レプリケーションは、変更を見逃すことなく、中断した場所からリスタートできます。

ノードはさまざまなリリースレベルを実行でき、通信に必要なプロトコルをネゴシエートします。その結果、EDB Postgres 分散クラスターは、データベースソフトウェアのメジャーバージョンの場合でも、ローリングアップグレードを使用できます。

DDL は、デフォルトでノード間でレプリケートされます。必要に応じて、DDL 実行をユーザーが制御して、アプリケーションのローリングアップグレードを許可できます。

アーキテクチャオプションとパフォーマンス

Always On アーキテクチャ

多数の異なるアーキテクチャを構成できますが、それぞれが異なるパフォーマンスとスケーラビリティ特性があります。

グループは、2 つ以上のノードサーバーで構成される基本的なビルディングブロックです。グループでは、各ノードは専用のルーターとバックアップを備えた異なるアベイラビリティーゾーンにあり、即時のスイッチオーバーと高可用性を提供します。各グループには、専用のレプリケーションセットが定義されています。グループがノードを失った場合、グループから既存のノードをコピーすることにより、簡単に修復または置換できます。

Always On アーキテクチャは、1 つの場所にある 1 つのグループ、または 2 つの別の場所にある 2 つのグループから構築されます。各グループは高可用性を提供します。2 つのグループが遠隔地で活用される場合、それらは一緒にディザスターリカバリー DR も提供します。

テーブルは両方のグループにまたがって作成されるため、変更はローカルグループのノードだけでなく、すべてのノードに適用されます。

各グループの 1 つのノードがグループの書き込みリーダーとして選択されます。書き込みリーダーは、メインアプリケーションの書き込みとクエリのターゲットです。他のすべてのノードはシャドウノードまたは「読み取り/書き込みレプリカ」として説明され、必要に応じて引き継ぎを待機します。ノードが接続を失うと、処理はすぐにシャドウノードに切り替わって処理を続行します。グループに障害が発生した場合、処理は他のグループに切り替えることができます。スケーラビリティはこのアーキテクチャの目標ではありません。

書き込みは主に 1 つのノードのみに行われるため、ノード間の競合の可能性はほぼゼロに減少します。その結果、パフォーマンスへの影響が大幅に削減されます。

セカンダリアプリケーションはシャドウノードに対して実行される場合がありますが、メインアプリケーションがそのノードの使用を開始すると、これらは削減または中断されます。

将来的には、1 つのノードが他のグループのメインレプリケーターとして選択され、クラスターの成長に応じてレプリケーションの CPU オーバーヘッドを制限し、他のグループへの帯域幅を最小化します。

サポートされている Postgres データベースサーバー

PGD は、 PostgreSQL 、 EDB Postgres Extended Server 、および EDB Postgres Advanced Server と互換性があり、BDR という名前の標準の Postgres 拡張機能として展開されます。サポートされているバージョンの組み合わせの詳細については、

> *Compatibility changes* を参照してください。

一部の主要な PGD 機能は、ターゲット Postgres データベースサーバーで使用可能な特定のコア機能に依存しています。したがって、PGD ユーザーは、ビジネスニーズに最適な Postgres データベースサーバーディストリビューションも採用する必要があります。たとえば、PGD 機能の Commit At Most OnceCAMO を使用することがユースケースにとってミッションクリティカルである場合、コミュニティ PostgreSQL ディストリビューションを採用しないでください。CAMO を処理するために必要なコア機能がありません。

> *Choosing a Postgres distribution* の完全な機能マトリックスの互換性を参照してください。

PGD は、ネイティブに近い Postgres の互換性を提供します。ただし、一部のアクセスパターンは、単一のインスタンスで行う場合と同じようにマルチノード設定で必ずしも機能するとは限りません。マルチノード設定で安全に複製できるものには、いくつかの制限があります。
: Application usage は、アプリケーション開発の観点から PGD がどのように動作するかについて詳しく説明します。

パフォーマンスに影響を与える特性

デフォルトでは、PGD はグループ内の各ノードに各テーブルのコピーを 1 つ保持し、変更はグループ内のすべてのノードに伝播します。

データのコピーはどこにでもあるため、SELECT はローカルノードにアクセスすることのみが必要です。読み取り専用クラスターでは、ノードのパフォーマンスはノード数の影響を受けず、長時間実行された SELECT クエリによって発生する他のノードでのレプリケーション競合の影響を受けません。したがって、ノードを追加すると、可能な合計 SELECT スループットが線形に増加します。

INSERT、UPDATE、および DELETEDML がローカルで実行される場合、変更はグループ内のすべてのノードに伝播します。DML apply のオーバーヘッドは、元の実行よりも少なくなります。したがって、複数のノードで純粋な書き込みワークロードを同時に実行する場合、マルチノードクラスターは、シングルノードよりも多くの TPS を処理できます。

競合処理にはコストがかかり、スループットを低下させます。スループットは、実際にアプリケーションが表示する競合の量によって異なります。競合が非常に低いアプリケーションは、単一ノードよりも優れたパフォーマンスを示します。競合の多いアプリケーションは、単一ノードよりもパフォーマンスが低下する場合があります。これらの結果は、マルチマスターテクノロジーと一貫性があり、PGD に固有ではありません。

同期レプリケーションオプションは、変更をマルチプルのノードに同時に送信できるため、レプリケーション遅延を最小限に抑えることができます。ノードを追加するということは、レプリケーションにより多くの CPU を使用することを意味するため、各ノードが追加されるとピーク TPS がわずかに減少します。

ワークロードがすべての CPU リソースを使用しようとすると、このリソースがレプリケーションを制約し、レプリケーションラグに影響を与える可能性があります。

要約すると、すべての書き込みがすべてのノードで再生されるため、ほとんどのテーブルがレプリケートされる場合、PGD グループにマスターノードを追加しても、大幅な書き込みスループットの増加はありません。PGD 書き込みは、一般に SQL を介して Postgres クライアントからの書き込みよりも効果的であるため、パフォーマンスを向上させることができます。読み取りスループットは、一般にノードの数に線形にスケールします。

5.4.2 Terminology

この用語リストには、 EDB Postgres Distributed に関連する馴染みのない用語が含まれています。

非同期レプリケーション

オリジナルノードでトランザクションが完了した後、他の PGD クラスターメンバーにデータをコピーするレプリケーションのタイプ。非同期レプリケーションは、

非同期レプリケーション よりも高いパフォーマンスと低いレイテンシーを提供できます。ただし、非同期レプリケーションでは、さまざまなクラスターメンバーに変更が表示されるまでにかかる時間に遅延が発生する場合があります。クラスターは eventually consistent になりますが、ノードが明らかに互いに同期していない可能性があります。

コミットスコープ

PGD クラスターのノードとグループ間でトランザクションがコミットされる方法を管理するためのルール。

非同期レプリケーション 、 グループコミット 、 *CAMO* またはコミット・アット・モスト・ワンス 、 熱心な

、遅延制御、およびその他の PGD 機能を構成するために使用されます。

CAMO またはコミット・アット・モスト・ワンス

一部のアプリケーションの高価値トランザクションでは、アプリケーションが正確に 1 回だけ、フェールオーバーと再試行が発生した場合に 1 回だけ正常にコミットする必要があります。PGD でこれが発生するように保証には、CAMO を有効にして、アプリケーションがトランザクションにアクティブに参加できるようにします。

競合

データは PGD クラスターのノードにわたってレプリケートされるため、あるソースからの変更が別のソースからの変更と衝突する場合があります。これは競合であり、競合の解決で処理できます。競合の解決は、どのソースが正しいまたは優先されるかを決定するルールセットです。競合は、競合のないデータ型を使用して回避することもできます。

コンセンサス

レプリケートされた利用可能なフォールトトレランス *Raft* がグループ全体の決定を行う方法。グループ内のノードの数を指定すると、Raft は、決定に投票するマジョリティのコンセンサスノードの数を 2 プラス 1 で割ったものを探します。たとえば、書き込みリーダーが選択される場合、グループ内のどのノードが書き込みリーダーになるかについて Raft コンセンサスが求められます。投票メンバーのクォーラムがある場合にのみコンセンサスに到達できます。

クラスター

一般に、クラスターは、エンドユーザーに 1 つのシステムとして見えるように配置された複数の冗長システムのグループです。
PGD クラスター および *Postgres クラスター* も参照してください。

DDL データ定義言語

データベースの構造の定義と管理を処理する SQL コマンドのサブセット。DDL ステートメントは、データベース内のオブジェクトつまりスキーマ、テーブル、インデックスを作成、変更、および削除できます。一般的な DDL コマンドは、CREATE、ALTER、および DROP です。

DML データ操作言語

データベースに保持されているデータの操作を処理する SQL コマンドのサブセット。DML ステートメントは、データベース内のテーブルの行を作成、変更、および削除できます。一般的な DML コマンドは、INSERT、UPDATE、および DELETE です。

熱心な

競合する可能性のある着信トランザクションを検出し、それらのいずれかを「迅速に」中止して一貫性を維持することにより競合を回避する同期コミットモード。

最終的な一貫性

異なるクラスターメンバーの同じ項目への変更を記述する分散コンピューティング一貫性モデルは、最終的に同じ値に収束します。競合解決と競合のないレプリケートデータ型を使用した非同期論理レプリケーションは、PGD の最終的一貫性を示します。

フェイルオーバー

高可用性データベースクラスターの障害を認識し、一貫性と可用性を維持するためのアクションを実行する自動プロセス。目標は、ダウンタイムとデータの損失を最小限に抑えることです。

グループコミット

複数の PGD ノードがコミット時にトランザクションを正常に受信および確認する必要がある同期コミットモード。

即時一貫性

すべてのレプリカが同期的かつ同時に更新される分散コンピューティングモデル。このモデルでは、書き込みが完了した後のすべての読み取りが、すべてのノードで同じ値を参照します。このアプローチの欠点は、パフォーマンスへの悪影響です。

論理レプリケーション

データベース内の変更をレプリケートするより効率的な方法。物理的ストリーミングレプリケーションは元のデータベースのディスクブロックを複製しますが、論理レプリケーションは代わりに、基になる物理的記憶形式とは無関係に変更を取得し、変更を表示するようにサブスクライブしたすべてのシステムに公開します。次に、各サブスクライバーは変更をローカルに適用します。論理レプリケーションは、ほとんどの DDL コマンドをサポートできません。

ノード

分散システムの要素の総称。ノードは任意のサービスのホストとして機能できます。PGD では、PGD nodes は Postgres データベース、BDR 拡張機能、およびオプションで PGD プロキシサービスを実行します。

通常、高可用性を実現するために、各ノードは別の物理ハードウェアで実行されますが、常にそうとは限りません。たとえば、プロキシはハードウェアノードをデータベースと共有する場合があります。

ノードグループ

PGD クラスター内の PGD ノードをグループに編成して、クラスターの論理操作を反映できます。たとえば、特定の物理的な場所にあるデータノードは、その場所の専用ノードグループの一部であることができます。

PGD クラスター

エンドユーザーには 1 つのシステムとして見えながら、単一障害点を回避するように配置された複数の冗長データベースシステムとプロキシのグループ。PGD クラスターは、Docker インスタンス、クラウドインスタンス、または「ベア」Linux ホスト、またはこれらのプラットフォームの組み合わせで実行できます。PGD クラスターには、バックアップノードとプロキシノードを含めることもできます。クラスター内のデータノードは、トップレベルグループにグループ化され、さまざまなローカル

ノードグループ にグループ化されます。

PGD ノード

PGD クラスターには、データベースを実行し、PGD クラスターに参加するノードがあります。一般的な PGD ノードは、Postgres データベース、BDR 拡張機能、およびオプションで PGD プロキシサービスを実行します。PGD モードは **データノード**とも呼ばれ、データを保存することを示唆しています。ただし、一部の PGD ノード、特に

Witness ノード はそれを行いません。

物理的レプリケーション

物理レプリケーションは、1 つ以上のスタンバイクラスターメンバーに変更されるときにデータベースディスクブロックの正確なコピーを作成することにより、サーバーをレプリケートする簡単に実装された方法を提供します。ただし、使用方法には制限があります。たとえば、1 つのマスターノードのみが書き込みトランザクションを実行できます。また、この方法では、すべてのクラスターメンバーが、同じオペレーティングシステムと CPU アーキテクチャを備えたデータベースソフトウェアの同じメジャーバージョンを使用している必要があります。

Postgres クラスター

通常、PostgreSQL では、単一のサーバーで実行されている多数のデータベースをデータベースのクラスターと呼びます。この種類の Postgres クラスターは、可用性が高くありません。高可用性と冗長性を取得するには、
PGD クラスター が必要です。

クォーラム

PGD クラスターで レプリケートされた利用可能なフォールトトレランス *Raft*
コンセンサス が必要な場合、投票に参加する最小数の投票ノードが必要です。この数はクォーラムと呼ばれます。たとえば、5 ノードクラスターの場合、クォーラムはクラスター投票の 3 ノードです。コンセンサスは 5/2+1 ノード、3 つのノードが同じように投票します。投票ノードが 2 つだけの場合、コンセンサスは決して確立されません。

レプリケートされた利用可能なフォールトトレランス Raft

分散クラスター内のマシンのクォーラムからの投票を使用してコンセンサスを確立するコンセンサスアルゴリズム。PGD は、グループトップレベルまたはローカル内で Raft を使用して、書き込みリーダーであるノードを確立します。

読み取りスケーラビリティ

増加する読み取りワークロードを処理するシステムの機能。たとえば、PGD は 1 つ以上のリードレプリカノードをクラスターに導入し、アプリケーションにプライマリノードに書き込みを指示し、レプリカノードに読み取りを行わせることができます。読み取りワークロードの増加に応じて、リードレプリカノードの数を増加してパフォーマンスを維持できます。

スイッチオーバー

アプリケーションまたはプロキシとクラスター内のアクティブなデータベースノード間の接続の計画的な変更。通常はメンテナンスのために行われます。

同期レプリケーション

変更がすべての参加ノードで同時に更新される場合、通常は 2 フェーズコミットを活用します。このアプローチでは、コミットする前に変更を複製し、競合を解決しますが、ノード全体で必要な調整のため、レイテンシーのパフォーマンスコストが発生します。

サブスクライバー専用ノード

PGD クラスターは、双方向レプリケーションをベースとしています。ただし、読み取り専用サーバーが必要な場合など、一部のユースケースでは、双方向レプリケーションは必要ありません。この場合、加入者専用ノードが使用されます。データベース内の変更のみをサブスクライブして自分自身を最新の状態に保ち、ノードで直接実行に対して正しい結果を提供します。この機能を使用して、PGD クラスターでのホリゾンタル読み取りのスケーラビリティを有効にできます。

2 フェーズコミット 2PC

複数のデータベースノード間の一貫性を実現するためのマルチステップのプロセス。最初のフェーズでは、元のノードで準備され、すべての参加ノードに送信されるトランザクションが表示されます。各参加ノードは、トランザクションを適用できることを検証し、その準備ができていることを元のノードに通知します。これは準備フェーズです。第 2 フェーズでは、すべての参加ノードが準備ができていることを通知した場合、元のノードはトランザクションのコミットを続行し、参加ノードにもコミットするように通知します。これはコミットフェーズです。準備フェーズで、いずれかのノードが準備ができていないことを通知した場合、トランザクション全体が中止されます。このプロセスにより、すべてのノードが同じ変更を取得します。

垂直スケーリングまたはスケールアップ

Oracle Exadata など、そのアーキテクチャの物理的制限に到達するまで、特定のワークロードをサポートするリソース CPU、メモリ、ストレージ、ネットワークを増加する従来のコンピューティングアプローチ。

Witness ノード

Witness ノードは、主にクラスターがコンセンサスを確立するのを支援するために機能します。コンセンサスを確立するには奇数のデータノードが必要であり、リソースが制限されている場合、監視ノードを使用してクラスターの決定に参加できますが、データを複製できません。データを保持しないことは、スタンバイサーバーとして動作できない、または同期コミットのマジョリティを提供できないことを意味します。

ライトリーダー

Always-On アーキテクチャでは、ノードがアプリケーションの正しい接続エンドポイントとして選択されます。このノードは書き込みリーダーと呼ばれます。選択すると、プロキシノードはクエリーと更新をルーティングします。1 つのノードのみが書き込みを受信するため、意図しないマルチノードの書き込みを回避できます。書き込みリーダーは、データノードのクォーラムのコンセンサスによって選択されます。書き込みリーダーが使用できなくなると、データノードは別のノードを選択して書き込みリーダーになります。書き込みリーダーではないノードは、**シャドウノード** と呼ばれます。

第6章　Planning

6.1 Choosing your architecture

Always On アーキテクチャは、EDB の Trusted Postgres アーキテクチャを反映しています。これらはプラクティスをカプセル化し、複数の構成で可能な限り最高のサービスの可用性を達成するのに役立ちます。これらの構成は、単一ロケーションのアーキテクチャから、ハードウェア障害やデータセンターの障害から保護する複雑な分散システムにまで及びます。このアーキテクチャは、EDB Postgres Distributed のマルチマスター機能と、メンテナンス操作中でも 99.999%の可用性を達成する機能を活用します。

ここで説明する例を超えたアーキテクチャに EDB Postgres 分散を使用できます。ユースケース固有のバリエーションは、実稼働環境に正常に展開されました。ただし、これらのバリエーションは、最初に厳密なアーキテクチャレビューを受ける必要があります。また、Always On アーキテクチャ用の EDB の標準展開ツールは、運用環境でサポートされる前に、Trusted Postgres ArchitectTPA を有効にしてバリエーションをサポートする必要があります。

6.1.1 標準の EDB Always On アーキテクチャ

EDB は、目標復旧ポイント RPO および目標復旧時間 RTO の要件に応じて、さまざまなレベルの冗長性で単一またはマルチロケーションの展開をサポートするための標準化されたアーキテクチャを特定しました。

Always ON アーキテクチャは、基本的なビルディングブロックとして 3 つのデータベースノードグループを使用します。冗長性を高めるために 5 つのノードグループを使用することもできます。

EDB Postgres Distributed は、次の主要なビルディングブロックで構成されています。

- 双方向レプリケーション BDR—マルチマスターメッシュネットワークを作成する Postgres 拡張機能
- PGD プロキシ—アプリケーションが適切なデータノードに接続されていることを確認する接続ルーター。

すべての Always On アーキテクチャは、ますます多くの障害状況を保護します。たとえば、2 つのデータノードを持つ単一のアクティブなロケーションは、ローカルハードウェア障害から保護しますが、ロケーションデータセンターまたはアベイラビリティーゾーンの障害からの保護は提供しません。別の場所にあるバックアップを使用してそのアーキテクチャを拡張することにより、場所が壊滅的に損失した場合に備えて、ある程度の保護が保証されます。ただし、最初にバックアップからデータベースを復元する必要があるため、RTO 要件に違反する可能性があります。マルチマスターメッシュネットワークで接続された 2 番目のアクティブなロケーションを追加すると、ロケーションがオフラインになってもサービスは利用可能なままです。最後に、3 番目の場所これは監視専用の場所にすることができますを追加すると、1 つの場所がオフラインになった場合でもグローバル Raft 機能が動作できます。グローバル Raft は、主に管理コマンドを実行するために必要です。また、DDL やシーケンスの割り当てなどの一部の機能は、それなしでは動作しない場合がありますが、DML レプリケーションは、グローバル Raft なしでも動作し続けます。

データは少なくとも 1 つのローカルマスターに同期してストリーミングできるため、各アーキテクチャはゼロ RPO を提供でき、ローカルハードウェアに障害が発生した場合のデータ損失ゼロを保証します。

可用性保証を強化すると、ハードウェアとライセンス、ネットワーク要件、および操作の複雑性の追加コストが常に増加します。アーキテクチャを選択する前に、可用性とコンプライアンス要件を注意深く検討することが重要です。

6.1.2 アーキテクチャの詳細

デフォルトでは、アプリケーショントランザクションは DML のクラスター全体のコンセンサス選択、挿入、更新、および削除を必要としないため、レイテンシーが低下し、パフォーマンスが向上します。ただし、新しいグローバルシーケンスの生成や分散 DDL の実行などの特定の操作の場合、EDB Postgres Distributed は Raft ベースのコンセンサスモデルを使用して決定を行うための奇数のノードが必要です。したがって、より単純なアーキテクチャでも、すべてのノードがデータを保存しているわけではない場合でも、常に 3 つのノードがあります。

アプリケーションは、マルチホスト接続文字列を介して標準の Always On アーキテクチャに接続します。各 PGD プロキシサーバーは、マルチホスト接続文字列の個別のエントリです。高可用性を保証には、各場所に常に少なくとも 2 つのプロキシノードが必要です。プロキシをデータベースインスタンスと同じ場所に配置できます。その場合、すべてのデータノードにプロキシを配置することをお勧めします。

他の接続メカニズムは実稼働環境に正常に展開されています。ただし、これらは標準の Always On アーキテクチャの一部ではありません。

Always On 単一のロケーション

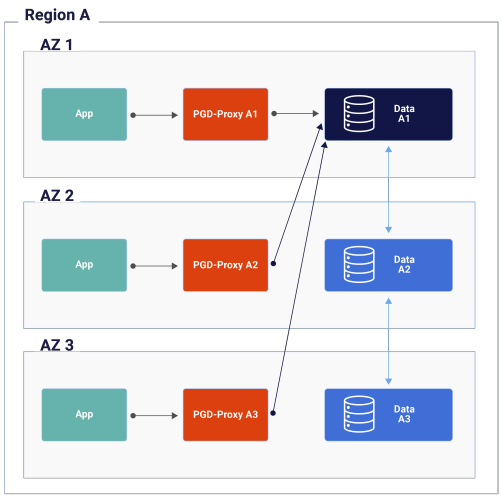


図 1: Always On 1 Location, 3 Nodes Diagram

*データノード 1 と 3 間の追加のレプリケーションは表示されていませんが、レプリケーションメッシュの一部として発生します

ローカル障害から迅速に復元するための冗長ハードウェア 3 つの PGD ノード *3* **つのデータノードにすることができます推奨** 2 つのデータノードとデータを保持しない 1 つの監視であることができます図示され

ていません**各データノードの *PGD* プロキシアプリケーションへのアフィニティ**データノードとコロケーションできます推奨 **別のノードに配置できます**データノードの構成とインフラストラクチャの対称性により、再ルーティングされたときにアプリケーションのワークロードを処理するために適切なリソースが利用できるようになります。

バックアップとリカバリーの *Barman* 不図示オフサイトはオプションですが推奨*マルチプルの PGD クラスターで共有できます

モニタリング用の *Postgres Enterprise ManagerPEM* は示されていませんマルチプルの PGD クラスターで共有できます

Always On マルチロケーション

*アプリケーションは、各場所でアクティブ/アクティブになるか、1 つの場所のみが書き込みを行うアクティブ/パッシブまたはアクティブ DR にすることができます。

*データノード 1 と 3 間の追加のレプリケーションは表示されていませんが、レプリケーションメッシュの一部として発生します。

ローカル障害から迅速に復元するための冗長ハードウェア。6 つの PGD ノード、各場所に 3 つ *3* **つのデータノードにすることができます推奨** 2 つのデータノードと、データを保持しない 1 つの監視にすることができます不図示**へのアフィニティを持つ各データノードの *PGD*-プロキシアプリケーション**データノードと同じ場所に配置できます推奨 **別のノードに配置できます**データノードと場所の構成とインフラストラクチャの対称性により、再ルーティングされたときにアプリケーションのワークロードを処理するために適切なリソースが利用できることが保証されます

バックアップとリカバリーの *Barman* 図示されていません。マルチプルの PGD クラスターで共有できます

モニタリングのための *Postgres Enterprise ManagerPEM* は示されていません。マルチプルの PGD クラスターで共有できます

オプションの監視ノードを *3* 番目のリージョンに配置して、ロケーション障害の許容度を高める必要があります。それ以外の場合、ロケーションに障害が発生すると、新しいノードや分散 DDL の追加など、グローバルコンセンサスを必要とするアクションがブロックされます。

6.1.3 アーキテクチャの選択

すべてのアーキテクチャは以下を提供します。

*ハードウェア障害保護

- ゼロダウンタイムのアップグレード

*パブリック/プライベートクラウドでのアベイラビリティーゾーンのサポート

これらの基準を使用して、適切な Always On アーキテクチャを選択します。

	Single Data Location	Two Data Locations	Two Data Locations + Witness	Three or More Data Locations
Locations needed	1	2	3	3
Fast restoration of local HA after data node failure	Yes - if 3 PGD data nodes No - if 2 PGD data nodes	Yes - if 3 PGD data nodes No - if 2 PGD data nodes	Yes - if 3 PGD data nodes No - if 2 PGD data nodes	Yes - if 3 PGD data nodes No - if 2 PGD data nodes
Data protection in case of location failure	No (unless offsite backup)	Yes	Yes	Yes
Global consensus in case of location failure	N/A	No	Yes	Yes
Data restore required after location failure	Yes	No	No	No
Immediate failover in case of location failure	No - requires data restore from backup	Yes - alternate Location	Yes - alternate Location	Yes - alternate Location
Cross-location network traffic	Only if backup is offsite	Full replication traffic	Full replication traffic	Full replication traffic
License cost	2 or 3 PGD data nodes	4 or 6 PGD data nodes	4 or 6 PGD data nodes	6+ PGD data nodes

6.1.4 標準アーキテクチャに柔軟性を追加する

必要なデータの復元力と、アプリケーションとデータを維持するユーザーへの近接性を提供するために、単一ロケーションアーキテクチャを必要なだけ多くの場所に展開できます。EDB Postgres 分散には、さまざまな競合処理アプローチが利用できますが、地理的に異なる場所からの書き込みアクティビティを許可する場合、予想される衝突数を最小限に抑えるように注意してください。

2 つの追加タイプのノードを使用して標準アーキテクチャを拡張することもできます。

- **サブスクライバー専用ノード**アプリケーションのワークロードの大部分が読み取り集中であり、書き込みがまれである場合、追加の読み取りスケーラビリティを実現し、データをユーザーの近くに使用できます。それらを活用して、レポート、アーカイブ、分析ニーズに合わせてデータのサブセットを公開することもできます。
- **ロジカルスタンバイ** PGD クラスター内の別のノードからレプリケートされたデータを受信しますが、レプリケーションメッシュまたはコンセンサスに参加しません。これらには、他の PGD データノードとすべて同じデータが含まれており、データノードの 1 つがクラスターをフルキャパシティ/コンセンサスに戻すことができなかった場合、すぐにマスターに昇格できます。データセンター間のネットワークトラフィックが懸念される環境で使用できます。それ以外の場合、ロケーションごとに 3 つの PGD データノードが常に優先されます。

6.2 Choosing a Postgres distribution

EDB Postgres Distributed は、3 つの異なる Postgres ディストリビューション PostgreSQL、 EDB Postgres Extended Server、または EDB Postgres Advanced Server で展開できます。特定の EDB Postgres 分散機能の可用性は、使用されている Postgres ディストリビューションによって異なります。したがって、ビジネスニーズに最適な Postgres ディストリビューションを採用することが重要です。たとえば、Commit At Most Once CAMO 機能を使用することがユースケースにとってミッションクリティカルである場合は、CAMO を処理するために必要なコア機能を持たないオープンソースの PostgreSQL を採用しないでください。

次の表は、 Postgres ディストリビューションとバージョンに依存する EDB Postgres Distributed の機能をリストしています。

Feature	PostgreSQL	EDB Postgres Extended	EDB Postgres Advanced
Rolling application and database upgrades	Y	Y	Y
PGD/TPA upgrades	Y	Y	Y
DML and DDL replication and nonreplication	Y	Y	Y
PGD/TPA upgrades	Y	Y	Y
PGD/TPA upgrades	v14+	v13+	v14+
PGD/TPA upgrades	Y	Y	Y
PGD/TPA upgrades	Y	Y	Y
Monitoring	Y	Y	Y
PGD/TPA upgrades	Y	Y	Y
Parallel Apply	Y	Y	Y
PGD/TPA upgrades	Y	Y	Y
列レベルの競合解決の有効化と無効化	Y	Y	Y
Transform トリガー	Y	Y	Y
競合トリガー	Y	Y	Y
非同期レプリケーション	Y	Y	Y
PGD を使用したレガシー同期レプリケーション	Y	Y	Y
グループコミット	N	Y	14+
PGD/TPA upgrades	N	Y	14+
Eager conflict resolution	N	Y	14+
遅延制御	N	Y	14+
Decoding worker	N	13+	14+
PGD/TPA upgrades	N	Y	14+
Missing partition conflict	N	Y	14+
No need for UPDATE Trigger on tables with TOAST	N	Y	14+

次のページに続く

表 2 – 前のページからの続き

Feature	PostgreSQL	EDB Postgres Extended	EDB Postgres Advanced
Automatically hold back FREEZE	N	Y	14+
Transparent Data Encryption	N	15+	15+

6.3 Choosing your deployment method

次の方法を使用して、 EDB Postgres 分散製品を展開およびインストールできます。

- *Deploying EDB Postgres Distributed using Trusted Postgres Architect* TPA は、Ansible を使用して Postgres クラスターをビルドするオーケストレーションツールです。さまざまなシナリオで Postgres をセットアップおよび操作する方法を文書化したリファレンスアーキテクチャセットを使用して Postgres クラスターをビルドします。TPA は、EDB が従うベストプラクティスを表しており、その推奨事項は、運用環境と同じように簡単なテストベッドのセットアップに適用されます。TPA の柔軟性により、仮想マシン、AWS クラウドインスタンス、または Linux ホストハードウェアに展開できます。詳細については、*Deploying with TPA* を参照してください。
- BigAnimal は、Oracle 互換性が組み込まれたフルマネージドのサービスとしてのデータベースであり、Postgres の専門家が操作するクラウドアカウントまたは BigAnimal のクラウドアカウントで実行されます。EDB BigAnimal を使用すると、データベースのセットアップ、管理、およびスケーリングが簡単にできます。EDB Postgres DistributedPGD を活用した分散高可用性サポートの追加により、シングルおよびマルチリージョンの Always On Gold クラスターが有効になります。詳細は、BigAnimal documentation の Distributed high availability を参照してください。
- EDB Postgres Distributed for Kubernetes は、EDB によって設計、開発、およびサポートされている Kubernetes オペレーターです。PGD レプリケーションを使用した、マルチマスターアーキテクチャと高可用性 Postgres データベースクラスターのライフサイクル全体をカバーします。これは、オープンソースの CloudNativePG オペレーターをベースにしており、EDB Postgres Advanced Server を使用した Oracle との互換性、 EDB Postgres Extended または Advanced Server を使用した透過的データ暗号化 TDE、IBM Power や OpenShift を含む追加のサポート対象プラットフォームなどの追加価値を提供します。この製品は現在プレビューの段階です。

	TPA	BigAnimal	Kubernetes (preview)
Single region	☒	☒	☒
Active-Active support	2+ regions	2 regions	2 regions
Write/Read routing	Local or global	Local	Local
Automated failover	AZ or Region	AZ	AZ
Major version upgrades	☒	Roadmap	Roadmap
Subscriber-only nodes (read replicas)	☒	TBD	TBD

次のページに続く

表 3 – 前のページからの続き

	TPA	BigAnimal	Kubernetes (preview)
Logical standby nodes	☒	TBD	TBD
PgBouncer	☒	TBD	TBD
Selective data replication	☒	☒	☒
Maintenance windows per region	☒	☒	☒
Target availability	99.999% SLO	99.99 SLA (single) 99.995% SLA (multi)	99.999% SLO

6.4 Other considerations

展開を計画するときは、これらのその他の考慮事項を確認してください。

6.4.1 データの一貫性

競合 について読んで、データの一貫性の観点からの非同期オペレーションモードの影響を理解します。

6.4.2 展開

PGD は、

Deploying EDB Postgres Distributed using Trusted Postgres Architect またはテクニカルサポートによって承認された構成管理アプローチと展開アーキテクチャを使用して、少数の既知の正常な構成のいずれかで展開することを目的としています。

手動展開は推奨されず、サポートされていない場合があります。

ログメッセージとドキュメントは、現在英語でのみ利用できます。

6.4.3 サイズ設定の考慮事項

運用展開の場合、EDB は、Postgres データノードごとに少なくとも 4 コアを推奨します。Witness ノードはデータレプリケーション操作に参加せず、この要件を満たす必要はありません。サブグループ Raft なしで 1 つのコアで十分です。サブグループ Raft を使用する場合、2 つのコアで十分です。ノードが昇格した場合のパフォーマンスの低下を回避するために、常にデータノードとまったく同じようにロジカルスタンバイのサイズを設定します。運用展開では、PGD プロキシノードには少なくとも 1 コアが必要で、データベースコア数の増加に応じて約 1:10 の比率で段階的に増やす必要があります。特定のパフォーマンス要件の詳細なベンチマークを作成して、ワークロードに基づいて適切なサイジングを決定することをお勧めします。EDB プロフェッショナルサービスチームが、必要に応じてサポートします。

開発のために、2 コア未満の Postgres データノードを割り当てないでください。Barman ノードのサイズは、データベースのサイズとデータ変更率によって異なります。

Postgres データノード、Barman ノード、および PGD プロキシノードを仮想マシンまたはベアメタル展開モードで展開できます。ただし、復元性が低下するため、同じ物理ハードウェア上にある VM に複数のデータノードを展開しないでください。また、同じ物理ハードウェア上の VM に複数の PGD プロキシノードを展開しないでください。それも復元性が低下します。

単一の PGD プロキシノードは、単一の PGD データノードとコロケーションできます。

6.4.4 時計とタイムゾーン

EDB Postgres 分散は、マルチプルのタイムゾーンのノードで動作するように設計されており、真にワールドワイドなデータベースクラスターを実現します。個々のサーバーは一致するタイムゾーンで構成する必要はありませんが、`log_timezone = UTC` を使用して、人間が判読可能なサーバーログにアクセスしやすく比較しやすくすることをお勧めします。

NTP またはその他のソリューションを使用してサーバークロックを同期します。

他の一部のソリューションの場合と同様、クロック同期はパフォーマンスにとって重要ではありません。クロックスキューはオリジンの競合検出に影響を与える可能性がありますが、EDB Postgres Distributed は、存在するスキューを報告および管理する制御を提供します。EDB Postgres Distributed は、

> *Column-level conflict detection* で説明しているように、行バージョンの競合検出も提供します。

6.5 Limitations

展開を計画するときは、次の EDB Postgres 分散 PGD デザインの制限を考慮してください。

6.5.1 ノード

- PGD は、適切なハードウェアとネットワークを想定して、数百のノードを実行できます。ただし、メッシュベースの展開の場合、通常は 1 つのクラスターで 48 を超えるノードを実行することはお勧めしません。48 ノード制限を超えて追加の読み取りスケーラビリティが必要な場合は、メッシュネットワークへの接続を追加せずにサブスクライバ専用ノードを追加できます。
- PGD のコンセンサスメカニズムにフォールトトレランスを提供するために、グループ内のノードの最小推奨数は 3 です。2 つのノードのみの場合、ノードの 1 つが応答しない場合、コンセンサスは失敗します。分散シーケンス生成などの一部の PGD 操作では、コンセンサスが必要です。EDB Postgres Distributed が使用するコンセンサスメカニズムの詳細については、Architectural details を参照してください。

6.5.2 単一のインスタンス上の複数のデータベース

同じ Postgres インスタンス上の複数のデータベースで PGD を使用することのサポートは、PGD 5 から **非推奨** であり、PGD 6 ではサポートされなくなります。製品の機能を拡張するにつれて、操作的および機能的に導入される追加の複雑さはありません。マルチデータベースデザインではより長く実行可能です。

これがベストプラクティスであり、PGD インスタンスごとに 1 つのデータベースのみを構成することをお勧めします。

TPA を使用した展開の自動化と、CLI や PGD プロキシなどのツールは、既にその推奨事項を成文化しています。

単一のインスタンスで最大 10 のデータベースをホストすることは引き続き可能ですが、そうすると多くの差し迫ったリスクと現在の制限が発生します。

- PGD 構成の変更が必要な場合は、データベースごとに管理コマンドを実行する必要があります。これを行うと、潜在的な不一致とエラーのリスクが増加します。
- 各データベースを個別に監視する必要があり、オーバーヘッドを追加します。
- TPAexec は、1 つのデータベースを想定しています。より多くのデータベースのレプリケーションを設定するには、顧客または EDB プロフェッショナルサービスチームが展開後フックで追加のコーディングが必要です。
- PGD プロキシは、データベースレベルではなく Postgres インスタンスレベルで動作します。つまり、リーダーノードがすべてのデータベースで同じであることを意味します。
- データベースを追加するごとに、サーバーのリソース要件が増加します。それぞれが、レプリケーションを維持する独自のワーカープロセス、たとえば、論理ワーカー、WAL センダー、WAL レシーバーなどを必要とします。それぞれは、レプリケーションクラスター内の他のインスタンスへの独自の接続セットも必要です。これらのニーズは、すべてのデータベースのパフォーマンスに重大な影響を与える可能性があります。

・ノードを再構築または追加する場合、1 つのデータベースに 1 つのノードにのみ物理初期化方法 `bdr_init_physical` を使用できます。論理レプリケーションによって他のすべてのデータベースを初期化する必要がありますが、これは時間がかかるため、大規模なデータベースの場合問題になる可能性があります。

- CAMO やグループコミットなどの同期レプリケーション方法は、予想通りに動作しません。Postgres WAL はデータベース間で共有されるため、同期コミット確認は任意のデータベースから取得できますが、必ずしも正しいコミットの順序ではありません。
- CLI と OTEL の統合 v5 の新機能は、1 つのデータベースを想定しています。

6.5.3 CAMO

Commit At Most Once

CAMO は、アプリケーションが複数回コミットするのを防ぐことを目的とした機能です。この機能を使用する場合、計画時に次の制限を考慮してください。

- CAMO は、オリジンノードで最近失敗した COMMIT の結果を照会するように設計されています。したがって、切断が発生した場合に、CAMO パートナーからトランザクションステータスをすぐに要求するようにアプリケーションをコーディングします。障害が発生してからステータスを要求するまでの遅延をできるだけ短くしてください。アプリケーションは、15 分を超えて保存される CAMO 決定に依存してはなりません。
- 再起動などの結果、アプリケーションが割り当てられたグローバル識別子を忘れた場合、それを回復する簡単な方法はありません。したがって、アプリケーションはシャットダウンする前に、未処理のトランザクションが終了するのを待機することをお勧めします。
- クライアントが適切なチェックを適用するには、CAMO によって保護されたトランザクションを、暗黙的なトランザクション制御を備えた単一のステートメントにすることはできません。また、CAMO は、トランザクション制御プロシージャ、またはトランザクションを開始または終了しようとする `DO` ブロックで使用することはできません。
- CAMO はコミットステータスを解決しますが、コミット時の保留中の通知を解決しません。CAMO および Eager Replication オプションでは、 `NOTIFY` SQL コマンドまたは `pg_notify()` ファンクションは使用できません。`LISTEN` または `UNLISTEN` も許可されません。
- 変更を再生するときに、CAMO トランザクションは他のトランザクションと同様に競合を検出する場合があります。タイムスタンプ競合検出が使用される場合、CAMO トランザクションは、プリペアオンザオリジンノードのタイムスタンプを使用します。これは、トランザクションがオリジンノード自分自身で可視される前です。
- CAMO は現在トランザクションストリーミングと互換性がありません。CAMO を使用する予定がある場合は、必ずトランザクションストリーミングを無効にしてください。このオプションはグローバルにまたは PGD ノードグループで構成できます。*Transaction streaming configuration* を参照してください。
- CAMO を使用する場合、すべての DDL を実行できるわけではありません。サポートされていない DDL を使用する場合、警告がログに記録され、トランザクションのコミットスコープはローカルのみに設定されます。サポートされている DDL 操作は次のとおりです。- 非コンカレント `CREATE INDEX` - 非コンカレント `DROP INDEX` - 個々のテーブルまたはインデックスの非コンカレント `REINDEX` - `CLUSTER` 単一のリレーションまたはインデックスのみ - `ANALYZE` - `TRUNCATE`

6.5.4 グループコミット

グループコミット は、グループ内のノードを介した構成可能な同期コミットを有効にします。この機能を使用する場合、次の制限を考慮してください。

- グループコミットを使用する場合、すべての DDL を実行できるわけではありません。サポートされていない DDL を使用する場合、警告がログに記録され、トランザクションのコミットスコープがローカルに設定されます。サポートされている DDL 操作は次のとおりです。- 非コンカレント `CREATE INDEX` - 非コンカレント `DROP INDEX` - 個々のテーブルまたはインデックスの非コンカレント `REINDEX` - `CLUSTER` 単一のリレーションまたはインデックスのみ - `ANALYZE` - `TRUNCATE`

6.5.5 Eager

熱心な は、グループコミットで使用できます。競合する可能性のあるトランザクションを積極的に中止することにより、競合を回避します。これには、グループコミットと同じ制限が適用されます。

6.5.6 その他の制限

この非包括的なリストには、予想されるデザインによる他の制限が含まれています。将来的にそれらを解決する予定はありません。展開を計画するときは、次の制限を考慮してください。

- ノードをフィジカルスタンバイに置き換えることは、 CAMO/Eager/Group Commit を使用するノードでは機能しません。可能であっても、フィジカルスタンバイと EDB Postgres 分散を組み合わせることはお勧めしません。
- `galloc` シーケンスは、ロールバックしたトランザクションでシーケンスを作成し、同じ名前で再度作成する場合、一部のチャンクをスキップする場合があります。チャンクのスキップは、DDL レプリケーションがアクティブでないときにシーケンスを作成して削除し、DDL レプリケーションがアクティブなときに再度作成する場合にも発生する可能性があります。順序保証に違反しないため、問題の影響は軽度です。シーケンスは、一部の最初のチャンクのみをスキップします。また、回避策として、シーケンスの開始値を `bdr.alter_sequence_set_kind()` ファンクションの引数として指定できます。
- 古い同期レプリケーションは、 CAMO、Eager、およびグループコミットで使用されるものとは異なるトランザクション確認のメカニズムを使用します。この 2 つは互換性がないため、一緒に使用しないでください。
- Postgres の 2 フェーズコミット 2PC トランザクションつまり *PREPARE TRANSACTION* は、 CAMO、グループコミット、または Eager Replication で使用できません。これらの機能は下で 2 フェーズコミットを使用するためです。

第7章　Installing

EDB Postgres 分散 PGD は、高度な競合管理、データ損失保護、およびネイティブ論理レプリケーションより最大 5 倍高速のスループットを備えたマルチマスターレプリケーションとデータ分散を提供します。最大ファイブナインの高可用性を備えた分散 Postgres クラスターが有効になります。

デフォルトでは、 EDB Postgres 分散は非同期レプリケーションを使用し、ローカルコミットの後にのみピアノードに変更を適用します。

> グループコミット 、 *CAMO* またはコミット・アット・モスト・ワンス 、または熱心な レプリケーションを構成することにより、異なるノード、ノードのグループ、またはすべてのノード間の追加レベルの同期性を構成できます。

7.1 Upgrading

7.1.1 PGD のアップグレード

EDB Postgres Distributed は、柔軟なプラットフォームです。これは、アップグレードパスが PGD のインストール方法に大きく依存することを意味します。

*** *Upgrading with TPA* ** - TPA を使用してインストールした場合、自動アップグレード機能を使用して最新のマイナーバージョンにアップグレードできます。

*** *Upgrading manually* ** - PGD クラスターを手動でインストールして構成した場合、このセクションでは、マイナーとメジャーの両方のバージョン間でクラスターを移動するために必要な詳細と手順を見つけます。

*** *Supported PGD upgrade paths* ** - このページでは、利用可能なサポートされているアップグレードパスについて説明します。

*** *Compatibility changes* ** - PGD 3.x または 4.x から PGD 5.x 以降にアップグレードする場合、このページではバージョン間の互換性の変更について説明します。

7.1.2 その他のアップグレード

*** *In-place Postgres upgrades* ** - bdr_pg_upgrade を使用してノードまたは複数のノードの Postgres バージョンを手動でアップグレードする方法。

*** *Application schema upgrades* ** - PGD で複数の分散サーバーを実行している場合、アプリケーションのスキーマを安全にアップグレードするためのガイド。

Upgrading PGD clusters with TPA

マイナーおよびメジャー PGD のアップグレード

PGD のマイナーバージョンのアップグレードは自動的に管理されます

PGD のメジャーバージョンのアップグレードには、展開構成が含まれる TPA `config.yml` ファイルを変更する必要があります。

以前の PGD メジャーバージョンから PGD 5 にアップグレードする場合は、
tpaexec reconfigure を使用して、展開構成に適切な変更を加えることができます。

`reconfigure` コマンドでは、アーキテクチャの設定が必要です実行するには、`PGD_Always_ON` および PGD プロキシルーティングのみ。実行前に展開構成をバックアップすることを忘れず、`--describe` および`--output` オプションを使用して再構成をプレビューします。

前提条件

- TPA が PGD クラスターを展開したときに作成されたクラスター構成ディレクトリ。
- PGD のメジャーバージョンのアップグレードを実行する場合は、`tpaexec reconfigure` が実行され、 appropriate configuration changes が作成されていることを確認します。

アップグレード

走る

```
tpaexec upgrade clustername
```

ここで、 **clustername** は、クラスターの名前とクラスター構成ディレクトリへのパスです。デフォルトでは、TPA はクラスターの各ノードを、ノードが構成されたソフトウェアの最新のマイナーバージョンにアップグレードします。

- クラスターをアップグレードするためのすべての前提条件が満たされていることを確認します。

クラスター内の各インスタンスについて、正しいリポジトリが構成されていること、および必要な *postgres* パッケージがそれらの中で利用可能なことを確認します。クラスター内の BDR ノードごとに、一度に 1 つずつ**ノードをフェンスして、*pgd-proxy* がそれに接続を送信しないようにします。**postgres を停止、更新、および再起動します。**ノードのフェンスを解除して、再び接続を受信できるようにします。**このノードに該当する場合、pgbouncer、pgd-proxy、および pgd-cli を更新します。

!!!

Upgrading PGD clusters manually

EDB Postgres Distributed は複数のソフトウェアコンポーネントで構成されているため、アップグレード戦略はアップグレードされるコンポーネントに部分的に依存します。

通常、ローリングアップグレードと呼ばれるアプローチを使用して、ほぼゼロのダウンタイムでクラスターをアップグレードできます。このアプローチを使用して、ノードは 1 つずつアップグレードされ、アプリケーション接続は既にアップグレードされたノードにスイッチオーバーされます。

すべてのノードを停止し、すべてのノードでアップグレードを実行して、クラスター全体を再起動することもできます。このアプローチは、標準の PostgreSQL セットアップと同じです。すべてのノードを同時にアップグレードするこの戦略は、ソフトウェアの混合バージョンでの実行を回避するため、最も簡単です。ただし、ダウンタイムが発生するため、何らかの理由でローリングアップグレードを実行できない場合を除き、お勧めしません。

EDB Postgres 分散クラスターをアップグレードするには

1. アップグレードを計画します。

2. アップグレードの準備をします。

3. サーバーソフトウェアをアップグレードします。

4. アップグレードを確認および検証します。

アップグレード計画

各ノードをアップグレードするには、主に 2 つの方法があります。

- 配置されているノードを新しいソフトウェアバージョンにアップグレードします。*Rolling server software upgrades* を参照してください。
- ノードを、新しいバージョンがインストールされたものに置き換えます。*Rolling upgrade using node join* を参照してください。

これらのアプローチは両方ともローリング方法で使用できます。

ローリングアップグレードの考慮事項

クラスターでローリングアップグレードが実行されている間、ソフトウェアの混合バージョンがクラスターで実行されています。たとえば、ノード A の PGD 3.7.16 が、ノード B およびノード C の 4.1.0 であるとします。この状態では、レプリケーションとグループ管理は最も古いバージョンこの例では 3.7.16 のプロトコルと機能を使用するため、新しいバージョンが提供するプロトコルの変更を必要とする新機能は無効になっています。すべてのノードが同じバージョンにアップグレードされると、新機能が有効になります。

同様に、WAL デコーダー対応ノードを含むクラスターがローリングアップグレードを実行している場合、高いバージョンの PGD ノードの WAL デコーダーは、より高い pg 論理バージョンで LCR
logical change records を生成します。

PGD ノードの下位バージョンの WAL デコーダは、下位の pg 論理バージョンの LCR を生成します。その結果、プロトコルバージョンの不一致のため、PGD ノードの上位バージョンの WAL 送信者は LCR を使用することはできません。PGD ノードの下のバージョンでは、WAL 送信者は LCR を使用し続けることができます。すべての PGD ノードが同じ PGD バージョンになると、WAL 送信者は LCR を使用します。

ローリングアップグレードは、以前のリリースのすべてのノードを含むクラスターで開始されます。次に、すべてのノードが新しいリリースになるまで、一度に 1 つのノードを新しいリリースにアップグレードして続行します。同時に実行されるソフトウェアのバージョンは 3 つまでです。別のアップグレードを開始する前に、すべてのノードを完全にアップグレードした状態でアップグレードを完了する必要があります。

ビジネスリスクを軽減するために注意が必要な場合、アップグレードプロセスに時間がかかる場合があります。ただし、ソフトウェアの混合バージョンを無期限に実行することはお勧めしません。

ローリングアップグレードを使用してソフトウェアのメジャーバージョンをアップグレードすることはできますが、1 つのクラスターでの PostgreSQL、EDB Postgres Extended、および EDB Postgres Advanced Server の混合はサポートされていません。したがって、このアプローチを使用して Postgres バリアントを変更することはできません。

警告: EDB Postgres Distributed のダウングレードはサポートされていません。クラスターを手動で再構築する必要があります。

ローリングサーバーソフトウェアのアップグレード

ローリングアップグレードとは、クラスターを停止せずに、クラスター内の各ノードで *server software upgrade* がシークエンシャルにアップグレードされる場合です。各ノードはクラスターへの参加が一時的に停止され、サーバーソフトウェアがアップグレードされます。更新されると、クラスターに返され、不在中のクラスターのアクティビティに追いつきます。

実際の手順は、Postgres コンポーネントが新しいメジャーバージョンにアップグレードされるかどうかによって異なります。

アップグレードプロセス中に、現在アップグレードされていないノードにアプリケーションをスイッチオーバーして、アプリケーションのデータベースの継続的な可用性を提供できます。

ノード参加を使用したローリングアップグレード

サーバーソフトウェアをアップグレードするもう 1 つの方法は、新しいノードをクラスターに参加させ、後で古いバージョンのソフトウェアを実行している既存のノードのいずれかをドロップすることです。

このアプローチの場合、手順は常に同じです。ただし、ノード参加が含まれるため、大規模なデータ転送が必要になる可能性があります。

すべてのノードが Postgres の新しい同じリリースにアップグレードされるまで、新しい Postgres バージョンでのみ使用可能な機能を使用しないように注意してください。これは、Postgres の新しいリリースに追加された新しい DDL 構文に特に当てはまります。

注釈: *bdr_init_physical* は、ソースノードのバイトごとのコピーを作成するため、メジャー Postgres バー

ジョンから別のバージョンへのアップグレード中に使用できません。実際、現在 `bdr_init_physical` では、ソースの PGD バージョンと参加ノードでもまったく同じであることが必要です。新しいノードに参加する方法によるローリングアップグレードには使用できません。代わりに、論理結合を使用します。

CAMO 対応クラスターのアップグレード

CAMO 対応クラスターをアップグレードするには、CAMO グループを 1 つずつアップグレードする必要がありますが、アップグレードするグループの CAMO 保護を無効にし、新しい **コミットスコープ** ベースの設定を使用して再構成する必要があります。

CAMO ペアを構成する 2 つの BDR ノードを PGD 5.0 にアップグレードするには、次のアプローチをお勧めします。

- 2 つのノードのいずれかのトランザクションで `bdr.enable_camo` が `off` のままであることを確認するか、クライアントを 2 つのノードからリダイレクトします。CAMO を使用しようとするときに CAMO ペアリングを削除すると、エラーが発生し、それ以上のトランザクションが防止されます。
- `bdr.camo_origin_for` および `bdr.camo_parter_of` をリセットすることにより BDR 3.7.x からアップグレードする場合、または `bdr.remove_camo_pair` BDR 4.x でを使用することにより、CAMO の構成を解除することにより、ペアのカップリングを解除します。
- 2 つのノードを PGD 5.0 にアップグレードします。
- 2 つのノードの専用ノードグループを作成し、そのノードグループに移動します。
- このノードグループ、および CAMO を使用するノードのペアの **コミットスコープ** を作成します。
- `default_commit_scope` を設定するか、セッションまたはトランザクションに `bdr.enable_camo` の代わりに `bdr.commit_scope` を明示的に設定するようにクライアントを変更することにより、CAMO 保護を再度アクティブにします。
- 必要に応じて、クライアントが CAMO 保護ノードに再度接続できるようにします。

アップグレードの準備

ソフトウェアの各メジャーリリースには、以前のリリースとの互換性性に影響を与える可能性のあるいくつかの変更が含まれています。これらは、Postgres 構成、展開スクリプト、および PGD を使用するアプリケーションに影響を与える可能性があります。アップグレードの前に、これらの変更を検討し、必要な調整を行うことをお勧めします。

> *EDB Postgres Distributed Release notes* およびバージョン固有のアップグレードノートで記載されている個々の変更を参照してください。

サーバーソフトウェアのアップグレード

個々のノードに分散された EDB Postgres のアップグレードは、インプレースで発生します。BDR 拡張機能をアップグレードするときにバックアップと復元を行う必要はありません。

BDR 拡張機能のアップグレード

BDR 拡張機能のアップグレードプロセスは、いくつかの手順で構成されています。

Postgres を停止します

バイナリパッケージのアップグレード中に、通常は最初に実行中の Postgres サーバーを停止するのが最善です。そうすることで、アップグレード中に予期せず再起動が発生した場合に、混合バージョンがロードされなくなります。

アップグレードパッケージ

アップグレードの最初の手順は、新しいバージョンの BDR パッケージをインストールすることです。このインストールでは、新しいバイナリと拡張 SQL スクリプトの両方をインストールします。この手順はオペレーティングシステムに固有です。

Postgres を開始する

パッケージがアップグレードされたら、Postgres インスタンスを起動できます。BDR 拡張機能は、新しいバイナリが拡張機能の古いバージョンを検出すると、起動時にアップグレードされます。

Postgres のアップグレード

Postgres のインプレースアップグレードのプロセスは、Postgres の新しいマイナーバージョンにアップグレードするか、Postgres の新しいメジャーバージョンにアップグレードするかによって異なります。

マイナーバージョン Postgres のアップグレード

Postgres の新しいマイナーバージョンへのアップグレードは、*upgrading the BDR extension* に似ています。通常、Postgres の停止、パッケージのアップグレード、および Postgres の再起動だけが必要なすべてです。

ただし、特定のマイナーバージョンのアップグレードには、インデックスの再作成などのより多くの手順が推奨される場合があります。アップグレード先の Postgres のバージョンのリリースノートを参照してください。

メジャーバージョン Postgres のアップグレード

Postgres の新しいメジャーバージョンへのアップグレードは、マイナーバージョンへのアップグレードよりも複雑です。

EDB Postgres Distributed は、 `bdr_pg_upgrade` コマンドラインユーティリティを提供し、

> *In-place Postgres major version upgrades* を実行するために使用できます。

注釈: Postgres、 BDR 拡張機能、その他を含むソフトウェアの新しいメジャーバージョンにアップグレードする場合、アップグレードするソフトウェアのターゲットバージョンとアプリケーションの互換性を確認することが常に重要です。

アップグレードのチェックと検証

PGD ノードをアップグレードした後、バイナリの現在のバージョンを確認できます。

```
SELECT bdr.bdr_version();
```

ノードをアップグレードした後は常に *Monitoring* をチェックして、アップグレードされたノードが予想通りに動作していることを確認します。

HARP から PGD プロキシへの移動

HARP は、新しい **接続管理** 構成と一時的に共存できます。これは、次のことができることを意味します。

- pre-5 クラスター全体を PGD 5 クラスターにアップグレードします。
- 接続ルーティングを設定します。
- HARP プロキシを PGD プロキシに置き換えます。
- アプリケーション接続を PGD プロキシインスタンスに移動します。
- すべてのサーバーから HARP Manager を削除します。

ノードを PGD 5 にアップグレードした後、できるだけ早くこれを行うことを強くお勧めします。HARP は、PGD 5 での長期使用が認定されていません。

TPA は、このためのいくつかの便利なツールを提供し、最終的には PGD 4 と PGD 5 間の単一コマンドのアップグレードパスを提供します。

Supported PGD upgrade paths

バージョン 5 内のアップグレード

バージョン 5.x リリースからそれ以降の 5.x リリースにアップグレードできます。

バージョン 4 からバージョン 5 へのアップグレード

PGD 4 から PGD 5 へのアップグレードは、バージョン 4.3.0 からサポートされています。以前のバージョンの場合、5 にアップグレードする前に 4.3.0 にアップグレードしてください。詳細については、Upgrading within 4 を参照してください。

通常、最新のバージョン 5 リリースにアップグレードする前に、最新のバージョン 4 リリースにアップグレードすることをお勧めします。4.3.0 以降にアップグレードした後、次のアップグレードパスが可能です。

From version	To version
4.3.0	5.0.0 or later
4.3.1	5.1.0 or later
4.3.2	5.1.0 or later
4.3.3	5.1.0 or later

バージョン 3.7 からバージョン 5 へのアップグレード

現時点では、TPA は PGD 3.7 から 4 および PGD 4 から 5 のみを有効にしています。3.7 から 5 に移行し、自動化が必要な場合は、この 2 段階のアップグレードパスを使用する必要があります。潜在的に、プロキシアーキテクチャは、HA プロキシから HARP 、最後に PGD プロキシまで複数回変更されます。

3.7 から 5 への直接アップグレードを可能かつ簡単にするために、重要な開発が行われました。PGD 5 でサポートされるデータベースバージョンを拡張し、複数の PGD バージョンにわたって BDR 拡張機能のアップグレード可能を有効にしました。以前は、以前のメジャーバージョンからのアップグレードのみをサポートしていました。多くの場合、データベースのアップグレードも必要でした。両方の PGD バージョンで 1 つのデータベースメジャーバージョンのみがサポートされていたためです。

第 4 四半期までに TPA を使用して 3.7 から 5 への直接アップグレードパスを提供するために開発が現在進行中です。それまでは、EDB プロフェッショナルサービスまたはサポートに連絡して、支援とガイダンスを得ることができます。

Compatibility changes

PGD 5 の変更の多くは、PGD 4 または PGD 3.7 との下位互換性がありません。

接続ルーティング

HARP Manager はもう存在しません。これは、新しい 接続管理 構成に置き換えられました。

HARP プロキシは、同様に機能する PGD プロキシに置き換えられます。これは、非推奨の機能を削除し、接続管理構成を介して構成されます。

Commit At Most Once

CAMO 構成は、 コミットスコープ を介して実行されるようになりました。bdr.camo_pairs カタログおよび関連する操作ファンクションは、もう存在しません。bdr.enable_camo GUC は削除されました。synchronous_replication_availability GUC は CAMO に影響を与えなくなりました。コミットスコープの DEGRADE ON ... TO ASYNC 句を使用します。

Eager All-Node Replication

global スコープは存在しません。同じ動作のスコープを作成するには、
グループコミット を使用します。

```
SELECT bdr.add_commit_scope(
    commit_scope_name := eager_scope,
    origin_node_group := top_group,
    rule := ALL (top_group) GROUP COMMIT (conflict_resolution = eager, commit_
↪decision = raft) ABORT ON (timeout = 60s),
    wait_for_ready := true
);
```

bdr.global_commit_timeout GUC は削除されました。コミットスコープには ABORT ON 句を使用します。

遅延制御

CAMO や Eager と同様に、Lag Control 構成も コミットスコープ に移動して、より柔軟な耐久性構成を実現します。

カタログ

- bdr.workers は、worker_commit_timestamp のようなワーカー固有の情報を表示しなくなりました。
- bdr.worker_errors は非推奨であり、情報のほとんどが失われます。
- bdr.state_journal_details は非推奨であり、情報のほとんどが失われます。
- bdr.event_summary は、 bdr.worker_errors および bdr.state_journal_details を Raft ロールの変更などの追加情報に置き換えます。
- テーブル bdr.node_catchup_info に、よりわかりやすい方法で情報を表示するユーザーコンシューマブルビュー bdr.node_catchup_info_details があります。
- Witness ノードは、レプリケートするレプリケーションセットではなく、bdr.node_summary の node_kind 値を使用して区別されます。
- すべての Raft コンセンサス関連のテーブルとファンクションは、マルチプルの Raft インスタンスサブグループ Raft をサポートするように調整されました。
- 情報がテーブルに保存されなくなったため、 bdr.node_pre_commit ビューと基になるテーブルが削除されました。
- bdr.commit_decisions ビューが追加され、 bdr.node_pre_commit ビューが置き換えられました。
- その背後にあるメカニズムが一般化されたため、複数の内部自動パーティションテーブルが tascmgr テーブルに置き換えられました。
- bdr.network_monitoring ビューは、基になるテーブルおよびファンクションとともに削除されました。
- カタログ で説明しているように、多くのカタログが追加され、一部には新しい列があります。これらは厳密には破壊的な変更ではありませんが、アップグレードの際に確認することをお勧めします。

In-place Postgres major version upgrades

コマンドラインユーティリティ bdr_pg_upgrade を使用して、PGD ノードを Postgres の新しいメジャーバージョンにアップグレードできます。

bdr_pg_upgrade は、標準の pg_upgrade のラッパーです

PGD 固有のロジックをプロセスに追加して、スムーズなアップグレードを保証します。

用語

この用語は、アップグレードプロセスと関連するコンポーネントを説明するときに使用されます。

Postgres **クラスター**—データベースファイルは実行可能ファイルとデータの両方で、実行時にシステム上の Postgres データベースインスタンスを構成します。

古い *Postgres* **クラスター**—アップグレードする既存の Postgres クラスター、データを移行するクラスター。

新しい *Postgres* クラスター—データの移行先の新しい Postgres クラスター。この Postgres クラスターは、古いクラスターの 1 つ前のメジャーバージョンである必要があります。

注意事項

両方の Postgres クラスターが
pg_upgrade のすべての要件を満たしている必要があるという事実を含む、標準の Postgres メジャーバージョンのアップグレードに関する注意事項が適用されます。

さらに、他のツールがレプリケーションスロットとレプリケーション起点を使用している場合は、bdr_pg_upgrade を使用しないでください。アップグレード後には、PGD スロットとオリジンのみが復元されます。

bdr_pg_upgrade のいくつかの前提条件を満たす必要があります。

- 古い Postgres クラスターを使用してアプリケーションを切断します。たとえば、PGD クラスター内の別のノードにリダイレクトできます。
- 両方の Postgres クラスターのピア認証を構成します。bdr_pg_upgrade はピア認証が必要です。
- 両方のクラスターに同じ PGD バージョンをインストールする必要があります。
- PGD バージョンは 4.1.0 以上である必要があります。バージョン 3.7.22 以降もサポートされています。
- 新しいクラスターはシャットダウン状態である必要があります。
- 新しいクラスターに PGD パッケージをインストールする必要があります。
- 新しいクラスターは、古いクラスター構成と一致するように、必要に応じて既に初期化および構成されている必要があります。
- データベース、テーブル、およびその他のオブジェクトは、新しいクラスターに存在してはなりません。

また、bdr_pg_upgrade を実行する前に、古い Postgres クラスターを起動することをお勧めします。CLI は、古い Postgres クラスターがシャットダウンしている場合、それを起動します。

使用法

Postgres の新しいメジャーバージョンにアップグレードするには、最初に新しいバージョンをインストールする必要があります。

bdr_pg_upgrade コマンドライン

bdr_pg_upgrade は、すべてのパラメーターを pg_upgrade に渡します。したがって、
pg_upgrade でサポートされているパラメーターを指定できます。

概要

```
bdr_pg_upgrade [OPTION] ...
```

オプション

pg_upgrade のオプションに加えて、次のパラメーターを bdr_pg_upgrade に渡すことができます。

必須パラメーター

これらのパラメーターは、コマンドラインで指定するか、 `--database` パラメーターを除くすべての場合、同等の環境変数で指定します。これらは bdr_pg_upgrade によって使用されます。

- `-b, --old-bindir` —古い Postgres クラスターの bin ディレクトリ。
- `-B, --new-bindir` —新しい Postgres クラスターの bin ディレクトリ。
- `-d, --old-datadir` —古い Postgres クラスターデータディレクトリ。
- `-D, --new-datadir` —新しい Postgres クラスターデータディレクトリ。
- `--database` — PGD データベース名。

オプショナルパラメーター

これらのパラメーターはオプショナルであり、bdr_pg_upgrade によって使用されます。

- `-p, --old-port` —古いクラスターポート番号。
- `-s, --socketdir` —アップグレード中にポストマスターソケットに使用するディレクトリ。
- `--check` —チェックのみを実行し、クラスターを変更しないように指定します。

その他のパラメーター

上記のいずれでもない他のパラメーターは pg_upgrade に渡されます。pg_upgrade は次のパラメーターを受け入れます。

- `-j, --jobs` —同時に使用するプロセスまたはスレッドの数。
- `-k, --link` —新しいクラスターにファイルをコピーする代わりに、ハードリンクを使用します。
- `-o, --old-options` —古い postgres コマンドに渡すオプション。複数の呼び出しが追加されます。
- `-O, --new-options` —新しい postgres コマンドに渡すオプション。複数の呼び出しが追加されます。
- `-N, --no-sync` —アップグレードされたクラスター内のすべてのファイルがディスクに書き込まれるのを待たないでください。
- `-P, --new-port` —新しいクラスターポート番号。
- `-r, --retain` —正常に完了した後でも SQL ファイルとログファイルを保持します。
- `-U, --username` —クラスターのインストールユーザー名。
- `--clone` —効率的なファイルのクローン作成を使用します。

環境変数

コマンドラインパラメーターの代わりにこれらの環境変数を使用できます。

- PGBINOLD —古い Postgres クラスターの bin ディレクトリ。
- PGBINNEW —新しい Postgres クラスターの bin ディレクトリ。
- PGDATAOLD —古い Postgres クラスターデータディレクトリ。
- PGDATANEW —新しい Postgres クラスターデータディレクトリ。
- PGPORTOLD —古い Postgres クラスターポート番号。
- PGSOCKETDIR —アップグレード中にポストマスターソケットに使用するディレクトリ。

例

次のようなシナリオがあるとします。

- 古い Postgres クラスターの bin ディレクトリは/usr/lib/postgresql/13/bin です。
- 新しい Postgres クラスターの bin ディレクトリは/usr/lib/postgresql/14/bin です。
- 古い Postgres クラスターデータディレクトリは/var/lib/postgresql/13/main です。
- 新しい Postgres クラスターデータディレクトリは/var/lib/postgresql/14/main です。
- データベース名は bdrdb です。

次のコマンドを使用して、クラスターをアップグレードできます。

```
bdr_pg_upgrade \
- -old-bindir /usr/lib/postgresql/13/bin \
- -new-bindir /usr/lib/postgresql/14/bin \
- -old-datadir /var/lib/postgresql/13/main \
- -new-datadir /var/lib/postgresql/14/main \
- -database bdrdb
```

実行された手順

これらの手順は、 bdr_pg_upgrade の実行時に実行されます。

注釈: *--check* が bdr_pg_upgrade への引数として指定される場合、CLI はデータベースを変更する手順をスキップします。

PGD Postgres チェック

Steps	*--check* supplied
Collecting pre-upgrade new cluster control data	*run*
Checking new cluster state is shutdown	*run*
Checking PGD versions	*run*
Starting old cluster (if shutdown)	*skip*
Connecting to old cluster	*skip*
Checking if bdr schema exists	*skip*
Turning DDL replication off	*skip*
Terminating connections to database.	*skip*
Waiting for all slots to be flushed	*skip*
Disconnecting from old cluster	*skip*
Stopping old cluster	*skip*
Starting old cluster with PGD disabled	*skip*
Connecting to old cluster	*skip*
Collecting replication origins	*skip*
Collecting replication slots	*skip*
Disconnecting from old cluster	*skip*
Stopping old cluster	*skip*

pg_upgrade 手順

標準の pg_upgrade 手順が実行されます。

注釈: 指定された場合、 *--check* は pg_upgrade に渡されます。

PGD のアップグレード後の手順

Steps	*--check* supplied
Collecting old cluster control data	*skip*
Collecting new cluster control data	*skip*
Advancing LSN of new cluster	*skip*
Starting new cluster with PGD disabled	*skip*
Connecting to new cluster	*skip*
Creating replication origin, repeated for each origin	*skip*
Advancing replication origin, repeated for each origin	*skip*
Creating replication slot, repeated for each slot	*skip*
Stopping new cluster	*skip*

Application schema upgrades

EDB Postgres Distributed のアップグレードと同様に、アプリケーションスキーマをアップグレードするには 2 つのアプローチがあります。より簡単なオプションは、影響を受けるすべてのアプリケーションを停止し、スキーマのアップグレードを実行し、新しいスキーマバリアントを使用するようにアップグレードされたアプリケーションを再起動することです。このアプローチでは、ある程度のダウンタイムが発生します。

このダウンタイムを排除するために、 EDB Postgres Distributed は、ローリングアプリケーションスキーマのアップグレードを実行するための便利なツールを提供します。

次の推奨事項とヒントは、クラスターに対するアプリケーションスキーマのアップグレードの影響を軽減します。

ローリングアプリケーションスキーマのアップグレード

デフォルトでは、 DDL はすべてのノードに自動的に送信されます。
DML and DDL replication and nonreplication で説明しているように、この動作は手動で制御できます。このアプローチを使用して、ノード全体にデータベーススキーマ間の差異を作成できます。

PGD は、ノード間のわずかな違いがあってもレプリケーションを続行できるように設計されています。これらの機能は、ダウンタイムなしでアプリケーションスキーマを移行できるように、またはロジカルスタンバイノードでレポートまたはテストをできるように設計されています。

> **警告:** PGD の外部でローリングアプリケーションスキーマのアップグレードを管理する必要があります。

これを実稼働クラスターで正しく動作させるには、注意的なスクリプトが必要です。広範なテストをお勧めします。

詳細は、 差分を含むノード間のレプリケーション を参照してください。

1 つのノードが新しいテーブルを追加する DDL を実行すると、最新の DDL をまだ受け取っていないノードは追加のテーブルを処理する必要があります。これを考慮して、ローリングスキーマアップグレードの適切な設定は、`target_table_missing` 競合が発生した場合に `skip` リゾルバーを適用するようにすべてのノードを構成することです。ノードにテーブルを追加する前に、この構成を実行します。この設定は永続的なものです。

次のクエリーを **各ノードで個別に** 実行します。 `node1` を実際のノード名に置き換えます。

```
SELECT bdr.alter_node_set_conflict_resolver(node1,
       target_table_missing, skip);
```

1 つのノードがテーブルに列を追加する DDL を実行すると、最新の DDL をまだ受け取っていないノードが追加の列を処理する必要があります。これを考慮して、ローリングスキーマアップグレードの適切な設定は、`target_column_missing` 競合が発生した場合に `ignore` リゾルバーを適用するようにすべてのノードを構成することです。1 つのノードに列を追加する前にこれを実行します。この設定は永続的なものです。

次のクエリーを **各ノードで個別に** 実行します。 node1 を実際のノード名に置き換えます。

```
SELECT bdr.alter_node_set_conflict_resolver(node1,
        target_column_missing, ignore);
```

1 つのノードがテーブルから列を削除する DDL を実行すると、最新の DDL をまだ受け取っていないノードが不足している列を処理する必要があります。この状況により、use_default_value リゾルバーを使用する source_column_missing 競合が発生します。したがって、NULL を受け入れず、DEFAULT 値を持たない列には、2 段階のプロセスが必要です。

1. NOT NULL 制約を削除するか、すべてのノードの列の DEFAULT 値を追加します。
2. カラムを取り外します。

コンストレインは、ローリング方法で削除できます。現在、一度に 1 ノードずつ、ローリング方法でテーブルコンストレインの追加を処理する方法はありません。

1 つのノードが既存の列の型を変更する DDL を実行すると、現在の型とターゲット型間のバイナリ強制性の存在によっては、オペレーションで基になるテーブルデータが書き換えられない場合があります。その場合、それは基になる列タイプのメタデータの更新だけです。テーブルの書き換えは通常制限されています。ただし、制御された DBA 環境では、すべてのノードの非レプリケート環境でこの列のタイプのローリングアップグレードを採用することにより、列のタイプを自動的にキャスト可能なものに変更できます。詳細は、
ALTER TABLE を参照してください。

7.2 Deploying EDB Postgres Distributed using Trusted Postgres Architect

自己管理設定で EDB Postgres 分散を展開する標準の方法は、EDB の展開ツール Trusted Postgres ArchitectTPA を使用することです。これは、セルフホストとクラウド EC2 内の両方の物理マシンと仮想マシンに適用されます。

無料トライアルアカウントと *Deploying EDB Postgres Distributed using Trusted Postgres Architect* TPA から *deploy directly to your own bare metal servers* を使用することもできます。

7.2.1 前提条件 TPA のインストール

TPA を使用して PGD を展開する前に、TPA をインストールする必要があります。続行する前に、*installation instructions in the Trusted Postgres Architect documentation* に従ってください。

7.2.2 構成

`tpaexec configure` コマンドは、選択したオプションに基づいて、クラスターを説明する単純な YAML 構成ファイルを生成します。構成はすぐに使用できるようになっており、ニーズに合わせて変更できます。構成ファイルの編集は、クラスターの作成前と後の両方で、クラスターの構成を変更する通常の方法です。

構文は次のとおりです。

```
tpaexec configure <cluster_dir> --architecture <architecture_name> [options]
```

使用可能な構成オプションには次のものが含まれます。

表 4: :header: Flags,Description :widths: 10,30 :align: left :class: longtable

--architecture	必須。 EDB Postgres 分散展開の場合は `PGD-Always-ON` に設定します。
–-postgresql <version> or *--edb-postgres-advanced <version>* or *--edb-postgres-extended <version>*	必須。使用する Postgres のディストリビューションとバージョンを指定します。詳細については、 *PGD/TPA upgrades* を参照してください。
--redwood or *--no-redwood*	`--edb-postgres-advanced` フラグが存在する場合に必要です。 Oracle データベース互換性機能が必要かどうかを指定します。
--location-names l1 l2 l3	必須。 PGD を展開する場所の名前を指定します。
--data-nodes-per-location N	ロケーションごとのデータノードの数を指定します。デフォルト 3 です。
--add-witness-node-per-location	ロケーションごとのデータノードが偶数の場合、監視ノードを追加してローカルコンセンサスを可能にします。 2 つのデータノードの場所でデフォルトで有効になっています。
--add-proxy-nodes-per-location	PGD プロキシをデータノードから分離するかどうか、および構成する数。デフォルトでは、データノードごとに 1 つのプロキシが構成および共同ホストされます。
--pgd-proxy-routing globalIlocal	PGD プロキシルーティングがグローバルまたはローカルロケーションごとに処理されるかどうか。
--add-witness-only-location loc	クラスター場所の 1 つを監視専用として指定しますその場所にはデータノードが存在しません。
--enable-camo	各ロケーションに CAMO ペアを設定します。ロケーションごとに 2 つのデータノードでのみ動作します。
PGD-Always-ON の TPA ドキュメントには、より多くの構成オプションがリストされています。	

例

```
[tpa]$ tpaexec configure ~/clusters/speedy \
        --architecture PGD-Always-ON \
        --platform aws \
```

(次のページに続く)

(前のページからの続き)

```
        --edb-postgres-advanced 15 \
        --redwood \
        --location-names eu-west-1 eu-north-1 eu-central-1 \
        --data-nodes-per-location 3 \
        --pgd-proxy-routing global
```

最初の引数は、クラスターディレクトリたとえば、speedy または~/clusters/speedy である必要があります。すべてのクラスターは、~/clusters などの共通のディレクトリに保持することをお勧めします。アーキテクチャを選択するには、次の引数が--architecture であり、その後にオプションが続く必要があります。

このコマンドは、 ~/clusters/speedy という名前のディレクトリを作成し、PGD-Always-ON アーキテクチャのレイアウトに従っている config.yml という名前の構成ファイルを生成します。tpaexec configure --architecture PGD-Always-ON --help コマンドを使用して、このアーキテクチャの構成オプションでサポートされている値を確認できます。

この例では、オプションは次を選択します。

- AWS 展開 --platform aws
- EDB Postgres Advanced Server バージョン 15 および Oracle 互換性--edb-postgres-advanced 15 および--redwood
- 3 か所 --location-names eu-west-1 eu-north-1 eu-central-1
- 各ロケーションに 3 つのデータノード --data-nodes-per-location 3
- グローバル --pgd-proxy-routing global のプロキシルーティングポリシー

一般的な構成オプション

その他の構成オプションには次のものが含まれます。

所有者

すべてのクラスターは、プロビジョニングされたリソースの責任者まで直接追跡できる必要があります。

デフォルトでは、クラスターは tpaexec provision を実行しているユーザーのログイン名が所有するものとしてタグ付けされます。この名前が個人を識別しない場合たとえば、postgres 、ec2-user 、 --owner SomeId を指定して識別可能な所有者を設定する必要があります。

イニシャル、「名、姓」、またはあなたを一意に識別するテキストを使用できます。

プラットフォームオプション

--platform のデフォルト値は aws であり、これは、PGD-Always-ON アーキテクチャでサポートされているプラットフォームです。

--region を指定して、アクセスがあり、必要な数のインスタンスを作成できる既存の AWS リージョンを指定します。デフォルトのリージョンは eu-west-1 です。

AWS の有効なインスタンスタイプで--instance-type を指定します。デフォルトは t3.micro です。

サブネットの選択

デフォルトでは、各クラスターには、10.33/16 の下のランダムな/28 サブネットが割り当てられます。ただし、アーキテクチャによっては、1 つ以上のサブネットが存在し、各サブネットは/24 から/29 の間の任意の場所にあります。

特定のサブネットを使用するには、 --subnet を指定します--subnet 192.0.2.128/27 など

ディスク領域

ルートボリュームのサイズを GB 単位で設定するには、 --root-volume-size を指定します、例、--root-volume-size 64 。デフォルトは 16GB です。インスタンスの作成に使用されるイメージによっては、ルートボリュームの最小サイズが存在する場合があります。

個別の Postgres および Barman ボリュームをサポートするアーキテクチャの場合

- --postgres-volume-size を指定して、Postgres ボリュームのサイズを GB 単位で設定します。デフォルトは 16GB です。
- --barman-volume-size を指定して、Barman ボリュームのサイズを GB 単位で設定します。デフォルトは 32GB です。

ディストリビューション

--os または--distribution を指定して、クラスターのインスタンスで使用する OS を指定します。値は大文字と小文字が区別されます。

選択したプラットフォームにより、使用可能なディストリビューションとデフォルトで使用されるディストリビューションが決まります。詳細については、tpaexec info platforms/<platformname> を参照してください。

通常、 Debian 、RedHat 、および Ubuntu を使用して、Postgres およびその他のソフトウェアがプリインストールされている TPA イメージを選択できます展開時間を削減します。代わりにストック分布画像を使用するには、値に-minimal を追加しますたとえば、--distribution Debian-minimal 。

リポジトリ

TPA を使用して PDG 5 以降を展開する場合、TPA は EDB Repos 2.0 からリポジトリを選択します。すべてのソフトウェアはこれらのリポジトリから取得しています。

> EDB Repos 2.0 を使用するには、

tpaexec を実行する前に `export EDB_SUBSCRIPTION_TOKEN=xxx` を使用する必要があります。 the web interface からサブスクリプショントークンを取得できます。

オプションで、`--edb-repositories repository …`を使用して、各インスタンスにインストールするデフォルトのリポジトリに加えて、EDB リポジトリを指定します。

ソフトウェアバージョン

デフォルトでは、TPA は Postgres の最新メジャーバージョンを使用します。`--postgres-version` を指定して以前にサポートされているメジャーバージョンをインストールするか、

> **構成** で説明しているフラグのいずれかを使用してバージョンとディストリビューションの両方を指定します。

デフォルトでは、TPA はすべてのパッケージの最新バージョンをインストールします。これは、通常、望ましい動作です。ただし、一部のテストシナリオでは、特定のパッケージバージョンを選択する必要がある場合があります。例

```
- --postgres-package-version 10.4-2.pgdg90+1
- --repmgr-package-version 4.0.5-1.pgdg90+1
- --barman-package-version 2.4-1.pgdg90+1
- --pglogical-package-version 2.2.0*
- --bdr-package-version 3.0.2*
- --pgbouncer-package-version 1.8*
```

さらにパッケージをインストールするには、 `--extra-packages` または`--extra-postgres-packages` を指定します。前者は、システムパッケージとともにインストールするパッケージをリストします。後者は、Postgres パッケージとともに後でインストールするパッケージをリストしています。前者のリストで Postgres に依存するパッケージを記載すると、Postgres がまだインストールされていないため、インストールは失敗します。引数は変更せずにインストールのためにパッケージマネージャーに渡されます。

`--extra-optional-packages` オプションは`--extra-packages` と同様に動作しますが、名前付けたパッケージをインストールできない場合、これはエラーではありません。

ホスト名

デフォルトでは、tpaexec configure は、数十の名前の事前承認リストから必要な数のホスト名をランダムに選択します。これは、ほとんどのクラスターに十分です。

--hostnames-from を指定して、提供されたリストで使用可能なより多くの名前が必要な場合など、別のリストから名前を選択します。ファイルには、1 行に 1 つのホスト名を含める必要があります。

--hostnames-pattern を指定して、ホスト名を egrep-syntax パターンに一致するものに制限します。これを行う場合、パターンが有効なホスト名 [a-zA-Z0-9-] のみと一致し、十分な数のホスト名を検出することを確認する必要があります。

ロケーション

デフォルトでは、tpaexec configure は、選択したアーキテクチャが使用する場所に first、second などの名前を使用します。

--location-names を指定して、各場所にもっと意味のある名前を提供します。

7.2.3 プロビジョニング

tpaexec provision コマンドは、クラスターに必要なインスタンスとその他のリソースを作成します。プロセスの詳細は、クラスターの構成中に選択したアーキテクチャ PGD-Always-ON などとプラットフォーム AWS などによって異なります。

たとえば、必要な特権を持つ AWS アクセスが与えられると、TPA は EC2 インスタンス、VPC、サブネット、ルーティングテーブル、インターネットゲートウェイ、セキュリティグループ、EBS ボリューム、Elastic IP などをプロビジョニングします。

bare プラットフォームを選択し、接続の詳細を提供することにより、既存のサーバーをプロビジョニングすることもできます。これらはベアメタルサーバーであるか、クラウドプラットフォームで別途プロビジョニングされたサーバーであるかにかかわらず、TPA によって作成されたかのように使用できます。

単一のプラットフォームに制限されません。必要に応じて、クラスターを複数のリージョンのいくつかの AWS インスタンスと一部のオンプレミスサーバーまたは他のデータセンターのサーバーに分散できます。

プロビジョニングステージの最後に、基本的なオペレーティングシステムがインストールされた必要な数のインスタンスができます。TPA は、SSH ルートに sudo を使用してアクセスできます。

7.2.4 Deploy

tpaexec deploy コマンドは、プロビジョニングされたサーバーに Postgres およびその他のソフトウェアをインストールおよび構成します。TPA はサーバーを作成できますが、SSH と sudo アクセスが利用できる限り、誰が作成したかは関係ありません。これには、レプリケーション、バックアップなどの設定が含まれます。

展開ステージの最後に、 EDB Postgres Distributed が稼働しています。

7.2.5 テスト

`tpaexec test` コマンドは、展開されたクラスターに対してさまざまなアーキテクチャとプラットフォーム固有のテストを実行して、予想通りに動作することを確認します。

テスト段階の最後に、完全に機能するクラスターが完成します。

詳細については、 *Deploying EDB Postgres Distributed using Trusted Postgres Architect* を参照してください。

第8章　Using

8.1 Application use

PGD でのアプリケーションの開発は、PostgreSQL データベースでの作業とほぼ同じです。ただし、異なるのは、アプリケーションがレプリケーションとどのように相互作用するかを認識する必要があることです。PGD がアプリケーションでどのように動作するか、レプリケートされる SQL とされない SQL、さまざまなノードがどのように処理されるか、およびその他の重要な情報を知る必要があります。

- *Application behavior* は、次のような PGD レプリケーションがアプリケーションにどのように見えるかを調べます。- レプリケートされるコマンド - ローカルで実行されるコマンド - 行レベルのロックが取得されたとき - トリガーが起動する方法と場所 - ラージオブジェクト - トースト
- *DML and DDL replication and nonreplication* は、SQL ステートメントの 2 つのクラスの違いと、PGD がそれらのレプリケートを処理する方法を示します。また、PGD がまったくレプリケートしないコマンドも調べます。
- *Nodes with differences* は、レプリケートノードに異なるテーブル構造とスキーマが存在する構成で PGD がどのように動作するかを調べます。また、このようなノードを LiveCompare で比較する方法、およびノードで実行されている PostgreSQL バージョンの違いを処理する方法についても説明します。
- *Application rules* は、データ異常を回避するためのアプリケーションにいくつかの一般的なルールを提供します。
- *Timing considerations and synchronous replication* は、非同期/同期レプリケーションがアプリケーションのデータのビューにどのような影響を与える可能性があるかを示し、古い読み取りを軽減する機能を示します。
- *Use of table access methods (TAMs) in PGD* TAMs は、PGD で使用可能な TAM とそれらを有効にする方法をノートしています。

8.1.1 Application behavior

PGD のレプリケーション動作の多くは、アプリケーションに対して透過的です。PGD でうまく動作するアプリケーションの開発を成功させるには、それを実現する方法と透明でない要素を理解することが重要です。

レプリケーション動作

PGD は、あるノードで行われた変更の他のノードへの複製をサポートしています。

PGD は、デフォルトで、INSERT、UPDATE、DELETE、および TRUNCATE 操作からのすべての変更をソースノードから他のノードにレプリケートします。すべてのトリガーとルールが処理された後、最終的な変更のみが送信されます。たとえば、`INSERT ... ON CONFLICT UPDATE` は、オリジンで発生した内容に応じて、挿入または更新を送信します。更新または削除が影響を与える行がない場合、変更は送信されません。

前提条件なしで INSERT をレプリケートできます。

他のノードで更新と削除をレプリケートするには、PGD が影響を受ける一意の行を識別できる必要があります。PGD では、テーブルに PRIMARY KEY が定義されている場合、UNIQUE 制約、または特定の列に明示的な REPLICA IDENTITY が定義されていることが必要です。これらのいずれかが定義されていない場合、警告が生成され、その後の更新または削除は明示的にブロックされます。テーブルに REPLICA IDENTITY FULL が定義されている場合、一意のインデックスは必要ありません。その場合、更新と削除が許可され、ライブ、有効、遅延せず、式または WHERE 句を含まない最初の非一意のインデックスを使用します。それ以外の場合、シークエンシャルスキャンが使用されます。

Truncate

TRUNCATE は、レプリケーション ID が定義されていない場合でも使用できます。TRUNCATE コマンドのレプリケーションはサポートされていますが、外部キーで接続されたテーブルのグループを切り詰める場合には注意してください。truncate アクションをレプリケートする場合、サブスクライバーは、レプリケーションセットが定義されている場合を除き、CASCADE によって明示的に指定または暗黙的に収集された、オリジンで切り詰められたテーブルのグループを切り捨てます。詳細と例については、

> *Replication sets* を参照してください。これは、影響を受けるすべてのテーブルが同じサブスクリプションの一部である場合、正常に動作します。しかし、サブスクライバーで切り詰めるテーブルに、同じまたは任意のレプリケーションセットの一部ではないテーブルへの外部キーリンクがある場合、サブスクライバーに truncate アクションを適用すると失敗します。

行レベルのロック

INSERT、UPDATE、および DELETE コマンドによって暗黙的に取得された行レベルのロックは、変更が発生すると複製されます。INSERT、UPDATE、DELETE、および TRUNCATE コマンドによって暗黙的に取得されたテーブルレベルのロックもレプリケートされます。ユーザーセッションによる明示的な行レベルのロック `SELECT ... FOR UPDATE/FOR SHARE` はレプリケートされず、アドバイザリロックもレプリケートされません。SERIALIZABLE モードで実行されているトランザクションによって格納されている情報は、他のノードにレプリケートされません。SERIALAZABLE のトランザクション分離レベルがサポートされていますが、マルチプルのノードに同時トランザクションが存在する場合、トランザクションはノード全体でシリアル化されません。

DML がマルチプルのノードで同時に実行される場合、非同期レプリケーションで実行すると潜在的な競合が発生する可能性があります。これらに対処するか、回避する必要があります。
競合 で議論されているように、さまざまな回避メカニズムが可能です。

シークエンス

シーケンスには、

シークエンス で説明している特別な処理が必要です。これは、クラスターでは、ノードが競合する値を作成するのを避けるためにシーケンスをグローバルにする必要があるためです。グローバルシーケンスは、完全性を保証するグローバルロックで使用できます。

バイナリオブジェクト

BYTEA 列のバイナリデータは通常にレプリケートされ、最大 1 GB のデータの「blob」が許可されます。PostgreSQL の「ラージオブジェクト」機能の使用は、PGD ではサポートされていません。

ルール

ルールはオリジンノードでのみ実行されるため、レプリカに対して有効になっている場合でも、適用中に実行されません。

ベーステーブルのみ

レプリケーションは、ベーステーブルからベーステーブルへのみ可能です。つまり、サブスクリプション側のソースとターゲットのテーブルは、ビュー、マテリアライズドビュー、外部テーブルではなく、テーブルである必要があります。ベーステーブル以外のテーブルを複製しようとすると、エラーが発生します。更新可能なビューを介して行われた DML 変更は、オリジン上のベーステーブルに解決され、ターゲット上の同じベーステーブル名に適用されます。

パーティション化されたテーブル

PGD は、パーティション化されたテーブルを透過的にサポートします。つまり、パーティション化されたテーブルをレプリケーションセットに追加でき、パーティションに関係する変更はダウンストリームにレプリケートされます。

トリガー

デフォルトでは、トリガーは元のノードでのみ実行されます。たとえば、INSERT トリガーは元のノードで実行され、ターゲットノードに変更を適用するときに無視されます。`ALTER TABLE ... ENABLE ALWAYS TRIGGER` を使用して、実行時にオリジンノードで実行され、レプリケートされたときにターゲットで実行されるトリガー「適用時」を指定できます。または、`REPLICA` オプションを使用して適用時にのみ実行します `ALTER TABLE ... ENABLE REPLICA TRIGGER`。

一部のトリガーは、テーブルに存在し、現在有効になっている場合でも、適用時に実行されません。実行されないトリガータイプは次のとおりです。

- ステートメントレベルのトリガー `FOR EACH STATEMENT`

- 列ごとの UPDATE トリガー `UPDATE OF column_name [, ...]`

PGD レプリケーション適用は、システムレベルのデフォルトの search_path を使用します。レプリカトリガー、ストリームトリガー、およびインデックス式ファンクションは、適用時に実行時に失敗する他の search_path 設定を引き受けることができます。これの発生を防ぐには、次のいずれかのテクニックを使用します。

- デフォルトの search_path のみを使用して、オブジェクト参照を明確に解決します。
- オブジェクトへの完全修飾参照は常に使用します `schema.objectname` など。
- 影響を受けるファンクションに対して `ALTER FUNCTION ... SET search_path = ...` を使用して、ファンクションの検索パスを設定します。

PGD は、テキストまたはその他の照合可能なデータ型に関連する問題がないことを前提としています。つまり、使用中のすべての照合順序はすべてのノードで使用でき、デフォルトの照合順序はすべてのノードで同じです。変更のレプリケーションは、等価検索を使用してレプリカ ID 値を見つけるため、一意のインデックスが一致しない照合修飾子で明示的に定義されている場合を除き、これは効果がありません。照合可能な式が使用される場合、行フィルタは照合順序の違いの影響を受ける可能性があります。

トースト

PostgreSQL の非常に長い「トーストされた」データの PGD 処理は、ユーザーに対して透過的です。TOAST の「chunkid」値は、異なるノードの同じ行の間で異なる可能性がありますが、それは問題を発生させません。

その他の制限

レプリカ ID 列が外部としてマークされている場合、PGD は正しく動作できません。

PostgreSQL では、揮発性ファンクションを含む CHECK() 制約が許可されます。PGD は適用時に CHECK() 制約を再実行するため、以前と同じ結果を返さない後続の再実行はデータの相違を発生させます。

PGD は、外部キーの使用を制限しません。カスケード FK は許可されます。

8.1.2 DML and DDL replication and nonreplication

SQL ステートメントの 2 つのメジャークラスは、 DML と DDL です。

- DML はデータ変更言語であり、テーブルに格納されているデータを変更する SQL ステートメントに関係しています。これには、UPDATE、DELETE、および INSERT が含まれます。
- DDL はデータ定義言語であり、データの保存方法を変更する SQL ステートメントに関係します。これには、CREATE、ALTER、および DROP が含まれます。

PGD は、各クラスを個別に処理します。

DML レプリケーション

PGD は DML ステートメントをレプリケートしません。DML ステートメントによって発生した変更をレプリケートします。たとえば、2 つの行を変更した UPDATE は 2 つの変更をレプリケートしますが、行を削除しなかった DELETE は何もレプリケートしません。これは、volatile ステートメントの実行結果がレプリケートされ、ステートメントベースのレプリケーションで発生する可能性のあるノード間の相違がないことを意味します。

DDL レプリケーション

DDL レプリケーションは DML とは異なります。DDL の場合、PGD はステートメントをレプリケートし、すべてのノードで実行します。したがって、`DROP TABLE IF EXISTS` はローカルノードで何もレプリケートしない場合がありますが、DDL レプリケーションが有効になっている場合、ステートメントは他のノードに送信されて実行されます。詳細については、

DML and DDL replication and nonreplication を参照してください。

PGD は、同じトランザクション内でも、混合された DML および DDL ステートメントが正しく動作するように機能します。

レプリケートされていないステートメント

これらの 2 つのクラスの外部には、PGD がデザインでレプリケートしない SQL コマンドがあります。次のユーザーコマンドは PGD によってレプリケートされないため、その効果はローカル/オリジンノードでのみ発生します。

- カーソル操作 DECLARE、CLOSE、FETCH
- 実行コマンド DO、CALL、PREPARE、EXECUTE、EXPLAIN
- セッション管理 DEALLOCATE、DISCARD、LOAD
- パラメーターコマンド SET、SHOW

・コンストレイン操作 SET CONSTRAINTS

- ロックコマンド LOCK
- テーブルメンテナンスコマンド VACUUM、ANALYZE、CLUSTER、REINDEX
- 非同期操作 NOTIFY、LISTEN、UNLISTEN

`NOTIFY` SQL コマンドと `pg_notify()` ファンクションはレプリケートされないため、フェイルオーバーの場合の通知は信頼できません。これは、サーバーがクラッシュしたときにトランザクションがコミットされた場合、フェールオーバー時に通知が簡単に失われる可能性があることを意味します。`LISTEN` を実行しているアプリケーションは、フェイルオーバーが発生した場合の通知を見逃す場合があります。

これは標準の PostgreSQL レプリケーションに当てはまりますが、PGD はこれをまだ改善していません。

CAMO および Eager Replication オプションでは、`NOTIFY` SQL コマンドまたは `pg_notify()` ファンクションは使用できません。

8.1.3 Nodes with differences

差分を含むノード間のレプリケーション

デフォルトでは、 DDL はすべてのノードに送信されます。
DML and DDL replication and nonreplication で説明しているように、この動作を制御でき、それを使用して、ノード間のデータベーススキーマ間の差異を作成できます。

PGD は、ノード間のわずかな違いがあってもレプリケーションを続行できるように設計されています。これらの機能は、ダウンタイムなしでアプリケーションスキーマを移行できるように、またはロジカルスタンバイノードでレポートまたはテストをできるように設計されています。

現在、レプリケーションには、すべてのノードで同じテーブル名が必要です。将来の機能では、異なるテーブル名間のマッピングが可能になる可能性があります。

ターゲット上のパーティションを変更する更新のサポートを含む、パーティションテーブルにレプリケートする通常のテーブルのソースなど、異なるパーティション定義を持つテーブル間でレプリケートが可能です。パーティショニング定義がソースとターゲットで同じである場合、適用時に動的パーティションルーティングを実行する必要がないため、高速になります。詳細については、
Replication sets を参照してください。

デフォルトでは、すべての列がレプリケートされます。

PGD は、列名に基づいてデータ列をレプリケートします。列の名前が同じで異なるデータ型がある場合、PGD はソースタイプからターゲットタイプにキャストを試行します（それを許可するキャストが定義されている場合）。

PGD は、列数が異なるテーブル間のレプリケーションをサポートしています。

ターゲットにソースからの欠落列がある場合、PGD は `target_column_missing` 競合を発生させます。デフォルトの競合リゾルバーは `ignore_if_null` です。これは、NULL 以外の値が到着した場合にエラーをスローします。または、`ignore` の競合リゾルバーを使用してノードを構成することもできます。この設定はエラーをスローしませんが、追加の列をサイレントに無視します。

ターゲットにソースレコードで見られない追加の列がある場合、PGD は `source_column_missing` 競合を発生させます。デフォルトの競合リゾルバーは `use_default_value` です。追加列にデフォルト NULL ヌル可能な場合またはデフォルト式がある場合、レプリケーションは続行されます。そうでない場合、エラーをスローし、レプリケーションを停止します。

変換トリガーはテーブルで使用して、デフォルト値を提供したり、適用前にさまざまな方法で受信データを変更したりすることもできます。

ソースとターゲットに異なる制約がある場合、レプリケーションが試行されますが、ソースからの行をターゲットに適用できない場合、失敗する場合があります。ここで行フィルタが役立ちます。

1 つのスキーマからより緩和されたスキーマにデータを複製しても、障害は発生しません。スキーマからより制限的なスキーマへのデータの複製は、潜在的な障害のソースになる可能性があります。これを解決する正しい方法は、より緩和な側にコンストレインを配置して、悪いデータを入力できないようにすることです。このようにして、レプリケーションによって不正なデータが到着することはなく、より制限的なスキーマへの変換に失敗することはありません。たとえば、あるスキーマに TEXT タイプの列があり、別のスキーマが XML と同じ列を定義している場合、TEXT 列に CHECK 制約を追加して、テキストが XML であることを強制します。

ノードごとに異なるインデックスを使用してテーブルを定義できます。デフォルトでは、インデックス定義はレプリケートされます。ノードのサブセットのみまたはローカルにインデックスを作成する方法を指定するには、
DML and DDL replication and nonreplication を参照してください。

`fillfactor` や `toast_tuple_target` などのストレージパラメーターは、テーブルのノード間で問題なく異なる場合があります。その動作の例外は、テーブルのストレージパラメーター `user_catalog_table` の値がすべてのノードで同一である必要があることです。

レプリケートされるテーブルは、各ノードで同じユーザー/ロールが所有している必要があります。詳細は、
Security and roles を参照してください。

ロールは、各ノードの接続に対して異なるパスワードを持つことができますが、デフォルトでは、ロールの変更は各ノードにレプリケートされます。ノードのサブセットのみまたはローカルでロールパスワードを変更する方法を指定するには、DDL replication を参照してください。

違いがあるノード間の比較

LiveCompare は、PGD ノードおよび非 PGD ノードとデータベースのデータを比較するためのツールです。比較して最終結果に到達するには、少なくとも 2 つの接続が必要です。

LiveCompare 1.3 以降、`all_bdr_nodes` セットを使用して構成できます。この設定により、クラスター内の個別のノードごとに関連するすべての DSN を明確にする必要がありません。EDB Postgres 分散クラスターには、接続情報を備えた N 個のノードがありますが、LiveCompare 1.3 以降がジョブを完了するために必要な初期接続と出力接続のみです。`logical_replication_mode` 設定は、すべてのノードがどのように通信しているかを示します。

すべての構成は、たとえば、 `bdrLC.ini` という名前の`.ini` ファイルで実行されます。 `/etc/2ndq-livecompare/` でこの構成ファイルのテンプレートを見つけます。

LiveCompare の実行中、N+1 の進行状況バーが表示されます。N はプロセス数です。すべてのテーブルがソースされると、1 秒あたりのトランザクション tps が測定されたとして時間が表示されます。このメカニズムは時間をカウントし続け、推定を提供して、最後に合計実行時間を提供します。

このツールは、テーブル、スキーマ、replication_sets など、多くのカスタマイズとフィルターを提供します。LiveCompare は、コンテキスト情報を失うことなく stop-start を使用できるため、都合の良いときに実行できます。比較の後、概要と DML スクリプトが生成されるので、確認できます。DML を適用して、見つかった差異を修正します。

異なるリリースレベル間のレプリケーション

ノード間のその他の違いは、ノードに PostgreSQL の異なるメジャーバージョンが存在するかどうかです。PGD は、異なるメジャーリリースバージョン間で複製するように設計されています。この機能は、ダウンタイムなしでメジャーバージョンのアップグレードを可能にするように設計されています。

PGD は、PGD ソフトウェアの異なるバージョンを持つノード間で複製するように設計されています。この機能は、ダウンタイムなしでバージョンのアップグレードとメンテナンスを可能にするように設計されています。

ただし、クラスター内のメジャーバージョンのノードを参加することは可能ですが、クラスターが新しいプロトコルバージョンを使用している場合、マイナーバージョンのノードを追加することはできません。そうするとエラーが返されます。

これらの機能は両方とも、特定の制限の影響を受ける可能性があります。既知の非互換性については、Release notes を参照してください。

8.1.4 General rules for applications

背景

PGD は、レプリカ ID 値を使用して、変更する行を識別します。アプリケーションが同じ一意の識別子を挿入、削除、および後で再利用すると、問題が発生する可能性があります。これは ABA problem と呼ばれます。PGD は、行が現在の行、最後の行、またはかなり古い行であるかどうかを知ることができません。

同様に、PGD はテーブル名を使用して、変更が再生されるテーブルを識別するため、同じオブジェクト名を作成、ドロップ、および後で再利用するアプリケーションにも同様の ABA 問題が存在します。

アプリケーションのルール

これらの問題により、アプリケーションが従うべき単純なルールがいくつか発生します。

- 行の一意の識別子を使用します INSERT
- 一意の識別子 UPDATE の変更を避けます。
- 削除された一意の識別子の再利用は避けてください。
- ドロップされたオブジェクト名の再利用は避けてください。

一般に、これらのルールに違反すると、データの異常と発散が発生する可能性があります。アプリケーションは、特定の条件が満たされる限り、これらのルールを破ることができます。ただし、注意してください。異常が発生する可能性は低いですが、不可能ではありません。たとえば、ダウンしたノードを含むすべてのノードで DELETE が再生された限り、行値を再利用できます。これは通常 1 秒以内に発生しますが、1 つのノードで重大な問題が発生し、正しく再起動できなかった場合には数日かかる場合があります。

8.1.5 Timing considerations and synchronous replication

デフォルトでは非同期であるため、ピアノードは遅延する場合があります。この動作により、複数の PGD ノードに接続したクライアント、またはそれらをスイッチングしたクライアントが古いデータを読み取ることができます。

queue wait function は、クライアントまたはプロキシに提供され、このような古い読み取りを防止します。

Postgres の同期レプリケーション機能は、PGD でも利用できます。さらに、PGD は、より同期したレプリケーションのための複数のバリアントを提供します。使用可能なすべてのバリアントとそのさまざまなモードの概要と比較については、

Durability and performance options を参照してください。

8.1.6 Use of table access methods (TAMs) in PGD

PGD 5.0 は、 EDB Postgres 15.0 でリリースされた 2 つのテーブルアクセス方法 TAM をサポートしています。これらの 2 つの TAM は認定され、PGD 5.0 で許可されています。

自動クラスター Ref データ

EDB によって認定されるまで、他の TAM は制限されます。テーブルで TAM を使用する予定がある場合は、PGD クラスター内の各参加ノードでその TAM を構成する必要があります。各ノードで自動クラスターまたは ref データ TAM を構成するには

1. `postgresql.conf` を更新して、`shared_preload_libraries` パラメーターに TAM `autocluster` または `refdata` を指定します。

1. サーバーを再起動し、`CREATE EXTENSION autocluster;` または `CREATE EXTENSION refdata;` を実行します。

拡張機能を作成した後、TAM を使用して、`CREATE TABLE test USING autocluster;` または `CREATE TABLE test USING refdata;` を使用してテーブルを作成できます。これらのコマンドは、すべての PGD ノードに複製します。これらのテーブルアクセス方法の詳細については、

> *CREATE TABLE* を参照してください。

8.2 Node management

PGD クラスター内のすべてのデータノードは、1 つ以上のグループのメンバーです。デフォルトでは、すべてのデータノードは、PGD クラスター内のすべてのデータノードにまたがるトップレベルグループのメンバーです。ノードは、PGD クラスターの論理または地理的組織を反映するように構成できるサブグループに属することもできます。

ノードとサブグループで使用可能なさまざまなオプションを使用して、ノードとグループを管理できます。

- *Node types* は、PGD クラスターに存在できるノードの種類をカバーしています。
- *Groups and subgroups* は、PGD でのグループとサブグループがどのように動作するかについて詳しく説明します
- *Creating and joining groups* は、新しい PGD グループを作成する方法と、PGD ノードをそれらに参加する方法を検討します。
- *Witness* **ノード** は、グループでコンセンサスを確立することに専用の PGD ノードの特別なクラスを調べます。
- *Logical standby nodes* は、スタンバイのノードを効率的に同期させ、障害が発生した場合にプライマリとしてステップインする準備をする方法を示します。
- **フィジカルスタンバイノード** は、スタンバイノードを提供する代替技術をカバーしています。
- *Subscriber-only nodes and groups* は、サブスクライバー専用ノードがどのように動作し、それらがどのように構成されているかを調べます。
- *Viewing topology* は、PGD クラスターノードとグループの構造を表示できるコマンドと SQL クエリーの詳細を示します。

- *Removing nodes and groups* は、グループからノード、またはクラスターからグループを安全に削除するために実行するプロセスを示します。
- *Heterogeneous clusters* は、PGD クラスターが以前のエディションの PGD ノードとどのように相互運用できるかを検討します。
- *Connection DSNs and SSL (TLS)* は、PGD クラスター内のノードに直接接続するために必要な DSN または接続文字列を導入します。また、SSL / TLS 証明書を使用して、サーバー間およびクライアント間の認証と暗号化を提供する方法についても説明します。
- *Decoding worker* は、ノードのグループがレプリケーションによる CPU オーバーヘッドを削減できる PGD の機能をカバーしています。
- **レプリケーションスロットのクリーンアップ** は、PGD が動作しているときに Postgres レプリケーションスロットがどのように消費されるかを調べます。
- *Node restart and down node recovery* は、障害またはスケジュールされたダウンタイムの後にノードをサービスに戻すために必要な手順と、それが戻るときにクラスターに与える影響について詳しく説明します。

8.2.1 Node types

データノード

PGD のデータノードは、Postgres インスタンスを実行するノードです。他のすべてのデータノードにデータを複製します。また、ロックとリーダーシップを中心にクラスター全体の Raft の意思決定にも参加します。これは 1 つ以上のグループのメンバーであり、デフォルトでは、クラスター内のすべてのデータノードにまたがる「トップレベル」グループのメンバーになります。

Witness ノード

監視ノードは、ロックとリーダーシップを中心にクラスター全体の Raft の意思決定に参加するという点でデータノードのように動作します。ただし、データを複製または保存しません。監視ノードの目的は、クラスターがコンセンサスを求めるときにマジョリティを達成できるように利用できることです。

Witness ノード セクションに詳細があります。

ロジカルスタンバイノード

論理スタンバイノードは、別のノードから論理データの変更を受け取り、ローカルに複製するノードです。これらは、複製しているノードが使用できなくなった場合に、そのノードを置き換えるために使用できます。いくつかの注意事項。詳細については、

Logical standby nodes を参照してください。

フィジカルスタンバイノード

物理スタンバイノードは、別のノードから物理データの変更を受け取り、ローカルに書き込むノードです。これらは、変更を受け取っているノードを置き換えるために使用できます。詳細については、
フィジカルスタンバイノード を参照してください。

サブスクライバー専用ノード

サブスクライバー専用ノードは、名前が示すように、クラスター内の変更をサブスクライブするのみが、他のノードに変更をレプリケートしないデータノードです。サブスクライバ専用ノードは、アプリケーションの読み取り専用ノードとして使用できます。加入者専用ノードは、データノードを取得し、加入者専用グループに追加することにより作成されます。詳細については、
Subscriber-only nodes and groups を参照してください。

8.2.2 Groups and subgroups

グループ

PGD クラスターのノードはグループに集められます。「トップレベル」グループは常に存在し、すべてのデータノードが自動的に属するグループです。「トップレベル」グループは、サブグループの直接の親になることもできます。

サブグループ

グループには、0 個以上のサブグループを含めることもできます。サブグループは、データセンターまたは場所を表すために使用でき、コミットスコープが特定のリージョンのノードを全体として参照できます。PGD プロキシは、サブグループを利用して、書き込みリーダーになることができるノードを区切ることもできます。

`node_group_type` 値は、サブグループの作成時のタイプを指定します。一部のサブグループタイプは、グループ内のノードの動作を変更します。たとえば、**サブスクライバー専用ノード** サブグループは、グループ内のすべてのノードをサブスクライバ専用ノードにします。

8.2.3 Creating and joining PGD groups

PGD グループの作成と参加

PGD の場合、すべてのノードは他のすべてのノードに接続する必要があります。構成を簡単にするために、新しいノードが参加すると、既存のすべてのノードがそれに接続するように構成します。このため、最初に作成された PGD ノードを含むすべてのノードは、他のノードが接続するために使用できる *PostgreSQL connection string* を知る必要があります。この接続文字列は、データソース名 DSN と呼ばれることがあります。

両方の形式の接続文字列がサポートされています。したがって、host=myhost port=5432 dbname=mydb のようなキー-値形式、または postgresql://myhost:5432/mydb のような URI 形式を使用できます。

SQL ファンクション

bdr.create_node_group() は、ローカルノードから PGD グループを作成します。これにより、そのノードで PGD がアクティブになり、他のノードがその時点で 1 つのノードのみで構成される PGD グループに参加できるようになります。作成時に、このノードへの接続に使用する他のノードの接続文字列を指定する必要があります。

ノードグループが作成されると、それ以降のすべてのノードは、

bdr.join_node_group() ファンクションを使用して PGD グループに参加できます。

または、コマンドラインユーティリティ *bdr_init_physical* を使用して、pg_basebackup または既存のノードのフィジカルスタンバイを使用して、新しいノードを作成します。pg_basebackup を使用する場合、bdr_init_physical ユーティリティはオプションでターゲットデータベースのみのベースバックアップを指定できます。以前の動作は、データベースクラスター全体をバックアップすることでした。このユーティリティを使用すると、アクティビティがより速く完了し、不要なデータベースを除外するため、使用する領域が少なくなります。ターゲットデータベースのみを指定した場合、除外されたデータベースは新しいノードでクリーンアップおよび削除されます。

新しい PGD ノードが既存の PGD グループに参加するか、ノードが上流ピアをサブスクライブする場合、レプリケーションを開始する前に、システムは既存のデータをピアノードからローカルノードにコピーする必要があります。このコピーは、ローカルデータとリモートデータが同一に始まるように、注意深く調整する必要があります。pg_dump を自分自身で使用するだけでは十分ではありません。BDR 拡張機能は、この初期コピーを作成するためのビルトイン機能を提供します。

参加プロセス中に、BDR 拡張機能は提供されたソースノードをベースとして使用して既存のデータを同期し、PGD グループのメッシュトポロジで自分自身を確立するために必要なすべてのメタデータ情報を作成します。この初期コピー中にソースと新しいノード間の接続が切断された場合、参加プロセスを最初からリスタートします。

クラスターに参加するノードには、PGD グループのデータベースに既に存在するスキーマまたはデータが含まれていない必要があります。新しく参加するデータベースは、BDR 拡張機能を除き空であることをお勧めします。ただし、必要なデータベースユーザーとロールがすべて作成されていることが重要です。

オプションで、*bdr.join_node_group* ファンクションの synchronize_structure パラメーターを使用して、スキーマの同期をスキップできます。この場合、スキーマは新しく参加するノードに既に存在する必要があります。

参加するソースノードとして、最適な接続を持つ最も近いソースノードを選択することをお勧めします。そうすることで、結合が完了するまでに必要な時間が短縮されます。

Raft コンセンサスアルゴリズムを使用して参加手順を調整します。これには、既存のノードのほとんどがオンラインで到達可能である必要があります。

論理結合プロシージャ *bdr.join_node_group* ファンクションを使用する は、 COPY 操作を実行してデータ同期を実行し、マルチプルのライターパラレル適用が有効になっている場合は使用します。

ノード参加は、参加にかかる時間の大部分で他のノード参加と同時に実行できます。ただし、一度に 1 つのレギュラーノードのみが PROMOTE または PROMOTING の状態になることができます。他のすべてのノードが起動して実行されている場合、これらの状態は通常かなり短いです。それ以外の場合、結合はこの段階でシリアル化されます。サブスクライバ専用ノードはこのルールの例外であり、それらは同時に

PROMOTE および PROMOTING 状態になることもできるため、それらの参加プロセスは完全にコンカレントです。

参加プロセスはソースとして 1 つのノードのみを使用するため、ノードの大部分が利用可能な場合、ノードがダウンしているときに実行できます。このアプローチでは、論理結合を実行するときに複雑さが発生する可能性があります。論理結合中に、ソースノードからコピーされた行のコミットタイムスタンプは、ソースノードの最新のコミットタイムスタンプに設定されます。これより前のコミットタイムスタンプを持つノードでコミットされた変更は、ノードがダウンしているか、大幅な遅延があるため、他のノードからの変更と競合する可能性があります。この場合、新しく参加したノードは他のノードとは異なる方法で解決され、発散が発生する可能性があります。その結果、ノード間に重大なレプリケーションラグが存在する場合は、ノード参加を実行しないことをお勧めします。これが必要に応じて、すべてのノードが利用可能になって追いついた後、新しく参加したノードで LiveCompare を実行してデータの相違を修正します。

pg_dump は、ソースノードに同時の DDL アクティビティがある場合、キャッシュルックアップの失敗が原因で失敗する場合があります。

> *bdr.join_node_group* は内部で pg_dump を使用するため、ソースノードに同時の DDL アクティビティがある場合、失敗する可能性があります。その場合、結合を再試行すると機能します。

8.2.4 Witness nodes

監視ノードは、データノードとして機能するが、データを保存または複製しない軽量ノードです。これは、Raft コンセンサスを使用する PGD クラスターが奇数の投票ノードを持つことができるため、決定を行うときにマジョリティを達成できるようにするために使用されます。

PGD グループまたはリージョン内の Witness ノード

監視ノードの一般的な使用の 1 つは、PGD グループに 2 つのデータノードがあるが、推奨される 3 つのデータノードでリソースを利用できない場合です。この場合、監視ノードを PGD グループに追加して、ローカルの Raft 意思決定に 3 番目の投票ノードを提供できます。これらの決定は、主に使用するプロキシの書き込みリーダーを誰が選択するかに関するものです。2 つのノードのみでは、どのデータノードが書き込みリーダーになるかについてコンセンサスが存在しない可能性があります。2 つのデータノードと監視 1 つの場合、通常は 2 つの候補者データノードと 3 つの有権者データノードと監視者が存在し、データノードがダウンしている場合でも、書き込みを選択できる 2 人の有権者が存在します。リーダー。

リージョン外の Witness ノード

より高いレベルでは、異なるリージョンにマッピングされた複数の PGD グループが存在する場合、監視ノードを使用できます。たとえば、2 つのリージョンのリージョンごとに 3 つのデータノードがある場合、通常に実行すると、6 つのデータノードすべてが Raft 決定に参加し、DDL および DML グローバルロックを取得できます。データノードがダウンしている場合でも、コンセンサスを取得するための十分なデータノードが存在します。しかし、ネットワークの分割が発生し、他のリージョンとの接続が失われると、使用可能な 6 つのノードのうち 3 つしかありません。これはコンセンサスには十分ではありません。このシナリオを回避するには、3 番目のリージョンの監視ノードを PGD クラスターの一部として展開できます。

この監視ノードにより、リージョンが利用できないときに PGD クラスターのほとんどの操作要件でコンセンサスを達成できます。

8.2.5 Logical standby nodes

PGD では、オフロードノード、読み取り専用ノード、受信専用ノード、または論理リードレプリカとしても知られる**ロジカルスタンバイノード**を作成できます。マスターノードには、0、1 つ、またはそれ以上のロジカルスタンバイノードを持つことができます。

注釈: 論理スタンバイノードは、データセンター間のネットワークトラフィックが懸念される環境で使用できます。それ以外の場合は、ロケーションごとにより多くのデータノードを持つことが常に優先されます。

フィジカルスタンバイノードでは、ノードが完全に起動しないため、継続的リカバリモードのままとなります。PGD では、同様のことができます。

> *bdr.join_node_group* には、ノードをロジカルスタンバイノードとして途中参加したままにする `pause_in_standby`

オプションがあります。論理スタンバイノードは変更を受信しますが、ローカルで行われた変更を他のノードに送信しません。

その後、必要に応じて、
: *bdr.promote_node* を使用して、ロジカルスタンバイを完全な通常の送信/受信ノードに移動します。

ロジカルスタンバイは、
: *bdr.join_node_group* の DSN で定義された 1 つのソースノードからデータが送信されます。他のすべてのノードからの変更はこの 1 つのソースノードから受信され、マルチプルのサイト間の帯域幅が最小化されます。

高可用性には複数のオプションがあります。

- ソースノードが停止した場合、1 つのフィジカルスタンバイをマスターに昇格させることができます。この場合、新しいマスターは、一部またはすべてのロジカルスタンバイノードに給電を継続できます。
- ソースノードが停止した場合、1 つのロジカルスタンバイをフルノードに昇格させ、シングルマスター操作と同様のフェールオーバー操作でソースを置き換えることができます。複数のロジカルスタンバイノードが存在する場合、他のノードは新しいマスターをフォローできないため、この手法の有効性は 1 つのロジカルスタンバイに制限されます。

既存の PGD ノードから新しいスタンバイが作成される場合、グループスロットが最後に進められてから少なくとも 16MB の LSN が経過するまで、操作に必要なレプリケーションスロットは新しいスタンバイに同期されません。極端な場合、これには、スロットがストリーミングレプリカで同期または作成される前に、完全な 16 MB が必要になる場合があります。この間隔でフェールオーバーまたはスイッチオーバーが発生した場合、グループスロットおよびその他の依存スロットがまだ存在していないため、ストリーミングスタンバイを PGD ノードに代わって昇格させることはできません。

スタンバイのスロット同期プロセスは、上流のファンクションを呼び出すことによりこれを解決します。この機能は、WAL スイッチを実行し、すべての PGD ピアノードに進行状況の更新を再生するように要求することにより、EDB Postgres 分散クラスター全体のグループスロットを移動します。この動作により、

グループスロットが短期間で前進します。これにより、スタンバイが初期スロットの同期に必要な時間が削減され、必要に応じてより迅速なフェイルオーバーが可能になります。

PostgreSQL では、スロットを昇格する前に、スタンバイでスロットの同期が完了することを確認することが重要です。ターゲットデータベースのスタンバイで次のクエリを実行して、スロットがアップストリームと同期していることを監視および確認できます。このクエリーが true を返すと、プロモーションを続行できます。

```
SELECT true FROM pg_catalog.pg_replication_slots WHERE
    slot_type = logical AND confirmed_flush_lsn IS NOT NULL;
```

WAL スイッチを手動で実行し、すべての PGD ピアノードに進行状況の更新を再生するように要求することにより、PGD クラスター全体のスロット同期プロセスをナッジすることもできます。このアクティビティにより、グループスロットが短時間で前進し、スタンバイでのスロット同期アップアクティビティも高速化されます。このターゲットデータベース内の任意の PGD ピアノードで次のクエリーを実行できます。

```
SELECT bdr.run_on_all_nodes(SELECT pg_catalog.pg_switch_wal());
SELECT bdr.run_on_all_nodes(SELECT bdr.request_replay_progress_update());
```

スタンバイでモニタリングクエリを使用して、これらのクエリがそのスタンバイでのスロットの同期の高速化に役立つことを確認します。

論理スタンバイノードは、必要に応じてフィジカルスタンバイノードを使用して保護できます。マスター->論理スタンバイ->フィジカルスタンバイ。LogicalStandby から LogicalStandby にカスケードすることはできません。

ロジカルスタンバイでは書き込みトランザクションが許可されるため、フィジカルスタンバイの制限は適用されません。これにより、ロジカルスタンバイに追加のインデックス、データのより長い保持期間、中間作業テーブル、LISTEN/NOTIFY、一時テーブル、マテリアライズドビュー、およびその他の違いを持つことができるため、大きなメリットがあります。

プロモーション前にコミットするロジカルスタンバイにローカルに加えられた変更は、他のノードに送信されません。プロモーション後にコミットするすべてのトランザクションは以降に送信されます。ロジカルスタンバイへの書き込みを実行する場合、昇格する前にデータベースを静止するように注意してください。

ロジカルスタンバイノードに DDL 変更を行う場合がありますが、それらはレプリケートされず、グローバル DDL ロックを取得しようとしません。DDL と同様に動作する PGD ファンクションもレプリケートされません。

> *DML and DDL replication and nonreplication* を参照してください。ロジカルスタンバイに互換性のない DDL 変更を行った場合、データベースは

ダイバージェントノードです。現在、ダイバージェントノードのプロモーションはレプリケーションに失敗します。その結果、ロジカルスタンバイノードをスタンバイとして使用する場合は、ロジカルスタンバイノードに発散的な変更がないようにするか、発散ノードが昇格しないように計画します。

8.2.6 Physical standby nodes

PGD を使用すると、従来のフィジカルスタンバイフェールオーバーノードを作成できます。これらは通常、短いプロモーション手順の後に、クラスター内の PGD ノードを直接置き換えることを目的としています。標準の Postgres クラスターと同様に、ノードには任意の数のこれらの物理レプリカを持つことができます。

ただし、PGD でのレプリケーションスロットおよびその他の機能要件を使用するため、これが適切に動作するには最小限の前提条件がいくつかあります。

- PGD プライマリとスタンバイ間の接続は、物理レプリケーションスロットを介したストリーミングレプリケーションを使用します。
- スタンバイには以下があります。 - `recovery.conf` PostgreSQL <12 の場合、PostgreSQL 12+の場合、これらの設定は `postgres.conf` にあります。 - `primary_conninfo` 、プライマリを指す - `primary_slot_name` 、このスタンバイのみで使用されるプライマリの物理レプリケーションスロットの名前付け- `postgresql.conf` : - `shared_preload_libraries = 'bdr'` 、リストには他のプラグインも含めることができますが、pglogical は含めないでください- `hot_standby = on` - `hot_standby_feedback = on`
- プライマリには以下があります。 - `postgresql.conf` - *bdr.standby_slot_names* は、スタンバイの `primary_slot_name` に使用される物理レプリケーションスロットを指定します。

これは、PGD ノードの作業用フィジカルスタンバイを生成するには十分ですが、いくつかの追加の懸念事項に対処する必要があります。

スタンバイは、確立されると、PGD グループスロットを含むプライマリの他の PGD 関連レプリケーションスロットの初期コピーをトリガーするために十分な時間と WAL トラフィックを必要とします。少なくとも、スタンバイのスロットはライブであり、`pg_replication_slots` によって報告されたゼロ以外の `confirmed_flush_lsn` を報告した場合にのみフェールオーバー後に生き残ることができます。

その結果、フェールオーバーが正常に機能すると仮定する前に、書き込みアクティビティの量が少ない、新しく初期化された PGD クラスターのフィジカルスタンバイノードをチェックしてください。この予防措置を講じないと、スタンバイが PGD ノードとして機能するために必要なレプリケーションスロットの不完全なサブセットを持つことになり、フェールオーバーが中止される可能性があります。

フィジカルスタンバイノードが最新の状態であり、昇格できることを保証する保護メカニズム
bdr.standby_slot_names による構成に従って、

PGD グループの全体的なレプリケーションレイテンシーに影響を与えます。これは、グループレプリケーションがフィジカルスタンバイノードが最新の場合にのみ発生するためです。

これらの理由から、一般的にはフィジカルスタンバイノードの代わりにロジカルスタンバイノードまたはサブスクライブ専用グループを使用することをお勧めします。どちらも比較して、より良い操作特性を持っています。

すべてのノードでグループスロットが可能な限り前進していることを手動で確認できます。これは、次の SQL 構文を使用して、フィジカルスタンバイでの PGD 関連のレプリケーションスロットの作成を早めるのに役立ちます。

```
SELECT bdr.move_group_slot_all_nodes();
```

フェールオーバーが発生すると、スタンバイは 2 つのアクションのいずれかを実行してプライマリを置き換える必要があります。

- プライマリと同じ IP アドレスまたはホスト名の制御を想定しています。
- 他のすべての PGD ノードで *bdr.alter_node_interface* ファンクションを実行することにより、アドレスの変更を EDB Postgres 分散クラスターに通知します。

これが完了すると、他の PGD ノードは、新しく昇格したスタンバイ → プライマリノードとの通信を再確立します。レプリケーションスロットは定期的にのみ同期されるため、この新しいプライマリは、既存の PGD ノードが予想するよりも低い LSN を反映する可能性があります。この場合、PGD は各遅延スロットを各 PGD ノードが使用した最後の場所に高速転送します。

bdr.alter_node_interface) パラメーターにも注意してください。プライマリ ->

フィジカルスタンバイの関係がある EDB Postgres 分散クラスター、またはサブスクライバ専用グループを使用する場合、これを設定することが重要です。

PGD は、アウトバウンドレプリケーションで最も大きな遅延を示すクラスターノードの状態を常に反映するグループスロットを維持します。物理レプリカを追加すると、グループスロットの状態に影響を与える不参加ノードメンバーが存在することを PGD に通知する必要があります。

スタンバイは他の PGD ノードと直接通信しないため、 `standby_slot_names` パラメーターは、グループスロットの必要に応じて名前付けスロットを考慮するように PGD に通知します。設定すると、グループスロットが通常に進んでいる場合でも、スタンバイが遅延を示している場合、グループスロットは保持されます。

他の物理レプリカと同様に、このタイプのスタンバイも同期レプリカとして構成できます。これには次のものが必要です。

- スタンバイ - `primary_conninfo` に一意の `application_name` を指定する
- プライマリで - `synchronous_commit` を有効にする - `synchronous_standby_names` にスタンバイ `application_name` を含める

`synchronous_standby_names` でフィジカルスタンバイと他の PGD ノードを混合することが可能です。CAMO および Eager All-Node Replication は、異なる同期メカニズムを使用し、同期レプリケーションでは動作しません。CAMO または Eager All-Node Replication が使用される場合、`synchronous_standby_names` に PGD ノードが含まれていないことを確認します。代わりに、非 PGD ノードたとえば、フィジカルスタンバイのみを使用します。

8.2.7 Subscriber-only nodes and groups

サブスクライバー専用ノード

名前が示すように、サブスクライバー専用ノードは、クラスター内の他のノードからのレプリケーション変更のみをサブスクライブします。ただし、他のノードは `subscriber-only` ノードからレプリケーションの変更を受信しません。これは、ロジカルスタンバイノードに似ています。ただし、ロジカルスタンバイとは対照的に、`subscriber-only` ノードはクラスターに完全に参加しています。これらは、クラスター内の他のすべてのノードからレプリケーションの変更を受信できるため、クラスター内の 1 つのノードの使用不可または分離の影響を受けません。

subscriber-only ノードは完全に参加した PGD ノードであるため、レプリケートされたすべての DDL を受信し、それらに基づいて動作します。また、Raft を使用して、クラスター内のすべてのノードにそのステータスを一貫して報告します。subscriber-only ノードには Raft の投票権がないため、Raft リーダーになることも、リーダー選挙に参加することもできません。また、レプリケートされた DDL を受信しますが、DDL または DML ロックの取得に参加しません。つまり、現在ダウンしている subscriber-only ノードは、DML ロックの取得を停止しません。

subscriber-only ノードは、PGD ツリートポロジのビルディングブロックを形成します。このトポロジでは、少数の完全にアクティブなノードが全方向に変更を複製しています。多数の subscriber-only ノードは変更のみを受信しますが、クラスター内の他のノードに変更を送信することはありません。このトポロジは、ノードの数が多いことによる接続の爆発を回避しながら、データの使用に使用できる非常に多くの leaf ノードを提供します。

購読者専用グループ

subscriber-only ノードを利用するには、最初に subscriber-only タイプの PGD グループを作成します。メンバノードがレプリケーションの変更を受信するグループのサブグループにします。サブグループを作成したら、subscriber-only ノードになるすべてのノードがサブグループに参加する必要があります。subscriber-only タイプの複数のサブグループを作成でき、それらは異なる親グループを持つことができます。

ノードが subscriber-only サブグループに参加すると、subscriber-only ノードになり、親グループのレプリケーション変更の受信を開始します。subscriber-only ノードで直接行われた変更は複製されません。

> *bdr.create_node_group* を参照

特定のタイプのサブグループを作成し、特定の親グループに属する方法を知るため。

注釈: *subscriber-only* ノードはクラスター内のノードに変更をレプリケートしないため、ノードがクラスターから分離されるときにレプリケーション変更を同期するソースとして機能できません。ただし、*subscriber-only* ノードが、現在クラスター内の他のノードが持っていない分割ノードからレプリケーション変更を既に受信および適用している場合、ノード間で不一貫性が発生します。

今のところ、 *bdr.standby_slot_names* を設定することによりこれを解決できます

と *bdr.standby_slots_min_confirmed*

そのため、subscriber-only ノードの前に完全にアクティブな PGD ノードが常に存在します。 !!!

8.2.8 Viewing PGD topology

PGD グループのリスト

pgd-cli の使用

---

pgd-cli show-groups

コマンドを使用して、PGD クラスター内のすべてのグループをリストします。

```
pgd show-groups
```

```
Group    Group ID   Type            Parent Group Location Raft  Routing Write Leader
-----    --------   ----            ------------ -------- ----  ------- ------------
bdrgroup 1360502012 global                                true  false
group_a  3618712053 data            bdrgroup     a        true  true    bdr-a1
group_b  402614658  data            bdrgroup     b        true  true    bdr-b1
group_c  2808307099 data            bdrgroup     c        false false
group_so 2123208041 subscriber-only bdrgroup     c        false false
```

SQL を使用する

次の単純なクエリーは、現在のノードがメンバーであるすべての PGD ノードグループをリストします。現在、
bdr.local_node_summary から 1 行のみを返します。

```
SELECT node_group_name
FROM bdr.local_node_summary;
```

より複雑なクエリーを使用して、各ノードグループの構成を表示できます。

```
SELECT g.node_group_name
, ns.pub_repsets
, ns.sub_repsets
, g.node_group_default_repset     AS default_repset
, node_group_check_constraints    AS check_constraints
FROM bdr.local_node_summary ns
JOIN bdr.node_group g USING (node_group_name);
```

PGD グループ内のノードのリスト

pgd-cli の使用

show-nodes コマンドを使用して、PGD クラスター内のすべてのノードをリストします。

```
pgd show-nodes
```

```
Node               Node ID    Group    Type           Current State Target State␣
↪Status Seq ID
----               -------    -----    ----           ------------- ------------ ----
↪-- ------
bdr-a1             3136956818 group_a  data           ACTIVE        ACTIVE       Up
   6
bdr-a2             2133699692 group_a  data           ACTIVE        ACTIVE       Up
   3
logical-standby-a1 1140256918 group_a  standby        STANDBY       STANDBY      Up
   9
witness-a          3889635963 group_a  witness        ACTIVE        ACTIVE       Up
   7
bdr-b1             2380210996 group_b  data           ACTIVE        ACTIVE       Up
   1
bdr-b2             2244996162 group_b  data           ACTIVE        ACTIVE       Up
   2
logical-standby-b1 3541792022 group_b  standby        STANDBY       STANDBY      Up
   10
witness-b          661050297  group_b  witness        ACTIVE        ACTIVE       Up
   5
witness-c          1954444188 group_c  witness        ACTIVE        ACTIVE       Up
   4
subscriber-only-c1 2448841809 group_so subscriber-only ACTIVE       ACTIVE       Up
   8
```

グループ名で grep を使用して、リストを特定のグループにフィルタリングします。

```
pgd show-nodes | grep group_b
```

```
bdr-b1             2380210996 group_b  data           ACTIVE        ACTIVE       Up
   1
bdr-b2             2244996162 group_b  data           ACTIVE        ACTIVE       Up
   2
logical-standby-b1 3541792022 group_b  standby        STANDBY       STANDBY      Up
   10
witness-b          661050297  group_b  witness        ACTIVE        ACTIVE       Up
   5
```

SQL を使用する

bdr.node_summary ビューから、特定のノードグループ

mygroup`などのすべてのノードのリストを抽出できます。例

```
SELECT node_name          AS name
, node_seq_id             AS ord
, peer_state_name         AS current_state
, peer_target_state_name AS target_state
, interface_connstr       AS dsn
FROM bdr.node_summary
WHERE node_group_name = mygroup;
```

current_state または target_state クエリー列で示されるノードの読み取り専用状態は、 STANDBY として示されます。

8.2.9 Removing nodes and groups

PGD グループからのノードの削除

PGD は、長期のノードの停止から復旧するように設計されているため、ノードを完全に削除するかどうかをシステムに明示的に指示する必要があります。ノードを完全にシャットダウンし、他のノードに通知しない場合、パフォーマンスが低下し、最終的にシステム全体が動作を停止します。

ノードの削除は *parting* とも呼ばれ、
bdr.part_node() を使用して実行されます

ファンクション。ノードを削除するには、ノードの作成中に渡されるノード名を指定する必要があります。
bdr.part_node() ファンクションは、削除するノードを含む、PGD グループのアクティブなノードから呼び出すことができます。

参加手順と同様に、分割は Raft コンセンサスを使用して実行され、動作するにはノードの大部分がオンラインである必要があります。

分離プロセスはすべてのノードに影響を与えます。Raft リーダーはノード間の投票を管理して、どのノードが分離ノードからの最新のデータを持つかを確認します。次に、残りのすべてのノードが最新のノードへのセカンダリの一時的な接続を作成して、不足しているデータをキャッチアップできるようにします。

分離されたノードは引き続き PGD に知られていますが、リソースを消費しません。ノードは、分割されたノードと同じ名前で再度追加される場合があります。まれに、ファンクション
bdr.drop_node()

を使用して、分割されたノードのすべてのメタデータをクリアすることが必要になる場合があります。

PGD グループ全体の削除

通常、PGD グループは場所にマッピングされます。ロケーションが展開されない場合、そのロケーションの PGD グループも削除する必要がある可能性があります。

削除される PGD グループは空である必要があります。グループを削除する前に、グループ内のすべてのノードを分割する必要があります。

8.2.10 Joining a heterogeneous cluster

PGD 4.0 ノードは、特定の最小メンテナンスリリース 3.7.6 などの 3.7.x または 3.7 と 4.0 ノードの混合で 3.7.x を実行している EDB Postgres 分散クラスターに参加できます。この手順は、PGD メジャーバージョンだけでなく、基になる PostgreSQL メジャーバージョンもアップグレードする場合に役立ちます。これは、PostgreSQL 12 または 13 で実行されている 3.7 ノードを、PostgreSQL 11 で 3.6.x を実行している EDB Postgres 分散クラスターに参加することにより実現できます。新しいノードは、既存のクラスター内のすべてのノードと同じ PostgreSQL メジャーリリースで実行することもできます。。

PGD は、一部のノードがある PostgreSQL メジャーリリースで 3.6 を実行しており、他のノードが別の PostgreSQL メジャーリリースで 3.7 を実行している場合でも、レプリケーションが全方向に正しく動作することを保証します。ただし、十分な数の新しいノードがクラスターに参加したら、古いノードを分離することにより、クラスターを迅速に同種の状態にすることをお勧めします。古いバージョンでは使用できない可能性のある DDL は実行しないでください。その逆も同様です。

別のメジャー PostgreSQL リリースに参加するノードは、

bdr_init_physical で取得された物理バックアップを使用できません。ノードは論理参加方法を使用して参加する必要があります。

PostgreSQL のメジャーリリースは相互にディスク上の互換性がないため、この方法を使用する必要があります。

3.6 ノードをソースとして使用するクラスターに 3.7 ノードが参加すると、競合解決などの特定の構成がソースノードからコピーされません。ノードは、クラスターに参加した後、構成する必要があります。

8.2.11 Connection DSNs and SSL (TLS)

ノードは `libpq` を使用して接続するため、ノードの DSN は *libpq* 接続文字列です。そのため、接続文字列には、SSL の接続パラメーターを含む許可された `libpq` 接続パラメーターを含めることができます。DSN は、指定されたノードに接続するクライアントからの接続文字列として機能する必要があります。クライアント証明書を使用するこのようなパラメーターセットの例は次のとおりです。

```
sslmode=verify-full sslcert=bdr_client.crt sslkey=bdr_client.key
sslrootcert=root.crt
```

この設定では、ファイル `bdr_client.crt` 、`bdr_client.key` 、および `root.crt` が、適切な権限を持つ各ノードのデータディレクトリに存在する必要があります。`verify-full` モードの場合、サーバーの SSL 証明書がチェックされ、`root.crt` 認証局で直接または間接的に署名されていること、および接続で使用されるホスト名またはアドレスが証明書の内容と一致することを確認します。名前の場合、これはサブジェ

クトの別名、または証明書にそのような名前が存在しない場合、サブジェクトのコモンネーム CN フィールドと一致します。Postgres は現在 IP アドレスのサブジェクト代替名をサポートしていないため、名前ではなくアドレスによって接続が行われる場合、CN フィールドと一致する必要があります。

クライアント証明書の CN は、PGD 接続を行うユーザーの名前である必要があります。通常はユーザー postgres です。各ノードには、pg_hba.conf ファイルでの接続を許可する一致する行が必要です。例

```
hostssl all         postgres 10.1.2.3/24 cert
hostssl replication postgres 10.1.2.3/24 cert
```

別の設定は、クライアント証明書の代わりに SCRAM-SHA-256 パスワードを使用し、証明書が適切に署名されている限りサーバー ID を検証しないことです。ここで、DSN パラメーターは次のとおりです。

```
sslmode=verify-ca sslrootcert=root.crt
```

対応する pg_hba.conf 行は次のとおりです。

```
hostssl all         postgres 10.1.2.3/24 scram-sha-256
hostssl replication postgres 10.1.2.3/24 scram-sha-256
```

このようなシナリオでは、postgres ユーザーには、正しいパスワードを含む .pgpass ファイルが必要です。

8.2.12 Decoding worker

PGD は、データが送信されるノードの数に関係なく、デコードを 1 回実行するデコードワーカープロセスを有効にするオプションを提供します。このオプションは、各 PGD ノードに新しいプロセス WAL デコーダーを導入します。接続ごとに 1 つの WAL 送信者プロセスがまだ存在しますが、これらのプロセスはデータの送受信のタスクを実行するだけです。まとめると、これらの変更は、大規模な PGD グループの CPU オーバーヘッドを削減し、WAL 送信プロセスが通信により多くの時間を費やすようになったため、より高いレプリケーションスループットを可能にします。

有効にする

enable_wal_decoder は、各 PGD グループのオプションであり、現在デフォルトで無効になっています。

> *bdr.alter_node_group_config()* を使用したグループ構成 を使用して、PGD グループのデコードワーカーを有効または無効にできます。

デコードワーカーが有効になっている場合、PGD は論理変更レコード LCR ファイルを保存して、デコードの間、およびすべてのサブスクライブノードがデータを受信したときに変更のバッファリングを許可します。LCR ファイルは、各ローカルノードのデータディレクトリの pg_logical ディレクトリの下に保存されます。レプリケーション遅延が増加すると、LCR ファイルの数とサイズが変化するため、このプロセスも監視が必要です。どの PGD ノードでも必要とされない LCR は、定期的にクリーニングされます。2 つの連続するクリーンアップ間の間隔は、

> *bdr.lcr_cleanup_interval* によって制御されます。デフォルトは 3 分です。*bdr.lcr_cleanup_interval* が 0 の場合、クリーンアップは無効になります。

無効化

無効にすると、論理デコードは、各ノードをサブスクライブする各ノードの WAL 送信プロセスによって実行されます。この場合、LCR ファイルは書き込まれません。

PGD グループでデコードワーカーが有効になっている場合でも、次の GUC はノードごとに LCR の生成と使用を制御します。デフォルトでは、これらは `false` です。 LCR を生成および使用するには、PGD グループのデコードワーカーを有効にし、PGD グループの各ノードでこれらの GUC を `true` に設定します。

- *bdr.enable_wal_decoder* — `false` の場合、LCR を使用するすべての WAL 送信者は WAL を直接使用するように再起動します。`true` と PGD グループ構成を使用すると、デコードワーカープロセスが開始され、LCR および LCR を使用する WAL センダーが生成されます。
- *bdr.receive_lcr* —サブスクライブノードで `true` を実行すると、パブリッシャーノードの WAL 送信者に LCR を使用するように要求します利用可能な場合。

サブスクライバ専用ノードは、各ノードから変更を直接受信します。したがって、加入者専用ノードにサービスを提供する WAL 送信者は、LCR を使用できます。

LCR が生成されても、対応する WAL は、デコードワーカーが有効になっていない場合と同様に保持されます。将来的には、LCR が必要でない場合、LCR に対応する WAL を削除することが可能になる可能性があります。

参考までに、LCR ファイル名の最初の 24 文字は、WAL ファイル名のものと似ています。名前の最初の 8 文字は現在すべて「0」です。将来的には、WAL セグメントファイル名の最初の 8 文字と同様の TimeLineId を表すことが予想されます。次の 16 文字の名前のシーケンスは、WAL ストリームに対して LCR 変更を追跡するために使用される WAL セグメント番号に似ています。

ただし、論理変更は、それらが属しているトランザクションのコミット順序に従って並べ替えられます。したがって、LCR セグメント内のそれらの配置は、WAL セグメント内の対応する WAL の配置と一致しません。

最後の 16 文字のセットは、LCR セグメントのサブセグメント番号を表します。各 LCR ファイルはサブセグメントに対応します。LCR ファイルはバイナリで可変サイズです。LCR ファイルの最大サイズは、`bdr.max_lcr_segment_file_size` で制御できます。デフォルトは 1 GB です。

8.2.13 Replication slots created by PGD

PGD マスターノードでは、次のレプリケーションスロットが PGD によって作成されます。

- 1 つの **グループスロット**、名前付けは `bdr_<database name>_<group name>`
- `bdr_<database name>_<group name>_<node name>` という名前の N-1 **ノードスロット**、N は、クラスター内の PGD ノードの合計数です。ダイレクトロジカルスタンバイがある場合は、

> **警告:** これらのスロットはドロップしないでください。 PGD はそれらを作成および管理し、必要に応じて削除します。

一方、PGD に影響を与えることなく、ソフトウェアの適切なコマンドを使用して、Barman または論理レプリケーションなどのソフトウェアに必要なレプリケーションスロットを作成またはドロップできます。他のソフトウェアが使用するスロット名を接頭辞 bdr_ で始めないでください。

たとえば、3 つのノード alpha 、beta 、および gamma で構成されるクラスターでは、PGD を使用して mydb データベースをレプリケートし、PGD グループは mygroup と呼ばれます。

- ノード alpha には、3 つのスロットがあります。 - bdr_mydb_mygroup という名前の 1 つのグループスロット - bdr_mydb_mygroup_beta および bdr_mydb_mygroup_gamma という名前の 2 つのノードスロット
- ノード beta には、3 つのスロットがあります。 - bdr_mydb_mygroup という名前の 1 つのグループスロット - bdr_mydb_mygroup_alpha および bdr_mydb_mygroup_gamma という名前の 2 つのノードスロット
- ノード gamma には、3 つのスロットがあります。 - bdr_mydb_mygroup という名前の 1 つのグループスロット - bdr_mydb_mygroup_alpha および bdr_mydb_mygroup_beta という名前の 2 つのノードスロット

グループレプリケーションスロット

グループスロットは、主に PGD グループ内のノードすべてのロジカルスタンバイを含むこのノードからのアウトバウンドレプリケーションについて追いついた最も古い安全な位置を追跡するために PGD が使用する内部スロットです。

グループスロット名は、ファンクション *bdr.local_group_slot_name()* によって与えられます。

グループスロットでは次のことができます。

- 既存のノードをすべて起動して実行せずに、新しいノードを PGD グループに参加させますが、ノードの大部分は起動している必要があります。参加中にダウンしたノードが再び複製を開始した場合、このプロセスではデータの損失は発生しません。
- 一部のノードが分離されたノードに完全に追いついていない場合でも、クラスターからノードを一貫して分離します。
- フリーズポイントを抑えて、いくつかの競合の見逃しを回避します。
- タイムスタンプベースのスナップショットの履歴スナップショットを保持します。

グループスロットは通常非アクティブで、他のノードからの Raft 進行状況メッセージに応答して定期的にのみ早送りされます。

> **警告:** グループスロットをドロップしないでください。通常は非アクティブですが、 EDB Postgres 分散クラスターの適切なオペレーションには依然として重要です。これをドロップすると、一部またはすべての機能が動作を停止するか、誤った結果が発生する可能性があります。

長い識別子のハッシュ化

レプリケーションスロットの名前は、他の PostgreSQL 識別子と同様に、63 バイトを超えることはできません。PGD は、結果のスロット名がその制限に対して長すぎる場合、データベース名、PGD グループ名、およびノードの名前を短縮することによりこれを処理します。識別子の短縮は、文字列の最後のセクションを文字列自分自身のハッシュに置き換えることにより実行されます。

たとえば、 `group20xxxxxxxxxxxx` 20 バイト長という名前の PGD グループを使用して、`db20xxxxxxxxxxxxxxx` 20 バイト長という名前のデータベースをレプリケートするクラスターを検討します。`3597186`、`be9cbd0`、および `7f304a2` は、それぞれ `db20xxxxxxxxxxxxxxx`、`group20xxxxxxxxxxxx`、および `a30xxxxxxxxxxxxxxxxxxxxxxxxxxx` のハッシュであるため、ノード `a30xxxxxxxxxxxxxxxxxxxxxxxxxxx` 30 バイト長に関連付けられている論理レプリケーションスロットが呼び出されます。

```
bdr_db20xxxx3597186_group20xbe9cbd0_a30xxxxxxxxxxxx7f304a2
```

8.2.14 Node restart and down node recovery

PGD は、ノードの再起動またはノードの切断から復旧するように設計されています。切断されたノードは、各ピアノードに再接続し、そのノードから欠落しているデータを複製することにより、グループに再参加します。

ノードが起動すると、各接続は `bdr.node_slots.state = catchup` を使用して *bdr.node_slots* に表示され始め、欠落データの複製を開始します。キャッチアップは、各ピアノードからの欠落データの量に応じて継続され、サーバーのワークロードに応じて、時間の経過とともに増加する可能性があります。

各ノードの書き込みアクティビティの量が均一でない場合、より多くのデータを持つノードからのキャッチアップ期間は他のノードよりも大幅に長くかかる場合があります。最終的に、スロットの状態は `bdr.node_slots.state = streaming` に変更されます。

時間や日などの長期間オフラインになっているノードは、さまざまな理由でリソースの問題を発生させる可能性があります。次の問題を理解することなく、長期の停止を計画しないでください。

各ノードは変更情報を保持します 1 つの replication slot を使用

ピアノードごとに) したがって、後で一時的に到達不能なノードへの変更を再生できます。ピアノードが無期限にオフラインになったままである場合、この蓄積された変更情報により、最終的にノードは PostgreSQL トランザクションログ `pg_wal` の *WAL* 用の記憶領域が不足し、これに似たエラーでデータベースサーバーがシャットダウンする可能性があります。

```
PANIC: could not write to file "pg_wal/xlogtemp.559": No space left on device
```

または、他のディスク不足関連の症状を報告する場合があります。

さらに、オフラインノードのスロットもカタログ xmin を抑制し、カタログテーブルのバキュームを防止します。

EDB Postgres Extended Server および EDB Postgres Advanced Server では、オフラインノードもデータのフリーズを抑制して、競合解決データの損失を防ぎます

オリジンの競合検出 を参照してください。

管理者は、ノードの停止を監視し

Monitoring を参照して、ノードに十分な空きディスク領域があることを確認する必要があります。ワークロードが予測可能な場合は、時間の経過とともに使用される領域の量を計算できるため、重要な問題が発生する前にノードがダウンできる最大時間を予測できます。

PGD によって作成されたレプリケーションスロットを手動で削除しないでください。そうした場合、クラスターは損傷し、

Replication slots created by PGD で説明しているように、スロットを使用していたノードをクラスターから分離する必要があります。

ノードがオフラインである間、他のノードはオフラインノードから同じデータのセットをまだ受け取っていない可能性があるため、これはノード全体でのわずかな相違として現れる場合があります。分離プロセスは、ノード間のこの不均衡を修正します。後のバージョンではこれを早く行う場合があります。

8.3 Postgres configuration

いくつかの Postgres 構成パラメーターは PGD ノードに影響を与えます。ノードごとにこれらのパラメーターを異なるように設定できますが、一般的にはお勧めしません。

PGD 独自の設定については、 *PGD settings reference* を参照してください。

8.3.1 Postgres 設定

PGD を正しく実行するには、次の Postgres 設定が必要です。

- `wal_level` — PGD は論理デコードに依存するため、 `logical` に設定する必要があります。
- `shared_preload_libraries` — `bdr` を含める必要がありますが、必要に応じて前後に他のエントリを含めることができます。ただし、`pglogical` は含めないでください。
- `track_commit_timestamp` —競合する各行のタイムスタンプを取得するには、競合を解決するために on に設定する必要があります。

PGD では、これらの PostgreSQL 設定を適切な値に設定する必要があります。これは、クラスターのサイズとスケールによって異なります。

- `logical_decoding_work_mem` —論理デコードによって使用されるメモリバッファサイズ。このサイズよりも大きいトランザクションはバッファをオーバーフローし、ローカルディスクに一時的に保存されます。デフォルトは 64MB ですが、かなり高く設定できます。
- `max_worker_processes` —PGD はレプリケーションとメンテナンスタスクにバックグラウンドワーカーを使用するため、正常に動作するには十分なワーカースロットが必要です。各データベースのワーカーの正しい最小数の式は、次の値を合計することです。- PostgreSQL インスタンスごとに 1 つ - そのインスタンスのデータベースごとに 1 つ - PGD 対応データベースごとに 4 つ - PGD グループのピアノードごとに 1 つ - に 1 つ PGD グループのピアノードごとに各ライター対応ノードが PGD グループから削除されるときに、一時的により多くのワーカープロセスが必要になる場合があります。
- `max_wal_senders` —各ピアノードに 2 つ必要です。
- `max_replication_slots` —各ピアノードに 2 つ必要です。

- `wal_sender_timeout` および `wal_receiver_timeout` —ノードが CAMO パートナーを切断または再接続したとみなすまでの時間を決定します。詳細は、*CAMO failure scenarios* を参照してください。

N 個のピアノードを持つグループの通常の実行では、PGD には N 個のスロットと WAL 送信機が必要です。同期中に、PGD は別の N-1 スロットと WAL センダーを一時的に使用するため、この時折のピーク要求に十分な高いパラメーターを設定するように注意してください。

並列適用をオンにすると、スロット数をフォーミュラ*ライターから N スロットに増やす必要があります。これは、`max_replication_slots` もレプリケーションオリジンの最大数を設定し、パラレル適用の一部の機能はライタごとに追加のオリジンを使用するためです。

> *Decoding worker* が有効になっている場合、このプロセスには PGD グループごとに 1 つの追加のレプリケーションスロットが必要です。

`max_worker_processes`、`max_wal_senders`、および `max_replication_slots` パラメーターを変更するには、ローカルノードを再起動する必要があります。

古い同期レプリケーションモードは、次のパラメーターを使用してサポートされています。詳細と制限については、
Durability and performance options を参照してください。

- `synchronous_commit` および `synchronous_standby_names` —PGD レプリケーションの耐久性とパフォーマンスに影響します。physical replication と同様の方法。

8.3.2 時間ベースのスナップショット

snapshot_timestamp

> *Timestamp-based snapshots* の使用をオンにし、使用するタイムスタンプを設定します。

8.3.3 準備されたトランザクションの最大数

max_prepared_transactions

明示的な 2 フェーズコミット、CAMO、または Eager トランザクションのため、クラスター全体で同時に準備されたトランザクションの最大数に対処するために十分に高く設定する必要があります。制限を超過すると、ノードはローカル 2 フェーズコミットまたは CAMO トランザクションを実行できず、クラスター上のすべての Eager トランザクションを防止します。このパラメーターは、Postgres サーバーの起動時にのみ設定できます。

8.4 DDL replication

DDL はデータ定義言語の略で、データベースオブジェクトを作成、変更、および削除する SQL 言語のサブセットです。

操作の利便性と正確性を維持するために、PGD はほとんどの DDL アクションをレプリケートしますが、次の例外を除きます。

- 一時的なまたはログに記録されていない関係
- 特定の DDL ステートメントほとんどの場合、長時間実行
- ロックコマンド `LOCK`
- テーブルメンテナンスコマンド `VACUUM` 、`ANALYZE` 、`CLUSTER` 、`REINDEX`
- オートバキュームのアクション

・操作コマンド `CHECKPOINT` 、`ALTER SYSTEM`

- データベースまたはテーブルスペースに関連するアクション

自動 DDL レプリケーションにより、DDL 変更をすべてのノードに手動で配布し、一貫性を確認する必要がなく、特定の DDL 変更が簡単になります。

デフォルトのレプリケーションセットでは、DDL はデフォルトですべてのノードにレプリケートされます。DDL をレプリケートするには、DDL レプリケーションフィルタをレプリケーションセットに追加する必要があります。

> *DDL* **レプリケーションフィルタリング** を参照してください。

DDL レプリケーションに関して、PGD はスタンドアロンの PostgreSQL とは大きく異なります。それを同じに扱うことは、PGD で最も一般的な問題です。

テーブルレプリケーションとの主な違いは、DDL レプリケーションが DDL の結果ではなくステートメント自分自身をレプリケートすることです。これは、ほとんどの場合で非常にうまく機能しますが、DDL をすべてのノードで同様に実行する必要があるという要件が導入されます。より微妙な点は、DDL は、拡張機能ビルトインではなくによって導入されたデータ型を含む、すべてのデータ型固有のパラメーター設定に関して不変である必要があることです。たとえば、DDL ステートメントは、各ノードで使用されるデフォルトのエンコーディングで正しく実行される必要があります。

8.4.1 DDL レプリケーションオプション

`bdr.ddl_replication` パラメーターは、レプリケーション動作を指定します。

`bdr.ddl_replication = on` はデフォルトであり、DDL をデフォルトのレプリケーションセットにレプリケートします。デフォルトでは、すべてのノードを意味します。デフォルト以外のレプリケーションセットは、

> *DDL filter* がない限り DDL をレプリケートしません

彼らのために定義されました。

ファンクション bdr.replicate_ddl_command() を使用して、DDL を特定のレプリケーションセットにレプリケートすることもできます。これは、ノードがダウンしているときに DDL コマンドを実行する場合、またはサイト 1 のすべてのノードなど、ノードまたは担当セットのサブセットに存在するインデックスまたはパーティションを必要とする場合に役立ちます。

```
SELECT bdr.replicate_ddl_command(
                CREATE INDEX CONCURRENTLY ON foo (col7);,
                ARRAY[site1],     -- the replication sets
                on);              -- ddl_locking to apply
```

お勧めしませんが、自動 DDL レプリケーションをスキップし、bdr.ddl_replication 構成パラメーターを使用して各ノードで手動で実行できます。

```
SET bdr.ddl_replication = off;
```

設定すると、PGD は実行された DDL コマンドのグローバルロックとレプリケーションの両方をスキップします。次に、すべてのノードで DDL を手動で実行する必要があります。

警告: グローバルロックを使用せずに各ノードで DDL を手動で実行すると、競合する DDL または DML が同時に実行される場合、PGD グループ全体のレプリケートが停止される場合があります。

bdr.ddl_replication パラメーターは、bdr_superuser、スーパーユーザー、または config ファイルでのみ設定できます。

8.4.2 PGD システムでの DDL の実行

PGD グループは、スタンドアロンの PostgreSQL サーバーと同じではありません。これは、集中ロックやトランザクションコーディネーターを使用しない非同期マルチマスターレプリケーションに基づいています。これは、DDL の実行時に重要な意味を持ちます。

パラレルに実行される DDL は、PGD で引き続き実行されます。DDL の実行は、実行時に各ノードの並列オペレーションに影響を与えるパラメーターを尊重するため、ノード間の設定の違いに気づく場合があります。

競合する DDL の実行を防止します。そうしないと、DDL レプリケーションでエラーが発生し、レプリケーションが停止します。

PGD は、これらの問題に対する 3 つのレベルの保護を提供します。

ddl_locking = 'dml' は操作に最適なオプションであり、一度に 1 つのノードのみから DDL を実行する場合に使用できます。これはデフォルトではありませんが、DDL を実行する場所を制御できる場合は、この設定を使用することをお勧めします。こうすることで、ノード間の競合が発生しないようにします。ノード内の競合は PostgreSQL によって既に処理されています。

ddl_locking = on は最も厳密なオプションであり、DDL が任意のノードから同時に実行される可能性があり、正確性を保証したい場合に最適です。

`ddl_locking = off` は最も厳密でないオプションであり、一般的な使用は危険です。このオプションは、ロックを完全にスキップし、パフォーマンスのオーバーヘッドを回避するため、新しい空のデータベーススキーマを作成するときに役立つオプションです。

これらのオプションは、bdr_superuser、スーパーユーザー、または `config file` でのみ設定できます。

`bdr.replicate_ddl_command` を使用する場合、そのファンクションに渡される DDL コマンドにのみ指定された `bdr.ddl_locking` 設定を使用して、3 番目の引数でこのパラメーターを直接設定できます。

8.4.3 DDL ロックの詳細

2 種類のロックは、PGD でレプリケートされた DDL の正しさを強制します。

最初の種類はグローバル DDL ロックと呼ばれ、`ddl_locking = on` の場合にのみ使用されます。グローバル DDL ロックは、各 DDL ステートメントの実行中にクラスターで他の DDL が実行されないようにします。これにより、一般的な場合に完全な正しさが保証されますが、多くの単純な場合には厳密すぎます。PGD は、スキーマ変更が行われるトランザクションで初めて DDL 操作のグローバルロックを取得します。これにより、クラスター内の DDL 実行トランザクションが効果的にシリアル化されます。つまり、DDL の実行中は、ノード上の他の接続は、別のテーブルに影響を与える場合でも、別の DDL コマンドを実行できません。

DDL 操作のロックを取得するために、DDL を実行する PGD ノードは PGD グループ内の他のノードに接続し、DDL を実行する排他的権限を付与するように求めます。ロック要求は通常のレプリケーションストリームによって送信され、ノードは同様にレプリケーションストリームによって応答します。したがって、ノードまたは少なくともノードの大部分が、レプリケーション遅延をほとんど発生せずに実行されることが重要です。そうしないと、ノードが DDL ロックを取得するまでに時間がかかる場合があります。ノードの大部分が同意すると、DDL 実行が実行されます。

DDL ロックの順序は、Raft プロトコルを使用して決定されます。1 つのノードで実行された DDL ステートメントは、他のすべてのノードで同じシーケンスで実行されます。

DDL を実行しているノードがクラスター内で実行された以前のすべての DDL の効果を確認したことを確認するために、以前の DDL を実行したノードに追いつくまで待機します。現在の DDL を実行しているノードが、以前の DDL を実行したノードと比較してレプリケーションが遅れている場合、ロックの取得に時間がかかる場合があります。したがって、単一のノード、または他のノードで発生したレプリケーションの変更にほぼ追いついたノードから DDL を実行することをお勧めします。

2 番目の種類は、グローバル DML ロックまたはリレーション DML ロックと呼ばれます。この種類のロックは、`ddl_locking = on` または `ddl_locking = dml` のいずれか、および DDL ステートメントによりフライト中の DML ステートメントが失敗する可能性がある場合に使用されます。これらの障害は、一意制約、チェック制約、NOT NULL 制約などの制約を追加または変更するときに発生する可能性があります。リレーション DML ロックは、一度に 1 つのリレーションにのみ影響します。リレーション DML ロックは、エラーでレプリケーションを停止する可能性のある変更がキューにあるときに DDL が実行されないことを保証します。

テーブルのグローバル DML ロックを取得するために、DDL を実行する PGD ノードは PGD グループ内の他のすべてのノードに接続し、書き込みに対してテーブルをロックするように依頼し、そのテーブルの保留中の変更がすべてドレインされるまで待機します。すべてのノードが完全に追いつくと、DML ロックの発信者は自由にテーブルのスキーマ変更を実行し、他のノードにレプリケートできます。

グローバル DML ロックは、各ノードのテーブルの EXCLUSIVE LOCK を保持するため、実行中にそのテーブルに対する DML、他の DDL、VACUUM、および index コマンドをブロックします。これは、通常 EXCLUSIVE LOCK 以上を使用しないコマンドにグローバル DML ロックが保持されている場合にも当てはまります。

保留中の DML 操作がドレインされるまでに長い時間がかかる場合があり、レプリケーションが現在遅延している場合はさらに長くなります。これは、データの変更とは異なり、行表現とコンストレインに影響を与えるスキーマの変更が、構成されているすべてのノードに到達でき、現在の書き込みレートに適度に追随しているときにのみ実行できることを意味します。ノードがダウンしているときにこのような DDL コマンドを実行する必要がある場合は、最初にダウンしたノードを構成から削除します。

DDL ステートメントがレプリケートされない場合、グローバルロックは取得されません。

PGD システムでの DDL の実行 で説明しているように、ロック動作は `bdr.ddl_locking`

パラメーターで指定されます。

- `ddl_locking = on` は、グローバル DDL ロックを取得し、必要に応じてリレーション DML ロックを取得します。
- `ddl_locking = dml` は、グローバル DDL ロックをスキップし、必要に応じてリレーション DML ロックを取得します。
- `ddl_locking = off` は、グローバル DDL ロックとリレーション DML ロックの両方をスキップします。

一部の PGD ファンクションは DDL 変更を行います。これらのファンクションには、DDL ロック動作が適用されます。これについては、各ファンクションのドキュメントに記載されています。

したがって、 `ddl_locking = dml` は、競合する DDL が他のノードから実行されないことを保証できる場合にのみ安全です。この設定では、グローバル DDL ロックのみを必要とするステートメントは、グローバルロックをまったく使用しません。

`ddl_locking = off` は、DDL が実行されるデータベースオブジェクトで競合する DDL と競合する DML 操作がないことを保証できる場合にのみ安全です。ロックをオフにした後に問題が発生すると、データの進行中の変更が失われる可能性があります。ユーザーアプリケーションチームは、発生した問題を解決する必要があります。

場合によっては、同時に実行される DDL を適切にシリアル化できる場合があります。これらのシリアル化障害が発生した場合、DDL が再実行される場合があります。

DDL レプリケーションは、昇格するまでロジカルスタンバイノードでアクティブになりません。

一部の PGD 管理機能は DDL のように動作します。つまり、グローバルロックを取得しようとし、DDL レプリケーションがアクティブな場合、アクションがレプリケートされます。レプリケートファンクションの完全なリストは、

DDL のように動作する PGD ファンクション にリストされています。

一時テーブルで実行される DDL は、グローバルロックを必要としません。

現在のトランザクションで作成されたオブジェクトの ALTER または DROP には、グローバル DML ロックは必要ありません。

グローバル DDL ロックとグローバル DML ロックのモニタリングは

Monitoring に表示されます。

8.4.4 DDL のインパクトの最小化

あらゆるデータベースに対する適切な運用上のアドバイス。PGD ではこれらの点がさらに重要になります。

- DDL の影響を最小限にするには、DDL を実行するトランザクションを短くし、大量の行変更と組み合わせず、長時間実行される外部キーまたはその他の制約の再チェックを回避します。
- ALTER TABLE の場合、ADD CONSTRAINT を単独で使用するのではなく、ADD CONSTRAINT NOT VALID を使用し、その後に VALIDATE CONSTRAINT との別のトランザクションを使用します。 VALIDATE CONSTRAINT は、すべてのノードで再生されるまで待機するため、確認の受信に顕著な遅延が発生します。
- インデックスを作成するときは、可能な限り CONCURRENTLY オプションを使用します。

長時間実行 DDL を実行する別の方法は、DDL レプリケーションを無効にして、各ノードで個別に DDL ステートメントを実行することです。次の例に示すように、単一の SQL ステートメントを使用してこれを行うことができます。グローバルロックルールは引き続き適用されるため、このタイプの使用法で自分自身をロックアウトしないように注意してください。これは回避策です。

```
SELECT bdr.run_on_all_nodes($ddl$
        CREATE INDEX CONCURRENTLY index_a ON table_a(i);
$ddl$);
```

CREATE INDEX CONCURRENTLY はマルチトランザクションコマンドであるため、セッション全体で DDL レプリケーションを無効にする必要があることに注意して、bdr.run_on_all_nodes() テクニックを使用することをお勧めします。実行中の書き込みを防止するため、実稼働システムでは CREATE INDEX を避けてください。 REINDEX は、3.6 までのバージョンでレプリケートされていますが、PGD 3.7 以降ではレプリケートされません。 REINDEX は、AccessExclusiveLocks を保持するため、使用を避けてください。

代わりに、PG12+または 2QPG11+で使用可能な REINDEX CONCURRENTLY または reindexdb --concurrently を使用します。

次のようなコマンドラインユーティリティを使用する場合、DDL レプリケーションを無効にできます。

```
$ export PGOPTIONS="-c bdr.ddl_replication=off"
$ pg_restore --section=post-data
```

複数の DDL ステートメントは、個々のステートメントとして起動されるよりも単一のトランザクションに束ねたほうがメリットがある場合があるため、DDL ロックは 1 回のみを取ります。テーブルレベルのロックが通常の操作を妨げる場合、これは望ましくない場合があります。

DDL がシステムを長時間保持している場合は、 psql の **Control-C** または pg_cancel_backend() を使用して、元のノードで DDL を安全にキャンセルできます。他のノードから DDL ロックをキャンセルすることはできません。

オプションのグローバルロックタイムアウト設定を使用して、グローバルロックにかかる時間を制御できます。bdr.global_lock_timeout は、グローバルロックの取得がキャンセルされるまでの待機時間を制

限します。bdr.global_lock_statement_timeout は、グローバルロックを保持するトランザクション内のステートメントの実行タイム長を制限し、bdr.global_lock_idle_timeout は、グローバルロックを保持するトランザクションの最大許可アイドル時間ステートメント間の時間を設定します。値をゼロに設定することにより、これらのタイムアウトをすべて無効にできます。

元のノードで DDL 操作がコミットされると、キャンセルまたは中止することはできません。PGD グループは、グローバルロックを確認した他のノードに正常に適用され、それらが再生を確認するまで待機する必要があります。このため、DDL トランザクションは短くて速いままにしてください。

8.4.5 ダウンしたノードでの DDL の処理

グローバル DDL ロックを開始するノードがグローバルロック DDL または DML を取得した後にダウンした場合、ロックはアクティブなままです。タイムアウトが設定されていても、グローバルロックはタイムアウトしません。ノードが復旧した場合、ノードは保持しているすべてのグローバルロックを解放します。

長時間または無期限にダウンしたままになる場合は、PGD グループからノードを削除してグローバルロックを解放します。これが、bdr_superuser として SET コマンドを使用して緊急 DDL を実行し、bdr.ddl_locking 値を更新する理由の 1 つです。

グローバルロックを確認した後、それを取得するコマンドが実行される前に、他のノードのいずれかがダウンした場合、ノードがアップしているかのように、ロックを要求するそのコマンドの実行は続行されます。

前述のように、グローバル DDL ロックはノードの大部分のみが応答する必要があるため、大部分が実行され到達可能である限り、クラスターの一部がダウンしている場合に機能します。ただし、クラスター全体が利用できない限り DML ロックは取得できません。

グローバル DDL またはグローバル DML ロックでは、別のノードがダウンすると、コマンドは通常に続行され、ロックが解放されます。

8.4.6 ステートメント固有の DDL レプリケーションの問題

すべてのコマンドを自動的に複製できるわけではありません。bdr.ddl_replication をオフにして DDL レプリケーションをオフにしない限り、このようなコマンドは許可されません。

PGD は、データベースでアクティブなときに一部の DDL ステートメントの実行を防止します。これにより、正しくレプリケートできないステートメント、またはレプリケーションがまだサポートされていないステートメントを禁止することにより、システムの一貫性が保護されます。

ステートメントが PGD で許可されない場合、多くの場合、同じことを行う別の方法を見つけることができます。たとえば、揮発性のデフォルト値を含む列を追加する ALTER TABLE は実行できません。しかし、一般的には、機能する一連の独立した ALTER TABLE および UPDATE ステートメントとして言い換えることができます。

通常、サポートされていないステートメントは実行されず、feature_not_supported SQLSTATE 0A000 エラーが発生します。

一時オブジェクトを参照または依存する DDL は、PGD でレプリケートできず、DDL レプリケーションを有効にして実行するとエラーがスローされます。

8.4.7 PGD DDL コマンド処理マトリックス

次の表では、許可されるユーティリティまたは DDL コマンド、レプリケートされるもの、およびレプリケート時に使用されるグローバルロックの種類について説明します。

`ALTER TABLE` のようなより複雑なステートメントの場合、これらは実行されるサブコマンドによって異なる場合があります。このようなすべてのコマンドには、次の表の下に詳細な説明があります。

Command	Allowed	Replicated	Lock
ALTER AGGREGATE	Y	Y	DDL
ALTER CAST	Y	Y	DDL
ALTER COLLATION	Y	Y	DDL
ALTER CONVERSION	Y	Y	DDL
ALTER DATABASE	Y	N	N
ALTER DATABASE LINK	Y	Y	DDL
ALTER DEFAULT PRIVILEGES	Y	Y	DDL
ALTER DIRECTORY	Y	Y	DDL
ALTER DOMAIN	Y	Y	DDL
ALTER EVENT TRIGGER	Y	Y	DDL
ALTER EXTENSION	Y	Y	DDL
ALTER FOREIGN DATA WRAPPER	Y	Y	DDL
ALTER FOREIGN TABLE	Y	Y	DDL
ALTER FUNCTION	Y	Y	DDL
ALTER INDEX	Y	Y	DDL
ALTER LANGUAGE	Y	Y	DDL
ALTER LARGE OBJECT	N	N	N
ALTER MATERIALIZED VIEW	Y	N	N
ALTER OPERATOR	Y	Y	DDL
ALTER OPERATOR CLASS	Y	Y	DDL
ALTER OPERATOR FAMILY	Y	Y	DDL
ALTER PACKAGE	Y	Y	DDL
ALTER POLICY	Y	Y	DDL
ALTER PROCEDURE	Y	Y	DDL
ALTER PROFILE	Y	Y	アーキテクチャの詳細
ALTER PUBLICATION	Y	Y	DDL
ALTER QUEUE	Y	Y	DDL
ALTER QUEUE TABLE	Y	Y	DDL
ALTER REDACTION POLICY	Y	Y	DDL
ALTER RESOURCE GROUP	Y	N	N
ALTER ROLE	Y	Y	DDL
ALTER ROUTINE	Y	Y	DDL
ALTER RULE	Y	Y	DDL
ALTER SCHEMA	Y	Y	DDL
ALTER SEQUENCE	アーキテクチャの詳細	Y	DML

次のページに続く

表 1 – 前のページからの続き

Command	Allowed	Replicated	Lock
ALTER SERVER	Y	Y	DDL
ALTER SESSION	Y	N	N
ALTER STATISTICS	Y	Y	DDL
ALTER SUBSCRIPTION	Y	Y	DDL
ALTER SYNONYM	Y	Y	DDL
ALTER SYSTEM	Y	N	N
ALTER TABLE	アーキテクチャの詳細	Y	アーキテクチャの詳細
ALTER TABLESPACE	Y	N	N
ALTER TEXT SEARCH CONFIGURATION	Y	Y	DDL
ALTER TEXT SEARCH DICTIONARY	Y	Y	DDL
ALTER TEXT SEARCH PARSER	Y	Y	DDL
ALTER TEXT SEARCH TEMPLATE	Y	Y	DDL
ALTER TRIGGER	Y	Y	DDL
ALTER TYPE	Y	Y	DDL
ALTER USER MAPPING	Y	Y	DDL
ALTER VIEW	Y	Y	DDL
ANALYZE	Y	N	N
BEGIN	Y	N	N
CHECKPOINT	Y	N	N
CLOSE	Y	N	N
CLOSE CURSOR	Y	N	N
CLOSE CURSOR ALL	Y	N	N
CLUSTER	Y	N	N
COMMENT	Y	アーキテクチャの詳細	DDL
COMMIT	Y	N	N
COMMIT PREPARED	Y	N	N
COPY	Y	N	N
COPY FROM	Y	N	N
CREATE ACCESS METHOD	Y	Y	DDL
CREATE AGGREGATE	Y	Y	DDL
CREATE CAST	Y	Y	DDL
CREATE COLLATION	Y	Y	DDL
CREATE CONSTRAINT	Y	Y	DDL
CREATE CONVERSION	Y	Y	DDL
CREATE DATABASE	Y	N	N
CREATE DATABASE LINK	Y	Y	DDL
CREATE DIRECTORY	Y	Y	DDL
CREATE DOMAIN	Y	Y	DDL
CREATE EVENT TRIGGER	Y	Y	DDL
CREATE EXTENSION	Y	Y	DDL

次のページに続く

表 1 – 前のページからの続き

Command	Allowed	Replicated	Lock
CREATE FOREIGN DATA WRAPPER	Y	Y	DDL
CREATE FOREIGN TABLE	Y	Y	DDL
CREATE FUNCTION	Y	Y	DDL
CREATE INDEX	Y	Y	DML
CREATE LANGUAGE	Y	Y	DDL
CREATE MATERIALIZED VIEW	Y	N	N
CREATE OPERATOR	Y	Y	DDL
CREATE OPERATOR CLASS	Y	Y	DDL
CREATE OPERATOR FAMILY	Y	Y	DDL
CREATE PACKAGE	Y	Y	DDL
CREATE PACKAGE BODY	Y	Y	DDL
CREATE POLICY	Y	Y	DML
CREATE PROCEDURE	Y	Y	DDL
CREATE PROFILE	Y	Y	アーキテクチャの詳細
CREATE PUBLICATION	Y	Y	DDL
CREATE QUEUE	Y	Y	DDL
CREATE QUEUE TABLE	Y	Y	DDL
CREATE REDACTION POLICY	Y	Y	DDL
CREATE RESOURCE GROUP	Y	N	N
CREATE ROLE	Y	Y	DDL
CREATE ROUTINE	Y	Y	DDL
CREATE RULE	Y	Y	DDL
CREATE SCHEMA	Y	Y	DDL
CREATE SEQUENCE	アーキテクチャの詳細	Y	DDL
CREATE SERVER	Y	Y	DDL
CREATE STATISTICS	Y	Y	DDL
CREATE SUBSCRIPTION	Y	Y	DDL
CREATE SYNONYM	Y	Y	DDL
CREATE TABLE	アーキテクチャの詳細	Y	DDL
CREATE TABLE AS	アーキテクチャの詳細	Y	DDL
CREATE TABLESPACE	Y	N	N
CREATE TEXT SEARCH CONFIGURATION	Y	Y	DDL
CREATE TEXT SEARCH DICTIONARY	Y	Y	DDL
CREATE TEXT SEARCH PARSER	Y	Y	DDL
CREATE TEXT SEARCH TEMPLATE	Y	Y	DDL
CREATE TRANSFORM	Y	Y	DDL
CREATE TRIGGER	Y	Y	DDL
CREATE TYPE	Y	Y	DDL
CREATE TYPE BODY	Y	Y	DDL

次のページに続く

表 1 – 前のページからの続き

Command	Allowed	Replicated	Lock
CREATE USER MAPPING	Y	Y	DDL
CREATE VIEW	Y	Y	DDL
DEALLOCATE	Y	N	N
DEALLOCATE ALL	Y	N	N
DECLARE CURSOR	Y	N	N
DISCARD	Y	N	N
DISCARD ALL	Y	N	N
DISCARD PLANS	Y	N	N
DISCARD SEQUENCES	Y	N	N
DISCARD TEMP	Y	N	N
DO	Y	N	N
DROP ACCESS METHOD	Y	Y	DDL
DROP AGGREGATE	Y	Y	DDL
DROP CAST	Y	Y	DDL
DROP COLLATION	Y	Y	DDL
DROP CONSTRAINT	Y	Y	DDL
DROP CONVERSION	Y	Y	DDL
DROP DATABASE	Y	N	N
DROP DATABASE LINK	Y	Y	DDL
DROP DIRECTORY	Y	Y	DDL
DROP DOMAIN	Y	Y	DDL
DROP EVENT TRIGGER	Y	Y	DDL
DROP EXTENSION	Y	Y	DDL
DROP FOREIGN DATA WRAPPER	Y	Y	DDL
DROP FOREIGN TABLE	Y	Y	DDL
DROP FUNCTION	Y	Y	DDL
DROP INDEX	Y	Y	DDL
DROP LANGUAGE	Y	Y	DDL
DROP MATERIALIZED VIEW	Y	N	N
DROP OPERATOR	Y	Y	DDL
DROP OPERATOR CLASS	Y	Y	DDL
DROP OPERATOR FAMILY	Y	Y	DDL
DROP OWNED	Y	Y	DDL
DROP PACKAGE	Y	Y	DDL
DROP PACKAGE BODY	Y	Y	DDL
DROP POLICY	Y	Y	DDL
DROP PROCEDURE	Y	Y	DDL
DROP PROFILE	Y	Y	DDL
DROP PUBLICATION	Y	Y	DDL
DROP QUEUE	Y	Y	DDL
DROP QUEUE TABLE	Y	Y	DDL
DROP REDACTION POLICY	Y	Y	DDL
DROP RESOURCE GROUP	Y	N	N

次のページに続く

表 1 – 前のページからの続き

Command	Allowed	Replicated	Lock
DROP ROLE	Y	Y	DDL
DROP ROUTINE	Y	Y	DDL
DROP RULE	Y	Y	DDL
DROP SCHEMA	Y	Y	DDL
DROP SEQUENCE	Y	Y	DDL
DROP SERVER	Y	Y	DDL
DROP STATISTICS	Y	Y	DDL
DROP SUBSCRIPTION	Y	Y	DDL
DROP SYNONYM	Y	Y	DDL
DROP TABLE	Y	Y	DML
DROP TABLESPACE	Y	N	N
DROP TEXT SEARCH CONFIGURATION	Y	Y	DDL
DROP TEXT SEARCH DICTIONARY	Y	Y	DDL
DROP TEXT SEARCH PARSER	Y	Y	DDL
DROP TEXT SEARCH TEMPLATE	Y	Y	DDL
DROP TRANSFORM	Y	Y	DDL
DROP TRIGGER	Y	Y	DDL
DROP TYPE	Y	Y	DDL
DROP TYPE BODY	Y	Y	DDL
DROP USER MAPPING	Y	Y	DDL
DROP VIEW	Y	Y	DDL
EXECUTE	Y	N	N
EXPLAIN	Y	アーキテクチャの詳細	アーキテクチャの詳細
FETCH	Y	N	N
GRANT	Y	アーキテクチャの詳細	DDL
GRANT ROLE	Y	Y	DDL
IMPORT FOREIGN SCHEMA	Y	Y	DDL
LISTEN	Y	N	N
LOAD	Y	N	N
LOAD ROW DATA	Y	Y	DDL
LOCK TABLE	Y	N	アーキテクチャの詳細
MOVE	Y	N	N
NOTIFY	Y	N	N
PREPARE	Y	N	N
PREPARE TRANSACTION	Y	N	N
REASSIGN OWNED	Y	Y	DDL
REFRESH MATERIALIZED VIEW	Y	N	N
REINDEX	Y	N	N
RELEASE	Y	N	N
RESET	Y	N	N

次のページに続く

表 1 – 前のページからの続き

Command	Allowed	Replicated	Lock
REVOKE	Y	アーキテクチャの詳細	DDL
REVOKE ROLE	Y	Y	DDL
ROLLBACK	Y	N	N
ROLLBACK PREPARED	Y	N	N
SAVEPOINT	Y	N	N
SECURITY LABEL	Y	アーキテクチャの詳細	DDL
SELECT INTO	アーキテクチャの詳細	Y	DDL
SET	Y	N	N
SET CONSTRAINTS	Y	N	N
SHOW	Y	N	N
START TRANSACTION	Y	N	N
TRUNCATE TABLE	Y	アーキテクチャの詳細	アーキテクチャの詳細
UNLISTEN	Y	N	N
VACUUM	Y	N	N

ALTER SEQUENCE

一般に `ALTER SEQUENCE` がサポートされていますが、グローバルシーケンスを使用する場合、一部のオプションは効果がありません。

`ALTER SEQUENCE ... RENAME` は、galloc シーケンスのみでサポートされていません。`ALTER SEQUENCE ... SET SCHEMA` は、galloc シーケンスのみでサポートされていません。

ALTER TABLE

通常、 `ALTER TABLE` コマンドは許可されます。ただし、いくつかのサブコマンドはサポートされていません。

ALTER TABLE は許可されないコマンド

`ALTER TABLE` の一部のバリアントは、現在 PGD ノードで使用できません。

- `ADD COLUMN ... DEFAULT (non-immutable expression)` —これは、現在別のノードで別のデータになるため、許可されていません。推奨される回避策については、列の追加 を参照してください。
- `ADD CONSTRAINT ... EXCLUDE` —除外コンストレインは、現時点ではサポートされていません。除外コンストレインは非同期システムではあまり意味がなく、再生できない変更をもたらします。
- `ALTER TABLE ... SET WITH[OUT] OIDS` — `CREATE TABLE` と同じ理由でサポートされていません。

- ALTER COLUMN ... SET STORAGE external —列がテーブルのレプリカ ID の列の 1 つである場合、拒否されます。
- RENAME —自動パーティション化されたテーブルの名前は変更できません。
- SET SCHEMA —自動パーティション化されたテーブルのスキーマは設定できません。
- ALTER COLUMN ... TYPE —コマンドによってテーブル全体が書き換えられる場合、列のタイプの変更はサポートされません。これは、変更がバイナリ強制可能でない場合に発生します。バイナリの強制変更は、一方通行のみが許可される場合があります。たとえば、VARCHAR(128) から VARCHAR(256) への変更はバイナリ強制可能であるため許可されますが、VARCHAR(256) から VARCHAR(128) への変更はバイナリ強制可能ではないため、通常は許可されません。非レプリケートの ALTER COLUMN ... TYPE は、列が新しいタイプに自動的にキャスト可能である場合に許可されます USING 句が含まれません。次に例を示します。テーブルリライトは、大規模なテーブルで AccessExclusiveLock を長期間保持するため、このようなコマンドは、いずれの場合も高可用データベースでは実行不可能である可能性があります。推奨される回避策については、列のタイプの変更 を参照してください。
- ALTER TABLE ... ADD FOREIGN KEY —現在のユーザーが参照されるテーブルを読み取る権限がない場合、または参照されるテーブルで現在のユーザーがバイパスできない RLS 制限が有効になっている場合、サポートされません。

次の例は、timestamp 型の定数値を timestamptz 型の列に追加しようとするため、失敗します。 timestamp と timestamptz 間のキャストは、セッションのタイムゾーンに依存するため、不変ではありません。

```
ALTER TABLE foo
  ADD expiry_date timestamptz DEFAULT timestamp 2100-01-01 00:00:00 NOT NULL;
```

PGD 3.7.4 以降、DML ロックを取得せずに、 CHECK や FOREIGN KEY 制約などの特定のタイプの制約を追加できます。ただし、これには、最初に NOT VALID 制約を作成し、次に ALTER TABLE ... VALIDATE CONSTRAINT コマンドを使用して別のトランザクションで制約を検証する 2 段階のプロセスが必要です。

コンストレインの追加 を参照

詳細については、

ALTER TABLE ロック

ALTER TABLE の次のバリアントは、DDL ロックのみを取得し、DML ロックは取得しません。

- ALTER TABLE ... ADD COLUMN ... (immutable) DEFAULT
- ALTER TABLE ... ALTER COLUMN ... SET DEFAULT expression
- ALTER TABLE ... ALTER COLUMN ... DROP DEFAULT
- ALTER TABLE ... ALTER COLUMN ... TYPE リライトが必要ない場合
- ALTER TABLE ... ALTER COLUMN ... SET STATISTICS
- ALTER TABLE ... VALIDATE CONSTRAINT
- ALTER TABLE ... ATTACH PARTITION

- ALTER TABLE ... DETACH PARTITION
- ALTER TABLE ... ENABLE TRIGGER ENABLE REPLICA TRIGGER は引き続き DML ロックを取得します
- ALTER TABLE ... CLUSTER ON
- ALTER TABLE ... SET WITHOUT CLUSTER
- ALTER TABLE ... SET (storage_parameter = value [, ...])
- ALTER TABLE ... RESET (storage_parameter = [, ...])
- ALTER TABLE ... OWNER TO

ALTER TABLE の他のすべてのバリアントは、変更されるテーブルで DML ロックを取得します。ALTER TABLE の一部のバリアントには、以下に説明する制限があります。

ALTER TABLE の例

この次の例は、型の変更がバイナリ強制可能であるため、テーブルの書き換えが発生しないため、機能します。カタログのみの変更として実行されます。

```
CREATE TABLE foo (id BIGINT PRIMARY KEY, description VARCHAR(20));
ALTER TABLE foo ALTER COLUMN description TYPE VARCHAR(128);
```

ただし、 VARCHAR(128) から VARCHAR(20) への変更はバイナリ強制可能ではないため、コマンドを逆に変更することは不可能です。

```
ALTER TABLE foo ALTER COLUMN description TYPE VARCHAR(20);
```

回避策については、 制限され *DDL* の回避策 を参照してください。

一般におよび非レプリケート環境で可能なさまざまなタイプの ALTER TABLE ... ALTER COLUMN TYPE ATCT 操作のコンテキストを提供すると役立ちます。

一部の ATCT 操作は、基になる列タイプのメタデータのみを更新し、基になるテーブルデータの書き換えは必要ありません。これは通常、既存の列タイプとターゲットタイプがバイナリ強制可能な場合に当てはまります。例

```
CREATE TABLE sample (col1 BIGINT PRIMARY KEY, col2 VARCHAR(128), col3 INT);
ALTER TABLE sample ALTER COLUMN col2 TYPE VARCHAR(256);
```

バイナリの強制性のため、列タイプを VARCHAR または TEXT データ型に変更することもできます。繰り返しますが、これは基になる列タイプの単なるメタデータの更新です。

```
ALTER TABLE sample ALTER COLUMN col2 TYPE VARCHAR;
ALTER TABLE sample ALTER COLUMN col2 TYPE TEXT;
```

ただし、col2 のサイズを削減したい場合は、基になるテーブルデータの書き換えが必要になります。テーブルの書き換えは通常制限されています。

```
ALTER TABLE sample ALTER COLUMN col2 TYPE VARCHAR(64);
ERROR:  ALTER TABLE ... ALTER COLUMN TYPE that rewrites table data may not affect␣
↪replicated tables on a PGD node
```

非テキストタイプの例として、INTEGER タイプを使用した上記の col3 を検討します。SMALLINT または BIGINT に変換しようとする ATCT 操作は、上記と同様の方法で失敗します。

```
ALTER TABLE sample ALTER COLUMN col3 TYPE bigint;
ERROR:  ALTER TABLE ... ALTER COLUMN TYPE that rewrites table data may not affect␣
↪replicated tables on a PGD node
```

これらの失敗したケースは両方とも、現在の型からターゲット型への自動割り当てキャストがあります。ただし、バイナリの強制力がないため、基になるテーブルデータの書き換えが発生します。

このような場合、制御された DBA 環境では、すべてのノードの非レプリケート環境でこの列のタイプのローリングアップグレードを採用することにより、列のタイプを自動的にキャスト可能なものに変更できます。DDL はレプリケートされず、列型の変更は自動的にキャスト可能なものであると仮定します。次に、この同じテーブル上の他のノードでの同時アクティビティとともに、変更を実行するノードでローカルに書き換えを許可できます。次に、すべてのノードでこの非レプリケートの ATCT 操作を 1 つずつ繰り返し、EDB Postgres 分散クラスター全体で列タイプの目的の変更をもたらすことができます。これには書き換えが含まれるため、アクティビティは引き続き短期間 DML ロックを取得するため、クラスター全体が利用できる必要があります。これらの詳細を設定すると、次のような非レプリケートの変更アクティビティのローリングアップグレードを実行できます。

```
- - foreach node in EDB Postgres Distributed cluster do:
SET bdr.ddl_replication TO FALSE;
ALTER TABLE sample ALTER COLUMN col2 TYPE VARCHAR(64);
ALTER TABLE sample ALTER COLUMN col3 TYPE BIGINT;
RESET bdr.ddl_replication;
- - done
```

自動割り当てキャストは多くのデータ型で利用できるため、このローカルの非レプリケート ATCT 操作は、さまざまな変換をサポートします。また、USING 句を使用する ATCT 操作は、自動割り当てキャストがないため失敗する可能性があります。この例は、自動割り当てキャストを使用したいくつかの一般的な変換を示しています。

```
- - foreach node in EDB Postgres Distributed cluster do:
SET bdr.ddl_replication TO FALSE;
ATCT operations to-from {INTEGER, SMALLINT, BIGINT}
ATCT operations to-from {CHAR(n), VARCHAR(n), VARCHAR, TEXT}
ATCT operations from numeric types to text types
RESET bdr.ddl_replication;
- - done
```

この例は、非レプリケート環境で許可される可能性のある ATCT 操作の完全なリストではありません。すべての ATCT 操作が機能するわけではありません。自動割り当てができない場合、DDL レプリケーションを無効にしても失敗します。したがって、数値型からテキスト型への変換は非レプリケート環境で機能し

ますが、テキスト型から数値型への逆変換は失敗します。

```
SET bdr.ddl_replication TO FALSE;
- - conversion from BIGINT to TEXT works
ALTER TABLE sample ALTER COLUMN col3 TYPE TEXT;
- - conversion from TEXT back to BIGINT fails
ALTER TABLE sample ALTER COLUMN col3 TYPE BIGINT;
ERROR:  ALTER TABLE ... ALTER COLUMN TYPE which cannot be automatically cast to new␣
↪type may not affect replicated tables on a PGD node
RESET bdr.ddl_replication;
```

非レプリケート環境の ATCT 操作はさまざまな型変換をサポートしていますが、基になるテーブルデータに新しいデータ型に割り当てできない値が含まれている場合、リライトは失敗する場合があります。たとえば、列の現在のタイプが VARCHAR(256) で、非レプリケート ATCT 操作を試行して VARCHAR(128) に変換するとします。テーブルに 128 バイトを超える既存のデータがある場合、書き換え操作はローカルに失敗します。

```
INSERT INTO sample VALUES (1, repeat(a, 200), 10);
SET bdr.ddl_replication TO FALSE;
ALTER TABLE sample ALTER COLUMN col2 TYPE VARCHAR(128);
INFO:  in rewrite
ERROR:  value too long for type character varying(128)
```

基になるテーブルデータが新しい型の特性を満たしている場合、書き換えは成功します。ただし、非レプリケートのローリングデータタイプのアップグレードをまだ実行していない他のノードが、128 バイトより広い新しいデータをこのローカル ATCT 操作に同時に導入する場合、レプリケーションは失敗する可能性があります。これにより、クラスターでのレプリケーションが停止します。したがって、これらの非レプリケートのローリングデータ型のアップグレード操作を実行する間は、データベースおよびアプリケーションレベルでのデータ型の制限と特性に注意してください。このような ATCT 操作は、制御された完全に認識した DBA 環境で実行およびテストすることを強くお勧めします。これらの ATCT 操作は非対称であり、失敗した特定の変更をバックアウトすると、時間がかかるテーブルの書き換えが発生する可能性があります。

また、トランザクションブロックで暗黙的なキャスト可能 ALTER アクティビティを実行することはできません。

ALTER TYPE

ALTER TYPE はレプリケートされますが、PostgreSQL はこれらの依存関係を記録しないため、グローバル DML ロックはそのデータ型を使用するすべてのテーブルに適用されません。

制限され *DDL* の回避策 を参照してください。

コメントオン

COMMENT ON のすべてのバリアントが許可されますが、COMMENT ON TABLESPACE/DATABASE/LARGE OBJECT はレプリケートされません。

CREATE PROFILE または ALTER PROFILE

ファンクションが SECURITY DEFINER の場合、プロファイルに関連付けられている PASSWORD_VERIFY_FUNCTION は IMMUTABLE である必要があります。このような CREATE PROFILE または ALTER PROFILE コマンドはレプリケートされますが、このプロファイルを使用する後続の CREATE USER または ALTER USER コマンドは、 writer ワーカーが cannot change current role within security-restricted operation エラーをスローするため、レプリケーションを中断します。

CREATE SEQUENCE

一般に CREATE SEQUENCE がサポートされていますが、グローバルシーケンスを使用する場合、一部のオプションは効果がありません。

CREATE TABLE

一般に CREATE TABLE はサポートされていますが、CREATE TABLE WITH OIDS は PGD ノードでは許可されていません。

CREATE TABLE AS と SELECT INTO

CREATE TABLE AS および SELECT INTO は、すべてのサブコマンドも許可される場合にのみ許可されます。

EXPLAIN

一般に EXPLAIN は許可されますが、 EXPLAIN ANALYZE はデータベースに副作用を与える可能性があるため、いくつかの制限があります。

EXPLAIN ANALYZE レプリケーション

EXPLAIN ANALYZE は、分析されたステートメントのレプリケーションルールに従います。

EXPLAIN ANALYZE ロック

EXPLAIN ANALYZE は、分析されたステートメントのロックルールに従います。

GRANT と REVOKE

通常、GRANT および REVOKE ステートメントはサポートされていますが、GRANT/REVOKE ON TABLESPACE/LARGE OBJECT はレプリケートされません。

ロックテーブル

LOCK TABLE はレプリケートされませんが、bdr.lock_table_locking が on に設定されている場合、グローバル DML ロックを取得する場合があります。

bdr.global_lock_table() ファンクションを使用して、グローバル DML ロックを明示的に要求することもできます。

セキュリティラベル

SECURITY LABEL のすべてのバリアントが許可されますが、SECURITY LABEL ON TABLESPACE/DATABASE/LARGE OBJECT はレプリケートされません。

TRUNCATE レプリケーション

TRUNCATE コマンドは、DDL ステートメントではなく DML としてレプリケートされます。テーブルの TRUNCATE がレプリケートされるかどうかは、影響を受ける各テーブルのレプリケーション設定によって異なります。

TRUNCATE ロック

TRUNCATE は他の DDL と同じ方法でレプリケートされませんが、bdr.truncate_locking が on に設定されている場合、グローバル DML ロックを取得できます。

ロール操作ステートメント

ユーザーは PostgreSQL インスタンスのグローバルオブジェクトです。つまり、ユーザーは複数のデータベースにまたがりますが、PGD は個々のデータベースレベルで動作します。これは、ロール操作ステートメントの処理に追加の検討が必要であることを意味します。

PGD では、レプリケートされた DDL によって参照されるロールがすべてのノードに存在する必要があります。ロールの付与、パスワードなどは同じである必要はありませんが、存在する必要があります。

bdr.role_replication が有効デフォルトであり、ロール操作ステートメントが PGD 対応データベースで実行されている場合、PGD はロール操作ステートメントをレプリケートします。

ロール操作ステートメントには次のものが含まれます。

- CREATE ROLE
- ALTER ROLE
- DROP ROLE
- GRANT ROLE
- CREATE USER
- ALTER USER
- DROP USER
- CREATE GROUP
- ALTER GROUP
- DROP GROUP

一般に、次のいずれかです。

- bdr.role_replication = off でシステムを構成し、Ansible、Puppet、Chef などの外部オーケストレーションツールまたは bdr.replicate_ddl_command(...) によって明示的にレプリケートされて、すべてのロール変更ユーザーとグループを展開します。
- PostgreSQL インスタンス上のちょうど 1 つの PGD 対応データベースが bdr.role_replication = on を持つようにシステムを構成し、そのデータベースですべてのロール管理 DDL を実行します。

すべてのロール管理コマンドを 1 つのデータベースで実行することをお勧めします。

ロールレプリケーションがオフになっている場合、管理者は、あるノードで DDL が使用するロールが他のノードにも存在することを確認する必要があります。それ以外の場合、PGD apply は、他のノードでロールが作成されるまで、エラーでストールします。

注釈: PGD は、PGD 対応の PostgreSQL インスタンスの非 PGD 対応データベースで実行される場合、ロール管理ステートメントをキャプチャおよびレプリケートしません。たとえば、DB 'bdrdb' bdr グループメンバーと'postgres' ベア db、および `bdr.role_replication = on` がある場合、 *bdrdb* で実行される `CREATE USER` はレプリケートされますが、 *postgres* で実行される `CREATE USER` はレプリケートされません。

制限され DDL の回避策

PGD DDL オペレーション処理の制限の一部は回避できます。多くの場合、操作をより小さな変更に分割すると、単一のステートメントとして許可されないか、過剰なロックが必要な目的の結果が生成される場合があります。

コンストレインの追加

DML ロックを必要とせずに CHECK および FOREIGN KEY 制約を追加できます。これには、2 段階のプロセスが含まれます。

- ALTER TABLE ... ADD CONSTRAINT ... NOT VALID
- ALTER TABLE ... VALIDATE CONSTRAINT

2 つの異なるトランザクションでこれらの手順を実行します。これらの手順は両方とも、テーブルでのみ DDL ロックを取得するため、1 つ以上のノードがダウンしている場合でも実行できます。ただし、コンストレインを検証するには、PGD は次のことを確認する必要があります。

- クラスター内のすべてのノードは ADD CONSTRAINT コマンドを参照します。
- コンストレインを検証するノードは、これらのノードに NOT VALID コンストレインを作成する前に、他のすべてのノードからレプリケーション変更を適用します。

したがって、新しいメカニズムでは、制約の検証中にすべてのノードがアップしている必要はありませんが、すべてのノードが ALTER TABLE .. ADD CONSTRAINT ... NOT VALID コマンドを適用し、十分に進行していることは必要です。PGD は、コンストレインを検証する前に、一貫した状態に到達するのを待機します。

新しい機能では、クラスターが Raft プロトコルバージョン 24 以降で実行されている必要があります。Raft プロトコルがまだアップグレードされていない場合、古いメカニズムが使用され、DML ロック要求が発生します。

列の追加

揮発性のデフォルトを使用して列を追加するには、別のトランザクションで次のコマンドを実行します。

```
ALTER TABLE mytable ADD COLUMN newcolumn coltype; -- Note the lack of DEFAULT or NOT␣
↪NULL

ALTER TABLE mytable ALTER COLUMN newcolumn DEFAULT volatile-expression;

BEGIN;
SELECT bdr.global_lock_table(mytable);
UPDATE mytable SET newcolumn = default-expression;
COMMIT;
```

このアプローチでは、スキーマの変更と行の変更を PGD が実行できる別のトランザクションに分割し、PGD グループ内のすべてのノードで一貫したデータが得られます。

最良の結果を得るには、更新をチャンクにバッチ処理して、一度に数万〜数十万行を更新しないようにします。これは、埋め込みトランザクションで PROCEDURE を使用して行うことができます。

変更の最後のバッチは、テーブルのグローバル DML ロックを取得するトランザクションで実行する必要があります。そうしないと、他のノードのテーブルに同時に挿入される行を見逃す可能性があります。

必要に応じて、UPDATE が完了した後、ALTER TABLE mytable ALTER COLUMN newcolumn NOT NULL; を実行できます。

列のタイプの変更

列のタイプを変更すると、PostgreSQL がテーブルを書き換える場合があります。ただし、場合によっては、この書き換えを回避できる場合があります。例

```
CREATE TABLE foo (id BIGINT PRIMARY KEY, description VARCHAR(128));
ALTER TABLE foo ALTER COLUMN description TYPE VARCHAR(20);
```

制限をデータ型の変更ではなくテーブル制約にすることにより、テーブルのリライトを回避するようにこのステートメントをリライトできます。必要に応じて、後続のコマンドでコンストレインを検証して、長いロックを回避できます。

```
CREATE TABLE foo (id BIGINT PRIMARY KEY, description VARCHAR(128));
ALTER TABLE foo
  ALTER COLUMN description TYPE varchar,
  ADD CONSTRAINT description_length_limit CHECK (length(description) <= 20) NOT VALID;
ALTER TABLE foo VALIDATE CONSTRAINT description_length_limit;
```

検証が失敗した場合は、失敗した行のみを UPDATE できます。このテクニックは、 length() を使用するか、 scale() を使用して NUMERIC データ型を使用する TEXT および VARCHAR に使用できます。

列タイプを変更する一般的な場合、最初に目的のタイプの列を追加します。

```
ALTER TABLE mytable ADD COLUMN newcolumn newtype;
```

BEFORE INSERT OR UPDATE ON mytable FOR EACH ROW .. として定義されたトリガーを作成します。これは、テーブルへの新しい書き込みによって新しい列が自動的に更新されるように、NEW.newcolumn を NEW.oldcolumn に割り当てます。

UPDATE 埋め込みトランザクションで PROCEDURE を使用して、oldcolumn の値を newcolumn にコピーするバッチ内のテーブル。作業をバッチ処理することは、大きなテーブルの場合、レプリケーションラグを削減するのに役立ちます。ID の範囲または任意の方法で更新しても問題ありません。または、小さなテーブルの場合、1 パスでテーブル全体を更新できます。

CREATE INDEX ... 新しい列に必要なインデックス。ロック期間を短縮するために、各ノードで DDL レプリケーションを使用せずに個別に実行される CREATE INDEX ... CONCURRENTLY を使用するのが安全です。

ALTER 必要に応じて、NOT NULL および CHECK 制約を追加する列。

1. BEGIN トランザクション。
2. DROP 追加したトリガー。
3. ALTER TABLE 列に必要な DEFAULT を追加します。
4. DROP 古い列。

1.ALTER TABLE mytable RENAME COLUMN newcolumn TO oldcolumn .

1.COMMIT .

注釈: 列を削除するため、テーブルに依存するビュー、プロシージャなどを再作成する必要がある場合があります。列を削除する場合は、それを参照したすべてを再作成する必要があるため、注意してください。

他のタイプの変更

ALTER TYPE ステートメントはレプリケートされますが、影響を受けるテーブルはロックされていません。

この DDL を使用する場合、新しいタイプを使用する前に、すべてのノードでステートメントが正常に実行されたことを確認してください。これは、bdr.wait_slot_confirm_lsn() ファンクションを使用して実現できます。

この例では、DML ステートメントで新しい値を使用する前に、DDL がすべてのノードに書き込まれるようにします。

```
ALTER TYPE contact_method ADD VALUE email;
SELECT bdr.wait_slot_confirm_lsn(NULL, NULL);
```

DDL のように動作する PGD ファンクション

次の PGD 管理機能は DDL のように動作します。これは、DDL レプリケーションがアクティブで、DDL フィルター設定で許可されている場合、グローバルロックを取得しようとし、アクションがレプリケートされることを意味します。詳細については、各機能のドキュメントを参照してください。

レプリケーションセット管理

- bdr.create_replication_set
- bdr.alter_replication_set
- bdr.drop_replication_set
- bdr.replication_set_add_table
- bdr.replication_set_remove_table
- bdr.replication_set_add_ddl_filter
- bdr.replication_set_remove_ddl_filter

競合管理

- bdr.alter_table_conflict_detection
- bdr.column_timestamps_enable
- bdr.column_timestamps_disable

シーケンス管理

- bdr.alter_sequence_set_kind

ストリームトリガー

- bdr.create_conflict_trigger
- bdr.create_transform_trigger
- bdr.drop_trigger

8.5 Security and roles

EDB Postgres Distributed を使用すると、デザインで保存されたデータへのアクセスを付与せずに PGD クラスターを管理できます。これは、ロールとシステムオブジェクトへの制御されたアクセスを使用して実現します。

- ロールとテーブルスペースの違いによるデータの競合 は、PGD 機能へのアクセスを制御するために PGD が事前定義するロールを導入します。
- *Role management* では、マルチデータベースノードと新しいノードでロールが管理される方法について説明します。
- *PGD predefined roles* は、 PGD ロールの特定の特権を詳細に説明します。
- *Roles and replication* は、PGD レプリケーションがロールおよび特権とどのように相互作用するかについて説明します。
- *Access Control* は、テーブル、ファンクション、カタログオブジェクト、トリガーが PGD ロールおよび Postgres 属性とどのように相互作用するかについて説明します。

8.5.1 Roles

PGD の構成と管理には、スーパーユーザーのアクセスは必要ありません。スーパーユーザーアクセスは使用しないことをお勧めします。代わりに、PGD の管理に必要な特権は、次の事前定義されたロールに分割されます。

ロール |説明 — | — **bdr_superuser** |すべての PGD テーブルとファンクションにアクセスする最高の特権ロール。**bdr_read_all_stats** | PGD の状態を理解するために十分な、テーブル、ビュー、およびファンクションへの読み取り専用アクセスを持つロール。**bdr_monitor** |現時点では、bdr_read_all_stats と同じです。後ほど延長します。 **bdr_application** | PGD を実行するアプリケーションに必要な最小限の特権。**bdr_read_all_conflicts** | *bdr.conflict_history* のすべての競合を表示できます。

これらのロールは、PostgreSQL の pg_ predefined roles に似た名前が付けられます。

PGD bdr_ ロールは、BDR 拡張機能のインストール時に作成されます。それぞれの権限の詳細については、PGD predefined roles を参照してください。

PGD の管理には、管理者がユーザーデータにアクセスする必要はありません。

競合を保護するための取り決めについては、

テーブルへの競合のロギング で説明されています。

bdr.conflict_history_summary ビューを使用して競合をモニタできます。

8.5.2 Role management

ユーザーは、PostgreSQL インスタンスのグローバルオブジェクトです。CREATE ROLE コマンドまたはそのエイリアス CREATE USER は、PGD レプリケートデータベースで実行される場合、自動的にレプリケートされます。ロールまたはユーザーが非 PGD、非レプリケートデータベースで作成された場合、ロールはその PostgreSQL インスタンスにのみ存在します。GRANT ROLE および DROP ROLE は同じように動作し、PGD レプリケートデータベースに適用される場合にのみレプリケートします。

注釈: Postgres 用語でのユーザーは、単にログイン権限を持つロールであることに注意してください。 !!!

ロールルール - 未複製のロールはありません

非 PGD の非レプリケートデータベースにロールまたはユーザーを作成する場合、PGD レプリケートデータベースのオブジェクトをそのロールに依存させないことが特に重要です。PGD は、PGD レプリケートデータベースにないロールをレプリケートできないため、レプリケーションプロセスが中断します。

bdr.role_replication 設定をオフにすることにより、この自動レプリケーション動作を無効にできますが、それはお勧めしません。

新しいノードのロール

bdr_init_physical を使用して追加された新しい PGD ノードは、PGD クラスターの他のノードからロールを自動的にレプリケートします。

bdr_init_physical を使用せずに PGD ノードが PGD グループに手動で参加している場合、既存のロールは新しく参加したノードにコピーされません。これは、アクセスが誤って付与されないようにするための意図的な動作です。

デフォルトでは、ロールはすべてのデータベースにアクセスします。したがって、新しく作成されたノードにユーザーを自動的にコピーすると、ノードに存在するデータベースが意図せずに公開される可能性があります。PGD クラスターにユーザー Alice があり、Alice が新しく参加したノードで自動的に作成された場合、そのノードに直接接続することにより、Alice はそのノード上のすべてのデータベースにアクセスできます。したがって、PGD は既存のロールをコピーしません。この状況では、ロールを手動でコピーすることをお勧めします。

PostgreSQL では、次のコマンドですべてのロールをダンプできます。

```
pg_dumpall --roles-only > roles.sql
```

次に、新しく作成したノードでファイルのコマンドを実行する前に、ファイル `roles.sql` を編集して不要なユーザーを削除できます。

新しいノードに参加する場合、「非複製ロールなし」ルールも適用されます。レプリケートされるデータベース内のオブジェクトが、レプリケートされていないローカルデータベースの非レプリケートロールに依存している場合、そのオブジェクトをレプリケートしようとすると、結合は失敗します。

接続とロール

新しい PGD ノードを割り当てるときに、 *bdr.create_node* の `local_dsn` 引数と *bdr.join_node_group* の `join_target_dsn` の DSN で指定されたユーザー

データベースオブジェクトを参照、作成、および管理するために頻繁に使用されます。

PGD は、これらの DSN で `SUPERUSER` 権限を持つロールを使用する場合でも、特権エスカレーション攻撃を防ぐように注意深く書き込まれています。

攻撃対象領域をさらに削減するために、これらの DSN でより制限されたユーザーを指定できます。少なくとも、このようなユーザーには、次の条件が満たされるように、すべてのノードで権限を付与する必要があります。

- ユーザは `REPLICATION` 属性を持っています。
- データベースに対する `CREATE` 権限が付与されています。
- bdr_superuser ロールを継承します。
- 複製するすべてのデータベースオブジェクトを直接、または所有者ロールの権限から所有します。

すべてのノードが参加したら、DML および DDL レプリケーションを引き続き許可するには、権限をさらに次まで減らすことができます。

- ユーザは `REPLICATION` 属性を持っています。
- bdr_superuser ロールを継承します。

8.5.3 PGD predefined roles

PGD の事前定義されたロールは、BDR 拡張機能のインストール時に作成されます。BDR 拡張機能がデータベースから削除された後、ロールは存在し続けます。ドロップが必要な場合は、手動でドロップする必要があります。この実践により、PGD を同じ PostgreSQL インスタンス上の複数のデータベースで問題なく使用できます。

`GRANT ROLE` DDL ステートメントは、PGD レプリケーションに参加しません。したがって、クラスターの各ノードでこれを実行します。

bdr_superuser

- スキーマ BDR のすべてのテーブルのすべての特権
- スキーマ BDR のすべてのルーチンのすべての特権

bdr_read_all_stats

以下の SELECT 特権

- *bdr.conflict_history_summary*
- *bdr.ddl_epoch*
- *bdr.ddl_replication*
- *bdr.global_consensus_journal_details*
- *bdr.global_lock*
- *bdr.global_locks*
- *bdr.local_consensus_state*
- *bdr.local_node_summary*
- *bdr.node_config*
- *bdr.node_catchup_info*
- *bdr.node_conflict_resolvers*
- *bdr.node_group_config*
- *bdr.node_local_info*
- *bdr.node_peer_progress*
- *bdr.node_slots*
- *bdr.node_summary*
- *bdr.replication_sets*
- *bdr.sequences*
- *bdr.stat_relation*
- *bdr.stat_subscription*
- *bdr.subscription*
- *bdr.subscription_summary*
- *bdr.tables*

以下の EXECUTE 特権

- *bdr.bdr_version*

- *bdr.bdr_version_num*
- *bdr.decode_message_payload*
- *bdr.get_global_locks*
- *bdr.get_raft_status*
- *bdr.get_relation_stats*
- *bdr.get_slot_flush_timestamp*
- bdr.get_sub_progress_timestamp
- *bdr.get_subscription_stats*
- *bdr.peer_state_name*
- *bdr.show_subscription_status*

bdr_monitor

bdr_read_all_stats からのすべての特権。

また、次の EXECUTE 特権

- *bdr.monitor_group_versions*
- *bdr.monitor_group_raft*
- *bdr.monitor_local_replslots*

bdr_application

以下の EXECUTE 特権

- column_timestamps データ型のすべてのファンクション
- CRDT データ型のすべてのファンクション
- *bdr.alter_sequence_set_kind*
- *bdr.create_conflict_trigger*
- *bdr.create_transform_trigger*
- *bdr.drop_trigger*
- bdr.get_configured_camo_partner
- *bdr.global_lock_table*
- bdr.is_camo_partner_connected
- bdr.is_camo_partner_ready
- bdr.logical_transaction_status

- bdr.ri_fkey_trigger
- *bdr.seq_nextval*
- bdr.seq_currval
- bdr.seq_lastval
- *bdr.trigger_get_committs*
- *bdr.trigger_get_conflict_type*
- *bdr.trigger_get_origin_node_id*
- *bdr.trigger_get_row*
- *bdr.trigger_get_type*
- *bdr.trigger_get_xid*
- bdr.wait_for_camo_partner_queue
- *bdr.wait_slot_confirm_lsn*

これらの機能の多くは、使用する前に追加の特権を必要とします。たとえば、bdr.alter_sequence_set_kind を正常に実行するには、テーブルの所有者である必要があります。これらの追加ルールは、特定の機能ごとに説明します。

bdr_read_all_conflicts

PGD は競合を *bdr.conflict_history* にログ記録します

テーブル。競合はテーブルの所有者にのみ可視されるため、競合履歴を読み取るために追加の特権は必要ありません。すべてのテーブルの競合を表示できるユーザーが便利な場合は、オプションでそのユーザーに bdr_read_all_conflicts ロールを付与できます。

8.5.4 Roles and replication

DDL および DML レプリケーションとユーザー

ユーザーが実行した DDL 変更は、各ノードでその同じユーザーとして適用されます。

テーブルへの DML 変更は、ターゲットノード上のテーブル所有ユーザーとして複製されます。

デフォルトでは、PGD はノード全体に同じ所有者で新しいテーブルをレプリケートします。

異なるテーブルの所有権

そのテーブルは、各ノードで同じユーザーが所有することをお勧めします。これはデフォルトの動作ですが、オーバーライドできます。その場合、考慮すべきことがいくつかあります。

テーブル A がノード 1 のユーザー X が所有し、ノード 2 のユーザー Y が所有している状況を考えます。ユーザー Y がユーザー X よりも高い特権を持っている場合、これは特権エスカレーションと見なされる場合があります。

ノードにはさまざまなユースケースがある可能性があるため、このシナリオを許可します。しかし、私たちはそれに対して警告します。テーブルの所有者が異なるノードに異なる場合、セキュリティ管理者にこの構成の計画と監査を手伝ってもらうことをお勧めします。

レプリケーションと行レベルのセキュリティ

行レベルのセキュリティポリシーが有効になっているテーブルでは、適用時にポリシーを強化せずに変更がレプリケートされます。この動作は、`FORCE ROW LEVEL SECURITY` が指定されている場合でも、`NO FORCE ROW LEVEL SECURITY` として適用される変更と同等です。これは希望するものでない場合は、すべての行のレプリケートを回避する row_filter を指定します。すべてのノードの行セキュリティポリシーが同一または少なくとも互換性があることをお勧めしますが、強制はしません。

bdr_superuser のロールとレプリケーション

ユーザー bdr_superuser は、PGD のレプリケーションを制御し、レプリケーションセットから任意のテーブルを追加または削除できます。bdr_superuser は、個々のテーブルに対する特権を必要とせず、お勧めしません。レプリケーションセットファンクションへのアクセスを制限する必要がある場合は、これらのファンクションの制限バージョンを `SECURITY DEFINER` ファンクションとして実装し、適切なユーザーに付与できます。

特権制限

PGD は追加の制限を適用し、TRIGGER または REFERENCES 特権のみに依存する DDL の使用を効果的に防止します。

`GRANT ALL` は引き続き TRIGGER と REFERENCES 特権の両方を付与するため、特権を明示的に記述することをお勧めします。たとえば、`ALL` の代わりに `GRANT SELECT, INSERT, UPDATE, DELETE, TRUNCATE` を使用します。

外部キー特権

`ALTER TABLE ... ADD FOREIGN KEY` は、ユーザーが参照されるテーブルに対する SELECT 特権を持っている場合、または参照先テーブルで現在のユーザーがバイパスできない RLS 制限が有効になっている場合にのみサポートされます。

これは、REFERENCES 特権だけでは PGD で外部キーを作成するのに十分でないことを意味します。REFERENCES 特権のみに依存すると、テーブルスキャンではなくトリガーを使用して検証チェックが実行されるため、通常は役立ちません。通常、コストが高すぎるため、正常に使用できません。

8.5.5 Access Control

カタログテーブル

システムカタログと情報スキーマテーブルは、PGD によってレプリケーションから常に除外されます。

さらに、拡張機能が所有するテーブルはレプリケーションから除外されます。

PGD ファンクションと演算子

すべての PGD ファンクションは `bdr` スキーマで公開されています。これらのファンクションへの呼び出しは、search_path に `bdr` を配置するのではなく、スキーマ修飾する必要があります。

すべての PGD 演算子は `pg_catalog` スキーマを介して使用できるため、ユーザーは search_path から `public` スキーマを問題なく除外できます。

カタログオブジェクトに対する特権の付与

管理者は、テーブル、ビュー、ファンクションなどのカタログオブジェクトに対する明示的な特権を付与してはなりません。

PGD default roles で説明されているロールのいずれかを付与して、これらのオブジェクトへのアクセスを管理します。

この要件は、結合のどちらの側のノードも全く同じバージョンの PGD、したがって PGD カタログを持たない場合でも、ノードグループに参加できる柔軟性の結果です。

より正確には、個々のカタログオブジェクトの特権が明示的に付与された場合、参加するノードから抽出された対応する GRANT ステートメントが参加しているノードに適用されない可能性があるため、`bdr.join_node_group()` プロシージャーは失敗する可能性があります。

トリガー

PostgreSQL では、テーブルの所有者と TRIGGER 特権を付与された人は誰でもトリガーを作成できます。非テーブル所有者によって付与されたトリガーは、PGD でテーブル所有者として実行されます。これは、セキュリティ問題を発生させる可能性があります。TRIGGER 特権はめったに使用されず、PostgreSQL コアチームは、「個別の TRIGGER 権限は時代遅れだと考えられるものです。」と述べています。

PGD は、テーブルにトリガーを作成できる人に関するより厳密なルールを使用することにより、この問題を緩和します。

- スーパーユーザー トリガーを作成できます。
- bdr_superuser トリガーを作成できます。
- テーブルの所有者 PostgreSQL と同じルールに従ってトリガーを作成できます。トリガーによって使用されるファンクションの EXECUTE 特権が必要です。
- テーブルに対する TRIGGER 特権を持つユーザーテーブルと同じ所有者が所有するファンクションを使用し、標準の PostgreSQL ルールを満たす場合にのみトリガーを作成できます。具体的には、ファンクションに対する EXECUTE 特権が必要です。テーブルとファンクションの両方の所有者が同じで、所有者がユーザーにテーブルの TRIGGER 特権とファンクションの EXECUTE 特権の両方を付与することにした場合。そのユーザーがこのファンクションを使用してそのテーブルにトリガーを作成してもよいと想定されています。
- テーブルの TRIGGER 権限を持つユーザー EXECUTE 権限がある場合、SECURITY DEFINER clause で定義されたファンクションを使用してトリガーを作成することもできます。SECURITY DEFINER 句により、ファンクションは常に標準の PostgreSQL と PGD の両方でファンクションの所有者として実行されます。

このロジックは、PostgreSQL では、トリガーの所有者がそれを作成したユーザーではなく、そのトリガーが使用するファンクションの所有者であるという事実に基づいて構築されています。

同じルールが既存のテーブルに適用され、既存のテーブルに、テーブルの所有者が所有せず、SECURITY DEFINER ファンクションを使用しないトリガーがある場合、レプリケーションセットに追加することはできません。

PGD レプリケーションは変更を適用する場合、システムレベルのデフォルトの search_path のみを使用します。他の search_path 設定を想定しているレプリカトリガー、ストリームトリガー、およびインデックス式ファンクションは、適用時に実行すると失敗します。これが発生しないようにするには、デフォルトの search_path のみを使用してオブジェクト参照を明確に解決するか、影響を受けるファンクションに `ALTER FUNCTION ... SET search_path = ...` を使用してファンクションの検索パスを設定します。デフォルトの search_path を使用する場合、schema.objectname などのオブジェクトへの完全修飾参照を常に使用します。

8.6 Sequences

多くのアプリケーションでは、一意のサロゲート ID をデータベースエントリに割り当てる必要があります。多くの場合、データベース SEQUENCE オブジェクトはこれらを生成するために使用されます。PostgreSQL では、これらは次のいずれかです。

- CREATE SEQUENCE コマンドを使用して手動で作成し、nextval() ファンクションを呼び出して取得したシーケンス
- serial および bigserial 列または GENERATED BY DEFAULT AS IDENTITY 列

ただし、PostgreSQL の標準シーケンスはマルチノード対応ではなく、ローカルノードでのみ一意の値を生成します。このようなシーケンスによって生成された一意の ID は、マルチマスターレプリケーションで破棄された INSERT アクションによる競合とデータ損失を発生させるため、これは重要です。

8.6.1 PGD グローバルシーケンス

このため、 PGD は、 **グローバルシーケンス** と呼ばれる、PGD グループ全体の bigint または bigserial データ型のシーケンスを使用して、一意の ID を生成するアプリケーション透過的な方法を提供します。

PGD グローバルシーケンスは、アプリケーションがデータベースを使用して、ほとんどの場合に機能する非同期分散システムで一意の合成キーを生成する簡単な方法を提供しますが、必ずしもすべての場合ではありません。

PGD グローバルシーケンスを使用すると、挿入の競合に関する問題を回避できます。グローバルシーケンスを使用している列に PRIMARY KEY または UNIQUE 制約を定義すると、ノードは他のノードと同じ値を取得できません。PGD がノード間で挿入を同期すると、競合することはできません。

PGD グローバルシーケンスは PostgreSQL シーケンスを拡張するため、クラッシュセーフです。これらを使用するには、bdr_application ロールを付与される必要があります。

グローバルシーケンスにはさまざまなアルゴリズムが考えられます。

- SnowflakeId シーケンス
- グローバルに割り当てられたレンジシーケンス

SnowflakeId シーケンスは、どの時点でもノード間通信を必要としないアルゴリズムを使用して値を生成します。より速く、より堅牢で、値が作成されたときにタイムスタンプを記録する便利な特性があります。

SnowflakeId シーケンスには、64 ビット BIGINT データ型でのみ動作し、最大 19 桁長の値を生成するという制限があります。これは、Javascript 整数型などの一部のホスト言語データ型で使用するには長すぎる場合があります。グローバルに割り当てられたシーケンスは、ノード間コンセンサスによって必要に応じて補充できるローカルな値の範囲を割り当て、BIGINT または INTEGER シーケンスに適しています。

bdr.alter_sequence_set_kind() を使用してグローバルシーケンスを作成できます

ファンクション。このファンクションは、標準の PostgreSQL シーケンスを取得し、PGD グローバルシーケンスとしてマークします。シーケンスを標準の PostgreSQL シーケンスに変換して戻すこともできます。

PGD は、構成変数 *bdr.default_sequence_kind* も提供します。これは、 `CREATE SEQUENCE` コマンドが実行されたとき、または `serial` 、`bigserial` 、または `GENERATED BY DEFAULT AS IDENTITY` 列が作成されたときに作成するシーケンスの種類を決定します。有効な設定は次のとおりです。

- `local` 、新しく作成されたシーケンスが標準の PostgreSQL ローカルシーケンスであることを意味します。
- `galloc` 、常にグローバルに割り当てられたレンジシーケンスを作成します。
- `snowflakeid` 、時間、ノード ID、およびカウンターコンポーネントで構成される BIGINT シーケンスのグローバルシーケンスを作成します。INTEGER シーケンスでは使用できませんので、 `bigserial` には使用できますが、 `serial` には使用できません。
- `timeshard` 、これは SnowflakeId シーケンスの古いバージョンであり、下位互換性のためのみに提供されています。SnowflakeId が優先されます。
- `distributed` デフォルト。これは、*bdr.default_sequence_kind* にのみ使用できる特別な値です。 `int8` シーケンスつまり `bigserial` の場合は `snowflakeid` を選択し、`int4` つまり `serial` および `int2` シーケンスの場合は `galloc` シーケンスを選択します。

  bdr.sequences ビューには、個々のシーケンス種類に関する情報が表示されます。

`currval()` および `lastval()` は、すべてのタイプのグローバルシーケンスで正しく動作します。

SnowflakeId シーケンス

SnowflakeId シーケンスによって生成された ID は、緩やかな時間順序であるため、これらを使用して、標準の PostgreSQL シーケンスのように、データ挿入のおおよその順序を取得できます。1 つのノードでも、同じミリ秒以内に生成された値は順序が崩れる場合があります。緩い時間順序付けの特性は、レンジパーティションキーとしての使用に適していることを意味します。

SnowflakeId シーケンスは 1 つ以上のノードで動作し、ノード参加プロセスが完了した後にノード間通信を必要としません。したがって、拡張ネットワーク分割のリスクがある場合でも、それらを使用し続けることができます。これらは、レプリケーション遅延やノード間レイテンシーの影響を受けません。

SnowflakeId シーケンスは、標準のシーケンスとは異なる方法で一意の ID を生成します。このアルゴリズムは、シーケンス番号に 3 つのコンポーネントを使用します。シーケンスの最初のコンポーネントは、シーケンス番号生成時のタイムスタンプです。シーケンス番号の 2 番目のコンポーネントは、各 PGD ノードに割り当てられる一意の ID であり、これにより、異なるノードからの ID が常に異なることが保証されます。3 番目の成分は、ローカルシーケンスによって生成された数です。

競合がないことを保証には一意のノード ID をシーケンス番号に追加するだけで十分ですが、シーケンスの別の便利なプロパティも保持したいと思います。シーケンス番号の順序は、データがテーブルに挿入された順序にほぼ対応します。最初にタイムスタンプを配置することにより、これが保証されます。

SnowflakeId シーケンスには、いくつかの制限と注意事項が適用されます。

SnowflakeId シーケンスは 64 ビット幅で、`bigint` または `bigserial` が必要です。生成される値は最大 19 桁の長さです。実用的な 32 ビット `integer` バージョンがないため、 `serial` シーケンスでは使用できません。代わりに、グローバルに割り当てられたレンジシーケンスを使用します。

SnowflakeId の場合、特定のノードでミリ秒ごとに生成されるシーケンス値 4096 の制限があります 1 秒あたり約 400 万シーケンス値。シーケンス値の生成が特定のミリ秒内でラップアラウンドする場合、SnowflakeId シーケンスは次のミリ秒まで待機し、そのミリ秒の新しい値を取得します。

SnowflakeId シーケンスはタイムスタンプをシーケンス値にエンコードするため、指定された時間フレーム内でのみ新しいシーケンス値を生成できますシステムクロックによって異なります。使用できる最も古いタイムスタンプは 2016-10-07 で、これは SnowflakeId のエポック時間です。値は 2086 年に負の値にラップし、2156 年までに数値が完全になくなります。

タイムスタンプは SnowflakeId シーケンスの重要な部分であるため、Postgres プロセスの有効期間中に使用される最新のタイムスタンプより古いシーケンスを生成しないための追加の保護がありますただし、Postgres の再起動の間ではありません。

SnowflakeId シーケンスの入力として使用されるシーケンスの `INCREMENT` オプションは、事実上無視されます。これは、多くのオブジェクトリレーショナルマッパー ORM ツール、特に Hibernate と同様に、シーケンス ID キャッシュを行うアプリケーションに関連する可能性があります。シーケンスは時間ベースであるため、アプリケーションがキャッシュされた値で何かをできるようになるまでにシーケンスは新しい非衝突値に進むため、実際的な効果はほとんどありません。

同様に、基になるシーケンスの `START` 、`MINVALUE` 、`MAXVALUE` 、および `CACHE` 設定を変更することもできますが、変更するメリットはありません。シーケンスの下位 14 ビットが使用され、残りは破棄されるため、値範囲制限はファンクションの結果に影響を与えません。同じ理由で、`setval()` は SnowflakeId シーケンスには役立ちません。

タイムシャードシーケンス

タイムシャードシーケンスは、既存のインストールとの下位互換性のために提供されていますが、新しいアプリケーションの使用はお勧めしません。代わりに SnowflakeId シーケンスを使用することをお勧めします。

Timeshard は SnowflakeId に非常に似ていますが、制限が異なり、保護が少なく、パフォーマンスが低下します。

Timeshard と SnowflakeId の違いは次のとおりです。

- Timeshard は、ミリ秒ごとに最大 16384 秒ごとに約 1600 万を生成できます。これは、SnowflakeId を超えています。ただし、特定のミリ秒内のラップアラウンドに対する保護はありません。Timeshard シーケンスを使用するスキーマは、特定の列に timeshard 値を使用する場合、`UNIQUE` 制約の使用を保護する必要があります。 - Timeshard シーケンスのタイムスタンプコンポーネントは、2050 年に値がなくなり、bigint と組み合わせて使用すると、値は 2033 年に負の数にラップします。これは、2033 年以降に生成されたシーケンスが負の値を持つことを意味します。これは SnowflakeId よりもかなり短い時間であり、これが SnowflakeId が優先される主な理由です。- Timeshard シーケンスは、時折のディスク書き込みが必要です標準のローカルシーケンスと同様に。SnowflakeId はメモリで計算されるため、SnowflakeId シーケンスは、一般に timeshard シーケンスよりも少し高速です。

グローバルに割り当てられたレンジシーケンス

グローバルに割り当てられたレンジまたは galloc シーケンスは、値のレンジチャンクを各ノードに割り当てます。ローカルレンジが使い果たされると、他のノード間のコンセンサスによって、新しいレンジがグローバルに割り当てられます。これは、キー空間を効率的に使用しますが、現在割り当てられているローカルレンジが使い果たされたときにシーケンスジェネレーターが進行するには、ローカルノードがクラスター内のノードの大部分に接続している必要があります。

SnowflakeId シーケンスとは異なり、galloc シーケンスは、PostgreSQL が提供するすべてのシーケンスデータ型 smallint 、integer 、および bigint をサポートします。これは、64 ビットシーケンスに問題がある環境で galloc シーケンスを使用できることを意味します。例には、53 ビット値のみをサポートしているため、またはシーケンスが制限されたスペースで出力に表示される場合、JavaScript での整数の使用が含まれます。

各投票によって割り当てられる範囲は、シーケンスが使用しているデータ型に基づいて、現在事前に決定されています。

- smallint — 1 000 数字
- 整数 — 1 000 000 番号
- bigint — 1 000 000 000 数字

各ノードは seq_chunk_size の 2 つのチャンク、現在の使用用に 1 つと将来の使用のために予約されたチャンクを割り当てるため、1 つのノードから生成される値は単調増加します。ただし、グローバルに見ると、生成された値はまったく順序付けられていません。これは、b ツリーインデックスへの影響によりパフォーマンスの低下を引き起こす可能性があり、通常は、生成された値がレンジパーティションキーとして役に立たないことを意味します。

galloc シーケンスの主な欠点は、割り当てられたレンジが使い果たされると、シーケンスジェネレーターがノード間通信を必要とするローカルノードの次のレンジに関するコンセンサスを求めなければならないことです。これにより、PGD グループの大部分がアクセスできない場合、遅延または操作の問題が発生する可能性があります。(これは、後のリリースで回避される可能性があります。)

CACHE 、START 、MINVALUE 、および MAXVALUE オプションは、galloc シーケンスで正常に動作します。ただし、シーケンスを galloc 種類に変換する前に、それらを設定する必要があります。 INCREMENT BY オプションも正常に動作します。ただし、各シーケンスデータ型に割り当てられた上記の範囲以上の増分値を割り当てることはできません。setval() は、galloc シーケンスのグローバル状態をリセットしません。使用しないでください。

galloc シーケンスには、いくつかの制限が適用されます。PGD は、特別な PGD カタログ *bdr.sequence_alloc* の galloc シーケンスを追跡します。このカタログは、galloc シーケンスに現在割り当てられているチャンクを追跡するために必要です。シーケンス名と名前空間はこのカタログに保存されます。シーケンスチャンクの割り当ては Raft によって管理され、シーケンス名前/名前空間の変更はレプリケーションストリームによって管理されるため、PGD は現在 galloc シーケンスの名前の変更、別の名前空間への移動、または galloc シーケンスを含む名前空間の名前の変更をサポートしていません。アプリケーションスキーマをデザインするときは、この制限に注意してください。

ローカルシーケンスの galloc シーケンスへの変換

ローカルシーケンスを galloc に変換する前に、いくつかの前提条件に注意する必要があります。

1. シーケンスと列のデータ型が一致することを確認します

シーケンスのデータ型が、使用される列のデータ型と一致することを確認します。たとえば、bigint シーケンスを作成し、 integer 列のデフォルトをそのシーケンスによって返される nextval() に割り当てることができます。 bigint の場合 1 000 000 000 のブロックで割り当てられる galloc シーケンスでは、3 つ以上のノードが使用されている場合、nextval() によって返される値がすぐに int4 範囲を超えます。

次の例は、何が起こるかを示しています。

```
CREATE SEQUENCE int8_seq;

SELECT sequencename, data_type FROM pg_sequences;
 sequencename | data_type
- -------------+-----------
 int8_seq     | bigint
(1 row)

CREATE TABLE seqtest (id INT NOT NULL PRIMARY KEY);

ALTER SEQUENCE int8_seq OWNED BY seqtest.id;

SELECT bdr.alter_sequence_set_kind(public.int8_seq::regclass, galloc, 1);
 alter_sequence_set_kind
- ------------------------

(1 row)

ALTER TABLE seqtest ALTER COLUMN id SET DEFAULT nextval(int8_seq::regclass);
```

2 つのノードで INSERT INTO seqtest VALUES(DEFAULT) を実行した後、テーブルには次の値が含まれます。

```
SELECT * FROM seqtest;
     id
- -----------
          2
 2000000002
(2 rows)
```

ただし、3 番目のノードで同じ操作を試行すると、シーケンスが値 4000000002 を生成したため、integer out of range エラーで失敗します。

Tip: PostgreSQL からシーケンスの現在のデータ型を取得できます *pg_sequences* ビュー。現在の値が新しいデータ型の最大値を超えない限り、`ALTER SEQUENCE ... AS ...` たとえば `ALTER SEQUENCE public.sequence AS integer` を使用してシーケンスのデータ型を変更できます。

2. シーケンスの新しい開始値を設定します

シーケンス種類が `galloc` に変更されると、書き換えられ、ローカルシーケンスの定義された開始値からリスタートします。これが実稼働データベースの既存のシーケンスで発生した場合、現在の値を照会し、開始値を適切に設定する必要があります。このユースケースを支援するために、PGD では、ユーザーがファンクション

bdr.alter_sequence_set_kind()

で開始値を渡すことができます。既にオフセットを使用しており、複数のノードからの書き込みがある場合は、最大使用値を確認し、少なくとも次の値までシーケンスをリスタートする必要があります。

```
- - determine highest sequence value across all nodes
SELECT max((x->response->command_tuples->0->>nextval)::bigint)
    FROM json_array_elements(
        bdr.run_on_all_nodes(
            ESELECT nextval(\public.sequence\);
            )::jsonb AS x;

- - turn into a galloc sequence
SELECT bdr.alter_sequence_set_kind(public.sequence::regclass, galloc, $MAX + $MARGIN);
```

ユーザーはシーケンスをロックできないため、 `$MARGIN` 値を残して、`max()` 値が照会されている間操作を続行できるようにする必要があります。

bdr.sequence_alloc テーブルは、チャンクサイズと、クラスター全体に割り当てられた範囲に関する情報を提供します。

この例では、シーケンスは 333 で始まり、クラスターには 2 つのノードがあります。割り当て数は 4 で、ノードごとに 2 であり、チャンクサイズは 1000000 で、整数シーケンスに関連しています。

```
SELECT * FROM bdr.sequence_alloc
    WHERE seqid = public.categories_category_seq::regclass;
          seqid          | seq_chunk_size | seq_allocated_up_to | seq_nallocs |      ␣
↪seq_last_alloc
- ------------------------+----------------+---------------------+-------------+------
↪-----------------------
 categories_category_seq |        1000000 |             4000333 |           4 | 2020-
↪05-21 20:02:15.957835+00
(1 row)
```

各ノードの特定のシーケンスに現在割り当てられている範囲を表示するには、次のクエリを使用します。

*ノード Node1 は、333 〜2000333 のレンジを使用しています。

```
SELECT last_value AS range_start, log_cnt AS range_end
    FROM categories_category_seq WHERE ctid = (0,2); -- first range
 range_start | range_end
- ------------+-----------
         334 |   1000333
(1 row)

SELECT last_value AS range_start, log_cnt AS range_end
    FROM categories_category_seq WHERE ctid = (0,3); -- second range
 range_start | range_end
- ------------+-----------
     1000334 |   2000333
(1 row)
```

*ノード Node2 は、2000004 〜4000003 のレンジを使用しています。

```
SELECT last_value AS range_start, log_cnt AS range_end
    FROM categories_category_seq WHERE ctid = (0,2); -- first range
 range_start | range_end
- ------------+-----------
     2000334 |   3000333
(1 row)

SELECT last_value AS range_start, log_cnt AS range_end
    FROM categories_category_seq WHERE ctid = (0,3); -- second range
 range_start | range_end
- ------------+-----------
     3000334 |   4000333
```

注釈: 最初の範囲のみが表示されるため、単一のクエリー `WHERE ctid IN ('(0,2)', '(0,3)')` のようなクエリーと組み合わせることはできません。

ノードはチャンクを終了すると、新しいチャンクのコンセンサスを求め、最初に利用可能なものを取得します。この例では、4000334〜5000333 です。これは新しい予約チャンクであり、古い予約チャンクの消費を開始します。

8.6.2 UUID、KSUUID、およびその他のアプローチ

PGD で使用できるグローバルシーケンスを使用せずに、他の方法でグローバルに一意の ID を生成できます。例

- UUID とその PGD バリアント KSUUID
- ノードごとに異なるオフセットを持つローカルシーケンスつまり手動
- 外部調整されたナチュラルキー

PGD アプリケーションは他の方法を安全に使用できません。PGD はノード間で行ロックを取得しないため、シーケンス生成で `SELECT ... FOR UPDATE`、`UPDATE ... RETURNING ...` または同様のものに依存するカウンタテーブルベースのアプローチは、PGD では正しく機能しません。同じ値が複数のノードで生成されます。同じ理由で、「ギャップレス」シーケンス生成の通常の戦略は PGD では機能しません。ほとんどの場合、アプリケーションは、2 フェーズコミットを使用して外部ソースからギャップレスである必要があるシーケンスの生成を調整します。または、PGD グループ内の 1 つのノードでのみ生成されます。

UUID

`UUID` キーは、代わりにシーケンスを完全に回避し、128 ビットのユニバーサル一意識別子を使用します。これらはランダムまたは擬似乱数値であり、非常に大きいため、同じ値を 2 回生成することはほぼ不可能です。`UUID` キーを使用する場合、ノードが継続的に通信する必要はありません。

万が一、衝突が発生した場合、競合検出は、挿入された 2 つのレコードの新しい方を選択して保持します。競合ログが有効になっている場合、このようなイベントが記録されます。ただし、約 2^64 キーが生成された後にのみ衝突が実際に可能になるため、発生する可能性は非常に低いです。

`UUID` キーの主な欠点は、領域とネットワークの点でやや非効率であることです。これらは、主キーとしてだけでなく、外部キーで参照される場合、および回線上で送信される場合にも、より多くの領域を消費します。また、すべてのアプリケーションが `UUID` キーにうまく対応できるわけではありません。

KSUUID

PGD は、KSUUID として知られる `UUID` データの K-Sortable バリアントを操作するためのファンクションを提供し、PostgreSQL 標準の `UUID` データ型を使用して保存できる値を生成します。 `KSUUID` 値は、 `UUID` 標準に従って、タイムスタンプとランダムデータの両方を保存するという点で `UUIDv1` に似ています。違いは、 `KSUUID` が K-Sortable であること、つまりタイムスタンプで弱くソート可能であることです。これにより、よりコンパクトな `btree` インデックスを生成するため、データベースキーとしてより役立ちます。これにより、検索の効率が向上し、結果データの自然な時間ソートが可能になります。`UUIDv1` とは異なり、`KSUUID` 値には、生成されたコンピューターの MAC が含まれないため、それらの使用にセキュリティ上の懸念はありません。

あらゆる場合に `KSUUID` v2 を推奨するようになりました。通常の比較演算子で生成された値を直接並べ替えることができます。

PGD には `KSUUID` の 2 つのバージョン v1 および v2 があります。古い `KSUUID` v1 は非推奨ですが、既存のインストールをサポートするために維持されます。新しいインストールには使用しないでください。v1 と

v2 の内部コンテンツには互換性がありません。そのため、それらを操作する機能も互換性がありません。KSUUID の v2 も、UUID バージョン番号を保存しなくなりました。

PGD リファレンスの *KSUUID v2* **ファンクション** および *KSUUID v1* **ファンクション** を参照してください。

ステップシーケンスとオフセットシーケンス

オフセットステップシーケンスでは、各ノードで通常の PostgreSQL シーケンスが使用されます。各シーケンスは同じ量だけインクリメントし、異なるオフセットで開始します。たとえば、ステップ 1000 では、ノード 1 のシーケンスは 1001、2001、3001 などを生成します。node2 のシーケンスは、1002、2002、3002 などを生成します。このスキームは、ノードが長期間通信できない場合でもうまく機能します。ただし、デザイナーはスキーマを確立するときにノードの最大数を指定する必要があり、ノードごとの構成が必要です。間違いにより、シーケンスのオーバーラップが簡単に発生する可能性があります。

次のように 1 つのノードで目的のシーケンスを作成することにより、PGD でこのアプローチを構成するのは比較的簡単です。

```
CREATE TABLE some_table (
    generated_value bigint primary key
);

CREATE SEQUENCE some_seq INCREMENT 1000 OWNED BY some_table.generated_value;

ALTER TABLE some_table ALTER COLUMN generated_value SET DEFAULT nextval(some_seq);
```

次に、 setval() を呼び出す各ノードで、各ノードに異なるオフセット開始値を与えます。例

```
- - On node 1
SELECT setval(some_seq, 1);

- - On node 2
SELECT setval(some_seq, 2);

 -- ... etc
```

将来的に変更することは困難であり、中断を伴うため、追加するすべてのノードのための領域を残すように十分な大きさの INCREMENT を許可してください。

bigint 値を使用する場合、10000 以上のオフセットを使用する場合でも、キーの枯渇に関する実質的な懸念はありません。枯渇に近づく可能性があるまでには、数百のマシンが毎秒数百万の挿入を実行して、数百年かかります。

PGD は、現在、このようなステップ/オフセットシーケンスでノードごとのオフセットを構成するための自動化を提供していません。

複合キー

ステップ/オフセットシーケンスのバリアントは、`PRIMARY KEY (node_number, generated_value)` で構成される複合キーを使用することです。ここで、ノード番号は、通常、各ノードで異なる番号を返すファンクションから取得されます。DDL レプリケーションを一時的に無効にし、定数 SQL ファンクションを作成することにより、このようなファンクションを作成できます。または、レプリケーションセットの一部ではない 1 行テーブルを使用して、各ノードに異なる値を保存できます。

8.6.3 関連項目

- *Global sequence management interfaces*
- *KSUUID v2* ファンクション
- *KSUUID v1* ファンクション

8.7 Durability

8.7.1 概要

EDB Postgres 分散では、 **コミットスコープ**を使用して、耐久性、一貫性、可用性、およびパフォーマンスのニーズに基づいて、いくつかのレプリケーション構成から選択できます。

基本的な構成では、 EDB Postgres 分散は非同期レプリケーションを使用します。ただし、コミットスコープは、デフォルトとトランザクションごとの動作の両方を変更できます。ビルトインの物理または論理レプリケーションと同じ方法で、標準の `synchronous_standby_names` を使用して古い Postgres 同期レプリケーションを構成することもできます。ただし、コミットスコープは、レプリケーション動作の柔軟性と制御を提供します。

さまざまな同期設定は、関連しているがすべて個別に実装できるアプリケーションの 3 つのプロパティに影響を与えます。

- 耐久性複数のノードに書き込むと、クラッシュ耐性が向上し、クラッシュと再起動後にデータを復旧できます。
- 可視性クライアントへのコミット確認により、データベースは、一部のノードセットでコミットされたトランザクションの即時の可視性を保証します。
- 競合処理競合はコミット後に楽観的に処理でき、コミットタイムスタンプに基づいてトランザクションがレプリケートされるときに競合が解決されます。または、プリコミット時に悲観的に処理できます。クライアントは、最終的にすべてのノードに適用されるトランザクションに依存して、さらなる競合または中止を取得して、クライアントにエラーを直接通知できます。

コミットスコープでは、トランザクションの持続性を制御する 2 つの方法ができます。

- グループコミット。このオプションは、トランザクションがコミット可能であると考えられる前に、どのノードといくつのノードがコンセンサスに到達する必要があるか、およびレプリケーションのどの段階でコミットされたと考えられるかを制御します。このオプションを使用すると、トランザクションの可視性の順序を制御することもできます。

- *CAMO* またはコミット・アット・モスト・ワンス。このオプションは、クライアントがコンセンサスに参加するグループコミットのバリアントです。
- 遅延制御。このオプションは、コミットを続行する前に、レプリケーションの点でノードがどれだけ遅れていてもよいかを制御します。

Postgres は *physical streaming replication* を提供します

PSR、これは一方向ですが *synchronous variant* を提供します。下位互換性を維持するために、PGD は `synchronous_commit` および `synchronous_standby_names` を使用した同期レプリケーションの構成を引き続きサポートしています。

> *PGD* を使用したレガシー同期レプリケーション を参照してくださいが、代わりにグループコミット の使用を検討します。

8.7.2 用語と定義

PGD ノードは、トランザクションのレプリケーション中にさまざまなロールを引き受けます。これらはトランザクションごとに暗黙的に割り当てられ、同時トランザクションの場合でも関係ありません。

** origin*は、クライアントまたはアプリケーションからトランザクションを受信するノードです。最初にトランザクションを処理するノードであり、他の PGD ノードへのレプリケーションを開始し、確認またはエラーでクライアントに応答します。

** パートナー*ノードは、グループコミット要件に従ってトランザクションを確認することが想定されている PGD ノードです。

** コミットグループ*は、コミットに関係するすべての PGD ノードのグループです。つまり、オリジンとそのすべてのパートナーノード。いくつかのまたはすべてのピアノードです。

8.7.3 比較

PGD で使用可能な同期レプリケーションのオプションのほとんどは、さまざまなレベルの同期を許可し、パフォーマンスとノードまたはネットワークの停止に対する保護の間のさまざまなトレードオフを提供します。

次の表は、トランザクションが発行されたオリジンノードから COMMIT 確認を受信した後、クライアントがレプリケートされたピアノードから期待できることをまとめています。Mode 列は、バリアントに応じて異なる意味を持ちます。PSR および PGD を使用した古い同期レプリケーションの場合、`synchronous_commit` 設定を参照します。コミットスコープの場合、それは *commit scope configuration* の確認要件を参照します。

Variant	Mode	Received	Visible	Durable
PSR Async	off (default)	no	no	no
PGD Async	off (default)	no	no	no
PGD Lag Control	'ON received' nodes	no	no	no
PGD Lag Control	'ON replicated' nodes	no	no	no
PGD Lag Control	'ON durable' nodes	no	no	no

次のページに続く

表 2 – 前のページからの続き

Variant	Mode	Received	Visible	Durable
PGD Lag Control	'ON visible' nodes	no	no	no
PSR Sync	remote_write (2)	yes	no	no (1)
PSR Sync	on (2)	yes	no	yes
PSR Sync	remote_apply (2)	yes	yes	yes
PGD Group Commit	'ON received' nodes	yes	no	no
PGD Group Commit	'ON replicated' nodes	yes	no	no
PGD Group Commit	'ON durable' nodes	yes	no	yes
PGD Group Commit	'ON visible' nodes	yes	yes	yes
PGD CAMO	'ON received' nodes	yes	no	no
PGD CAMO	'ON replicated' nodes	yes	no	no
PGD CAMO	'ON durable' nodes	yes	no	yes
PGD CAMO	'ON visible' nodes	yes	yes	yes
PGD Legacy Sync (3)	remote_write (2)	yes	no	no
PGD Legacy Sync (3)	on (2)	yes	yes	yes
PGD Legacy Sync (3)	remote_apply (2)	yes	yes	yes

(1) OS に書き込まれ、*OS* が実行されたままで *Postgres* のみがクラッシュした場合に持続します。

- (2) `synchronous_replication_availability` を `async'` に設定してローカルモードに切り替えない限り、許可されている場合。それ以外の場合、非同期 PGD デフォルトの値が適用されます。

(3) 代わりにグループコミットの使用を検討します。

受信により、通常に動作しているピアは、完全または部分的なネットワークの停止が発生した場合でも、最終的に追加の通信を必要とせずにトランザクションを適用できます。この確認には永続ストレージが関係しないため、ピアノードがクラッシュしてもトランザクションの再送信が必要になる場合があります。同期と考えられるすべてのモードがこの保護を提供します。

可視性は、トランザクションがリモートで適用されたことを示します。他のすべてのクライアントは、すべてのノードでトランザクションの結果を確認します。元のノードによってコミットが確認された直後にこの保証を提供します。可視性がないと、接続している他のクライアントはトランザクションの結果を認識せず、古い読み取りを経験する可能性があります。

耐久性は、ピアノードのストレージに関連し、ピアノードのクラッシュと復旧後のデータの損失に対する保護を提供します。これは、データの受信物理的ストリーミングレプリケーションの場合または可視性グループコミットの場合のいずれかに関連します。前者により、クラッシュ後の再送信の必要がなくなり、後者により、再起動しても可視性が維持されます。

8.7.4 操作の内部タイミング

さまざまなモードがどのように動作するかをより深く理解するために、PSR と PGD はトランザクションを異なる方法で適用することを理解すると役立ちます。

物理的ストリーミングレプリケーションを使用する場合、操作の順序は次のとおりです。

- オリジンはコミットレコードを WAL にフラッシュし、トランザクションをローカルに認識できるようにします。
- ピアノードは変更を受信し、書き込みを発行します。
- ピアは、受信した変更をディスクにフラッシュします。
- ピアは変更を適用し、トランザクションをローカルに認識できるようにします。

PGD では、操作の順序が異なります。

- オリジンはコミットレコードを WAL にフラッシュし、トランザクションをローカルに認識できるようにします。
- ピアノードは、メモリ内の適用キューに変更を受信します。
- ピアは変更を適用し、トランザクションをローカルに認識できるようにします。
- ピアはディスクにフラッシュすることによりトランザクションを永続化します。

Group Commit、CAMO、および Eager の場合、オリジンノードは、トランザクションをローカルに表示する前に、特定の数の確認を待機します。操作の順序は次のとおりです。

- Origin は、準備または事前コミットレコードを WAL にフラッシュします。
- ピアノードは、メモリ内の適用キューに変更を受信します。
- ピアは変更を適用し、トランザクションをローカルに認識できるようにします。
- ピアはディスクにフラッシュすることによりトランザクションを永続化します。
- Origin はトランザクションをコミットし、ローカルに見えるようにします。

次の表は、違いをまとめたものです。

Variant	Order of apply vs persist	Replication before or after commit
PSR	persist first	after WAL flush of commit record
PGD Async	apply first	after WAL flush of commit record
PGD Lag Control	apply first	after WAL flush of commit record
PGD Group Commit	apply first	before COMMIT on origin
PGD CAMO	apply first	before COMMIT on origin

8.7.5 構成

PGD の他の管理操作と同様に、SQL ファンクションを使用してコミットスコープを構成します。

たとえば、example_group PGD グループ内の大部分のノードでグループコミットを実行する基本的なコミットスコープを定義できます。

```
SELECT bdr.add_commit_scope(
  commit_scope_name := example_scope,
  origin_node_group := example_group,
  rule := ANY MAJORITY (example_group) GROUP COMMIT,
  wait_for_ready := true
);
```

次に、構成変数 GUC bdr.commit_scope をトランザクションごとに、またはそのコミットスコープにグローバルに設定することにより、コミットスコープを使用できます。

```
BEGIN;
SET LOCAL bdr.commit_scope = example_scope;
...
COMMIT;
```

特定の PGD グループのデフォルトのコミットスコープを設定することもできます。

```
SELECT bdr.alter_node_group_option(
  node_group_name := example_group,
  config_key := default_commit_scope,
  config_value := example_scope
);
```

default_commit_scope は、指定されたオリジンノードが属するグループツリーで下から上にチェックされます。default_commit_scope は特別な値 local に設定できません。つまり、コミットスコープで bdr.commit_scope 構成パラメーターを使用する方法がないことを意味します。

説明したすべてのオプションを含むコミットスコープ言語の詳細については、
コミットスコープ を参照してください。

Postgres 構成パラメーター

次の表は、デフォルト以外の値に設定する必要がある構成設定 req と、オプショナルですが特定のバリアントに影響を与える構成設定の概要を提供します。

Setting (GUC)	Group Commit	Lag Control	PSR (1)	Legacy Sync
synchronous_standby_names	n/a	n/a	req	req
synchronous_commit	n/a	n/a	opt	opt

次のページに続く

表 4 – 前のページからの続き

Setting (GUC)	Group Commit	Lag Control	PSR (1)	Legacy Sync
synchronous_replication_availability	n/a	n/a	opt	opt
bdr.commit_scope	opt	opt	n/a	n/a

8.7.6 計画的なシャットダウンと再起動

受信確認でグループコミットを使用する場合、計画的なシャットダウンまたは再起動に注意してください。デフォルトでは、適用キューはシャットダウンの前に消費されます。ただし、`immediate` シャットダウンモードでは、シャットダウン時にキューは破棄されるため、停止したノードはキュー内のトランザクションを「忘れ」ます。元のノードに同時に障害が発生すると、両方のノードに障害が発生したかのように、データの損失が発生する可能性があります。

適用キューがディスクにフラッシュされるようにするには、メンテナンスタスクに `smart` または `fast` シャットダウンを使用します。このアプローチでは、必要な同期レベルを維持し、データの損失を防ぎます。

8.7.7 PGD を使用したレガシー同期レプリケーション

注釈: 代わりに グループコミット の使用を検討します。

使用法

PGD を使用した同期レプリケーションを有効にするには、関連する PGD ピアノードのアプリケーション名を `synchronous_standby_names` に追加する必要があります。 `FIRST x` または `ANY x` を使用すると、非 PGD スタンバイノードの要件と競合しない場合、ある程度の柔軟性が提供されます。

追加したら、 `synchronous_commit` を使用してトランザクションごとの同期レベルを構成できます。デフォルトは `on` です。この設定は、アプリケーション名を `synchronous_standby_names` に追加することにより、既に同期レプリケーションが有効になっていることを意味します。`synchronous_commit` を `local` または `off` に設定すると、同期レプリケーションがオフになります。

PGD は永続化する前にトランザクションを適用するため、値 `on` および `remote_apply` は論理レプリケーションでは等価です。

コミットスコープへの移行

synchronous_commit および synchronous_standby_names とは無関係に、PGD のグループコミット機能を構成します。代わりに、bdr.commit_scope GUC を使用すると、トランザクションごとにスコープを選択できます。また、各ノードで synchronous_standby_names を個別に構成するのではなく、グループコミットはグローバルに同期したコミットスコープを使用します。

注釈: *synchronous_standby_names* およびコミットスコープの文法は似ていますが、前者はオリジンノードを考慮していませんが、後者は考慮します。したがって、たとえば *synchronous_standby_names = 'ANY 1 (..)'* は、*ANY 2 (...)* のコミットスコープと同等です。この選択により、マジョリティに関する推論が簡単になり、起点ノードがトランザクションの耐久性と可視性にも貢献することを反映しています。

Commit scopes

コミットスコープにより、アプリケーションは EDB Postgres Distributed の耐久性と一貫性に関する詳細な制御を提供します。

コミットスコープは、COMMIT レプリケーションの動作を記述する名前付けルールです。実際の動作は、コミットスコープが **グループコミット**、 *Commit At Most Once* 、 **遅延制御**、またはこれらの組み合わせを使用するかどうかによって異なります。

構成

グループコミットを使用するには、最初にコミットスコープを定義します。これにより、トランザクションのコミットに関係する PGD ノードが決定されます。スコープが確立されたら、次のようにグループコミットを使用するようにトランザクションを構成できます。

```
BEGIN;
SET LOCAL bdr.commit_scope = example_scope;
...
COMMIT;
```

トランザクションがデータを書き込む前に、コミットスコープを設定する必要があります。

この例では、以前にコミットスコープを次のように定義している可能性があります。

```
SELECT bdr.add_commit_scope(
    commit_scope_name := example_scope,
    origin_node_group := example_bdr_group,
    rule := ANY 2 (example_bdr_group) GROUP COMMIT,
    wait_for_ready := true
);
```

この例では、 example_bdr_group という名前の **ノードグループ**が存在し、少なくとも 2 つの PGD ノードをメンバーとして直接またはサブグループに含むことを前提としています。example_scope でコミットさ

れたトランザクションは、グループ内の PGD ノードからの追加の確認が 1 つ必要です。元のノードと合わせて、これはグループ外の「ANY 2」ノードを構成し、トランザクションはコミット後に可視的で耐久性のあることが保証されます。

オリジングループ

コミットスコープのルールは、トランザクションがコミットされるノード、つまりトランザクションのオリジンとして機能するノードに依存する場合があります。これをアプリケーションに対して透過的にするために、PGD では、トランザクションの発生場所に応じて、コミットスコープでさまざまなルールを定義できます。

たとえば、左側と右側の 2 つのデータセンターにノードが分散している EDB Postgres 分散クラスターを検討します。トップレベルの PGD ノードグループの名前が `top_group` であると仮定します。次のコマンドを使用して、サブグループをセットアップし、ローカルデータセンター内のすべてのノードがトランザクションを確認する必要があるコミットスコープを作成できますが、リモートから 1 つのノードのみを確認します。

```
- - create sub-groups
SELECT bdr.create_node_group(
    node_group_name := left_dc,
    parent_group_name := top_group,
    join_node_group := false
);
SELECT bdr.create_node_group(
    node_group_name := right_dc,
    parent_group_name := top_group,
    join_node_group := false
);

- - create a commit scope with individual rules
- - for each sub-group
SELECT bdr.add_commit_scope(
    commit_scope_name := example_scope,
    origin_node_group := left_dc,
    rule := ALL (left_dc) GROUP COMMIT AND ANY 1 (right_dc) GROUP COMMIT,
    wait_for_ready := true
);
SELECT bdr.add_commit_scope(
    commit_scope_name := example_scope,
    origin_node_group := right_dc,
    rule := ANY 1 (left_dc) GROUP COMMIT AND ALL (right_dc) GROUP COMMIT,
    wait_for_ready := true
);
```

次に、 `left_dc` の一部であるノードで `example_scope` を使用すると、最初のスコープが使用されます。`right_dc` の一部であるノードで同じスコープを使用すると、2 番目のスコープが使用されます。これは、アプリケーションでスコープ名をジャグリングする必要なく、逆スコープを作成する効果的な方法です。

各グループは、 bdr.alter_node_group_option 管理インターフェイスを使用して指定されたデフォルトのコミットスコープを持つこともできます。

上記のスコープを、これらのグループのノードで発生したすべてのトランザクションのデフォルトのスコープにすると、次のようになります。

```
SELECT bdr.alter_node_group_option(
  node_group_name := left_dc,
  config_key := default_commit_scope,
  config_value := example_scope
);
SELECT bdr.alter_node_group_option(
  node_group_name := right_dc,
  config_key := default_commit_scope,
  config_value := example_scope
);
```

確認レベル

PGD ノードは、さまざまなタイミングでトランザクションの確認を送信できます。保護レベルが増加すると、確認ノードの観点から、これらは次のとおりです。

- received —リモート PGD ノードは、トランザクションを受信したらすぐに、ローカルアプリケーションを開始する前に確認します。
- replicated —トランザクションの変更を適用した後、ディスクにフラッシュする前に確認します。
- durable —すべての変更がディスクにフラッシュされた後、トランザクションを確認します。
- visible デフォルトすべての変更がディスクにフラッシュされ、同時トランザクションに可視された後、トランザクションを確認します。

コミットスコープのルールでは、これらの確認レベルを次のように ON のかっこ内のノードグループ定義に追加できます。

- ANY 2 (right_dc) ON replicated
- ALL (left_dc) ON visible デフォルト
- ALL (left_dc) ON received AND ANY 1 (right_dc) ON durable

リファレンス

コミットスコープの文法

コミットスコープの文法は次のように構成されます。

```
commit_scope:
    confirmation [AND ...]
```

(次のページに続く)

(前のページからの続き)

```
commit_scope_operation:
    commit_scope_group [ ON { received|replicated|durable|visible } ] commit_scope_
↪kind

commit_scope_group:
{ ANY num (node_group [, ...])
  | MAJORITY (node_group [, ...])
  | ALL (node_group [, ...]) }

commit_scope_kind:
{ GROUP COMMIT [ ( group_commit_parameter = value ) ] [ ABORT ON ( abort_on_parameter␣
↪= value ) ]
  | CAMO [ DEGRADE ON ( degrade_on_parameter = value ) TO ASYNC ]
  | LAG CONTROL [ ( lag_control_parameter = value ) ] }
```

パラメーター

- node_group —ノードグループの名前。

``( group_commit_parameter = value )`` **—グループコミットのオプション。** transaction_tracking ブール値—トランザクションのステータスを追跡するかどうかを指定します。 ``conflict_resolution``enum) **—競合を処理する方法を指定します。指定可能な値は、レプリケーション中に競合解決ポリシーを使用して競合を非同期的に解決することを意味する** ``async`` **、または** ``eager`` **は、競合するトランザクションの** *1* **つを中止することにより、** *COMMIT* **中に競合が熱心に解決されることを意味します。** commit_decision enum) —COMMIT 決定を行う方法を指定します。値 group は、commit_scope_group 仕様が耐久性だけでなく COMMIT 決定にも影響を与えることを意味します。値 partner は、パートナーノードがトランザクションをコミットできるかどうかを決定することを意味します。この値は、2 つのデータノードグループでのみ許可されます。値 raft は、 COMMIT 決定が commit_scope_group コンセンサスとは無関係の Raft コンセンサスを使用して行われることを意味します。

``ABORT ON ( abort_on_parameter = value )`` **—タイムアウト時の自動トランザクションのアボートを許可します。** timeout インターバル—ミリ秒単位のタイムアウト他の単位を受け入れます。

``DEGRADE ON ( degrade_on_parameter = value )`` **—タイムアウト** timeout インターバルで非同期オペレーションに低下することを許可します—ミリ秒単位のタイムアウト他の単位を受け入れますこの後、操作は非同期になります。* require_write_lead ブール値—ノードが非同期モードに切り替えることができるように書き込みリードである必要があるかどうかを指定します。

``( lag_control_parameter = value )`` — *Lag Control* **のオプション** max_lag_size (int) — WAL バイトに基づいた最大許容遅延。 ``max_lag_time`` **(インターバル) —壁時計サンプリングに基づいた最大許容遅延。** max_commit_delay インターバル—遅延制限内に保つようにコミットに注入できる最大遅延。

注釈: *CAMO* コミットスコープ種類のほとんどは、追加の `DEGRADE ON` 句を備えた `GROUP COMMIT (transaction_tracking = true, commit_decision = partner)` の構文シュガーです。 *GROUP COMMIT* は、最終

的に `DEGRADE ON` 句も取得し、*CAMO* 構文を非推奨にすることが予想されます。

注釈: *synchronous_standby_names* およびコミットスコープの文法は似ているように見えますが、前者はオリジンノードを考慮していませんが、後者は考慮します。したがって、たとえば *synchronous_standby_names = 'ANY 1 (..)'* は、 *ANY 2 (...)* のコミットスコープと同等です。この選択により、マジョリティに関する推論が簡単になり、起点ノードがトランザクションの耐久性と可視性にも貢献することを反映しています。

コミットスコープルールの追加

ファンクション bdr.add_commit_scope は、指定されたコミットスコープ名とオリジンノードグループのルールを作成します。ルールが EDB Postgres 分散クラスター内のすべてのノードで同じである場合、トップレベルのノードグループに対してこのファンクションを 1 回呼び出すだけで、コミットスコープを完全に定義できます。

または、同じ commit_scope_name ではあるが、トランザクションのオリジンによって異なるオリジンノードグループとコミットスコープのルールを使用して、複数回呼び出すこともできます。

概要

```
bdr.add_commit_scope(
    commit_scope_name NAME,
    origin_node_group NAME,
    rule TEXT
    wait_for_ready boolean DEFAULT true)
```

コミットスコープルールの変更

コミットスコープ内のシングルオリジンノードグループの特定のルールを変更するには、ファンクション bdr.alter_commit_scope を使用できます。

概要

```
bdr.alter_commit_scope(
    commit_scope_name NAME,
    origin_node_group NAME,
    rule TEXT)
```

コミットスコープルールの削除

bdr.remove_commit_scope を使用して、コミットスコープ内の単一のルールを削除できます。コミットスコープに複数のルールを定義する場合、ルールごとに 1 回このファンクションを呼び出して、コミットスコープ全体を完全に削除する必要があります。

概要

```
bdr.remove_commit_scope(
    commit_scope_name NAME,
    origin_node_group NAME)
```

注釈: ノードグループによってデフォルトとして使用されているコミットスコープを削除することはできません。

Group Commit

グループコミットの目標は、単一ノードの障害または一時的な停止が発生した場合のデータの損失から保護することです。これは、複数の PGD ノードが COMMIT 時にトランザクションを正常に受信および確認する必要があることにより実現します。

要件

通常のオペレーションでは、グループコミットはアプリケーションに対して透過的です。フェールオーバー中に進行していたトランザクションには、アプリケーションまたは間のプロキシによってトリガーまたは統合される調整フェーズが必要です。このアクティビティは現在、元のノードが復旧した場合、またはクラスターから分離された場合にのみ発生します。この動作は、Postgres の古いビルトイン同期レプリケーションの場合と同じです。

グループコミットでコミットされたトランザクションは、その下で 2 フェーズコミットを使用します。したがって、ノードごとに発生するこのようなすべてのトランザクションを処理できるように十分に高い max_prepared_transactions を構成します。

構成

グループコミットを使用するには、最初に コミットスコープを定義します。コミットスコープは、トランザクションのコミットに関係する PGD ノードを決定します。

動作

Group Commit の動作は、コミットスコープによって適用される構成によって異なります。

決定をコミットする

group 、partner 、および raft の 3 つの方法でコミットを決定するようにグループコミットを構成できます。

グループコミットの決定は、耐久性の目的で使用されるのと同じコミットスコープグループ設定を使用して指定されたコンセンサスを通じて行われます。違いは、コミットの決定が PREPARE レプリケーションに基づいて行われるのに対し、耐久性は COMMIT (PREPARED) レプリケーションをチェックすることです。

パートナー決定は、

Commit At Most Once が使用するものです。このアプローチは、ノードグループに 2 つのデータノードが存在する場合にのみ機能します。これらの 2 つのノードはお互いのパートナーであり、オリジンではなくレプリカが何かをコミットするかどうかを決定します。このアプローチでは、アプリケーションが何らかの形でコンセンサスの一部であるため、

CAMO トランザクションプロトコルを使用して正常に動作するには、アプリケーションの変更が必要です。このアプローチの詳細については、
CAMO またはコミット・アット・モスト・ワンス を参照してください。

raft オプションは、ビルトインの Raft コンセンサスを使用して、コミットが発生できるかどうかを決定します。現在、グローバル Raft が使用されています。これが機能するには、クラスター全体のノードの大部分が動作している必要があります。

競合の解決

競合の解決は async または eager です。

非同期とは、PGD が、特定のノードに構成されている行レベルの解決を使用して、レプリケーション中にオプティミスティック競合解決を行うことを意味します。これは、元のトランザクションがコミットされたか、まだ進行中であるかに関係なく発生します。非同期競合解決の仕組みの詳細については、
競合 を参照してください。

Eager とは、競合が COMMIT 契約の一部として熱心に解決され、競合するトランザクションがシリアル化エラーで中止されることを意味します。このアプローチは、パフォーマンスを犠牲にして非同期解決よりも高い分離を提供します。Eager 競合解決の仕組みの詳細については、

Eager conflict resolution を参照してください。

アボート

COMMIT でコンセンサスを取得できないトランザクションが永久にハングしないように、ABORT ON 句でタイムアウトを指定できます。タイムアウトの後、トランザクションのアボートが要求されます。アボート要求が送信されたときにトランザクションがコミットされることが既に決定されている場合、クライアントがアボートメッセージを受信する場合でも、トランザクションは最終的に COMMIT します。

制限事項

グループコミットトランザクションはまだ DDL を実行できず、明示的な 2 フェーズコミットをサポートしていません。将来のリリースでは許可される可能性があります。ただし、TRUNCATE コマンドは許可されます。

CAMO トランザクションのみを DEGRADE TO 句と組み合わせて、可用性が低下した場合に非同期オペレーションに切り替えることができます。

Eager および CAMO トランザクションは、デコードワーカー機能またはトランザクションストリーミングとの組み合わせで現在サポートされていません。Eager を使用したインストールでは、PGD ノードグループの enable_wal_decoder および streaming_mode を無効のままにする必要があります。

同期レプリケーションは、グループコミットとは異なるトランザクション確認のメカニズムを使用します。この 2 つは互換性がないため、一緒に使用しないでください。したがって、トランザクションをグループコミットするときは常に、synchronous_standby_names で PGD ノードが構成されていないことを確認してください。

現在、Raft のコミット決定は非常に遅く、非常に低い TPS を生成します。eager 競合解決設定でのみこれらを使用して、PGD 4 以前の Eager All-Node Replication 動作を取得することをお勧めします。

同じトランザクションでのさまざまなコミット決定オプションの組み合わせは、サポートされていません。同じトランザクションで異なる競合解決オプションを組み合わせることもサポートされていません。

Commit At Most Once

Commit At Most Once CAMO 機能の目的は、アプリケーションが複数回コミットしないようにすることです。

CAMO がないと、 COMMIT が送信された後にクライアントが接続を失うと、アプリケーションはサーバーから応答を受け取らない場合があるため、トランザクションがコミットしたかどうかがわかりません。

アプリケーションは、次の 2 つのオプションの間を簡単に決定できません。

- 場合によっては、データが 2 回入力される可能性があるため、同じデータでトランザクションを再試行します。
- トランザクションを再試行せず、データがまったく処理されないリスク

これらはいずれも、高値のデータに関する重大なエラーです。

この状況を回避する 1 つの方法は、トランザクションの一意のインデックスを持つテーブルに少なくとも 1 つの INSERT を含めることです。ただし、これはアプリケーションのデザインに依存し、アプリケーション固有のエラー処理ロジックが必要であるため、すべての場合に効果的ではありません。

PGD の CAMO 機能は、より一般的なソリューションを提供し、INSERT を必要としません。 bdr.commit_scope によってアクティブ化されると、アプリケーションはトランザクション識別子が既に割り当てられている場合を含むメッセージを受信します。それ以外の場合、トランザクションの最初の write ステートメントはその情報をクライアントに送信します。

アプリケーションが明示的な COMMIT を送信する場合、プロトコルは、COMMIT が送信される前にアプリケーションがトランザクション識別子の通知を受信することを保証します。サーバーが COMMIT に応答しない場合、アプリケーションはトランザクション識別子を使用して別の PGD ノードからトランザクションの最終ステータスを要求することにより、このエラーを処理できます。以前のトランザクションステータスがわかっている場合、アプリケーションはトランザクションを再試行するかどうかを安全に決定できます。

CAMO は、同じ PGD グループからの 2 つの PGD ノードであるパートナーノードのペアを作成することにより機能します。この操作モードでは、ペアの各ノードは、他のピアで実行された最近のトランザクションの結果を知っており、特にニーズに応じて、COMMIT 中に切断されたトランザクションの結果を知っています。アプリケーションからトランザクションを受信するノードは「オリジン」と呼ばれ、これらのトランザクションを確認するノードは「パートナー」と呼ばれます。ただし、CAMO ペアのノードの CAMO 構成に違いはありません。ペアは対称です。

> **警告:** CAMO では、高度なエラー処理を利用するには、ユーザーのアプリケーションを変更する必要があります。パラメーターを有効にするだけでは保護を得るには十分ではありません。リファレンスクライアント実装は、要求に応じてお客様に提供されます。

要件

CAMO を使用するには、アプリケーションはマルチステートメント要求の一部としてではなく、別の要求として明示的な COMMIT メッセージを発行する必要があります。CAMO は、プロシージャーまたは暗黙的なコミットを使用する単一ステートメントトランザクションから発行されたトランザクションのステータスを提供できません。

構成

CAMO の構成は、 コミットスコープ を介して発生します。

障害シナリオ

さまざまな構成では、さまざまな障害シナリオが発生します。

レシーバー側のデータの永続性

デフォルトでは、PGL ライタはリモートノードからトランザクションを適用するときに bdr.synchronous_commit = off モードで動作します。これは CAMO にも当てはまります。つまり、トランザクションは、CAMO パートナーのディスクに到達する前に、オリジンノードに確認されます。クラッシュまたはハードウェア障害が発生した場合、確認されたトランザクションは CAMO パートナーで自分自身では回復できない場合があります。これは、CAMO パートナーノードが復旧するとトランザクションを再配布するため、CAMO 起点ノードが動作している限り問題ではありません。

これは、CAMO が単一ノードの障害から保護できることを意味します。これは、ローカルモードおよびリモート書き込みと同様に、またはそれと組み合わせて正しいです。

CAMO ペアの両方のノードの停止をカバーするには、bdr.synchronous_commit = local を使用して、コミット前の確認の前にフラッシュを強制できます。これは、リモート書き込みモードでもローカルモードでも動作せず、レイテンシーの影響を受けやすいコミットパスにある CAMO パートナーの I/O 要件により、パフォーマンスに影響を与えます。

非同期モード

コミットスコープで DEGRADE ON ... TO ASYNC 句が使用される場合、ノードは CAMO パートナーの準備ができているかどうかを検出します。そうでない場合、一時的に非同期ローカルモードに切り替わります。このモードの場合、ノードは CAMO モードに戻すまで、ローカルにトランザクションをコミットします。

これでは、COMMIT ステータスを取得することはできませんが、一貫性よりも可用性を選択できます。このモードは、単一ノードの障害を許容できます。CAMO ペアの両方のノードに障害が発生した場合、可用性を維持するために一致しないコミット決定を選択する可能性があり、データの不一貫性が発生します。

CAMO パートナーが準備ができているように切り替えるには、接続する必要があり、推定キャッチアップインターバルは TO ASYNC の timeout 値を下回る必要があります。 bdr.is_camo_partner_ready を使用して CAMO パートナーの現在の準備状況を確認できます。bdr.node_replication_rates は、キャッチアップ時間の現在の推定値を提供します。

CAMO 保護から非同期モードへのスイッチは、コミットが TO ASYNC の timeout 値を超えるため、または CAMO パートナーが既に知られている場合、コミット時に切断されるため、実際の CAMO トランザクションによってのみトリガーされます。このスイッチは、推定キャッチアップインターバルとは無関係です。CAMO ペアが、現在のノードが enable_proxy_routing ノードグループオプションで構成されたグループの書き込みリードであることを必要とするように構成されている場合。構文については、

> コミットスコープ を参照してください。これにより、分離されたノードが非同期モードに切り替わらないことによるスプリットブレイン状況を防ぐことができます。

CAMO グループに enable_proxy_routing が設定されていない場合、オリジンノードはすぐに非同期モードに切り替わります。

非同期モードから CAMO モードへの切り替えは、接続を開始する CAMO パートナーノードに依存します。CAMO パートナーは、少なくとも 30 秒ごとに再接続を試行します。したがって、接続が再確立された後、CAMO パートナーが元のノードに接続するまでに最大 30 秒かかる場合があります。CAMO パートナーに蓄積された遅延は、CAMO 保護モードへの切り替えをさらに遅延させます。

通常の CAMO オペレーション中とは異なり、非同期モードでは、コミットオーバーヘッドの追加はありま

せん。これは、CAMO ペアが通常処理できるよりも多くのトランザクションをノードが継続的に処理できるため、問題になる可能性があります。CAMO パートナーが最終的に再接続してトランザクションを適用した場合でも、このような状況では遅延が増加するだけであり、CAMO 保護の再確立を妨げます。トランザクションのスループットを人為的に調整するために、PGD は bdr.camo_local_mode_delay 設定を提供します。これにより、ローカルモードで COMMIT を任意の時間遅延できます。予想されるワークロード中に通常の CAMO モードでコミット時間を測定し、それに応じてこの遅延を構成することをお勧めします。デフォルトは 5 ミリ秒で、これは非同期ネットワークと比較的迅速な CAMO パートナーの応答を反映しています。

アーキテクチャと可用性要件を考慮して、非同期モードを許可するかどうかの選択を検討します。次の例は、詳細を提供します。

例

この例では、互いに CAMO パートナーである 2 つの PGD ノードを使用したセットアップを検討します。

edb_notranlate_0 この CAMO コミットスコープが正当であるためには、グループ内のノードの数が正確に 2 である必要があります。複数のノードで構成されるグループで ALL または ANY 2 を使用すると、非定量化グループ式が明確なペアに解決されないため、エラーになりますノードの。

非同期モードの場合

非同期モードが許可されている場合、単一障害点はありません。1 つのノードに障害が発生した場合

- 他のノードは、障害が発生したノードで COMMIT 中に切断されたすべてのトランザクションのステータスを判断できます。
- 新しい書き込みトランザクションが許可されます。2 番目のノードにも障害が発生した場合、その時点でコミットされていたトランザクションの結果は不明です。

非同期モードなし

非同期モードが許可されない場合、各ノードはトランザクションをコミットするために他のノードを必要とします。つまり、各ノードは単一障害点です。1 つのノードに障害が発生した場合

- 他のノードは、障害が発生したノードで COMMIT 中に切断されたすべてのトランザクションのステータスを判断できます。
- ノードが復旧するまで、新しい書き込みトランザクションは防止されます。

アプリケーションの使用

概要と要件

CAMO は、再試行ループとクライアント側での特定のエラー処理に依存しています。それには 3 つの側面があります。

- トランザクションの COMMIT の結果を確認する必要があり、一時的なエラーが発生した場合、クライアントはトランザクションを再試行する必要があります。
- COMMIT の前に、クライアントはノード ID とトランザクション ID 両方 32 ビット整数で構成されるトランザクションのグローバル識別子を取得する必要があります。
- トランザクションの COMMIT を試行中に現在のサーバーに障害が発生した場合、アプリケーションは CAMO パートナーに接続し、そのトランザクションのステータスを取得し、応答に応じて再試行する必要があります。

アプリケーションは、 COMMIT 中に切断された場合にトランザクションステータスを確認する目的でのみグローバルトランザクション識別子を保存する必要があります。特に、アプリケーションは別の永続レイヤーを必要としません。アプリケーションに障害が発生した場合、データベースの情報のみを再起動します。

CAMO パートナーの接続ステータス

ファンクション bdr.is_camo_partner_connected を使用すると、ペアモードで構成された CAMO パートナーノードの接続ステータスを確認できます。現在、Eager Replication で使用される CAMO に相当するものはありません。

概要

```
bdr.is_camo_partner_connected()
```

戻り値

CAMO パートナーが現在ローカルノード上の WAL 送信プロセスに接続しているため、トランザクションデータを受信し、確認を送り返すことができるかどうかを示すブール値。

CAMO パートナーの準備状況

ファンクション bdr.is_camo_partner_ready を使用すると、ペアモードで構成された CAMO パートナーノードの準備状況を確認できます。その下で、これはローカルモードへの、またはローカルモードからのスイッチをトリガーします。

概要

```
bdr.is_camo_partner_ready()
```

戻り値

CAMO パートナーがタイムリーに、つまり TO ASYNC の timeout の有効期限が切れる前に、ローカルノードから発生したトランザクションを確認することが合理的に期待できるかどうかを示すブール値。

注釈: このファンクションは、過去または現在の状態を照会します。正の戻り値は、 CAMO パートナーが将来のトランザクションを確認できるかどうかを示しません。

CAMO パートナーを取得する

この機能は、ローカルノードの CAMO パートナーペアモードで構成を表示します。

```
bdr.get_configured_camo_partner()
```

CAMO パートナーからの適用キューの消費を待機します

ファンクション bdr.wait_for_camo_partner_queue は、CAMO パートナーノードを照会することがデフォルトの bdr.wait_for_apply_queue のラッパーです。ローカルノードが CAMO ペアの一部でない場合、エラーを返します。

概要

```
bdr.wait_for_camo_partner_queue()
```

CAMO ノード間のトランザクションステータス

この機能により、CAMO トランザクションが完全に解決されるまでの待機が有効になります。

```
bdr.camo_transactions_resolved()
```

トランザクション状態照会機能

ノードに障害が発生したときにコミットされていたトランザクションのステータスを確認するには、アプリケーションはこのファンクションを使用する必要があります。

```
bdr.logical_transaction_status(node_id OID, xid OID,
                               require_camo_partner boolean)
```

ペアモードで CAMO を使用する場合、CAMO ペアの一部であるノードでのみこの機能を使用します。 Eager Replication と併せて、すべてのノードで使用できます。

どちらの場合も、コミットが発行されてから 15 分以内にファンクションを呼び出す必要があります。CAMO パートナーはこのようなメタ情報を定期的にパージする必要があるため、古いトランザクションに正しい回答を提供できません。

トランザクションのステータスを照会する前に、このファンクションは、受信キューが消費され完全に適用されるまで待機します。このメカニズムは、受信されたがまだ適用されていないトランザクションの早期の否定的な回答を防ぎます。

その名前にもかかわらず、それは常に読み取り専用操作であるわけではありません。ステータスが不明な場合、CAMO パートナーはトランザクションをコミットするか中止するかを決定し、その決定をローカルに保存して、今後の一貫性を保証します。

クライアントは、オリジンでコミットする前にこのファンクションを呼び出してはなりません。そうしないと、トランザクションが強制的にロールバックされる可能性があります。

概要

```
bdr.logical_transaction_status(node_id OID, xid OID,
                               require_camo_partner boolean DEFAULT true)
```

パラメーター

- node_id —トランザクションが発生する PGD ノードのノード ID。通常はクライアントが PQ パラメーター bdr.local_node_id から COMMIT の前に取得します。
- xid —オリジンノードのトランザクション ID。通常はクライアントが PQ パラメーター transaction_id から COMMIT の前に取得します。
- require_camo_partner —デフォルトで true で、構成チェックが有効になります。これらのチェックを無効にし、CAMO トランザクションではないトランザクションのステータスを照会するには、false に設定します。

戻り値

ファンクションは、次のいずれかの結果を返します。

- `'committed'::TEXT` —トランザクションはコミットされ、CAMO ペアの両方のノードで可視され、最終的に他のすべての PGD ノードにレプリケートされます。クライアントが再試行する必要はありません。
- `'aborted'::TEXT` —トランザクションは中止され、他の PGD ノードにレプリケートされません。クライアントは再試行するか、トランザクションのコミットの失敗をエスカレートする必要があります。
- `'in progress'::TEXT` —トランザクションはこのローカルノードでまだ進行中であり、まだコミットまたは中止されていません。トランザクションは COMMIT フェーズにあり、CAMO パートナーがコミットを確認または拒否するのを待機している可能性があります。推奨されるクライアントの反応は、元のノードから切断し、CAMO パートナーに再接続して、代わりにそれを照会することです。間にロードバランサーまたはプロキシがあり、クライアントがどのノードを照会するかを制御できない場合、クライアントはステータスが`'committed'` または`'aborted'` に切り替わるまで、繰り返しポーリングのみできます。

Eager All-Node Replication の場合、ピアノードは、まだコミットまたは中止されていないトランザクションに対してこの結果を生成します。この場合、まだレプリケートされていないトランザクション、またはオリジンノードで開始されていないトランザクションでも、ピア PGD ノードで `in progress` 結果を生成する場合があります。ただし、クライアントは、オリジンでコミットする前にトランザクションステータスを照会してはなりません。

- `'unknown'::TEXT` —指定されたトランザクションは、将来であるか、その特定のノードにまだレプリケートされていない、または過去すぎるため不明です。このようなトランザクションのステータスはまだ知られていない、または不明です。この戻り値は、クライアントによる不適切な使用の兆候です。

クライアントは、エラーが発生した場合にファンクション呼び出しを再試行する準備をする必要があります。

接続プールとプロキシ

CAMO クラスターをデザインするときは、接続プールとプロキシの効果を考慮してください。プロキシは、コミットグループ内のすべてのノード、つまり CAMO ペアの両方のノード、または Eager All-Node Replication の場合はすべての PGD ノードにトランザクションを自由に分散することができます。

アプリケーションが適切なノード ID を取得するように注意してください。セッションプーリングを使用する場合、クライアントは同じノードに接続されたままであるため、ノード ID はクライアントセッションの有効期間を通じて一定のままです。ただし、より詳細なトランザクションプーリングでは、クライアントはすべてのトランザクションのノード ID を取得する必要があります次の例のように。

PGD ノードに直接接続されていないクライアントは、フェールオーバーまたはスイッチオーバーに気付かない場合があります。ただし、`bdr.local_node_id` パラメーターを使用して、現在接続しているノードを判断することができます。COMMIT 中の切断という重要な状況では、プロキシはその切断をエラーとして CAMO プロトコルを適用するクライアントに適切に転送する必要があります。

`received` モードの CAMO の場合、CAMO ペア間を切り替える可能性のあるプロキシは、`bdr.wait_for_camo_partner_queue` ファンクションを使用して、古い読み取りを防ぐ必要があります。

例

この例は、CAMO 対応クライアントアプリケーションの再試行ループが C のような擬似コードでどのように見えるかを示しています。接続情報を提供する 2 つの DSN origin_dsn および partner_dsn を想定しています。これらは通常、bdr.create_node への最初の呼び出しに使用される DSN と同じであり、bdr.node_summary 、interface_connstr 列でルックアップできます。

```
PGconn *conn = PQconnectdb(origin_dsn);

loop {
    // start a transaction
    PQexec(conn, "BEGIN");

    // apply transactional changes
    PQexec(conn, "INSERT INTO ...");
    ...

    // store a globally unique transaction identifier
    node_id = PQparameterStatus(conn, "bdr.local_node_id");
    xid = PQparameterStatus(conn, "transaction_id");

    // attempt to commit
    PQexec(conn, "COMMIT");
    if (PQresultStatus(res) == PGRES_COMMAND_OK)
        return SUCCESS;
    else if (PQstatus(res) == CONNECTION_BAD)
    {
        // Re-connect to the partner
        conn = PQconnectdb(partner_dsn);
        // Check if successfully reconnected
        if (!connectionEstablished())
            panic();

        // Check the attempted transactions status
        sql = "SELECT bdr.logical_transaction_status($node_id, $xid)";
        txn_status = PQexec(conn, sql);
        if (txn_status == "committed")
            return SUCCESS;
        else
            continue;   // to retry the transaction on the partner
    }
    else
    {
        // The connection is intact, but the transaction failed for some
        // other reason.  Differentiate between permanent and temporary
        // errors.
```

(次のページに続く)

(前のページからの続き)

```
        if (isPermanentError())
            return FAILURE;
        else
        {
            // Determine an appropriate delay to back-off to account for
            // temporary failures due to congestion, so as to decrease
            // the overall load put on the servers.
            sleep(increasing_retry_delay);

            continue;
        }
    }
}
```

この例は、再試行やエラー処理を含む、接続のための適切なロジックで拡張する必要があります。PgBouncer のようなロードバランサーを使用している場合、PQreset を使用して再接続を実装できます。ロードバランサーがクライアントを CAMO パートナーにのみリダイレクトし、他の PGD ノードではないことを確認します。

実際には、再試行の上限を設定することをお勧めします。トランザクションで実行されるアクションによっては、他の一時的なエラーが発生する可能性があります。これらは、SERIALIZABLE 分離モードでのデッドロックまたはシリアル化障害のベストプラクティスと同様に、エラーコードに応じてトランザクションを再試行することにより処理する必要があります。

DDL およびグローバルロックとの相互作用

CAMO によって保護されたトランザクションには、DDL 操作を含めることができます。ただし、DDL はグローバルロックを使用します。これは既にノード間である程度の同期を提供しています。詳細については、

> *DDL* ロックの詳細 を参照してください。

CAMO と DDL を組み合わせると、レイテンシーが長くなり、グローバルデッドロックの可能性が高くなります。したがって、比較的低い bdr.global_lock_timeout を使用することをお勧めします。これは DDL を中止し、適切な時間でデッドロックを解決します。

非トランザクション DDL

次の DDL 操作はトランザクションブロックでは許可されていないため、CAMO 保護の恩恵を受けることはできません。これらの場合、CAMO は内部で自動的に無効になります。

- すべての同時インデックス操作 CREATE 、DROP 、および REINDEX
- REINDEX DATABASE 、REINDEX SCHEMA 、および REINDEX SYSTEM
- VACUUM
- パラメーターなしの CLUSTER

- ALTER TABLE DETACH PARTITION CONCURRENTLY
- ALTER TYPE [enum] ADD VALUE
- ALTER SYSTEM
- CREATE および DROP DATABASE
- CREATE および DROP TABLESPACE
- ALTER DATABASE [db] TABLESPACE

CAMO の制限

CAMO の制限については、 *PGD limitations* ページでカバーされています。

パフォーマンスへの影響

CAMO は、コミット時にメッセージのラウンドトリップを追加することにより、Postgres レプリケーションプロトコルを拡張します。アプリケーションのコミットレイテンシーは非同期レプリケーションの場合よりも高く、これは主に、関係するノード間の往復時間によって決まります。同時セッションの数を増やすと、並列処理が増加して、合理的なトランザクションスループットを取得できます。

トランザクションを確認する CAMO パートナーは、トランザクションの状態を保存する必要があります。非 CAMO オペレーションと比較して、これは、オリジンから適用される各トランザクションの追加シークが必要になる場合があります。

クライアントアプリケーションのテスト

クライアント側で CAMO を適切に使用することは簡単ではありません。ノードのクラッシュやネットワークの停止などの障害シナリオに対して、PGD クラスターでアプリケーションの動作をテストすることを強くお勧めします。

Lag Control

PGD 起点ノード上のデータベースアプリケーションのデータスループットは、コミットされたデータを下流のピアノードに安全にレプリケートできる速度を超える場合があります。高可用性アプリケーションでこの差が一定の期間を超えてまたは慢性的に続く場合、ディザスターリカバリーまたは事業継続計画に関連する組織の目標は満たされない可能性があります。

レプリケーションラグ制御 RLC 機能は、PGD グループノード間のデータフローがこれらの組織の目標に準拠するように、動的レート制限デバイスを使用してこの不均衡を調整するように設計されています。これは、PGD ノード間のレプリケーションラグの程度を制御することにより行われます。

これらの目的の一部には次のものが含まれます。

- 目標復旧ポイント RPO は、計画外のイベントによって失われる可能性のあるデータの最大許容量を指定します。通常は時間として表されます。非レプリケートシステムでは、RPO を使用してバックアップ間隔を設定し、障害によるコミットされたデータの損失のリスクを制限します。レプリケート

システムの場合、RPO は、1 つ以上のピアノードに安全に適用されていないコミットされたデータの許容量を決定します。

- リソース制約目標 RCO は、有限のストレージ制約があることを確認します。このストレージには、データベースファイル、WAL、およびオペレーションの継続に必要な一時または中間ファイルが含まれます。レプリケートシステムの場合、遅延が増加すると、これらのストレージリソースへの要求も増加します。
- グループ弾性目標 GEO は、ノードがピアノードに受け入れられないクリップで新しいデータを生成していないことを保証します。その場合、その条件の検出は、データベースノードの数を拡張する決定における 1 つのメトリックとして使用できます。同様に、その状態が和らぐと、データベースノードの数を契約する決定に影響を与える可能性があります。

Lag Control は、クライアント接続が READ WRITE トランザクションをコミットできるレートを制御することにより、レプリケーションラグを管理します。レプリケーションラグは、満たす目的に応じて、ラグタイムまたはラグサイズとして測定されます。トランザクションのコミットレートは、設定された PGD コミット遅延時間を使用して調整されます。

要件

Lag Control の使用を開始するには

- すべてのデータベースアプリケーションが許容できる最大許容コミット遅延時間 `max_commit_delay` を決定します。
- 使用する遅延測定を決定します。ラグサイズ `max_lag_size` またはラグタイム `max_lag_time` のいずれかを選択します。
- 関係するグループまたはサブグループ、および確認を満たすために必要な各コレクションのノードの最小数を決定します。この情報は、コミットスコープルールの定義の基礎を形成します。

構成

コミットスコープでラグ制御を指定すると、コミットスコープルールがスパンするノード全体で一貫した調整されたパラメーター設定が可能になります。ラグ制御仕様は、トップグループのデフォルトのコミットスコープに、またはオリジングループのコミットスコープの一部として含めることができます。

> コミットスコープ のサンプルノードグループを使用して、この例は、2 つのデータセンターのラグ制御ルールを示します。

```
- - create a Lag Control commit scope with individual rules
- - for each sub-group
SELECT bdr.add_commit_scope(
    commit_scope_name := example_scope,
    origin_node_group := left_dc,
    rule := ALL (left_dc) LAG CONTROL (max_commit_delay=500ms, max_lag_time=30s) AND␣
↪ANY 1 (right_dc) LAG CONTROL (max_commit_delay=500ms, max_lag_time=30s),
    wait_for_ready := true
```

(次のページに続く)

(前のページからの続き)

```
);
SELECT bdr.add_commit_scope(
    commit_scope_name := example_scope,
    origin_node_group := right_dc,
    rule := ANY 1 (left_dc) LAG CONTROL (max_commit_delay=0.250ms, max_lag_
↪size=100MB) AND ALL (right_dc) LAG CONTROL (max_commit_delay=0.250ms, max_lag_
↪size=100MB),
    wait_for_ready := true
);
```

パラメーター値は、GUC パラメーター規則と互換性のあるユニット仕様を許可します。

ラグ制御コミットスコープルールを、グループコミットおよび CAMO ルール仕様を含む既存のコミットスコープルールに追加できます。

`max_commit_delay` パラメーターは、必要に応じてサブミリ秒設定を含む、小数部分を含むミリ秒の仕様を許可および推奨します。

概要

Lag Control は、クライアント接続レベルで動作する動的な TPS レート制限メカニズムです。構成された遅延制御のコンストレインを満たしながら、できるだけ目立たないように設計されています。これは、十分な PGD ノードが構成された遅延測定しきい値を下回るように十分な速度で変更をレプリケートできる場合、PGD ランタイムコミット遅延が 0 ミリ秒に固定されることを意味します。

これに当てはまらない場合は、適合ノードの数が最小しきい値に戻るまで、PGD ランタイムコミット遅延を必要に応じて最小限に調整しますが、それ以上にはなりません。

最小ノードしきい値に到達した後でも、Lag Control は PGD ランタイムコミット遅延をゼロに戻そうとし続けます。PGD コミット遅延は、ほとんどの場合、平衡レベルを中心に上下する可能性がありますが、データスループットまたはラグ適用レートが向上すると、コミット遅延は時間の経過とともに減少します。

PGD コミット遅延は、コミット後の遅延です。これは、トランザクションがコミットされた後、トランザクションによってロックまたは取得されたすべての Postgres リソースが解放された後に発生します。したがって、遅延は、同時アクティブなトランザクションがその値を監視または変更する、またはそのリソースを取得することを妨げるものではありません。Postgres 拡張機能によって管理される外部リソースについては、同じ保証はできません。拡張機能の依存関係に関係なく、PGD 拡張機能が `postgresql.conf` の拡張機能ベースのリソースマネージャーの前にリストされている場合、同じ保証を行うことができます。

厳密には、PGD コミット遅延はトランザクションごとの遅延ではありません。これは、特定のクライアント接続のトランザクションストリームにおけるコミット遅延の平均値です。この技術により、コミット遅延と値のきめの細かい調整が、OS スケジューラー、クロック割り込み、およびシステム負荷による変動の粗い粒度をエスケープできます。また、PGD ランタイムコミット遅延を可能な限り最小の期間のマイクロ秒以内に安定させて、遅延測定しきい値を維持できます。

注釈: PGD コミット遅延と Postgres コミット遅延を混同しないでください。これらは無関係であり、異な

る機能を実行します。一方を他方に置き換えないでください。 !!!

トランザクションアプリケーション

PGD コミット遅延は、ユーザーアプリケーションのデータを変更するすべての READ WRITE トランザクションに適用されます。この動作は、宣言された READ WRITE トランザクションを含む、データを変更しないトランザクションがコミット遅延から免除されることを意味します。

非同期トランザクションのコミットは、PGD コミット遅延も実行します。これは直観に反しているように見えるかもしれませんが、非同期コミットは、そのパフォーマンスのおかげで、レプリケーション遅延の最大のソースの 1 つになる可能性があります。

Postgres および PGD 補助プロセスは、トランザクションのコミット時に遅延しません。最も注目的なのは、PGD ライターは、ローカルノードでリモートトランザクションを適用するときにコミット遅延を実行しないことです。PGD ライターは発信レプリケーションラグに何も寄与せず、遅延によってトランザクションコミットが調整されないことにより、着信レプリケーションラグを最も削減できるため、これはデザインです。

制限事項

最大コミット遅延は、ハード制限を表す天井値であり、コミット遅延が構成された値を超えないことを意味します。逆に、最大遅延はサイズと時間の両方で測定され、超過できるソフト制限です。最大コミット遅延に到達すると、遅延対策に追加のバックプレッシャーはなく、継続的な増加を防ぎます。

PGD レプリケーションセットを変更しないオリジントランザクションをコミット遅延から免除する方法はありません。これらのトランザクションの場合、最大トランザクション遅延を 0 に SET LOCAL にすると役立ちます。

注意事項

アプリケーション TPS は、レプリケーション遅延に影響を与える可能性のある多くの要因の 1 つです。他の要素には、PGD コミット遅延の効果があまりない可能性があるトランザクションの平均サイズが含まれます。特に、大量のロード操作はレプリケーション遅延の増加を引き起こす可能性があり、これは、最大許容遅延を下回っていますが、通常のアプリケーションで合理的に予想されるレベルを超えて PGD ランタイムコミット遅延の付随的な上昇をトリガーする可能性があります。

同様に、非常に高い OLTP 要件と適度なデータ変更があるアプリケーションは、許容可能な PGD コミット遅延設定によって不当に抑制される可能性があります。

これらの場合、 `SET [SESSION|LOCAL]` コマンドを使用して、これらのアプリケーションのラグ制御設定をカスタム構成するか、これらのアプリケーションを変更すると便利です。たとえば、大量のロード操作は複数の小さなトランザクションに分割されて、トランザクションのスナップショットの期間と WAL 保持サイズを制限したり、大量のロードが失敗した場合にリスタートポイントを確立したりする場合があります。ラグ制御を参照して、これらのトランザクションコミットは、非常に長い PGD コミット遅延をスケジュールして、以前の部分的な大量ロードによって発生した遅延をダイジェストすることもできます。

組織目標の達成

先ほどの目標リストの例では

- 適切な最大ラグタイムを設定することにより、RPO を満たすことができます。
- 適切な最大遅延サイズを設定することにより、RCO を満たすことができます。
- GEO は、PGD ランタイムコミット遅延と PGD ランタイムラグ対策をモニタリングすることにより満たすことができます。

前述のように、PGD ランタイムコミット遅延の最大値が PGD 構成済みのコミット遅延制限でペッグされ、遅延測定値が一貫して PGD 構成の最大レベルを超える場合、このシナリオは PGD グループ拡張のマーカーになる可能性があります。

8.8 Consistency

EDB Postgres Distributed は、アクティブ/アクティブまたはマルチマスター DBMS です。非同期で使用される場合、標準のデータ型を使用する場合、複数の異なるノードから同じまたは関連する行への書き込みにより、データが **競合** になる場合があります。

競合はエラーではありません。ほとんどの場合、これらは発生時に PGD が検出および解決できるイベントです。解決策はアプリケーションの性質とデータの意味によって異なるため、PGD がアプリケーションにそれらを解決する方法に関して幅広い選択肢を提供することが重要です。

デフォルトでは、競合は行レベルで解決されます。2 つのノードからの変更が競合する場合、ローカルまたはリモートのタプルのいずれかが選択され、他方は破棄されます。たとえば、コミットタイムスタンプは、2 つの競合する変更と新しい方が保持されると比較される場合があります。このアプローチでは、すべてのノードが同じ結果に収束し、クラスター全体でコミットオーダーのようなセマンティクスを確立します。

列レベルの競合の検出と解決は、
CLCD で説明している PGD で利用できます。

競合を回避したい場合は、
グループコミット を *Eager conflict resolution* または競合のないデータ型 CRDT とともに使用できます。*CRDT* **データ型を使用した列の競合の処理** で説明しています。

8.8.1 Conflicts

EDB Postgres Distributed は、アクティブ/アクティブまたはマルチマスター DBMS です。非同期で使用される場合、標準のデータ型を使用するときに、複数の異なるノードから同じまたは関連する行への書き込みにより、データの競合が発生する可能性があります。

競合はエラーではありません。ほとんどの場合、これらは発生時に PGD が検出および解決できるイベントです。それらの解決は、アプリケーションの性質とデータの意味によって異なります。したがって、PGD はアプリケーションに競合を解決する方法についての幅広い選択肢を提供することが重要です。

デフォルトでは、競合は行レベルで解決されます。2 つのノードからの変更が競合する場合、PGD はローカルまたはリモートタプルのいずれかを選択し、他方は破棄します。たとえば、コミットタイムスタンプは、

2 つの競合する変更と新しい方が保持されると比較される場合があります。このアプローチでは、すべてのノードが同じ結果に収束し、クラスター全体でコミットオーダーのようなセマンティクスを確立します。

> **列レベルの競合解決の有効化と無効化** で説明しているように、競合処理は構成可能です。 PGD は、*Stream triggers* で説明しているように、競合トリガーを使用してテーブルごとに競合を検出し、それらをさまざまな方法で処理できます。

列レベルの競合の検出と解決は、
CLCD で説明している PGD で利用できます。

デフォルトでは、すべての競合は `bdr.conflict_history` ログに記録されます。競合の可能性がある場合、テーブル所有者は競合を監視して回避方法を分析するか、アプリケーションタスクとして定期的に処理する計画を立てる必要があります。

> *LiveCompare* **によるデータ検証** ツールは、発散がないか定期的にスキャンすることもできます。

一部のクラスタリングシステムは、分散ロックメカニズムを使用して、データへの同時アクセスを防止します。これらはサーバーが互いに非常に近い場合に合理的なパフォーマンスを発揮しますが、許容可能なパフォーマンスには非常に低い遅延が重要である地理的に分散したアプリケーションをサポートできません。

分散ロックは本質的に悲観的なアプローチです。PGD は、可能な限り競合を回避するが、一部の種類の競合の発生を許可し、発生した場合にそれらを解決する楽観的なアプローチを提唱しています。

競合が発生する仕組み

ノード間の競合は、関係するすべてのトランザクションが同じノードで同時に発生した場合に発生することはできない一連のイベントの結果として発生します。ノードはトランザクションがコミットした後にのみ変更を交換するため、各トランザクションはコミットしたノードで個別に有効です。他の競合する作業を同時に実行した別のノードに適用された場合、有効ではありません。

PGD レプリケーションは基本的に他のノードでトランザクションを再生するため、適用されるトランザクションと受信ノードでコミットされたトランザクションとの間に競合がある場合、再生操作は失敗する可能性があります。

Postgres にはそれを防ぐトランザクション間通信メカニズムがあるため、すべてのトランザクションが単一のノードで実行されている場合、ほとんどの競合は発生しません。これらのメカニズムの例は、`UNIQUE` インデックス、`SEQUENCE` 操作、行およびリレーションロック、`SERIALIZABLE` 依存関係追跡などです。これらのメカニズムはすべて、進行中のトランザクション間で通信して、望ましくない同時実行の問題を防ぐ方法です。

PGD には、分散トランザクションマネージャーもロックマネージャーもありません。これが、レイテンシーとネットワークパーティションで良好なパフォーマンスを発揮する理由の一部です。その結果、異なるノード上のトランザクションは、デフォルトの遅延レプリケーションを使用する場合、互いに完全に独立して実行されます。ノード間の独立性が低いほど、競合を完全に回避できます。これが、これが重要な場合に PGD が Eager Replication も提供する理由です。

競合の種類

主キーまたは一意の競合

最も一般的な競合は行の競合であり、2 つの操作が単一のノードではできない方法で同じキーを持つ行に影響を与えます。PGD はこれらのほとんどを検出でき、update_if_newer 競合リゾルバーを適用します。

行の競合には次のものが含まれます。

- INSERT vs INSERT
- UPDATE vs UPDATE
- UPDATE vs DELETE
- INSERT vs UPDATE
- INSERT vs DELETE
- DELETE vs DELETE

bdr.node_conflict_resolvers ビューは、すべての既知の競合タイプに対して競合解決が現在どのように構成されているかに関する情報を提供します。

INSERT/INSERT の競合

最も一般的な競合 INSERT /INSERT は、2 つの異なるノードでの INSERT 操作が、同じ PRIMARY KEY 値または PRIMARY KEY が存在しない場合、単一の UNIQUE コンストレインの同じ値を持つタプルを作成する場合に発生します。

PGD は、元のノードのタイムスタンプに従って、2 つのうちの最後に挿入されたタプルを保持することにより、この状況を処理します。ユーザー定義の競合ハンドラーは、この動作をオーバーライドできます。

この競合は insert_exists 競合タイプを生成します。これは、デフォルトで解決されます。コミット時間に基づいて、新しい行を選択し、その 1 つだけ update_if_newer リゾルバー。他のリゾルバーを構成できます。詳細は、

> 列レベルの競合解決の有効化と無効化 を参照してください。

この競合タイプを解決するには、列レベルの競合解決とユーザー定義の競合トリガーを使用することもできます。

> *PGD* グローバルシーケンス を使用して、このタイプの競合を効果的に排除できます。

複数の UNIQUE 制約に違反する INSERT 操作

INSERT /INSERT 競合は、複数の UNIQUE 制約に違反する可能性があります。そのうちの 1 つは PRIMARY KEY である可能性があります。新しい行が複数の UNIQUE 制約に違反し、その結果他の複数の行と競合が発生する場合、レプリケーション変更を適用すると multiple_unique_conflicts 競合が生成されます。

このような競合が発生した場合、レプリケーションを続行するにはいくつかの行を削除する必要があります。multiple_unique_conflicts のリゾルバー設定によっては、適用プロセスはエラーで終了するか、着信行をスキップするか、一部の行を削除します。削除では、正しい PRIMARY KEY を含む行を保持し、他の行を削除しようとします。

> **警告:** この方法で競合する複数の行がある場合、競合解決の結果、挿入操作を続行すると、常にデータの一部が削除されます。

競合トリガーを使用して、別の動作を定義することもできます。

UPDATE/UPDATE の競合

異なるノードでの 2 つの同時 UPDATE 操作が同じタプルを変更するが、その PRIMARY KEY を変更しない場合、再生時に UPDATE /UPDATE 競合が発生する可能性があります。

これらは、構成と状況に基づいて、さまざまな種類の競合を生成する可能性があります。テーブルが 行バージョンの競合検出 で構成されている場合、元のキー行がローカル行と比較されます。それらが異なる場合、update_differing 競合が生成されます。 オリジンの競合検出を使用する場合、行の原点がチェックされます。オリジンは、現在のローカル行が発生したノードです。これが変更されると、update_origin_change 競合が生成されます。その他の場合、UPDATE は通常、競合を生成せずに適用されます。

これらの競合は両方とも、 *INSERT/INSERT* の競合 で説明している insert_exists と同じ方法で解決されます。

主キーの UPDATE の競合

PGD は、現在、 PRIMARY KEY が UPDATE オペレーションによって変更される競合解決を実行できません。主キーを更新できますが、既存の値と競合しないことを確認する必要があります。

主キーの更新の競合は 多様な競合 であり、手動介入が必要です。

Postgres で主キーの更新は可能ですが、Postgres と PGD の両方に問題があります。

単純なスキーマは、次のことを説明する例を提供します。

```
CREATE TABLE pktest (pk integer primary key, val integer);
INSERT INTO pktest VALUES (1,1);
```

主キー列の更新が可能であるため、次の SQL は成功します。

```
UPDATE pktest SET pk=2 WHERE pk=1;
```

ただし、テーブルに複数の行があるとします。

```
INSERT INTO pktest VALUES (3,3);
```

一部の UPDATE 操作は成功します。

```
UPDATE pktest SET pk=4 WHERE pk=3;

SELECT * FROM pktest;
 pk | val
- ---+-----
  2 |   1
  4 |   3
(2 rows)
```

他の UPDATE 操作は制約エラーで失敗します。

```
UPDATE pktest SET pk=4 WHERE pk=2;
ERROR:  duplicate key value violates unique constraint "pktest_pkey"
DETAIL:  Key (pk)=(4) already exists
```

したがって、主キーを更新する Postgres アプリケーションの場合、PGD がなくても、実行時エラーを回避するように注意してください。

PGD では、複数の場所から同時に UPDATE 操作が許可される場合、状況はより複雑になります。

これらの 2 つの変更を同時に実行すると、動作します。

```
node1: UPDATE pktest SET pk=pk+1 WHERE pk = 2;
node2: UPDATE pktest SET pk=pk+1 WHERE pk = 4;

SELECT * FROM pktest;
 pk | val
- ---+-----
  3 |   1
  5 |   3
(2 rows)
```

両方の変更が受け入れられるため、これらの次の 2 つの変更を同時に実行すると、発散エラーが発生します。ただし、他のノードに変更を適用すると、update_missing 競合が発生します。

```
node1: UPDATE pktest SET pk=1 WHERE pk = 3;
node2: UPDATE pktest SET pk=2 WHERE pk = 3;
```

このシナリオでは、各ノードで異なるデータのままになります。

```
node1:
SELECT * FROM pktest;
 pk | val
- ---+-----
  1 |   1
  5 |   3
(2 rows)

node2:
SELECT * FROM pktest;
 pk | val
- ---+-----
  2 |   1
  5 |   3
(2 rows)
```

:ref:`LiveCompare によるデータ検証 <LiveCompare によるデータ検証>` を使用して、この状況を特定して解決できます。

同時競合により問題が発生します。これら 2 つの変更を同時に実行することは、解決するのが簡単ではありません。

```
node1: UPDATE pktest SET pk=6, val=8 WHERE pk = 5;
node2: UPDATE pktest SET pk=6, val=9 WHERE pk = 5;
```

どちらの変更もローカルに適用されるため、ノード間の相違が発生します。しかし、ターゲットへの適用は、両方のノードで失敗し、重複キー値違反エラーが発生します。このエラーにより、レプリケーションが停止され、手動の解決が必要です。

conflict_type update_pkey_exists を skip 、update 、または update_if_newer に設定すると、この重複キー違反エラーを回避でき、レプリケーションは中断されません。このアプローチでも、更新の性質によっては、発散が発生する可能性があります。

update_pkey_exists から update_if_newer を設定することにより、同じ古いキーが同じ新しいキーによって同時に更新されている場合、発散を回避できます。ただし、特定の状況では、update_if_newer でも発散が発生します。つまり、2 つの異なる行が両方とも同じ新しい主キーに同時に更新される場合。

その結果、アプリケーション、特に PGD で主キーの UPDATE 操作を許可しないことを強くお勧めします。アプリケーションの一部が主キーを変更する場合、同時変更を回避するには、Eager Replication を使用してこれらの変更を行います。

警告: *update_pkey_exists* 競合の競合解決の結果が更新された場合、常にいずれかの行が削除されます。

複数の UNIQUE 制約に違反する UPDATE 操作

> 複数の *UNIQUE* 制約に違反する *INSERT* 操作 と同様に、受信した UPDATE が複数の UNIQUE

インデックスまたは PRIMARY KEY に違反すると、PGD は multiple_unique_conflicts 競合を発生させます。

PGD は、遅延一意コンストレインをサポートしています。トランザクションがソースでコミットできる場合、競合が発生しない限り、ターゲットにクリーンに適用されます。ただし、遅延主キーをレプリカ ID として使用することはできないため、ユースケースはそれと複数の一意の制約の使用に関する警告によって既に制限されています。

UPDATE/DELETE の競合

1 つのノードは、別のノードが同時に削除する行を更新できます。この場合、再生時に UPDATE /DELETE 競合が発生する可能性があります。

削除された行がまだ検出可能な場合 削除された行が VACUUM によって削除されなかった場合、update_recently_deleted 競合が生成されます。デフォルトでは、UPDATE はスキップされますが、この解像度を構成できます。詳細は、

> 列レベルの競合解決の有効化と無効化 を参照してください。

ローカルノードのレプリケーションが遅延している場合、データベースは、UPDATE を受信するまでに削除された行をクリーンアップできます。この場合、PGD は UPDATE /DELETE 競合と *INSERT / UPDATE* の競合 を区別できません。update_missing 競合が生成されます。

競合する DELETE および UPDATE の別のタイプは、行がローカルに更新された後に来る DELETE です。この状況では、結果は使用される競合検出の種類によって異なります。デフォルトの

> オリジンの競合検出 を使用する場合、競合は検出されないため、 DELETE

が適用され、行が削除されます。 行バージョンの競合検出 を有効にすると、delete_recently_updated 競合が生成されます。この競合タイプのデフォルトの解決策は、DELETE を適用し、行を削除することです。ただし、これを構成するか、競合トリガーで処理できます。

INSERT / UPDATE の競合

デフォルトの非同期オペレーションモードを使用している場合、ノードは元の INSERT を受信する前に行の UPDATE を受信する場合があります。これは、3 つ以上のノードがアクティブな場合にのみ発生する可能性があります

> *3* つ以上のノードとの競合 を参照してください。

これが発生すると、update_missing 競合が生成されます。デフォルトの競合リゾルバーは insert_or_skip ですが、代わりに insert_or_error または skip を使用できます。insert-or-action を実行するリゾルバーは、可能な場合行全体が受信されたとき、UPDATE からのデータに基づいて、新しい行を INSERT 試行します。行の再構成を可能にするには、テーブルに REPLICA IDENTITY FULL が必要であるか、行にトーストされたデータが含まれていない必要があります。

トーストされたデータの詳細については、

TOAST サポートの詳細 を参照してください。

INSERT/DELETE の競合

INSERT /UPDATE 競合と同様に、ノードは INSERT をまだ受け取っていない行で DELETE オペレーションを受信する場合があります。これも、3 つ以上のノードがセットアップされている場合にのみ可能です

3 つ以上のノードとの競合 を参照してください。

PGD は現在この競合タイプを検出できません。 INSERT オペレーションは競合タイプを生成せず、 INSERT が適用されます。

DELETE オペレーションは常に delete_missing 競合を生成します。これは、デフォルトでオペレーションをスキップすることにより解決されます。

DELETE/DELETE の競合

DELETE / DELETE 競合は、2 つの異なるノードが同じタプルを同時に削除すると発生します。

このシナリオでは、常に delete_missing 競合が生成されます。これは、デフォルトで、オペレーションをスキップすることにより解決されます。

両方の DELETE 操作は同じ効果があるため、この競合は無害です。それらのいずれかを無視しても安全です。

3 つ以上のノードとの競合

1 つのノードが行を挿入し、それが 2 番目のノードに再生され、そこで更新されると、3 番目のノードは、最初のノードから INSERT を受信する前に、2 番目のノードから UPDATE を受信できます。このシナリオは、INSERT /UPDATE 競合です。

これらの競合は、UPDATE を破棄することにより処理されます。これにより、異なるノードに異なるデータが発生する可能性があります。これらは

多様な競合 です。

この競合タイプは、3 つ以上のマスターでのみ発生する可能性があります。少なくとも 2 人のマスターがアクティブに書き込みを行っている必要があります。

また、ノード 1 からノード 3 へのレプリケーションラグは、次の一連のアクションを許可するように十分に高い必要があります。

1. ノード 2 はノード 1 から INSERT を受信します

2. ノード 2 は UPDATE を実行します

3. ノード 3 はノード 2 から UPDATE を受信します

4. ノード 3 はノード 1 から INSERT を受信します

insert_or_error または場合によっては、 update_missing 競合タイプの insert_or_skip 競合リゾルバーを使用することは、これらの競合の実行可能な緩和戦略です。ただし、このオプションを有効にすると、INSERT /DELETE 競合の扉が開きます。

1. ノード 1 が UPDATE を実行します

2. ノード 2 が DELETE を実行します

3. ノード 3 はノード 2 から DELETE を受信します

4. ノード 3 はノード 1 から UPDATE を受信し、INSERT に変換します

これらが問題である場合は、テーブルまたはデータベースのフリーズ設定を調整して、update_recently_deleted として正しく検出されるようにすることをお勧めします。

> *Eager Replication* **の効果一般** を使用して、これらの競合を防ぐこともできます。

INSERT /DELETE 競合は、3 つ以上のノードで発生する場合もあります。このような競合は、UPDATE が DELETE に置き換えられることを除き、 INSERT /UPDATE と同じです。これにより、delete_missing 競合が発生する可能性があります。

PGD は、 update_missing 競合で発生するように、各 INSERT を最近削除されたチェックにすることを選択できます。ただし、これを行うコストは大部分のユーザーにペナルティを与えるため、現時点では代わりに delete_missing ログに記録されます。

将来のリリースでは、delete_missing 競合が発生したときに *LiveCompare* **によるデータ検証** を使用した再チェックにより、INSERT /DELETE 異常を自動的に解決します。アプリケーションは、bdr.conflict_history_summary ビューを確認することにより、これらを手動で実行できます。

これらの競合は、2 つの主な問題のユースケースで発生する可能性があります。

- INSERT の後にすぐに DELETE が続きます、キューイングアプリケーションで使用できます
- テーブルの主キー識別子が再利用される場合

これらのケースはいずれも一般的なものではありません。これらの問題のあるユースケースが発生した場合、影響を受けるテーブルをレプリケートしないことをお勧めします。

PGD は識別子の一意に依存してレプリケーションが正しく動作するため、後者の場合に問題があります。

同じ一意の識別子を挿入、削除、および後で再利用するアプリケーションは、問題を発生する可能性があります。これは、
> ABA problem として知られています。

PGD は、行が現在の行、最後の行、またはかなり古い行であるかを知る方法がありません。

一意の識別子の再利用は、時間の経過とともに一意の識別を妨げ、監査、トレーサビリティ、および賢明なデータ品質を妨げるため、ビジネス上の問題でもあります。アプリケーションは一意の識別子を再利用する必要はありません。

変更がシステム全体に渡されるまでにかかる時間間隔で発生する識別子の再利用は、問題を発生させます。この時間は通常のオペレーションでは短いかもしれませんが、ダウンノードではその間隔を数時間または数日に延長できます。

アプリケーションは一意の識別子を再利用しないことをお勧めします。その場合、1 年未満は再利用を避けるための措置を講じます。

この問題は、シーケンスまたは UUID を使用するアプリケーションでは発生しません。

外部キーコンストレインの競合

適用されるリモートトランザクションと既存のローカルデータの競合は、FOREIGN KEY FK コンストレインでも発生する可能性があります。

PGD は session_replication_role = 'replica' を使用して変更を適用するため、変更を適用するときに外部キーは再チェックされません。アクティブ/アクティブ環境では、参照テーブルへの挿入と同時に参照先テーブルで削除が発生すると、この状況により FK 違反が発生する可能性があります。このシナリオは、INSERT /DELETE 競合に似ています。

シングルマスター Postgres では、参照先テーブルの値を参照する INSERT /UPDATE は、行レベルのロックを取得する前に、DELETE 操作が完了するまで待機する必要があります。 DELETE が参照値を削除する場合、INSERT /UPDATE は FK チェックに失敗します。

マルチマスター PGD において。ノード間の行レベルのロックはありません。参照テーブルの INSERT は、参照テーブルの DELETE の背後で待機しないため、両方のアクションが同時に発生できます。したがって、参照テーブルのあるノードの INSERT /UPDATE は、別のノードの参照先テーブルの DELETE として同時に値を使用できます。したがって、結果は、参照先テーブルに存在しない参照テーブルの値です。

実際、この状況は、 DELETE 操作が、一般的な操作ではない参照テーブルでの DELETE 操作とは別のトランザクションの参照対象テーブルで発生した場合に発生します。

Orders -> OrderItems のような親子関係では、これは一般的ではありません。OrderItem を完全に削除するよりも、キャンセル済みとしてマークする可能性が高くなります。参照/ルックアップデータの場合、新しいファクトデータに同じ値を使用すると同時にエントリを完全に削除することはまれです。

ぶら下がった FK が可能ですが、一般的にこのリスクは非常に低いです。したがって、PGD は、この場合をカバーする汎用ソリューションを課しません。これが発生する状況を理解すると、2 つの解決策が考えられます。

最初の解決策は、一般的に一度に 1 つのノードのみから変更される、変更の頻度が低い、または変更のコンカレンシーがアプリケーションを介する場合に、密接に関連するエンティティに FK の使用を制限することです。このアプローチでは、アプリケーションレベルでの FK 違反を回避します。

2 番目の解決策は、 PGD 提供のファンクション bdr.ri_fkey_trigger() および bdr.ri_fkey_on_del_trigger() を使用して、この場合から保護するトリガーを追加することです。BEFORE トリガーとして呼び出された場合、これらのファンクションは FOREIGN KEY 情報を使用して、SET NULL 制約があるかのように参照列を NULL に設定することにより FK 異常を回避します。このアプローチでは、1 つのトリガーですべての FK を再チェックするため、FK 違反を防ぐには、テーブルごとにトリガーを 1 つだけ追加する必要があります。

例として、Fact と RefData の 2 つのテーブルがあるとします。Fact には、RefData を参照する FK があります。Fact は参照テーブルであり、RefData は参照されるテーブルです。各テーブルにトリガーを 1 つ追加する必要があります。

RefData で参照されている行が既に削除されている場合、Fact に列を NULL に設定するトリガーを追加します。

```
CREATE TRIGGER bdr_replica_fk_iu_trg
    BEFORE INSERT OR UPDATE ON fact
    FOR EACH ROW
    EXECUTE PROCEDURE bdr.ri_fkey_trigger();

ALTER TABLE fact
    ENABLE REPLICA TRIGGER bdr_replica_fk_iu_trg;
```

RefData テーブルで DELETE が発生したときに、Fact の列を NULL に設定するトリガーを追加します。

```
CREATE TRIGGER bdr_replica_fk_d_trg
    BEFORE DELETE ON refdata
    FOR EACH ROW
    EXECUTE PROCEDURE bdr.ri_fkey_on_del_trigger();

ALTER TABLE refdata
    ENABLE REPLICA TRIGGER bdr_replica_fk_d_trg;
```

両方のトリガーを追加すると、ダングリング外部キーが回避されます。

TRUNCATE の競合

TRUNCATE は、すべての行の DELETE と同様に動作しますが、行ごとに削除するのではなく、テーブルデータを物理的に削除することによりこのアクションを実行します。その結果、行レベルの競合処理は利用できないため、明確な競合が存在する場合でも、TRUNCATE コマンドは他の DML アクションとの競合を生成しません。

その結果、TRUNCATE への他のノードで別の DML が同時に実行される場合、再生の順序により発散的な変更が発生する可能性があります。

次のいずれかのアクションを実行できます。

- TRUNCATE が他のコンカレント DML とともに実行されていないことを確認します。*LiveCompare* によるデータ検証 を利用して、このような不一致を強調表示します。
- TRUNCATE を、 WHERE 句のない DELETE ステートメントに置き換えます。このアプローチは、大規模なテーブルではパフォーマンスが低下する可能性があります。
- Set bdr.truncate_locking = 'on' TRUNCATE コマンドのロック動作を設定します。この設定は、TRUNCATE が bdr.ddl_locking 設定に従うかどうかを決定します。すべてのノードが起動している必要があるため、これは TRUNCATE のデフォルト動作ではありません。この構成は、すべての場合に使用できないか、必要な場合があります。

除外コンストレインの競合

PGD は除外コンストレインをサポートしておらず、その作成を防止します。

既存のスタンドアロンデータベースが PGD データベースに変換される場合、すべての除外制約を手動で削除します。

分散非同期システムでは、異なるノード上のすべてのトランザクションが完全に分離されているため、制約に違反する行セットが存在しないことを保証できません。除外コンストレインは、再生デッドロックを発生させ、排他コンストレイン違反のため、再生がノードから他のノードに進行できません。

PGD に除外制約を作成するように強制するか、スタンドアロンデータベースを PGD に変換するときに既存の制約を削除しない場合、レプリケーションが中断することが予想されます。再び進行させるには、リモートトランザクションを適用できるように、着信リモートタプルが競合するローカルタプルを削除または変更します。

ロールとテーブルスペースの違いによるデータの競合

競合は、ノードにロールのようなグローバル Postgres システム全体のデータが異なる場合にも発生する可能性があります。この競合により、操作主に `DDL` が発生し、1 つのノードで正常に実行してコミットできますが、他のノードへの適用に失敗する場合があります。

たとえば、ノード 1 には fred という名前のユーザーがあり、そのユーザーはノード 2 で作成されたものではない場合があります。ノード 1 の fred がテーブルを作成すると、テーブルは所有者を fred に設定して複製されます。DDL コマンドがノード 2 に適用されると、fred という名前のユーザーが存在しないため、DDL は失敗します。この障害により、Postgres ログにエラーが生成されます。

PGD が実行されているデータベースにユーザー fred を作成することにより、この競合を解決するには、管理者の介入が必要です。将来的にこれを解決するように `bdr.role_replication = on` を設定できます。

ロックの競合とデッドロックアボート

PGD ライタプロセスは通常のユーザーセッションと同じように動作するため、行とテーブルのロックに関する通常のルールの対象となります。これにより、PGD ライタプロセスがユーザートランザクションまたは相互に保持するロックで待機する場合があります。

関連するロックには次のものが含まれます。

- ユーザーセッションによる明示的なテーブルレベルのロック `LOCK TABLE ...`
- ユーザーセッションによる明示的な行レベルのロック `SELECT ... FOR UPDATE/FOR SHARE`
- ローカルアクティビティまたは他のノードからのレプリケーションからの行 `UPDATE` 、`INSERT` 、または `DELETE` 操作のための暗黙的ロック

PGD ライタプロセスは、ユーザートランザクションとデッドロックになる場合があります。ユーザートランザクションは、ライタプロセスが保持するロックで待機しています。その逆も可能です。2 つのライタプロセスが互いにデッドロックする場合もあります。Postgres のデッドロック検出機能は、問題のあるトランザクションのいずれかに介入して終了します。PGD ライタプロセスが終了すると、再試行され、通常は成功します。

これらの問題はすべて一時的なもので、通常、管理者のアクションは必要ありません。ライタプロセスがアイドルなユーザーセッションのロックの背後で長時間スタックしている場合、管理者はユーザーセッションを終了して、レプリケーションフローを再度取得できます。ただし、これは、ユーザーが別のユーザーセッションに影響を与える長いロックを保持していることと変わりません。

Postgres の *log_lock_waits* 機能を使用すると、ロック関連の再生ストールを特定するのに役立ちます。

多様な競合

発散競合は、別のノードで同じであるはずのデータが予期せず異なる場合に発生します。多様な競合は発生すべきではありませんが、執筆時点でこのような競合すべてを確実に防止できるわけではありません。

すべてのノードが変更を再生する前に別のノードが同じ行のキーを変更した場合、行の `PRIMARY KEY` を変更すると、発散競合が発生する可能性があります。主キーの変更を避けるか、1 つの指定ノードでのみ変更します。

行データを含む多様な競合では、一般に、一方のノードのデータを他方のノードと一貫性があるように手動で調整する管理者のアクションが必要です。文書に従って PGD を使用し、安全でないとマークされた設定または機能を回避する限り、このような競合は発生しません。

管理者は、このような競合を手動で解決する必要があります。競合の性質によっては、`bdr.ddl_replication` や `bdr.ddl_locking` などの詳細オプションの使用が必要になる場合があります。ただし、これらのオプションを不注意に使用すると、状況をさらに悪化させ、汎用命令では対処できない競合が発生する可能性があります。

TOAST サポートの詳細

Postgres は、 TOAST と呼ばれる大きな列にアウトオブラインストレージを使用します。

論理デコーディング PGD がその上に構築されるおよび論理レプリケーションでの TOAST 値の処理は、テーブルのメイン行の一部として保存されるインラインデータとは異なります。

TOAST 値は、値が変更された場合にのみトランザクションログ WAL に記録されます。トーストされた列の値を変更しなかった `UPDATE` ステートメントは、その列のない行を生成するため、特に UPDATE の競合を処理する場合に問題が発生する可能性があります。

> *INSERT / UPDATE* **の競合** で述べたように、PGD は、 `insert_or_error`

を使用して `update_missing` 競合が解決され、欠落している TOAST 列がある場合にエラーを報告します。

ただし、非同期レプリケーションと同時ワークロードの場合、これよりも微妙な問題が発生します。Eager トランザクションは影響を受けません。たとえば、A、B、および C と呼ばれる 3 つのノードを持つ EDB Postgres 分散クラスターでの次のワークロードを想像してください。

1. ノード A で txn A1 は UPDATE SETcol1 = ’toast data…’ を実行し、最初にコミットします。

2. ノード B で txn B1 は UPDATE SET other_column = ‘anything else’; そして、A1 の後にコミットします。

3. ノード C では、ノード A への接続が遅れます。

4. ノード C では txn B1 が最初に適用されますが、col1 の TOASTed 列を見逃しますが、競合せずに適用されます。

5. ノード C では、txn A1 は update_origin_change で競合し、スキップされます。

6. ノード C は、A1 からのトーストされたデータを永久に逃します。

PGD を使用する場合、このシナリオは通常問題になりません。PGD は、マルチマスターにビルトイン論理レプリケーションまたはプレーン pglogical のいずれかを使用する場合です。PGD は、 TOAST 列変更を最近レプリケートし、ローカル UPDATE がそうでない行にローカル UPDATE を検出すると、TOAST 列の独自のロギングを追加します。 t TOAST を変更するしたがって、PGD は、異なるノード間でトーストされたデータの不一貫性を防ぎます。この状況により、マルチプルのノードで更新が発生した場合、つまりタプルのオリジンが変更された場合、WAL ログの増加が発生します。通常、PGD AlwaysOn アーキテクチャの場合と同様に、すべての更新が単一のノードから行われる場合、追加の WAL オーバーヘッドはゼロです。

注釈: メインテーブルで同じことをせずに TOAST テーブルのみで `VACUUM FULL` または `CLUSTER` を実行すると、追加のロギングが機能するために必要なメタデータが削除されます。これは、このようなステートメントの後の短期間、これらの同時実行問題に対する保護が存在しないことを意味します。

警告: TOAST の追加 WAL ロギングは、標準の Postgres の `BEFORE UPDATE` トリガーを使用して実行されます。このトリガーは、テーブル上のすべての `BEFORE UPDATE` トリガーの中で、トリガー名に基づいて、アルファベット順に最後にソートする必要があります。これを簡単にするために `zzzz_bdr_` という接頭辞が付いていますが、その後にソートされる名前でトリガーを作成しないようにしてください。そうしないと、同時実行の問題から保護されません。

insert_or_error 競合解決の場合、引き続き REPLICA IDENTITY FULL の使用が必要です。

トーストされた列に関連するこれらの問題は、 REPLICA IDENTITY FULL を使用するテーブルには影響しません。この設定では、行全体がキーの一部と考えられるため、キーの一部としてトースト値が常にログに記録されます。PGD は、新しい行を再構成し、キー行から欠落しているデータを埋めることができます。その結果、REPLICA IDENTITY FULL を使用すると、WAL サイズが大幅に増加する可能性があります。

競合の回避または許容

ほとんどの場合、競合を回避または許容するようにアプリケーションをデザインできます。

競合は、マルチプルのノードで同時に発生している場合にのみ発生します。競合を回避する最も簡単な方法は、1 つのノードにのみ書き込むか、一度に 1 つの特定のノードから特定の方法で特定の行のみに書き込むことです。

この回避は、多くのアプリケーションで自然に発生します。たとえば、多くのコンシューマアプリケーションでは、所有ユーザーのみがアカウントのデフォルトの請求先住所の変更など、データを変更できます。このようなデータの変更では、更新の競合が発生することはほとんどありません。

ノードがダウンする直前に変更を加える可能性があるため、変更は失われるようです。次に、同じ変更を再度行うと、別のノードで 2 つの更新が発生する場合があります。ダウンしたノードが復旧すると、古い変更を他のノードに送信しようとします。データの最終更新が保持されるため、リジェクトされます。

INSERT / INSERT 競合の場合、
PGD グローバルシーケンス を使用してこのタイプの競合を防止します。

部屋予約アプリケーションなどのオブジェクト間の関係を割り当てるアプリケーションの場合、update_if_newer を適用すると、許容できるビジネス結果が得られない場合があります。つまり、同じ部屋を予約したことを 2 人に個別に確認することは役に立ちません。最も簡単な解決策は、Eager Replication を使用して、1 つの予約のみが成功するようにすることです。アプリケーションによっては、より複雑な方法が可能である場合があります。たとえば、各ノードに 100 席を割り当て、そのノードのライタがそれらを予約できるようにします。ただし、ローカルで利用できるものがない場合は、ほとんどのシートが予約された後に分散ロックスキームまたは Eager Replication を使用します。

特定の種類の更新が特定のノードからのみ発生するようにする別の手法は、異なるノードを介して異なる種類のトランザクションをルーティングすることです。例

- 1 つのノードで小包を受信するが、別のノードを使用して小包を配送する
- 1 つのノードで注文が入力され、2 番目のノードで作業が準備され、別のノードで顧客に提供されるサービスアプリケーション

多くの場合、最良のコースは、競合の発生を許可し、競合に対処するために PGD の競合解決メカニズムと連携するようにアプリケーションをデザインすることです。

競合検出

PGD は、競合検出のための次のメカニズムを提供します。

- **オリジンの競合検出** デフォルト
- **行バージョンの競合検出**
- *Column-level conflict detection*

オリジンの競合検出

オリジン競合検出は、トランザクションの発生元のノードに記録されたコミットタイムスタンプを使用および依存します。これには、クロックが正しく動作するか、2 つのノード間の最速のメッセージの許容範囲内に同期している必要があります。これが当てはまらない場合、競合解決はより前にあるノードを優先する傾向があります。パラメーター bdr.maximum_clock_skew および bdr.maximum_clock_skew_action を使用して、ノード間のクロックスキューを管理できます。

行オリジンは、track_commit_timestamp = on の場合にのみ使用できます。

競合は、レプリケーション元が変更されたかどうかに基づいて最初に検出されるため、競合と判明しない可能性のある状況で競合トリガーが呼び出されます。したがって、このメカニズムは正確ではありません、偽陽性の競合を生成する可能性があります。

元の情報は、行がフリーズされた時点まででのみ利用できます。凍結された後に行に到着する更新は競合を発生させないため、すべての場合に適用されます。これは bdr_init_physical によって新しいノードを追加する場合の通常のケースであるため、競合が発生すると、その場合に多くの偽陽性の結果が発生します。

オフラインだったノードが再接続してデータ変更の送信を開始すると、新しく到着した更新が更新する凍結行よりも古い場合、発散エラーが発生する可能性があります。挿入と削除は、この状況の影響を受けません。

> *Node restart and down node recovery* で説明しているように、長時間の停止のためにノードをダウンしたままにしないことをお勧めします。

EDB Postgres Extended Server および EDB Postgres Advanced Server では、ノードがダウンしている間、PGD は行のフリーズを抑制します。このメカニズムはこの状況を適切に処理するため、パラメーター設定を変更する必要はありません。

Postgres の他のバリアントでは、この状況をある程度注意して管理する必要がある場合があります。

フリーズは、通常、バキュームされる行が現在の xid から vacuum_freeze_min_age xid より古い場合に発生します。これは、これらのパラメーターに適切に高い値を構成する必要があることを意味します。

- vacuum_freeze_min_age
- vacuum_freeze_table_age
- autovacuum_freeze_max_age

トランザクションレートに基づいて値を選択し、データベースノードから競合データを削除する前にダウンタイムの猶予期間を与えます。たとえば、vacuum_freeze_min_age が 5 億に設定されている場合、1000TPS を実行するノードは、競合データが削除されるまで 5.5 日強の間ダウンする可能性があります。CommitTS データ構造は、その設定で 5 GB のディスク上の領域を必要とするため、トランザクションレートの低いシステムはより低い設定からメリットを得ることができます。

最初に推奨される設定は次のとおりです。

```
#  1 billion = 10GB

autovacuum_freeze_max_age = 1000000000

vacuum_freeze_min_age = 500000000

#  90% of autovacuum_freeze_max_age

vacuum_freeze_table_age = 900000000
```

次のことに注意してください。

- autovacuum_freeze_max_age はノード起動時にのみ設定できます。
- vacuum_freeze_min_age を設定できるため、低い値を使用すると行が早期にフリーズし、競合が無視される場合があります。個々のテーブルに autovacuum_freeze_min_age および toast.autovacuum_freeze_min_age を設定することもできます。
- CLUSTER または VACUUM FREEZE コマンドを実行しても、行が早期にフリーズされ、競合が無視される場合があります。

行バージョンの競合検出

PGD は、行バージョン管理を使用し、ノードのシステムクロックとは無関係に競合検出を行うオプションを提供します。

行バージョンの競合検出には、3 つのことを有効にする必要があります。これらの手順のいずれかが正しく実行されない場合、
オリジンの競合検出 が使用されます。

- check_full_tuple または PGD ノードグループを有効にします。
- 行バージョンの競合検出を使用するすべてのテーブルで REPLICA IDENTITY FULL を有効にします。
- bdr.alter_table_conflict_detection を使用して、テーブルの行バージョンの追跡を有効にします。このファンクションは、指定した名前の列と、新しい列値を管理する UPDATE トリガーを追加します。列は INTEGER タイプとして作成されます。

カウンタは UPDATE でのみインクリメントされますが、この技術により、UPDATE と DELETE の両方の競合検出が可能になります。

このアプローチはランポートタイムスタンプに似ており、競合検出の ABA 問題を完全に防止します。

注釈: 行レベルの競合解決は、行バージョン管理を使用しても 列レベルの競合解決の有効化と無効化 構成に基づいて処理されます。行バージョンの生成方法は、競合を検出する場合にのみ役立ちます。行のどのバージョンが新しいかに関する信頼できる情報として依存しないでください。

特定のテーブルに使用されている現在の競合解決戦略を判断するには、ビュー bdr.tables の列 conflict_detection を参照してください。

bdr.alter_table_conflict_detection

テーブルの所有者は、特定のテーブルの競合検出がどのように動作するかを変更できます。

概要

```
bdr.alter_table_conflict_detection(relation regclass,
                                   method text,
                                   column_name name DEFAULT NULL)
```

パラメーター

- relation —新しい競合検出方法を設定する関係の名前。
- method —使用する競合検出方法。
- column_name —列検出データの保存に使用する列。これはスキップできます。その場合、列名は競合検出方法に基づいて選択されます。row_origin メソッドは、メタデータストレージに追加の列を必要としません。

競合検出として認識されている方法は次のとおりです。

- row_origin —タプルに加えられた以前の変更のオリジン **オリジンの競合検出** を参照してください。これは、テーブルに追加の列を必要としないサポートされている唯一の方法です。
- row_version —行バージョン列 **行バージョンの競合検出** を参照してください。
- column_commit_timestamp —列ごとのコミットタイムスタンプ *CLCD* を参照してください。
- column_modify_timestamp —列ごとの変更タイムスタンプ *CLCD* で説明

注

column_commit_timestamp と column_modify_timestamp の競合検出方法の違いの詳細については、

現在のタイムスタンプとコミットタイムスタンプ を参照してください。

このファンクションは、 DDL ステートメントと同じレプリケーションメカニズムを使用します。これは、レプリケーションが *ddl filters* 構成の影響を受けることを意味します。

ファンクションは、列レベルの競合解決が有効になっているリレーションで DML グローバルロックを取得します。

このファンクションはトランザクションです。トランザクションの ROLLBACK を使用してエフェクトをロールバックできます。変更は現在のトランザクションに可視されます。

bdr.backwards_compatibility が 30618 以下に設定されていない限り、relation の所有者のみが bdr.alter_table_conflict_detection ファンクションを実行できます。

警告: 追加の列を使用してメタデータを保存する方法から競合検出方法を変更すると、その列がドロップされます。

警告: このファンクションは、*bdr.camo_enable_client_warnings* で警告が無効になっていない限り、CAMO を無効にし、警告を発します。

競合タイプのリスト

PGD は、次の競合タイプを認識し、 conflict_type パラメーターとして使用できます。

- insert_exists —着信挿入は、主キーまたは一意キー/インデックスを介して既存の行と競合します。
- update_differing —着信更新のキー行はローカル行とは異なります。これは、行バージョンの競合検出 を使用する場合にのみ発生する可能性があります。
- update_origin_change —着信更新は、別のノードによって最後に変更された行を変更しています。
- update_missing —着信更新は、存在しない行を変更しようとしています。
- update_recently_deleted —着信更新は、最近削除された行を変更しようとしています。
- update_pkey_exists —着信更新により、 PRIMARY KEY が変更され、変更を適用しているノードに既に存在する値が変更されました。
- multiple_unique_conflicts —受信行は、ターゲットテーブル内の複数の UNIQUE 制約/インデックスと競合します。
- delete_recently_updated —現在のノードまたは行バージョンの競合検出 を使用する場合の行の最新の更新よりも古いコミットタイムスタンプを含む着信削除。
- delete_missing —着信削除は、存在しない行を削除しようとしています。
- target_column_missing —ターゲットテーブルには、受信行に存在する 1 つ以上の列がありません。
- source_column_missing —着信行には、ターゲットテーブルに存在する 1 つ以上の列がありません。
- target_table_missing —ターゲットテーブルがありません。
- apply_error_ddl —レプリケートされた DDL コマンドを適用するときに Postgres によってエラーがスローされました。

競合の解決

ほとんどの競合は自動的に解決できます。PGD は、last-update-wins メカニズム、より正確には update_if_newer 競合リゾルバーにデフォルトで設定されます。このメカニズムでは、競合検出に使用される同じコミットタイムスタンプに基づいて、2 つの競合する行の最後に挿入または変更された行を保持します。特定のコーナーケースのシナリオでの動作は、bdr.create_node_group または bdr.alter_node_group に使用される設定によって異なります。

PGD では、次のファンクションを使用して競合解決のデフォルト動作をオーバーライドできます。

bdr.alter_node_set_conflict_resolver

この機能は、特定のノードでの競合解決の動作を設定します。

概要

```
bdr.alter_node_set_conflict_resolver(node_name text,
                                     conflict_type text,
                                     conflict_resolver text)
```

パラメーター

- node_name —変更されるノードの名前。
- conflict_type —設定を適用する競合タイプ競合タイプのリスト を参照してください。
- conflict_resolver —指定された競合タイプに使用するリゾルバー競合リゾルバーのリスト を参照してください。

注

現在、ローカルノードのみを変更できます。ファンクション呼び出しはレプリケートされません。複数のノードの設定を変更する場合は、各ノードでファンクションを実行する必要があります。

このファンクションによる構成変更は、 bdr.create_node_group または bdr.alter_node_group で指定された競合解決のデフォルト動作をオーバーライドします。

このファンクションはトランザクションです。変更はロールバックできます。それらは現在のトランザクションに表示されます。

競合リゾルバーのリスト

PGD ではいくつかの競合リゾルバーが使用でき、処理できる競合タイプのカバレッジが異なります。

- error —エラーをスローし、レプリケーションを停止します。あらゆる競合タイプに使用できます。
- skip —リモート変更の処理をスキップし、次の変更でレプリケーションを続行します。 insert_exists 、update_differing 、update_origin_change 、update_missing 、update_recently_deleted 、update_pkey_exists 、delete_recently_updated 、delete_missing 、target_table_missing 、target_column_missing 、および source_column_missing 競合タイプに使用できます。
- skip_if_recently_dropped —最近ダウンストリームで 1 日以内にドロップされたため、ダウンストリームが存在しないテーブル用の場合、リモート変更をスキップします。それ以外の場合はエラーをスローします。target_table_missing 競合タイプに使用できます。skip_if_recently_dropped 競合リゾルバーは、同じ名前のテーブルがドロップされた後すぐに再作成される場合、課題を引き起こす可能性があります。その場合、ノードのいずれかが、テーブルを再作成する DDL を参照する前に、再作成されたテーブルの DML を参照する場合があります。次に、テーブルが最近ドロップさ

れたと仮定して、リモートデータを誤ってスキップし、データ損失を引き起こします。したがって、この競合リゾルバーとともにドロップされた直後にオブジェクト名を再利用しないことをお勧めします。

- skip_transaction —競合を生成したトランザクション全体をスキップします。apply_error_ddl 競合に使用できます。
- update_if_newer —リモート行が競合するローカル行よりも後にコミットされた場合に更新されます元ノードの壁時計によって決定されます。タイムスタンプが同じ場合、ノード ID はタイブレーカーとして使用され、すべてのノードで同じ行が選択されるように保証されます。より高いノード ID が勝ちます。insert_exists 、update_differing 、update_origin_change 、および update_pkey_exists 競合タイプに使用できます。
- update —レプリケートされたアクションを常に実行します。insert_exists INSERT を UPDATE に変更します、update_differing 、update_origin_change 、update_pkey_exists 、および delete_recently_updated 削除を実行します。
- insert_or_skip —オリジンから送信された利用可能な情報から新しい行を構築し、INSERT しようとします。完全な行を作成するための十分な情報がない場合、変更をスキップします。update_missing および update_recently_deleted 競合タイプに使用できます。
- insert_or_error —オリジンから送信された利用可能な情報から新しい行を構築し、挿入しようとします。完全な行を構築するために利用できる十分な情報がない場合、エラーをスローし、レプリケーションを停止します。update_missing および update_recently_deleted 競合タイプに使用できます。
- ignore —欠落しているターゲット列を無視して、処理を続行します。target_column_missing 競合タイプに使用できます。
- ignore_if_null —リモート行の追加列に NULL 値が含まれる場合、欠落しているターゲット列を無視します。それ以外の場合は、エラーをスローし、レプリケーションを停止します。target_column_missing 競合タイプに使用できます。
- use_default_value —欠落している列値をデフォルト列のデフォルトの場合は NULL を含むで埋めて、処理を続行します。デフォルトまたは制約違反つまり、NOT NULL 列の NULL デフォルトの処理中にエラーが発生すると、レプリケーションが停止されます。source_column_missing 競合タイプに使用できます。

insert_exists 、update_differing 、update_origin_change 、update_missing 、multiple_unique_conflicts 、update_recently_deleted 、update_pkey_exists 、delete_recently_updated 、および delete_missing 競合タイプは、

競合トリガー を使用するユーザー定義ロジックでも解決できます。

このマトリックスは、競合リゾルバーが処理できる競合タイプを特定するのに役立ちます。

	insert exists	update differing	update origin change	update missing	update recently deleted	update pkey exists	delete recently updated	delete missing	target column missing	source column missing	target table missing	multiple unique conflicts
error	X	X	X	X	X	X	X	X	X	X	X	X
skip	X	X	X	X	X	X	X	X	X	X	X	X
skip_if_rece											X	
update_if_new	X	X	X			X						
update	X	X	X			X	X					X
insert_or_skip				X	X							
insert_or_erro				X	X							
ignore									X			
ignore_if_null									X			
use_default_										X		
conflict_trigger	X	X	X	X	X	X	X	X				X

デフォルトの競合リゾルバー

Conflict type	Resolver
insert_exists	update_if_newer
update_differing	update_if_newer
update_origin_change	update_if_newer
update_missing	insert_or_skip
update_recently_deleted	skip
update_pkey_exists	update_if_newer
multiple_unique_conflicts	error
delete_recently_updated	skip
delete_missing	skip
target_column_missing	ignore_if_null
source_column_missing	use_default_value
target_table_missing	skip_if_recently_dropped
apply_error_ddl	error

競合解決のリスト

競合解決は、競合リゾルバーが選択した解決の種類を表し、競合を解決するために実行された特定のアクションに対応します。

次の競合解決は、`conflict_resolution` パラメーターで現在サポートされています。

- `apply_remote` —リモート着信行が適用されました。
- `skip` —行の処理はスキップされましたローカルでの変更は行われませんでした。
- `merge` —リモート行とローカル行からの情報をマージして、新しい行が作成されました。
- `user` —ユーザーコード競合トリガーは、ターゲットテーブルに書き込まれる行を生成しました。

競合ログ

マルチマスター競合の診断と処理を容易にするために、PGD はデフォルトで、すべての競合を `bdr.conflict_history` テーブルに記録します。次の機能を使用して、この動作をより詳細に変更できます。

bdr.alter_node_set_log_config

ノードの競合ログ構成を設定します。

概要

```
bdr.alter_node_set_log_config(node_name text,
                              log_to_file bool DEFAULT true,
                              log_to_table bool DEFAULT true,
                              conflict_type text[] DEFAULT NULL,
                              conflict_resolution text[] DEFAULT NULL)
```

パラメーター

- node_name —変更されるノードの名前。
- log_to_file —ノードログファイルに記録するかどうか。
- log_to_table — bdr.conflict_history テーブルにログを記録するかどうか。
- conflict_type —ログに記録する競合タイプ。NULL デフォルトはすべてを意味します。
- conflict_resolution —ログへの競合の解決。NULL デフォルトはすべてを意味します。

注

ローカルノードのみを変更できます。ファンクション呼び出しはレプリケートされません。複数のノードの設定を変更する場合は、各ノードでファンクションを実行する必要があります。

このファンクションはトランザクションです。変更はロールバックできます。それらは現在のトランザクションに表示されます。

競合ログ構成のリスト

bdr.node_log_config ビューには、すべてのロギング構成が表示されます。ここには、ロギング構成の名前、ログの場所、およびログに記録される競合のタイプと解決がリストされています。

テーブルへの競合のロギング

log_to_table が true に設定されている場合、競合はテーブルにログに記録されます。競合ログのターゲットテーブルは bdr.conflict_history です。

このテーブルは列 local_time でレンジパーティション化されています。テーブルはオートパーティションで管理されています。デフォルトでは、新しいパーティションは毎日作成され、過去 1 か月の競合が維持されます。その後、古いパーティションは自動的に削除されます。自動パーティションは、事前に 7〜14 のパーティションを作成します。bdr_superuser はこれらのデフォルトを変更できます。

PGD によって管理されるすべてのテーブルで生成された競合はこのテーブルに記録されるため、正当なユーザーのみが競合したデータを読み取ることができるようにすることが重要です。PGD は、 bdr.conflict_history テーブルで ROW LEVEL SECURITY ポリシーを定義することによりこれを行います。テーブルの所有者のみが、各テーブルの競合を読み取ることができます。基になるテーブルに RLS ポリシーが定義、有効化、および適用されている場合、所有者でも競合を読み取ることはできません。FORCE オプションで作成された RLS ポリシーは、テーブルの所有者にも適用されます。その場合、基になるテーブルの一部またはすべての行は、所有者でも読み取ることができない場合があります。したがって、PGD は、競合ログテーブルにより厳密なポリシーも適用します。

デフォルトロール bdr_read_all_conflicts は、 bdr_superuser ロールを付与せずに、bdr.conflict_history テーブルに記録されたすべての競合の詳細を表示する必要があるユーザーに付与できます。

デフォルトロール bdr_read_all_stats は、bdr.conflict_history_summary と呼ばれるカタログビューにアクセスできます。これにはユーザーデータが含まれず、ログに記録される競合の監視ができます。

競合報告

レポートのテーブルに記録された競合を要約できます。レポートにより、アプリケーションの所有者は競合を特定、理解、解決し、競合を防ぐためのアプリケーションの変更を導入できます。

```
SELECT nspname, relname
, date_trunc(day, local_time) :: date AS date
, count(*)
FROM bdr.conflict_history
WHERE local_time > date_trunc(day, current_timestamp)
GROUP BY 1,2,3
ORDER BY 1,2;

 nspname | relname |    date    | count
- --------+---------+------------+-------
 my_app  | test    | 2019-04-05 |     1
(1 row)
```

LiveCompare によるデータ検証

LiveCompare は、2 つのデータベースを比較して、それらが同一であることを確認するように設計されたユーティリティプログラムです。

LiveCompare は PGD スタックの一部として含まれ、PGD ノードの任意のペアを対象とできます。デフォルトでは、レプリケートされたすべてのテーブルを比較し、違いを報告します。LiveCompare は、Postgres や Oracle などの非 PGD データソースでも動作します。

LiveCompare を使用して、着信行を継続的に監視することもできます。コンテキスト情報を失うことなく停止および開始できるため、都合の良いときに実行できます。

LiveCompare では、複数のテーブルを同時にチェックできます。いくつかのテーブル、またはテーブル内の行のセクションのみのチェックを許可するように構成できます。チェックは、最初に行全体のハッシュを比較することにより実行されます。異なる場合、LiveCompare は行全体を比較します。LiveCompare は、有用なサイズのバッチで行を比較することにより、オーバーヘッドを回避します。

違いが見つかった場合は、時間の経過とともに再チェックできるため、最終的な一貫性の遅延が発生します。

詳細については、 *LiveCompare* **によるデータ検証** ドキュメントを参照してください。

8.8.2 Column-level conflict detection

デフォルトでは、競合は行レベルで解決されます。2 つのノードからの変更が競合する場合、ローカルまたはリモートのタプルのいずれかが選択され、他方は破棄されます。たとえば、2 つの競合する変更のコミットタイムスタンプを比較し、新しい方が保持される場合があります。このアプローチでは、すべてのノードが同じ結果に収束し、クラスター全体でコミットオーダーのようなセマンティクスを確立します。

ただし、場合によっては、行レベルではなく列レベルで競合を解決することが適切である場合があります。

テーブル t に 2 つの整数列 a および b と、単一の行 (1,1) がある単純な例を考えます。 1 つのノードで次を実行します。

```
UPDATE t SET a = 100
```

別のノードでは、前述の UPDATE を受信する前に、次のことを同時に実行します。

```
UPDATE t SET b = 100
```

このシーケンスにより、UPDATE-UPDATE 競合が発生します。update_if_newer 競合解決では、コミットタイムスタンプが比較され、新しい行バージョンが保持されます。2 番目のノードが最後にコミットしたと仮定すると、結果は (1,100) であり、列 a への変更を効果的に破棄します。

多くのユースケースでは、この動作は望ましいおよび予想される動作です。ただし、一部のユースケースでは、これが問題になる場合があります。たとえば、アプリケーションの各部分が別のノードに接続され、共有テーブルの列の専用サブセットを更新するマルチノードクラスターを考えます。その場合、さまざまなコンポーネントが競合し、変更を上書きする可能性があります。

このようなユースケースでは、特定のテーブルの競合を列レベルで解決することがより適切である場合があります。これを行うために、PGD は各列の最後の変更のタイムスタンプを個別に追跡し、それを使用して最新の値を選択し、基本的に update_if_newer を実行します。

前の例に適用すると、どのノードもそのような行を認識しないにもかかわらず、結果は両方のノードで (100,100) になります。

列レベルの競合の解決について考えるとき、テーブルを垂直にパーティション化して、各更新が 1 つのスライスのデータのみに影響を与えるようにすると便利です。このアプローチにより、列のさまざまなサブセットへの変更間の競合が排除されます。実際、垂直パーティショニングは、列レベルの競合解決の実用的な代替品です。

列レベルの競合解決には、テーブルに REPLICA IDENTITY FULL が必要です。 bdr.alter_table_conflict_detection ファンクションはそれを確認し、この設定が存在しない場合はエラーで失敗します。

列レベルの競合解決の有効化と無効化

bdr.alter_table_conflict_detection() ファンクションは、列レベルの競合解決を管理します。

例

この例では、テーブル test_table を作成し、その列レベルの競合解決を有効にします。

```
db=# CREATE TABLE my_app.test_table (id SERIAL PRIMARY KEY, val INT);
CREATE TABLE

db=# ALTER TABLE my_app.test_table REPLICA IDENTITY FULL;
ALTER TABLE

db=# SELECT bdr.alter_table_conflict_detection(
db(# my_app.test_table::regclass,
db(# column_modify_timestamp, cts);
 alter_table_conflict_detection
- --------------------------------
 t

db=# \d my_app.test_table
```

ファンクションは、ファンクション呼び出しでの指定に従って cts 列を追加します。また、各変更の前に新しい列のタイムスタンプを維持することを担当する 2 つのトリガー BEFORE INSERT および BEFORE UPDATE も作成します。

新しい列は、デフォルト値で NOT NULL を指定します。これは、ALTER TABLE ... ADD COLUMN がテーブルリライトを実行しないことを意味します。

注釈: *bdr.column_timestamps* データ型の列を他の目的で使用することは避けてください。悪影響を与える可能性があります。たとえば、テーブルを列レベルの競合解決に切り替えますが、これはトリガーがなしでは正しく機能しません。

列レベルの競合解決を含むリストテーブル

次のクエリーを使用して、列レベルの競合解決が有効になっているテーブルをリストできます。このクエリーは、bdr.column_timestamp 型の列の存在を検出します。

```
SELECT nc.nspname, c.relname
FROM pg_attribute a
JOIN (pg_class c JOIN pg_namespace nc ON c.relnamespace = nc.oid)
  ON a.attrelid = c.oid
JOIN (pg_type t  JOIN pg_namespace nt ON t.typnamespace = nt.oid)
  ON a.atttypid = t.oid
WHERE NOT pg_is_other_temp_schema(nc.oid)
  AND nt.nspname = bdr
  AND t.typname = column_timestamps
  AND NOT a.attisdropped
  AND c.relkind IN (r, v, f, p);
```

bdr.column_timestamps_create

このファンクションは、列レベルの競合解決を作成します。column_timestamp_enable 内で呼び出されます。

概要

```
bdr.column_timestamps_create(p_source cstring, p_timestamp timestampstz)
```

パラメーター

- p_source — 2 つのオプションは current または commit です。
- p_timestamp —タイムスタンプは、選択したソースによって異なります。commit の場合は TIMESTAMP_SOURCE_COMMIT 。 current の場合は TIMESTAMP_SOURCE_CURRENT 。

DDL ロック

テーブルの列タイムスタンプを有効または無効にする場合、コードは DDL ロックを使用して、スイッチ前からの保留中の変更がないことを確認します。このアプローチでは、両方のタプルのタイムスタンプと競合のみが表示されないようにします。そうしないと、コードは予期せずローカルタプルのタイムスタンプとリモートタプルの NULL を認識する場合があります。また、変更がすべてのノードで同じ方法列レベルまたは行レベルで解決されることも保証します。

現在のタイムスタンプとコミットタイムスタンプ

重要な決定は、変更された列に割り当てるタイムスタンプです。

デフォルトでは、変更された列に割り当てられたタイムスタンプは、clock_timestamp から取得したかのように、現在のタイムスタンプです。これは簡単で、多くの場合これは正しいですたとえば、競合する行が列の重複しないサブセットを変更する場合。

ただし、さまざまな予期しない影響を与える可能性があります。

- タイムスタンプはステートメントの実行中に変更されます。したがって、UPDATE が複数の行に影響を与える場合、それぞれがわずかに異なるタイムスタンプを取得します。これは、異なるノードで実行された変更がどのようにインターリーブするかに応じて、同時の変更のエフェクトがさまざまな方法で「混合」される可能性があることを意味します。
- タイムスタンプはコミットタイムスタンプとは関係ありません。競合を解決するために使用することは、結果がコミット順序と等価でないこと、つまりシリアル化できない可能性が高いことを意味します。

注釈: 将来的にステートメントとトランザクションのタイムスタンプが追加される可能性があります。これにより、コンカレントのステートメントまたはトランザクションの混合効果に関する問題が解決されます。それでも、これらのオプションはいずれも、コミットオーダーと同等の結果を生成することはできません。

実際のコミットタイムスタンプを使用することもできますが、この機能は実験的だと考えられています。コミットタイムスタンプを使用するには、列レベルの競合解決を有効にするときに最後のパラメーターを true に設定します。

```
SELECT bdr.column_timestamps_enable(test_table::regclass, cts, true);
```

bdr.column_timestamps_disable を使用して無効にできます。

現在、コミットタイムスタンプには、
注 で説明する制限があります。

カラムのタイムスタンプの検査

変更された列のタイムスタンプを格納する列は、トリガーによって維持されます。直接変更しないでください。たとえば、競合がどのように解決されたかを調査しているときに、現在のタイムスタンプ値を検査すると役立つ場合があります。

この目的には 3 つの機能が役立ちます。

- bdr.column_timestamps_to_text(bdr.column_timestamps)

このファンクションは、タイムスタンプマッピングの人間が判読可能な表現を返し、値を text にキャストするときに使用されます。

```
db=# select cts::text from test_table;
                                                    cts
- ------------------------------------------------------------------------------
↪----------------
 {source: current, default: 2018-09-23 19:24:52.118583+02, map: [2 : 2018-09-23␣
↪19:25:02.590677+02]}
(1 row)
```

- bdr.column_timestamps_to_jsonb(bdr.column_timestamps)

このファンクションは、タイムスタンプマッピングの JSONB 表現を変換し、値を jsonb にキャストするときに使用されます。

```
db=# select jsonb_pretty(cts::jsonb) from test_table;
                   jsonb_pretty
- ------------------------------------------------
 {                                                +
     "map": {                                     +
         "2": "2018-09-23T19:24:52.118583+02:00"  +
     },                                           +
     "source": "current",                         +
     "default": "2018-09-23T19:24:52.118583+02:00"+
 }
(1 row)
```

- bdr.column_timestamps_resolve(bdr.column_timestamps, xid)

このファンクションは、最新のトランザクションが既にコミットしている場合、それによって変更された属性のコミットタイムスタンプを使用してマッピングを更新します。これは、コミットタイムスタンプを使用する場合にのみ重要です。たとえば、この場合、最後のトランザクションは 2 番目の属性を更新しました attnum = 2 を使用

```
test=# select cts::jsonb from test_table;
                                                                  cts
- ------------------------------------------------------------------------------
↪--------------------------------------------------
 {"map": {"2": "2018-09-23T19:29:55.581823+02:00"}, "source": "commit", "default":
↪"2018-09-23T19:29:55.581823+02:00", "modified": [2]}
(1 row)

db=# select bdr.column_timestamps_resolve(cts, xmin)::jsonb from test_table;
                                            column_timestamps_resolve
- ------------------------------------------------------------------------------
↪---------------------------------
 {"map": {"2": "2018-09-23T19:29:55.581823+02:00"}, "source": "commit", "default":
↪"2018-09-23T19:29:55.581823+02:00"}
(1 row)
```

CRDT データ型を使用した列の競合の処理

デフォルトでは、列レベルの競合解決は、より高いタイムスタンプを持つ値を選択し、他の値を破棄します。ただし、さまざまなより複雑な方法で競合を調整することはできます。たとえば、情報を破棄せずに競合する値をマージできる CRDT タイプを使用できます。

注

- UPDATE によって変更された属性は、トリガー内の古い行と新しい行を比較することにより決定されます。これは、属性が値を変更しない場合、明示的に設定されていても変更として検出されないことを意味します。たとえば、UPDATE t SET a = a は、 a をどの行でも変更されたものとしてマークしません。同様に、UPDATE t SET a = 1 は、既に 1 に設定されている行の a を変更済みとしてマークしません。
- INSERT ステートメントの場合、新しいものと比較する古い行がないため、すべての属性が変更されたとみなされ、新しいタイムスタンプが割り当てられます。この条件は、INSERT ステートメントに含まれず、デフォルト値を受け取った列にも適用されます。PGD は、デフォルト値を持つ属性を検出できますが、それが自動的に含まれたか明示的に指定されたかどうかを知ることはできません。

この状況は、 INSERT ステートメントで列の別のサブセットを指定している場合でも、INSERT-INSERT 競合では列レベルの競合解決が機能しないことを実質的に意味します。新しい行のタイムスタンプは、古い行よりもすべて新しいです。

- 列を独立して扱うことにより、すべての変更が同じノードで発生した場合に不可能な方法でコンストレインに違反するのが簡単になります。例、次のようなテーブルを考えます。

```
CREATE TABLE t (id INT PRIMARY KEY, a INT, b INT, CHECK (a > b));
INSERT INTO t VALUES (1, 1000, 1);
```

1 つのノードが次のことを行うと仮定します。

```
UPDATE t SET a = 100;
```

別のノードは同時に次のことを行います。

```
UPDATE t SET b = 500;
```

これらの更新はそれぞれ、最初の行で実行されたときに有効であるため、各ノードに渡されます。しかし、他のノードにレプリケートする場合、結果の行は CHECK (A > b) 制約に違反し、問題が手動で解決されるまでレプリケーションは停止します。

- タイムスタンプマッピングを格納する列は自動的に管理されます。結果は予測できない場合があるため、クエリーで値を指定またはオーバーライドしないでください。値は可能な場合に無視されます。
- タイムスタンプマッピングはトリガーによって維持されますが、トリガーの実行順序が重要です。したがって、タプルを変更し、pgl_clcd_ トリガーの後に実行されるカスタムトリガーがある場合、変更された列は正しく検出されません。

- 通常のタイムスタンプを使用して変更またはコミットを順序付ける場合、2 つ以上のノードがたまたま同じタイムスタンプを生成したため、競合する変更のタイムスタンプがまったく同じになる場合があります。このリスクは、通常の行レベルの競合解決でも発生する可能性があるため、列レベルの競合解決に固有ではありません。この状況では、ノード ID がタイブレーカーです。ノード ID が高い方が優先します。このアプローチでは、すべてのノードに同じ変更が適用されます。
- クロックスキューは異なるノード間で発生する可能性があります。やや予期しない動作を誘発し、タイムスタンプが反転されているために新しい変更を破棄する可能性があります。ただし、パラメーター bdr.maximum_clock_skew および bdr.maximum_clock_skew_action を使用してノード間のクロックスキューを管理できます。

```
SELECT bdr.alter_node_group_config(group, ignore_redundant_updates := false);
```

8.8.3 Conflict-free replicated data types

競合のないレプリケートデータ型 CRDT は、従来の解決のように行の 1 つを破棄するのではなく、同時に変更された行からの値のマージをサポートしています。

各 CRDT タイプは、bdr.crdt_handlers カタログに追加される追加のコールバックを備えた別の PostgreSQL データタイプとして実装されます。マージプロセスは、適用側の PGD ライタ内で発生し、ユーザーアクションは必要ありません。

CRDT では、
CLCD で説明しているように、テーブルで列レベルの競合解決を有効にする必要があります。

実行する必要がある唯一のアクションは、整数などの標準のビルトインデータ型ではなく、CREATE / ALTER TABLE で特定のデータ型を使用することです。たとえば、1 つの通常の整数カウンターと単一の行を含む次のテーブルを検討します。

```
CREATE TABLE non_crdt_example (
    id      integer             PRIMARY KEY,
    counter integer             NOT NULL DEFAULT 0
);

INSERT INTO non_crdt_example (id) VALUES (1);
```

2 つのノードで次の SQL を同時に発行するとします。

```
UPDATE non_crdt_example
   SET counter = counter + 1    -- "reflexive" update
 WHERE id = 1;
```

両方の更新を適用した後、次のクエリを使用して結果の値を確認できます。

```
SELECT * FROM non_crdt_example WHERE id = 1;
   id |   counter
 -----+-----------
```

(次のページに続く)

(前のページからの続き)

```
    1 |         1
(1 row)
```

このコードは、 update_if_newer 競合リゾルバーが原因でインクリメントの 1 つが失われたことを示しています。代わりに CRDT カウンターデータ型を使用する場合、結果は次のようになります。

```
CREATE TABLE crdt_example (
    id      integer             PRIMARY KEY,
    counter bdr.crdt_gcounter   NOT NULL DEFAULT 0
);

ALTER TABLE crdt_example REPLICA IDENTITY FULL;

SELECT bdr.alter_table_conflict_detection(crdt_example,
            column_modify_timestamp, cts);

INSERT INTO crdt_example (id) VALUES (1);
```

再度、2 つのノードで次の SQL を同時に発行し、変更が適用されるまで待ちます。

```
UPDATE crdt_example
   SET counter = counter + 1    -- "reflexive" update
 WHERE id = 1;

SELECT id, counter FROM crdt_example WHERE id = 1;
   id |   counter
 -----+-----------
    1 |         2
(1 row)
```

この例は、CRDT が他の方法で競合する非同期同時更新に直面しても、アキュムレータ列が動作できることを示しています。

crdt_gcounter タイプは、例が示すように、 x = x + 1 などの再帰的 UPDATE SQL でのみ動作する状態ベースの CRDT タイプの例です。

bdr.crdt_raw_value 構成オプションは、クエリが現在の値または CRDT タイプの完全な内部状態を返すかどうかを決定します。デフォルトでは、現在の数値のみが返されます。true に設定されている場合、クエリーは完全な状態の表現を結果ます。特殊なハッシュ演算子# を使用して、特殊な演算子デフォルト動作を使用せずに現在の数値のみを要求できます。bdr.crdt_raw_value = on を使用して完全な状態がダンプされた場合、値は bdr.crdt_raw_value = on でのみリロードできます。

注釈: *bdr.crdt_raw_value* は、クライアントに返されたデータ、つまり選択リストの単純な列参照のみのフォーマットを適用します。クエリーの他の部分の列参照たとえば`WHERE` 句または select リストの式などは、 # 演算子を使用する必要がある場合があります。

CRDT データ型の別のクラスは、 *delta CRDT* タイプと呼ばれます。これらは、オペレーションベースの CRDT の特別なサブクラスです。

デルタ CRDT では、値の更新は、同じノード上の以前の値と比較されます。次に、変更は他のすべてのノードにデルタとして適用されます。

```
CREATE TABLE crdt_delta_example (
    id       integer            PRIMARY KEY,
    counter  bdr.crdt_delta_counter NOT NULL DEFAULT 0
);

ALTER TABLE crdt_delta_example REPLICA IDENTITY FULL;

SELECT bdr.alter_table_conflict_detection(crdt_delta_example,
            column_modify_timestamp, cts);

INSERT INTO crdt_delta_example (id) VALUES (1);
```

2 つのノードで次の SQL を同時に発行するとします。

```
UPDATE crdt_delta_example
   SET counter = 2          -- notice NOT counter = counter + 2
 WHERE id = 1;
```

両方の更新を適用した後、次のクエリを使用して結果の値を確認できます。

```
SELECT id, counter FROM crdt_delta_example WHERE id = 1;
   id | counter
 -----+---------
    1 |       4
(1 row)
```

通常の integer 列の場合、結果は 2 になります。ただし、デルタ CRDT カウンターで行を更新する場合、古い行バージョンで開始し、新しい行バージョンを作成し、両方をリモートノードに送信します。そこで、そこにあるバージョンたとえばローカルバージョンなどと比較します。標準 CRDT は NEW と LOCAL バージョンをマージしますが、デルタ CRDT は OLD と NEW バージョンを比較し、デルタをローカルバージョンに適用します。

CRDT タイプは、bdr の一部として bdr スキーマにインストールされます。便宜上、基本的な演算子+ 、# 、および! と多くの一般的な集計関数 min 、max 、sum 、および avg が pg_catalog で作成されます。したがって、search_path を調整せずに使用できます。

重要な問題は、クエリのプランニングと最適化がこれらの新しいデータ型でどのように機能するかです。CRDT タイプは透過的に処理されます。 ANALYZE とオプティマイザーの両方が動作するため、他に何もせずに推定とクエリプランニングは正常に動作します。

状態ベースおよびオペレーションベースの CRDT

[1] の表記に従って、オペレーションベースと状態ベースの CRDT の両方が実装されます。

オペレーションベースの CRDT タイプ CmCRDT

操作は明示的に転送されないが、リモートノードから受け取った古い行と新しい行から計算されるため、操作ベースの型の実装は簡単です。

現在、次のオペレーションベースの CRDT が実装されています。

- `crdt_delta_counter` — `bigint` カウンターインクリメント/デクリメント
- `crdt_delta_sum` — `numeric` sum インクリメント/デクリメント

これらの型は、デルタを計算する少しのコードで既存のデータ型を活用します。たとえば、`crdt_delta_counter` は `bigint` 上のドメインです。

このアプローチは、デルタを計算する方法が知られている型でのみ可能ですが、結果はシンプルで安価、スペースと CPU の両方の点で、いくつかの追加の利点があります。たとえば、基になるデータ型の演算子/構文を活用できます。

主な欠点は、非同期コンカレント環境ではこの値を確実にリセットできないことです。

注釈: カスタムデータタイプを作成し、状態と最後のオペレーションを保存することにより、より複雑なオペレーションベースのタイプを実装できます。すべての変更はデコードされて転送されるため、複数の操作は必要ありません。しかし、その時点で、主な利点単純さ、既存のデータ型の再利用などは、領域要件を除き、状態ベースの型たとえば、まだリセット機能と比較して利点を得ることなく失われます。ノードごとの状態は必要ありません。

状態ベースの CRDT タイプ CvCRDT

状態ベースの型は、より複雑な内部状態を必要とするため、操作ベースの型のように通常のデータ型を直接使用できません。

現在、4 つの状態ベースの CRDT が実装されています。

- `crdt_gcounter` — `bigint` カウンターインクリメント専用
- `crdt_gsum` — `numeric` sum/counter インクリメントのみ
- `crdt_pncounter` — `bigint` カウンターインクリメント/デクリメント
- `crdt_pnsum` — `numeric` sum/counter インクリメント/デクリメント

内部状態には通常、ノードごとの情報が含まれるため、ディスク上のサイズは増加しますが、追加の利点が得られます。カスタムデータ型を実装する必要があるということは、より多くのコード in/out ファンクションと演算子を意味します。

利点は、値を確実にリセットする機能、変更が失われた場合のある程度の自己修復性正常に動作するクラスターでは発生しません、およびソースノード以外のノードから変更を受信できる機能です。

たとえば、ノード A で値が変更され、変更は B にレプリケートされますが、A と C 間のネットワークの問題により C にレプリケートされません。B が値を変更し、この変更が C にレプリケートされる場合、それには A からの元の変更。オペレーションベースの CRDT を使用すると、A-C ネットワーク接続が再び動作し始めるまで、ノード C は変更を受信しません。

CvCRDT の主な欠点は、ディスク領域と CPU 使用率の面でコストが高いことです。クラスターから既に削除されたノードを含む、ノードごとに少しの情報が必要です。状態 varlena タイプにシリアル化の複雑な性質は、CPU 使用量の増加を意味します。

ディスク領域の要件

重要な考慮事項は、CRDT タイプ、特にディスク上のサイズに関連するオーバーヘッドです。

オペレーションベースの型の場合、型は他の型の上のドメインにすぎないため、これは簡単です。ノードの数に関係なく、必要なディスク領域は同じです。

- `crdt_delta_counter` — `bigint` と同じ 8 バイト
- `crdt_delta_sum` — `numeric` と同じ変数、精度とスケールに依存します

操作ベースの CRDT タイプはノードごとの情報を保存しないため、ノードの数への依存関係はありません。

状態ベース型の場合、状況はより複雑です。すべてのタイプは可変長であり、基本的に `bytea` 列として保存され、ヘッダーと、値を変更した各ノードの特定の量のノードごとの情報で構成されています。

`bigint` バリアントの場合、おおよそのサイズを計算する式は次のとおりです。

- `crdt_gcounter` — `32B (header) + N * 12B (per-node)`
- `crdt_pncounter` -— `48B (header) + N * 20B (per-node)`

`N` は、この値を変更したノードの数を示します。

`numeric` バリアントの場合、ヘッダー部分とノードごとの部分の両方に `numeric` 可変長値が含まれるため、正確な式はありません。保持する必要があるこのような値の数を知るには

- `crdt_gsum` - 固定 `20B (header) + N * 4B (per-node)` - 変数 `(2 + N)` `numeric` 値
- `crdt_pnsum` - 固定 `20B (header) + N *4B (per-node)` - 変数 `(4 + 2* N)` `numeric` 値

注釈: 複数のノードで値が更新されない場合、クラスター内のノードの数は関係ありません。また、更新が同時実行されたかどうか、競合が発生したかどうかも関係ありません。

さらに、これらのノードのうちのいくつがクラスターから既に削除されたかは関係ありません。状態を圧縮する方法はまだありません。

CRDT タイプと競合処理

テーブルには CRDT 列と非 CRDT 列の両方を含めることができるため、ほとんどの列は非 CRDT であることが予想されるため、通常の競合解決と CRDT マージの両方を行う必要があります。

競合の解決は最初に発生し、保持するタプル applytuple と破棄するタプルを決定します。次にマージフェーズが発生し、CRDT 列のデータを破棄タプルから適用タプルにマージします。

注釈: この処理により、毎回マージが発生する必要があるため、単純な競合解決に比べて CRDT タイプのコストが多少高くなります。これは、競合解決で高速パスのいずれか現在のトランザクションで変更されたパスなどを使用できる場合でも、当てはまります。

CRDT タイプと競合レポート

デフォルトでは、検出された競合は個別に報告されます。CRDT タイプがなければ、競合解決は本質的に使用可能な情報の半分を破棄するため、これは理にかなっています構成に応じてローカルまたはリモート行。これにより、データの損失が発生します。

CRDT タイプを使用すると、何も捨てずに情報の両方の部分を組み合わせることができ、データ損失の問題を排除します。このアプローチにより、競合報告が不要になります。

このため、CRDT マージによって競合を完全に解決できる場合、競合レポートはスキップされます。各列は、次の 2 つの条件の少なくとも 1 つを満たす必要があります。

- ローカルタプルとリモートタプルの値が同じ NULL または等しい。
- CRDT データ型を使用するため、マージできます。

注釈: CRDT 列はないが、ローカル/リモートタプルのすべての値が等しい場合にも、競合レポートはスキップされます。

CRDT 値のリセット

CRDT 値のリセットは可能ですが、特別な処理が必要です。クラスターの非同期の性質は、実装方法に関係なく、さまざまなノードが変更ストリームのさまざまな場所でリセット操作を認識する可能性があることを意味します。別のノードが同時にリセットを開始する場合があります。つまり、他のノードからリセットを観察する前に。

言い換えれば、リセット操作を正しく動作させるには、通常の操作に対して可換である必要があります。単一ノードでうまく機能する可能性のある値をリセットする多くの単純な方法は、この理由で失敗します。

たとえば、値をリセットする最も簡単なアプローチは次のとおりです。

```
UPDATE crdt_table SET cnt = 0 WHERE id = 1;
```

状態ベースの CRDT では、これは機能しません。他のノードの状態を破棄しますが、ローカルでのみです。リモートノードのマージファンクションによって追加され、値の発散を引き起こし、最終的に他のノードでの変更によりそれを受信します。

オペレーションベースの CRDT では、更新が-cnt の減算として解釈されるため、これは機能するように見える場合があります。ただし、それは同時リセットがない場合にのみ機能します。2 つのノードが同時にリセットを実行しようとすると、デルタが 2 回適用され、負の値を取得しますリセットからは予想されません。

DELETE + INSERT をリセットとして使用できるように見えるかもしれませんが、このアプローチにはいくつかの弱点もあります。行が同じキーで再挿入された場合、他のノードからの変更に関して操作ストリームの同じ位置ですべてのノードがそれを見るという保証はありません。PGD は、コンカレントケースでデータ異常を引き起こす可能性があるため、同じ主キー値の再利用を特にお勧めしません。

状態ベースの CRDT タイプは、次のような特別な! 演算子を使用してリセットを確実に処理できます。

```
UPDATE tab SET counter = !counter WHERE ...;
```

「確実に」とは、値にマルチプルの同時リセットと発散という 2 つの問題がないことを意味します。

オペレーションベースの CRDT タイプは、

Eager Replication **の効果一般** を使用してのみ確実にリセットできます。これは、マルチプルの同時リセットを回避するためです。

Eager Replication を使用して、いずれかの種類の CRDT を特定の値に設定することもできます。

実装された CRDT データ型

現在、6 つの CRDT データ型が実装されています。

- Grow 専用のカウンターと合計
- ポジティブ/ネガティブカウンタと合計
- デルタカウンターとサム

カウンタと合計は、カウンタタイプが整数ベース bigint であるのに対し、sum タイプが 10 進数ベース numeric であることを除き、ほとんど同じ動作をします。

[1] で説明されている追加の CRDT タイプは、後で実装される可能性があります。

次のクエリーを使用して、現在実装されている CRDT データ型をリストできます。

```
SELECT n.nspname, t.typname
FROM bdr.crdt_handlers c
JOIN (pg_type t JOIN pg_namespace n ON t.typnamespace = n.oid)
  ON t.oid = c.crdt_type_id;
```

成長専用カウンター crdt_gcounter

- 非負の値のインクリメントのみをサポート value + int および counter + bigint 演算子。
- # 演算子を使用するか、bigint にキャストすることにより、カウンターの現在値を取得できます。
- counter = value のような単純な割り当てとは互換性がありません。これは、新しい値がアプリケーションのどこかで計算される場合の一般的なパターンです。
- ! 演算子 counter = !counter を使用してカウンターを単純にリセットできます。
- crdt_gcounter_to_text を使用して内部状態を検査できます。

```
CREATE TABLE crdt_test (
    id       INT PRIMARY KEY,
    cnt      bdr.crdt_gcounter NOT NULL DEFAULT 0
);

INSERT INTO crdt_test VALUES (1, 0);      -- initialized to 0
INSERT INTO crdt_test VALUES (2, 129824); -- initialized to 129824
INSERT INTO crdt_test VALUES (3, -4531);  -- error: negative value

- - enable CLCD on the table
ALTER TABLE crdt_test REPLICA IDENTITY FULL;
SELECT bdr.alter_table_conflict_detection(crdt_test, column_modify_timestamp, cts);

- - increment counters
UPDATE crdt_test SET cnt = cnt + 1 WHERE id = 1;
UPDATE crdt_test SET cnt = cnt + 120 WHERE id = 2;

- - error: minus operator not defined
UPDATE crdt_test SET cnt = cnt - 1 WHERE id = 1;

- - error: increment has to be non-negative
UPDATE crdt_test SET cnt = cnt + (-1) WHERE id = 1;

- - reset counter
UPDATE crdt_test SET cnt = !cnt WHERE id = 1;

- - get current counter value
SELECT id, cnt::bigint, cnt FROM crdt_test;

- - show internal structure of counters
SELECT id, bdr.crdt_gcounter_to_text(cnt) FROM crdt_test;
```

Grow-only sum crdt_gsum

- 負でない値のインクリメントのみをサポート sum + numeric 。
- # 演算子を使用するか、numeric にキャストすることにより、合計の現在値を取得できます。
- sum = value のような単純な割り当てとは互換性がありません。これは、新しい値がアプリケーションのどこかで計算される場合の一般的なパターンです。
- ! 演算子 sum = !sum を使用して合計を単純にリセットできます。
- crdt_gsum_to_text を使用して内部状態を検査できます。

```
CREATE TABLE crdt_test (
    id       INT PRIMARY KEY,
    gsum     bdr.crdt_gsum NOT NULL DEFAULT 0.0
);

INSERT INTO crdt_test VALUES (1, 0.0);      -- initialized to 0
INSERT INTO crdt_test VALUES (2, 1298.24); -- initialized to 1298.24
INSERT INTO crdt_test VALUES (3, -45.31);  -- error: negative value

- - enable CLCD on the table
ALTER TABLE crdt_test REPLICA IDENTITY FULL;
SELECT bdr.alter_table_conflict_detection(crdt_test, column_modify_timestamp, cts);

- - increment sum
UPDATE crdt_test SET gsum = gsum + 11.5 WHERE id = 1;
UPDATE crdt_test SET gsum = gsum + 120.33 WHERE id = 2;

- - error: minus operator not defined
UPDATE crdt_test SET gsum = gsum - 15.2 WHERE id = 1;

- - error: increment has to be non-negative
UPDATE crdt_test SET gsum = gsum + (-1.56) WHERE id = 1;

- - reset sum
UPDATE crdt_test SET gsum = !gsum WHERE id = 1;

- - get current sum value
SELECT id, gsum::numeric, gsum FROM crdt_test;

- - show internal structure of sums
SELECT id, bdr.crdt_gsum_to_text(gsum) FROM crdt_test;
```

ポジティブネガカウンター crdt_pncounter

- 正と負の値の両方のインクリメントをサポート counter + int および counter + bigint 演算子を介して。
- # 演算子を使用するか、bigint にキャストすることにより、カウンターの現在値を取得できます。
- counter = value のような単純な割り当てとは互換性がありません。これは、新しい値がアプリケーションのどこかで計算される場合の一般的なパターンです。
- ! 演算子 counter = !counter を使用してカウンターを単純にリセットできます。
- crdt_pncounter_to_text を使用して内部状態を検査できます。

```
CREATE TABLE crdt_test (
    id       INT PRIMARY KEY,
    cnt      bdr.crdt_pncounter NOT NULL DEFAULT 0
);

INSERT INTO crdt_test VALUES (1, 0);      -- initialized to 0
INSERT INTO crdt_test VALUES (2, 129824); -- initialized to 129824
INSERT INTO crdt_test VALUES (3, -4531);  -- initialized to -4531

- - enable CLCD on the table
ALTER TABLE crdt_test REPLICA IDENTITY FULL;
SELECT bdr.alter_table_conflict_detection(crdt_test, column_modify_timestamp, cts);

- - increment counters
UPDATE crdt_test SET cnt = cnt + 1      WHERE id = 1;
UPDATE crdt_test SET cnt = cnt + 120    WHERE id = 2;
UPDATE crdt_test SET cnt = cnt + (-244) WHERE id = 3;

- - decrement counters
UPDATE crdt_test SET cnt = cnt - 73    WHERE id = 1;
UPDATE crdt_test SET cnt = cnt - 19283 WHERE id = 2;
UPDATE crdt_test SET cnt = cnt - (-12) WHERE id = 3;

- - get current counter value
SELECT id, cnt::bigint, cnt FROM crdt_test;

- - show internal structure of counters
SELECT id, bdr.crdt_pncounter_to_text(cnt) FROM crdt_test;

- - reset counter
UPDATE crdt_test SET cnt = !cnt WHERE id = 1;

- - get current counter value after the reset
SELECT id, cnt::bigint, cnt FROM crdt_test;
```

正負の和 crdt_pnsum

- sum + numeric を介して正と負の値の両方のインクリメントをサポートします。
- then # 演算子を使用するか、numeric にキャストすることにより、合計の現在値を取得できます。
- sum = value のような単純な割り当てとは互換性がありません。これは、新しい値がアプリケーションのどこかで計算される場合の一般的なパターンです。
- ! 演算子 sum = !sum を使用して合計を単純にリセットできます。
- crdt_pnsum_to_text を使用して内部状態を検査できます。

```
CREATE TABLE crdt_test (
    id       INT PRIMARY KEY,
    pnsum    bdr.crdt_pnsum NOT NULL DEFAULT 0
);

INSERT INTO crdt_test VALUES (1, 0);       -- initialized to 0
INSERT INTO crdt_test VALUES (2, 1298.24); -- initialized to 1298.24
INSERT INTO crdt_test VALUES (3, -45.31);  -- initialized to -45.31

- - enable CLCD on the table
ALTER TABLE crdt_test REPLICA IDENTITY FULL;
SELECT bdr.alter_table_conflict_detection(crdt_test, column_modify_timestamp, cts);

- - increment sums
UPDATE crdt_test SET pnsum = pnsum + 1.44     WHERE id = 1;
UPDATE crdt_test SET pnsum = pnsum + 12.20    WHERE id = 2;
UPDATE crdt_test SET pnsum = pnsum + (-24.34) WHERE id = 3;

- - decrement sums
UPDATE crdt_test SET pnsum = pnsum - 7.3      WHERE id = 1;
UPDATE crdt_test SET pnsum = pnsum - 192.83   WHERE id = 2;
UPDATE crdt_test SET pnsum = pnsum - (-12.22) WHERE id = 3;

- - get current sum value
SELECT id, pnsum::numeric, pnsum FROM crdt_test;

- - show internal structure of sum
SELECT id, bdr.crdt_pnsum_to_text(pnsum) FROM crdt_test;

- - reset sum
UPDATE crdt_test SET pnsum = !pnsum WHERE id = 1;

- - get current sum value after the reset
SELECT id, pnsum::numeric, pnsum FROM crdt_test;
```

デルタカウンター crdt_delta_counter

- bigint ドメインとして定義されているため、 bigint 列とまったく同様に動作します。
- 正と負の値の両方のインクリメントをサポートします。
- counter = value のような単純な割り当てと互換性があります。これは、新しい値がアプリケーションのどこかで計算される場合に一般的です。
- 値を確実にリセットする簡単な方法はありません。

```
CREATE TABLE crdt_test (
    id       INT PRIMARY KEY,
    cnt      bdr.crdt_delta_counter NOT NULL DEFAULT 0
);

INSERT INTO crdt_test VALUES (1, 0);      -- initialized to 0
INSERT INTO crdt_test VALUES (2, 129824); -- initialized to 129824
INSERT INTO crdt_test VALUES (3, -4531);  -- initialized to -4531

- - enable CLCD on the table
ALTER TABLE crdt_test REPLICA IDENTITY FULL;
SELECT bdr.alter_table_conflict_detection(crdt_test, column_modify_timestamp, cts);

- - increment counters
UPDATE crdt_test SET cnt = cnt + 1      WHERE id = 1;
UPDATE crdt_test SET cnt = cnt + 120    WHERE id = 2;
UPDATE crdt_test SET cnt = cnt + (-244) WHERE id = 3;

- - decrement counters
UPDATE crdt_test SET cnt = cnt - 73    WHERE id = 1;
UPDATE crdt_test SET cnt = cnt - 19283 WHERE id = 2;
UPDATE crdt_test SET cnt = cnt - (-12) WHERE id = 3;

- - get current counter value
SELECT id, cnt FROM crdt_test;
```

デルタサム crdt_delta_sum

- numeric ドメインとして定義されるため、 numeric 列とまったく同様に動作します。
- 正と負の値の両方のインクリメントをサポートします。
- sum = value のような単純な割り当てと互換性があります。これは、新しい値がアプリケーションのどこかで計算される場合に一般的です。
- 値を確実にリセットする簡単な方法はありません。

```
CREATE TABLE crdt_test (
    id       INT PRIMARY KEY,
    dsum     bdr.crdt_delta_sum NOT NULL DEFAULT 0
);

INSERT INTO crdt_test VALUES (1, 0);       -- initialized to 0
INSERT INTO crdt_test VALUES (2, 129.824); -- initialized to 129824
INSERT INTO crdt_test VALUES (3, -4.531);  -- initialized to -4531

- - enable CLCD on the table
ALTER TABLE crdt_test REPLICA IDENTITY FULL;
SELECT bdr.alter_table_conflict_detection(crdt_test, column_modify_timestamp, cts);

- - increment counters
UPDATE crdt_test SET dsum = dsum + 1.32   WHERE id = 1;
UPDATE crdt_test SET dsum = dsum + 12.01  WHERE id = 2;
UPDATE crdt_test SET dsum = dsum + (-2.4) WHERE id = 3;

- - decrement counters
UPDATE crdt_test SET dsum = dsum - 7.33   WHERE id = 1;
UPDATE crdt_test SET dsum = dsum - 19.83  WHERE id = 2;
UPDATE crdt_test SET dsum = dsum - (-1.2) WHERE id = 3;

- - get current counter value
SELECT id, cnt FROM crdt_test;
```

[1] https://en.wikipedia.org/wiki/Conflict-free_replicated_data_type

8.8.4 Eager conflict resolution

Eager 競合解決 Eager Replication としても知られ、COMMIT 決定プロセス中にシリアル化可能なエラーで互いに競合するトランザクションをアボートすることにより、競合を防止します。

グループコミット の競合解決オプションの 1 つとしてコミットスコープ を使用して構成します。

使用法

迅速な競合解決を有効にするには、クライアントをコミットスコープに切り替える必要があります。ここで示すように、セッションレベルまたは個々のトランザクションでそれを使用します。

```
BEGIN;

SET LOCAL bdr.commit_scope = eager_scope;
```

(次のページに続く)

(前のページからの続き)

```
... other commands possible...
```

クライアントは、トランザクションの最後に COMMIT の発行を継続し、PGD に 2 つのフェーズを管理させることができます。

```
COMMIT;
```

この場合、 eager_scope コミットスコープは次のように定義されます。

```
SELECT bdr.add_commit_scope(
    commit_scope_name := eager_scope,
    origin_node_group := top_group,
    rule := ALL (top_group) GROUP COMMIT (conflict_resolution = eager, commit_
↪decision = raft) ABORT ON (timeout = 60s),
    wait_for_ready := true
);
```

エラー処理

PGD がトランザクションを管理することを考えると、クライアントは COMMIT の結果のみを確認する必要があります。これは、シングルノードの Postgres を含む、いかなる場合にもお勧めします。

オリジンノードに障害が発生した場合、残りのノードは最終的に少なくとも ABORT ON timeout の後、グローバルに準備されたトランザクションをロールバックすることを決定します。Raft は、一貫性のないコミットとロールバックの決定を防ぎます。ただし、これには接続されたノードの大部分が必要です。切断されたノードは、必要に応じて最終的にコミットまたはロールバックするようにトランザクションを準備し続け、決定してさらに進行した可能性のあるノードの大部分と調整します。

Eager Replication の効果一般

コミットレイテンシーの増加

同期ステップを追加すると、ノード間の通信が増加し、コミット時のレイテンシーが増加することを意味します。Eager All-Node Replication は、約 2 回のネットワークラウンドトリップ、最悪の場合、最も遠いピアノードまでを追加します。論理スタンバイノードと、まだ参加またはキャッチアップ中のノードは含まれませんが、最終的に変更を受け取ります。

ピアノードがトランザクションのローカルでの準備を確認する前に、それをローカルに適用する必要があります。これにより、トランザクションのサイズによっては、コミットレイテンシーがさらに増加します。この設定は synchronous_commit 設定とは無関係です。

アボート率の増加

シングルノード Postgres、またはデフォルトの非同期レプリケーションモードの PGD でも、COMMIT 時のエラーはほとんどありません。追加された同期手順はエラーのソースを追加するため、アプリケーションはこのようなエラーを適切に処理するように準備する必要があります通常は再試行ループを適用します。

アボートの率は、ワークロードにのみ依存します。多くの行を変更する大規模なトランザクションは、他の同時トランザクションと競合する可能性が非常に高くなります。

8.9 Parallel Apply

8.9.1 パラレル適用とは何ですか?

Parallel apply は、PGD ノードがサブスクリプションごとにマルチプルのライターを使用できるようにする PGD の機能です。この動作は、一般にサブスクリプションのスループットを向上させ、レプリケーションパフォーマンスを向上させます。

Parallel apply が動作している場合、サブスクリプションからのトランザクションの変更は、マルチプルのライターによって書き込まれます。ただし、各ライタは、トランザクションの最終コミットが、オリジンノードで実行されたコミット順序に違反していないことを保証します。違反がある場合は、エラーが生成され、トランザクションをロールバックできます。

このメカニズムは、以前は、次のことがすべて true の場合、結果のエラーがデッドロックとして現れる可能性があることを意味しました。

- トランザクションはコミット保留中で、別のトランザクションが変更する必要がある行を変更します。
- 保留中のトランザクションが実行する前に、オリジンノードで他のトランザクションが実行されました。
- 保留中のトランザクションはロック要求を取り出しました。

さらに、エラーを処理すると、にかかった時間の組み合わせにより、レプリケーションラグが増加する可能性があります。

- デッドロックを検出するには
- クライアントがトランザクションをロールバックする場合
- すでに適用された変更の間接的なガベージコレクションの場合
- 作業をやり直すには

ここで、 PGD 5.2 で導入された Parallel apply のデッドロック緩和が役立ちます。いかなるトランザクションでも、Parallel apply は、現在のトランザクションが書き込む行タプルに既にスケジュールされているトランザクションを調べます。見つかった場合、行は、行に変更を適用する前に、他のトランザクションがコミットされるまで待機する必要があるとしてマークされます。

このアプローチにより、行が正しい順序で書き込まれます。

パラレル適用の構成

2 つの変数は PGD 5 のパラレルアプライを制御します。 *bdr.max_writers_per_subscription* デフォルト 8 および *bdr.writers_per_subscription* デフォルト 2。

```
bdr.max_writers_per_subscription = 8
bdr.writers_per_subscription = 2
```

この構成では、各サブスクリプションに 2 つのライターを与えます。ただし、状況によっては、システムはサブスクリプションに最大 8 つのライターを割り当てる場合があります。

> *bdr.max_writers_per_subscription* は、サーバーを再起動した場合のみ変更できます。

次の方法で、再起動せずに特定のサブスクリプションの *bdr.writers_per_subscription* を変更できます。

1. *bdr.alter_subscription_disable* を使用してサブスクリプションを停止します。

1. 新しい値の設定。

1. *bdr.alter_subscription_enable* を使用してサブスクリプションを再開します。

ただし、最初に、 `select * from bdr.subscription` を使用してサブスクリプションの名前を確立します。この例では、サブスクリプション名は `bdr_bdrdb_bdrgroup_node2_node1` です。

```
SELECT bdr.alter_subscription_disable (bdr_bdrdb_bdrgroup_node2_node1);

UPDATE bdr.subscription
SET num_writers = 4
WHERE sub_name = bdr_bdrdb_bdrgroup_node2_node1;

SELECT bdr.alter_subscription_enable (bdr_bdrdb_bdrgroup_node2_node1);
```

Parallel apply を使用する場合

Parallel apply はデフォルトで常にオンになっており、ほとんどの操作では、オンのままにすることをお勧めします。

PGD 5.2 から、 Parallel apply は CAMO で動作します。 Group Commit または Eager Replication を使用している場合は無効にします。

PGD 5.1 までは、 Group Commit、 CAMO、および Eager Replication で Parallel apply を使用しないでください。これらのシナリオでは、パラレル適用を無効にします。PGD 5.1 以前を使用しているときに、大量のデッドロックが発生している場合は、パラレル適用を無効にするか、アップグレードを検討することもできます。

モニタリング パラレル 適用

Parallel apply のデッドロックの緩和をサポートするために、PGD 5.2 は
bdr.stat_subscription に列を追加します。新しい列は nprovisional_waits

、ntuple_waits 、および ncommmit_waits です。これらは、Parallel apply が、以前はデッドロックであったものをどの程度適切に管理しているかを示すメトリックです。これらはシステム全体のパフォーマンスを反映するものではありません。

nprovisional_waits 値は、同時適用トランザクションによって実行されている同じタプルの操作の数を反映しています。これらは暫定的な待機で、実際にはまだ待機していませんが、待機する可能性があります。

タプルの書き込みが安全に適用できるまで待機する必要がある場合、ntuple_waits でカウントされます。コミットされる前に待機した完全に適用されたトランザクションは、ncommit_waits でカウントされます。

パラレル適用の無効化

Parallel apply を無効にするには、 *bdr.writers_per_subscription* を 1 に設定します。

8.10 Replication sets

レプリケーションセットは、PGD ノードがサブスクライブできるテーブルのグループです。レプリケーションセットを使用して、各ノードが他のノードの正確なコピーである通常の対称マルチマスターよりも複雑なレプリケーショントポロジを作成できます。

すべての PGD グループは、グループと同じ名前のレプリケーションセットを作成します。このレプリケーションセットは、すべてのユーザーテーブルと DDL レプリケーションに使用されるデフォルトのレプリケーションセットです。すべてのノードがそれにサブスクライブされます。つまり、デフォルトでは、すべてのユーザーテーブルがすべてのノード間でレプリケートされます。

8.10.1 レプリケーションセットを使用する

bdr.create_replication_set

を使用して、挿入、更新、削除、または切り捨てアクションを含めるかどうかを指定して、レプリケーションセットを作成できます。1 つのオプションでは既存のテーブルをセットに追加でき、2 番目のオプションでは作成時にテーブルを追加するかどうかを定義します。

テーブルを手動で定義して、レプリケーションセットに追加または削除することもできます。

レプリケーションセットに含まれるテーブルは、ノードがクラスターに参加したときおよびその後に維持されます。

ノードが参加したら、レプリケーションセットからテーブルを削除できますが、再同期操作を使用して新しいテーブルを追加する必要があります。

デフォルトでは、新しく定義されたレプリケーションセットは DDL または PGD 管理ファンクション呼び出しをレプリケートしません。
bdr.replication_set_add_ddl_filter を使用する

複製するコマンドを定義します。

PGD は、すべてのノードでレプリケーションセット定義を作成します。次に、
bdr.alter_node_replication_sets を使用して各レプリケーションセットをパブリッシュまたはサブスクライブするように各ノードを定義できます。

ファンクションを使用して、これらの定義を後で変更したり、レプリケーションセットを削除したりできます。

注釈: 選択的レプリケーションにデフォルトのレプリケーションセットを使用しないでください。クラスター内の PGD ノードにあるデフォルトのレプリケーションセットは、 DDL レプリケーションおよび管理ファンクション呼び出しにもデフォルトで使用されるため、ドロップまたは変更しないでください。

8.10.2 パーティション分割テーブルの動作

PGD は、パーティション化テーブルを透過的にサポートします。つまり、パーティション化されたテーブルをレプリケーションセットに追加できます。

パーティションに関係する変更は、ダウンストリームにレプリケートされます。

注釈: パーティションがパーティションテーブルを介してレプリケートされる場合、パーティションで直接実行されるステートメントは、親テーブルで実行されたときと同じようにレプリケートされます。例外は`TRUNCATE` コマンドであり、これは常に影響を受けるテーブルまたはパーティションのリストを使用して複製します。

個々のパーティションをレプリケーションセットに追加できます。この場合、それらは通常のテーブルと同様に、つまり、ダウンストリームのパーティションと同じ名前のテーブルにレプリケートされます。パーティショニング定義がプロバイダーとサブスクライバーの両方で同じである場合、パーティショニングロジックを実行する必要がないため、この動作にはいくつかのパフォーマンスの利点があります。

注釈: ルートパーティションテーブルがレプリケーションセットの一部である場合、個々のパーティションのメンバーシップは無視されます。そのルートテーブルのメンバーシップのみが考慮されます。

8.10.3 外部キーを使用した動作

外部キー制約は、参照テーブルの各行が参照先テーブルの行と一致することを保証します。したがって、参照テーブルがレプリケーションセットのメンバーである場合、参照されるテーブルも同じレプリケーションセットのメンバーである必要があります。

PGD の現在のバージョンは、この条件を自動的にチェックまたは適用しません。レプリケーションセットにテーブルを追加するとき、データベース管理者は、外部キーによって参照されるすべてのテーブルも追加されていることを確認する必要があります。

次のクエリを使用して、この要件を満たさないすべての外部キーとレプリケーションセットをリストできます。参照テーブルはレプリケーションセットのメンバーですが、参照されるテーブルはレプリケーションセットのメンバーではありません。

```
SELECT t1.relname,
       t1.nspname,
       fk.conname,
       t1.set_name
  FROM bdr.tables AS t1
  JOIN pg_catalog.pg_constraint AS fk
    ON fk.conrelid = t1.relid
   AND fk.contype = f
 WHERE NOT EXISTS (
  SELECT *
    FROM bdr.tables AS t2
   WHERE t2.relid = fk.confrelid
     AND t2.set_name = t1.set_name
);
```

このクエリの出力は次のようになります。

```
 relname | nspname |  conname   | set_name
- --------+---------+------------+----------
 t2      | public  | t2_x_fkey | s2
(1 row)
```

この出力は、テーブル t2 がレプリケーションセット s2 のメンバーであるが、外部キー t2_x_fkey によって参照されるテーブルがそうでないことを意味します。

TRUNCATE CASCADE コマンドは、コマンドをレプリケートする前にレプリケーションセットのメンバーシップを考慮します。例

```
TRUNCATE table1 CASCADE;
```

これは、レプリケーションセットのみの一部であるすべてのテーブルでカスケードなしの TRUNCATE になります。

```
TRUNCATE table1, referencing_table1, referencing_table2 ...
```

8.10.4 レプリケーションセットのメンバーシップ

1 つ以上のレプリケーションセットにテーブルを追加または削除できます。そうすると、これらのテーブルの変更 DML のレプリケーションにのみ影響します。スキーマ変更 DDL は、DDL レプリケーションセットフィルターによって処理されます

> *DDL* レプリケーションフィルタリング を参照してください。

レプリケーションは、ノードレプリケーションセット構成を使用してレプリケーションセットのテーブルメンバーシップを使用して、どのノードにレプリケートするアクションを決定します。決定は、すべてのメンバーシップとレプリケーションセットオプションの和集合を使用して行われます。テーブルが、INSERT アクションのみをレプリケートするレプリケーションセット A と、UPDATE アクションのみをレプリケートするレプリケーションセット B のメンバーであるとします。ターゲットノードがレプリケーションセット A および B の両方にサブスクライブされている場合、INSERT および UPDATE アクションは両方ともレプリケートされます。

> *bdr.replication_set_add_table* および *bdr.replication_set_remove_table* を使用してメンバーシップを制御できます。

8.10.5 レプリケーションセットのリスト

次のクエリーを使用して、既存のレプリケーションセットをリストできます。

```
SELECT set_name
FROM bdr.replication_sets;
```

このクエリを使用して、特定のレプリケーションセット内のすべてのテーブルをリストできます。

```
  SELECT nspname, relname
  FROM bdr.tables
  WHERE set_name = myrepset;

:ref:`外部キーを使用した動作 <外部キーを使用した動作>` は、参照されるテーブルが参照テーブルと同じレプリケーションセットに含まれていないすべての外部キーをリストするクエリーを示しています。
```

次の SQL を使用して、現在のノードが発行およびサブスクライブするレプリケーションセットを表示します。

```
SELECT node_id,
       node_name,
       pub_repsets,
       sub_repsets
  FROM bdr.local_node_summary;
```

このコードは、次のような出力を生成します。

```
  node_id   | node_name |    pub_repsets     |   sub_repsets
- -----------+-----------+--------------------------------------
 1834550102 | s01db01   | {bdrglobal,bdrs01} | {bdrglobal,bdrs01}
(1 row)
```

クラスター内のすべてのノードに対して同じクエリーを実行するには、次のクエリーを使用できます。このアプローチでは、すべてのノードに関連付けられたレプリケーションセットを同時に取得します。

```
WITH node_repsets AS (
  SELECT jsonb_array_elements(
    bdr.run_on_all_nodes($$
        SELECT
          node_id,
          node_name,
          pub_repsets,
          sub_repsets
        FROM bdr.local_node_summary;
    $$)::jsonb
  ) AS j
)
SELECT j->response->command_tuples->0->>node_id AS node_id,
       j->response->command_tuples->0->>node_name AS node_name,
       j->response->command_tuples->0->>pub_repsets AS pub_repsets,
       j->response->command_tuples->0->>sub_repsets AS sub_repsets
FROM node_repsets;
```

これは、例を示します。

```
  node_id   | node_name |    pub_repsets     |    sub_repsets
- -----------+-----------+--------------------------------------
 933864801  | s02db01   | {bdrglobal,bdrs02} | {bdrglobal,bdrs02}
 1834550102 | s01db01   | {bdrglobal,bdrs01} | {bdrglobal,bdrs01}
 3898940082 | s01db02   | {bdrglobal,bdrs01} | {bdrglobal,bdrs01}
 1102086297 | s02db02   | {bdrglobal,bdrs02} | {bdrglobal,bdrs02}
(4 rows)
```

8.10.6 DDL レプリケーションフィルタリング

デフォルトでは、サポートされているすべての DDL のレプリケーションは、デフォルトの PGD グループレプリケーションセットを介して発生します。このレプリケーションは、PGD グループと同じ名前の DDL フィルターを使用して実現されます。このフィルタは、PGD グループの作成時に、デフォルトの PGD グループレプリケーションセットに追加されます。

これは、既存のすべてのレプリケーションセットの DDL レプリケーションフィルターを変更することにより調整できます。これらのフィルターは、レプリケーションセットのテーブルメンバーシップとは独立し

ています。データ変更と同様に、各 DDL ステートメントは、複数のレプリケーションセットの複数のフィルターと一致する場合でも、1 回だけレプリケートされます。

次のクエリーを使用して既存の DDL フィルターをリストできます。これは、フィルターごとに、コマンドタグとロール名に適用された正規表現を示します。

```
  SELECT * FROM bdr.ddl_replication;

:ref:`bdr.replication_set_add_ddl_filter <bdr.replication_set_add_ddl_filter>` および␣
↪:ref:`bdr.replication_set_remove_ddl_filter <bdr.replication_set_remove_ddl_filter>
↪` を使用して、
```

DDL フィルターを操作できます。これらは DDL であると考えられるため、DDL レプリケーションとグローバルロックの対象になります。

8.10.7 選択的レプリケーションの例

この例では、テーブルを特定のノードのグループに選択的にレプリケートするように EDB Postgres 分散を構成します。

クラスター構成

この例では、6 つのデータノードのクラスターが 2 つの場所に data-a1 ～data-a3 および data-b1 ～data-b3 あり、 region_a および region_b グループのメンバーであることによって表されます。

また、お勧めしますが、 region-c の witness という名前の監視ノードもありますが、この例ではそれについて言及する必要はありません。クラスター自分自身の名前は sere になります。

この構成は次のようになります。

これは、

Choosing your architecture セクションで説明した標準の Always-On マルチリージョン構成です。

アプリケーション要件

この例では、音楽作品の公演に出席した人々の意見を記録するアプリケーションを使用します。出席者用のテーブル、作品用のテーブル、そしてどの出席者がどの作品を見た、どこで、いつ、どのように作品を採点したかを記録する意見テーブルがあります。データ規制のため、この例では、意見データは、意見が記録されたリージョンにのみ存在する必要があることを前提としています。

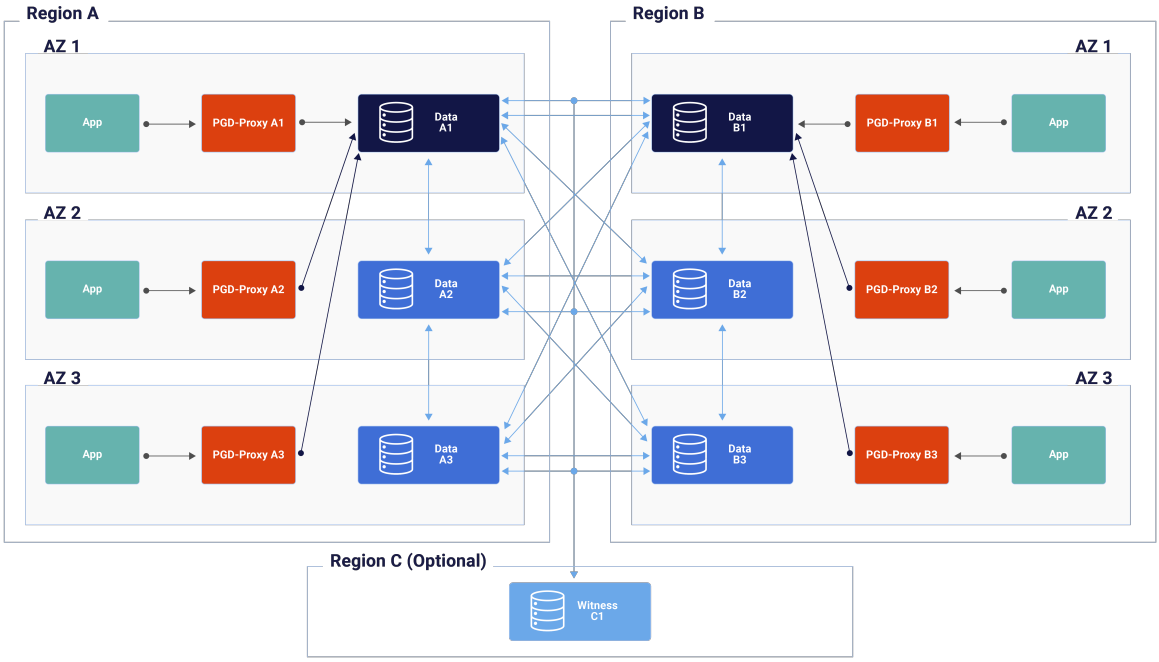


図 1: Multi-Region 3 Nodes Configuration

テーブルの作成

最初の手順は、適切なテーブルを作成することです。

```
CREATE TABLE attendee (
   id bigserial PRIMARY KEY,
   email text NOT NULL
);

CREATE TABLE work (
    id int PRIMARY KEY,
    title text NOT NULL,
    author text NOT NULL
);

CREATE TABLE opinion (
    id bigserial PRIMARY KEY,
    work_id int NOT NULL REFERENCES work(id),
    attendee_id bigint NOT NULL REFERENCES attendee(id),
    country text NOT NULL,
    day date NOT NULL,
    score int NOT NULL
);
```

グループとレプリケーションセットの表示

デフォルトでは、 EDB Postgres 分散は、各テーブル全体を各すべてのノードにレプリケートするように構成されます。これは、レプリケーションセットを介して管理されます。

初期構成のデフォルトのレプリケーションセットを表示するには、次のコマンドを実行します。

```
SELECT node_group_name, default_repset, parent_group_name
FROM bdr.node_group_summary;
```

```
 node_group_name | default_repset | parent_group_name
- ----------------+----------------+-------------------
 sere            | sere           |
 region_a        | region_a       | sere
 region_b        | region_b       | sere
 region_c        | region_c       | sere
```

出力には、sere という名前のデフォルトのレプリケーションセットを含むトップレベルグループ sere があることがわかります。3 つのサブグループには、それぞれ、サブグループと同じ名前のレプリケーションセットがあります。region_a グループには、region_a デフォルトレプリケーションセットがあります。

デフォルトでは、既存のすべてのテーブルと新しいテーブルは、トップレベルグループのレプリケーションセットのメンバーになります。

レプリケーションセットへのテーブルの追加

このプロセスの次のステップは、リージョンを表すグループに属するレプリケーションセットにテーブルを追加することです。前述のように、新しいテーブルはすべて sere レプリケーションセットに自動的に追加されます。次を実行してそれを確認できます。

```
SELECT relname, set_name FROM bdr.tables ORDER BY relname, set_name;
```

```
 relname  | set_name
- ---------+----------
 attendee | sere
 opinion  | sere
 work     | sere
(3 rows)
```

opinion テーブルを region_a 内でのみレプリケートし、別に region_b 内でのみレプリケートする必要があります。そのためには、各リージョンのレプリカセットにテーブルを追加します。

```
SELECT bdr.replication_set_add_table(opinion, region_a);
SELECT bdr.replication_set_add_table(opinion, region_b);
```

ただし、 opinion はまだ sere レプリケーションセットのメンバーであるため、これで完了ではありません。テーブルが複数のレプリケーションセットのメンバーである場合、各テーブル内でレプリケートされ

ます。ただし、各行は各ターゲットノードで 1 回のみレプリケートされるため、これはパフォーマンスに影響を与えません。opinion をすべてのノードでレプリケートしたくないため、トップレベルグループのレプリケーションセットから削除する必要があります。

```
SELECT bdr.replication_set_remove_table(opinion, sere);
```

これらの変更を確認できるようになりました。

```
SELECT relname, set_name FROM bdr.tables ORDER BY relname, set_name;
```

```
 relname  | set_name
- ---------+-------------------
 attendee | sere
 opinion  | region_a
 opinion  | region_b
 work     | sere
(4 rows)
```

これにより、目的の選択的レプリケーションが提供されます。次のステップは、それをテストすることです。

選択的レプリケーションのテスト

いくつかのテストデータ、2 つの作品、1 つの出席者を作成してみましょう。data-a1 に直接接続して、この次のコードを実行します。

```
INSERT INTO work VALUES (1, Aida, Verdi);
INSERT INTO work VALUES (2, Lohengrin, Wagner);
INSERT INTO attendee (email) VALUES (gv@example.com);
```

これらのテーブルにデータが入ったので、外部キー制約に違反せずに opinion テーブルに挿入できます。

```
INSERT INTO opinion (work_id, attendee_id, country, day, score)
SELECT work.id, attendee.id, Italy, 1871-11-19, 3
  FROM work, attendee
 WHERE work.title = Lohengrin
   AND attendee.email = gv@example.com;
```

挿入したら、同じノードでデータベースの内容を検証できます。

```
SELECT a.email
, o.country
, o.day
, w.title
, w.author
, o.score
FROM opinion o
```

(次のページに続く)

(前のページからの続き)

```
JOIN work w ON w.id = o.work_id
JOIN attendee a ON a.id = o.attendee_id;
```

```
    email       | country |    day     |   title   | author | score
- ---------------+---------+------------+-----------+--------+-------
 gv@example.com | Italy   | 1871-11-19 | Lohengrin | Wagner |     3
(1 row)
```

ここで、ノード data-a2 および data-a3 に接続し、同じクエリーを実行すると、同じ結果が得られます。データは region_a で複製されています。 data-b1 、data-b2 または data-b3 に接続する場合、クエリーは行を返しません。これは、 attendee および work テーブルにデータが入力されていますが、選択できる opinion 行がないためです。これは、 region_a での opinion のレプリケーションがそのリージョンでのみ発生するためです。

data-b1 に接続し、次のようにそこに意見を挿入すると

```
INSERT INTO attendee (email) VALUES (fb@example.com);

INSERT INTO opinion (work_id, attendee_id, country, day, score)
SELECT work.id, attendee.id, Germany, 1850-08-27, 9
  FROM work, attendee
 WHERE work.title = Lohengrin
   AND attendee.email = fb@example.com;
```

この意見は region_b でのみ複製されます。 data-b1 、data-b2 、および data-b3 では、次を実行できます。

```
SELECT a.email
, o.country
, o.day
, w.title
, w.author
, o.score
FROM opinion o
JOIN work w ON w.id = o.work_id
JOIN attendee a ON a.id = o.attendee_id;
```

```
    email       | country |    day     |   title   | author | score
- ---------------+---------+------------+-----------+--------+-------
 fb@example.com | Germany | 1850-08-27 | Lohengrin | Wagner |     9
(1 row)
```

各 region_b データノードで同じ結果が表示されます。 region_a ノードでクエリーを実行すると、この特定のエントリは表示されません。

最後に、 attendee テーブルはすべてのノードで同様に共有されることに注意してください。任意のノードで、クエリを実行します。

```
SELECT * FROM attendee;
```

```
         id         |    email
- ------------------+----------------
 904252679641903104 | gv@example.com
 904261037006536704 | fb@example.com
(2 rows)
```

8.11 Application connection management

アプリケーション接続の管理は、高可用性の重要な部分です。

特に非同期レプリケーションの場合、競合を回避し、アプリケーションの可用性を保証するためには、一貫した書き込みリードノードを持つことが重要です。

EDB Postgres Distributed は、PGD プロキシと呼ばれるプロキシレイヤーを提供します。これは、通常、高可用構成リージョンごとに少なくとも 2 つのインスタンスでインストールされます。

PGD プロキシは、 EDB Postgres 分散ノードのいずれかに接続し、 EDB Postgres 分散クラスターによって決定されたとおりにルーティング構成の変更を監視します。これにより、接続が一貫して正しいノードにルーティングされることが保証されます。

8.11.1 構成

ルーティングの構成は、SQL インターフェイスまたは PGD-CLI を介して行われます。

`bdr.alter_node_group_option()` ファンクションを呼び出して、ルーティングの決定を有効にできます。例

```
SELECT bdr.alter_node_group_option(region1-group, enable_proxy_routing, true)
```

同じオプションを `false` に設定することにより、無効にできます。

追加のグループレベルのオプションは、ルーティングの決定に影響します。

- `route_writer_max_lag` —書き込みリーダーとして選択される新しい書き込み候補のバイト単位の最大遅延。これを通過した候補者がない場合、ライタは自動的に選択されません。
- `route_reader_max_lag` —ノードが実行可能な読み取り専用ノードと考えられるバイト単位の最大遅延。将来の使用のために現在予約されています。

ノードごとのルーティングの構成は、 `bdr.alter_node_option()` を使用して設定されます。ルーティングに影響する使用可能なオプションは次のとおりです。

- `route_dsn` —このノードに接続するためにプロキシが使用する dsn。
- `route_priority` —同じノードグループ内の他のノードに対するノードの相対ルーティング優先度。

- route_fence —ノードがルーティングからフェンスされているかどうか、つまり、PGD プロキシから接続を受信できないかどうか。
- route_writes —書き込みをこのノードにルーティングできるかどうか、つまりノードが書き込みリーダーになることができるかどうか。
- route_reads —読み取り専用接続をこのノードにルーティングできるかどうか。将来の使用のために現在予約されています。

SQL インターフェイスを使用してプロキシを構成することもできます。bdr.create_proxy を使用してプロキシ構成を追加できます。たとえば、SELECT bdr.create_proxy('region1-proxy1', 'region1-group'); は、PGD グループ region1-group のメンバーである region1-proxy1 という名前のプロキシのデフォルト構成を追加します。ここで指定されるプロキシの名前は、プロキシ構成ファイルで指定された名前と同じである必要があります。SELECT bdr.drop_proxy('region1-proxy1') を使用してプロキシ構成を削除できます。その結果、プロキシは非アクティブ化されます。

bdr.alter_proxy_option() ファンクションを使用して、プロキシごとにオプションを構成できます。使用可能なオプションは次のとおりです。

- listen_address —リッスンするプロキシのアドレス。
- listen_port —リッスンするプロキシのポート。
- max_client_conn —プロキシが受け入れる接続の最大数。
- max_server_conn —プロキシが Postgres ノードへの接続の最大数。
- server_conn_timeout —サーバー接続の接続タイムアウト。
- server_conn_keepalive —サーバー接続のキープアライブ間隔。
- consensus_grace_period —Raft リーダーを失ってもプロキシがルーティングを継続する期間。 0s に設定されている場合、プロキシはルーティングをすぐに停止します。

すべてのグループの現在の構成は、bdr.node_group_routing_config_summary ビューに表示されます。同様に、bdr.node_routing_config_summary ビューには、現在のノードごとのルーティング構成が表示されます。bdr.proxy_config_summary は、プロキシごとの構成を示します。

スイッチオーバー操作を実行して、書き込みリーダーであるノードを明示的に変更することもできます。これを行うには、bdr.routing_leadership_transfer() ファンクションを使用します。

EDB Postgres Distributed Proxy

EDB Postgres 分散プロキシは、クライアントアプリケーションと Postgres 間の抽象化レイヤーとして機能するデーモンです。PGD コンセンサスメカニズムとインターフェイスして、現在の書き込みリーダーノードの ID を取得し、トラフィックをそのノードにリダイレクトします。

PGD クラスターには、常に少なくとも 1 つのグローバルグループと 1 つのデータグループがあります。PGD は、 enable_proxy_routing および enable_raft オプションが true に設定されている各データグループの書き込みリーダーを選択します。プロキシをグローバルグループまたはデータグループにアタッチできます。各グループに複数のプロキシをアタッチできます。

PGD プロキシは、TCP レイヤー 4 プロキシです。

その仕組み

PGD プロキシは、起動時に、ローカル構成ファイルで指定されたエンドポイントのいずれかに接続します。それは取得します

- 全ノードの DB 接続情報
- リッスンアドレス、リッスンポートなどのプロキシオプション
- 現在の書き込みリーダーなどのルーティングの詳細

構成ファイルで指定されたエンドポイントは、起動時にのみ使用されます。その後、実際のエンドポイントは PGD カタログの `bdr.node_routing_config_summary` の `route_dsn` フィールドから取得されます。

PGD は、書き込みリーダー選択を管理します。PGD プロキシは PGD と対話して、Postgres 通知/リッスンチャネルで書き込みリーダー変更イベント通知を取得し、クライアントトラフィックを現在の書き込みリーダーにルーティングします。PGD プロキシは、書き込みリーダーの変更または書き込みリーダーが使用できないときに、既存のすべてのクライアント接続を切断します。書き込みリーダー選挙は Raft によってサポートされるアクティビティであり、Raft リーダーの可用性の対象となります。書き込みリーダーが使用できない場合、PGD プロキシは新しいクライアント接続を閉じます。

PGD プロキシは、 **フェールオーバー** と **スイッチオーバー**の 2 つの操作モードに分類できる書き込みリーダー変更イベントに応答します。

Postgres またはオペレーティングシステムがクラッシュした場合に、現在の書き込みリーダーノードから新しいノードへの書き込みリーダーシップの自動転送は、フェールオーバーと呼ばれます。PGD は、現在の書き込みリーダーがダウンするか、応答しなくなると、新しい書き込みリーダーを選択します。新しい書き込みリーダーが PGD によって選択されると、PGD プロキシは古い書き込みリーダーへの既存のクライアント接続を閉じ、新しいクライアント接続を新しく選択された書き込みリーダーにリダイレクトします。

現在の書き込みリーダーから新しいターゲットリーダーへのユーザー制御の手動転送は、スイッチオーバーと呼ばれます。スイッチオーバーは、
PGD CLI switchover コマンドを介してトリガーされます。コマンドは PGD に送信され、指定されたターゲットノードを新しい書き込みリーダーとして選択しようとします。フェールオーバーと同様に、

PGD プロキシは既存のクライアント接続を閉じ、新しいクライアント接続を新しく選択された書き込みリーダーにリダイレクトします。これは、サーバーのメンテナンス中に、たとえば、サーバーの更新や OS パッチの更新などのメンテナンスのために現在の書き込みリーダーノードを停止する必要がある場合に役立ちます。

コンセンサス猶予期間

PGD プロキシは、Raft リーダーの喪失時のルーティング動作を構成するために使用できる consensus_grace_period プロキシオプションを提供します。PGD プロキシは、この期間にわたって現在の書き込みリーダー利用可能な場合にルーティングし続けます。この期間中に新しい Raft リーダーが選出されない場合、プロキシはルーティングを停止します。`0s` に設定されている場合、PGD プロキシはルーティングをすぐに停止します。

このオプションの主な目的は、Raft リーダーが失われたときにユーザーが書き込み動作を構成できるようにすることです。Raft リーダーがクラスターに存在しない場合、プロキシから見られる現在の書き込みリーダーが正しいものであるとは、必ずしも保証されません。場合によっては、次の例のネットワークパーティ

ションのように、2 つの書き込みリーダーが、同じグループに接続された 2 つの異なるプロキシによって認識され、書き込み競合の可能性が増加する可能性があります。これが目的の動作でない場合は、前述の `consensus_grace_period` を 0 に設定できます。この設定は、Raft リーダーが失われたことを検出すると、ルーティングを停止し、既存のオープン接続をすぐに閉じるようにプロキシを構成します。

ネットワークパーティションの例

各データノードにプロキシがある 3 つのデータノードグループを検討します。この場合、現在の書き込みリーダーがネットワーク分割または分離されると、マジョリティパーティションに存在するデータノードが新しい書き込みリーダーを選択します。`consensus_grace_period` がゼロ以外の値 `10s` に設定されている場合、以前の書き込みリーダーに存在するプロキシは、この期間書き込みをルーティングし続けます。

この場合、猶予期間が長すぎると、2 つの書き込みリーダーで書き込みが発生し続けます。この条件により、書き込み競合が発生する可能性が増加します。

そうは言っても、ほとんどの場合、現在の Raft リーダーを失うと、ノードクォーラムの半分以上がまだ残っている場合、新しい Raft リーダーは数秒以内に BDR によって選択されます。したがって、Raft リーダーがダウンしているが、書き込みリーダーがまだアップしている場合、`consensus_grace_period` をゼロ以外の正の値に保つことにより、ルーティングを許可するようにプロキシを構成できます。プロキシは、ルーティングを停止する前に、この期間に Raft リーダーが選出されるのを待ちます。これは、可用性がより重要な場合に役立つ場合があります。

マルチホスト接続文字列

PostgreSQL C クライアントライブラリ libpq を使用すると、単純なフェイルオーバーのために単一の接続文字列で複数のホスト名を指定できます。これは、他の一部のプログラミング言語のクライアントライブラリドライバーでもサポートされています。ダウンまたはアクセス不能な PGD プロキシインスタンス全体のフェイルオーバーに適しています。

ただし、PGD プロキシインスタンスにアクセスできるが、書き込みリーダーにアクセスできない場合、または特定のインスタンスの書き込みリーダーが存在しない場合、つまり、特定の PGD グループに書き込みリーダーがないため、接続単に失敗するだけです。マルチホスト接続文字列内の他のホストは試行されません。この動作は、HAProxy や pgbouncer などの他のプロキシを使用した PostgreSQL クライアントライブラリの動作と一貫しています。

PGD プロキシの管理

PGD CLI は、 `create-proxy` 、`delete-proxy` 、`set-proxy-options` 、`show-proxies` など、PGD クラスターでプロキシを管理するためのいくつかのコマンドを提供します。詳細については、

> *Configuring PGD CLI* を参照してください。

PGD プロキシの構成と管理の PGD 側の詳細については、
> 接続管理 を参照してください。

プロキシのヘルスチェック

PGD プロキシは、次の HTTP ヘルスチェック API エンドポイントを提供します。API エンドポイントは GET 要求に応答します。使用する前にそれらを有効にして構成する必要があります。

> 競合ログ構成のリスト を参照してください。

```
GET /health/is-ready
GET /health/is-live
```

準備状況

有効な GET 要求を受信すると、プロキシは現在の書き込みリーダーに接続を正常にルーティングできるかどうかを確認します。チェックが正常に返された場合、API は true と HTTP ステータスコード 200 (OK) を含む本文で応答します。それ以外の場合、false を含む本文を HTTP ステータスコード 500 (Internal Server Error) とともに返します。

ライブネス

Liveness チェックは、HTTP ステータスコード 200 (OK) を含む true または Error のいずれかを返します。PGD プロキシサービスが開始に失敗するか終了すると、要求をリッスンする HTTP サーバーが停止するため、false は返されません。

プロキシログの場所

syslog

- Debian ベース - /var/log/syslog
- Red Hat ベース - /var/log/messages

journalctl コマンドを使用して、プロキシのトラブルシューティングのためのログをフィルタリングおよび表示します。以下は、クイックリファレンスのためのいくつかのサンプルコマンドです。

```
journalctl -u pgd-proxy -n100 -f
journalctl -u pgd-proxy --since today
journalctl -u pgd-proxy --since "10 min ago"
journalctl -u pgd-proxy --since "2022-10-20 16:21:50" --until "2022-10-20 16:21:55"
```

Installing PGD Proxy

PGD プロキシのインストール

2 つの方法を使用して、PGD プロキシをインストールして構成し、 EDB Postgres 分散クラスターを管理できます。PGD プロキシをインストールして構成する推奨方法は、クラスターの展開と管理に EDB Trusted Postgres ArchitectTPA ユーティリティを使用することです。

TPA を介したインストール

PGD クラスターが TPA を介して展開されている場合、TPA は推奨アーキテクチャに従って、PGD プロキシを自動的にインストールおよび構成します。PGD クラスター内の他のノードに PGD プロキシをインストールする場合は、TPA 構成ファイルでそのインスタンスに pgd-proxy ロールをアタッチする必要があります。また、この例が示しているように、展開する前に bdr_child_group パラメーターを設定します。詳細については、

Deploying EDB Postgres Distributed using Trusted Postgres Architect を参照してください。

```
- Name: proxy-a1
  location: a
  node: 4
  role:
  - pgd-proxy
  vars:
    bdr_child_group: group_a
  volumes:
  - device_name: /dev/sdf
    volume_type: none
```

構成

PGD プロキシは、プロキシオプションの取得や書き込みリーダーの詳細の取得などの内部操作を行うために PGD データベースに接続します。したがって、PGD ノードに接続するにはエンドポイント/dsn のリストが必要です。PGD プロキシは、これらの構成をローカル構成ファイル pgd-proxy-config.yml で想定しています。次に、pgd-proxy-config.yml ファイルの作業例を示します。

```
log-level: debug
cluster:
  name: cluster-name
  endpoints:
    - "host=bdr-a1 port=5432 dbname=bdrdb user=pgdproxy "
    - "host=bdr-a3 port=5432 dbname=bdrdb user=pgdproxy "
    - "host=bdr-a2 port=5432 dbname=bdrdb user=pgdproxy "
  proxy:
    name: "proxy-a1"
```

デフォルトでは、TPA を介して作成されたクラスターでは、pgd-proxy-config.yml は/etc/edb/pgd-proxy ディレクトリにあります。PGD プロキシは、次の場所で pgd-proxy-config.yml を検索します。優先順位は高から低です。

1./etc/edb/pgd-proxy デフォルト 2.$HOME/.edb/pgd-proxy

ファイルの名前を変更するか、別の場所に移動する場合は、サービスを開始するときにオプションの-f または--config-file フラグを使用して、新しい名前と場所を指定します。

> *sample service file* を参照してください。

サンプル構成に示すように、トップレベルの構成パラメーター log-level を使用して、PGD プロキシサービスのログレベルを設定できます。log-level の有効な値は、debug 、info 、warn 、および error です。

cluster.endpoints および cluster.proxy.name は、構成ファイルの必須フィールドです。PGD プロキシは、常にリストの最初のエンドポイントに接続しようとします。失敗した場合は、次のエンドポイントを試行します。以下、同様に。

PGD プロキシは、プロキシのスタートアップにのみローカル構成ファイルで指定されたエンドポイントを使用します。その後、PGD プロキシは、PGD プロキシカタログから実際のエンドポイント route_dsn のリストを取得します。したがって、各 PGD プロキシノードにノードオプション route_dsn を設定する必要があります。詳細については、

> *route_dsn* を参照してください。

ヘルスチェックの構成

PGD プロキシは、

> *HTTP(S) health check APIs* を提供します。ヘルスチェックが必要な場合は、次の構成パラメーターを pgd-proxy 構成ファイルに追加することにより、有効にできます。デフォルトでは、無効になっています。

```
cluster:
  name: cluster-name
  endpoints:
    - "host=bdr-a1 port=5432 dbname=bdrdb user=pgdproxy "
    - "host=bdr-a3 port=5432 dbname=bdrdb user=pgdproxy "
    - "host=bdr-a2 port=5432 dbname=bdrdb user=pgdproxy "
  proxy:
    name: "proxy-a1"
    endpoint: "host=proxy-a1 port=6432 dbname=bdrdb user=pgdproxy "
    http:
      enable: true
      host: "0.0.0.0"
      port: 8080
      secure: false
      cert_file: ""
      key_file: ""
```

(次のページに続く)

(前のページからの続き)

```
    probes:
      timeout: 10s
```

構成 cluster.proxy.http.enable: true を追加することにより、API を有効にできます。有効にすると、HTTP サーバーはデフォルトポート 8080 でリッスンし、10 秒の timeout と HTTPS サポートなし。

HTTPS を有効にするには、構成パラメーター cluster.proxy.http.secure: true を設定します。 true に設定されている場合、 cert_file および key_file も設定する必要があります。

cluster.proxy.endpoint は、プロキシがチェックの一部として現在の書き込みリーダーに接続するために使用されるエンドポイントです。cluster.proxy.http.enable が true の場合、cluster.proxy.endpoint も設定する必要があります。これは、 BDR ノード

routing_dsn と同じにすることができます。ホストは listen_address

、ポートは listen_port *proxy options* です。必要に応じて、このエンドポイントに sslmode 、sslrootcert 、user などの接続文字列パラメーターを追加できます。

PGD プロキシユーザー

エンドポイントで指定されたデータベースユーザーは、スーパーユーザーである必要はありません。通常、TPA 環境では、pgdproxy は OS ユーザーであるだけでなく、bdr_superuser ロールを持つデータベースユーザーでもあります。

PGD プロキシサービス

PGD プロキシを systemd サービスとして実行することをお勧めします。pgd-proxy サービスユニットファイルは、デフォルトで/etc/systemd/system/pgd-proxy.service にあります。次に、TPA によって作成されたサンプルサービスファイルを示します。

```
[Unit]
Description=PGD Proxy

[Service]
Type=simple
User=pgdproxy
Group=pgdproxy
Restart=on-failure
RestartSec=1s
ExecStart=/usr/bin/pgd-proxy -f /etc/edb/pgd-proxy/pgd-proxy-config.yml
StandardOutput=syslog
StandardError=syslog
SyslogIdentifier=pgd-proxy

[Install]
WantedBy=multi-user.target
```

次のコマンドを使用して、pgd-proxy サービスを管理します。

```
systemctl status pgd-proxy
systemctl stop pgd-proxy
systemctl restart pgd-proxy
```

手動インストール

PGD リポジトリから入手できる.deb および.rpm パッケージを使用して、Linux マシンに PGD プロキシを手動でインストールできます。パッケージ名は edb-pgd5-proxy です。例

```
#  for Debian

sudo apt-get install edb-pgd5-proxy
```

Proxies, Raft, and Raft subgroups

PGD は、トップレベルグループが PGD インストール内のすべてのデータノードにまたがる Raft モデルを使用してメタデータを管理します。Raft リーダーは、トップレベルグループによって選出され、トップレベルグループの状態をグループ内の他のすべてのノードに伝播します。

トップレベルグループの特定の操作では、Raft リーダーを確立して接続することが重要です。これらの操作の例には、ノードの追加と削除、**ローカルシーケンスの** *galloc* **シーケンスへの変換** シーケンスのレンジの割り当てが含まれます。

また、トップレベルグループのノードの絶対大多数それらの半分と 1 つが相互に到達できる必要があることも意味します。したがって、5 つのノードを持つトップレベルグループでは、Raft リーダーを確立するには、少なくとも 3 つのノードが相互に到達可能である必要があります。

プロキシルーティング

同じく Raft を使用する機能の 1 つがプロキシルーティングです。プロキシルーティングでは、プロキシがノードのグループ内のデータノードへの書き込みを調整できる必要があります。このデータノードは書き込みリーダーです。書き込みリーダーがオフラインになった場合、プロキシはデータノードによって選択された新しい書き込みリーダーに切り替えて、接続されたアプリケーションの継続性を維持できる必要があります。

PGD 5 ではノードグループごとにプロキシルーティングを構成できますが、推奨される構成は**グローバル**および **ローカル** ルーティングです。

グローバルルーティング

グローバルルーティングは、トップレベルグループを使用してプロキシルーティングを管理します。グループ内のすべての書き込み可能なデータノード監視またはサブスクライブ専用ノードではないは、すべてのプロキシの書き込みリーダーになる資格があります。トップレベルグループ内のプロキシへの接続は、トップレベルグループ内のデータノードにルーティングされます。

グローバルルーティングでは、トップレベルグループ全体に対して書き込みリーダーが 1 つだけあります。

ローカルルーティング

ローカルルーティングは、多くの場合場所にマッピングされるサブグループを使用して、サブグループ内のプロキシルーティングを管理します。ローカルルーティングは、書き込みを地理的に分離するために使用されることがよくあります。トップレベルのコンセンサスが失われた場合でも、ルーティングを継続することが重要です。

これは、PGD を使用すると、トップレベルのコンセンサスが失われた場合でも、クエリと非同期データ操作 DML が機能するためです。しかし、グローバルルーティングの場合と同様に、トップレベルコンセンサスを使用することは、そのコンセンサスが失われた場合に新しい書き込みリーダーを選択できないことを意味します。ローカルグループは、独立したコンセンサスメカニズムとその複雑性を追加せずに、トップレベルのコンセンサスに依存することはできません。

PGD 5 では、この問題にエレガントに対処するためにサブグループ Raft サポートを導入しました。サブグループ Raft のサポートにより、PGD トップレベルグループのサブグループは、必要なリーダーを独立して選択できます。彼らは、他のサブグループまたはトップレベルの Raft コンセンサスから独立して書き込みリーダーを選択できる委任された Raft グループを形成することによりこれを行います。サブグループ内のプロキシへの接続は、サブグループ内のデータノードにルーティングされます。

ローカルルーティングでは、各サブグループに書き込みリーダーがあります。

詳細情報

- *Raft subgroups and TPA* は、 Trusted Postgres Architect で展開するときに PGD で Raft サブグループを有効にする方法を示します。
- *Working with Raft subgroups and PGD CLI* は、 PGD CLI が Raft サブグループの存在とステータスをレポートする方法を示します。
- *Migrating to Raft subgroups* は、既存のインストールを移行し、TPA を使用せずに Raft サブグループを有効にするガイドです。
- *Raft elections in depth* は、Raft を使用して書き込みリーダーが選択される方法を詳細に調べます。

Creating Raft subgroups using TPA

`--enable_proxy_routing local` オプションが設定されている場合、`TPAexec configure` コマンドは Raft サブグループを有効にします。 TPA は**ロケーション**という用語を使用して、物理/地域ドメインにマッピングするサブグループの一般的なユースケースを反映しています。構成が生成されると、指定されたロケーション名は、ロケーション名に基づいて、生成されたグループ名の下に保存されます。

TPA を使用して Raft サブグループを作成する

この例では、各場所に 3 つのデータノードを持つ 2 つの場所のクラスターを作成します。各ロケーションのノードは、ロケーションの PGD Raft サブグループの一部です。

トップレベルグループの名前は `pgdgroup` です。

トップレベルグループには、`us_east` および `us_west` の 2 つの場所があります。これらの場所は、2 つのサブグループ `us_east_subgroup` および `us_west_subgroup` にマッピングされます。

各ロケーションには 4 つのノードがあります。3 つのデータノードと 1 つのバーマンバックアップノード。3 つのデータノードは、PGD プロキシも共同ホストします。構成は次のように視覚化できます。

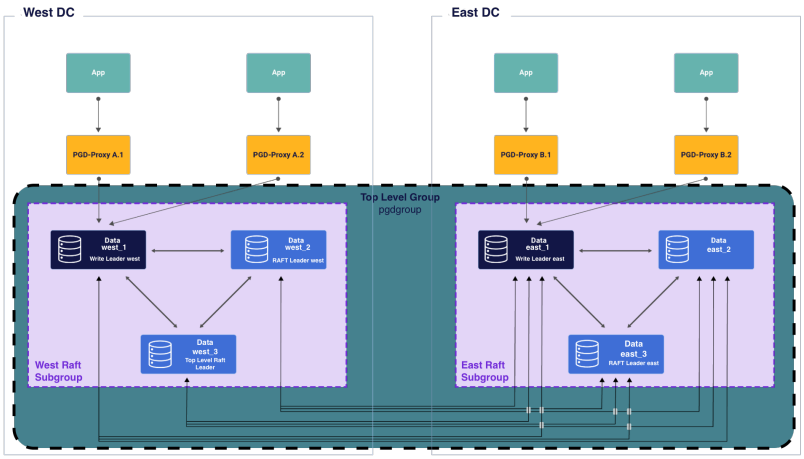


図 2: 6 Node Cluster with 2 Raft Subgroups

barman ノードはサブグループ、ひいては Raft グループに参加しません。したがって、それらは表示されません。この図は、West Raft グループが書き込みリーダーとして west_1 を選択し、west_2 を独自の Raft リーダーとして選択したクラスターの潜在的な状態のスナップショットです。East では、east_1 が書き込みリーダーであり、east_3 が Raft リーダーです。クラスター全体は、トップレベルの Raft グループ内に含まれます。そこで、west_3 は現在 Raft のリーダーです。

この構成を作成するには、次を実行します。

```
tpaexec configure pgdgroup --architecture PGD-Always-ON --location-names us_east us_
↪west --data-nodes-per-location 3 --epas 15 --no-redwood --enable_proxy_routing␣
↪local --hostnames-from hostnames.txt
```

`hostnames.txt` には以下が含まれます。

```
east1
east2
east3
eastbarman
west1
west2
west3
westbarman
```

構成ファイル

生成された config.yml ファイルには、トップレベルグループ pgdgroup と 2 つのサブグループ us_east_subgroup および us_west_subgroup を含む bdr_node_groups セクションがあります。これらのサブグループには、ロケーションセット us_east および us_west と、true に設定されている他の 2 つのオプションがあります。

- enable_raft 、サブグループ内のサブグループ Raft をアクティブにする
- enable_proxy_routing pgd_proxy ルーターがトラフィックをサブグループの書き込みリーダーにルーティングできるようにします

次に、サンプルの tpaexec コマンドによって生成された例を示します。

```
cluster_vars:
  apt_repository_list: []
  bdr_database: bdrdb
  bdr_node_group: pgdgroup
  bdr_node_groups:
  - name: pgdgroup
  - name: us_east_subgroup
    options:
      enable_proxy_routing: true
      enable_raft: true
      location: us_east
    parent_group_name: pgdgroup
  - name: us_west_subgroup
    options:
      enable_proxy_routing: true
      enable_raft: true
      location: us_west
    parent_group_name: pgdgroup
  bdr_version: 5
```

すべてのノードインスタンスには、インスタンスリストのエントリがあります。そのエントリでは、bdr_child_group が変数セクションに表示され、ノードが属するサブグループに設定されます。次に、サンプルの tpaexec コマンドによって生成された例を示します。

```
instances:

- Name: east1
  backup: eastbarman
  location: us_east
  node: 1
  role:
  - bdr
  - pgd-proxy
  vars:
    bdr_child_group: us_east_subgroup
    bdr_node_options:
      route_priority: 100

- Name: east2
  location: us_east
  node: 2
  role:
  - bdr
  - pgd-proxy
  vars:
    bdr_child_group: us_east_subgroup
    bdr_node_options:
      route_priority: 100

- Name: east3
  location: us_east
  node: 3
  role:
  - bdr
  - pgd-proxy
  vars:
    bdr_child_group: us_east_subgroup
    bdr_node_options:
      route_priority: 100

- Name: eastbarman
  location: us_east
  node: 4
  role:
  - barman
```

bdr_child_group 設定がないこの場所の 1 つのノードは、Raft の意思決定プロセスに参加しないため、barman ノードです。

Working with Raft subgroups and PGD CLI

PGD と TPA の紹介

CLI コマンドを使用して、ノードとサブグループのステータスを表示できます。この例では、
Creating Raft subgroups with TPA で構成されたクラスターを想定しています。

pgd でノードを表示する

pgd コマンドは show-nodes です。

```
$pgd show-nodes
__OUTPUT__
Node     Node ID    Node Group Type Current State Target State Status Seq ID
- ---     -------    ---------- ---- ------------- ------------ ------ ------
east1    916860695  us_east    data ACTIVE        ACTIVE       Up     1
east2    2241077170 us_east    data ACTIVE        ACTIVE       Up     2
east3    1093023575 us_east    data ACTIVE        ACTIVE       Up     3
west1    1668243030 us_west    data ACTIVE        ACTIVE       Up     4
west2    2311995928 us_west    data ACTIVE        ACTIVE       Up     5
west3    4162758468 us_west    data ACTIVE        ACTIVE       Up     6
```

pgd を使用したグループおよびサブグループの表示

PGD 展開内のグループとその名前および属性を表示するには、 PGD CLI コマンド show-groups. を使用します

```
$pgd show-groups
Group    Group ID   Type   Parent Group Location Raft Routing Write Leader
- ----    --------   ----   ------------ -------- ---- ------- ------------
pgdgroup 1360502012 global                       true false
us_east  1806884964 data   pgdgroup     us_east  true true    east2
us_west  3098768667 data   pgdgroup     us_west  true true    west1
```

Migrating to Raft subgroups

実行中の PGD インストールに Raft サブグループを導入できます。

Raft サブグループへの移行 SQL のみを使用

既存のクラスターに対して Raft サブグループを有効にするには、次の構成手順が必要です。

- PGD クラスター内のすべてのノードのトップレベルグループを特定します。既存のクラスターには、すべてのノードが属するトップレベルグループが既にあります。

*場所ごとにサブグループを作成します。 bdr.create_node_group は、トップレベルグループを値として指定する parent_group_name 引数とともに使用します。

- bdr.switch_node_group() を使用して、各ロケーションの各ノードをそのロケーションのサブグループに追加します。
- ロケーションの各サブグループを変更して、グループで Raft を有効にします。bdr.alter_node_group_option() を使用し、 enable_raft オプションを true に設定します。

サブグループ Raft ノードグループの有効化 SQL のみを使用

```
SELECT bdr.alter_node_group_option($group_name, enable_raft, true);
```

Raft elections in depth

PGD の書き込みリーダーの選択は、 PGD の Raft メカニズムに依存しています。Raft メカニズムは、PGD の BDR Postgres 拡張機能の完全な内部にあり、透過的に動作します。グループ内のノードは、グループのノード内に Raft リーダーを確立することから始めます。

ノードの相互作用

Raft リーダーが確立されると、リーダーはカタログを照会して、プロキシルーティングの書き込みリーダーが指定されたかどうかを確認します。

書き込みリーダーが指定されていない場合、Raft リーダーは新しい書き込みリーダーを指定するための手順を実行します。プロセスは、グループ内のすべてのノードを照会してその状態を確立することから始まります。結果のノードのリストは、資格のないノードたとえば、監視ノードについてフィルタリングされ、優先順位が付けられます。リストの最初/一番上のエントリが Raft ログの新しい書き込みリーダーとして設定されます。

プロキシの相互作用

すべてのプロキシは、最初にグループ内の任意のデータノードに接続します。この動作により、現在の書き込みリーダーのカタログを照会し、そのノードへのルーティング接続を開始できます。

彼らは Raft リーダーに接続し、書き込みリーダーのカタログエントリの変更を監視します。書き込みリーダーの変更が通知されると、ルーティングを再構成し、新しい書き込みリーダーに接続を送信します。

ノードとプロキシの相互作用の両方が次のシーケンス図に示されています。2 つのノードと 1 つのプロキシが関係し、どのノードが書き込みリーダーになるかを調整し、プロキシはどのノードが書き込みリーダーであるかを学習するのを待機しています。

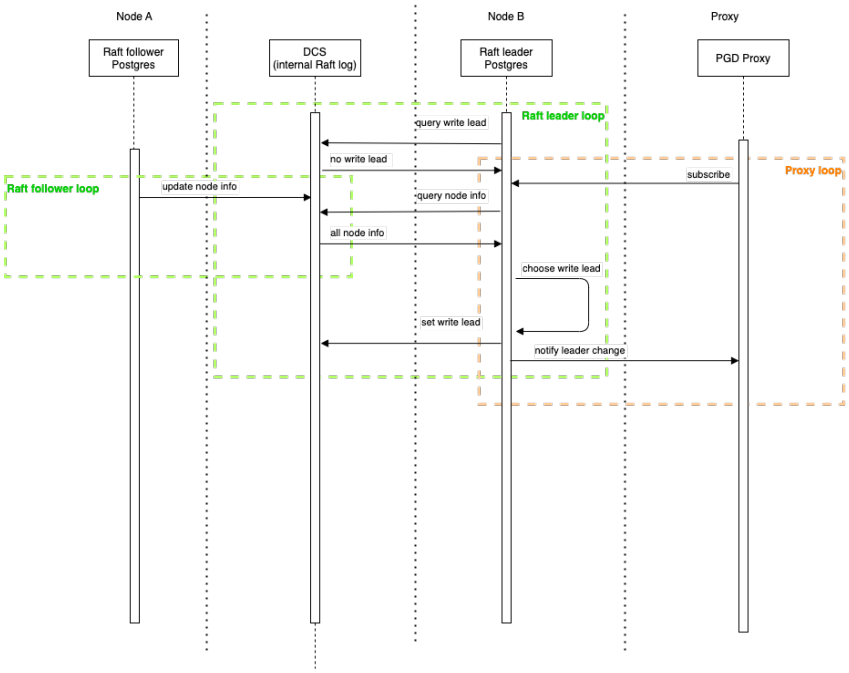


図 3: Sequence Diagram

8.12 Backup and recovery

PGD は、分散された高可用システムであるように設計されています。クラスターの 1 つ以上のノードが失われた場合、それらを置き換える最良の方法は、残りのノードから直接新しいノードのクローンを作成することです。

PGD におけるバックアップとリカバリーの役割は、次の状況などのディザスターリカバリー DR を提供することです。

- クラスター内のすべてのノードの損失
- データの破損、アプリケーションエラー、またはセキュリティ侵害の結果、マルチプルのノードにわたる重大な修正不可能なデータの破損

8.12.1 バックアップ

pg_dump

pg_dump は、 **論理バックアップ**と呼ばれることもあります、通常は PGD で使用できます。

pg_dump は、ローカルシーケンスとグローバルシーケンスの両方をローカルシーケンスであるかのようにダンプします。この動作は意図的なもので、PGD スキーマをダンプして他の PostgreSQL データベースに

移植できるようにします。これは、ダンプ時にシーケンス種類のメタデータが失われることを意味するため、リストアはすべてのシーケンス種類をリストア時に bdr.default_sequence_kind の値に効果的にリセットします。

シーケンスごとに正確なシーケンス種類をリセットする復元後スクリプトを作成するには、次のような SQL スクリプトを使用することができます。

```
SELECT SELECT bdr.alter_sequence_set_kind(||
        nspname||.||relname||,||seqkind||);
FROM bdr.sequences
WHERE seqkind != local;
```

bdr.crdt_raw_value = on を使用して pg_dump が実行されている場合、bdr.crdt_raw_value = on でのみダンプをリロードできます。

テクニカルサポートでは、PGD のバックアップとリカバリーに物理的バックアップ技術を使用することをお勧めします。

物理的バックアップ

Barman などの標準の PostgreSQL ソフトウェアを使用して、 EDB

Postgres 分散クラスター内のノードの物理バックアップを取得できます。

PostgreSQL ノードに適用されるのと同じ手順を使用して、PGD ノードの物理バックアップを実行できます。PGD ノードは、 BDR 拡張機能を実行する単なる PostgreSQL ノードです。

PostgreSQL バックアップ技術を PGD に適用する際に、次の特定の点を考慮してください。

- PGD は単一のデータベースのレベルで動作しますが、物理バックアップにはインスタンス内のすべてのデータベースが含まれます。データベースを簡単にバックアップおよび復元できるように計画します。
- バックアップは、1 つのノードのみのコピーを作成します。最も単純なケースでは、すべてのノードにすべてのデータのコピーがあるため、すべてのデータをキャプチャするには 1 つのノードのみをバックアップする必要があります。ただし、その単一のコピーを含むサイトがダウンした場合、PGD の目標は満たされないため、最小はサイトごとに少なくとも 1 つのノードバックアップ多数のコピーなど。
- ただし、各ノードにはレプリケーションされていないローカルデータがある場合、またはレプリケーションセットの定義が複雑な場合があるため、すべてのノードがすべてのレプリケーションセットをサブスクライブしない場合があります。これらの場合、バックアップ計画には、レプリケートされていないローカルデータと、各レプリケーションセットをサブスクライブする少なくとも 1 つのノードのバックアップをバックアップする方法に関する計画も含める必要があります。

最終的な一貫性

EDB Postgres 分散クラスター内のノードは **結果的に一貫性** ですが、**完全に一貫性**ではありません。特定のノードの物理バックアップは、そのノードが実際に想定する状態に制限されたポイントインタイムリカバリ機能を提供します。

次の例は、同じ EDB Postgres 分散クラスター内の 2 つのノードがどのようにして同じ状態のシーケンスを通過しないか、通常は通過しないかを示しています。

2 つのノード N1 および N2 を含むクラスターで、最初は S 状態であるとします。トランザクション W1 がノード N1 に適用され、同時に競合しないトランザクション W2 がノード N2 に適用される場合、ノード N1 は次の状態を経ます。

```
(N1)   S  -->  S + W1  -->  S + W1 + W2
```

ノード N2 は、次の状態を経ます。

```
(N2)   S  -->  S + W2  -->  S + W1 + W2
```

つまり、ノード N1 は決して*状態 S + W2 を引き受けることはなく、ノード N2 も同様に状態 S + W1 を引き受けることはありません。ただし、両方のノードは同じ状態 S + W1 + W2 になります。この状況を考慮すると、バックアップ戦略の決定方法に影響を与える可能性があります。

ポイントインタイムリカバリー PITR

前の例では、変更も時間的に一貫していないことを示しました。 W1 と W2 は両方とも T1 で発生しますが、変更 W1 は T2 まで N2 に適用されません。

PostgreSQL PITR は、単一のマスターから COMMIT オーダーで変更が到着するという想定に基づいて設計されています。したがって、PITR は、特定の時点 PIT に到達するまで変更をスキャンすることにより可能です。このスキームを使用すると、1 つのノードをその観点から単一のポイントに復元できます T1 など。ただし、その状態には、その時間近くにコミットしたがノードにまだ到着していない他のノードからの他のデータは含まれません。その結果、回復は部分的に一貫していない、または少なくとも 1 つのレプリケーションオリジンのみについて一貫していると考えられる場合があります。

これを要求するには、標準の構文を使用します。

```
recovery_target_time = T1
```

PGD では、マルチプルのマスターからの変更が可能で、すべては 1 つのノードの WAL ログに記録され、レプリケーションオリジン識別子を使用して個別に識別されます。

PGD は、すべてまたは一部のレプリケーションオリジンの特定の時点への PITR を可能にし、ノードのすべてのサブセットにわたって完全に一貫した観点を提供します。

したがって、マルチオリジンの場合、WAL ストリームを、複数のストリームがすべて 1 つの大きなストリームに混合されたものとして表示できます。PIT はまだ 1 つだけですが、それは各原点の異なるポイントとして個別に到達されます。

WAL ストリームは、要求されたオリジンが PIT を見つけるまで読み取られます。すべての変更は、その時点までに適用されますが、オリジンの PIT に到達した後、トランザクションレコードはオリジンのコミットとしてマークされません。

WAL には 1 つの LSN「停止ポイント」がありますが、シングルオリジン PITR の場合と同様に、単一のタイムスタンプが一貫して適用されます。

定義された PIT に到達すると、必要に応じてリカバリーを続行できるように新しい PIT が設定される場合があります。

目的の停止ポイントに到達した後、復旧したサーバーが昇格する場合は、最初にシャットダウンします。`pg_resetwal` を使用して、このサーバーのタイムラインで使用されるよりも高い LSN 値に LSN を移動します。このアプローチでは、論理デコードによって生成される重複 LSN がないことが保証されます。

この特定の例では、`N1` は `T1` に復元されます。また、後まで `N1` に適用されなかった場合でも、 `T1` によってコミットされた他のノードからの変更も含まれます。

マルチオリジン PITR を要求するには、 `recovery.conf` ファイルの標準の構文を使用します。

```
recovery_target_time = T1
```

2 つの方法のいずれかで `T1` に復元されるレプリケーションオリジンのリストを指定する必要があります。新しいパラメーター `recovery_target_origins` を介して別の `multi_recovery.conf` ファイルを使用できます。

```
recovery_target_origins = *
```

または、オリジンのサブセットを `recovery_target_origins` のリストとして指定できます。

```
recovery_target_origins = 1,3
```

指定された `recovery_target_time` へのローカル WAL アクティビティのリカバリーは、常に暗黙的に実行されます。`recovery_target_origins` で指定されていないオリジンの場合、`recovery_target_origins` で記載されているリストの目標が達成される時期に応じて、任意の時点でリカバリーを停止できます。

`multi_recovery.conf` ファイルが存在しない場合、リカバリーは、COMMIT オーダーで単一のマスターから到着する変更を想定して設計された元の PostgreSQL PITR 動作がデフォルトになります。

注釈: この機能は、 EDB Postgres Extended でのみ使用できます。 Barman は `multi_recovery.conf` ファイルを作成しません。

8.12.2 リストア

標準の PostgreSQL ノードと同じ手順で物理バックアップを取ることができますが、PGD ノードの物理バックアップを復元するのは少し複雑です。

EDB Postgres 分散クラスター障害またはバックアップからの新しいクラスターのシード

物理バックアップを復元するための最も一般的なユースケースには、データセンターに障害が発生した場合など、クラスター内のすべての PGD ノードの障害または交換が含まれます。

また、この手順を実行して、EDB Postgres 分散クラスターの現在のコンテンツのクローンを作成して、QA または開発インスタンスをシードすることもできます。

その場合、単一の PGD ノードとオプションで WAL アーカイブの物理バックアップに基づいて、PGD 機能を復元できます。

- いくつかの PGD ノードがまだライブで実行されている場合は、PGD ノードを復元したホストをフェンスオフして、残りの PGD ノードに接続できないようにします。この実践により、新しいノードが既存のクラスターを混乱させないようになります。
- PGD ノードの 1 つの物理バックアップから単一の PostgreSQL ノードを復元します。
- バックアップに関連付けられている WAL アーカイブがある場合は、適切な `recovery.conf` を作成し、リカバリーで PostgreSQL を起動して最新の状態まで再生します。必要に応じて、ここで代替の `recovery_target` を指定できます。
- 復元されたノードを起動するか、スタンバイ復旧している場合は読み取り/書き込みに昇格させます。生き残ったノードからフェンスしてください。
- 物理バックアップに含まれる残りの PGD メタデータをクリーンアップします。
- PostgreSQL インスタンスを完全に停止して再起動します。
- `bdr.join_node_group()` ファンクション呼び出しに基づいた標準プロシージャで PGD ノードをさらに追加します。

PGD メタデータのクリーンアップ

残った PGD メタデータをクリーンアップするには

1. `bdr.drop_node` を使用して PGD ノードを削除します。
2. PostgreSQL を完全に停止して再起動します重要！

レプリケーション起点のクリーンアップ

レプリケーションオリジンはシステムカタログに永続的に記録されるため、別の手順で明示的に削除する必要があります。したがって、これらはバックアップと復元されたインスタンスに含まれます。これらは依存関係として明示的に記録されていないため、BDR 拡張機能をドロップするときに自動的に削除されません。

クラッシュセーフな方法で着信レプリケーションの進行状況を追跡するため、PGD はリモートマスターノードごとに 1 つのレプリケーションオリジンを作成します。したがって、以前のクラスターのノードごとに、これを 1 回実行します。

```
SELECT pg_replication_origin_drop(bdr_dbname_grpname_nodename);
```

次のようにして、レプリケーションオリジンをリストできます。

```
SELECT * FROM pg_replication_origin;
```

PGD によって作成されたものは、名前で簡単に認識されます。

レプリケーションスロットのクリーンアップ

pg_basebackup で物理バックアップが作成された場合、レプリケーションスロットはバックアップから省略されます。

他のバックアップ方法には、レプリケーションスロットが古いまたは無効な状態で保持される場合があります。バックアップを復元したら、これを使用してすべてのレプリケーションスロットをドロップします。

```
SELECT pg_drop_replication_slot(slot_name)
FROM pg_replication_slots;
```

一部のスロットを保持する理由がある場合は、`WHERE slot_name LIKE 'bdr%'` 句を追加できますが、これはほとんど役に立ちません。

> **警告:** これは、ライブ PGD ノードでは決して実行しないでください。

8.13 Monitoring

レプリケーションセットアップの監視は、システムが次のことを保証するために重要です。

- 最適なパフォーマンス
- ディスク領域が不足しない
- オペレーションを停止する可能性のある他の障害に遭遇しない

自動監視を導入して、問題が発生したときに管理者が警告を受け取り、プロアクティブなアクションを実行できるようにすることが重要です。たとえば、レプリケーションスロットが大幅に遅延し始めた場合、管理者にアラートを受け取ることができます。

EDB は、バージョン 8.1 から PGD をサポートする Postgres Enterprise ManagerPEM を提供します。詳細については、

Monitoring EDB Postgres Distributed を参照してください。

または、ツールまたはユーザーは、BDR 拡張機能が提供する情報ビューと機能を独自に呼び出すことができます。詳細は、

Monitoring through SQL を参照してください。

EDB Postgres Distributed は OpenTelemetry と統合しているため、既存のレポート設定を使用して EDB Postgres Distributed クラスターの状態を追跡できます。詳細は、

OpenTelemetry integration を参照してください。

8.13.1 OpenTelemetry integration

モニタリング情報とトレースを OpenTelemetry コレクターに報告するように EDB Postgres 分散を構成できます。

EDB Postgres 分散 OTEL コレクターは、いくつかのリソース属性を埋めます。これらはすべてのメトリックとトレースにアタッチされます。

- `service.name` は、 `bdr.otel_service_name` 構成設定で構成できます。 - `service.namespace` は常に `edb_postgres_distributed` に設定されます。 - `service.instance.id` は、常に Postgres インスタンスのシステム識別子に設定されます。 - `service.version` は、Postgresql インスタンスにロードされた BDR 拡張機能の現在のバージョンに設定されます。

OTEL と OLTP の互換性

OTEL 接続の場合、統合は、HTTP または HTTPS を介して OLTP/HTTP バージョン 1.0.0 のみをサポートします。OLTP/gRPC はサポートされていません。

メトリック収集

構成オプション `bdr.metrics_otel_http_url` を空以外の URL に設定すると、メトリック収集が有効になります。

以下の表に示すように、さまざまな種類のメトリックが収集されます。

汎用メトリック

Metric name	Type	Labels	Description
pg_backends_by_state	gauge	conn_state - idle, active, idle in transaction, fast-path functioncall, idle in transaction (aborted), disabled, undefined	特定の状態のバックエンドの数
pg_oldest_xact_start	gauge		最も古いトランザクション開始時刻
pg_oldest_activity_start	gauge		最も古いクエリ開始時刻
pg_waiting_backends	gauge	wait_type - LWLock, Lock, BufferPin, Activity, Client, Extension, IPC, Timeout, IO, ??? (for unknown)	待機タイプ別の現在待機しているバックエンドの数
pg_start_time	gauge		サーバーが起動したタイムスタンプ
pg_reload_time	gauge		サーバーが最後に構成をリロードしたタイムスタンプ

レプリケーションメトリック

Metric name	Type	Labels	Description
bdr_slot_sent_lag	gauge	slot_name - name of a slot	各レプリケーションスロットの現在の送信遅延バイト単位
bdr_slot_write_lag	gauge	slot_name - name of a slot	各レプリケーションスロットの現在のバイト単位の書き込み遅延
bdr_slot_flush_lag	gauge	slot_name - name of a slot	各レプリケーションスロットのバイト単位の現在のフラッシュラグ
bdr_slot_apply_lag	gauge	slot_name - name of a slot	各レプリケーションスロットのバイト単位の現在の適用ラグ
bdr_subscription_receive_l	gauge	sub_name - name of subscription	各サブスクリプションの現在受信した LSN
bdr_subscription_flush_lsn	gauge	sub_name - name of subscription	各サブスクリプションの現在フラッシュされた LSN
bdr_subscription_apply_lsr	gauge	sub_name - name of subscription	各サブスクリプションに現在適用されている LSN

次のページに続く

表 8 – 前のページからの続き

Metric name	Type	Labels	Description
bdr_subscription_receiver	gauge	sub_name - name of subscription	サブスクリプションレシーバーが現在実行されているかどうか 1 かどうか 0

コンセンサスメトリック

Monitoring Raft コンセンサス も参照

Metric name	Type	Labels	Description
bdr_raft_state	gauge	state_str - RAFT_FOLLOWER, RAFT_CANDIDATE RAFT_LEADER, RAFT_STOPPED	このノードのコンセンサスの Raft 状態
bdr_raft_protocol_version	gauge		このノードで使用されるコンセンサスプロトコルバージョン
bdr_raft_leader_node	gauge		このノードが現在のリーダーと見なすノードの ID
bdr_raft_nodes	gauge		コンセンサスに参加するノードの合計数学習者/非投票ノードを含む
bdr_raft_voting_nodes	gauge		コンセンサスにおける実際の投票ノードの数
bdr_raft_term	gauge		このノードが存在する現在の raft
bdr_raft_commit_index	gauge		このノードによってコミットされた Raft コミットインデックス
bdr_raft_apply_index	gauge		このノードによって適用される Raft コミットインデックス

トレース

OpenTelemetry へのトレース収集には、`bdr.trace_otel_http_url` を構成し、`bdr.trace_enable` を使用してトレースを有効にする必要があります。

トレースは、現時点では一部のサブシステム、主にクラスター管理機能に制限されています。トレースには次のスパンが表示されます。

Span name	Description
create_node_group	グループの作成

次のページに続く

表 10 – 前のページからの続き

Span name	Description
alter_node_group_config	グループ構成オプションの変更
alter_node_config	ノード構成オプションの変更
join_node_group	グループに参加するノード
join_send_remote_request	参加ノードに代わって参加要求を送信する参加ソース
add_camo_pair	CAMO ペアを追加
alter_camo_pair	CAMO ペアを変更する
remove_camo_pair	CAMO ペアの削除
alter_commit_scope	コミットスコープ定義の変更新規作成または既存の更新のいずれか
alter_proxy_config	PGD-プロキシインスタンスの構成を変更します新規作成または既存の更新のいずれか
walmsg_global_lock_send	グローバルロック WAL メッセージを送信する
walmsg_global_lock_recv	受信したグローバルロック WAL メッセージ
ddl_epoch_apply	グローバルロックエポック適用新しいエポックを開始するためにクラスターが十分に同期していることを確認します
walmsg_catchup	ノードの削除中のキャッチアップ WAL メッセージ
raft_send_appendentries	内部 Raft ブックキーピングメッセージ
raft_recv_appendentries	内部 Raft ブックキーピングメッセージ
raft_request	Raft リクエストの実行
raft_query	Raft クエリーの実行
msgb_send	コンセンサスメッセージングレイヤーメッセージ
msgb_recv_receive	コンセンサスメッセージングレイヤーメッセージ
msgb_recv_deliver	コンセンサスメッセージングレイヤーのメッセージ配信
preprocess_ddl	DDL コマンドの前処理

TLS サポート

メトリックとトレースエンドポイントは、HTTP または HTTPS です。`bdr.otel_https_ca_path`、`bdr.otel_https_key_path`、および `bdr.otel_https_cert_path` 構成オプションを使用して、CA バンドル、クライアントキー、およびクライアント証明書へのパスを構成できます。

8.13.2 Monitoring through SQL

EDB Postgres Distributed は、分散の性質に固有のいくつかのモニタリングおよび統計ビューを提供します。標準の Postgres モニタリングは、EDB Postgres 分散をモニタリングするのにも役立ちます。

モニタリングの概要

PGD グループは、複数のサーバーで構成されており、多くの場合ノードと呼ばれます。すべてのノードを監視して、グループ全体の状態を確認します。

bdr_monitor ロールは、bdr.monitor ファンクションを実行して、3 つのレベルのいずれかを使用して PGD の状態の評価を提供できます。

- OK —多くの場合、緑色で表示されます。
- WARNING —多くの場合、黄色で表示されます。
- CRITICAL —多くの場合、赤で表示されます。
- UNKNOWN —認識されない状況の場合、多くの場合赤で表示されます。

PGD は、さまざまな内部メトリックの瞬間的な状態を表示する動的なカタログビューも提供します。また、ユーザーが要求した構成のデフォルトと構成の変更を保存するメタデータカタログも提供します。これらのビューとテーブルの一部は、bdr_monitor または bdr_read_all_stats からアクセスできますが、一部には、より高いセキュリティ要件が必要なユーザーまたは内部情報が含まれています。

PGD を使用すると、各ノードを個別に監視したり、単一のノードへのアクセスでグループ全体を監視したりできます。各ノードを個別に監視する場合は、各ノードに接続し、監視要求を発行します。これらの要求は他のノードを呼び出してグループレベルの情報セットをアセンブルするため、単一のノードからグループをモニタする場合は、bdr.group で始まるビューを使用します。

bdr_superuser によって bdr.run_on_all_nodes() ファンクションへのアクセスが付与されている場合、すべてのノードに独自の呼び出しを行うことができます。

監視ノードの参加と削除

デフォルトでは、ノード管理機能は join または part 操作が完了するまで待機します。それぞれの wait_for_completion ファンクション引数を使用して、待機をオフにできます。待機がオフになっている場合、join または part オペレーションが終了したときを確認するには、bdr.node_summary および bdr.event_summary を使用して間接的にノードの状態を確認します。

ヘルパーファンクション bdr.wait_for_join_completion() は、呼び出されると、すべての未処理のノード結合操作領域が完了するまで PostgreSQL セッションを一時停止します。

この例は、 bdr.node_summary からの SELECT クエリーの出力を示しています。これは、2 つのノードがアクティブで、別の 1 つが参加していることを示します。

```
#  SELECT node_name, interface_connstr, peer_state_name,

#      node_seq_id, node_local_dbname

#  FROM bdr.node_summary;

- [ RECORD 1 ]-----+----------------------------------------
node_name          | node1
```

(次のページに続く)

(前のページからの続き)

```
interface_connstr | host=localhost dbname=postgres port=7432
peer_state_name   | ACTIVE
node_seq_id       | 1
node_local_dbname | postgres
- [ RECORD 2 ]-----+----------------------------------------
node_name         | node2
interface_connstr | host=localhost dbname=postgres port=7433
peer_state_name   | ACTIVE
node_seq_id       | 2
node_local_dbname | postgres
- [ RECORD 3 ]-----+----------------------------------------
node_name         | node3
interface_connstr | host=localhost dbname=postgres port=7434
peer_state_name   | JOINING
node_seq_id       | 3
node_local_dbname | postgres
```

また、テーブル *bdr.node_catchup_info* は、ノードへの参加または分離に関連する可能性のあるキャッチアップ状態に関する情報を提供します。

ノードが分離されると、クラスター内の一部のノードがその分離したノードからすべてのデータを受信しない場合があります。したがって、ノードを分離すると、そのデータを既に受信し、転送できるノードから一時的なスロットが作成されます。

catchup_state は、次のいずれかです。

```
10 = setup
20 = start
30 = catchup
40 = done
```

レプリケーションピアのモニタリング

レプリケーションアクティビティの監視には、2 つのメインビューを使用します。

- *bdr.node_slots* 送信レプリケーションを監視するため
- 着信レプリケーションを監視するための *bdr.subscription_summary*

標準の PostgreSQL レプリケーション監視ビュー
pg_catalog.pg_stat_replication を照会することにより、 bdr.node_slots

が提供する情報のほとんどを取得することもできます

および *pg_catalog.pg_replication_slots* 。

各ノードには 1 つの PGD グループスロットがあります。これらのスロットには接続してはならず、アクティブとしてマークされることはほとんどありません。これは正常であり、何かがダウンまたは切断され

ていることを意味するものではありません。ノード管理の レプリケーションスロットのクリーンアップ を参照してください。

送信レプリケーションの監視

送信レプリケーションアクティビティの監視に別のビューを使用できます。

- *bdr.node_replication_rates* 送信レプリケーションを監視するため

  bdr.node_replication_rates ビューは、送信レプリケーションアクティビティの全体像と、特にピアノードのキャッチアップ推定を提供します。

```
#  SELECT * FROM bdr.node_replication_rates;

- [ RECORD 1 ]----+-----------
peer_node_id     | 112898766
target_name      | node1
sent_lsn         | 0/28AF99C8
replay_lsn       | 0/28AF99C8
replay_lag       | 00:00:00
replay_lag_bytes | 0
replay_lag_size  | 0 bytes
apply_rate       | 822
catchup_interval | 00:00:00
- [ RECORD 2 ]----+-----------
peer_node_id     | 312494765
target_name      | node3
sent_lsn         | 0/28AF99C8
replay_lsn       | 0/28AF99C8
replay_lag       | 00:00:00
replay_lag_bytes | 0
replay_lag_size  | 0 bytes
apply_rate       | 853
catchup_interval | 00:00:00
```

apply_rate は、1 秒あたりのバイト数のレートを参照します。これは、ピアがローカルノードからデータを消費している速度です。ノードがクラスターに再接続したときの replay_lag は、すぐにゼロに設定されます。この情報は将来のリリースで修正される予定です。回避策として、ピアノードがローカルノードデータに追いつくまでに必要な時間を参照する catchup_interval 列を使用することをお勧めします。他のフィールドは、

bdr.node_slots から利用できます。

ビュー。

管理者は、ローカルノードからの送信レプリケーションについて *bdr.node_slots* を照会できます。これは、現在のノードで知られているグループ内の他のすべてのノードのレプリケーションステータスと、現在のノードで PGD によって作成された追加のレプリケーションスロットに関する情報を表示します。

```
#  SELECT node_group_name, target_dbname, target_name, slot_name, active_pid,

#      catalog_xmin, client_addr, sent_lsn, replay_lsn, replay_lag,

#      replay_lag_bytes, replay_lag_size

#  FROM bdr.node_slots;

- [ RECORD 1 ]---+-----------------------------
node_group_name | bdrgroup
target_dbname   | postgres
target_name     | node3
slot_name       | bdr_postgres_bdrgroup_node3
active_pid      | 15089
catalog_xmin    | 691
client_addr     | 127.0.0.1
sent_lsn        | 0/23F7B70
replay_lsn      | 0/23F7B70
replay_lag      | [NULL]
replay_lag_bytes| 120
replay_lag_size | 120 bytes
- [ RECORD 2 ]---+-----------------------------
node_group_name | bdrgroup
target_dbname   | postgres
target_name     | node2
slot_name       | bdr_postgres_bdrgroup_node2
active_pid      | 15031
catalog_xmin    | 691
client_addr     | 127.0.0.1
sent_lsn        | 0/23F7B70
replay_lsn      | 0/23F7B70
replay_lag      | [NULL]
replay_lag_bytes| 84211
replay_lag_size | 82 kB
```

PGD はメッシュネットワークであるため、クラスター内の遅延の完全なビューを取得するには、参加しているすべてのノードでこのクエリを実行する必要があります。

replay_lag_bytes は、ローカルサーバーの現在の WAL 書き込み位置と、ピアノードによって再生確認された最後の位置である replay_lsn 間の WAL 位置の差を報告します。 replay_lag_size は、同じの人が判読可能な形式です。通常、WAL には、レプリケートされないが replay_lag_bytes でカウントされる大量の書き込みが含まれることを理解することが重要です。

- VACUUM アクティビティ
- インデックスの変更
- 同じノード上の他のデータベースに関連付けられた書き込み

- レプリケーションセットの一部ではないテーブルの書き込み

したがって、ここで報告されるバイト単位の遅延は、ピアノードを最新の状態にするためにワイヤで複製する必要があるデータの量ではなく、処理する必要があるサーバーサイドの WAL の量のみです。

同様に、replay_lag は、ピアノードが追いつくまでに要した時間、または現在位置から bdr.node_slots が照会された時点の書き込み位置まで再生に要した時間を表すものではありません。ピアが最新のコミットを確認したときと現在の実測時間との間の遅延を測定します。この列は、ノードが再接続した直後にゼロに設定されるため、replay_lag_bytes と replay_lag_size または bdr.node_replication_rates の catchup_interval をモニタすることをお勧めします。

論理レプリケーションがトランザクションをストリーミングしている間、バイトと時間の両方の遅延は進行しません。コミットがレプリケートされた場合にのみ変更されます。したがって、遅延は「のこぎり波」の傾向があり、トランザクションがストリーミングされると上昇し、ピアノードがコミット、フラッシュ、確認を送信すると再び低下します。報告された LSN は、同様の理由で、スムーズに進むのではなく、「階段」を位置づけています。

レプリケーションが切断されている場合 active = 'f' 、active_pid 列は NULL 、client_addr およびアクティブな接続でのみ意味をなすその他のフィールドと同様に、NULL です。 state フィールドは'disconnected' です。_lsn フィールドは、クライアントが再生および保存したことが確認されている最後の位置であるため、confirmed_flush_lsn と同じです。 _lag フィールドは、クライアントで確認された最新のフラッシュから現在までの経過時間を示します。_lag_size および_lag_bytes フィールドは、confirmed_flush_lsn とローカルサーバーの現在の WAL 挿入位置間の距離をレポートします。

注釈: *restart_lsn* が他の `lsn` 列の後ろにあるのは通常です。これは、レプリケーションまたはピアノードの遅延に関する問題を示しているわけではありません。 *restart_lsn* は、PostgreSQL の内部論理デコードが中断された場合に WAL を読み取る位置です。これは、通常、まだレプリケートおよびフラッシュされていない最も古いトランザクションの位置を反映します。非常に古い `restart_lsn` は、切断後のレプリケーションの再起動を遅くし、望ましいよりも多くの WAL の保持を強制する場合がありますが、それ以外の場合は無害です。心配する場合は、非常に長時間実行されているトランザクションと忘れられた準備済みトランザクションを探してください。

着信レプリケーションの監視

bdr.subscription_summary ビューを照会することにより、受信レプリケーションサブスクリプションとも呼ばれますをモニタできます。このクエリは、EDB Postgres 分散クラスター内の他のノードへの既知のサブスクリプションのリストとレプリケーションワーカーの状態を表示します。

```
#  SELECT node_group_name, origin_name, sub_enabled, sub_slot_name,

#      subscription_status

#  FROM bdr.subscription_summary;

- [ RECORD 1 ]-------+---------------------------
node_group_name      | bdrgroup
```

(次のページに続く)

(前のページからの続き)

```
origin_name         | node2
sub_enabled         | t
sub_slot_name       | bdr_postgres_bdrgroup_node1
subscription_status | replicating
- [ RECORD 2 ]-------+---------------------------
node_group_name     | bdrgroup
origin_name         | node3
sub_enabled         | t
sub_slot_name       | bdr_postgres_bdrgroup_node1
subscription_status | replicating
```

LCR を使用した WAL 送信者のモニタリング

Decoding worker が有効になっている場合、ファンクション *bdr.wal_sender_stats()* を使用して、各 WAL センダーの現在の論理変更レコード LCR ファイルに関する情報をモニタできます。例

```
postgres=# SELECT * FROM bdr.wal_sender_stats();
   pid   | is_using_lcr |       decoder_slot_name       |              lcr_file_name
- --------+--------------+-------------------------------+---------------------------
↪--------------
 2059904 | f            |                               |
 2059909 | t            | bdr_postgres_bdrgroup_decoder |␣
↪000000000000000000000140000000000000000
 2059916 | t            | bdr_postgres_bdrgroup_decoder |␣
↪000000000000000000000140000000000000000
(3 rows)
```

is_using_lcr が FALSE の場合、decoder_slot_name /lcr_file_name は NULL です。これは、デコードワーカーが有効になっていない場合、または WAL 送信者が

Logical standby nodes を提供している場合に当てはまります。

また、ファンクション

bdr.get_decoding_worker_stat() を使用して、デコードワーカーに関する情報をモニタできます。例

```
postgres=# SELECT * FROM bdr.get_decoding_worker_stat();
   pid   | decoded_upto_lsn | waiting | waiting_for_lsn
- --------+------------------+---------+-----------------
 1153091 | 0/1E5EEE8        | t       | 0/1E5EF00
(1 row)
```

PGD レプリケーションワーカーのモニタリング

すべての PGD ワーカーは、

pg_stat_activity と同じ列と情報コンテンツがあるシステムビュー bdr.stat_activity

に表示されます。したがって、このビューは、PGD システムの状態に関する次の洞察を提供します。

- 待機の理由が PGD に関連している場合、wait_event 列に強化された情報があります。
- ライタプロセスが DDL を実行している場合を除き、PGD ワーカーの query 列は空白です。

bdr.workers ビューには、 bdr.stat_activity からは使用できない PGD ワーカー固有の詳細が表示されます。

bdr.event_summary ビューは、作業の続行に問題があるワーカーによって報告された最後のエラーがある場合を表示します。この情報は永続的なため、エラーの存在だけでなく、エラーの時間を記録することが重要です。ほとんどのエラーは一時的なもので、PGD ワーカーは失敗した操作を再試行します。

PGD ライターのモニタリング

別のシステムビュー bdr.writers は、ライタアクティビティを監視します。このビューには、ライタワーカーの現在のステータスのみが表示されます。それには以下が含まれます

- sub_name ライタが属しているサブスクリプションを識別する
- Writer ライタプロセスの pid
- streaming_allowed ライタが進行中のストリーミングトランザクションの適用をサポートしているかどうかを知るため
- is_streaming ライタが現在ストリーミングトランザクションを適用しているかどうかを知るため
- commit_queue_position コミットキュー内のライタの位置を確認する

PGD は、オリジンで発生したのと同じコミット順序に従って、コミット順序を尊重します。並列ライターの場合、複数のライターが異なるトランザクションを同時に適用する場合があります。commit_queue_position は、コミットする順序を示します。値 0 は、ライタが最初にコミットすることを意味します。値-1 は、コミット位置がまだ不明であることを意味します。これは、ストリーミングトランザクション、またはライタが現在トランザクションを適用していない場合に発生します。

グローバルロックの監視

グローバルロックは、現在 DDL レプリケーションにのみ使用されていますが、PGD グループ全体に存在する重量ロックです。

現在、2 種類のグローバルロックがあります。

- DDL ロック、データベース内の一時的なものではない永続的なオブジェクトつまりテーブルに対するすべての DDL 操作をシリアル化するために使用されます
- DML リレーションロック、リレーション定義を変更する DDL 操作中にリレーションへの書き込みをロックアウトするために使用されます

DDL 操作のタイプと bdr.ddl_locking 設定の値に応じて、同じトランザクションに一方または両方のエントリータイプを作成できます。

ローカルノードで保持されているグローバルロックは、*bdr.global_locks* ビューに表示されます。このビューには、ロックのタイプが表示されます。リレーションロックの場合、ロックされている関係、ロックを保持している PID ローカルの場合、およびロックがグローバルに付与されたかどうかを示します。グローバルアドバイザリロックの場合、lock_type 列は GLOBAL_LOCK_ADVISORY を示し、 relation 列は、ロックが取得されるアドバイザリキーを示します。

この例は、bdr.ddl_locking = on を使用して ALTER TABLE ステートメントを実行中の bdr.global_locks の出力を示しています。

```
#  SELECT lock_type, relation, pid FROM bdr.global_locks;

- [ RECORD 1 ]--------------
lock_type | GLOBAL_LOCK_DDL
relation  | [NULL]
pid       | 15534
- [ RECORD 2 ]--------------
lock_type | GLOBAL_LOCK_DML
relation  | someschema.sometable
pid       | 15534
```

ロックタイミング情報を含むすべてのフィールドの詳細については、
カタログ を参照してください。

競合のモニタリング

レプリケーション
競合 は、複数のノードが相互作用できる方法で同じ行に影響を与える変更を行う場合に発生する可能性があります。

PGD システムをモニタして競合を特定し、可能であればアプリケーションを変更して競合を排除するか、競合の頻度を減らします。

デフォルトでは、すべての競合は bdr.conflict_history ログに記録されます。このログには、競合するデータの完全な詳細が含まれているため、行は行レベルのセキュリティで保護され、レプリケートテーブルの所有者にのみ表示されます。所有者は競合を予想し、それらを分析して、存在する場合、どれが解決すべき問題と考えられるかを確認する必要があります。

モニタリングには、ユーザーデータを含まない bdr.conflict_history_summary を使用します。この例は、効率的なクエリプランを使用して、その日に発生した競合の数をカウントするクエリを示しています。

```
SELECT count(*)
FROM bdr.conflict_history_summary
WHERE local_time > date_trunc(day, current_timestamp)
  AND local_time < date_trunc(day, current_timestamp + 1 day);
```

統計を適用する

PGD は、サブスクリプションごととテーブルごとの両方で、レプリケーションの適用に関する統計を収集します。

2 つのモニタリングビューが存在します。サブスクリプション統計用の bdr.stat_subscription とリレーション統計用の bdr.stat_relation 。これらのビューは両方とも次を提供します。

- レプリケートされた INSERT / UPDATE / DELETE / TRUNCATE の数
- ブロックアクセスとキャッシュヒット率
- 読み取り/書き込みの合計 I/O 時間
- ファイルにストリーミングされた進行中のトランザクションの数
- ライターにストリーミングされる進行中のトランザクションの数
- コミット/中止された進行中のストリーミングトランザクションの数

リレーションのみの場合、bdr.stat_relation には次のものも含まれます。

- リレーションのレプリケーションの処理に費やされた合計時間
- リレーションのみのロックがある場合を取得するまでの合計ロック待機時間

サブスクリプションの場合のみ、bdr.stat_subscription には以下が含まれます。

- サブスクリプションに対してレプリケートされた COMMIT/ DDL の数
- このサブスクリプションがアップストリームに接続した回数

これらの統計の追跡は、それぞれ PGD GUC bdr.track_subscription_apply および bdr.track_relation_apply によって制御されます。

次に、これらの出力例を示します。

```
#  SELECT sub_name, nconnect, ninsert, ncommit, nupdate, ndelete, ntruncate, nddl

FROM bdr.stat_subscription;
- [ RECORD 1 ]---------------------------------
sub_name  | bdr_regression_bdrgroup_node1_node2
nconnect  | 3
ninsert   | 10
ncommit   | 5
nupdate   | 0
ndelete   | 0
ntruncate | 0
nddl      | 2
```

この場合、サブスクリプションは上流に 3 回接続し、10 行を挿入し、5 つのトランザクション内で 2 つの DDL コマンドを実行しました。

ファンクション bdr.reset_subscription_stats および bdr.reset_relation_stats を使用して、これらのビューの統計カウンターをゼロにリセットできます。

標準の PostgreSQL 統計ビュー

テーブルとインデックスの使用状況に関する統計は、通常、ダウンストリームマスターによって更新されます。これは、
autovacuum の正しい機能のために重要です。ダウンストリームマスターにローカル書き込みがなく、統計がリセットされていない場合、これらの 2 つのビューは、アップストリームとダウンストリームで対応する結果を表示します。

- `pg_stat_user_tables`
- `pg_statio_user_tables`

注釈: 上流のテーブル統計がダウンストリームのテーブル統計と*同様*であることを必ずしも期待しているわけではありません。私たちはそれらが同じ量だけ*変更*されることを期待しています。統計が 100 万の挿入と 100 万の更新を示すテーブルの例を考えます。新しいノードが PGD グループに参加すると、新しいノードの同じテーブルの統計には、1M の挿入とゼロの更新が示されます。ただし、その瞬間から、一方の側ですべての変更がもう一方の側にレプリケートされるため、上流と下流のテーブル統計は同じ量だけ変更されます。

インデックスは変更を適用するために使用されるため、ダウンストリーム側の識別インデックスは、非識別インデックスよりも `UPDATE` および `DELETE` を実行するワークロードで頻繁に使用される場合があります。

ビルトインインデックスモニタリングビューは次のとおりです。

- `pg_stat_user_indexes`
- `pg_statio_user_indexes`

これらのビューはすべて、 *PostgreSQL documentation on the statistics views* で詳細に説明されています。

PGD バージョンのモニタリング

PGD では、同じクラスター内のノード全体で異なる Postgres バージョンと異なる BDR 拡張バージョンを実行できます。この機能は、アップグレードに役立ちます。

ビュー `bdr.group_versions_details` は、ファンクション `bdr.run_on_all_nodes()` を使用して、すべてのノードから Postgres および BDR 拡張バージョンを同時に取得します。例

```
bdrdb=# SELECT node_name, postgres_version, bdr_version
        FROM bdr.group_versions_details;
 node_name | postgres_version | bdr_version
- ----------+------------------+-------------
 node1     | 15.2.0           | 5.0.0
 node2     | 15.2.0           | 5.0.0
```

推奨されるセットアップは、すべてのノードでできるだけ早く同じ最新のバージョンを実行するようにすることです。クラスターは、BDR 拡張機能のさまざまなバージョンを長時間実行しないことをお勧めします。

モニタリングのために、次のアラートレベルをお勧めします。

- status = UNKNOWN、message =このノードは PGD グループの一部ではありません
- status = OK、message =すべてのノードが同じ PGD バージョンを実行しています
- status = WARNING、message =アクセスできないノードが少なくとも 1 つあります
- status = WARNING、message =他のノードと比較して、異なる PGD バージョンを実行しているノードがあります

説明した動作はファンクション bdr.monitor_group_versions() に実装されており、ビュー bdr.group_version_details から返された PGD バージョン情報を使用して、クラスター全体のバージョンチェックを提供します。例

```
bdrdb=# SELECT * FROM bdr.monitor_group_versions();
 status |                message
- -------+---------------------------------------
 OK     | All nodes are running same BDR versions
```

Monitoring Raft コンセンサス

Raft コンセンサスは、常にクラスター全体で動作している必要があります。Raft コンセンサスが機能せずに EDB Postgres 分散クラスターを実行した場合の影響は次のとおりです。

- PGD データ変更のレプリケーションは、引き続き正常に動作する場合があります。
- グローバル DDL/DML ロックは機能しません。
- Galloc シーケンスは、最終的にチャンクを使い果たします。
- Eager Replication が機能しない。
- クラスターメンテナンス操作ノード参加、部分ノード、プロモートスタンバイは引き続き許可されますが、完了しない代わりにハングする場合があります。
- PGD ノード間でノードのステータスが正しく同期されない場合があります。
- PGD グループレプリケーションスロットは LSN を進歩させないため、ディスク上に WAL ファイルを保持します。

ビュー bdr.group_raft_details は、ファンクション bdr.run_on_all_nodes() および bdr.get_raft_status() を使用して、すべてのノードから同時に Raft コンセンサスステータスを取得します。例

```
bdrdb=# SELECT node_id, node_name, state, leader_id
FROM bdr.group_raft_details;
  node_id   | node_name | node_group_name |     state     | leader_id
- ----------+-----------+-----------------+---------------+------------
 1148549230 | node1     | top_group       | RAFT_LEADER   | 1148549230
 3367056606 | node2     | top_group       | RAFT_FOLLOWER | 1148549230
```

これらの条件がすべて満たされる場合、Raft コンセンサスは正常に動作します。

- 有効な状態 RAFT_LEADER または RAFT_FOLLOWER がすべてのノードで定義されています。
- ノードのうちの 1 つだけが RAFT_LEADER です。
- leader_id はすべての行で同じであり、state = RAFT_LEADER が存在する行の node_id と一致する必要があります。

時々、Raft コンセンサスは新しい選挙を開始して、新しい RAFT_LEADER を定義します。選挙中に、RAFT_LEADER が存在せず、一部のノードが自分自身を RAFT_CANDIDATE と見なす中間状況が発生する場合があります。選挙全体には bdr.raft_election_timeout より長くかかることはありませんデフォルトでは 6 秒に設定されています。上記のクエリーが選挙中の状況を結果た場合、bdr.raft_election_timeout を待って、クエリーを再度実行します。bdr.raft_election_timeout が経過した後、リストされた条件の一部がまだ満たされていない場合、Raft コンセンサスは機能していません。

Raft コンセンサスは、単一のノードでのみ正常に動作していない可能性があります。たとえば、ノードの 1 つが現在のリーダーを認識せず、自分自身を RAFT_CANDIDATE と見なします。この場合、次のことを確認することが重要です。

- すべての PGD ノードは、レギュラー接続とレプリケーション接続の両方を介して相互にアクセスできますチェックファイル pg_hba.conf 。
- PGD バージョンはすべてのノードで同じです。
- bdr.raft_election_timeout はすべてのノードで同じです。

場合によっては、特にノードが地理的に離れている場合、またはネットワーク遅延が高い場合、bdr.raft_election_timeout のデフォルト値 6 秒では十分でない場合があります。すべてが正しいことを確認した後でも Raft コンセンサスがまだ機能していない場合は、すべてのノードで bdr.raft_election_timeout を 30 秒に増加することを検討します。 PGD 3.6.11 以降の場合、bdr.raft_election_timeout の設定に必要なのはサーバーのリロードのみです。

Raft コンセンサスがクラスター操作タスクにどのような影響を与えるか、また Raft コンセンサスがグループスロットを前進させることに直接責任があるため、モニタリングアラートレベルは次のように定義されます。

- status = UNKNOWN、message =このノードは PGD グループの一部ではありません
- status=OK、message=Raft コンセンサスは正常に動作しています
- status = WARNING、message =アクセスできないノードが少なくとも 1 つあります
- status = WARNING、 message = RAFT_CANDIDATE としてノードがあります、選択が進行中の可能性があります
- status = WARNING、message = RAFT_LEADER がありません、選挙が進行中の可能性があります
- status=CRITICAL、message=Raft コンセンサスには単一のノードがあります
- status = CRITICAL、message = RAFT_CANDIDATE としてノードがありますが、RAFT_LEADER が定義されています
- status=CRITICAL、message=RAFT_LEADER として設定されたノードとは異なるリーダーをフォローしているノードがあります。

説明した動作はファンクション bdr.monitor_group_raft() に実装されており、ビュー bdr.group_raft_details から返された Raft コンセンサスステータス情報を使用して、クラスター全体の Raft チェックを提供します。例

```
bdrdb=# SELECT * FROM bdr.monitor_group_raft();
node_group_name | status |               message
- ---------------/--------+-------------------------------------
myroup           | OK     | Raft Consensus is working correctly
```

レプリケーションスロットの監視

各 PGD ノードは以下を保持します。

- アクティブな PGD ピアごとに 1 つのレプリケーションスロット
- 1 つのグループレプリケーションスロット

例

```
bdrdb=# SELECT slot_name, database, active, confirmed_flush_lsn
FROM pg_replication_slots ORDER BY slot_name;
        slot_name          | database | active | confirmed_flush_lsn
- -------------------------+----------+--------+---------------------
 bdr_bdrdb_bdrgroup        | bdrdb    | f      | 0/3110A08
 bdr_bdrdb_bdrgroup_node2 | bdrdb    | t      | 0/31F4670
 bdr_bdrdb_bdrgroup_node3 | bdrdb    | t      | 0/31F4670
 bdr_bdrdb_bdrgroup_node4 | bdrdb    | t      | 0/31F4670
```

ピアスロット名は bdr_<DATABASE>_<GROUP>_<PEER> 規則に従いますが、PGD グループスロット名は bdr_<DATABASE>_<GROUP> 規則に従います。ファンクション bdr.local_group_slot_name() を使用してグループスロットにアクセスできます。

ピアレプリケーションスロットは、すべてのノードで常にアクティブである必要があります。ピアレプリケーションスロットがアクティブでない場合、それは次のいずれかを意味する可能性があります。

- 対応するピアはシャットダウンしているか、アクセスできません。
- PGD レプリケーションが壊れています。

ERROR または FATAL のログファイルを grep し、すべてのノードで bdr.event_summary を確認します。根本的な原因は、たとえば、ノードの 1 つで DDL レプリケーションを無効にして、互換性のない DDL が実行されたことが考えられます。

ただし、PGD グループレプリケーションスロットは、ほとんどの場合非アクティブです。他のすべてのピアが対応するトランザクションを既に消費している場合、PGD はこのスロットを維持し、その LSN を進めます。したがって、グループスロットのステータスを監視する必要はありません。

ファンクション bdr.monitor_local_replslots() は、すべての PGD ノードレプリケーションスロットが予想通りに動作しているかどうかの概要を提供します。例

```
bdrdb=# SELECT * FROM bdr.monitor_local_replslots();
 status |                    message
- -------+-------------------------------------------------
 OK     | All BDR replication slots are working correctly
```

次のステータスの概要のいずれかが返されます。

- UNKNOWN This node is not part of any BDR group
- OK All BDR replication slots are working correctly
- OK This node is part of a subscriber-only group
- CRITICAL There is at least 1 BDR replication slot which is inactive
- CRITICAL There is at least 1 BDR replication slot which is missing

トランザクションの COMMIT の監視

デフォルトでは、PGD トランザクションはローカルノードでのみコミットします。その場合、トランザクション COMMIT はすぐに処理されます。

PGD は、標準の PostgreSQL 同期レプリケーションで使用できます。 PGD は、CAMO と Eager レプリケーションという 2 つの新しいトランザクションコミットモードも提供します。これらの各モードは堅牢性機能を追加しますが、COMMIT での追加のレイテンシーが犠牲になります。bdr.stat_activity カタログを使用して、COMMIT での追加時間を動的にモニタできます。ここで、プロセスはさまざまな wait_event 状態を報告します。1 つ以上の同期スタンバイからの確認を待機している COMMIT のトランザクションは SyncRep 待機イベントをレポートしますが、2 つの新しいモードは EagerRep をレポートします。

8.14 EDB Postgres Distributed Command Line Interface

EDB Postgres 分散コマンドラインインターフェイス PGD CLI は、 EDB Postgres 分散クラスターを管理するためのツールです。 EDB Postgres 分散クラスターに対してコマンドを実行できます。TPA 展開された PGD クラスター内のシステムに自動的にインストールされます。または、EDB BigAnimal 分散高可用性クラスターや EDB PGD for Kubernetes オペレーターを使用して展開された PGD クラスターなどの PGD クラスターに接続できるシステムに手動でインストールできます。

- *Installing PGD CLI* には、さまざまなシステムに PGD CLI を手動でインストールする手順が含まれています。
- *Using PGD CLI* は、 PGD CLI の使用と PGD クラスターに接続する方法の概要を提供します。
- *Configuring PGD CLI* には、迅速な接続のための永続構成の作成に関する詳細が記載されています。
- PGD CLI's Command reference は、クラスターリソースに関する情報を検査、管理、および取得するために使用可能なすべてのコマンドをカバーしています。
- *Discovering connection strings* は、PGD を利用した展開の正しい接続文字列を取得する方法を示します。

8.14.1 Installing PGD CLI

PGD CLI は、PGD クラスターに接続できる任意のシステムにインストールできます。PGD CLI を使用するには、PGD スーパーユーザー権限または同等のユーザーが必要です。スーパーユーザー権限を持つ PGD ユーザーは

> *bdr_superuser* のロールとレプリケーション です。同等のユーザーの例は、EDB

BigAnimal 分散高可用性クラスターの edb_admin です。

Trusted Postgres ArchitectTPA を使用した自動インストール

デフォルトでは、Trused Postgres Architect は各 PGD ノードに PGD CLI をインストールおよび構成します。クラスター内の非 PGD インスタンスに PGD CLI をインストールする場合は、展開する前に Trusted Postgres Architect の構成ファイルで pgdcli ロールをそのインスタンスにアタッチします。詳細については、

> *Deploying EDB Postgres Distributed using Trusted Postgres Architect* を参照してください。

Linux での手動インストール

PGD CLI は EDB リポジトリからインストールできます。これらのリポジトリからのダウンロードを有効にするには、トークンが必要です。

> EDB Repos 2.0 にログインして、トークンを取得します。次に、オペレーティングシステムに表示されているコマンドを実行して、

<your-token> のトークンを置き換えます。

Debian または Ubuntu にリポジトリを追加し、PGD CLI をインストールする

```
curl -1sLf https://downloads.enterprisedb.com/<your-token>/postgres_distributed/setup.
↪deb.sh | sudo -E bash
sudo apt-get install edb-pgd5-cli
```

RHEL、Rocky、AlmaLinux、または Oracle Linux にリポジトリを追加し、PGD CLI をインストールする

```
  curl -1sLf https://downloads.enterprisedb.com/<your-token>/postgres_distributed/
↪setup.rpm.sh | sudo -E bash
  sudo yum install edb-pgd5-cli

:ref:`Next: Using PGD CLI <Using PGD CLI>`
```

8.14.2 Using PGD CLI

PGD CLI とは何ですか?

PGD CLI は、PGD クラスターに接続して管理する便利な方法です。これを使用するには、PGD スーパーユーザー権限または同等のユーザーが必要です。スーパーユーザー権限を持つ PGD ユーザーは

bdr_superuser のロールとレプリケーション です。同等のユーザーの例は、EDB

BigAnimal 分散高可用性クラスターの edb_admin です。

- .pgpass にエントリを追加します。これには、ホスト、ポート、データベース名、ユーザー名、パスワードが含まれます。- PGPASSWORD 環境変数にパスワードを設定する。 - 接続文字列にパスワードを含めます。

他のオプションは複数のデータベースでうまく拡張できないか、パスワードの機密性が危険にさらされるため、最初のオプションをお勧めします。

コマンドを実行して PGD コマンドラインインターフェイスにアクセスします。pgd コマンドには、ユーザー名とパスワードとともに、接続するホスト、ポート、データベースに関する詳細が必要です。

データベース接続文字列を渡す

--dsn フラグを使用して、データベース接続文字列を pgd コマンドに渡します。 --dsn フラグを使用して接続文字列を渡す場合、構成ファイルは必要ありません。構成ファイルが存在する場合でも、フラグが優先されます。例

```
pgd show-nodes --dsn "host=bdr-a1 port=5432 dbname=bdrdb user=enterprisedb"
```

コマンドオプションの説明については、コマンドリファレンスの *PGD と TPA の紹介* を参照してください。

構成ファイルの指定

pgd-cli-config.yml ファイルが/etc/edb/pgd-cli または$HOME/.edb/pgd-cli にある場合、pgd はそれを使用します。オプションの-f または--config-file フラグを使用して、この動作をオーバーライドできます。例

```
pgd show-nodes -f /opt/my-config.yml
Node             Node ID    Group          Type    Current State Target State Status␣
↪Seq ID
- ---             -------    -----          ----    ------------- ------------ ------␣
↪------
p-vjljj303dk-a-1 2573417965 p-vjljj303dk-a data    ACTIVE        ACTIVE       Up     1
p-vjljj303dk-a-2 126163807  p-vjljj303dk-a data    ACTIVE        ACTIVE       Up     2
p-vjljj303dk-a-3 3521351376 p-vjljj303dk-a witness ACTIVE        ACTIVE       Up     3
```

出力形式の指定

-o または--output フラグを使用して、デフォルトの出力形式を JSON または YAML に変更します。例

```
pgd show-nodes -o json
[
    {
        "node_id": 2573417965,
        "node_name": "p-vjljj303dk-a-1",
        "node_group_id": 4169125197,
        "node_group_name": "p-vjljj303dk-a",
        "node_kind_name": "data",
        "current_state": "ACTIVE",
        "target_state": "ACTIVE",
        "status": "Up",
        "node_seq_id": 1,
        "node_local_dbname": "bdrdb",
        "interface_connstr": "host=p-vjljj303dk-a-1-node.vmk31wilqpjeopka.biganimal.
↪io user=streaming_replica sslmode=verify-full port=5432 sslkey=/controller/
↪certificates/streaming_replica.key sslcert=/controller/certificates/streaming_
↪replica.crt sslrootcert=/controller/certificates/server-ca.crt application_name=p-
↪vjljj303dk-a-1 dbname=bdrdb",
        "route_priority": -1,
        "route_fence": false,
        "route_writes": true,
        "route_reads": true,
        "route_dsn": "host=p-vjljj303dk-a-1-node.vmk31wilqpjeopka.biganimal.io␣
↪user=streaming_replica sslmode=verify-full port=5432 sslkey=/controller/
↪certificates/streaming_replica.key sslcert=/controller/certificates/streaming_
↪replica.crt sslrootcert=/controller/certificates/server-ca.crt application_name=p-
↪vjljj303dk-a-1 dbname=bdrdb"
    },
...
]
```

PGD CLI は、次の出力形式をサポートしています。

Setting	Format	Considerations
none	Tabular	デフォルトのフォーマット。この設定では、データを表形式で表示します。
json	JSON	フォーマットなしの生データを表示します。一部のコマンドでは、JSON 出力には、追加のフィールドや詳細なメッセージなど、表形式出力より多くのデータが表示される場合があります。

次のページに続く

表 11 – 前のページからの続き

Setting	Format	Considerations
yaml	YAML	JSON 出力に似ていますが、YAML として、フィールドがアルファベット順にオーダーされます。実験的であり、将来のバージョンでは完全にサポートされない可能性があります。

コマンドラインヘルプへのアクセス

サポートされているコマンドをリストするには、次を入力します。

```
pgd help
```

特定のコマンドとそのパラメーターのヘルプが必要な場合は、`pgd help <command_name>` と入力してください。例

```
pgd help show-nodes
```

8.14.3 Configuring PGD CLI

PGD CLI は、PGD クラスターに接続できる任意のシステムにインストールできます。PGD CLI を使用するには、PGD スーパーユーザー権限または同等のユーザーが必要です。スーパーユーザー権限を持つ PGD ユーザーは

> *bdr_superuser* のロールとレプリケーション

です。同等のユーザーの例は、BigAnimal 分散高可用性クラスターの edb_admin です。

PGD CLI とデータベース接続文字列

データベース接続文字列は必要ない場合があります。たとえば、Trused Postgres Architect はシステムに PGD CLI をインストールすると、PGD クラスターへの接続も構成します。これは、 PGD CLI が実行時にクラスターに接続できることを意味します。

PGD CLI を手動でインストールする場合は、 PGD CLI にデータベース接続文字列を指定して、どの PGD クラスターに接続するかを認識する必要があります。

- .pgpass にエントリを追加します。これには、ホスト、ポート、データベース名、ユーザー名、パスワードが含まれます。- `PGPASSWORD` 環境変数にパスワードを設定する。 - 接続文字列にパスワードを含めます。

他のオプションは複数のデータベースでうまく拡張できないか、パスワードの機密性が危険にさらされるため、最初のオプションをお勧めします。

その情報を入手したら、続行できます。

接続するデータベースの構成

PGD CLI は、 PGD CLI 構成ファイルまたはコマンドラインからデータベース接続情報を取得します。

コマンドラインでデータベース接続文字列を使用する

--dsn オプションを使用して、接続文字列を pgd に直接渡すことができます。詳細については、

sample use case を参照してください。例

```
pgd --dsn "host=bdr-a1 port=5432 user=enterprisedb" show-version
```

構成ファイルを使用する

pgd-cli-config.yml 構成ファイルを使用して、クラスターのデータベース接続文字列を指定します。構成ファイルには、クラスター内の少なくとも 1 つの PGD ノードのデータベース接続文字列が含まれている必要があります。クラスター名はオプショナルであり、検証されません。

例

```
cluster:
  name: cluster-name
  endpoints:
  - "host=bdr-a1 port=5432 dbname=bdrdb user=enterprisedb"
  - "host=bdr-b1 port=5432 dbname=bdrdb user=enterprisedb"
  - "host=bdr-c1 port=5432 dbname=bdrdb user=enterprisedb"
```

デフォルトでは、pgd-cli-config.yml は/etc/edb/pgd-cli ディレクトリにあります。 PGD CLI は、次の場所で pgd-cli-config.yml を検索します。優先順位は高から低です。

1./etc/edb/pgd-cli デフォルト 2.$HOME/.edb/pgd-cli

構成ファイルがこれらのディレクトリのいずれにもない場合は、 pgd コマンドでオプションの-f または--config-file フラグを使用して、構成として読み取るようにファイルを設定できます。

sample use case を参照してください。

8.14.4 Discovering connection strings

PGD CLI は、PGD クラスターに接続できる任意のシステムにインストールできます。PGD CLI を使用するには、PGD スーパーユーザー権限または同等のユーザーが必要です。スーパーユーザー権限を持つ PGD ユーザーは

bdr_superuser のロールとレプリケーション です。同等のユーザーの例は、EDB

BigAnimal 分散高可用性クラスターの edb_admin です。

PGD CLI とデータベース接続文字列

データベース接続文字列は必要ない場合があります。たとえば、Trused Postgres Architect はシステムに PGD CLI をインストールすると、PGD クラスターへの接続も構成します。これは、 PGD CLI が実行時にクラスターに接続できることを意味します。

データベース接続文字列の取得

PGD はさまざまな構成をサポートするため、すべての展開方法には、接続文字列を取得する異なる方法があります。通常、展開の構成から必要な情報を取得できます。次に、その情報を接続文字列にアセンブルできます。

TPA 展開された PGD クラスターの場合

TPA は非常に柔軟であるため、クラスター構成ファイル `config.yml` から接続文字列を導き出す必要があります。

- ロール pgd-proxy がリストされているホストの名前または IP アドレスが必要です。このホストには、接続できるプロキシがあります。通常、プロキシはポート 6432 でリッスンします。確認するには、構成の `default_pgd_proxy_options` および `listen_port` の設定を確認してください。
- デフォルトのデータベース名は `bdrdb` です。確認するには、構成の `bdr_database` 設定を確認してください。
- デフォルトの PGD スーパーユーザーは、 EDB Postgres Advanced Server の場合は enterprisedb であり、PostgreSQL および EDB Postgres Extended Server の場合は postgres です。

次に、その情報に基づいて接続文字列をアセンブルできます。

```
"host=<hostnameOrIPAddress> port=<portnumber> dbname=<databasename> user=<username>␣
↪sslmode=require"
```

これを説明するために、クラスターの `config.yml` ファイルの一部の抜粋を次に示します。

```
...
cluster_vars:
  ...
  bdr_database: bdrdb
  ...
  default_pgd_proxy_options:
    listen_port: 6432
  ...

instances:

- Name: kaboom
  backup: kapok
```

(次のページに続く)

(前のページからの続き)

```
  location: dc1
  node: 1
  role:
  - bdr
  - pgd-proxy
  networks:
  - ipv4_address: 192.168.100.2
    name: tpanet
...
```

このクラスターの接続文字列は次のとおりです。

```
"host=192.168.100.2 port=6432 dbname=bdrdb user=enterprisedb sslmode=require"
```

EDB BigAnimal 分散高可用性クラスターの場合

1. BigAnimal clusters ビューにログインします。

1. フィルターで **クラスタータイプ** を **分散高可用性** に設定して、PGD CLI で動作するクラスターのみを表示します。

1. クラスターを選択します。

1. クラスターのビューで、 **Connect** タブを選択します。

1. 接続情報から読み取り/書き込み URI をコピーします。これは接続文字列です。

Kubernetes の EDB PGD で展開されたクラスターの場合

TPA と同様に、Kubernetes の EDB PGD は非常に柔軟性があり、接続文字列を取得する方法は複数あります。これは、主に、デプロイメント用に services がどのように構成されたかによって異なります。

・ノードサービステンプレートを使用する場合、各ノードとプロキシサービスへの直接接続が利用できます。

- グループサービステンプレートを使用する場合、各グループへのゲートウェイサービスがあります。
- プロキシサービステンプレートを使用する場合、単一のプロキシがすべてのアプリケーションのクラスターへのエントリポイントを提供します。

構成ファイルを参照して、この情報を判断します。

ホスト名または IP アドレス、ポート、データベース名、およびユーザー名を確立します。デフォルトのデータベース名は bdrdb で、デフォルトのユーザー名は EDB Postgres Advanced Server の場合は enterprisedb であり、PostgreSQL および EDB Postgres Extended Server の場合は postgres です。

次に、その情報に基づいて接続文字列をアセンブルできます。

```
"host=<hostnameOrIPAddress> port=<portnumber> dbname=<databasename> user=<username>"
```

デプロイメントの構成で必要な場合、 sslmode=<sslmode> を追加します。

8.14.5 Command reference

pgd は、PGD コマンドラインインターフェイスのコマンド名です。

概要

EDB Postgres 分散コマンドラインインターフェイス PGD CLI は、 EDB Postgres 分散クラスターを管理するツールです。 EDB Postgres 分散クラスターに対してコマンドを実行できます。これを使用して、クラスターリソースを検査および管理できます。

オプション

```
-f, --config-file string   config file; ignored if
                           --dsn flag is present (default "/etc/edb/pgd-cli/pgd-cli-
↪config.yml")
    --dsn string           database connection string
                           e.g."host=bdr-a1 port=5432 dbname=bdrdb user=postgres "
-h, --help                 help for pgd
-L, --log-level string     logging level: debug, info, warn, error (default "error")
-o, --output string        output format: json, yaml
```

関連項目

- *check-health*
- *create-proxy*
- *delete-proxy*
- *set-group-options*
- *set-node-options*
- *set-proxy-options*
- *show-clockskew*
- *show-events*
- *show-groups*
- *show-nodes*
- *show-proxies*

- *show-raft*
- *show-replslots*
- *show-subscriptions*
- *show-version*
- **スイッチオーバー**
- *verify-cluster*
- *verify-settings*

check-health

EDB Postgres 分散クラスターの状態を確認します。

概要

すべてのノードがアクセス可能であり、すべてのレプリケーションスロットが動作しているかどうかなど、さまざまなチェックを実行します。

このコマンドの実行中にクラスターが高負荷になっている場合、または多数のノードが含まれている場合、クロックスキューの現在の実装は不正確なスキュー値を返す場合があることに注意してください。

```
pgd check-health [flags]
```

例

```
Example 1 (3 node cluster, bdr-a1 and bdr-c1 are up, bdr-b1 is down)

$ pgd check-health

Check      Status   Message
-----      ------   -------
ClockSkew  Critical Clockskew cannot be determined for at least 1 BDR node pair
Connection Critical The node bdr-b1 is not accessible
Raft       Warning  There is at least 1 node that is not accessible
Replslots  Critical There is at least 1 BDR replication slot which is inactive
Version    Warning  There is at least 1 node that is not accessible

Example 2 (3 node cluster, all nodes are up but system clocks are not in sync)

$ pgd check-health

Check      Status  Message
```

(次のページに続く)

(前のページからの続き)

```
-----      ------  -------
ClockSkew  Warning At least 1 BDR node pair has clockskew greater than 2 seconds
Connection Ok      All BDR nodes are accessible
Raft       Ok      Raft Consensus is working correctly
Replslots  Ok      All BDR replication slots are working correctly
Version    Ok      All nodes are running same BDR versions

Example 3 (3 node cluster, all nodes are up and all checks are Ok)

$ pgd check-health

Check      Status Message
-----      ------ -------
ClockSkew  Ok     All BDR node pairs have clockskew within permissible limit
Connection Ok     All BDR nodes are accessible
Raft       Ok     Raft Consensus is working correctly
Replslots  Ok     All BDR replication slots are working correctly
Version    Ok     All nodes are running same BDR versions
```

オプション

```
-h, --help   help for check-health
```

親コマンドから継承したオプション

```
-f, --config-file string   config file; ignored if
                           --dsn flag is present (default "/etc/edb/pgd-cli/pgd-cli-
↪config.yml")
    --dsn string           database connection string
                           e.g."host=bdr-a1 port=5432 dbname=bdrdb user=postgres "
-L, --log-level string     logging level: debug, info, warn, error (default "error")
-o, --output string        output format: json, yaml
```

create-proxy

EDB Postgres 分散クラスターにプロキシを作成します。

概要

EDB Postgres 分散クラスターにプロキシを作成し、指定されたグループに接続します。プロキシ名はクラスター全体で一意であり、対応するプロキシ構成ファイルで指定された名前と一致する必要があります。

```
pgd create-proxy [flags]
```

例

```
Example 1 (attach new proxy called proxy-a1 to group bdrgroup)

$ pgd create-proxy --proxy-name proxy-a1 --group-name bdrgroup
proxy created successfully
```

オプション

```
    --group-name string   group name
-h, --help                help for create-proxy
    --proxy-name string   proxy name
```

親コマンドから継承したオプション

```
-f, --config-file string   config file; ignored if
                           --dsn flag is present (default "/etc/edb/pgd-cli/pgd-cli-
↪config.yml")
    --dsn string           database connection string
                           e.g."host=bdr-a1 port=5432 dbname=bdrdb user=postgres "
-L, --log-level string     logging level: debug, info, warn, error (default "error")
-o, --output string        output format: json, yaml
```

delete-proxy

EDB Postgres 分散クラスターからプロキシを削除します。

概要

EDB Postgres 分散クラスターからプロキシを削除します。

```
pgd delete-proxy [flags]
```

例

```
Example 1 (delete proxy proxy-a1)

$ pgd delete-proxy --proxy-name proxy-a1
proxy deleted successfully
```

オプション

```
-h, --help                help for delete-proxy
    --proxy-name string   proxy name
```

親コマンドから継承したオプション

```
-f, --config-file string   config file; ignored if
                           --dsn flag is present (default "/etc/edb/pgd-cli/pgd-cli-
↪config.yml")
    --dsn string           database connection string
                           e.g."host=bdr-a1 port=5432 dbname=bdrdb user=postgres "
-L, --log-level string     logging level: debug, info, warn, error (default "error")
-o, --output string        output format: json, yaml
```

set-group-options

‘enable_raft’、‘enable_proxy_routing’、’location’などのグループオプションを設定します。

概要

このコマンドで次のグループオプションを設定できます。

- ‘enable_raft’
- ‘enable_proxy_routing’
- ‘location’
- ‘route_writer_max_lag’

プロキシがグループに接続されている場合、’enable_raft’と’enable_proxy_routing’の両方が true である必要があります。

’pgd show-groups -o json’を使用して、各グループのオプション値を表示します。

```
pgd set-group-options [flags]
```

例

```
Example 1 (comma separated multiple options, spaces are not allowed)

$ pgd set-group-options --group-name bdrgroup --option enable_proxy_routing=true,
↪route_writer_max_lag=1000000
group options updated successfully

Example 2 (multiple --option flags are allowed)

$ pgd set-group-options --group-name bdrgroup --option enable_proxy_routing=true --
↪option route_writer_max_lag=1000000
group options updated successfully

Example 3 (use double quote if option value has spaces or special characters)

$ pgd set-group-options --group-name bdrgroup --option "location = mumbai" --option
↪"route_writer_max_lag = 1000000"
group options updated successfully
```

オプション

```
    --group-name string   group name
-h, --help                help for set-group-options
    --option strings      option in name=value format
```

親コマンドから継承したオプション

```
-f, --config-file string   config file; ignored if
                           --dsn flag is present (default "/etc/edb/pgd-cli/pgd-cli-
↪config.yml")
    --dsn string           database connection string
                           e.g."host=bdr-a1 port=5432 dbname=bdrdb user=postgres "
-L, --log-level string     logging level: debug, info, warn, error (default "error")
-o, --output string        output format: json, yaml
```

set-node-options

‘route_fence’、‘route_priority’、’route_writes’などのノードオプションを設定します。

概要

このコマンドで次のノードオプションを設定できます。

- ‘route_dsn’
- ‘route_fence’
- ‘route_priority’
- ‘route_writes’

’pgd show-nodes -o json’を使用して、各ノードのオプション値を表示します。

```
pgd set-node-options [flags]
```

例

```
Example 1 (comma separated multiple options, spaces are not allowed)

$ pgd set-node-options --node-name bdr-a1 --option route_priority=100,route_fence=true
node options updated successfully

Example 2 (multiple --option flags are allowed)

$ pgd set-node-options --node-name bdr-a1 --option route_priority=100 --option route_
↪fence=true
node options updated successfully

Example 3 (use double quote if option value has spaces or special characters)

$ pgd set-node-options --node-name bdr-a1 --option "route_priority = 100" --option
↪"route_fence = true"
node options updated successfully
```

オプション

```
-h, --help               help for set-node-options
    --node-name string   node name
    --option strings     option in name=value format
```

親コマンドから継承したオプション

```
-f, --config-file string   config file; ignored if
                           --dsn flag is present (default "/etc/edb/pgd-cli/pgd-cli-
↪config.yml")
    --dsn string           database connection string
                           e.g."host=bdr-a1 port=5432 dbname=bdrdb user=postgres "
-L, --log-level string     logging level: debug, info, warn, error (default "error")
-o, --output string        output format: json, yaml
```

set-proxy-options

‘listen_address’、‘listen_port’、’ max_client_conn’などのプロキシオプションを設定します。

概要

このコマンドで次のプロキシオプションを設定できます。

- ‘listen_address’
- ‘listen_port’
- ‘max_client_conn’
- ‘max_server_conn’
- ‘server_conn_keepalive’
- ‘server_conn_timeout’
- ‘consensus_grace_period’

これらのオプションを更新した後、プロキシを再起動します。

’ pgd show-proxies -o json’を使用して、各プロキシのオプション値を表示します。

```
pgd set-proxy-options [flags]
```

例

```
Example 1 (comma separated multiple options, spaces are not allowed)

$ pgd set-proxy-options --proxy-name proxy-a1 --option listen_address=0.0.0.0,listen_
↪port=6432
proxy options updated successfully, please restart proxy service

Example 2 (multiple --option flags are allowed)

$ pgd set-proxy-options --proxy-name proxy-a1 --option listen_address=0.0.0.0 --
↪option listen_port=6432
proxy options updated successfully, please restart proxy service

Example 3 (use double quote if option value has spaces or special characters)

$ pgd set-proxy-options --proxy-name proxy-a1 --option "listen_address = 0.0.0.0" --
↪option "listen_port = 6432"
proxy options updated successfully, please restart proxy service
```

オプション

```
-h, --help                help for set-proxy-options
    --option strings      option in name=value format
    --proxy-name string   proxy name
```

親コマンドから継承したオプション

```
-f, --config-file string   config file; ignored if
                           --dsn flag is present (default "/etc/edb/pgd-cli/pgd-cli-
↪config.yml")
    --dsn string           database connection string
                           e.g."host=bdr-a1 port=5432 dbname=bdrdb user=postgres "
-L, --log-level string     logging level: debug, info, warn, error (default "error")
-o, --output string        output format: json, yaml
```

show-clockskew

各 BDR 間のクロックスキューの状態を示します。

概要

クラスター内の各 BDR 間のクロックスキューのステータスを示します。

このコマンドの実行中にクラスターが高負荷になっている場合、または多数のノードが含まれている場合、クロックスキューの現在の実装は不正確なスキュー値を返す場合があることに注意してください。

記号の意味 —— - —— – * ok ~ warning (skew > 2 秒) !クリティカルスキュー> 5 秒 x ダウン/到達不能 ?不明 - n/a

```
pgd show-clockskew [flags]
```

例

```
Example 1 (3 node cluster, bdr-a1 and bdr-c1 are up, bdr-b1 is down)

$ pgd show-clockskew

Node   bdr-a1 bdr-b1 bdr-c1 Current Time
----   ------ ------ ------ ------------
bdr-a1  *?*       2022-03-30 07:02:21.334472
bdr-b1 x      *      x      x
bdr-c1  *?*       2022-03-30 07:02:21.186809

Example 2 (3 node cluster, all nodes are up)

$ pgd show-clockskew

Node   bdr-a1 bdr-b1 bdr-c1 Current Time
----   ------ ------ ------ ------------
bdr-a1  **       *      2022-03-30 07:04:54.147017
bdr-b1  **       *      2022-03-30 07:04:54.340543
bdr-c1  **       *      2022-03-30 07:04:53.90451
```

オプション

```
-h, --help   help for show-clockskew
```

親コマンドから継承したオプション

```
-f, --config-file string   config file; ignored if
                           --dsn flag is present (default "/etc/edb/pgd-cli/pgd-cli-
↪config.yml")
    --dsn string           database connection string
                           e.g."host=bdr-a1 port=5432 dbname=bdrdb user=postgres "
-L, --log-level string     logging level: debug, info, warn, error (default "error")
-o, --output string        output format: json, yaml
```

show-events

バックグラウンドワーカーエラーやノードメンバーシップの変更などのイベントを表示します。

概要

バックグラウンドワーカーエラーやノードメンバーシップの変更などのイベントを表示します。出力は時間列の降順でソートされます。メッセージ列は数行後に切り捨てられます。完全なメッセージを表示するには、json 出力形式‘-o json’ を使用します。

各ノードの状態の詳細については、show-nodes コマンドのヘルプ’pgd show-nodes -h’を参照してください。

```
pgd show-events [flags]
```

例

```
Example 1 (3 node cluster)

$ pgd show-events --lines 10

Time                          Observer Node Subject Node Source    Type   Subtype
 Message
----                          ------------- ------------ ------    ----   -------
 -------
2023-03-23 05:38:25.243257+00 witness-a1    witness-a1   consensus RAFT   STATE_
↪CHANGE RAFT_LEADER
2023-03-23 05:38:25.23815+00  witness-a1    witness-a1   consensus RAFT   STATE_
```

(次のページに続く)

(前のページからの続き)

```
↪CHANGE RAFT_CANDIDATE
2023-03-23 05:38:21.197974+00 bdr-a1        bdr-a1       consensus RAFT   STATE_
↪CHANGE RAFT_FOLLOWER
2023-03-23 05:38:21.197107+00 witness-a1    witness-a1   consensus RAFT   STATE_
↪CHANGE RAFT_FOLLOWER
2023-03-23 05:38:21.169781+00 bdr-a2        bdr-a2       consensus RAFT   STATE_
↪CHANGE RAFT_FOLLOWER
2023-03-23 05:38:17.949669+00 witness-a1    bdr-a1       consensus NODE   STATE_
↪CHANGE ACTIVE
2023-03-23 05:38:17.949544+00 bdr-a1        bdr-a1       consensus NODE   STATE_
↪CHANGE ACTIVE
2023-03-23 05:38:17.946857+00 bdr-a2        bdr-a1       consensus NODE   STATE_
↪CHANGE ACTIVE
2023-03-23 05:38:17.91628+00  bdr-a1        bdr-a2       receiver  WORKER ERROR
 pglogical worker received fast finish request, exiting
2023-03-23 05:38:17.915236+00 witness-a1    bdr-a1       consensus NODE   STATE_
↪CHANGE PROMOTING
```

オプション

```
-h, --help        help for show-events
-n, --lines int   show top n lines
```

親コマンドから継承したオプション

```
-f, --config-file string   config file; ignored if
                           --dsn flag is present (default "/etc/edb/pgd-cli/pgd-cli-
↪config.yml")
    --dsn string           database connection string
                           e.g."host=bdr-a1 port=5432 dbname=bdrdb user=postgres "
-L, --log-level string     logging level: debug, info, warn, error (default "error")
-o, --output string        output format: json, yaml
```

show-groups

EDB Postgres 分散クラスター内のすべてのグループとその概要を表示します。

概要

EDB Postgres 分散クラスター内のすべてのグループとその概要を表示します。

raft が適切に動作していない場合、またはグループ raft リーダーが存在しない場合、このコマンドはそのグループの古いまたは誤った書き込みリーダーを表示する場合があります。

```
pgd show-groups [flags]
```

例

```
Example 1 (multi-group cluster, with special witness-only data group
group_c and subscriber-only group group_so)
Note:
1. For group write leader election both enable_raft and
enable_proxy_routing options should be true for that group
2. enable_raft is always set to true for global group

$ pgd show-groups

Group    Group ID   Type            Parent Group Location Raft  Routing Write Leader
-----    --------   ----            ------------ -------- ----  ------- ------------
bdrgroup 1360502012 global                                true  false
group_a  3618712053 data            bdrgroup     a        true  true    bdr-a1
group_b  402614658  data            bdrgroup     b        true  true    bdr-b1
group_c  2808307099 data            bdrgroup     c        false false
group_so 2123208041 subscriber-only bdrgroup     c        false false
```

オプション

```
-h, --help   help for show-groups
```

親コマンドから継承したオプション

```
-f, --config-file string   config file; ignored if
                           --dsn flag is present (default "/etc/edb/pgd-cli/pgd-cli-
↪config.yml")
    --dsn string           database connection string
                           e.g."host=bdr-a1 port=5432 dbname=bdrdb user=postgres "
-L, --log-level string     logging level: debug, info, warn, error (default "error")
-o, --output string        output format: json, yaml
```

show-nodes

EDB Postgres 分散クラスター内のすべてのノードとその概要を表示します。

概要

EDB Postgres 分散クラスター内のすべてのノードと、名前、ノード ID、グループ、現在の/ターゲット状態を含むその概要を表示します。

ノードの状態

- NONE ワーカーの起動時にノードの状態は設定解除され、現在の既知の状態にすぐに設定されることが予想されます。

*作成済み bdr.create_node() は実行されましたが、ノードはまだ EDB Postgres 分散クラスターのメンバーではありません。

- JOIN_START bdr.join_node_group() は、ローカルノードの既存の EDB Postgres 分散クラスターへの参加を開始します。
- JOINING ノード参加が開始され、現在初期同期フェーズにあり、ノードにスキーマとデータを作成します。
- CATCHUP 初期同期フェーズが完了しました。現在、結合は、結合が開始されてから上流のピアノードで実行されたトランザクションを取得および適用する最後のステップにあります。
- STANDBY ノード参加は完了しましたが、変更のブロードキャストはまだ開始されていません。すべての結合はこの状態でしばらく時間を費やしますが、論理スタンバイとして定義されている場合、ノードはこの状態で継続します。
- PROMOTE ノードはロジカルスタンバイであり、bdr.promote_node を呼び出してノードの状態を ACTIVE に移動したところです。これらの 2 つの PROMOTE 状態は、1 つのノードのみが STANDBY より高いが ACTIVE より低い状態になることができるという事実と一貫している必要があります。
- PROMOTING ロジカルスタンバイからフル BDR ノードへのプロモーションが進行中です。
- ACTIVE ノードは完全な BDR ノードであり、現在アクティブです。これは、最も一般的なノードのステータスです。
- PART_START ノードはアクティブまたはスタンバイで、bdr.part_node を呼び出して EDB Postgres 分散クラスターからノードを削除しました。
- PARTING ノードは他のノードから切断し、コンセンサスまたはレプリケーションでそれ以上の役割を果たしません。
- PART_CATCHUP 非分割ノードは、最近分割されたノードからの欠落データを同期します。
- PARTED ノード分割操作がすべてのノードで完了しました。

一度に 1 つのノードのみが PROMOTE または PROMOTING の状態になります。

Current State または Target State 列に表示されるノードの読み取り専用状態は、STANDBY として示されることに注意してください。

```
pgd show-nodes [flags]
```

例

```
Example 1 (3 node cluster, bdr-a1 and witness-a are up, bdr-a2 is down)

$ pgd show-nodes

Node      Node ID    Group   Type    Current State Target State Status      Seq ID
----      -------    -----   ----    ------------- ------------ ------      ------
bdr-a1    3136956818 group_a data    ACTIVE        ACTIVE       Up          1
bdr-a2    2133699692 group_a data    ACTIVE        ACTIVE       Unreachable 2
witness-a 3889635963 group_a witness ACTIVE        ACTIVE       Up          3

Example 2 (multi-group cluster with witness, logical standby and
subscriber-only nodes)
Note: In contrast to logical standby, the subscriber-only nodes are fully
joined node to the cluster

$ pgd show-nodes

Node               Node ID    Group    Type            Current State Target State␣
↪Status Seq ID
----               -------    -----    ----            ------------- ------------ ----
↪-- ------
bdr-a1             3136956818 group_a  data            ACTIVE        ACTIVE       Up
   6
bdr-a2             2133699692 group_a  data            ACTIVE        ACTIVE       Up
   3
logical-standby-a1 1140256918 group_a  standby         STANDBY       STANDBY      Up
   9
witness-a          3889635963 group_a  witness         ACTIVE        ACTIVE       Up
   7
bdr-b1             2380210996 group_b  data            ACTIVE        ACTIVE       Up
   1
bdr-b2             2244996162 group_b  data            ACTIVE        ACTIVE       Up
   2
logical-standby-b1 3541792022 group_b  standby         STANDBY       STANDBY      Up
   10
witness-b          661050297  group_b  witness         ACTIVE        ACTIVE       Up
   5
witness-c          1954444188 group_c  witness         ACTIVE        ACTIVE       Up
   4
subscriber-only-c1 2448841809 group_so subscriber-only ACTIVE        ACTIVE       Up
```

(次のページに続く)

(前のページからの続き)

```
  8
```

オプション

```
-h, --help   help for show-nodes
```

親コマンドから継承したオプション

```
-f, --config-file string   config file; ignored if
                           --dsn flag is present (default "/etc/edb/pgd-cli/pgd-cli-
↪config.yml")
    --dsn string           database connection string
                           e.g."host=bdr-a1 port=5432 dbname=bdrdb user=postgres "
-L, --log-level string     logging level: debug, info, warn, error (default "error")
-o, --output string        output format: json, yaml
```

show-proxies

EDB Postgres 分散クラスター内のすべてのプロキシとその概要を表示します。

概要

EDB Postgres 分散クラスター内のすべてのプロキシとその概要を表示します。

同じグループに接続されているすべてのプロキシに同じプロキシオプション値を与えることをお勧めします。

```
pgd show-proxies [flags]
```

例

```
Example 1 (multi-group cluster, with 2 proxies attached to each data group)

$ pgd show-proxies

Proxy    Group   Listen Addresses Listen Port
-----    -----   ---------------- -----------
proxy-a1 group_a [0.0.0.0]        6432
proxy-a2 group_a [0.0.0.0]        6432
```

(次のページに続く)

(前のページからの続き)

```
proxy-b1 group_b [0.0.0.0]        6432
proxy-b2 group_b [0.0.0.0]        6432
```

オプション

```
-h, --help   help for show-proxies
```

親コマンドから継承したオプション

```
-f, --config-file string   config file; ignored if
                           --dsn flag is present (default "/etc/edb/pgd-cli/pgd-cli-
↪config.yml")
    --dsn string           database connection string
                           e.g."host=bdr-a1 port=5432 dbname=bdrdb user=postgres "
-L, --log-level string     logging level: debug, info, warn, error (default "error")
-o, --output string        output format: json, yaml
```

show-raft

BDR Raft コンセンサスプロトコルの詳細を表示します。

概要

Raft インスタンス ID、Raft 状態リーダー、フォロワー、Raft 用語などの BDR Raft コンセンサスプロトコルの詳細を表示します。Raft がサブグループレベルで有効になっている場合、そのサブグループの Raft インスタンスも表示されます。

ネットワークパーティションなどの場合、出力は、CLI が接続されているノードによって異なる場合があります。

```
pgd show-raft [flags]
```

例

```
Example 1 (multi-group cluster with subgroup Raft and with witness,
logical standby, subscriber-only nodes)
Note: Unlike data or witness node, logical standby and subscriber-only
nodes dont have Raft voting rights (see Voting Nodes column).

$ pgd show-raft
```

(次のページに続く)

(前のページからの続き)

```
Instance Group    Node               Raft State    Raft Term Commit Index Nodes␣
↪Voting Nodes Protocol Version
-------- -----    ----               ----------    --------- ------------ ----- ------
↪------ ----------------
1        bdrgroup bdr-b1             RAFT_LEADER   0         383          10    7
       5000
1        bdrgroup bdr-a1             RAFT_FOLLOWER 0         383          10    7
       5000
1        bdrgroup bdr-a2             RAFT_FOLLOWER 0         383          10    7
       5000
1        bdrgroup bdr-b2             RAFT_FOLLOWER 0         383          10    7
       5000
1        bdrgroup logical-standby-a1 RAFT_FOLLOWER 0         383          10    7
       5000
1        bdrgroup logical-standby-b1 RAFT_FOLLOWER 0         383          10    7
       5000
1        bdrgroup subscriber-only-c1 RAFT_FOLLOWER 0         383          10    7
       5000
1        bdrgroup witness-a          RAFT_FOLLOWER 0         383          10    7
       5000
1        bdrgroup witness-b          RAFT_FOLLOWER 0         383          10    7
       5000
1        bdrgroup witness-c          RAFT_FOLLOWER 0         383          10    7
       5000
2        group_a  witness-a          RAFT_LEADER   1         2            4     3
       0
2        group_a  bdr-a1             RAFT_FOLLOWER 1         2            4     3
       0
2        group_a  bdr-a2             RAFT_FOLLOWER 1         2            4     3
       0
2        group_a  logical-standby-a1 RAFT_FOLLOWER 1         2            4     3
       0
3        group_b  witness-b          RAFT_LEADER   1         2            4     3
       0
3        group_b  bdr-b1             RAFT_FOLLOWER 1         2            4     3
       0
3        group_b  bdr-b2             RAFT_FOLLOWER 1         2            4     3
       0
3        group_b  logical-standby-b1 RAFT_FOLLOWER 1         2            4     3
       0
```

オプション

```
-h, --help   help for show-raft
```

親コマンドから継承したオプション

```
-f, --config-file string   config file; ignored if
                           --dsn flag is present (default "/etc/edb/pgd-cli/pgd-cli-
↪config.yml")
    --dsn string           database connection string
                           e.g."host=bdr-a1 port=5432 dbname=bdrdb user=postgres "
-L, --log-level string     logging level: debug, info, warn, error (default "error")
-o, --output string        output format: json, yaml
```

show-replslots

BDR レプリケーションスロットのステータスを示します。

概要

BDR レプリケーションスロットのステータスを示します。verbose フラグを使用した出力は、スロットがアクティブか、レプリケーション状態切断、ストリーミング、キャッチアップ、おおよその遅延などの詳細を提供します。

シンボル 意味 ——–——– * ok ~ warning (lag > 10M) !クリティカルラグ> 100M OR スロットが’inactive’ OR ‘disconnected’) x ダウン/到達不能 - n/a

マトリックスビューでは、バイトラグが括弧内に表示される場合があります。これは maxOf(WriteLag, FlushLag, ReplayLag, SentLag) です。

```
pgd show-replslots [flags]
```

例

```
Example 1 (3 node cluster, bdr-a1 and bdr-c1 are up, bdr-b1 is down)

$ pgd show-replslots

Node   bdr-a1 bdr-b1  bdr-c1
----   ------ ------  ------
bdr-a1  *!(6.6G)*
bdr-b1 x      *       x
```

(次のページに続く)

(前のページからの続き)

```
bdr-c1  *!(6.9G)*

$ pgd show-replslots --verbose

Origin Node Target Node Status (active/state) Write Lag (bytes/duration)    Flush Lag␣
↪(bytes/duration)    Replay Lag (bytes/duration)   Sent Lag (bytes)
----------- ----------- -------------------- -------------------------    ----------
↪----------------    ---------------------------   ----------------
bdr-a1      bdr-b1      f / disconnected      6.6G / 8 days 02:58:36.243723 6.6G / 8␣
↪days 02:58:36.243723 6.6G / 8 days 02:58:36.243723 6.6G
bdr-a1      bdr-c1      t / streaming         0B / 00:00:00                 0B /␣
↪00:00:00                 0B / 00:00:00                0B
bdr-c1      bdr-a1      t / streaming         0B / 00:00:00.000812          0B /␣
↪00:00:00.000812          0B / 00:00:00.000812          0B
bdr-c1      bdr-b1      f / disconnected      6.9G / 8 days 02:58:36.004415 6.9G / 8␣
↪days 02:58:36.004415 6.9G / 8 days 02:58:36.004415 6.9G

Example 2 (3 node cluster, bdr-b1 was down and it has just been restarted)

$ pgd show-replslots

Node   bdr-a1 bdr-b1  bdr-c1
----   ------ ------  ------
bdr-a1  *!(6.9G)*
bdr-b1  **        *
bdr-c1  *!(5.8G)*

$ pgd show-replslots --verbose

Origin Node Target Node Status (active/state) Write Lag (bytes/duration) Flush Lag␣
↪(bytes/duration) Replay Lag (bytes/duration) Sent Lag (bytes)
----------- ----------- -------------------- ------------------------- -------------
↪------------- --------------------------- ----------------
bdr-a1      bdr-b1      t / catchup           6.9G / 00:00:00.000778     6.9G /␣
↪00:00:00.000778     6.9G / 00:00:00.000778      6.9G
bdr-a1      bdr-c1      t / streaming         0B / 00:00:00.104121       0B /␣
↪00:00:00.104133       0B / 00:00:00.104133        0B
bdr-b1      bdr-a1      t / streaming         0B / 00:00:00              0B /␣
↪00:00:00              0B / 00:00:00               0B
bdr-b1      bdr-c1      t / streaming         0B / 00:00:00              0B /␣
↪00:00:00              0B / 00:00:00               0B
bdr-c1      bdr-a1      t / streaming         6.8K / 00:00:00            6.8K /␣
↪00:00:00            6.8K / 00:00:00             6.8K
bdr-c1      bdr-b1      t / catchup           5.5G / 00:00:00.008257     5.5G /␣
↪00:00:00.008257     5.5G / 00:00:00.008257      5.5G
```

(次のページに続く)

(前のページからの続き)

```
Example 3 (3 node cluster, all nodes are up and in streaming state)

$ pgd show-replslots

Node   bdr-a1 bdr-b1 bdr-c1
----   ------ ------ ------
bdr-a1  **       *
bdr-b1  **       *
bdr-c1  **       *

$ pgd show-replslots --verbose

Origin Node Target Node Status (active/state) Write Lag (bytes/duration) Flush Lag␣
↪(bytes/duration) Replay Lag (bytes/duration) Sent Lag (bytes)
----------- ----------- -------------------- ------------------------- -------------
↪------------- -------------------------- ----------------
bdr-a1      bdr-b1      t / streaming         0B / 00:00:00             0B /␣
↪00:00:00              0B / 00:00:00               0B
bdr-a1      bdr-c1      t / streaming         0B / 00:00:00             0B /␣
↪00:00:00              0B / 00:00:00               0B
bdr-b1      bdr-a1      t / streaming         0B / 00:00:00             0B /␣
↪00:00:00              0B / 00:00:00               0B
bdr-b1      bdr-c1      t / streaming         0B / 00:00:00             0B /␣
↪00:00:00              0B / 00:00:00               0B
bdr-c1      bdr-a1      t / streaming         0B / 00:00:00             528B /␣
↪00:00:00            528B / 00:00:00             0B
bdr-c1      bdr-b1      t / streaming         528B / 00:00:00           528B /␣
↪00:00:00            528B / 00:00:00             0B

Example 4 (cluster with witness, logical standby and subscriber-only nodes;
upstream for logical-standby-a1 is bdr-a1 and for logical-standby-b1 it is bdr-b1)
Note:
1. A logical standby is sent data only by one source node, but no other
nodes receive replication changes from it
2. Subscriber-only node subscribes to replication changes from other nodes
in the cluster, but no other nodes receive replication changes from it

$ pgd show-replslots

Node               bdr-a1 bdr-b1 logical-standby-a1 logical-standby-b1 subscriber-
↪only-c1 witness-c1
----               ------ ------ ------------------ ------------------ ---------------
↪--- ----------
bdr-a1              **        *_*                  *
```

(次のページに続く)

(前のページからの続き)

```
bdr-b1              **       -                    **                    *
logical-standby-a1 -      -      *                   -                    -
    -
logical-standby-b1 -      -      -                   *                    -
    -
subscriber-only-c1 -      -      -                   -                    *
    -
witness-c1          **       -                   -                    **
```

オプション

```
-h, --help      help for show-replslots
-v, --verbose   verbose output
```

親コマンドから継承したオプション

```
-f, --config-file string   config file; ignored if
                           --dsn flag is present (default "/etc/edb/pgd-cli/pgd-cli-
↪config.yml")
    --dsn string           database connection string
                           e.g."host=bdr-a1 port=5432 dbname=bdrdb user=postgres "
-L, --log-level string     logging level: debug, info, warn, error (default "error")
-o, --output string        output format: json, yaml
```

show-subscriptions

BDR サブスクリプション受信レプリケーションの詳細を表示します。

概要

オリジン/ターゲットノード、最後に再生されたトランザクションのタイムスタンプ、現在と最後に再生されたトランザクションのタイムスタンプ間の遅延など、BDR サブスクリプション着信レプリケーションの詳細を表示します。

```
pgd show-subscriptions [flags]
```

例

```
Example 1 (3 node cluster, bdr-a1 and bdr-c1 are up, bdr-b1 is down)

$ pgd show-subscriptions

Origin Node Target Node Last Transaction Replayed At  Lag Duration (seconds)
----------- ----------- ----------------------------  ----------------------
bdr-a1      bdr-c1      2022-04-23 13:13:40.854433+00 0.514275
bdr-b1      bdr-a1
bdr-b1      bdr-c1
bdr-c1      bdr-a1      2022-04-23 13:13:40.852233+00 0.335464

Example 2 (3 node cluster, bdr-b1 was down and it has just been restarted)

$ pgd show-subscriptions

Origin Node Target Node Last Transaction Replayed At  Lag Duration (seconds)
----------- ----------- ----------------------------  ----------------------
bdr-a1      bdr-b1      2022-04-23 13:14:45.669254+00 0.001686
bdr-a1      bdr-c1      2022-04-23 13:14:46.157913+00 -0.002009
bdr-b1      bdr-a1
bdr-b1      bdr-c1
bdr-c1      bdr-a1      2022-04-23 13:14:45.698472+00 0.259521
bdr-c1      bdr-b1      2022-04-23 13:14:45.667979+00 0.002961

Example 3 (3 node cluster, all nodes are up and in streaming state)

$ pgd show-subscriptions

Origin Node Target Node Last Transaction Replayed At  Lag Duration (seconds)
----------- ----------- ----------------------------  ----------------------
bdr-a1      bdr-b1      2022-04-23 13:15:39.732375+00 0.034462
bdr-a1      bdr-c1      2022-04-23 13:15:40.179618+00 0.002647
bdr-b1      bdr-a1      2022-04-23 13:15:39.719994+00 0.305814
bdr-b1      bdr-c1      2022-04-23 13:15:40.180886+00 0.001379
bdr-c1      bdr-a1      2022-04-23 13:15:39.714397+00 0.311411
bdr-c1      bdr-b1      2022-04-23 13:15:39.714397+00 0.052440

Example 4 (cluster with witness, logical standby and subscriber-only nodes;
upstream for logical-standby-a1 is bdr-a1 and for logical-standby-b1 it is bdr-b1)
Note: Logical standby and subscriber-only nodes receive changes but do not
send changes made locally to other nodes

$ pgd show-subscriptions
```

(次のページに続く)

(前のページからの続き)

```
Origin Node Target Node        Last Transaction Replayed At  Lag Duration (seconds)
----------- -----------        ----------------------------  ----------------------
bdr-a1      bdr-b1             2022-04-23 13:40:49.106411+00 0.853665
bdr-a1      logical-standby-a1 2022-04-23 13:40:50.72036+00  0.138430
bdr-a1      logical-standby-b1
bdr-a1      subscriber-only-c1 2022-04-23 13:40:50.72036+00  0.016226
bdr-a1      witness-c1         2022-04-23 13:40:50.470142+00 0.001514
bdr-b1      bdr-a1             2022-04-23 13:40:49.10174+00  1.095422
bdr-b1      logical-standby-a1
bdr-b1      logical-standby-b1 2022-04-23 13:40:50.713666+00 0.271213
bdr-b1      subscriber-only-c1 2022-04-23 13:40:50.713666+00 0.022920
bdr-b1      witness-c1         2022-04-23 13:40:50.471789+00 -0.000133
witness-c1  bdr-a1             2022-04-23 13:40:49.107706+00 1.089456
witness-c1  bdr-b1             2022-04-23 13:40:49.107706+00 0.852370
witness-c1  logical-standby-a1
witness-c1  logical-standby-b1
witness-c1  subscriber-only-c1 2022-04-23 13:40:50.719844+00 0.016742
```

オプション

```
-h, --help   help for show-subscriptions
```

親コマンドから継承したオプション

```
-f, --config-file string   config file; ignored if
                           --dsn flag is present (default "/etc/edb/pgd-cli/pgd-cli-
↪config.yml")
    --dsn string           database connection string
                           e.g."host=bdr-a1 port=5432 dbname=bdrdb user=postgres "
-L, --log-level string     logging level: debug, info, warn, error (default "error")
-o, --output string        output format: json, yaml
```

show-version

各ノードにインストールされている BDR と Postgres のバージョンを表示します。

概要

クラスター内の各ノードにインストールされている BDR と Postgres のバージョンを表示します。

```
pgd show-version [flags]
```

例

```
Example 1 (3 node cluster, bdr-a1 and bdr-c1 are up, bdr-b1 is down)

$ pgd show-version

Node   BDR Version Postgres Version
----   ----------- ----------------
bdr-c1 4.1.0       14.2 (EDB Postgres Extended Server 14.2.0) (Debian 2:14.2.0edbpge-
↪1.buster+1)
bdr-a1 4.1.0       14.2 (EDB Postgres Extended Server 14.2.0) (Debian 2:14.2.0edbpge-
↪1.buster+1)
bdr-b1

Example 2 (3 node cluster, all nodes are up)

$ pgd show-version

Node   BDR Version Postgres Version
----   ----------- ----------------
bdr-c1 4.1.0       14.2 (EDB Postgres Extended Server 14.2.0) (Debian 2:14.2.0edbpge-
↪1.buster+1)
bdr-a1 4.1.0       14.2 (EDB Postgres Extended Server 14.2.0) (Debian 2:14.2.0edbpge-
↪1.buster+1)
bdr-b1 4.1.0       14.2 (EDB Postgres Extended Server 14.2.0) (Debian 2:14.2.0edbpge-
↪1.buster+1)
```

オプション

```
-h, --help   help for show-version
```

親コマンドから継承したオプション

```
-f, --config-file string   config file; ignored if
                           --dsn flag is present (default "/etc/edb/pgd-cli/pgd-cli-
↪config.yml")
    --dsn string           database connection string
                           e.g."host=bdr-a1 port=5432 dbname=bdrdb user=postgres "
-L, --log-level string     logging level: debug, info, warn, error (default "error")
-o, --output string        output format: json, yaml
```

switchover

新しい書き込みリーダーに切り替えます。

概要

新しい書き込みリーダーに切り替えます。即時スイッチオーバーには、スイッチオーバー方法’fast’を使用します。’strict’を使用して、指定されたターゲットノードで遅延が’route_writer_max_lag’より小さくなるまで待機します。タイムアウトまたはその他の問題のためにスイッチオーバーが失敗した場合、BDRは特定のターゲットノードとは異なる書き込みリーダーを選択する場合があります。

```
pgd switchover [flags]
```

例

```
Example 1 (with required arguments, default method is strict and default
timeout is 10s)

$ pgd switchover --group-name group_a --node-name bdr-a1
switchover is complete

Example 2 (with optional arguments)

$ pgd switchover --group-name group_a --node-name bdr-a1 --method strict --timeout 15s
switchover is complete

Example 3 (immediate switchover)
```

(次のページに続く)

(前のページからの続き)

```
$ pgd switchover --group-name group_a --node-name bdr-a1 --method fast
switchover is complete
```

オプション

```
    --group-name string   group name
-h, --help                help for switchover
    --method string       switchover method (strict, fast)
                          strict - waits until lag on given node is less than route_
↪writer_max_lag
                          fast - immediate switchover, route_writer_max_lag is␣
↪ignored (default "strict")
    --node-name string    node name
    --timeout duration    timeout period when switchover method is strict (default␣
↪10s)
```

親コマンドから継承したオプション

```
-f, --config-file string   config file; ignored if
                           --dsn flag is present (default "/etc/edb/pgd-cli/pgd-cli-
↪config.yml")
    --dsn string           database connection string
                           e.g."host=bdr-a1 port=5432 dbname=bdrdb user=postgres "
-L, --log-level string     logging level: debug, info, warn, error (default "error")
-o, --output string        output format: json, yaml
```

verify-cluster

クラスターが AlwaysOn アーキテクチャごとのルールに従っているかどうかを確認します。

概要

クラスターが AlwaysOn アーキテクチャごとのルールに従っているかどうかを確認します。

```
pgd verify-cluster [flags]
```

例

```
Example 1 (cluster with not recommended architecture)

$ pgd verify-cluster

Check                                                                          ␣
↪Status   Groups
-----                                                                           --
↪----   ------
There is always at least 1 Global Group and 1 Data Group                        Ok
There are at least 2 data nodes in a Data Group (except for the witness-only group)␣
↪Critical group_b
There is at most 1 witness node in a Data Group                                ␣
↪Warning  group_a
Witness-only group does not have any child groups                               Ok
There is at max 1 witness-only group iff there is even number of local Data Groups ␣
↪Warning  bdrgroup
There are at least 2 proxies configured per Data Group if routing is enabled   ␣
↪Warning  group_a, group_b

Example 2 (cluster with recommended architecture)

$ pgd verify-cluster

Check                                                                          ␣
↪Status Groups
-----                                                                           --
↪---- ------
There is always at least 1 Global Group and 1 Data Group                        Ok
There are at least 2 data nodes in a Data Group (except for the witness-only group) Ok
There is at most 1 witness node in a Data Group                                 Ok
Witness-only group does not have any child groups                               Ok
There is at max 1 witness-only group iff there is even number of local Data Groups  Ok
There are at least 2 proxies configured per Data Group if routing is enabled    Ok
```

オプション

```
-h, --help   help for verify-cluster
```

親コマンドから継承したオプション

```
-f, --config-file string   config file; ignored if
                           --dsn flag is present (default "/etc/edb/pgd-cli/pgd-cli-
↪config.yml")
    --dsn string           database connection string
                           e.g."host=bdr-a1 port=5432 dbname=bdrdb user=postgres "
-L, --log-level string     logging level: debug, info, warn, error (default "error")
-o, --output string        output format: json, yaml
```

verify-settings

EDB Postgres 分散クラスター設定を確認します。

概要

EDB Postgres 分散クラスター設定を確認します。

```
pgd verify-settings [flags]
```

例

```
Example 1

$ pgd verify-settings

# bdr.accept_connections
Node               Status   Pending Restart Value Message
----               ------   --------------- ----- -------
bdr-a1             Critical false           off   must be set to on
bdr-a2             Ok       false           on
bdr-b1             Ok       false           on
bdr-b2             Ok       false           on
logical-standby-a1 Ok       false           on
logical-standby-b1 Ok       false           on
subscriber-only-c1 Ok       false           on
witness-a          Ok       false           on
```

(次のページに続く)

(前のページからの続き)

```
witness-b          Ok       false           on
witness-c          Ok       false           on
Warning: value must be same on all primary nodes

# bdr.ddl_locking
Ok: all node values are ok

# bdr.ddl_replication
Node               Status  Pending Restart Value Message
----               ------  --------------- ----- -------
bdr-a1             Warning false           0     must be set to on
bdr-a2             Ok      false           on
bdr-b1             Ok      false           on
bdr-b2             Ok      false           on
logical-standby-a1 Ok      false           on
logical-standby-b1 Ok      false           on
subscriber-only-c1 Ok      false           on
witness-a          Ok      false           on
witness-b          Ok      false           on
witness-c          Ok      false           on
Warning: value must be same on all primary nodes

# bdr.max_writers_per_subscription
Ok: all node values are ok

# bdr.raft_group_max_connections
Ok: all node values are ok

# bdr.replay_progress_frequency
Node               Status  Pending Restart Value Message
----               ------  --------------- ----- -------
bdr-a1             Warning false           61000 must be <= 60000
bdr-a2             Ok      false           60000
bdr-b1             Ok      false           60000
bdr-b2             Ok      false           60000
logical-standby-a1 Ok      false           60000
logical-standby-b1 Ok      false           60000
subscriber-only-c1 Ok      false           60000
witness-a          Ok      false           60000
witness-b          Ok      false           60000
witness-c          Ok      false           60000
Warning: value must be same on all primary nodes

# bdr.role_replication
Node               Status  Pending Restart Value Message
```

(次のページに続く)

(前のページからの続き)

```
----                 ------  --------------- ----- -------
bdr-a1               Warning false           off   must be set to on
bdr-a2               Ok      false           on
bdr-b1               Ok      false           on
bdr-b2               Ok      false           on
logical-standby-a1 Ok      false           on
logical-standby-b1 Ok      false           on
subscriber-only-c1 Ok      false           on
witness-a            Ok      false           on
witness-b            Ok      false           on
witness-c            Ok      false           on
Warning: value must be same on all primary nodes

# bdr.standby_slot_names
Node                 Status  Pending Restart Value         Message
----                 ------  --------------- -----         -------
bdr-a1               Warning false           bdr_bdrdb_ja··· must contain valid logical␣
↪slots of peer data nodes only
bdr-a2               Warning false           bdr_bdrdb_ja··· must contain valid logical␣
↪slots of peer data nodes only
bdr-b1               Warning false                         must contain valid logical␣
↪slots of peer data nodes only
bdr-b2               Warning false                         must contain valid logical␣
↪slots of peer data nodes only
logical-standby-a1 Ok      false
logical-standby-b1 Ok      false
subscriber-only-c1 Ok      false
witness-a            Ok      false
witness-b            Ok      false
witness-c            Ok      false

# bdr.standby_slots_min_confirmed
Node                 Status  Pending Restart Value Message
----                 ------  --------------- ----- -------
bdr-a1               Warning false           -1    must be >= 1
bdr-a2               Warning false           -1    must be >= 1
bdr-b1               Warning false           -1    must be >= 1
bdr-b2               Warning false           -1    must be >= 1
logical-standby-a1 Ok      false           -1
logical-standby-b1 Ok      false           -1
subscriber-only-c1 Ok      false           -1
witness-a            Ok      false           -1
witness-b            Ok      false           -1
witness-c            Ok      false           -1
```

(次のページに続く)

(前のページからの続き)

```
# bdr.start_workers
Ok: all node values are ok

# bdr.xact_replication
Ok: all node values are ok

# max_prepared_transactions
Node                Status  Pending Restart Value Message
----                ------  --------------- ----- -------
bdr-a1              Warning false           16    must be >= 250
bdr-a2              Warning false           16    must be >= 250
bdr-b1              Warning false           16    must be >= 250
bdr-b2              Warning false           16    must be >= 250
logical-standby-a1 Warning false           16    must be >= 250
logical-standby-b1 Warning false           16    must be >= 250
subscriber-only-c1 Warning false           16    must be >= 250
witness-a           Warning false           16    must be >= 250
witness-b           Warning false           16    must be >= 250
witness-c           Warning false           16    must be >= 250

# max_replication_slots
Node                Status   Pending Restart Value Message
----                ------   --------------- ----- -------
bdr-a1              Critical false           8     must be >= 10
bdr-a2              Ok       false           12
bdr-b1              Ok       false           12
bdr-b2              Ok       false           12
logical-standby-a1 Ok       false           12
logical-standby-b1 Ok       false           12
subscriber-only-c1 Ok       false           12
witness-a           Ok       false           12
witness-b           Ok       false           12
witness-c           Ok       false           12
Warning: value must be same on all primary nodes

# max_wal_senders
Ok: all node values are ok

# max_worker_processes
Ok: all node values are ok

# shared_preload_libraries
Node                Status  Pending Restart Value         Message
----                ------  --------------- -----         -------
bdr-a1              Warning false           pg_stat_stat… must contain bdr as first␣
```

(次のページに続く)

(前のページからの続き)

```
↪entry
bdr-a2              Warning false           pg_stat_stat··· must contain bdr as first␣
↪entry
bdr-b1              Warning false           pg_stat_stat··· must contain bdr as first␣
↪entry
bdr-b2              Warning false           pg_stat_stat··· must contain bdr as first␣
↪entry
logical-standby-a1 Warning false            pg_stat_stat··· must contain bdr as first␣
↪entry
logical-standby-b1 Warning false            pg_stat_stat··· must contain bdr as first␣
↪entry
subscriber-only-c1 Warning false            pg_stat_stat··· must contain bdr as first␣
↪entry
witness-a           Warning false           pg_stat_stat··· must contain bdr as first␣
↪entry
witness-b           Warning false           pg_stat_stat··· must contain bdr as first␣
↪entry
witness-c           Warning false           pg_stat_stat··· must contain bdr as first␣
↪entry

# track_commit_timestamp
Ok: all node values are ok

# wal_level
Ok: all node values are ok
```

オプション

```
-h, --help   help for verify-settings
```

親コマンドから継承したオプション

```
-f, --config-file string   config file; ignored if
                           --dsn flag is present (default "/etc/edb/pgd-cli/pgd-cli-
↪config.yml")
    --dsn string           database connection string
                           e.g."host=bdr-a1 port=5432 dbname=bdrdb user=postgres "
-L, --log-level string     logging level: debug, info, warn, error (default "error")
-o, --output string        output format: json, yaml
```

8.15 Transaction streaming

論理レプリケーションでは、トランザクションはパブリッシャーで同時にデコードされますが、トランザクションがコミットされるまでサブスクライバーに送信されません。変更が `logical_decoding_work_mem` PostgreSQL 13 以降を超える場合、それらはディスクにあふれます。これは、特に大規模なトランザクションの場合、サブスクライバーに到達するまでにある程度の遅延が発生し、パブリッシャーで追加の I/O を必要とする場合があることを意味します。

PostgreSQL 14 以降、パブリッシャーでコミットされる前に、オプションでトランザクションをデコードして、サブスクライバーに送信できます。サブスクライバは、着信した変更をステージングファイルまたはファイルセットに保存し、トランザクションがコミットするときに適用します、またはトランザクションがアボートする場合は破棄します。これにより、トランザクションがコミットされるとすぐに、サブスクライバーにトランザクションを適用できるようになります。

8.15.1 PGD の機能強化

PostgreSQL のビルトイントランザクションストリーミングには、次の制限があります。

- パブリッシャーのディスクに変更をスピルする必要はありませんが、各サブスクライバーのディスクに変更を書き込む必要があります。
- トランザクションが中止される場合、作業各サブスクライバが受け取った変更および関連するストレージ I/O は無駄になります。

ただし、バージョン 3.7 以降、PGD はパラレル適用をサポートし、各サブスクライバーでマルチプルのライタプロセスを有効にします。この機能を活用して、次の機能強化を提供します。

- デコードされたトランザクションは、サブスクライバーのライタに直接ストリーミングできます。
- デコードされたトランザクションは、サブスクライバーのディスクに保存する必要はありません。
- サブスクライバーへのトランザクションの適用を開始する前に、トランザクションがコミットされるのを待機する必要はありません。

注意事項

- 並列適用を有効にする必要があります。
- 多数の小規模で競合するトランザクションで構成されるワークロードは、ライター間で頻繁なデッドロックを発生させる可能性があります。

注釈: ライタへの直接ストリーミングはまだ実験的な機能です。注意して使用してください。具体的には、ストリーミングのコミットタイムスタンプを利用できない可能性があるため、競合解決ではうまく機能しない可能性があります。トランザクションはオリジンでまだコミットされていない可能性があります。

8.15.2 構成

2 つの場所でトランザクションストリーミングを構成します。

- ノードレベルで、 GUC *bdr.default_streaming_mode* を使用したノード構成 を使用
- グループレベルで、ファンクション *bdr.alter_node_group_config()* を使用したグループ構成 を使用

bdr.default_streaming_mode を使用したノード構成

許可される値は次のとおりです。

- `off`
- `writer`
- `file`
- `auto`

デフォルト値は `auto` です。

この設定を変更するには、設定を有効にするために各サブスクリプションの pglogical レシーバープロセスを再起動する必要があります。これは、サーバーを再起動することで実現できます。

`bdr.default_streaming_mode` が `off` 以外の値に設定されている場合、サブスクライバーはパブリッシャーにトランザクションストリーミングを要求します。これが提供される方法は、グループ構成設定によっても異なります。詳細は、

> *bdr.default_streaming_mode* を使用したノード構成 を参照してください。

bdr.alter_node_group_config() を使用したグループ構成

ファンクションでパラメーター `streaming_mode` を使用できます
> *bdr.alter_node_group_config()* を使用したグループ構成

グループトランザクションストリーミング構成を設定します。

許可される値は次のとおりです。

- `off`
- `writer`
- `file`
- `auto`
- `default`

デフォルト値は `default` です。

現在の設定の値は、ビュー
> *bdr.node_group_config* の列 `node_group_streaming_mode`

に含まれています。返される値は単一の char 型で、使用可能な値は D default 、W writer 、 F file 、 A auto 、および O off です。

構成設定の効果

トランザクションストリーミングは、GUC bdr.default_streaming_mode によってサブスクライバーレベルで制御されます。トランザクションストリーミングを無効にする off に設定されていない限り、サブスクライバーはトランザクションストリーミングを要求します。

パブリッシャーがトランザクションストリーミングを提供できる場合、トランザクションサイズが logical_decoding_work_mem で設定されたしきい値を超えるたびに、トランザクションをストリーミングします。通常、パブリッシャーは、トランザクションをファイルにストリーミングするか、ライタにストリーミングするかを制御できません。COPY などの一部の状況を除き、サブスクライバーがトランザクションをライタにストリーミングすることを示唆する場合があります可能であれば。

サブスクライバーは、パブリッシャーから受け取ったトランザクションをライタまたはファイルにストリーミングできます。決定はいくつかの要素に基づいて行われます。

- 並列適用がオフ num_writers = 1 の場合、ファイルにストリーミングされます。ライタ 0 は常に非ストリーミングトランザクション用に予約されています。
- 並列適用がオンになっているが、すべてのライターがすでにビジー状態である場合、新しいトランザクションはファイルにストリーミングされます。PGD ライタのステータスを確認するには、*PGD ライターのモニタリング* を参照してください。

ライタへのストリーミングが可能である場合、つまりフリーライタが利用可能な場合、トランザクションをライタにストリーミングするかファイルにストリーミングするかは、次の表にあるグループとノード設定の組み合わせに基づいて決定されます。

Group	Node	Streamed to
off	(any)	(none)
(any)	off	(none)
writer	file	file
file	writer	file
default	writer	writer
default	file	file
default	auto	writer
auto	(any)	writer

グループ構成が auto に設定されている場合、またはグループ構成が default でノード構成が auto である場合、パブリッシャーがこれを行うことをヒントにした場合にのみ、トランザクションはライタにストリーミングされます。

現在、パブリッシャーは、サブスクライバーが次のトランザクションタイプのライタにストリーミングすることを示唆しています。これらは競合しないことが知られており、ライタが安全に処理できます。

- COPY
- CREATE INDEX CONCURRENTLY

8.15.3 モニタリング

bdr.stat_subscription を使用して、トランザクションストリーミングの使用をモニタできます。

サブスクライバノード上のファンクション。

- nstream_writer —ライタにストリーミングされたトランザクションの数。
- nstream_file —ファイルにストリーミングされたトランザクションの数。
- nstream_commit —コミットされたストリーミングトランザクションの数。
- nstream_abort —中止されたストリーミングトランザクションの数。
- nstream_start —開始されたストリーミングトランザクションの数。
- nstream_stop —完全に受信されたストリーミングトランザクションの数。

8.16 Testing and tuning PGD clusters

次のアプローチを使用して PGD アプリケーションをテストできます。

- *Deploying EDB Postgres Distributed using Trusted Postgres Architect*
- pgd_bench with CAMO/Failover options

8.16.1 Trusted Postgres アーキテクト

Deploying EDB Postgres Distributed using Trusted Postgres Architect は、 EDB Postgres Distributed に基づくものを含むリファレンスアーキテクチャを展開するために EDB が使用するシステムです。

Trusted Postgres Architect には、各リファレンスアーキテクチャのテストスイートが含まれています。また、次のような構文を使用して、TPA クラスターに対して実行するテストのローカルコレクションの作成と管理も簡素化します。

```
tpaexec test mycluster mytest
```

開発者は、アプリケーションの主な予想されるプロパティを検証する Trused Postgres Architect テストの独自のマルチノードスイートを作成することを強くお勧めします。

8.16.2 pgd_bench

Postgres ベンチマークアプリケーション *pgbench* は、新しいアプリケーション pgd_bench の形で PGD 5.0 で拡張されました。

pgd_bench は、PostgreSQL

bin ディレクトリに追加される通常のコマンドラインユーティリティです。このユーティリティは、PostgreSQL pgbench ツールに基づいていますが、CAMO トランザクションと PGD 固有のワークロードのベンチマークをサポートしています。

pgd_bench の機能は pgbench の機能のスーパーセットですが、正常に動作するには BDR 拡張機能をインストールする必要があります。

主な違いは次のとおりです。

- 特定の場合にグローバルロックタイムアウトを防ぐための標準の pgbench シナリオでの初期化 `-i` フラグを調整。
- 標準シナリオの `VACUUM` コマンドは、すべてのノードで実行されます。
- pgd_bench リリースは BDR 拡張機能のリリースに関連付けられ、対応する Postgres ディストリビューションに対してビルドされます。これは、`--version` フラグの出力に反映されます。

現在のバージョンでは、CAMO または通常の PGD 展開を使用しながらフェールオーバーテストを実行できます。

次のオプションが追加されました。

```
- m, --mode=regular|camo|failover
mode in which pgbench should run (default: regular)
```

- `-m camo` または `-m failover` を使用して、pgd_bench のモードを指定します。 `-m failover` 仕様を使用して、通常の PGD 展開でフェイルオーバーをテストできます。

```
- -retry
retry transactions on failover
```

- `--retry` を使用して、 `-m failover` モードでフェイルオーバーが発生したときにトランザクションをリトライするかどうかを指定します。このオプションは `-m camo` モードではデフォルトで有効になっています。

これらのオプションに加えて、 DSN form でフェールオーバーのピアノードに関する接続情報を指定する必要があります。

次に、 CAMO 環境の例を示します。

```
pgd_bench -m camo -p $node1_port -h $node1_host bdrdemo \
    "host=$node2_host user=postgres port=$node2_port dbname=bdrdemo"
```

このコマンドは CAMO モードで実行されます。ノード 1 に接続し、テストを実行します。ノード 1 への接続が失われると、pgd_bench はノード 2 に接続します。ノード 2 を照会して、進行中のトランザクショ

ンのステータスを取得します。中止されたトランザクションおよび進行中のトランザクションは、CAMO モードで再試行されます。

フェイルオーバーモードで`--retry`を指定すると、進行中のトランザクションが再試行されます。このシナリオでは、進行中のトランザクションのステータスを見つける方法はありません。

8.16.3 pgd_bench の使用に関する注意事項

- カスタム init スクリプトを使用する場合、DDL コマンドの背後にある意味を理解することが重要です。通常、`CREATE INDEX`などの DDL 操作を続行する前に、セカンダリノードがデータのロード手順に追いつくのを待機することをお勧めします。後者は、データのロードが完了するまで取得できないグローバルロックを取得するため、タイムアウトになる可能性があります。
- PostgreSQL および/または BDR 拡張機能を含む考えられる拡張機能によって発行される`NOTICE`および`WARNING`メッセージなどのクライアントメッセージを抑制するために追加の手順は実行されません。`client_min_messages`、`bdr.camo_enable_client_warnings`などの適切な変数を設定してそれらを抑制するのはあなたの責任です。

パフォーマンスのテストとチューニング

PGD を使用すると、マルチプルのノードに書き込みトランザクションを発行できます。これらの書き込みを各ノードに戻すと、パフォーマンスのコストが発生します。

第一に、別のノードからの変更の再生には、CPU コストと I/O コストが発生し、WAL レコードが生成されます。SQL を再実行する必要がないため、CPU オーバーヘッドが低いため、通常、リソースの使用量は元のトランザクションよりも少なくなります。UPDATE および DELETE トランザクションの場合、データがキャッシュされていない場合、再生時に I/O コストが発生する可能性があります。

次に、変更の再生は、テーブルレベルおよび行レベルのロックを保持するため、ローカルワークロードに対する競合を生成する可能性があります。競合のないレプリケートデータ型 CRDT と列レベルの競合検出 CLCD 機能は、同時更新の場合でも正しい回答を取得しますが、通常のロックオーバーヘッドは削除されません。ロック競合が発生した場合は、競合する更新を回避するか、トランザクションをできるだけ短くしてください。大規模なトランザクションで頻繁に更新された行は、そのトランザクションのパフォーマンスのボトルネックを発生させます。複雑なアプリケーションでは、スケーラビリティを維持するためにいくつかの考慮が必要です。

パフォーマンスに問題があると思われる場合は、ベンチマークツールを使用してパフォーマンステストを開発します。pgd_bench を使用すると、ユースケースに固有のカスタムテストスクリプトを作成できるため、SQL のオーバーヘッドを理解し、同時実行の影響を測定できます。

PGD の実行が遅い場合、次のことをお勧めします。

1. 実稼働システムの問題ケースにできる限り近づけて、pgd_bench のカスタムテストスクリプトを作成します。
2. 1 つのノードでスクリプトを実行して、ベースライン図を取得します。
3. 1 つのノードで実行したのと同じ合計数のセッションを使用して、運用環境で発生するのと同じ数のノードでスクリプトを実行します。このテクニックは、複数のノードに移動した効果を示します。

4. これらの 2 つのテストのセッション数を増やして、アプリケーションでの競合の増加による影響をプロットできます。

5. テストがレプリケーションの遅延を考慮して十分な長さであることを確認します。

6. テスト中にレプリケーション遅延が増加していないことを確認します。

通常の Postgres チューニング機能をすべて使用して、アプリケーションの重要な部分の速度を向上させます。

8.17 Stream triggers

PGD は、ダウンストリーム/ターゲットノードでの追加データ処理に使用できる新しいタイプのトリガーを導入しました。

- 競合トリガー
- トランスフォームトリガー

これらのタイプのトリガーは、まとめて **ストリームトリガー** と呼ばれます。

ストリームトリガーは、構文がトリガーのようなものになるように設計されています。これらは PostgreSQL BEFORE トリガーアーキテクチャを活用し、PostgreSQL BEFORE トリガーと同様のパフォーマンス特性を持つ可能性があります。

通常の PostgreSQL トリガーと同様に、複数のトリガー定義で 1 つのトリガーファンクションを使用できます。トリガーファンクションは、`CREATE FUNCTION ... RETURNS TRIGGER` 形式で定義されたプログラムです。トリガーの作成に、 `CREATE TRIGGER` コマンドを使用する必要はありません。代わりに、特別な PGD ファンクション

> *bdr.create_conflict_trigger()* および *bdr.create_transform_trigger()* を使用してストリームトリガーを作成します。

トリガーは、作成されると、カタログテーブル `pg_trigger` に表示されます。ストリームトリガーは `tgisinternal = true` および `tgenabled = 'D'` としてマークされ、名前サフィックス’_bdrc’または’_bdrt’が付いています。`bdr.triggers` ビューは、テーブルに関連するトリガー、実行されているプロシージャーの名前、それをトリガーするイベント、およびトリガータイプに関する情報を提供します。

ストリームトリガーは、通常の SQL 処理では有効になっていません。このため、`ALTER TABLE ... ENABLE TRIGGER` は、特定の名前バリアントと ALL バリアントの両方でストリームトリガーに対してブロックされます。このメカニズムにより、トリガーは通常の SQL トリガーとして実行されません。

これらのトリガーは、ダウンストリームまたはターゲットノードで実行されます。元のノードで実行するオプションはありません。ただし、オリジンで `row_filter` 式の使用を検討することができます。

また、ストリームトリガーの実行中に適用される DML は、他の PGD ノードにレプリケートされず、標準のローカルトリガーの実行をトリガーしません。これは意図的なものです。たとえば、これを使用して、ストリームトリガーによってキャプチャされた変更または競合を、クラッシュセーフでそのノードに固有のテーブルにログに記録できます。実用的な例については、
ストリームトリガーの例 を参照してください。

8.17.1 適用中のトリガー実行

変換トリガーは、トリガーテーブルに着信する変更ごとに 1 回実行されます。これらのトリガーは、一致するターゲット行を見つけようとする前に起動するため、非常に幅広い変換を効率的かつ一貫して適用できます。

次に、UPDATE および DELETE 変更の場合、ターゲット行を見つけます。ターゲット行がない場合、これらの変更タイプに対してそれ以上の処理は発生しません。

次に、テーブルレベルでレプリカトリガーとして明示的に有効にされていたノーマルトリガーを実行します。

```
ALTER TABLE tablename
ENABLE REPLICA TRIGGER trigger_name;
```

次に、潜在的な競合が存在するかどうかを判断します。その場合、そのテーブルに存在する競合トリガーを呼び出します。

欠落列の競合の解決

変換トリガーが実行される前に、PostgreSQL は着信タプルをターゲットテーブルの行タイプと照合しようとします。

入力行には存在するがターゲットテーブルには存在しない列は、target_column_missing タイプの競合をトリガーします。逆に、ターゲットテーブルには存在するが、入力行にない列は、source_column_missing 競合をトリガーします。これらの 2 つの競合タイプのデフォルトの解決策は、それぞれ ignore_if_null および use_default_value です。

これは、ローリングスキーマのアップグレードのコンテキストで関連しますたとえば、スキーマの新しいバージョンが新しい列を導入する場合。古いバージョンのスキーマから新しいバージョンにレプリケートする場合、ソース列が欠落しており、新しく導入された列にデフォルト値を移入する use_default_value ストラテジーが適切です。

ただし、新しいスキーマバージョンを持つノードから古いスキーマバージョンを持つノードに複製する場合、ターゲットテーブルから列が失われます。ignore_if_null リゾルバーは、ユーザーがアップグレードされたノードの新しい列に NULL 以外の値を含むタプルを挿入するとすぐにレプリケーションを中断するため、ローリングアップグレードには適していません。

この例を考慮すると、ローリングスキーマアップグレードの適切な設定は、target_column_missing 競合が発生した場合に ignore リゾルバーを適用するように各ノードを構成することです。

これは、次のクエリーで行うことができます。これは、各ノードで個別に実行する必要があります。node1 を実際のノード名に置き換えます。

```
SELECT bdr.alter_node_set_conflict_resolver(node1,
    target_column_missing, ignore);
```

データ損失と発散リスク

競合リゾルバーを ignore に設定すると、データの損失とクラスターの発散が発生する可能性があります。

次の例を考えます。テーブル t はノード 1 および 2 に存在しますが、その列 col はノード 1 にのみ存在します。

競合リゾルバーが ignore に設定されている場合、ノード 1 に c が null でない行、たとえば (pk=1, col=100) が存在する場合があります。その行はノード 2 にレプリケートされ、列 c の値は破棄されますたとえば、(pk=1) 。

列 c がノード 2 のテーブルに追加される場合、最初に既存のすべての行で NULL に設定され、上記で検討される行は (pk=1, col=NULL) になります。 pk=1 を持つ行はすべてのノードで同一ではなくなり、したがって、クラスターは発散します。

ノード 2 にレプリケートされた行には col=NULL があるため、デフォルトの ignore_if_null リゾルバーはこのリスクの影響を受けません。

この例に基づいて、 ignore リゾルバーが使用されたローリングスキーマアップグレードの最後に、クラスター全体に対して LiveCompare を実行することをお勧めします。この実践は、発散を確実に検出および修正するのに役立ちます。

8.17.2 行型の用語

次の行タイプを使用します。

- SOURCE_OLD は更新前の行、つまりキーです。
- SOURCE_NEW は、別のノードからの新しい行です。
- TARGET は、ノードに既に存在する行、つまり競合する行です。

8.17.3 競合トリガー

競合トリガーは、PGD によって競合が検出されると実行されます。彼らは、紛争が発生したときに何が起こるかを決定します。

- トリガーファンクションが行を返した場合、アクションはターゲットに適用されます。
- トリガーファンクションが NULL 行を返した場合、アクションはスキップされます。

たとえば、DELETE に対してトリガーが呼び出された場合、DELETE をスキップする場合、トリガーは NULL を返します。 DELETE を続行する場合は、行値を返します。SOURCE_OLD または TARGET のいずれかが機能します。競合するオペレーションが INSERT または UPDATE で、選択された解決が競合する行を削除することである場合、トリガーは明示的に削除を実行し、NULL を返す必要があります。トリガーファンクションは、選択した他の SQL アクションを実行できますが、これらのアクションはローカルにのみ適用され、レプリケートされません。

2 つ以上のノード間で実際のデータの競合が発生すると、2 つ以上の変更が同時に発生します。変更が適用されると、競合の解決は各ノードで独立して発生します。これは、競合の解決が各ノードで 1 回発生し、

それらの間で大幅な時間差で発生する可能性があることを意味します。その結果、競合トリガーの複数の実行間の通信は不可能です。トリガーが関連するすべてのイベントに対してまったく同じ結果を与えることを確認するのは、競合トリガーの作成者の責任です。そうしないと、データの相違が発生します。テクニカルサポートは、PGD に付属している分離テスターツールを使用して、すべての競合トリガーを正式にテストすることをお勧めします。

警告:

- 単一のテーブルに複数の競合トリガーを指定できますが、それらは個別のイベントと一致する必要があります。つまり、各競合は、単一の競合トリガーのみと一致する必要があります。 - 同じテーブルの同じイベントに一致する複数のトリガーはお勧めしません。これらは一貫性のない動作を引き起こす可能性があり、将来のリリースでは許可されません。

同じ競合トリガーが複数のイベントと一致する場合、トリガーで TG_OP 変数を使用して、競合を生成した操作を特定できます。

デフォルトでは、PGD は行のレプリケーションオリジンの変更を監視することにより競合を検出します。したがって、1 つの変更のみが発生している場合でも、競合トリガーを呼び出すことができます。この場合、実際の競合は存在しないため、この競合検出メカニズムは偽陽性の競合を生成する可能性があります。競合トリガーは、これらをすべて同様に処理する必要があります。

場合によっては、タイムスタンプ競合検出は競合をまったく検出しない場合があります。たとえば、UPDATE の直後に DELETE が発生するコンカレント UPDATE /DELETE では、最初に UPDATE を、次に DELETE を参照するノードは競合を認識しません。競合が発生しない場合、競合トリガーは呼び出されません。同じ状況ですが、行バージョンの競合検出を使用すると、競合が表示され、競合トリガーで処理できます。

トリガーファンクションは、操作タイプに応じて、追加の状態情報と競合に関係するデータ行にアクセスします。

- INSERT では、競合トリガーはソースから SOURCE_NEW 行と TARGET 行にアクセスできます。
- UPDATE では、競合トリガーはソースから SOURCE_OLD および SOURCE_NEW 行と TARGET 行にアクセスできます。
- DELETE では、競合トリガーはソースから SOURCE_OLD 行と TARGET 行にアクセスできます。

そのオペレーションに値が存在する場合、ファンクション bdr.trigger_get_row() を使用して、SOURCE_OLD 、SOURCE_NEW 、または TARGET 行を取得できます。

競合トリガーの変更はトランザクション的に発生し、ALTER TABLE の一部のバリアントが処理される方法と同様に、構成変更のレプリケーション中にグローバル DML ロックによって保護されます。

競合トリガー内で主キーが更新されると、実行タイミングの違いにより一意制約違反エラーが発生する場合があります。したがって、競合トリガーでの主キーの更新は避けてください。

8.17.4 Transform トリガー

これらのトリガーは、特定のテーブルに対するデータストリームのすべての行に対して実行される点を除き、競合トリガーに似ています。戻り値と公開変数の動作は似ていますが、変換トリガーはターゲット行が識別される前に実行されるため、TARGET 行はありません。

PGD の各テーブルで複数の変換トリガーを指定できます。変換トリガーはアルファベット順に実行されます。

変換トリガーは行をフィルターして取り除くことができ、必要に応じて追加の操作を実行できます。列の値を変更したり、NULL に設定したりできます。戻り値によって、さらに実行されるアクションが決まります。

- トリガーファンクションが行を返した場合、ターゲットに適用されます。
- トリガーファンクションが NULL 行を返した場合、それ以上に実行するアクションはありません。未実行のトリガーは実行されません。
- トリガー機能は、自分の選択に応じて他のアクションを実行できます。

トリガーファンクションは、追加の状態情報と、競合に関係する行にアクセスします。

- INSERT では、変換トリガーはソースから SOURCE_NEW 行にアクセスできます。
- UPDATE では、変換トリガーはソースから SOURCE_OLD および SOURCE_NEW 行にアクセスできます。
- DELETE では、変換トリガーはソースから SOURCE_OLD 行にアクセスできます。

ファンクション bdr.trigger_get_row() を使用して、SOURCE_OLD または SOURCE_NEW 行を取得できます。このタイプのトリガーは、このようなターゲット行が存在する場合が識別される前に実行されるため、TARGET 行は使用できません。

変換トリガーは通常の BEFORE 行トリガーに非常に似ていますが、次の重要な違いがあります。

- 変換トリガーは、入ってくる変更ごとに呼び出されます。 UPDATE および DELETE では、BEFORE トリガーはまったく呼び出されず、テーブル内で一致する行が見つからない場合、DELETE が変更されます。
- 変換トリガーは、パーティションテーブルルーティングが発生する前に呼び出されます。
- 変換トリガーは、SOURCE_OLD を介してルックアップキーにアクセスできます。これは、通常の SQL トリガーでは使用できません。

8.17.5 行の内容

SOURCE_NEW 、SOURCE_OLD 、および TARGET の内容は、オペレーション、テーブルの REPLICA IDENTITY 設定、およびターゲットテーブルの内容によって異なります。

TARGET 行は、競合トリガーでのみ使用できます。TARGET 行には、ターゲットテーブルで UPDATE または DELETE を適用するときに行が見つかった場合にのみデータが含まれます。行が見つからない場合、TARGET は NULL です。

8.17.6 実行オーダー

トリガーの実行順序

- Transform トリガー —ターゲットへの入力行ごとに 1 回実行します。
- 通常トリガー —行ごとに 1 回実行します。
- 競合トリガー —競合が存在する行ごとに 1 回実行します。

8.17.7 ストリームトリガーの例

update_if_newer 競合リゾルバーと同様の動作を提供する競合トリガー

```
CREATE OR REPLACE FUNCTION update_if_newer_trig_func
RETURNS TRIGGER
LANGUAGE plpgsql
AS $$
BEGIN
    IF (bdr.trigger_get_committs(TARGET) >
        bdr.trigger_get_committs(SOURCE_NEW)) THEN
    RETURN TARGET;
    ELSIF
        RETURN SOURCE;
    END IF;
END;
$$;
```

カウンター列にデルタ変更を適用し、他のすべての列に SOURCE_NEW を使用する競合トリガー。

```
CREATE OR REPLACE FUNCTION delta_count_trg_func
RETURNS TRIGGER
LANGUAGE plpgsql
AS $$
DECLARE
    DELTA bigint;
    SOURCE_OLD record;
    SOURCE_NEW record;
    TARGET record;
BEGIN
    SOURCE_OLD := bdr.trigger_get_row(SOURCE_OLD);
    SOURCE_NEW := bdr.trigger_get_row(SOURCE_NEW);
    TARGET := bdr.trigger_get_row(TARGET);

    DELTA := SOURCE_NEW.counter - SOURCE_OLD.counter;
    SOURCE_NEW.counter = TARGET.counter + DELTA;
```

(次のページに続く)

(前のページからの続き)

```
    RETURN SOURCE_NEW;
END;
$$;
```

すべての変更を適用する代わりにログテーブルにログを記録する変換トリガー

```
CREATE OR REPLACE FUNCTION log_change
RETURNS TRIGGER
LANGUAGE plpgsql
AS $$
DECLARE
    SOURCE_NEW record;
    SOURCE_OLD record;
    COMMITTS timestamptz;
BEGIN
    SOURCE_NEW := bdr.trigger_get_row(SOURCE_NEW);
    SOURCE_OLD := bdr.trigger_get_row(SOURCE_OLD);
    COMMITTS := bdr.trigger_get_committs(SOURCE_NEW);

    IF (TG_OP = INSERT) THEN
        INSERT INTO log SELECT I, COMMITTS, row_to_json(SOURCE_NEW);
    ELSIF (TG_OP = UPDATE) THEN
        INSERT INTO log SELECT U, COMMITTS, row_to_json(SOURCE_NEW);
    ELSIF (TG_OP = DELETE) THEN
        INSERT INTO log SELECT D, COMMITTS, row_to_json(SOURCE_OLD);
    END IF;

    RETURN NULL; -- do not apply the change
END;
$$;
```

この例は、信頼できるサイト、優先ノード、または Always Wins 解決としても知られる、信頼できるソースの競合検出を実装する競合トリガーを示しています。bdr.trigger_get_origin_node_id() ファンクションを使用して、3 つ以上のノードで動作するソリューションを提供します。

```
CREATE OR REPLACE FUNCTION test_conflict_trigger()
RETURNS TRIGGER
LANGUAGE plpgsql
AS $$
DECLARE
    SOURCE  record;
    TARGET  record;

    TRUSTED_NODE    bigint;
    SOURCE_NODE     bigint;
```

(次のページに続く)

(前のページからの続き)

```
    TARGET_NODE     bigint;
BEGIN
    TARGET := bdr.trigger_get_row(TARGET);
    IF (TG_OP = DELETE)
        SOURCE := bdr.trigger_get_row(SOURCE_OLD);
    ELSE
        SOURCE := bdr.trigger_get_row(SOURCE_NEW);
    END IF;

    TRUSTED_NODE := current_setting(customer.trusted_node_id);

    SOURCE_NODE := bdr.trigger_get_origin_node_id(SOURCE_NEW);
    TARGET_NODE := bdr.trigger_get_origin_node_id(TARGET);

    IF (TRUSTED_NODE = SOURCE_NODE) THEN
        RETURN SOURCE;
    ELSIF (TRUSTED_NODE = TARGET_NODE) THEN
        RETURN TARGET;
    ELSE
        RETURN NULL; -- do not apply the change
    END IF;
END;
$$;
```

8.18 AutoPartition

AutoPartition を使用すると、テーブルを複数のパーティションに分割できます。自動パーティション管理を使用して、テーブルを大きなサイズに簡単に拡張できます。この機能は、パーティションの作成と削除の低競合ロックなどの PGD の機能を使用します。

新しいパーティションを定期的に作成し、データ保持期間の有効期限が切れたら削除できます。

PGD 管理は、主に SQL によって呼び出されるファンクションによって実行されます。PGD のすべてのファンクションは bdr スキーマで公開されています。search_path に配置しない限り、各ファンクションの名前をスキーマ修飾する必要があります。

8.18.1 パーティションの自動作成

bdr.autopartition() は、表の自動レンジパーティションの定義を作成または変更します。定義が存在しない場合、作成されます。それ以外の場合、後の実行で定義が変更されます。

bdr.autopartition() は、実際のテーブルをロックしません。新しいパーティションのメンテナンスアクションがいつどのように発生するかという定義が変更されます。

bdr.autopartition() は、テーブルの残りの部分をロックせずにパーティションをアタッチまたはデタッチ/ドロップできる機能を活用します基になる Postgres バージョンがサポートしている場合。

テーブルが RANGE パーティション化されていない場合、または複数列パーティションキーが使用されている場合、ERROR が発生します。

デフォルトでは、AutoPartition はパーティションをグローバルに管理します。つまり、1 つのノードでパーティションが作成されると、クラスター内の他のすべてのノードで同じパーティションが作成されます。デフォルトを使用すると、すべてのパーティションに一貫性があり、使用できることが保証されます。この機能のために、AutoPartition は Raft を利用します。

`managed_locally` を `true` に設定することにより、この動作を変更できます。その場合、すべてのパーティションは各ノードでローカルに管理されます。ローカルでのパーティションの管理は、パーティション化されたテーブルがレプリケートテーブルでない場合に役立ちます。その場合、すべてのノードにすべてのパーティションを必要としない、または必要ない場合があります。たとえば、ビルトイン *bdr.conflict_history* テーブルはレプリケートテーブルではありません。これは AutoPartition によってローカルに管理されます。各ノードはこのテーブルのパーティションをローカルに作成し、十分に古くなると削除します。

また、次のことも考慮します。

- `managed_locally` としてマークされたテーブルをグローバルに管理するように後で変更することはできません。その逆も可能です。
- アクティビティは、エントリーが `enabled = on` とマークされている場合にのみ実行されます。
- AutoPartition によって管理されるテーブルのパーティションを手動で作成または削除しないことをお勧めします。そうすると、AutoPartition メタデータの一貫性がなくなり、障害が発生する可能性があります。

8.18.2 オートパーティションの例

日次パーティション、データを 1 か月間保持します

```
CREATE TABLE measurement (
logdate date not null,
peaktemp int,
unitsales int
) PARTITION BY RANGE (logdate);

bdr.autopartition(measurement, 1 day, data_retention_period := 30 days);
```

パーティションがあと 2 つだけ残っている場合、5 つの事前パーティションを作成します。各パーティションには、10 億の注文を保持できます。

```
bdr.autopartition(Orders, 1000000000,
        partition_initial_lowerbound := 0,
        minimum_advance_partitions := 2,
        maximum_advance_partitions := 5
    );
```

8.18.3 RANGE パーティションテーブル

新しいパーティションは、partition_increment 値の範囲ごとに追加され、下限と上限の partition_increment は異なります。 timestamp または date タイプのパーティションキーを持つテーブルの場合、 partition_increment は interval タイプの有効な定数である必要があります。たとえば、1 Day を指定すると、新しいパーティションが毎日追加され、パーティション境界は 1 日ごとに追加されます。

パーティション列が snowflakeid 、timeshard 、または ksuuid シーケンスに接続されている場合、partition_increment を interval タイプとして指定する必要があります。それ以外の場合、パーティションキーが整数または数値の場合、partition_increment は同じデータ型の有効な定数である必要があります。たとえば、 1000000 を指定すると、100 万の値ごとに新しいパーティションが追加されます。

テーブルに既存のパーティションがない場合、指定された partition_initial_lowerbound が最初のパーティションの下限として使用されます。partition_initial_lowerbound を指定しない場合、システムはパーティション列タイプと指定された partition_increment からその値を導き出そうとします。たとえば、 partition_increment が 1 Day として指定されている場合、partition_initial_lowerbound は CURRENT DATE に設定されます。partition_increment が 1 Hour として指定される場合、partition_initial_lowerbound は現在の日付の現在時間に設定されます。後続のパーティションの境界は、partition_increment 値を使用して設定されます。

システムは常に特定の最小数の事前パーティションを持とうとします。新しいパーティションを作成するかどうかを決定するために、指定された partition_autocreate_expression を使用します。これは、チェックが実行されるたびに評価される SQL で評価できる式です。たとえば、列タイプ date のパーティションテーブルで、partition_autocreate_expression が DATE_TRUNC('day',CURRENT_DATE) として指定され、partition_increment が 1 Day として指定され、minimum_advance_partitions が 2 として指定されている場合、最後のパーティションの上限が DATE_TRUNC('day', CURRENT_DATE) + '2 Days'::interval より小さくなるまで、新しいパーティションが作成されます。

式は、システムが新しいパーティションをチェックするたびに評価されます。

列タイプ integer のパーティションテーブルの場合、partition_autocreate_expression を SELECT max(partcol) FROM schema.partitioned_table として指定できます。次に、システムは、パーティション化された列の最大値が最後のパーティションの上限の minimum_advance_partitions * partition_increment の距離内にあるかどうかを定期的にチェックします。クエリーが効率的に実行されるように、partcol にインデックスを作成します。カラムタイプ integer 、smallint 、または bigint のパーティションテーブルに partition_autocreate_expression を指定しない場合、システムは max(partcol) に設定します。

data_retention_period が設定されている場合、パーティションはこの期間の後にドロップされます。パーティションは、新しいパーティションが追加されると同時に削除され、ロックを最小限に抑えます。この値が設定されていない場合、パーティションを手動で削除する必要があります。

data_retention_period パラメーターは、タイムスタンプおよび関連ベースのパーティションでのみサポートされています。期間は、パーティションの上限を考慮して計算されます。上限と比較して、指定された期間が満了すると、パーティションはドロップされます。

8.18.4 パーティションの自動作成の停止

bdr.drop_autopartition() を使用して、特定のリレーションの自動パーティションルールを削除します。リレーションの保留中の作業項目はすべて削除され、新しい作業項目は作成されません。

8.18.5 パーティションの作成を待機しています

パーティションの作成は非同期プロセスです。AutoPartition は、ローカルまたはすべてのノードでパーティションが作成されるのを待機する一連の機能を提供します。

bdr.autopartition_wait_for_partitions() を使用して、ローカルノードでパーティションの作成を待機します。ファンクションは、パーティションテーブル名とパーティションキー列値を取得し、その値を保持するパーティションが作成されるまで待機します。

このファンクションは、パーティションがローカルに作成されるのをのみ待機します。パーティションがリモートノードにも存在することは保証されません。

すべての PGD ノードでパーティションが作成されるのを待機するには、

bdr.autopartition_wait_for_partitions_on_all_nodes() ファンクションを使用します。このファンクションは、ローカルノードとすべてのリモートノードを内部的にチェックし、パーティションがどこでも作成されるまで待機します。

8.18.6 パーティションの検索

bdr.autopartition_find_partition() ファンクションを使用して、指定されたパーティションキー値のパーティションを見つけます。その値を保持するパーティションが存在しない場合、ファンクションは NULL を結果ます。それ以外の場合、パーティションの Oid が返されます。

8.18.7 AutoPartitioning の有効化または無効化

bdr.autopartition_enable() を使用して、特定のテーブルで AutoPartitioning を有効にします。

AutoPartitioning が既に有効になっている場合、アクションは発生しません。同様に、

bdr.autopartition_disable() を使用して、特定のテーブルで自動パーティション化を無効にします。

8.19 Explicit two-phase commit (2PC)

アプリケーションは、PGD で 2 フェーズコミットを使用することを明示的に選択できます。

Distributed Transaction Processing: The XA Specification を参照してください。

X/Open 分散トランザクション処理 DTP モデルは、3 つのソフトウェアコンポーネントを想定しています。

- トランザクション境界を定義し、トランザクションを構成するアクションを指定するアプリケーションプログラム AP
- 共有リソースへのアクセスを提供するリソースマネージャー RM、データベースまたはファイルアクセスシステムなど
- トランザクションに識別子を割り当て、その進行状況を監視し、トランザクションの完了と障害からの回復に対して責任を負うトランザクションマネージャー TM と呼ばれる別のコンポーネント

PGD は、 `PREPARE TRANSACTION` および `COMMIT PREPARED` /`ROLLBACK PREPARED` コマンドを使用して明示的な外部 2PC をサポートします。外部的には、 EDB Postgres 分散クラスターは、単一セッションのトランザクションマネージャーに対する単一のリソースマネージャーであるように見えます。

`bdr.commit_scope` が `local` の場合、トランザクションはローカルノードでのみ準備されます。コミットされると、変更がレプリケートされ、PGD がコミット後の競合解決を適用します。

明示的な 2 フェーズコミットでは、 `local` に設定して `bdr.commit_scope` を使用するのは意味がないと思われる場合があります。ただし、このオプションは、トランザクションのレイテンシーと堅牢性の間のトレードオフを制御できるように提供されています。

明示的な 2 フェーズコミットは、CAMO またはグローバルコミットスコープでは機能しません。将来のリリースでは、この組み合わせが有効になる可能性があります。

8.19.1 使用する

ローカルコミットスコープの 2 フェーズコミットは、標準の PostgreSQL とまったく同じように動作します。ローカルコミットスコープを使用し、CAMO を無効にします。

```
BEGIN;

SET LOCAL bdr.enable_camo = off;
SET LOCAL bdr.commit_scope = local;

... other commands possible...
```

コミットの最初のフェーズを開始するには、クライアントはグローバルトランザクション ID を割り当てる必要があります。これは、トランザクションを識別する一意の文字列です。

```
PREPARE TRANSACTION some-global-id;
```

最初のフェーズが成功した後、すべてのノードが変更を適用し、トランザクションをコミットする準備が整います。次に、クライアントは同じノードから第 2 フェーズを呼び出す必要があります。

```
COMMIT PREPARED some-global-id;
```

8.20 Timestamp-based snapshots

タイムスタンプベースのスナップショットでは、通常の MVCC スナップショットではなくユーザー指定のタイムスタンプを使用して、一貫した方法でデータを読み取ることができます。この機能を使用して、共通の時点でさまざまな PGD ノード上のデータにアクセスできます。たとえば、データ品質チェックのために複数のノード上のデータを比較できます。

この機能は現在、書き込みトランザクションでは動作しません。

snapshot_timestamp パラメーターを使用して、タイムスタンプベースのスナップショットの使用を有効にします。このパラメーターは、タイムスタンプ値または現在のタイムスタンプ now を表す特別な値'current'を受け入れます。 snapshot_timestamp が設定されている場合、クエリーはそのタイムスタンプを使用して、通常の MVCC セマンティクスではなく行の可視性を判断します。

たとえば、次のクエリーは、2018-12-08 02:28:30 GMT での customers テーブルの状態を結果ます。

```
SET snapshot_timestamp = 2018-12-08 02:28:30 GMT;
SELECT count(*) FROM customers;
```

PGD がないと、このクエリーは将来のタイムスタンプまたは特別な'current' 値でのみ動作するため、履歴クエリーには使用できません。

PGD は、マルチノード環境でのその機能と連携し、改善します。最初に、PGD は、他のノードへのすべての接続が、指定されたタイムスタンプより前にデータベースに追加された未処理のデータをレプリケートすることを確認します。これにより、タイムスタンプベースのスナップショットがマルチマスターグループ全体で一貫していることが保証されます。次に、PGD は bdr.timestamp_snapshot_keep というパラメーターを追加します。このパラメーターは、そのノードで最近の履歴に対してクエリーを実行できる時間枠を指定します。

任意の間隔を指定できますが、VACUUM 自動バキュームを含むは、指定された間隔の最大 2 倍より新しいデッド行はクリーニングしないことに注意してください。これは、トランザクション ID が同じ時間解放されないことも意味します。その結果、これを使用すると、ユーザーテーブルがさらに肥大化する可能性があります。最初は一般的な設定として 10 秒をお勧めしますが、必要に応じて変更できます。

クエリーが実行のために受け入れられると、クエリーは通常と同じように問題なく bdr.timestamp_snapshot_keep より長く実行される場合があります。

また、スナップショットがどこまで保持されたかに関する情報は、サーバーを再起動すると残されません。タイムスタンプベースのスナップショットの最も古い使用可能なタイムスタンプは、PostgreSQL インスタンスが最後に再起動された時刻です。

bdr.timestamp_snapshot_keep の使用と postgres_fdw 拡張機能を組み合わせて、PGD グループ内のマルチプルのノードにわたって一貫した読み取りを取得できます。外部テーブルで使用する場合、この組み合わせを使用して、ノード全体で並列クエリーを実行できます。

この機能を使用する場合、マルチノードクエリ内のノードの数に制限はありません。

タイムスタンプベースのスナップショットを使用しても、ノード間トラフィックや帯域幅は増加しません。クエリデータに加えて、タイムスタンプ値のみが渡されます。

第9章　PGD Reference

リファレンスセクションは、 EDB Postgres Distributed で使用可能なすべてのファンクション、ビュー、コマンドの最終リストです。

User visible catalogs and views

- *bdr.camo_decion_journal*
- *bdr.commit_scopes*
- *bdr.conflict_history*
- *bdr.conflict_history_summary*
- *bdr.consensus_kv_data*
- *bdr.crdt_handlers*
- *bdr.ddl_replication*
- *bdr.depend*
- *bdr.global_consensus_journal*
- *bdr.global_consensus_journal_details*
- *bdr.global_consensus_response_journal*
- *bdr.global_lock*
- *bdr.global_locks*
- *bdr.group_camo_details*
- *bdr.group_raft_details*
- *bdr.group_replslots_details*
- *bdr.group_subscription_summary*
- *bdr.group_versions_details*
- *bdr.local_consensus_snapshot*
- *bdr.local_consensus_state*
- *bdr.local_node*
- *bdr.local_node_summary*

- *bdr.local_sync_status*
- *bdr.node_config*
- *bdr.node_catchup_info*
- *bdr.node_catchup_info_details*
- *bdr.node_conflict_resolvers*
- *bdr.node_group_config*
- *bdr.node_group_replication_sets*
- *bdr.node_local_info*
- *bdr.node_log_config*
- *bdr.node_peer_progress*
- *bdr.node_replication_rates*
- *bdr.node_slots*
- *bdr.node_summary*
- *bdr.queue*
- *bdr.replication_set*
- *bdr.replication_set_table*
- *bdr.replication_set_ddl*
- *bdr.replication_sets*
- *bdr.schema_changes*
- *bdr.sequence_alloc*
- *bdr.sequences*
- *bdr.stat_activity*
- *bdr.stat_relation*
- *bdr.stat_subscription*
- *bdr.subscription*
- *bdr.subscription_summary*
- *bdr.tables*
- *bdr.taskmgr_work_queue*
- *bdr.taskmgr_workitem_status*
- *bdr.taskmgr_local_work_queue*
- *bdr.taskmgr_local_workitem_status*

- *bdr.trigger*
- *bdr.triggers*
- *bdr.workers*
- *bdr.* ライター
- *bdr.worker_tasks*

System functions

バージョン情報ファンクション

- *bdr.bdr_version*
- *bdr.bdr_version_num*

システム情報ファンクション

- *bdr.get_relation_stats*
- *bdr.get_subscription_stats*

システムおよび進行状況情報パラメーター

- *bdr.local_node_id*
- *bdr.last_committed_lsn*
- *transaction_id*
- *bdr.is_node_connected*
- *bdr.is_node_ready*

コンセンサスファンクション

- *bdr.consensus_disable*
- *bdr.consensus_enable*
- *bdr.consensus_proto_version*
- *bdr.consensus_snapshot_export*
- *bdr.consensus_snapshot_import*
- *bdr.consensus_snapshot_verify*
- *bdr.get_consensus_status*
- *bdr.get_raft_status*
- *bdr.raft_leadership_transfer*

ユーティリティファンクション

- *bdr.wait_slot_confirm_lsn*
- *bdr.wait_for_apply_queue*
- *bdr.get_node_sub_receive_lsn*
- *bdr.get_node_sub_apply_lsn*
- *bdr.run_on_all_nodes*
- *bdr.run_on_nodes*
- *bdr.run_on_group*
- *bdr.global_lock_table*
- *bdr.wait_for_xid_progress*
- *bdr.local_group_slot_name*
- *bdr.node_group_type*
- *bdr.alter_node_kind*
- *bdr.alter_subscription_skip_changes_upto*

グローバルアドバイザリーロック

- *bdr.global_advisory_lock*
- *bdr.global_advisory_unlock*

モニタリング機能

- *bdr.monitor_group_versions*
- *bdr.monitor_group_raft*
- *bdr.monitor_local_replslots*
- *bdr.wal_sender_stats*
- *bdr.get_decoding_worker_stat*
- *bdr.lag_control*

PGD settings

Exploring conflict handling with PGD

- *bdr.default_conflict_detection*

グローバルシーケンスパラメーター

- *bdr.default_sequence_kind*

  DDL 処理

- *bdr.default_replica_identity*
- *bdr.ddl_replication*
- *bdr.role_replication*
- *bdr.ddl_locking*
- :ref:``bdr.truncate_locking` <*bdr.truncate_locking*>`

  グローバルロック

- *bdr.global_lock_max_locks*
- *bdr.global_lock_timeout*
- *bdr.global_lock_statement_timeout*
- :ref:``bdr.global_lock_idle_timeout` <*bdr.global_lock_idle_timeout*>`
- :ref:``bdr.predictive_checks` <*bdr.predictive_checks*>`

  Node management

- *bdr.replay_progress_frequency*
- *bdr.standby_slot_names*

  汎用レプリケーション

- *bdr.writers_per_subscription*
- *bdr.max_writers_per_subscription*
- :ref:``bdr.xact_replication` <*bdr.xact_replication*>`
- *bdr.permit_unsafe_commands*
- *bdr.batch_inserts*
- *bdr.maximum_lock_skew*
- *bdr.maximum_lock_skew_action*
- :ref:``bdr.accept_connections` <*bdr.accept_connections*>`
- *bdr.standby_slot_names*
- *bdr.standby_slots_min_confirmed*

- *bdr.writer_input_queue_size*
- *bdr.writer_output_queue_size*
- *bdr.min_worker_backoff_migrate*

状態ベースおよびオペレーションベースの *CRDT*

- :ref:``bdr.crdt_raw_value` <*bdr.crdt_raw_value*>`

コミットスコープ

- *bdr.commit_scopes*

Commit At Most Once

- *bdr.camo_local_mode_deploy*
- :ref:``bdr.camo_enable_client_warnings` <*bdr.camo_enable_client_warnings*>`

Transaction streaming

- *bdr.default_streaming_mode* を使用したノード構成

遅延制御

- *bdr.lag_control_max_commit_deploy*
- :ref:``bdr.lag_control_max_lag_size` <*bdr.lag_control_max_lag_size*>`
- *bdr.lag_control_max_lag_time*
- *bdr.lag_control_min_conforming_nodes*
- *bdr.lag_control_commit_deploy_adjust*
- *bdr.lag_control_sample_interval*
- *bdr.lag_control_commit_deploy_start*

Timestamp-based snapshots

- *bdr.timestamp_snapshot_keep*

モニタリングとロギング

- *bdr.debug_level*
- :ref:``bdr.trace_level` <*bdr.trace_level*>`
- *bdr.track_subscription_apply*

- *bdr.track_relation_apply*
- *bdr.track_apply_lock_timing*

Decoding worker

- *bdr.enable_wal_decoder*
- *bdr.receive_lcr*
- *bdr.lcr_cleanup_interval*

接続設定

- *bdr.global_connection_timeout*
- *bdr.global_keepalives*
- *bdr.global_keepalives_idle*
- *bdr.global_keepalives_interval*
- *bdr.global_keepalives_count*
- *bdr.global_tcp_user_timeout*

内部設定-Raft タイムアウト bdr.raft_global_election_timeout

- 内部設定-Raft タイムアウト bdr.raft_global_election_timeout
- *bdr.raft_local_election_timeout*
- *bdr.raft_response_timeout*

内部設定 - その他の *Raft* 値

- *bdr.raft_keep_min_entries*
- *bdr.raft_log_min_apply_duration*
- *bdr.raft_log_min_message_duration*
- *bdr.raft_group_max_connections*

内部設定 - その他の値

- *bdr.backwards_compatibility*
- *bdr.track_replication_estimates*
- *bdr.lag_tracker_apply_rate_weight*

Node management

- ノードの状態のリスト
- ノード管理コマンド
- *bdr_init_physical*

Node management interfaces

- *bdr.create_node*
- *bdr.drop_node*
- *bdr.create_node_group*
- *bdr.alter_node_group_config()* を使用したグループ構成
- *bdr.join_node_group*
- *bdr.switch_node_group*
- *bdr.promote_node*
- *bdr.wait_for_join_completion*
- *bdr.part_node*
- *bdr.alter_node_interface*
- *bdr.alter_subscription_enable*
- *bdr.alter_subscription_disable*
- *bdr.alter_node_group_option*
- *bdr.alter_node_option*

Routing functions

- *bdr.create_proxy*
- *bdr.alter_proxy_option*
- *bdr.drop_proxy*
- *bdr.routing_leadership_transfer*

Replication set management

- *bdr.create_replication_set*
- *bdr.alter_replication_set*
- *bdr.drop_replication_set*
- *bdr.alter_node_replication_sets*

レプリケーションセットのメンバーシップ

- *bdr.replication_set_add_table*
- *bdr.replication_set_remove_table*

DDL レプリケーションフィルタリング

- *bdr.replication_set_add_ddl_filter*
- *bdr.replication_set_remove_ddl_filter*

Testing and tuning commands

- *pgd_bench*

Global sequence management interfaces

シーケンスファンクション

- *bdr.alter_sequence_set_kind*
- *bdr.extract_timestamp_from_snowflakeid*
- *bdr.extract_nodeid_from_snowflakeid*
- *bdr.extract_localseqid_from_snowflakeid*
- *bdr.timestamp_to_snowflakeid*
- *bdr.extract_timestamp_from_timeshard*
- *bdr.extract_nodeid_from_timeshard*
- *bdr.extract_localseqid_from_timeshard*
- *bdr.timestamp_to_timeshard*

KSUUID v2 ファンクション

- *bdr.gen_ksuuid_v2*
- *bdr.ksuuid_v2_cmp*
- *bdr.extract_timestamp_from_ksuuid_v2*

KSUUID v1 ファンクション

- *bdr.gen_ksuuid_v2*
- *bdr.uuid_v1_cmp*

- *bdr.extract_timestamp_from_ksuuid_v2*

  AutoPartition

- *bdr.autopartition*
- *bdr.drop_autopartition*
- *bdr.autopartition_wait_for_partitions*
- *bdr.autopartition_wait_for_partitions_on_all_nodes*
- *bdr.autopartition_find_partition*
- *bdr.autopartition_enable*
- :ref:``bdr.autopartition_disable` <*bdr.autopartition_disable*>`
- 内部ファンクション
- *bdr.autopartition_create_partition*
- *bdr.autopartition_drop_partition*

9.1 ストリームトリガーリファレンス

Stream triggers manipulation interfaces

- *bdr.create_conflict_trigger*
- *bdr.create_transform_trigger*
- *bdr.drop_trigger*

  Stream triggers row functions

- *bdr.trigger_get_row*
- *bdr.trigger_get_committs*
- *bdr.trigger_get_xid*
- *bdr.trigger_get_type*
- *bdr.trigger_get_conflict_type*
- *bdr.trigger_get_origin_node_id*
- *bdr.ri_fkey_on_del_trigger*

  Stream triggers row variables

- *TG_NAME*

- *TG_WHEN*
- *TG_LEVEL*
- *TG_OP*
- *TG_RELID*
- *TG_TABLE_NAME*
- *TG_TABLE_SCHEMA*
- *TG_NARGS*
- *TG_ARGV[]*

Internal catalogs and views

- *bdr.ddl_epoch*
- *bdr.event_history*
- *bdr.event_summary*
- *bdr.node_config*
- *bdr.node_group_config*
- *bdr.node_group_routing_config_summary*
- *bdr.node_group_routing_info*
- *bdr.node_group_routing_summary*
- *bdr.node_routing_config_summary*
- *bdr.proxy_config*
- *bdr.proxy_config_summary*
- *bdr.sequence_kind*

Internal system functions

一般的な内部ファンクション

- *bdr.decode_message_response_payload*
- *bdr.decode_message_payload*
- *bdr.get_global_locks*
- *bdr.get_slot_flush_timestamp*
- *bdr.internal_alter_sequence_set_kind*
- *bdr.internal_replication_set_add_table*

- *bdr.internal_replication_set_remove_table*
- *bdr.internal_submit_join_request*
- *bdr.isolation_test_session_is_blocked*
- *bdr.local_node_info*
- *bdr.msgb_connect*
- *bdr.msgb_deliver_message*
- *bdr.peer_state_name*
- *bdr.request_replay_progress_update*
- *bdr.seq_nextval*
- *bdr.show_subscription_status*
- *bdr.get_node_conflict_resolvers*
- *bdr.reset_subscription_stats*
- *bdr.reset_relation_stats*
- *bdr.pg_xact_origin*
- *bdr.difference_fix_origin_create*
- *bdr.difference_fix_session_setup*
- *bdr.difference_fix_session_reset*
- *bdr.difference_fix_xact_set_avoid_conflict*
- *bdr.resynchronize_table_from_node*
- *bdr.consensus_kv_store*
- *bdr.consensus_kv_fetch*

タスクマネージャー機能

- *bdr.taskmgr_set_leader*
- *bdr.taskmgr_get_last_completed_workitem*
- *bdr.taskmgr_work_queue_check_status*
- *bdr.node_catchup_state_name*
- *bdr.bdr_track_commit_Decision*
- *bdr.bdr_get_commit_decions*
- *bdr.show_workers*
- *bdr.show_writers*
- *bdr.node_kind_name*

9.1.1 User visible catalogs and views

ここでは、カタログとビューがアルファベット順に表示されています。

bdr.camo_decion_journal

bdr.logical_transaction_status が呼び出された場合、フェイルオーバー後に CAMO パートナーノードによって解決された決定の永続ジャーナル。bdr.node_pre_commit とは異なり、これは通常の動作条件つまり、CAMO ペアの両方のノードが実行され接続されている下で処理されるトランザクションをカバーしません。このジャーナルのエントリは、自動的にクリーンアップされることはありません。これは、システムが依存しない診断ツールです。

bdr.camo_decision_journal 列

Name	Type	Description
origin_node_id	oid	トランザクションが実行されたノードの OID
origin_xid	oid	リモートオリジンノードのトランザクション ID
decision	char	コミットの場合は'c'、アボートの場合は'a'
decision_ts	timestamptz	ディシジョンタイム

bdr.commit_scopes

bdr.commit_scope でグループコミットを有効にするために使用できるすべてのコミットスコープを保存するカタログ。

bdr.commit_scopes 列

Name	Type	Description
commit_scope_id	oid	参照するスコープの ID
commit_scope_name	name	参照するスコープの名前
commit_scope_origin_node_	oid	ID で参照される、ルールが適用されるノードグループ
sync_scope_rule	text	スコープの定義

bdr.conflict_history

このテーブルは、競合がログに記録されるデフォルトのテーブルです。テーブルは列 `local_time` で RANGE パーティション化されており、Autopartition によって管理されます。デフォルトのデータ保持期間は 30 日です。

このテーブルへのアクセスは、テーブルの所有者が可能であり、行レベルのセキュリティによって制限されている、自分が所有するテーブルのすべての競合を表示できます。

詳細については、 テーブルへの競合のロギング を参照してください。

bdr.conflict_history 列

Name	Type	Description
sub_id	oid	この競合を生成したサブスクリプション。`bdr.subscription`テーブルに結合できます
local_xid	xid	競合時のレプリケーションプロセスのローカルトランザクション
local_lsn	pg_lsn	競合時のローカル LSN
local_time	timestamp with time zone	紛争の現地時間
remote_xid	xid	リモートノードオリジンで競合する変更を生成したトランザクション
remote_commit_lsn	pg_lsn	リモートノードオリジンで競合する変更を生成したトランザクションのコミット LSN
remote_commit_time	timestamp with time zone	リモートノードオリジンで競合する変更を生成したトランザクションのコミットタイムスタンプ
conflict_type	text	検出された競合のタイプ
conflict_resolution	text	選択された競合解決
conflict_index	regclass	競合するインデックスインデックスが削除されていない場合にのみ有効です
reloid	oid	競合するリレーションインデックスがドロップされていない場合にのみ有効
nspname	text	競合時に競合が発生したリレーションのスキーマの名前 名前の変更に従いません
relname	text	競合時に競合が発生したリレーションの名前名前の変更に従いません。
key_tuple	json	行のマッチングに使用されるキーの Json 表現
remote_tuple	json	競合する着信行の Json 表現
local_tuple	json	ローカル競合行の Json 表現
apply_tuple	json	結果の適用された行の Json 表現
local_tuple_xmin	xid	ローカル競合行を生成したトランザクション`local_tuple`が設定され、行が固定されていない場合

次のページに続く

表 3 – 前のページからの続き

Name	Type	Description
local_tuple_node_id	oid	ローカル競合行を生成したノード`local_tuple`が設定され、行が固定されていない場合
local_tuple_commit_time	timestamp with time zone	ローカル競合行の最後の既知の変更タイムスタンプ`local_tuple`が設定され、行が固定されていない場合

bdr.conflict_history_summary

行の競合に関するユーザーが読み取り可能な詳細を含むビュー。

bdr.conflict_history_summary 列

Name	Type	Description
nspname	text	スキーマの名前
relname	text	テーブルの名前
local_time	timestamp with time zone	紛争の現地時間
local_tuple_commit_time	timestamp with time zone	ローカルコミットの時間
remote_commit_time	timestamp with time zone	リモートコミットの時間
conflict_type	text	競合の種類
conflict_resolution	text	採択された決議

bdr.consensus_kv_data

`bdr.consensus_kv_store()` および `bdr.consensus_kv_fetch()` インターフェイスによって使用される内部 Raft ベースの KV ストアの永続ストレージ。

bdr.consensus_kv_data 列

Name	Type	Description
kv_key	text	一意のキー
kv_val	json	json 形式の任意の値
kv_create_ts	timestamptz	最終書き込みタイムスタンプ
kv_ttl	int	ミリ秒単位の値の生存時間
kv_expire_ts	timestamptz	有効期限タイムスタンプ *kv_create_ts* + *kv_ttl*

bdr.crdt_handlers

この表は、すべての CRDT データ型のマージハンドラーファンクションをリストしています。

bdr.crdt_handlers 列

Name	Type	Description
crdt_type_id	regtype	CRDT データ型 ID
crdt_merge_id	regproc	このデータ型のマージファンクション

bdr.ddl_replication

このビューには、現在の *DDL filters* によってセットアップされた DDL レプリケーション構成がリストされます。

bdr.ddl_replication 列

Name	Type	Description
set_ddl_name	name	DDL フィルタの名前
set_ddl_tag	text	適用されるコマンドタグ正規表現
set_ddl_role	text	適用されるロール正規表現
set_name	name	このフィルタが定義されているレプリケーションセットの名前

bdr.depend

このテーブルは、PGD カタログ内の内部オブジェクトの依存関係を追跡します。

bdr.global_consensus_journal

このカタログテーブルは、グローバルコンセンサスを管理中に送信されたすべての Raft メッセージのログを記録します。

`bdr.global_consensus_response_journal` カタログと同様、ペイロードはバイナリエンコードされた形式で保存され、`bdr.decode_message_payload()` ファンクションでデコードできます。詳細については、

bdr.global_consensus_journal_details ビューを参照してください。

bdr.global_consensus_journal 列

Name	Type	Description
log_index	int8	ジャーナルエントリの ID
term	int8	Raft 用語
origin	oid	要求が発生したノードの ID
req_id	int8	リクエストの ID
req_payload	bytea	要求のペイロード
trace_context	bytea	要求のトレースコンテキスト

bdr.global_consensus_journal_details

このビューは、 `bdr.decode_message_payload()` ファンクションを使用してペイロードをデコードして、送信された Raft メッセージと対応する応答を表示します。

bdr.global_consensus_journal_details 列

Name	Type	Description
node_group_name	name	ノードグループの名前
log_index	int8	ジャーナルエントリの ID
term	int8	Raft 用語
request_id	int8	リクエストの ID
origin_id	oid	要求が発生したノードの ID
req_payload	bytea	要求のペイロード
origin_node_name	name	要求が発生したノードの名前
message_type_no	oid	要求の PGD メッセージタイプの ID
message_type	text	要求の PGD メッセージタイプの名前
message_payload	text	要求の PGD メッセージペイロード
response_message_type_n	oid	応答の PGD メッセージタイプの ID
response_message_type	text	応答の PGD メッセージタイプの名前
response_payload	text	応答の PGD メッセージペイロード
response_errcode_no	text	応答の SQLSTATE
response_errcode	text	応答のエラーコード
response_message	text	応答のエラーメッセージ

bdr.global_consensus_response_journal

このカタログテーブルは、グローバルコンセンサスを管理中に受信した Raft メッセージへのすべての応答を収集します。

bdr.global_consensus_journal カタログと同様、ペイロードはバイナリエンコードされた形式で保存され、bdr.decode_message_payload() ファンクションでデコードできます。詳細については、

bdr.global_consensus_journal_details ビューを参照してください。

bdr.global_consensus_response_journal 列

Name	Type	Description
log_index	int8	ジャーナルエントリの ID
res_status	oid	応答のステータスコード
res_payload	bytea	応答のペイロード
trace_context	bytea	応答のトレースコンテキスト

bdr.global_lock

このカタログテーブルには、サーバー再起動時にグローバルロック状態を回復するために必要な情報が保存されます。

bdr.global_lock の表示行は必ずしもすべてのグローバルロックアクティビティを反映しているわけではないため、使用状況をモニタリングする場合は、

bdr.global_locks ビューが適しています。

このテーブルの内容は変更しないでください。重要な PGD カタログです。

bdr.global_lock 列

Name	Type	Description
ddl_epoch	int8	ロックの DDL エポック
origin_node_id	oid	グローバルロックが発生したノードの OID
lock_type	oid	ロックのタイプ DDL または DML
nspname	name	ロックされたリレーションのスキーマ名
relname	name	ロックされたリレーションのリレーション名

次のページに続く

表 11 – 前のページからの続き

Name	Type	Description
groupid	oid	トップレベルグループの OID アドバイザリーロックの場合
key1	integer	最初の 32 ビットキーまたは 64 ビットキーの下位 32 ビットアドバイザリーロック用
key2	integer	64 ビットキーの 2 番目の 32 ビットキー以上の 32 ビットアドバイザリロック用
key_is_bigint	boolean	64 ビット整数キーを使用する場合に true アドバイザリロックの場合

bdr.global_locks

このノードのアクティブなグローバルロックを含むビュー。

bdr.global_locks ビューは、

PGD の共有メモリロック状態追跡を公開し、管理者に PGD のグローバルロックアクティビティと進行状況についてのより良い洞察を提供します。

グローバルロックの監視 を参照

グローバルロックの詳細については、

bdr.global_locks 列

Name	Type	Description
origin_node_id	oid	グローバルロックが発生したノードの OID
origin_node_name	name	グローバルロックが発生したノードの名前
lock_type	text	ロックのタイプ DDL または DML
relation	text	ロックされたリレーション名 DML ロックの場合またはキーアドバイザリロックの場合
pid	int4	ロックを保持しているプロセスの PID
acquire_stage	text	ロック取得プロセスの内部状態
waiters	int4	同じグローバルロックを待機するバックエンドのリスト
global_lock_request_tim	timestamptz	このグローバルロックの取得がオリジンノードによって開始された時間
local_lock_request_time	timestamptz	ローカルノードがローカルロックの取得を試行し始めた時間
last_state_change_time	timestamptz	`acquire_stage`が最後に変更された時間

カラムの詳細

- relation DML ロックの場合、relation は、DML ロックが取得されたリレーションを示します。グローバルアドバイザリロックの場合、relation 列は、実際に、ロックが取得された 2 つの 32 ビット整数または 1 つの 64 ビット整数を表示します。
- origin_node_id および origin_node_name これらがローカルノードの ID および名前と同じである場合、ローカルノードはグローバル DDL ロックのイニシエーター、つまり、取得トランザクションを実行しているノードです。これらのフィールドが別のノードを指定している場合、ローカルノードは代わりにローカル DDL ロックを取得して、リモートノードからのグローバル DDL ロック要求を満たそうとします。
- pid グローバル DDL ロックを要求したプロセスのプロセス ID。ローカルノードが要求ノードの場合。他のノードでは NULL。オリジンノードを照会して、ロッカー pid を特定します。
- global_lock_request_time グローバルロック要求イニシエーターがグローバルロックを取得するプロセスを開始したタイムスタンプ。現在のノードで不明な場合は null にすることができます。この時間は DDL ロック要求の先頭にスタンプされ、DDL エポック管理および保留中レプリケーションキューの必要なフラッシュに要した時間が含まれます。現在、オリジンノードでのみ知られています。
- local_lock_request_time ローカルノードがこのグローバルロックのローカルロックを取得しようと開始したタイムスタンプ。これには、重量セッションロックの取得に要した時間が含まれますが、DDL エポックまたはキューのフラッシュにかかる時間は含まれません。ローカルノードの再起動後にロックが再取得された場合、それがノードの再起動時間になります。
- last_state_change_time このグローバルロックエントリーの bdr.global_locks.acquire_stage フィールドが最後に変更されたタイムスタンプ。

bdr.group_camo_details

bdr.run_on_all_nodes を使用して、すべてのノードから CAMO 関連の情報を収集します。

bdr.group_camo_details 列

Name	Type	Description
node_id	text	内部ノード ID
node_name	text	ノードの名前
camo_partner	text	カモフラージュパートナーのノード名
is_camo_partner_connec	text	接続ステータス
is_camo_partner_ready	text	準備状況
camo_transactions_resol	text	保留中および未解決の CAMO トランザクションはありますか
apply_lsn	text	再生されたとして報告された最新の位置可視
receive_lsn	text	受信した変更またはメッセージの最新の LSN 再起動の場合に遡ることができます

次のページに続く

表 13 – 前のページからの続き

Name	Type	Description
apply_queue_size	text	apply_lsn と receive_lsn のバイト差

bdr.group_raft_details

bdr.run_on_all_nodes を使用して、すべてのノードから Raft コンセンサスステータスを収集します。

bdr.group_raft_details 列

Name	Type	Description
node_id	oid	内部ノード ID
node_name	name	ノードの名前
node_group_name	name	グループの名前は次の一部です
state	text	ノード上の Raft ワーカーの状態
leader_id	oid	RAFT_LEADER のノード ID
current_term	int	Raft 選挙内部 ID
commit_index	int	Raft スナップショットの内部 ID
nodes	int	アクセス可能なノードの数
voting_nodes	int	投票ノードの数
protocol_version	int	このノードのプロトコルバージョン

bdr.group_replslots_details

bdr.run_on_all_nodes を使用して、すべてのノードから PGD スロット情報を収集します。

bdr.group_replslots_details 列

Name	Type	Description
node_group_name	text	PGD グループの名前
origin_name	text	オリジンノードの名前
target_name	text	ターゲットノードの名前
slot_name	text	このサブスクリプションで使用されるオリジンノードのスロット名
active	text	スロットはアクティブですか?接続は接続されていますか?

次のページに続く

表 15 – 前のページからの続き

Name	Type	Description
state	text	レプリケーションの状態キャッチアップ、ストリーミングなど、またはオフラインの場合は「切断」
write_lag	interval	報告された書き込みのおおよその遅延時間
flush_lag	interval	報告されたフラッシュのおおよその遅延時間
replay_lag	interval	報告されたリプレイのおおよそのラグタイム
sent_lag_bytes	int8	send_lsn と現在の WAL 書き込み位置のバイト差
write_lag_bytes	int8	write_lsn と現在の WAL 書き込み位置のバイト差
flush_lag_bytes	int8	lush_lsn と現在の WAL 書き込み位置のバイト差
replay_lag_byte	int8	recovery_lsn と現在の WAL 書き込み位置のバイト差

bdr.group_subscription_summary

bdr.run_on_all_nodes を使用して、すべてのノードからサブスクリプションステータスを収集します。

bdr.group_subscription_summary 列

Name	Type	Description
origin_node_name	text	サブスクリプションの元の名前
target_node_name	text	サブスクリプションのターゲットの名前
last_xact_replay_timesta	text	最後に再生されたトランザクションのタイムスタンプ
sub_lag_seconds	text	now と last_xact_replay_timestamp 間のラグ

bdr.group_versions_details

bdr.run_on_all_nodes を使用して、すべてのノードから PGD 情報を収集します。

bdr.group_versions_details 列

Name	Type	Description
node_id	oid	内部ノード ID
node_name	name	ノードの名前
postgres_version	text	ノード上の PostgreSQL バージョン

次のページに続く

表 17 – 前のページからの続き

Name	Type	Description
bdr_version	text	ノード上の PGD バージョン

bdr.local_consensus_snapshot

このカタログテーブルには、ローカルノードによって作成または受信されたコンセンサススナップショットが含まれています。

bdr.local_consensus_snapshot 列

Name	Type	Description
log_index	int8	ジャーナルエントリの ID
log_term	int8	Raft 用語
snapshot	bytea	Raft スナップショットデータ

bdr.local_consensus_state

このカタログテーブルには、ローカルノード上の Raft の現在の状態が保存されます。

bdr.local_consensus_state 列

Name	Type	Description
node_id	oid	ノードの ID
current_term	int8	Raft 用語
apply_index	int8	Raft はインデックスを適用します
voted_for	oid	今期にこのノードによって投じられた投票
last_known_leader	oid	最後に知られている Raft リーダーの node_id

bdr.local_node

このテーブルは、現在の Postgres インスタンスの現在のデータベース内のローカルノードを識別します。

bdr.local_node 列

Name	Type	Description
node_id	oid	ノードの ID
pub_repsets	text[]	公開されたレプリケーションセット
sub_repsets	text[]	サブスクライブされたレプリケーションセット

bdr.local_node_summary

bdr.node_summary および pub_repsets および sub_repsets

と同じ情報を含むビューですが、ローカルノードのみを対象とします。

bdr.local_sync_status

サブスクリプションまたはテーブル同期プロセスのステータスに関する情報。

bdr.local_sync_status 列

Name	Type	Description
sync_kind	char	実行された同期の種類
sync_subid	oid	同期を実行するサブスクリプションの ID
sync_nspname	name	同期テーブルのスキーマ名存在する場合
sync_relname	name	同期テーブルの名前存在する場合
sync_status	char	同期の現在の状態
sync_remote_relid	oid	上流に同期されたテーブルがある場合の ID
sync_end_lsn	pg_lsn	同期状態が最後に変更された位置

bdr.node

このテーブルは、クラスター内のすべての PGD ノードをリストしています。

bdr.node 列

Name	Type	Description
node_id	oid	ノードの ID
node_name	name	ノードの名前
node_group_id	oid	ノードグループの ID
source_node_id	oid	ソースノードの ID
synchronize_structure	"char"	結合中に実行されるスキーマの同期
node_state	oid	ノードの一貫した状態
target_state	oid	ノードが到達しようとしている状態参加または昇格中に
seq_id	int4	一意のシーケンス番号を生成するために使用されるノードのシーケンス識別子
dbname	name	ノードのデータベース名
node_dsn	char	ノードの接続文字列
proto_version_ranges	int[]	ノードによってサポートされているプロトコルバージョンレンジ
node_join_finished	boolean	結合が完了したかどうかを確認する

bdr.node_catchup_info

このカタログテーブルは、各ノードに関連するキャッチアップ情報を記録します。結合または部分プロシージャに関連している場合。

bdr.node_catchup_info 列

Name	Type	Description
node_id	oid	ノードの ID
node_source_id	oid	データのソースとして使用されるノードの ID
slot_name	name	このソースに使用されるスロット
min_node_lsn	pg_lsn	ノードがピアノードからの直接再生に切り替えることができる最小 LSN
catchup_state	oid	キャッチアップ状態のステータスコード
origin_node_id	oid	トランザクションが必要なノードの ID

ノード node_id は、分割ノード origin_node_id からの欠損データが必要な場合、転送によって既にそれ node_source_id を持つノードからそれを取得できます。このテーブルのレコードは、ノード node_id が EDB Postgres 分散クラスターのメンバーになるまで持続します。

bdr.node_catchup_info_details

情報をより分かりやすく表示する bdr.node_catchup_info カタログのビュー

bdr.node_conflict_resolvers

すべての既知の競合タイプの現在構成されている競合解決。

bdr.node_conflict_resolvers 列

Name	Type	Description
conflict_type	text	競合の種類
conflict_resolver	text	この競合タイプに使用されるリゾルバー

bdr.node_group

このカタログテーブルには、すべての PGD ノードグループがリストされています。

bdr.node_group 列

Name	Type	Description
node_group_id	oid	ノードグループの ID
node_group_name	name	ノードグループの名前
node_group_default_rep	oid	このノードグループのデフォルトレプリケーションセット
node_group_default_rep	oid	このノードグループのデフォルトレプリケーションセット
node_group_parent_id	oid	親グループの ID これがルートグループの場合は 0
node_group_flags	int	グループフラグ
node_group_uuid	uuid	グループの uuid
node_group_apply_delay	interval	プロバイダーからの変更を適用するまでに加入者が待機する時間
node_group_check_cons	bool	適用プロセスがデータの適用時にコンストレインをチェックするかどうか
node_group_num_writer	int	このノードグループをバッキングするサブスクリプションに使用するライターの数

次のページに続く

表 25 – 前のページからの続き

Name	Type	Description
node_group_enable_wal	bool	グループに enable_wal_decoder セットが設定されているかどうか
node_group_streaming_	char	トランザクションストリーミング設定 'O'-オフ、'F'-ファイル、 'W'-ライタ、 'A'-自動、 'D'-デフォルト
node_group_location	char	ノードグループに関連付けられた場所の名前
node_group_enable_pro	char	ノードグループが `pgd-proxy`からのルーティングを許可するかどうか
node_group_enable_raft	bool	ノードグループが Raft コンセンサスを許可するかどうか

bdr.node_group_replication_sets

PGD グループ用に作成されるデフォルトのレプリケーションセットを示すビュー。bdr.replication_sets も参照してください。

bdr.node_group_replication_sets 列

Name	Type	Description
node_group_name	name	PGD グループの名前
def_repset	name	デフォルトの repset の名前
def_repset_ops	text[]	デフォルトの repset によってレプリケートされたアクション
def_repset_ext	name	デフォルトの「外部」repset の名前通常は def_repset と同じです
def_repset_ext_ops	text[]	デフォルトの「外部」rep セットによってレプリケートされたアクション通常は def_repset_ops と同じです

bdr.node_local_info

ローカルノードに固有のノードごとの構成を保存するために使用されるカタログテーブルノードごとの構成のグローバルビューではなく。

bdr.node_local_info 列

Name	Type	Description
node_id	oid	ノードの OID ローカルノードを含む
applied_state	oid	ノード状態の内部 ID
ddl_epoch	int8	ノードによって処理された最後のエポック番号
slot_name	name	そのノードへの接続に使用されるスロットの名前ローカルノードの場合は NULL

bdr.node_log_config

競合ログ構成に関する情報を保存するカタログビュー。

bdr.node_log_config 列

Name	Description
log_name	ロギング構成の名前
log_to_file	サーバーログファイルにログを記録するかどうか
log_to_table	テーブルにログを記録するかどうか、およびどのテーブルがターゲットであるか
log_conflict_type	NULL がすべてを意味する場合、ログに記録する競合タイプ
log_conflict_res	NULL がすべてを意味する場合、どの競合解決をログに記録しますか

bdr.node_peer_progress

レプリケーションストリーム内のすべてのノードの進行状況を追跡するために使用されるカタログ。クラスター内のすべてのノードは、その進行状況を `bdr.replay_progress_frequency` ミリ秒ごとに他のすべてのノードに定期的にブロードキャストしますデフォルトは 60000 ミリ秒、つまり 1 分です。このリレーションには N * (N-1) 行が必要です。

モニタリングには、 `bdr.node_slots` ビューの方が興味深いかもしれません。 *Monitoring* も参照してください。

bdr.node_peer_progress 列

Name	Type	Description
node_id	oid	この位置情報を報告した元ノードの OID
peer_node_id	oid	この位置情報が報告されたノードのピアリモートノードの OID
last_update_sent_time	timestamptz	レポートが元ノードによって送信された時刻
last_update_recv_time	timestamptz	ローカルサーバーがレポートを受信した時刻
last_update_node_lsn	pg_lsn	レポート時の元のノードの LSN
peer_position	pg_lsn	元のノードから見たノードのピアの最新の LSN
peer_replay_time	timestamptz	報告ノードによって認識されたピアの最新の再生時間
last_update_horizon_xid	oid	内部解像度ホライズン すべての下位 xid は報告ノードで解決されることが知られています
last_update_horizon_lsn	pg_lsn	内部解像度ホライズン レポートノードの LSN に関して同じ

bdr.node_replication_rates

このビューには、特定のノードからの送信レプリケーションアクティビティに関する情報が含まれています。

bdr.node_replication_rates 列

Column	Type	Description
peer_node_id	oid	この情報が報告されたノードのピアリモートノードの OID
target_name	name	ターゲットピアノードの名前
sent_lsn	pg_lsn	最新の送信位置
replay_lsn	pg_lsn	再生されたとして報告された最新の位置可視
replay_lag	interval	報告されたリプレイのおおよそのラグタイム
replay_lag_bytes	int8	attempts_lsn とオリジンの現在の WAL 書き込み位置のバイト差
replay_lag_size	text	repair_lsn と現在の WAL 書き込み位置間の人間が判読可能なバイトの差
apply_rate	bigint	ピアノードで 1 秒ごとに適用される LSN
catchup_interval	interval	ピアノードがまだ適用されていないすべての変更に追いつくまでに必要なおおよその時間

注釈: *replay_lag* は、再接続後すぐにゼロに設定されます。回避策として、*replay_lag_bytes* 、*replay_lag_size* 、または `catchup_interval` を使用します。

bdr.node_slots

このビューには、PGD が現在のデータベースで使用するレプリケーションスロットに関する情報が含まれています。

送信レプリケーションの監視 を参照

このビューのフィールドの使用と解釈に関するガイダンスについては。

bdr.node_slots 列

Name	Type	Description
target_dbname	name	ターゲットノード上のデータベース名
node_group_name	name	PGD グループの名前
node_group_id	oid	PGD グループの OID
origin_name	name	オリジンノードの名前
target_name	name	ターゲットノードの名前
origin_id	oid	元ノードの OID
target_id	oid	ターゲットノードの OID
local_slot_name	name	PGD に従ったレプリケーションスロットの名前
slot_name	name	Postgres によるスロットの名前上記と同じ
is_group_slot	boolean	スロットがこのノードのノードグループのクラッシュリカバリスロットである場合は true ["Group Replication Slot"](nodes#Group Replication Slot) を参照してください。
is_decoder_slot	boolean	このスロットはデコードワーカー機能によって使用されますか
plugin	name	このスロットを使用する論理デコードプラグイン pglogical_output または bdr である必要があります
slot_type	text	スロットのタイプ論理的である必要があります。
datoid	oid	現在のデータベースの OID
database	name	現在のデータベースの名前
temporary	bool	スロットは一時的なものですか
active	bool	スロットはアクティブですか?接続は接続されていますか?
active_pid	int4	スロットに接続されたプロセスの PID
xmin	xid	スロットに必要な XID
catalog_xmin	xid	スロットに必要なカタログ XID
restart_lsn	pg_lsn	スロットがデコードをリスタートできる LSN
confirmed_flush_lsn	pg_lsn	最新に確認された複製位置
usesysid	oid	レプリケーションセッションが実行されているユーザーの sysid

次のページに続く

表 31 – 前のページからの続き

Name	Type	Description
usename	name	レプリケーションセッションが実行されているユーザーのユーザー名
application_name	text	クライアント接続のアプリケーション名 `synchronous_standby_names`によって使用されます
client_addr	inet	クライアント接続の IP アドレス
client_hostname	text	クライアント接続のホスト名
client_port	int4	クライアント接続のポート
backend_start	timestamptz	接続が開始されたとき
state	text	レプリケーションの状態キャッチアップ、ストリーミングなど、またはオフラインの場合は「切断」
sent_lsn	pg_lsn	最新の送信位置
write_lsn	pg_lsn	最新の立場を書面どおりに報告
flush_lsn	pg_lsn	最新の位置はディスクにフラッシュされたとして報告されました
replay_lsn	pg_lsn	再生されたとして報告された最新の位置可視
write_lag	interval	報告された書き込みのおおよその遅延時間
flush_lag	interval	報告されたフラッシュのおおよその遅延時間
replay_lag	interval	報告されたリプレイのおおよそのラグタイム
sent_lag_bytes	int8	send_lsn と現在の WAL 書き込み位置のバイト差
write_lag_bytes	int8	write_lsn と現在の WAL 書き込み位置のバイト差
flush_lag_bytes	int8	lush_lsn と現在の WAL 書き込み位置のバイト差
replay_lag_bytes	int8	recovery_lsn と現在の WAL 書き込み位置のバイト差
sent_lag_size	text	send_lsn と現在の WAL 書き込み位置の間の人間が判読可能なバイトの差
write_lag_size	text	write_lsn と現在の WAL 書き込み位置間の人間が判読可能なバイトの差
flush_lag_size	text	flash_lsn と現在の WAL 書き込み位置の間の人間が判読可能なバイトの差
replay_lag_size	text	repair_lsn と現在の WAL 書き込み位置間の人間が判読可能なバイトの差

注釈: *replay_lag* は、再接続後すぐにゼロに設定されます。回避策として、*replay_lag_bytes* または `replay_lag_size` を使用します。

bdr.node_summary

このビューには、ローカルノードに知られているすべての PGD ノードに関する概要情報が含まれています。

bdr.node_summary 列

Name	Type	Description
node_name	name	ノードの名前
node_group_name	name	ノードが一部である PGD グループの名前
interface_connstr	text	ノードへの接続文字列
peer_state_name	text	人間が読める形式のノードの一貫した状態
peer_target_state_name	text	ノードが到達しようとしている状態参加または昇格中に
node_seq_id	int4	一意のシーケンス番号を生成するために使用されるノードのシーケンス識別子
node_local_dbname	name	ノードのデータベース名
node_id	oid	ノードの OID
node_group_id	oid	PGD ノードグループの OID
node_kind_name	oid	ノード種類名

bdr.queue

このテーブルには、レプリケートされた DDL ステートメントの履歴レコードが保存されます。

bdr.queue 列

Name	Type	Description
queued_at	timestamptz	ステートメントがキューに入れられたとき
role	name	ステートメントを実行したロール
replication_sets	text[]	ステートメントはどのレプリケーションセットに公開されましたか
message_type	char	メッセージの種類。考えられる値 A - テーブル同期 D - DDL S - シークエンス T - 切り捨て Q - SQL ステートメント
message	json	ステートメントのレプリケーションに必要なメッセージのペイロード

bdr.replication_set

レプリケーションセット構成を保存するテーブル。ユーザークエリーの場合、代わりに bdr.replication_sets ビューを確認することをお勧めします。

bdr.replication_set 列

Name	Type	Description
set_id	oid	レプリケーションセットの OID
set_nodeid	oid	ノードの OID 現在は常にローカルノード oid
set_name	name	レプリケーションセットの名前
replicate_insert	boolean	レプリケーションセットが INSERT をレプリケートするかどうかを示します
replicate_update	boolean	レプリケーションセットが UPDATE をレプリケートするかどうかを示します
replicate_delete	boolean	レプリケーションセットが DELETE をレプリケートするかどうかを示します
replicate_truncate	boolean	レプリケーションセットが TRUNCATE をレプリケートするかどうかを示します
set_isinternal	boolean	予約済み
set_autoadd_tables	boolean	新しいテーブルがこのレプリケーションセットに自動的に追加されるかどうかを示します
set_autoadd_seqs	boolean	新しいシーケンスがこのレプリケーションセットに自動的に追加されるかどうかを示します

bdr.replication_set_table

レプリケーションセットテーブルのメンバーシップを保存するテーブル。ユーザークエリーの場合、代わりに bdr.tables ビューを確認することをお勧めします。

bdr.replication_set_table 列

Name	Type	Description
set_id	oid	レプリケーションセットの OID
set_reloid	regclass	テーブルのローカル ID
set_att_list	text[]	予約済み
set_row_filter	pg_node_tree	コンパイルされた行フィルタリング式

bdr.replication_set_ddl

レプリケーションセット ddl レプリケーションフィルターを保存するテーブル。ユーザークエリーの場合、代わりに bdr.ddl_replication ビューを確認することをお勧めします。

bdr.replication_set_ddl 列

Name	Type	Description
set_id	oid	レプリケーションセットの OID
set_ddl_name	name	DDL フィルタの名前
set_ddl_tag	text	DDL フィルタのコマンドタグ
set_ddl_role	text	DDL を実行するロール

bdr.replication_sets

現在ノードで使用されていない場合でも、PGD グループで定義されたレプリケーションセットを表示するビュー。

bdr.replication_sets 列

Name	Type	Description
set_id	oid	レプリケーションセットの OID
set_name	name	レプリケーションセットの名前
replicate_insert	boolean	レプリケーションセットが INSERT をレプリケートするかどうかを示します
replicate_update	boolean	レプリケーションセットが UPDATE をレプリケートするかどうかを示します
replicate_delete	boolean	レプリケーションセットが DELETE をレプリケートするかどうかを示します
replicate_truncate	boolean	レプリケーションセットが TRUNCATE をレプリケートするかどうかを示します
set_autoadd_tables	boolean	新しいテーブルがこのレプリケーションセットに自動的に追加されるかどうかを示します
set_autoadd_seqs	boolean	新しいシーケンスがこのレプリケーションセットに自動的に追加されるかどうかを示します

bdr.schema_changes

スキーマ win PGD へのすべての変更を表示するシンプルなビュー。

bdr.schema_changes 列

Name	Type	Description
schema_changes_ts	timestampstz	トリガーの ID
schema_changes_change	char	変更タイプのフラグ
schema_changes_classid	oid	クラス ID
schema_changes_objecti	oid	オブジェクト ID
schema_changes_subid	smallint	サブスクリプション
schema_changes_descr	text	オブジェクトが変更されました
schema_changes_addrna	text[]	スキーマ変更の場所

bdr.sequence_alloc

galloc シーケンスの割り当ての詳細を表示するビュー。

bdr.sequence_alloc 列

Name	Type	Description
seqid	regclass	シーケンスの ID
seq_chunk_size	bigint	値内のチャンクのシーケンス番号
seq_allocated_up_to	bigint	NA
seq_nallocs	bigint	NA
seq_last_alloc	timestamptz	最後に割り当てられたシーケンス

bdr.sequences

このビューには、内部 PGD 簿記のシーケンスを除き、すべてのシーケンスとその種類がリストされます。

bdr.sequences 列

Name	Type	Description
nspname	name	シーケンスを含む名前空間
relname	name	シーケンスの名前
seqkind	text	シーケンスのタイプ'local'、'timeshard'、'galloc'

bdr.stat_activity

各バックエンドまたはワーカープロセスの動的アクティビティ。

これには、pg_stat_activity と同じ情報が含まれていますが、待機が PGD に関連する場合に wait_event が正しく設定される場合を除きます。

bdr.stat_relation

各リレーションに統計を適用します。追跡が有効になっており、特定のリレーションに対して何かがレプリケートされた場合にのみデータが含まれます。

bdr.stat_relation 列

Column	Type	Description
nspname	name	リレーションのスキーマの名前
relname	name	リレーションの名前
relid	oid	リレーションの OID
total_time	double precision	リレーションのレプリケーションの処理に費やされた合計時間
ninsert	bigint	リレーションに対してレプリケートされた挿入の数
nupdate	bigint	リレーションに対して複製された更新の数
ndelete	bigint	リレーションに対してレプリケートされた削除の数
ntruncate	bigint	リレーションに対してレプリケートされたトランケートの数
shared_blks_hit	bigint	リレーションの共有ブロックキャッシュヒットの合計数
shared_blks_read	bigint	リレーションに対して読み取られた共有ブロックの合計数
shared_blks_dirtied	bigint	リレーション用にダーティな共有ブロックの合計数

次のページに続く

表 41 – 前のページからの続き

Column	Type	Description
shared_blks_written	bigint	リレーション用に書き込まれた共有ブロックの合計数
blk_read_time	double precision	リレーションのブロックの読み取りに費やされた合計時間ミリ秒単位`track_io_timing`が有効な場合、それ以外の場合はゼロ
blk_write_time	double precision	リレーションのブロックの書き込みに費やされた合計時間ミリ秒単位`track_io_timing`が有効な場合、それ以外の場合はゼロ
lock_acquire_time	double precision	リレーションのロックの取得に費やされた合計時間ミリ秒単位 `bdr.track_apply_lock_timing`が有効な場合、それ以外の場合はゼロ

bdr.stat_subscription

各サブスクリプションの統計を適用します。追跡が有効になっている場合にのみデータが含まれます。

bdr.stat_subscription 列

Column	Type	Description
sub_name	name	サブスクリプションの名前
subid	oid	サブスクリプションの OID
mean_apply_time	double precision	適用トランザクションごとの平均時間ミリ秒
nconnect	bigint	このサブスクリプションがアップストリームに接続した回数
ncommit	bigint	このサブスクリプションが行ったコミット数
nabort	bigint	ライタがこのサブスクリプションに対して実行した中止の数
nerror	bigint	このサブスクリプションでライタがヒットしたエラーの数
nskippedtx	bigint	このサブスクリプションのライタによってスキップされたトランザクションの数`skip_transaction`競合リゾルバーのため
ninsert	bigint	このサブスクリプションが行った挿入の数
nupdate	bigint	このサブスクリプションが行った更新の数
ndelete	bigint	このサブスクリプションが行った削除数
ntruncate	bigint	このサブスクリプションが行った切り捨ての数
nddl	bigint	このサブスクリプションが実行した DDL 操作の数
ndeadlocks	bigint	デッドロックが発生したエラーの数

次のページに続く

表 42 – 前のページからの続き

Column	Type	Description
nretries	bigint	ライタが実行した再試行数完全な再起動/再接続を行わずに
nstream_writer	bigint	ライタにストリーミングされたトランザクションの数
nstream_file	bigint	ファイルにストリーミングされたトランザクションの数
nstream_commit	bigint	コミットされたストリーミングトランザクションの数
nstream_abort	bigint	アボートされたストリーミングトランザクションの数
nstream_start	bigint	処理された STREAM START メッセージの数
nstream_stop	bigint	処理された STREAM STOP メッセージの数
nstream_commit	bigint	コミットされたストリーミングトランザクションの数
nstream_abort	bigint	アボートされたストリーミングトランザクションの数
nstream_prepare	bigint	準備されたストリーミングトランザクションの数
nstream_insert	bigint	処理されたストリーミング挿入の数
nstream_update	bigint	処理されたストリーミング更新の数
nstream_delete	bigint	処理されたストリーミング削除の数
nstream_truncate	bigint	処理されたストリーミングトランケートの数
shared_blks_hit	bigint	サブスクリプションによる共有ブロックキャッシュヒットの合計数
shared_blks_read	bigint	サブスクリプションによって読み取られた共有ブロックの合計数
shared_blks_dirtied	bigint	サブスクリプションによってダーティされた共有ブロックの合計数
shared_blks_written	bigint	サブスクリプションによって書き込まれた共有ブロックの合計数
blk_read_time	double precision	サブスクリプションがブロックの読み取りに費やした合計時間ミリ秒単位`track_io_timing`が有効な場合、それ以外の場合はゼロ
blk_write_time	double precision	サブスクリプションがブロックの書き込みに費やした合計時間ミリ秒単位`track_io_timing`が有効な場合、それ以外の場合はゼロ
connect_time	timestamp with time zone	現在の上流接続が確立された時間、接続されていない場合は NULL
last_disconnect_time	timestamp with time zone	最後のアップストリーム接続がドロップされた時刻
start_lsn	pg_lsn	このサブスクリプションが上流からレプリケーションの開始を要求した LSN

次のページに続く

表 42 – 前のページからの続き

Column	Type	Description
retries_at_same_lsn	bigint	サブスクリプションが同じ LSN 値からリスタートされた試行回数
curr_ncommit	bigint	現在の接続が確立された後にこのサブスクリプションが実行したコミット数
npre_commit_confirmati	bigint	CAMO パートナーによるプリコミット確認の数
npre_commit	bigint	プリコミット数
ncommit_prepared	bigint	準備されたトランザクションのコミット数
nabort_prepared	bigint	準備されたトランザクションアボートの数
nprovisional_waits	bigint	同時適用トランザクションによる同じタプルの更新/削除操作の数。これらは暫定的な待機です。*Parallel Apply* を参照
ntuple_waits	bigint	安全に適用されるまで待機した更新/削除操作の数。 *Parallel Apply* を参照
ncommit_waits	bigint	コミットされる前に待機する必要があった、完全に適用されたトランザクションの数。 *Parallel Apply* を参照
stats_reset	timestamp with time zone	これらのサブスクリプション統計がリセットされた時間

bdr.subscription

このカタログテーブルには、ローカル PGD ノードが所有するすべてのサブスクリプションとそのモードがリストされています。

bdr.subscription 列

Name	Type	Description
sub_id	oid	サブスクリプションの ID
sub_name	name	サブスクリプションの名前
nodegroup_id	oid	ノードグループの ID
origin_node_id	oid	オリジンノードの ID
source_node_id	oid	ソースノードの ID
target_node_id	oid	ターゲットノードの ID
subscription_mode	char	サブスクリプションのモード
sub_enabled	bool	サブスクリプションが有効かどうかレプリケーションである必要があります。
apply_delay	interval	このサブスクリプションの変更の適用はどのくらい遅れますか通常 0

次のページに続く

表 43 – 前のページからの続き

Name	Type	Description
slot_name	name	このサブスクリプションで使用されるアップストリームのスロット
origin_name	name	このサブスクリプションで使用されるローカルオリジン
num_writers	int	このサブスクリプションが使用するライタプロセスの数
streaming_mode	char	サブスクリプションのストリーミング構成
replication_sets	text[]	このサブスクリプションによってレプリケートされたレプリケーションセット NULL = all
forward_origin	text[]	このサブスクリプションによって転送されたオリジン NULL = all

bdr.subscription_summary

このビューには、ローカルノードが他のノードに対して持っているすべての PGD サブスクリプションに関する概要情報が含まれています。

bdr.subscription_summary 列

Name	Type	Description
node_group_name	name	ノードが一部である PGD グループの名前
sub_name	name	サブスクリプションの名前
origin_name	name	オリジンノードの名前
target_name	name	ターゲットノードの名前通常はローカルノード
sub_enabled	bool	サブスクリプションは有効になっていますか
sub_slot_name	name	このサブスクリプションで使用されるオリジンノードのスロット名
sub_replication_sets	text[]	サブスクライブされたレプリケーションセット
sub_forward_origins	text[]	サブスクリプションは、オリジン以外のノードから転送された変更を受け入れますか
sub_apply_delay	interval	オリジンと比較して、これだけの遅延トランザクション
sub_origin_name	name	このサブスクリプションで使用されるレプリケーション元の名前
bdr_subscription_mode	char	サブスクリプションモード
subscription_status	text	サブスクリプションワーカーのステータス
node_group_id	oid	ノードが一部である PGD グループの OID
sub_id	oid	サブスクリプションの OID
origin_id	oid	元ノードの OID

次のページに続く

表 44 – 前のページからの続き

Name	Type	Description
target_id	oid	ターゲットノードの OID
receive_lsn	pg_lsn	受信した変更またはメッセージの最新の LSN これは、再起動の場合に後退する可能性があります
receive_commit_lsn	pg_lsn	受け取った最後に COMMIT の最新の LSN これは、再起動の場合に後退する可能性があります
last_xact_replay_lsn	pg_lsn	このサブスクリプションで再生された最後のトランザクションの LSN
last_xact_flush_lsn	timestamptz	このサブスクリプションで再生され、永続的にディスクにフラッシュされる最後のトランザクションの LSN
last_xact_replay_timesta	timestamptz	このサブスクリプションで再生された最後のトランザクションのタイムスタンプ

bdr.tables

このビューは、レプリケーションセットのテーブルメンバーシップに関する情報をリストします。テーブルが複数のレプリケーションセットに存在する場合、このテーブルに複数回表示されます。

bdr.tables 列

Name	Type	Description
relid	oid	リレーションの OID
nspname	name	スキーマリレーションの名前は次のとおりです
relname	name	リレーションの名前
set_name	name	レプリケーションセットの名前
set_ops	text[]	レプリケートされた操作のリスト
rel_columns	text[]	レプリケートされた列のリスト NULL = すべての列*
row_filter	text	行フィルタリング式
conflict_detection	text	使用される競合検出方法 row_origin デフォルト、row_version または column_level

(*) これらの列は将来の使用のために予約されており、現在 NULL である必要があります。

bdr.taskmgr_work_queue

タスクマネージャーによって作成および処理された作業項目が含まれています。作業項目は 1 つのノードでのみ作成され、別のノードで処理されます。

bdr.taskmgr_work_queue 列

Column	Type	Description
ap_wq_workid	bigint	ワークアイテムの一意の ID
ap_wq_ruleid	int	autopartition_rules にリストされているルールの ID。ルールは bdr.autopartition コマンドを使用して指定されます
ap_wq_relname	name	タスクが属するリレーションの名前
ap_wq_relnamespace	name	この作業項目のルールで指定されたテーブルスペースの名前
ap_wq_partname	name	作業項目によって作成されたパーティションの名前
ap_wq_work_category	char	作業カテゴリは、'c' パーティションの作成 、'm' パーティションの移行 、 'd' パーティションのドロップ 、'a' パーティションの変更 のいずれかです。
ap_wq_work_sql	text	作業項目の SQL クエリー
ap_wq_work_depends	Oid[]	ワークアイテムが依存するノードの OID

bdr.taskmgr_workitem_status

各ノードでローカルに更新される作業項目のステータス。

bdr.taskmgr_workitem_status 列

Column	Type	Description
ap_wi_workid	bigint	ワークアイテムの ID
ap_wi_nodeid	Oid	ワークアイテムが処理されているノードの OID
ap_wi_status	char	ステータスは、'q' キューイング、'c'Complete、'f'Failed、'u'Unknown のいずれかです。
ap_wi_started_at	timestamptz	ワークアイテムの開始タイムスタンプ
ap_wi_finished_at	timestamptz	ワークアイテムの終了タイムスタンプ

bdr.taskmgr_local_work_queue

タスクマネージャーによって作成および処理された作業項目が含まれています。これは bdr.taskmgr_work_queue に似ていますが、これらの作業項目はローカル管理テーブル用である点が異なります。各ノードは、クラスター内の他のノードから独立して、独自のローカル作業項目を作成および処理します。

bdr.taskmgr_local_work_queue 列

Column	Type	Description
ap_wq_workid	bigint	ワークアイテムの一意の ID
ap_wq_ruleid	int	autopartition_rules にリストされているルールの ID。ルールは bdr.autopartition コマンドを使用して指定されます
ap_wq_relname	name	タスクが属するリレーションの名前
ap_wq_relnamespace	name	この作業項目のルールで指定されたテーブルスペースの名前。
ap_wq_partname	name	作業項目によって作成されたパーティションの名前
ap_wq_work_category	char	カテゴリは、'c' パーティションの作成、'm' パーティションの移行、'd' パーティションのドロップ、'a' パーティションの変更 のいずれかです。
ap_wq_work_sql	text	作業項目の SQL クエリー
ap_wq_work_depends	Oid[]	常に NULL

bdr.taskmgr_local_workitem_status

ローカルに管理されるテーブルの作業項目のステータス。

bdr.taskmgr_local_workitem_status 列

Column	Type	Description
ap_wi_workid	bigint	ワークアイテムの ID
ap_wi_nodeid	Oid	ワークアイテムが処理されているノードの OID
ap_wi_status	char	ステータスは、'q' キューイング、'c'Complete、'f'Failed、'u'Unknown のいずれかです。
ap_wi_started_at	timestamptz	ワークアイテムの開始タイムスタンプ
ap_wi_finished_at	timestamptz	ワークアイテムの終了タイムスタンプ

bdr.trigger

このビューでは、作成されたすべてのストリームトリガーを表示できます。多くの場合、ここでのトリガーは bdr.create_conflict_trigger から作成されます。

bdr.trigger 列

Name	Type	Description
trigger_id	oid	トリガーの ID
trigger_reloid	regclass	関連するファンクションの名前
trigger_pgtgid	oid	Postgres トリガー ID
trigger_type	char	トリガー呼び出しの種類
trigger_name	name	トリガーの名前

bdr.triggers

読みやすい列を含む bdr.trigger の展開ビュー。

Name	Type	Description
trigger_name	name	トリガーの名前
event_manipulation	text	オペレーション
trigger_type	bdr.trigger_type	トリガーの種類
trigger_table	bdr.trigger_reloid	それを呼び出すテーブル
trigger_function	name	使用されるファンクション

bdr.workers

実行中の PGD ワーカープロセスに関する情報。

これを pid を使用して bdr.stat_activity と結合して、PGD ワーカーの状態についてのさらに多くの洞察を得ることができます。

bdr.workers 列

Name	Type	Description
worker_pid	int	ワーカープロセスのプロセス ID
worker_role	int	ワーカーロールの数値表現

次のページに続く

表 52 – 前のページからの続き

Name	Type	Description
worker_role_name	text	ワーカーロールの名前
worker_subid	oid	ワーカーが関連付けられている場合のサブスクリプション ID

bdr. ライター

PGD ライタプロセスに関する特定の情報。

bdr.writers 列

Name	Type	Description
sub_name	name	サブスクリプションの名前
pid	int	ワーカープロセスのプロセス ID
syncing_rel	int	同期される関係の OID 存在する場合
streaming_allowed	text	このライタはライタへの直接ストリーミングのターゲットになりますか
is_streaming	bool	このライタにストリーミングされているトランザクションはありますか
remote_xid	xid	処理中のトランザクションのリモートトランザクション ID 存在する場合
remote_commit_lsn	pg_lsn	最後に処理されたコミットの LSN
commit_queue_position	int	内部コミットキューの位置
nxacts	bigint	このライタによって処理されたトランザクションの数
ncommits	bigint	このライタがコミットしたトランザクションの数
naborts	bigint	このライタによって中止されたトランザクションの数
nstream_file	bigint	このライタによって処理されたストリームからファイルへのトランザクションの数
nstream_writer	bigint	このライタによって処理されたライターへのストリーミングトランザクションの数

bdr.worker_tasks

bdr.worker_tasks ビューは、PGD の現在のワーカー起動レート制限状態と、バックグラウンドでのワーカーの起動と登録アクティビティに関するいくつかの基本的な統計を表示します。

ここにリストされている他のビューとは異なり、現在のデータベースと PGD ノードに固有ではありません。現在の PostgreSQL インスタンスのすべての PGD ノードの状態が表示されます。現在のデータベースに参加してフィルタリングします。

bdr.worker_tasks は、walsender と出力プラグインを追跡しません。

bdr.worker_tasks 列

Column	Type	Description
task_key_worker_role	integer	ワーカーロール識別子
task_key_worker_role_n	text	ワーカーロール名
task_key_dboid	oid	データベース識別子、使用可能な場合
datname	name	データベースの名前使用可能な場合
task_key_subid	oid	サブスクリプション識別子、可能な場合
sub_name	name	サブスクリプションの名前使用可能な場合
task_key_ext_libname	name	ライブラリの名前おそらく bdr
task_key_ext_funcname	name	ファンクションエントリーポイントの名前
task_key_ext_workernan	name	ワーカーに割り当てられた名前
task_key_remoterelid	oid	リモート同期関係の識別子使用可能な場合
task_pid	integer	ワーカーのプロセス ID
task_registered	timestamp with time zone	ワーカー登録タイムスタンプ
since_registered	interval	ワーカーが登録されてからのインターバル
task_attached	timestamp with time zone	ワーカー接続タイムスタンプ
since_attached	interval	ワーカーが接続してからのインターバル
task_exited	timestamp with time zone	ワーカー終了タイムスタンプ
since_exited	interval	ワーカーが終了してからのインターバル
task_success	boolean	ワーカーはまだ実行されていますか？
task_next_launch_not_b	timestamp with time zone	ワーカーが再度再起動されるときのタイムスタンプ
until_launch_allowed	interval	次の起動までの残り時間
task_last_launch_reques	integer	起動を要求したプロセス ID
task_last_launch_reques	timestamp with time zone	要求が行われたときのタイムスタンプ
since_last_request	interval	最後の要求からのインターバル
task_last_launch_reques	boolean	最後の要求は成功しましたか？
task_nrequests	integer	要求の数
task_nregistrations	integer	登録数

次のページに続く

表 54 – 前のページからの続き

Column	Type	Description
task_prev_pid	integer	前世代のプロセス ID
task_prev_registered	timestamp with time zone	以前に登録されたタスクのタイムスタンプ
since_prev_registered	interval	前回の登録からのインターバル
task_prev_launched	timestamp with time zone	前回の起動のタイムスタンプ
since_prev_launched	interval	前回の起動からのインターバル
task_prev_exited	timestamp with time zone	前のタスクが終了した時のタイムスタンプ
since_prev_exited	interval	前のタスクが終了してからの間隔
task_first_registered	timestamp with time zone	最初に登録が発生したときのタイムスタンプ
since_first_registered	interval	最初の登録からのインターバル

9.1.2 System functions

主に SQL から呼び出すファンクションを使用して、PGD 管理を実行します。PGD のすべてのファンクションは bdr スキーマで公開されています。search_path に bdr を配置する代わりに、これらのファンクションへの呼び出しをスキーマ修飾します。

バージョン情報ファンクション

bdr.bdr_version

このファンクションは、現在使用している BDR 拡張機能のバージョンのテキスト表現を取得します。

bdr.bdr_version_num

このファンクションは、現在使用されている BDR 拡張機能のバージョン番号を取得します。バージョン番号は単調増加であるため、この値をより小さいおよびより大きい比較に使用できます。

次の式は、メジャーバージョン、マイナーバージョン、およびパッチリリースで構成されるバージョン番号を単一の数値に結果ます。

```
MAJOR_VERSION  *10000 + MINOR_VERSION*  100 + PATCH_RELEASE
```

システム情報ファンクション

bdr.get_relation_stats

リレーション情報を返します。

bdr.get_subscription_stats

現在のサブスクリプション統計を結果ます。

システムおよび進行状況情報パラメーター

PGD は、 `psql` の `SHOW` を使用して、またはクライアントアプリケーションから `PQparameterStatus` または同等の製品を使用して照会できるいくつかのパラメーターを公開します。

bdr.local_node_id

セッションを初期化すると、これはクライアントが接続しているノード ID に設定されます。これにより、アプリケーションは、透明なプロキシの背後にある場合でも、接続されているノードを認識できます。

> 接続プールとプロキシ でも使用されます。

bdr.last_committed_lsn

非同期トランザクションの `COMMIT` ごとに、このパラメーターは更新されて、オリジンノードのコミットレコードの最後を指します。`bdr.wait_for_apply_queue` と組み合わせると、アプリケーションはマルチプルのノードにわたってカウサル読み取りを実行できます。つまり、トランザクションがリモートで可視されるまで待機します。

transaction_id

CAMO が有効になっている場合、Postgres がトランザクション ID を割り当てるとすぐに、このパラメーターが更新されて、割り当てられたばかりのトランザクション ID を表示します。

bdr.is_node_connected

概要

```
bdr.is_node_connected(node_name name)
```

指定されたピアのワルセンダーがこのノードでアクティブかどうかを確認することにより、ブール値を返します。

bdr.is_node_ready

概要

```
bdr.is_node_ready(node_name name, span interval DEFAULT NULL)
```

ラグが指定されたスパンより低いか、それ以外の場合は TO ASYNC の timeout より低いかどうかをチェックすることにより、ブール値を返します。

コンセンサスファンクション

bdr.consensus_disable

サーバーが再起動するか、bdr.consensus_enable を使用して再有効化されるまで、ローカルノードのコンセンサスワーカーを無効にします。最初に発生した方。

> **警告:** コンセンサスを無効にすると、PGD の一部の機能が無効になり、長時間無効になっていると EDB Postgres 分散クラスターの可用性に影響します。この機能は、テクニカルサポートと協力する場合にのみ使用します。

bdr.consensus_enable

ローカルノードで無効になったコンセンサスワーカーが再度有効になりました。

bdr.consensus_proto_version

ローカルノードが現在使用しているコンセンサスプロトコルのバージョンを返します。

PGD グループの再構成の内部メカニズムに必要です。

bdr.consensus_snapshot_export

概要

```
bdr.consensus_snapshot_export(version integer DEFAULT NULL)
```

ローカルノードの現在コミットおよび適用された状態から新しい PGD コンセンサススナップショットを生成し、bytea として結果ます。

デフォルトでは、サポートされている最新の Raft バージョンのスナップショットがエクスポートされます。ただし、明示的な version 番号を渡すことにより、それをオーバーライドできます。

エクスポートするノードは現在の Raft リーダーである必要はなく、リーダーの最新の状態で完全に最新の状態である必要はありません。ただし、bdr.consensus_snapshot_import() は、このようなスナップショットを受け入れない場合があります。

新しいスナップショットは、ローカルノードの bdr.local_consensus_snapshot テーブルに自動的に保存されません。呼び出し元にのみ返されます。

生成されたスナップショットは、エクスポートノードの Raft ログ位置の背後にある同じ PGD ノードグループ内の他のノードの bdr.consensus_snapshot_import() に渡される場合があります。

この機能が動作するには、ローカル PGD コンセンサスワーカーを無効にする必要があります。一般的な使用法は次のとおりです。

```
SELECT bdr.bdr_consensus_disable();
\copy (SELECT * FROM bdr.consensus_snapshot_export()) TO my_node_consensus_snapshot.
↪data
SELECT bdr.bdr_consensus_enable();
```

PGD コンセンサスワーカーが無効になっている間

- ノードでの DDL ロックの試行は失敗するか、タイムアウトします。
- galloc シーケンスは新しい値を取得しません。
- Eage および CAMO トランザクションの一時停止またはエラー。
- 分散コンセンサスシステムを必要とする他の機能が中断されます。必要なダウンタイムは、一般に非常に短時間です。

ユースケースによっては、 bdr.local_consensus_snapshot テーブルの snapshot フィールドから既に存在するスナップショットを抽出し、代わりにそれを使用することが現実的である場合があります。その際、コンセンサスワーカーを停止する必要はありません。

bdr.consensus_snapshot_import

概要

```
bdr.consensus_snapshot_import(IN snapshot bytea)
```

bdr.consensus_snapshot_export() によって、通常は同じ PGD ノードグループ内の別のノードからエクスポートされたコンセンサススナップショットをインポートします。

別のノード上の bdr.local_consensus_snapshot テーブルの snapshot フィールドから直接抽出されたスナップショットを使用することもできます。

この機能は、破損またはユーザーエラーが発生した場合に、PGD ノードのカタログ状態を既知の良好な状態にリセットするのに役立ちます。

スナップショットが生成されたときに、インポートノードの apply_index がスナップショットエクスポートノードの commit_index 以下の場合、スナップショットをインポートできます。bdr.get_raft_status() を参照してください。ログが既に進みすぎているためにスナップショットを受け入れることができないノー

ドは、エラーを発生させ、変更は行いません。スナップショットがインポートされると、ノードは現在のリーダーから残りの変更を取得するため、インポートされたスナップショットは完全に最新の状態である必要はありません。

この機能が動作するには、インポートノードで PGD コンセンサスワーカーを無効にする必要があります。詳細については、bdr.consensus_snapshot_export() のノートを参照してください。

この機能を使用して、次のことを実行してローカルノードに新しい Raft スナップショットを生成させることができます。

```
SELECT bdr.consensus_snapshot_import(bdr.consensus_snapshot_export());
```

このアプローチでは、現在適用されているログの位置まで Raft ログが切り捨てられる場合があります。

bdr.consensus_snapshot_verify

概要

```
bdr.consensus_snapshot_verify(IN snapshot bytea)
```

bdr.consensus_snapshot_export() によってエクスポートされた指定されたコンセンサススナップショットを確認します。スナップショットヘッダーには、生成されたバージョンが含まれており、ノードは同じバージョンに対して検証しようとします。

スナップショットは、クラスター内の同じノードまたは他のノードでエクスポートされた可能性があります。スナップショットを検証するノードがエクスポートされたスナップショットのバージョンをサポートしていない場合、エラーが発生します。

bdr.get_consensus_status

現在のコンセンサス Raft ワーカーに関するステータス情報を結果ます。

bdr.get_raft_status

現在のコンセンサス Raft ワーカーに関するステータス情報を結果ます。bdr.get_consensus_status のエイリアス。

bdr.raft_leadership_transfer

概要

```
bdr.raft_leadership_transfer(IN node_name text, IN wait_for_completion boolean)
```

node_name で指定されたノードに Raft リーダーになるように要求します。要求は任意の PGD ノードから開始でき、現在のリーダーに内部転送されて、指定されたノードにリーダーシップを転送します。指定されたノードは、完全な投票権を持つ ACTIVE PGD ノードである必要があります。

wait_for_completion が false の場合、要求はベストエフォートベースで提供されます。ノードが bdr.raft_election_timeout 期間にリーダーになることができない場合、他の有効なノードが再びリーダーになります。また、リーダーシップは Raft プロトコルごとに時間の経過とともに変更される場合があります。true の戻り結果は、要求が正常に送信されたことのみを示します。

wait_for_completion が true の場合、ファンクションは指定されたノードが新しいリーダーになるまで待機し、要求されたノードが Raft リーダーになれなかった場合たとえば、ネットワークの問題のため、無限に待機します。したがって、無限ループを防ぐために、常に statement_timeout と wait_for_completion を設定することをお勧めします。

ユーティリティファンクション

bdr.wait_slot_confirm_lsn

このセッションの最後の書き込みが 1 つまたはすべてのノードで再生されるまで待機できます。

スロットが特定の LSN を通過するまで待機します。位置が指定されない場合、現在の書き込み位置がローカルノードで使用されます。

スロット名が渡されない場合、すべての PGD スロットが LSN を通過するまで待機します。

ファンクションは、他のノードからの変更を 1000 ミリ秒ごとにポーリングします。

スロットが同時にドロップされた場合、そのスロットの待機は終了します。ノードが現在ダウンしており、スロットを更新していない場合、待機は継続されます。その場合、statement_timeout をより早く完了するように設定することができます。

概要

```
bdr.wait_slot_confirm_lsn(slot_name text DEFAULT NULL, target_lsn pg_lsn DEFAULT NULL)
```

パラメーター

- slot_name —レプリケーションスロットの名前、または NULL の場合、すべての PGD スロットのみ。
- target_lsn —待機する LSN、または NULL の場合、ローカルノード上の現在の書き込み LSN を使用します。

bdr.wait_for_apply_queue

ファンクション bdr.wait_for_apply_queue を使用すると、PGD ノードは、特定の PGD ノードから発生した特定のトランザクションのローカルアプリケーションを待機できます。そのピアノードからのすべてのトランザクションがローカルに適用された後にのみ返されます。アプリケーションまたはプロキシはこの機能を使用して、古い読み取りを防止できます。

便宜上、PGD は CAMO および CAMO パートナーノードにこのファンクションのバリアントを提供します。
bdr.wait_for_camo_partner_queue を参照してください。

特定の LSN が指定された場合、それは、ピアが待機するリカバリストリームのポイントです。これは、以前のまたは同時接続でそのピアノードから取得した bdr.last_committed_lsn と使用できます。

指定された target_lsn が NULL の場合、このファンクションはローカル受信バッファをチェックし、指定されたピアノードから受け取った最後のトランザクションの LSN を使用し、既に受信したすべてのトランザクションが適用されるのを効果的に待機します。これは、ピアノードに障害が発生し、どのトランザクションが送信されたかが不明な場合に特に役立ちます。この場合、送信者側でまだ転送中またはバッファリングされているトランザクションは待機されません。

概要

```
bdr.wait_for_apply_queue(peer_node_name TEXT, target_lsn pg_lsn)
```

パラメーター

- peer_node_name —着信トランザクションがキューに入れられて待機するピアノードの名前。NULL の場合、すべてのピアノードの適用キューが使用されるまで待機します。
- target_lsn —待機するピアノードからのレプリケーションストリームの LSN。通常、ピアノードから bdr.last_committed_lsn を介して学習します。

bdr.get_node_sub_receive_lsn

サブスクライバーでこのファンクションを使用して、特定のオリジンから受信した最後の LSN を取得できます。適用されるトランザクションに関連する LSN インクリメントのみを考慮して、フィルタリングしないか、フィルタリングすることができます。

このファンクションの出力と bdr.get_node_sub_apply_lsn() の出力の差は、対応する適用キューのサイズを測定します。

概要

```
bdr.get_node_sub_receive_lsn(node_name name, committed bool default true)
```

パラメーター

- node_name —LSN が取得されるレプリケーションストリームのソースであるノードの名前。
- committed —; デフォルト true では、このファンクションは、最後の LSN 全体ではなく、受信したトランザクションのコミットのみを考慮します。これには、サブスクライバノードに影響を与えないアクションが含まれます。

bdr.get_node_sub_apply_lsn

サブスクライバーでこのファンクションを使用して、特定のオリジンから受信および適用された最後の LSN を取得できます。

概要

```
bdr.get_node_sub_apply_lsn(node_name name)
```

パラメーター

- node_name —LSN が取得されるレプリケーションストリームのソースであるノードの名前。

bdr.run_on_all_nodes

すべてのノードでクエリを実行するファンクション。

警告: このファンクションは、ノードの DSN で指定されたノード間接続に使用されるユーザーの権限を使用して、リモートノードで任意のクエリーを実行します。この機能に特権を付与するときは注意してください。

概要

```
bdr.run_on_all_nodes(query text)
```

パラメーター

- query —実行する任意のクエリー。

注

このファンクションは、他のノードに接続してクエリーを実行し、各ノードから JSON 形式で結果を返します。複数の行が各ノードから返され、JSON 配列としてエンコードされる場合があります。ノードがダウンしているため接続できないなどのエラーは、応答フィールドに表示されます。明示的な statement_timeout またはその他のランタイムパラメーターが設定されていないため、デフォルトが使用されます。

このファンクションは、通常のレプリケーションを経由しません。すべての既知のノードへの直接クライアント接続を使用します。デフォルトでは、コマンドはクラスター内のすべてのノードに既に送信されているため、bdr.ddl_replication = off で接続が作成されます。

レプリケーションが中断され、ノード間で不一致が発生する危険があるため、この機能を使用する場合は注意してください。透過的 DDL レプリケーションまたは bdr.replicate_ddl_command() を使用して DDL をレプリケートします。DDL は、将来のリリースでブロックされる可能性があります。

例

例、次のクエリのように、モニタリングでこのファンクションを使用すると便利です。

```
SELECT bdr.run_on_all_nodes($$
    SELECT local_slot_name, origin_name, target_name, replay_lag_size
      FROM bdr.node_slots
     WHERE origin_name IS NOT NULL
$$);
```

このクエリは、2 ノードクラスターで次のような結果を返します。

```
[
    {
        "dsn": "host=node1 port=5432 dbname=bdrdb user=postgres ",
        "node_id": "2232128708",
        "response": {
            "command_status": "SELECT 1",
            "command_tuples": [
                {
                    "origin_name": "node1",
                    "target_name": "node2",
```

(次のページに続く)

(前のページからの続き)


```
                    "local_slot_name": "bdr_bdrdb_bdrgroup_node2",
                    "replay_lag_size": "0 bytes"
                }
            ]
        },
        "node_name": "node1"
    },
    {
        "dsn": "host=node2 port=5432 dbname=bdrdb user=postgres ",
        "node_id": "2058684375",
        "response": {
            "command_status": "SELECT 1",
            "command_tuples": [
                {
                    "origin_name": "node2",
                    "target_name": "node1",
                    "local_slot_name": "bdr_bdrdb_bdrgroup_node1",
                    "replay_lag_size": "0 bytes"
                }
            ]
        },
        "node_name": "node2"
    }
]
```


bdr.run_on_nodes

指定されたノードのリストでクエリを実行するファンクション。

> **警告:** このファンクションは、ノードの DSN で指定されたノード間接続に使用されるユーザーの権限を使用して、リモートノードで任意のクエリーを実行します。この機能に特権を付与するときは注意してください。

概要

```
bdr.run_on_nodes(node_names text[], query text)
```

パラメーター

- node_names —クエリーが実行されるノード名のテキスト ARRAY
- query —実行する任意のクエリー。

注

このファンクションは、他のノードに接続してクエリーを実行し、各ノードから JSON 形式で結果を返します。複数の行を各ノードから返すことができ、JSON 配列としてエンコードされます。ノードがダウンしているため接続できないなどのエラーは、応答フィールドに表示されます。明示的な statement_timeout またはその他のランタイムパラメーターが設定されていないため、デフォルトが使用されます。

このファンクションは、通常のレプリケーションを経由しません。すべての既知のノードへの直接クライアント接続を使用します。デフォルトでは、接続は bdr.ddl_replication = off で作成され、同じレプリケートされた DDL コマンドが複数のノードに送信された場合のレプリケーションの問題を回避します。

レプリケーションが中断され、ノード間で不一致が発生する危険があるため、この機能を使用する場合は注意してください。グローバルスキーマ変更の場合、透過的 DDL レプリケーションまたは bdr.replicate_ddl_command() を使用して DDL をレプリケートします。

bdr.run_on_group

ノードのグループでクエリを実行する機能。

> **警告:** このファンクションは、ノードの DSN で指定されたノード間接続に使用されるユーザーの権限を使用して、リモートノードで任意のクエリーを実行します。この機能に特権を付与するときは注意してください。

概要

```
bdr.run_on_group(node_group_name text, query text)
```

パラメーター

- node_group_name —クエリが実行されるノードグループの名前。
- query —実行する任意のクエリー。

注

このファンクションは、他のノードに接続してクエリーを実行し、各ノードから JSON 形式で結果を返します。複数の行を各ノードから返すことができ、JSON 配列としてエンコードされます。ノードがダウンしているため接続できないなどのエラーは、応答フィールドに表示されます。明示的な statement_timeout またはその他のランタイムパラメーターが設定されていないため、デフォルトが使用されます。

このファンクションは、通常のレプリケーションを経由しません。すべての既知のノードへの直接クライアント接続を使用します。デフォルトでは、接続は bdr.ddl_replication = off で作成され、同じレプリケートされた DDL コマンドが複数のノードに送信された場合のレプリケーションの問題を回避します。

レプリケーションが中断され、グループ内のノード間で不一致が発生する危険があるため、この機能を使用する場合は注意してください。グローバルスキーマ変更の場合、透過的 DDL レプリケーションまたは bdr.replicate_ddl_command() を使用して DDL をレプリケートします。

bdr.global_lock_table

このファンクションは、指定されたテーブルのグローバル DML ロックを取得します。グローバル DML ロックについては、
DDL ロックの詳細 を参照してください。

概要

```
bdr.global_lock_table(relation regclass)
```

パラメーター

- relation —ロックへの関係の名前または oid。

注

このファンクションは、ddl_locking 設定とは無関係にグローバル DML ロックを取得します。

bdr.global_lock_table ファンクションには、bdr.backwards_compatibility が 30618 以下に設定されていない限り、ロックされた relation に対する UPDATE 、DELETE 、または TRUNCATE 特権が必要です。

bdr.wait_for_xid_progress

このファンクションを使用して、特定のノードノード ID で識別される特定のトランザクション XID で識別されるが、クラスターで十分な進行を行うのを待機できます。進行状況は、ノードに適用されているトランザクションとして定義され、このノードは、トランザクションが適用される前に行われた他のすべてのレプリケーション変更を確認しています。

概要

```
bdr.wait_for_xid_progress(origin_node_id oid, origin_topxid int4, allnodes boolean␣
↪DEFAULT true)
```

パラメーター

- origin_node_id —トランザクションが発生したノードのノード ID。
- origin_topxid —トランザクションの XID。
- allnodes — true の場合、すべてのノードでトランザクションが進行するまで待機します。それ以外の場合は、現在のノードのみを待機します。

注

現在、これらのトランザクションのみが追跡されるため、DDL コマンドをレプリケートしたトランザクションにのみファンクションを使用できます。誤った origin_node_id または origin_topxid が指定された場合、ファンクションは永久にまたは statement_timeout が発生するまで待機する場合があります。

bdr.local_group_slot_name

ローカルノードのグループスロットの名前を返します。

例

```
bdrdb=# SELECT bdr.local_group_slot_name();
 local_group_slot_name
- ----------------------
 bdr_bdrdb_bdrgroup
```

bdr.node_group_type

指定されたノードグループのタイプを返します。戻り値は、ノードグループの作成時に bdr.create_node_group() に渡されたものと同じですが、グループの作成時に node_group_type が NULL として渡された場合、 normal が返されます。

例

```
bdrdb=# SELECT bdr.node_group_type(bdrgroup);
 node_group_type
- ----------------
 normal
```

bdr.alter_node_kind

PGD5 は、タスクマネージャーリーダーノードの概念を導入しました。ノードは PGD によって自動的に選択されますが、アップグレードされたクラスターの場合、クラスター内のすべてのノードに node_kind を適切に設定することが重要です。ユーザーは、最新の PGD バージョンにアップグレードした後、ノードごとに bdr.alter_node_kind() SQL ファンクションを呼び出すことにより、これを手動で行うことが予想されます。

概要

```
bdr.alter_node_kind(node_name text,
                    node_kind text);
```

パラメーター

- node_name —種類を変更するノードの名前。
- node_kind —ノードの種類。 data 、standby 、witness 、または subscriber-only のいずれかです。

bdr.alter_subscription_skip_changes_upto

論理レプリケーションはバージョンをまたがってレプリケートでき、ロールのようなグローバル変更をレプリケートせず、選択的にレプリケートできるため、論理レプリケーション適用プロセスでエラーが発生し、変更の適用を停止する場合があります。

可能な場合は、ターゲット側に変更を加えてこのような問題を修正します。CREATE レプリケーションをブロックしている欠落テーブル、CREATE 必要なロール、GRANT 必要な権限など。ただし、その方法では問題を修正できない場合があり、トランザクションを完全にスキップする必要がある場合があります。変更はトランザクション全体としてスキップされます、オール・オア・ナッシング。スキップする場所を決定す

るには、次の例のように、ログ出力を使用してコミット LSN を見つけるか、論理デコード機能を使用して変更ストリームをピークにします。

トランザクションが 1 つの変更のみを行った場合を除き、多くの場合、ターゲット側でトランザクションのエフェクトを手動で適用する必要があります。そのため、以下の例に示すように、可能な限り問題のあるトランザクションを保存することが重要です。

`pg_catalog.pg_logical_slot_get_binary_changes` を使用して目的の LSN にスキップすることにより、`bdr.alter_subscription_skip_changes_upto` なしで変更をスキップすることが可能であるため、これは便利なファンクションです。論理デコードにおけるある種のエラーをバイパスする場合がありますが、より速いスキップを行います。

この機能は、無効になっているサブスクリプションでのみ動作します。

通常の手順のシーケンスは次のとおりです。

1. 問題のあるサブスクリプションと問題のあるコミットの LSN を特定します。

1. サブスクリプションを無効にします。

    1. 可能であれば、ソースノードで `pg_catalog.pg_logical_slot_peek_changes` を使用してトランザクションのコピーを保存します。

1. ターゲットノード上の `bdr.alter_subscription_skip_changes_upto` 。

1. 必要に応じて、修復または同等の変更をターゲットに手動で適用します。

1. サブスクリプションを再度有効にします。

> **警告:** このファンクションを使用すると、問題を悪化させるのは簡単です。それが唯一のオプションであると確信できない限り、何もしないでください。

概要

```
bdr.alter_subscription_skip_changes_upto(
  subname text,
  skip_upto_and_including pg_lsn
);
```

例

トランザクションの適用はエラーで失敗し、ターゲット側の変更などのインパクトの低い修正ではこの問題を解決できないと判断しました。トランザクションをスキップする必要があると判断します。

エラーログで、次の例のように、スキップするコミットレコード LSN を見つけます。

```
ERROR:  XX000: CONFLICT: target_table_missing; resolver skip_if_recently_dropped␣
↪returned an error: table does not exist
```

(次のページに続く)

(前のページからの続き)

```
CONTEXT:  during apply of INSERT from remote relation public.break_me in xact with␣
↪commit-end lsn 0/300AC18 xid 131315
committs 2021-02-02 15:11:03.913792+01 (action #2) (effective sess origin id=2 lsn=0/
↪300AC18)
while consuming I message from receiver for subscription bdr_regression_bdrgroup_
↪node1_node2 (id=2667578509)
on node node2 (id=3367056606) from upstream node node1 (id=1148549230, reporiginid=2)
```

ログのこの部分には、必要な情報があります。the_target_lsn: **0/300AC18** the_subscription: **bdr_regression_bdrgroup_node1_node2**

次に、サブスクリプションを無効にして、適用ワーカーがレプリケーションスロットに接続しようとしないようにします。

```
SELECT bdr.alter_subscription_disable(the_subscription);
```

トランザクションの一部だけをスキップすることはできません。それはオール・オア・ナッシングです。したがって、サブスクリプションのスロット名を使用して、最初にプロバイダー側でコピーして、レコードを保存することを強くお勧めします。

```
\copy (SELECT * FROM pg_catalog.pg_logical_slot_peek_changes(the_slot_name,
    the_target_lsn, NULL, min_proto_version, 1, max_proto_version, 1,
    startup_params_format, 1, proto_format, json))
 TO transaction_to_drop.csv WITH (FORMAT csv);
```

この例は、読みやすいように複数行に分割されていますが、単一行で発行します。\copy は、複数行のコマンドをサポートしていません。

peek を get に変更することにより、変更をスキップできますが、bdr....skip_changes_upto は、すべてのデータのデコードと出力を回避する高速なスキップを行います。

```
SELECT bdr.alter_subscription_skip_changes_upto(subscription_name,
    the_target_lsn);
```

ダンプされたトランザクションの内容をガイドとして使用して、同じ変更またはその修復バージョンをターゲットノードに手動で適用できます。

最後に、サブスクリプションを再度有効にします。

```
SELECT bdr.alter_subscription_enable(the_subscription);
```

グローバルアドバイザリーロック

PGD は、グローバルアドバイザリーロックをサポートしています。これらのロックは、PGD でサポートされている勧告ロックがグローバルであることを除き、PostgreSQL で使用可能な勧告ロックと似ています。これらは DDL ロックと同様のセマンティクスに従います。したがって、アドバイザリロックはマジョリティコンセンサスによって取得され、すべてのノードの大部分が連携できる限り、1 つ以上のノードがダウンまたは遅延している場合でも使用できます。

現在、EXCLUSIVE ロックのみがサポートされています。したがって、別のノードまたは同じノード上の別のバックエンドがオブジェクトの勧告ロックを既に取得している場合、他のノードまたはバックエンドはロックが解放されるまで待機する必要があります。

アドバイザリーロックはトランザクション的な性質を持っています。したがって、トランザクションが終了する前に明示的に解放しない限り、トランザクションが終了するとロックは自動的に解放されます。この場合、リリースされるとすぐに利用可能になります。セッションレベルの勧告ロックは現在サポートされていません。

グローバル勧告ロックは再入可能です。したがって、同じリソースが 3 回ロックされている場合、他のセッションで使用できるように解放するには、3 回ロックを解除する必要があります。

bdr.global_advisory_lock

このファンクションは、提供されたオブジェクトの EXCLUSIVE ロックを取得します。ロックが利用できない場合、ロックが利用可能になるか、`bdr.global_lock_timeout` に到達するまで待機します。

概要

```
bdr.global_advisory_lock(key bigint)
```

パラメーター

- `key` —アドバイザリロックが取得されるオブジェクト。

概要

```
bdr.global_advisory_lock(key1 integer, key2 integer)
```

パラメーター

- key1 —複合キーの最初の部分。
- key2 —複合キーの 2 番目の部分。

bdr.global_advisory_unlock

このファンクションは、アプリケーション定義のソースで以前に取得したロックを解放します。ロックは、アプリケーションによって同じトランザクションで取得されている必要があります。それ以外の場合、エラーが発生します。

概要

```
bdr.global_advisory_unlock(key bigint)
```

パラメーター

- key —アドバイザリロックが取得されるオブジェクト。

概要

```
bdr.global_advisory_unlock(key1 integer, key2 integer)
```

パラメーター

- key1 —複合キーの最初の部分。
- key2 —複合キーの 2 番目の部分。

モニタリング機能

bdr.monitor_group_versions

クラスター全体のバージョンチェックを提供するために、このファンクションはビュー bdr.group_version_details から返された PGD バージョン情報を使用します。

概要

```
bdr.monitor_group_versions()
```

注

Monitoring で説明したように、このファンクションは、フィールド

`status` および `message` を持つレコードを結果ます。

このファンクションは `bdr.run_on_all_nodes()` を呼び出します。

bdr.monitor_group_raft

クラスター全体の Raft チェックを提供するために、このファンクションはビュー `bdr.group_raft_details` から返された PGD Raft 情報を使用します。

概要

```
bdr.monitor_group_raft()
```

パラメーター

- `node_group_name` —確認するノードグループ名。

注

Monitoring で説明しているように、このファンクションは、フィールド

`status` および `message` を持つレコードを結果ます。

このファンクションは `bdr.run_on_all_nodes()` を呼び出します。

bdr.monitor_local_replslots

このファンクションは、ビュー `pg_replication_slots` スロットアクティブまたは非アクティブから返されたレプリケーションスロットステータス情報を使用して、PGD グループスロットを除くすべてのレプリケーションスロットを考慮したローカルチェックを提供します。

概要

```
bdr.monitor_local_replslots()
```

注

レプリケーションスロットの監視 で説明しているように、このファンクションは、フィールド status および message を持つレコードを結果ます。

bdr.wal_sender_stats

Decoding worker が有効になっている場合、このファンクションは、デコーダースロットと、各 WAL 送信者によって読み取られている現在の LCR 論理変更レコードセグメントファイルに関する情報を表示します。

概要

```
bdr.wal_sender_stats()
```

出力列

- pid — WAL 送信者の PID pg_stat_replication の pid 列に対応します。
- is_using_lcr — WAL 送信者が LCR ファイルを送信しているかどうか。is_using_lcr が FALSE の場合、次の列は NULL です。
- decoder_slot_name —デコーダーレプリケーションスロットの名前。
- lcr_file_name —現在の LCR ファイルの名前。

bdr.get_decoding_worker_stat

Decoding worker が有効になっている場合、このファンクションは、現在のデータベースに関連付けられているデコードワーカーの状態に関する情報を表示します。これは、ワーカーの進行状況のデコードに関するより詳細な情報も提供します

pg_replication_slots を介して利用可能な情報。

概要

```
bdr.get_decoding_worker_stat()
```

出力列

- pid —デコードワーカーの PID pg_replication_slots の列 active_pid に対応します。
- decoded_upto_lsn —デコードワーカーがトランザクションログを読み取る LSN。
- waiting —デコードワーカーが新しい WAL を待機しているかどうか。
- waiting_for_lsn —次に予想される WAL の LSN。

注

詳細については、 *LCR を使用した WAL 送信者のモニタリング* を参照してください。

bdr.lag_control

遅延制御 が有効になっている場合、このファンクションは、ローカルノードと現在のデータベースの構成された遅延対策に適合するノードの数とコミット遅延に関する情報を表示します。

概要

```
bdr.lag_control()
```

出力列

- commit_delay —現在のランタイムコミット遅延ミリ秒単位。
- commit_delay_maximum —構成された最大コミット遅延ミリ秒単位。
- commit_delay_adjustment —サンプルインターバル中に発生する可能性のあるランタイムコミット遅延の変更ミリ秒単位。
- conforming_nodes —遅延対策に適合しているノードの現在の実行時数。
- conforming_nodes_minimum —遅延対策に適合するために必要なノードの構成済みの最小数。これを下回ると、コミット遅延調整が適用されます。
- lag_bytes_threshold —コミット遅延が適用される遅延サイズキロバイト単位。
- lag_bytes_maximum —キロバイト単位の構成された最大遅延サイズ。
- lag_time_threshold —ミリ秒単位のコミット遅延が適用される遅延時間。

- lag_time_maximum —設定された最大遅延時間ミリ秒単位。
- sample_interval —ミリ秒単位の遅延サンプル間の構成された最小時間と考えられるコミット遅延調整。

9.1.3 PGD settings

PGD 固有の構成設定を設定することもできます。特に断りのない限り、値はいつでも設定できます。

競合処理

bdr.default_conflict_detection

新しく作成されるテーブルのデフォルトの競合検出方法を設定します。

bdr.alter_table_conflict_detection() と同じ値を受け入れます。

グローバルシーケンスパラメーター

bdr.default_sequence_kind

デフォルトの *sequence kind* を設定します。

デフォルト値は distributed で、これは、 snowflakeid が int8 シーケンスつまり bigserial に使用され、int4 つまり serial および int2 シーケンスの galloc シーケンスに使用されることを意味します。

DDL 処理

bdr.default_replica_identity

新しく作成されるテーブルに REPLICA IDENTITY のデフォルト値を設定します。 REPLICA IDENTITY は、更新または削除された行を識別するためにログ先行書き込みに書き込まれる情報を定義します。

受け入れられる値は次のとおりです。

- default —主キーの列の古い値がある場合は、それを記録しますこれはデフォルトの PostgreSQL 動作です。
- full —行内のすべての列の古い値を記録します。
- nothing —古い行に関する情報は記録しません。
- auto — PK を使用するテーブルは REPLICA IDENTITY DEFAULT で作成され、PK のないテーブルは REPLICA IDENTITY FULL で作成されます。これはデフォルトの PGD 動作です。

詳細は、 *PostgreSQL documentation* を参照してください。

PGD は、 PRIMARY KEY または UNIQUE 制約のないテーブルで UPDATE および DELETE オペレーションをレプリケートできません。例外は、テーブルのレプリカ ID がテーブル固有の構成または bdr.default_replica_identity による FULL の場合です。

bdr.default_replica_identity が default で、テーブルに UNIQUE 制約がある場合、それは REPLICA IDENTITY として自動的に選択されません。上記のように、テーブルの作成時または後に明示的に設定する必要があります。

テーブルのレプリカ ID を full に設定すると、テーブルのワイヤに書き込まれる WAL の量とレプリケートされるデータの量が増加します。

bdr.ddl_replication

ノード全体で DDL を自動的にレプリケートしますデフォルトは on です。

このパラメーターは、bdr_superuser または superuser ロールによってのみ設定できます。

DDL を実行するか、 bdr.ddl_replication = off を使用して PGD 管理機能を呼び出すと、管理者が介入できるまでレプリケーションが停止する状況が発生する場合があります。詳細は、

> *DML and DDL replication and nonreplication* を参照してください。

bdr.ddl_replication が off に設定されている場合は常に、 LOG レベルのログメッセージが PostgreSQL サーバーログに出力されます。さらに、キャプチャされた DDL コマンドまたは PGD レプリケーションファンクションのレプリケーションがこの設定によりスキップされるたびに、WARNING-level メッセージが書き込まれます。

bdr.role_replication

ノード全体で ROLE コマンドを自動的にレプリケートしますデフォルトは on です。スーパーユーザーのみがこのパラメーターを設定できます。この設定は、bdr.ddl_replication もオンになっている場合にのみ機能します。

すべてのノードでロールが同期していることを確認する外部方法を使用せずにこれをオフにすると、管理者が介入するまでレプリケート DDL がレプリケーションを中断する場合があります。

> ロール操作ステートメント を参照

詳細については。

bdr.ddl_locking

DDL のグローバルロックの操作モードを構成します。

このパラメーターは、bdr_superuser または superuser ロールによってのみ設定できます。

考えられるオプションは次のとおりです。

- オフ — DDL 操作にはグローバルロックを使用しないでください。
- on —すべての DDL 操作にグローバルロックを使用します。
- dml —リレーションのグローバル DML ロックを取得することにより書き込みを防止する必要がある DDL 操作にのみグローバルロックを使用します。

bdr.ddl_replication が off に設定されている場合は常に、 LOG レベルのログメッセージが PostgreSQL サーバーログに出力されます。さらに、この設定によりグローバルロックステップがスキップされるたびに、WARNING メッセージが書き込まれます。一部のステートメントでは、2 つの WARNING メッセージが発生するのが通常です。1 つは DML ロックをスキップし、もう 1 つは DDL ロックをスキップします。

グローバルロック も参照

bdr.truncate_locking

この構成オプションは、 TRUNCATE コマンドのロック動作を設定します。TRUNCATE が true の場合、bdr.ddl_locking 設定に従うかどうかを決定します。デフォルトでは false に設定されます。

グローバルロック

DDL ロックは、
bdr.ddl_locking によって制御されます。他のグローバルロック設定には次のものが含まれます。

bdr.global_lock_max_locks

ノードで保持できるグローバルロックの最大数を設定しますデフォルト 1000。Postgres サーバー起動時にのみ設定できます。

bdr.global_lock_timeout

グローバルロックの待機の最大許可時間を設定しますデフォルト 10 分。値 0 はこのタイムアウトを無効にします。

bdr.global_lock_statement_timeout

グローバルロックを保持するステートメントの最大許可期間デフォルト 60 分を設定します。値 0 はこのタイムアウトを無効にします。

bdr.global_lock_idle_timeout

グローバルロックを保持するトランザクションのアイドル時間の最大許可期間を設定しますデフォルト 10 分。値 0 はこのタイムアウトを無効にします。

bdr.predictive_checks

予測チェックのログレベルを設定します現在グローバルロックによってのみ使用されます。DEBUG、LOG、WARNING デフォルト、または ERROR です。予測チェックは、特定の操作を実行するときに予想されるクラスター状態の早期検証です。タイムアウトを待機するのではなく、早期フェイルのこれらの操作に使用できます。グローバルロック用語では、PGD は、接続されている十分なノードがあり、グローバルロックに必要なクォーラムを取得するための妥当な遅延制限内であることをチェックします。

ノード管理

bdr.replay_progress_frequency

レプリケーション位置情報をクラスターの残りの部分に送信する間隔を設定しますデフォルト 1 分

bdr.standby_slot_names

他のスロットよりも前にレプリケーションの変更を受信して確認するために必要なスロットを設定します。この設定は、主にフェールオーバーにフィジカルスタンバイを使用する場合、またはサブスクライブ専用ノードを使用する場合に役立ちます。

汎用レプリケーション

bdr.writers_per_subscription

サブスクリプションごとのライターのデフォルト数を設定します PGD では、グループの bdr.alter_node_group_config を使用してこれを変更することもできます。

bdr.max_writers_per_subscription

サブスクリプションごとのライターの最大数上記の設定の上限を設定します。

bdr.xact_replication

現在のトランザクションをレプリケートしますデフォルトは on です。

これをオフにすると、トランザクション全体がローカルのみになります。つまり、トランザクションは、PGD による論理デコードおよび論理デコードのその他のすべてのダウンストリームターゲットから可視されません。データは、ロジカルスタンバイノードを含む他のノードに転送されません。

このパラメーターは、bdr_superuser または superuser ロールによってのみ設定できます。

このパラメーターは、 `bdr.permit_unsafe_commands = on` を除き `SET LOCAL` コマンドを使用して現在のトランザクション内でのみ設定できます。

注釈: トランザクションレプリケーションを無効にしても WAL は生成されますが、これらの変更はオリジンでフィルタリングされます。

警告: *bdr.xact_replication* をオフにすると、ノード間でデータの不一貫性が発生します。ノード間のデータの相違からリカバリーするため、またはレプリケーションを続行するために単一ノードの変更が必要なレプリケーション状況にのみ使用します。自分の責任で使用してください。

bdr.permit_unsafe_commands

一般的な使用にとって安全でないと考えられるコマンドの安全性チェックをオーバーライドするオプション。

bdr_superuser または PostgreSQL スーパーユーザーが必要です。

警告: 通常安全だと考えられていないコマンドは、一貫性のない結果を生成するか、レプリケーションを完全に中断する可能性があります。自分の責任で使用してください。

bdr.batch_inserts

単一のトランザクションでの 1 つのテーブルへの連続した挿入の数により、そのテーブルの挿入のバッチ処理がオンになります。

この設定では、大規模なデータのレプリケーションを、挿入のセットではなく COPY として内部的にロードできます。これは、ノード参加中の初期データのコピー方法でもあります。

bdr.maximum_lock_skew

この設定は、bdr.maximum_clock_skew_action をトリガーする前に、受信トランザクションコミットタイムスタンプとサブスクライバーの現在時間の最大差を指定します。

現在再生されているトランザクションのタイムスタンプが、サブスクライバーの現在時刻と比較して将来的であるかどうかを確認します。その場合、その差が bdr.maximum_clock_skew より大きい場合、bdr.maximum_clock_skew_action 設定で指定されたアクションを実行します。

デフォルトは-1 で、これはクロックスキューを無視するチェックがオフになることを意味します。すべてのサーバーの時計が同期している場合、0 を設定するのが有効です。トランザクションを再生しているという事実は、過去にコミットされたことを意味します。

bdr.maximum_lock_skew_action

この設定は、bdr.maximum_clock_skew より高いクロックスキューが検出された場合に実行するアクションを指定します。

この設定には 2 つの値があります。

- WARN —このファクトに関する警告をログに記録します。警告は、サーバーログの氾濫を防ぐために、最大で 1 分に 1 回デフォルトでログに記録されます。
- WAIT —現在のローカルタイムスタンプがリモートコミットタイムスタンプから bdr.maximum_clock_skew を引いたものより古くなくなるまで待機します。

bdr.accept_connections

この設定は、 PGD への接続を有効または無効にします。デフォルト on

bdr_superuser または PostgreSQL スーパーユーザーが必要です。

bdr.standby_slot_names

この設定は通常、フェールオーバー構成で使用され、この PGD ノードのフェールオーバー候補ストリーミング物理レプリカが、サブスクライバーに可視される前にすべての変更を受信およびフラッシュしていることを保証します。これにより、プロバイダーのスタンバイへのフェールオーバー時にコミットが消えないことが保証されます。

コンマ区切りの bdr.standby_slot_names リストに名前がリストされているレプリケーションスロットは、PGD ノードの walsender によって特別に扱われます。

PGD の論理レプリケーション walsender は、ノードがこれらの変更を他の PGD レプリケーションクライアントに送信する前に、すべてのローカル変更が bdr.standby_slot_names のレプリケーションスロットに送信およびフラッシュされるようにします。事実上、スロットの名前付けリストと他のすべてのレプリケーションクライアントの間に同期レプリケーションバリアを提供します。

bdr.standby_slot_names には、任意のレプリケーションスロットをリストできます。論理スロットと物理スロットの両方が機能しますが、通常は物理スロットに使用されます。

この安全対策がないと、サブスクライバーがコミットを受信し、フェールオーバー候補がまだそれを受け取っていないため、フェールオーバー時にプロバイダーから消える 2 つの異常が発生する可能性があります。

- 1+加入者の場合、加入者は変更を適用した可能性がありますが、新しいプロバイダーは、プロバイダーに関する限り決して起こらなかったため、受け取った変更と競合する新しいトランザクションを実行する可能性があります。
- 2 つ以上のサブスクライバーの場合、フェールオーバー時に、すべてのサブスクライバーが変更を適用しているわけではありません。コミットを受け取らなかったサブスクライバーにはそれを取得する方法がないため、サブスクライバーは一貫性のない調整不能な状態になります。

デザインによって `bdr.standby_slot_names` を設定すると、リストされたノードの必要な数が追いついていない場合、そこにリストされていない他のサブスクライバがプロバイダーに遅れをとります。したがって、モニタリングは重要です。

`bdr.standby_slot_names` が役立つもう 1 つのユースケースは、サブスクライバー専用ノードを使用して、通常の PGD ノードより先に移動しないことを確認する場合です。これは、`bdr.standby_slots_min_confirmed` を少なくとも 1 つに設定することと、すべての通常の PGD ピアノードの論理スロットをリストすることにより、最適に達成できます。

bdr.standby_slots_min_confirmed

この設定は、PGD サブスクライバーにデータを送信する前に確認する必要がある `bdr.standby_slot_names` の数を制御します。

bdr.writer_input_queue_size

この設定は、受信者が書き込みライタプロセスにデータを送信するために使用する共有メモリキューのサイズを指定します。ライタプロセスが停止しているか、進行が遅い場合、キューがいっぱいになり、受信側プロセスも停止する可能性があります。したがって、このキューに十分な共有メモリを提供することが重要です。デフォルトは 1MB で、最大許可サイズは 1GB です。GUC の設定には任意のストレージサイズ指定子を使用できますが、デフォルトは KB です。

bdr.writer_output_queue_size

この設定は、レシーバーが書き込みライタプロセスからデータを受信するために使用する共有メモリキューのサイズを指定します。ライタは大量のデータを送信することは想定されていないため、比較的小さいサイズのキューで十分です。デフォルトは 32KB で、最大許可サイズは 1MB です。GUC の設定には任意のストレージサイズ指定子を使用できますが、デフォルトは KB です。

bdr.min_worker_backoff_migrate

この設定では、特定のワーカーが bdr.min_worker_backoff_delay ミリ秒ごとよりも頻繁に再起動されないようにすることにより、PGD バックグラウンドワーカー起動のレート制限が可能になります。エラーが繰り返されると、バックオフは指数関数的に増加し、最大 bdr.max_worker_backoff_delay までジッターが追加されます。

時間単位のサフィックスがサポートされています。

注釈: この設定は現在レシーバーワーカーにのみ影響します。つまり、主にエラーまたは接続障害が発生したときにサブスクリプションが再接続を試行する速さに影響を与えます。

---

bdr.min_worker_backoff_delay のデフォルトは 1 秒です。bdr.max_worker_backoff_delay の場合、1 分です。

バックオフ遅延設定が変更され、PostgreSQL 構成がリロードされると、現在のすべてのバックオフがリセットを待機します。さらに、bdr.worker_task_reset_backoff_all() ファンクションは、管理者がすべてのバックオフインターバルを強制的にすぐに有効期限が切れるように提供されています。

共有メモリ内の追跡テーブルは、各種類のワーカーの最終起動時刻を記憶するために維持されます。この追跡テーブルは永続的ではありません。これは、汚れたバックエンド終了後のクラッシュリカバリー中のソフトリスタートを含む、PostgreSQL の再起動によってクリアされます。

ビュー

bdr.worker_tasks を使用してこの状態を検査できるため、管理者は、現在有効になっているバックオフレート制限を確認できます。

レート制限の目的で、ワーカーはタスクごとに分類されます。このキーは、ワーカーロール、データベース OID、サブスクリプション ID、サブスクリプションライタ ID、拡張ライブラリ名とファンクション名、拡張機能提供のワーカー名、および同期ライターのリモートリレーション ID で構成されています。NULL は、特定の分類子が適用されない場合に使用されます。たとえば、マネージャーワーカーにはサブスクリプション ID がなく、レシーバーにはライタ ID がありません。

CRDT

bdr.crdt_raw_value

CRDT データ型を使用した列の競合の処理 の出力フォーマットを設定します。

デフォルト出力この設定が off の場合、ベース CRDT タイプたとえば、crdt_pncounter の bigint の現在値のみを結果ます。 on に設定されている場合、戻り値は CRDT 値の完全な表現を表します。これには、たとえば、マルチプルのノードからの状態を含めることができます。

コミットスコープ

bdr.commit_scope

現在またはデフォルトの コミットスコープ を設定しますデフォルトは空の文字列です。

Commit At Most Once

bdr.camo_local_mode_deploy

CAMO の非同期モードで適用され、トランザクションを確認する必要がある CAMO パートナーで通常発生するオーバーヘッドをエミュレートするコミット遅延。デフォルト 5 ミリ秒。この機能を無効にするには、`0` に設定します。 -

bdr.camo_enable_client_warnings

CAMO プロパティを保証できないデータベースでアクティビティが実行された場合、警告を発します。これはデフォルトで有効になっています。十分な情報のあるユーザーは、これを無効にして、ログに記録される警告の量を減らすことができます。

トランザクションストリーミング

bdr.default_streaming_mode

サブスクライバノードによるトランザクションストリーミングを制御するために使用されます。許可される値は `off` 、 `writer` 、 `file` 、および `auto` です。デフォルト `auto` 。 `off` に設定されている場合、サブスクライバーはトランザクションストリーミングを要求しません。他の値に設定されている場合、サブスクライバーはトランザクションストリーミングを要求し、パブリッシャーはそれをサポートしている場合、およびグループレベルで構成されている場合にそれを提供します。詳細については、

> *Transaction streaming* を参照してください。

遅延制御

bdr.lag_control_max_commit_deploy

ミリ秒単位での許容できる最大許容コミット後遅延。

bdr.lag_control_max_lag_size

許容できる最大許容遅延サイズキロバイト単位。

bdr.lag_control_max_lag_time

ミリ秒単位の許容できる最大許容遅延時間。

bdr.lag_control_min_conforming_nodes

許容可能な遅延測定値を下回るように必要なノードの最小数。

bdr.lag_control_commit_deploy_adjust

最大コミット遅延時間の一部として測定されるコミット遅延のマイクロ調整。デフォルト値の 0.01%では、最大コミット遅延に到達するまでに 100 ネットインクリメントが必要です。

bdr.lag_control_sample_interval

ミリ秒単位の遅延サンプルとコミット遅延マイクロ調整間の最小時間。

bdr.lag_control_commit_deploy_start

コミット遅延インクリメントが適用され始める遅延しきい値。許容可能な遅延尺度の割合で表されます。デフォルト値の 1.0%では、許容可能な遅延測定値に違反するまでコミット遅延のインクリメントは開始されません。

より小さい分数を設定することにより、許容可能な遅延尺度に漸近するように早期に「遅延曲線を曲げる」ことにより、違反を防止できる場合があります。

タイムスタンプベースのスナップショット

bdr.timestamp_snapshot_keep

タイムスタンプベースのスナップショット使用の有効なスナップショットを保持する時間デフォルトは `0`、過去のスナップショットを保持しないことを意味します。

モニタリングとロギング

bdr.debug_level

PGD がデバッグメッセージを書き込むために使用するログレベルを定義します。デフォルト値は debug2 です。詳細な PGD デバッグ出力を表示する場合は、`bdr.debug_level = 'log'` を設定します。

bdr.trace_level

上記と同様に、これは PGD トレースメッセージに使用するログレベルを定義します。EDB Postgres 分散クラスターのすべてのノードでトレースを有効にすると、EDB サポートが問題を診断するのに役立つ場合があります。これは、Postgres サーバーの起動時にのみ設定できます。

警告: *bdr.debug_level* または `bdr.trace_level` を値>= *log_min_messages* に設定すると、非常に大量のログ出力が生成される可能性があるため、ディスク領域の枯渇を防ぐためのログフィルタリング、アーカイブ、およびローテーションの計画が整っていない限り、運用環境で長期的に有効にしないでください。 !!!

bdr.track_subscription_apply

各サブスクリプションの適用統計を追跡します。

bdr.track_relation_apply

各リレーションの適用統計を追跡します。

bdr.track_apply_lock_timing

リレーションの統計を追跡するときにロックタイミングを追跡します。

デコードワーカー

bdr.enable_wal_decoder

> *Decoding worker* を使用して単一ノードで論理変更レコード LCR 送信を有効にします。デフォルトでは、この設定は false です。

true に設定すると、デコードワーカープロセスが開始され、WAL 送信側は生成した LCR を送信します。false に設定し直すと、LCR を使用する WAL 送信者が再起動され、WAL を直接使用します。

注釈: PGD グループ内のすべてのノードでこの設定を有効にし、グループで `enable_wal_decoder` オプションを true に設定する必要があります。 !!!

bdr.receive_lcr

別のノードをサブスクライブする場合、この設定により、ノードはサブスクリプションの論理変更レコード LCR の使用を要求できます。デフォルトでは、この設定は false です。下流ノードでこの設定が true の場合、ノードは上流ノードに送信するときに LCR を使用することを要求します。ノードで `bdr.enable_wal_decoder` を true に設定する場合、この設定も `true` に設定します。

注釈: PGD グループ内のすべてのノードでこの設定を有効にし、グループで `enable_wal_decoder` オプションを true に設定する必要があります。 !!!

bdr.lcr_cleanup_interval

論理変更レコード LCR ファイルのクリーンアップ間隔。

Decoding worker が有効になっている場合、デコードワーカーは LCR ファイルをバッファとして保存します。これらのファイルは定期的にクリーンアップされ、この設定は 2 つの連続するクリーンアップ間の間隔を制御します。デフォルトは 3 分です。ゼロに設定すると、クリーンアップが無効になります。

接続設定

以下は、すべてのクロスノード `libpq` 接続に影響を与える接続設定のセットです。デフォルトはかなり保守的な値に設定されており、ほとんどの運用ニーズをカバーします。すべての変数には `SIGHUP` コンテキストがあります。これは、リロード時に変更が適用されることを意味します。

bdr.global_connection_timeout

接続中に待機する最大時間秒単位。10 進の整数、たとえば、10 として書き込みます。ゼロ、負の数、または指定なしは、無期限に待機することを意味します。最小許可タイムアウトは 2 秒であるため、値 1 は次のように解釈されます。

2.

デフォルトは 15 秒です。

bdr.global_keepalives

TCP キープアライブを使用するかどうかを制御します。デフォルト値は 1、オンを意味します。キープアライブが不要な場合は、これを 0、つまりオフに変更できます。このパラメーターは、Unix ドメインソケットによって作成された接続では無視されます。

デフォルトは 1 オンです。

bdr.global_keepalives_idle

TCP がキープアライブメッセージをサーバーに送信するまでの非アクティブな秒数を制御します。値 0 は、システムのデフォルトを使用します。このパラメータは、Unix ドメインソケットによって作成された接続、またはキープアライブが無効になっている場合に無視されます。TCP_KEEPIDLE または同等のソケットオプションが使用可能なシステムでのみサポートされています。他のシステムでは、効果はありません。

デフォルトは 1 秒です。

bdr.global_keepalives_interval

サーバーによって確認されなかった TCP キープアライブメッセージを再送信する秒数を制御します。値 0 は、システムのデフォルトを使用します。このパラメータは、Unix ドメインソケットによって作成された接続、またはキープアライブが無効になっている場合に無視されます。TCP_KEEPINTVL または同等のソケットオプションが使用可能なシステムでのみサポートされています。他のシステムでは、効果はありません。

デフォルトは 2 秒です。

bdr.global_keepalives_count

サーバーへのクライアントの接続がデッドと見なされる前に、失われる可能性のある TCP キープアライブの数を制御します。値 0 は、システムのデフォルトを使用します。このパラメータは、Unix ドメインソケットによって作成された接続、またはキープアライブが無効になっている場合に無視されます。TCP_KEEPCNT または同等のソケットオプションが使用可能なシステムでのみサポートされています。他のシステムでは、効果はありません。

デフォルトは 3 です。

bdr.global_tcp_user_timeout

接続が強制的に閉じられるまでに、送信されたデータが未確認のままでいられるミリ秒数を制御します。値 0 は、システムのデフォルトを使用します。このパラメーターは、Unix ドメインソケットによって作成された接続では無視されます。TCP_USER_TIMEOUT が利用可能なシステムでのみサポートされています。他のシステムでは、効果はありません。

デフォルトは 5 秒ミリ秒 5000 で表されます。

内部設定-Raft タイムアウト ### bdr.raft_global_election_timeout

ネットワーク障害を説明するために、Raft コンセンサスプロトコルは選択と要求のタイムアウトを実装します。この値は、要求がグローバルトップレベルグループに送信されるときに使用されます。デフォルトでは 6 秒 6s です。

bdr.raft_local_election_timeout

ネットワーク障害を説明するために、Raft コンセンサスプロトコルは選択と要求のタイムアウトを実装します。この値は、要求がサブグループに送信されるときに使用されます。デフォルトでは 3 秒 3s です。

bdr.raft_response_timeout

レスポンスの場合、 内部設定-Raft タイムアウト bdr.raft_global_election_timeout および *bdr.raft_local_election_timeout* の設定が必要に応じて使用されます。この動作は、この変数を設定することによりオーバーライドできます。`bdr.raft_response_timeout` の設定は、いずれの選択タイムアウト値よりも小さい必要があります。この変数を-1 に設定すると、オーバーライドが無効になります。デフォルト-1 です。

内部設定 - その他の Raft 値

bdr.raft_keep_min_entries

ログ圧縮を行うときに Raft ログに保持するエントリの最小数デフォルト 100。値 0 はログ圧縮を無効にします。これは、Postgres サーバーの起動時にのみ設定できます。

> **警告:** ログ圧縮が無効になっている場合、ログのサイズは永久に増加します。 !!!

bdr.raft_log_min_apply_duration

ステートマシンを前進させるために、Raft は内部ログにエントリを追加します。通常オペレーションでは、追加には数ミリ秒しかかかりません。これにより、その追加アクションの期間に上限しきい値が設定され、それを超えると `INFO` メッセージがログに記録されます。これは問題を示している可能性があります。このパラメーターのデフォルト値は 3000 ミリ秒です。

bdr.raft_log_min_message_duration

コンセンサス要求をログに記録する場合。bdr コンセンサス要求の往復時間を測定し、時間がこのパラメーターを超えた場合は `INFO` メッセージをログに記録します。このパラメーターのデフォルト値は 5000 ミリ秒です。

bdr.raft_group_max_connections

Postgres サーバーのすべての PGD グループの最大接続数。これらの接続は、グループのノード間で bdr コンセンサス要求を伝送します。このパラメーターのデフォルト値は 100 接続です。Postgres サーバー起動時にのみ設定できます。

内部設定 - その他の値

bdr.backwards_compatibility

`bdr.bdr_version_num` 、`30618` などで使用されるのと同じ数値形式で、下位互換性のあるバージョンを指定します。一般に不要な効果がある場合でも、以前の PGD バージョンの正確な動作を有効にします。現在の PGD バージョンのデフォルト。これはリリースごとに異なるため、値が現在のバージョンと異なる場合を除き、構成ファイルで明示的に使用しないことをお勧めします。

bdr.track_replication_estimates

ピアノードの適用レートとキャッチアップ間隔の観点から、レプリケーション推定を追跡します。CAMO のようなプロトコルは、この情報を使用して、ピアノードの準備状況を推定できます。このパラメーターはデフォルトで有効になっています。

bdr.lag_tracker_apply_rate_weight

ローカルノードから WAL を適用するという点でピアノードがどれだけ遅れているかを監視し、遅延追跡の適用レートの移動平均を計算します。このパラメーターは、この移動平均計算で新しい計算値がどの程度寄与するかを指定します。デフォルト値は 0.1 です。

9.1.4 Node management

ノードの状態のリスト

- `NONE` ワーカーの起動時にノードの状態は設定解除され、現在の既知の状態にすぐに設定されることが予想されます。
- `CREATED` `bdr.create_node()` が実行されましたが、ノードはまだ EDB Postgres 分散クラスターのメンバーではありません。

- JOIN_START bdr.join_node_group() は、ローカルノードを既存の EDB Postgres 分散クラスターへの参加を開始します。
- JOINING ノード参加が開始され、現在初期同期フェーズにあり、ノードにスキーマとデータを作成しています。
- CATCHUP 初期同期フェーズが完了しました。現在、結合は、結合が開始されてから上流のピアノードで実行されたトランザクションを取得および適用する最後のステップにあります。
- STANDBY ノードへの参加は完了しましたが、変更のブロードキャストはまだ開始されていません。すべての結合はこの状態でしばらく時間を費やしますが、ロジカルスタンバイとして定義されている場合、ノードはこの状態を継続します。
- PROMOTE ノードはロジカルスタンバイであり、bdr.promote_node を呼び出してノード状態を ACTIVE に移動したところです。これらの 2 つの PROMOTE 状態は、1 つのノードのみが STANDBY より高いが ACTIVE より低い状態になることができるという事実と一貫している必要があります。
- PROMOTING ロジカルスタンバイからフル PGD ノードへの昇格が進行中です。
- ACTIVE ノードは完全な PGD ノードであり、現在 ACTIVE です。これは、最も一般的なノードのステータスです。
- PART_START ノードは ACTIVE または STANDBY であり、bdr.part_node を呼び出して EDB Postgres 分散クラスターからノードを削除しました。
- PARTING ノードは他のノードから切断し、コンセンサスまたはレプリケーションでそれ以上の役割を果たしません。
- PART_CATCHUP 非分割ノードは、最近分割されたノードからの欠落データを同期します。
- PARTED すべてのノードでノード分割操作が完了しました。

一度に 1 つのノードのみが PROMOTE または PROMOTING の状態になります。

ノード管理コマンド

PGD は、既存のノードの物理コピー pg_basebackup を使用して PGD グループにノードを追加し、既存のノードのフィジカルスタンバイを PGD グループ内の新しいノードに変換するためのコマンドラインユーティリティも提供します。

bdr_init_physical

これは、PostgreSQL の bin ディレクトリに追加される通常のコマンドです。

データディレクトリを指定する必要があります。このデータディレクトリが空の場合は、pg_basebackup -X stream を使用して、高速なブロックレベルのコピー操作を使用してディレクトリを埋めます。

指定されたデータディレクトリが空でない場合、これは新しいノードのベースとして使用されます。データディレクトリがフィジカルスタンバイノードとして既にアクティブである場合、Postgres を管理する bdr_init_physical を実行する前にスタンバイを停止する必要があります。最初にキャッチアップを待機し、PGD グループに参加する前にマスターノードに昇格します。--standby オプションを使用する場合、

既存のフィジカルスタンバイをロジカルスタンバイノードに変更します。これは、指定されたデータディレクトリの開始状態ではなく、新しい PGD ノードの終了状態を参照します。

このコマンドは、すべての PostgreSQL ネイティブ論理レプリケーションサブスクリプションをデータベースから削除または-S オプションを使用する場合を無効にします。また、レプリケーションオリジンとスロットも削除します。

概要

```
bdr_init_physical [OPTION] ...
```

オプション

一般オプション

- -D, --pgdata=DIRECTORY —新しいノードに使用するデータディレクトリ。空または存在しないディレクトリ、または pg_basebackup -X stream コマンド必須を使用して設定されたディレクトリのいずれかです。
- -l, --log-file=FILE — ロギングには FILE を使用します。デフォルトは bdr_init_physical_postgres.log です。
- -n, --node-name=NAME —新しく作成したノードの名前必須。
- --replication-sets=SETS —使用するレプリケーションセット名のコンマ区切りリストの名前。指定しない場合、すべてのレプリケーションセットが使用されます。
- --standby —完全な送信/受信ノードではなく、ロジカルスタンバイ受信専用ノードを作成します。
- --node-group-name —参加するグループ。デフォルトはソースノードと同じグループです。
- -s, --stop —初期化が完了したら、サーバーを停止します。
- -v —ロギングの詳細度を高めます。
- -L —空のまたは存在しないデータディレクトリ-D オプションで使用される場合、選択的な pg_basebackup を実行します。これは EDB Postgres Extended Server のみの機能です。
- -S —論理レプリケーションサブスクリプションをドロップする代わりに、無効にします。

接続オプション

- -d, --remote-dsn=CONNSTR —リモートノードの接続文字列必須。
- --local-dsn=CONNSTR —ローカルノードの接続文字列必須。

構成ファイルのオーバーライド

- `--hba-conf` —新しい `pg_hba.conf` へのパス。
- `--postgresql-conf` —新しい `postgresql.conf` へのパス。
- `--postgresql-auto-conf` —新しい `postgresql.auto.conf` へのパス。

注

コマンドで指定されたレプリケーションセット名は、ノードが PGD グループに参加する前にデータディレクトリに存在するデータに影響を与えません。これは、`bdr_init_physical` が独自のベースバックアップを作成するか、既存のベースバックアップが新しい PGD ノードに昇格するかにかかわらず当てはまります。したがって、`--replication-sets` オプションは、ノードが PGD ノードグループに参加した後にパブリッシュおよびサブスクライブされたデータにのみ影響します。この動作は、`bdr.join_node_group()` を使用する場合など、論理結合でレプリケーションセットを使用する方法とは異なります。

オペレーターは、結合が完了した後、不要なテーブルを切り詰めることができます。`bdr.tables` カタログを参照して、レプリケーションセットのメンバーシップを判断し、サブスクライブされたレプリケーションセットのメンバーではないテーブルを特定します。次の理由から、テーブルを削除するのではなく、切り詰めることを強くお勧めします。

- DDL レプリケーションセットは行 DML レプリケーションセットと同じではないため、誤って他のノードでテーブルをドロップする可能性があります。
- 後でテーブルをレプリケーションセットに追加し、ノードの一部のサブセットにドロップした場合、レプリケーションセットに追加する前に、DDL 競合を作成せずにこれらのノードでのみ再作成する必要があります。

非レプリケートテーブルを切り捨て、存在するが空のままにする方が簡単かつ安全です。

9.1.5 Node management interfaces

SQL インターフェイスを使用して、ノードを動的に追加および削除できます。

bdr.create_node

このファンクションはノードを作成します。

概要

```
bdr.create_node(node_name text, local_dsn text)
```

パラメーター

- node_name —新しいノードの名前。データベースごとに 1 つのノードのみが許可されます。有効なノード名は、小文字、数字、ハイフン、アンダースコアで構成されます。
- local_dsn —ノードへの接続文字列。

注

このファンクションは、関連するパブリック接続文字列を使用してローカルノードのレコードを作成します。ローカルレコードは 1 つだけであるため、作成されると、ファンクションは再度実行されるとエラーを報告します。

このファンクションはトランザクションファンクションです。ロールバックできます。これによる変更は、現在のトランザクションに表示されます。

ファンクションは、トランザクションが終了するまで、新しく作成された bdr ノードのロックを保持します。

bdr.drop_node

ノードをドロップします。

> **警告:** このファンクションは、通常の使用を目的としたものではありません。テクニカルサポートから指示された場合にのみ実行してください。

このファンクションは、特定のノードのメタデータをローカルデータベースから削除します。ノードは次のいずれかです。

- ローカルノード。この場合、リモートノードに関する情報を含むすべてのノードのメタデータが削除されます。
- リモートノード。その場合、その特定のノードのメタデータのみが削除されます。

概要

```
bdr.drop_node(node_name text, cascade boolean DEFAULT false, force boolean DEFAULT␣
↪false)
```

パラメーター

- node_name —既存のノードの名前。
- cascade —非推奨。将来的に削除される予定です。
- force —不一致を引き起こす可能性のある危険にもかかわらず、すべてのサニティチェックを回避し、指定された PGD ノードのすべてのメタデータの削除を強制します。テクニカルサポートのみが、分離に関連する緊急の場合に強制ノードドロップを使用します。

注

これを実行する前に、bdr.part_node() を使用してノードを分割します。

このファンクションは、特定のノードのメタデータをローカルデータベースから削除します。ノードはローカルノードになることができ、その場合、リモートノードに関する情報を含むすべてのノードのメタデータが削除されます。または、リモートノードの場合、その特定のノードのメタデータのみが削除されます。

注釈: 各ノードには、スノーフレーク ID および timeshard シーケンスで使用する一意のシーケンス番号が割り当てられているため、一度に最大 1024 のノードレコード ACTIVE と PARTED の両方を持つことができます。 PARTED ノードは自動的にクリーンアップされません。これが問題になる場合は、この機能を使用してこれらのレコードを削除できます。

---

bdr.create_node_group

このファンクションは、グループの唯一のメンバーとしてローカルノードを使用して PGD グループを作成します。

概要

```
bdr.create_node_group(node_group_name text,
                      parent_group_name text DEFAULT NULL,
                      join_node_group boolean DEFAULT true,
                      node_group_type text DEFAULT NULL)
```

パラメーター

- node_group_name —新しい PGD グループの名前。ノード名と同様に、有効なグループ名は小文字、数字、アンダースコアのみで構成されている必要があります。
- parent_group_name —サブグループの親グループの名前。
- join_node_group —このパラメーターは、ノードが作成するグループに参加するかどうかを決定するのに役立ちます。デフォルト値は true です。これは、ノードが参加したくないシャードグループを作成する場合に使用されます。parent_group_name を指定した場合にのみ false になります。
- node_group_type —有効な値は NULL 、subscriber-only 、datanode 、read coordinator 、および write coordinator です。 subscriber-only タイプは、クラスター内の完全に参加したノードから変更のみを受信するノードのグループを作成するために使用されますが、レプリケーションの変更を他のノードに送信することはありません。詳細については、購読者専用グループ を参照してください。 Datanode は、グループがシャードを表すことを意味しますが、他の値は、グループが各コーディネーターを表すことを意味します。subscriber-only を除き、他の値は将来の使用のために予約されています。 NULL は、通常の汎用ノードグループが作成されることを意味します。

注

このファンクションは、ローカルノードで実行されているローカルコンセンサスワーカーに要求を渡します。

ファンクションはトランザクションではありません。グループの作成はバックグラウンドプロセスであるため、機能が完了すると、変更をロールバックすることはできません。また、変更は現在のトランザクションにすぐに表示されない場合があります。bdr.wait_for_join_completion を呼び出して、そうなるまで待機できます。

グループの作成では、ロックは保持されません。

bdr.alter_node_group_config

この機能は、既存の PGD グループの構成パラメーターを変更します。NULL 値を持つオプションすべてのデフォルトは変更されません。

概要

```
bdr.alter_node_group_config(node_group_name text,
                            insert_to_update boolean DEFAULT NULL,
                            update_to_insert boolean DEFAULT NULL,
                            ignore_redundant_updates boolean DEFAULT NULL,
                            check_full_tuple boolean DEFAULT NULL,
                            apply_delay interval DEFAULT NULL,
                            check_constraints boolean DEFAULT NULL,
                            num_writers int DEFAULT NULL,
                            enable_wal_decoder boolean DEFAULT NULL,
```

(次のページに続く)

(前のページからの続き)

```
                    streaming_mode text DEFAULT NULL,
                    default_commit_scope text DEFAULT NULL)
```

パラメーター

- node_group_name —既存の PGD グループの名前。ローカルノードはグループの一部である必要があります。
- insert_to_update —下位互換性のために予約されています。
- update_to_insert —下位互換性のために予約されています。このオプションは非推奨であり、PGD の将来のバージョンでは無効になるか削除される予定です。代わりに bdr.alter_node_set_conflict_resolver を使用してください。
- ignore_redundant_updates —下位互換性のために予約されています。
- check_full_tuple —下位互換性のために予約されています。
- apply_delay —下位互換性のために予約されています。
- check_constraints —適用プロセスがレプリケートデータを書き込むときに制約をチェックするかどうか。このオプションは非推奨であり、PGD の将来のバージョンでは無効になるか削除される予定です。
- num_writers —このノードグループをバッキングするサブスクリプションの並列ライターの数。-1 は、デフォルト GUC bdr.writers_per_subscription で指定されたとおりに使用されることを意味します。有効な値は-1 または正の整数です。
- enable_wal_decoder —デコードワーカープロセスを有効/無効にします。streaming_mode が既に有効になっている場合、デコードワーカープロセスを有効にすることはできません。
- streaming_mode —大規模なトランザクションのストリーミングを有効/無効にします。off に設定すると、ストリーミングが無効になります。他の値に設定されている場合、大規模なトランザクションは進行中にデコードされ、変更がダウンストリームに送信されます。値が file に設定されている場合、ストリーミングトランザクションの着信変更はファイルに保存され、上流でトランザクションがコミットされた後にのみ適用されます。値が writer に設定されている場合、着信変更はライターのいずれか利用可能な場合に直接送信されます。並列適用が無効になっている場合、またはストリーミングトランザクションを処理できるライタがない場合、変更はファイルに書き込まれ、トランザクションがコミットされた後に適用されます。値が auto に設定されている場合、PGD は、トランザクションプロパティと使用可能なリソースに応じて、file と writer の間でインテリジェントに選択しようとします。WAL デコーダーが既に有効になっている場合、streaming_mode を有効にすることはできません。

詳細については、 *Transaction streaming* を参照してください。

- default_commit_scope —デフォルトで使用するコミットスコープ、最初は local コミットスコープです。これは、トップレベルのノードグループにのみ適用されます。同じコミットスコープの異なるオリジングループに個々のルールを使用できます。詳細は、オリジングループ を参照してください。

注

このファンクションは、デフォルトを変更するように要求をグループコンセンサスメカニズムに渡します。行われた変更は、コンセンサスメカニズムを使用してグローバルに複製されます。

ファンクションはトランザクションではありません。要求はバックグラウンドで処理されるため、ファンクション呼び出しをロールバックすることはできません。また、変更は現在のトランザクションにすぐに表示されない場合があります。

このファンクションはロックを保持しません。

> **警告:** このファンクションを使用して `apply_delay` 値を変更する場合、変更は既にグループのメンバーであるノードに適用されません。この値は通常テストの外部で使用されないため、この制限は実稼働使用にはほとんど影響しません。

bdr.join_node_group

この機能は、ローカルノードを既存の PGD グループに参加させます。

概要

```
bdr.join_node_group (
    join_target_dsn text,
    node_group_name text DEFAULT NULL,
    pause_in_standby boolean DEFAULT false,
    wait_for_completion boolean DEFAULT true,
    synchronize_structure text DEFAULT all
)
```

パラメーター

- join_target_dsn —ローカルノードを追加する PGD グループ内の既存のソースノードへの接続文字列を指定します。
- node_group_name —PGD グループのオプションの名前。デフォルトは NULL で、ソースノードに存在する情報からグループ名を検出しようとします。
- pause_in_standby —オプションで、論理スタンバイノードとしてのみ参加するように参加プロセスに指示します。これは、後で完全なメンバーに昇格できます。
- wait_for_completion —戻る前に、参加プロセスが完了するのを待ちます。デフォルト true
- synchronize_structure —結合中に実行する構造スキーマ同期の種類を設定します。有効なオプションは、完全なデータベース構造を同期する all と、構造を同期しない none です。ただし、データは引き続き同期されます。

wait_for_completion が false として指定された場合、これは非同期呼び出しであり、参加プロシージャが開始されるとすぐに返されます。結合の進行状況は、ログと bdr.event_summary 情報ビューで、または bdr.join_node_group() が戻った後に bdr.wait_for_join_completion() ファンクションを呼び出すことで確認できます。

注

このファンクションは、join_target_dsn 接続文字列がポイントするノードを介して、グループコンセンサスメカニズムに要求を渡します。行われた変更は、コンセンサスメカニズムによってグローバルに複製されます。

ファンクションはトランザクションではありません。参加プロセスはバックグラウンドで発生し、ロールバックすることはできません。wait_for_completion が true に設定されている場合、または後で bdr.wait_for_join_completion を呼び出した場合、変更はローカルトランザクションにのみ可視されます。

ノードは 1 つのグループのみに所属できるため、各ノードで 1 回だけこのファンクションを呼び出すことができます。

ノード参加は、PGD グループのロックを保持しません。

bdr.switch_node_group

この機能は、ローカルノードを現在のサブグループから同じ既存の PGD ノードグループ内の別のサブグループに切り替えます。

概要

```
bdr.switch_node_group (
    node_group_name text,
    wait_for_completion boolean DEFAULT true
)
```

パラメーター

- node_group_name — PGD グループまたはサブグループの名前。
- wait_for_completion —戻る前に、スイッチプロセスが完了するのを待ちます。デフォルト true

wait_for_completion が false として指定された場合、これは非同期呼び出しであり、スイッチングプロシージャが開始するとすぐに返されます。スイッチの進行状況は、ログと bdr.event_summary 情報ビューで、または bdr.switch_node_group() が戻った後に bdr.wait_for_join_completion() ファンクションを呼び出すことで確認できます。

注

このファンクションは、要求をグループコンセンサスメカニズムに渡します。行われた変更は、コンセンサスメカニズムによってグローバルに複製されます。

ファンクションはトランザクションではありません。スイッチングプロセスはバックグラウンドで発生し、ロールバックすることはできません。wait_for_completion が true に設定されている場合、または後で bdr.wait_for_join_completion を呼び出した場合、変更はローカルトランザクションにのみ可視されます。

ローカルノードは、クラスターを分割する必要なく、現在のサブグループから同じ PGD ノードグループ内の別のサブグループにメンバーシップを変更します。ノードの種類は、ターゲットサブグループ内の既存のノードの種類と一致する必要があります。

ノードスイッチングは、PGD グループのロックを保持しません。

制限現在、この機能では、サブグループとその PGD ノードグループ間の切り替えのみが許可されています。サブグループ間の移動を有効にするには、2 つの別個の呼び出しを行う必要があります。1) サブグループからノードグループにスイッチし、2) ノードグループから他のサブグループにスイッチします。

bdr.promote_node

この機能は、ローカル論理スタンバイノードを PGD グループの完全なメンバーに昇格させます。

概要

```
bdr.promote_node(wait_for_completion boolean DEFAULT true)
```

注

このファンクションは、デフォルトを変更するように要求をグループコンセンサスメカニズムに渡します。行われた変更は、コンセンサスメカニズムによってグローバルに複製されます。

ファンクションはトランザクションではありません。プロモーションプロセスはバックグラウンドで発生し、ロールバックすることはできません。wait_for_completion が true に設定されている場合、または後で bdr.wait_for_join_completion を呼び出した場合、変更はローカルトランザクションにのみ可視されます。

プロモーションプロセスは、他のプロモーションに対してロックを保持します。このロックは他の bdr.promote_node 呼び出しをブロックしませんが、プロモーションのバックグラウンドプロセスが一度に複数のノードで進行することを防ぎます。

bdr.wait_for_join_completion

このファンクションは、ローカルノードの参加手順が完了するのを待機します。

概要

```
bdr.wait_for_join_completion(verbose_progress boolean DEFAULT false)
```

パラメーター

- verbose_progress —オプションで、参加プロシージャ中に実行される個々のステップに関する情報を出力します。

注

このファンクションは、ローカルノードのチェック状態が bdr.create_node_group 、bdr.join_node_group 、または bdr.promote_node で設定されたターゲット状態に到達するまで待機します。

bdr.part_node

PGD グループからノードを削除しますが、ノードからデータは削除されません。

削除するノードを含む、PGD グループ内の任意のアクティブノードからファンクションを呼び出すことができます。ただし、ノードが分離されると、クラスター内の他のノードを分離することはできません。

注釈: ローカルノードを分離する場合、*wait_for_completion* から `false` に設定する必要があります。それ以外の場合、エラーが報告されます。

> **警告:** このアクションは永続的です。ノードへのレプリケーションを一時的に停止する場合は、*bdr.alter_subscription_disable()* を参照してください。

概要

```
bdr.part_node (
    node_name text,
    wait_for_completion boolean DEFAULT true,
    force boolean DEFAULT false
)
```

パラメーター

- node_name —パートへの既存のノードの名前。
- wait_for_completion — true の場合、ノードがクラスターから完全に分離されるまで、ファンクションは返されません。それ以外の場合、ファンクションは分割プロシージャを開始し、待機せずにすぐに戻ります。ローカルノードで実行する場合、または force を使用する場合、常に false に設定します。
- force —ローカルノードでノードを強制的に削除します。これにより、コンセンサスに到達できない場合、またはノード分割プロセスがスタックしている場合、ノードの状態をローカルに設定します。

警告: *force = true* を使用すると、PGD グループが一貫性のない状態になる場合があります。他の方法でノードを削除できない障害から回復するためにのみ使用します。

注

このファンクションは、グループコンセンサスメカニズムに要求を渡して、特定のノードを分割します。行われた変更は、コンセンサスメカニズムによってグローバルに複製されます。分離プロセスはバックグラウンドで発生し、ロールバックすることはできません。wait_for_completion が true に設定されている場合、分割プロセスによって行われた変更はローカルトランザクションにのみ可視されます。

force が true に設定されている場合、コンセンサスが失敗すると、このファンクションはローカルノードでのみ特定のノードの状態を設定します。このような場合、ファンクションはトランザクションであり、ファンクションがノードの状態を変更するため、ロールバックできます。force が true に設定されて既に分離処理中のノードでファンクションが呼び出された場合、指定されたノードをローカルに分離済みとしてマークして、終了します。これは、クラスターでコンセンサスに到達できない場合つまりノードの大部分がダウンしている場合、または分割プロセスがスタックしている場合にのみ役立ちます。ただし、書き込みを受信していた分離ノードが書き込みを行った場合、分離プロセスはフリーズせずに長時間かかる場合があることを考慮することが重要です。他のノードは、特定のノードからの欠落データを再同期する必要があります。強制分離はこの再同期を完全にスキップし、他のノードを一貫性のない状態のままにする可能性があります。

分離プロセスはロックを保持しません。

bdr.alter_node_interface

このファンクションは、指定されたノードの接続文字列 DSN を変更します。

概要

```
bdr.alter_node_interface(node_name text, interface_dsn text)
```

パラメーター

- node_name —変更する既存のノードの名前。
- interface_dsn —ノードの新しい接続文字列。

注

このファンクションを実行し、ローカルノードでのみ変更を加えます。これは、通常、変更されるノードを含む、PGD グループ内のすべてのノードで実行することを意味します。

このファンクションはトランザクションです。ロールバックできます。変更は現在のトランザクションに表示されます。

ファンクションはローカルノードでロックを保持します。

bdr.alter_subscription_enable

この機能は、指定されたサブスクリプションまたはローカル PGD ノードのすべてのサブスクリプションを有効にします。これは、再開サブスクリプションとも呼ばれます。サブスクリプションが既に有効になっている場合、エラーはスローされません。このオペレーションの影響を受けるサブスクリプションの数を返します。

概要

```
bdr.alter_subscription_enable(
    subscription_name name DEFAULT NULL,
    immediate boolean DEFAULT false
)
```

パラメーター

- subscription_name —有効にするサブスクリプションの名前。NULL の場合デフォルト、ローカルノードのすべてのサブスクリプションが有効になります。
- immediate —これは現在効果がありません。

注

この機能はレプリケートされず、ローカルノードサブスクリプション特定のノードまたはすべてのノードにのみ影響します。

このファンクションはトランザクションです。ロールバックできます。現在のトランザクションは、カタログの変更を確認できます。サブスクリプションワーカーは、トランザクションがコミットされた後、バックグラウンドプロセスによって起動されます。

bdr.alter_subscription_disable

このファンクションは、指定されたサブスクリプションまたはローカル PGD ノードのすべてのサブスクリプションを無効にします。オプションで、無効なサブスクリプションに関連付けられているすべてのワーカーをすぐに停止することもできます。これは、サブスクリプションの一時停止とも呼ばれます。サブスクリプションが既に無効になっている場合、エラーはスローされません。このオペレーションの影響を受けるサブスクリプションの数を返します。

概要

```
bdr.alter_subscription_disable(
    subscription_name name DEFAULT NULL,
    immediate boolean DEFAULT false,
    fast boolean DEFAULT true
)
```

パラメーター

- subscription_name —無効にするサブスクリプションの名前。NULL の場合デフォルト、ローカルノードのすべてのサブスクリプションが無効になります。
- immediate —アクションをすぐに強制し、無効になったサブスクリプションに関連付けられているすべてのワーカーを停止するために使用されます。このオプションが true の場合、トランザクションブロック内でこのファンクションを実行できません。
- fast —この引数は、immediate の動作に影響を与えます。true デフォルトに設定されている場合、現在の作業が完了するのを待たずに、無効なサブスクリプションに関連付けられているすべてのワーカーを停止します。

注

このファンクションはレプリケートされず、ローカルノードサブスクリプション特定のサブスクリプションまたはすべてのサブスクリプションにのみ影響します。

このファンクションはトランザクションです。ロールバックできます。現在のトランザクションは、カタログの変更を確認できます。ただし、サブスクリプションワーカーが停止するタイミングは、immediate の値に依存します。 true に設定されている場合、ワーカーは COMMIT を待たずに stop を受け取ります。fast 引数が true に設定されている場合、ワーカーの中断は、現在の作業が完了するまで待機しません。

bdr.alter_node_group_option

PGD ノードグループのルーティング構成を変更する

概要

```
bdr.alter_node_group_option(node_group_name text,
    config_key text,
    config_value text);
```

パラメーター

- node_group_name —変更するグループの名前。
- config_key —変更するノードグループのオプションのキー。
- config_value —指定されたキーに設定される新しい値。

bdr.alter_node_option

PGD ノードのルーティング構成を変更する

概要

```
bdr.alter_node_option(node_name text,
    config_key text,
    config_value text);
```

パラメーター

- node_name —変更するノードの名前。
- config_key —変更するノードのオプションのキー。
- config_value —指定されたキーに設定される新しい値。

9.1.6 Routing functions

bdr.create_proxy

プロキシの作成

概要

```
bdr.create_proxy(proxy_name text, node_group text);
```

パラメーター

- proxy_name —新しいプロキシの名前。
- node_group —プロキシが使用するグループの名前。

bdr.alter_proxy_option

プロキシを変更する

概要

```
bdr.alter_proxy_option(proxy_name text, config_key text, config_value text);
```

パラメーター

- proxy_name —変更するプロキシの名前。
- config_key —変更するプロキシのオプションのキー。
- config_value —指定されたキーに設定される新しい値。

bdr.drop_proxy

プロキシのドロップ

概要

```
bdr.drop_proxy(proxy_name text);
```

パラメーター

- proxy_name —ドロップするプロキシの名前。

bdr.routing_leadership_transfer

ルーティングリーダーを変更すると、ノードグループのリーダーシップが別のノードに転送されます

概要

```
bdr.routing_leadership_transfer(node_group_name text,
              leader_name text,
              transfer_method text DEFAULT strict,
              transfer_timeout interval DEFAULT 10s);
```

パラメーター

- node_group_name —リーダーシップの譲渡が要求されたグループの名前。
- leader_name —書き込みリーダーになるノードの名前。
- transfer_method —転送のタイプ、最大遅延をチェックする「fast」またはデフォルトの「strict」です。
- transfer_timeout —リーダーシップ転送のタイムアウト、デフォルトは 10 秒です。

9.1.7 Replication set management

bdr.create_replication_set

この機能は、レプリケーションセットを作成します。

このコマンドのレプリケーションは、 DDLDDL 構成の影響を受けます。

概要

```
bdr.create_replication_set(set_name name,
                           replicate_insert boolean DEFAULT true,
                           replicate_update boolean DEFAULT true,
                           replicate_delete boolean DEFAULT true,
                           replicate_truncate boolean DEFAULT true,
                           autoadd_tables boolean DEFAULT false,
                           autoadd_existing boolean DEFAULT true)
```

パラメーター

- set_name —新しいレプリケーションセットの名前。PGD グループ全体で一意である必要があります。
- replicate_insert —このレプリケーションセット内のテーブルへの挿入をレプリケートするかどうかを示します。
- replicate_update —このレプリケーションセット内のテーブルの更新をレプリケートするかどうかを示します。
- replicate_delete —このレプリケーションセット内のテーブルからの削除をレプリケートするかどうかを示します。
- replicate_truncate —このレプリケーションセット内のテーブルのトランケートをレプリケートするかどうかを示します。
- autoadd_tables —新しく作成される将来のテーブルをこのレプリケーションセットにレプリケートするかどうかを示します
- autoadd_existing —既存のすべてのユーザーテーブルをこのレプリケーションセットに追加するかどうかを示します。このパラメーターは、autoadd_tables が true に設定されている場合にのみ効果があります。

注

デフォルトでは、新しいレプリケーションセットは DDL または PGD 管理ファンクション呼び出しをレプリケートしません。レプリケーションセットの DDL レプリケーションを設定する方法については、 *ddl filters* を参照してください。既存の DDL フィルターは、すべての DDL および管理ファンクション呼び出しをレプリケートするデフォルトのグループレプリケーションセットに設定されます。これは、グループの作成時に作成されますが、

PGD グループのデフォルトレプリケーションセットで DDL または PGD 管理ファンクション呼び出しをレプリケートしたくない場合にドロップできます。

このファンクションは、 DDL ステートメントと同じレプリケーションメカニズムを使用します。これは、レプリケーションが *ddl filters* の影響を受けることを意味します

構成。

ファンクションは DDL グローバルロックを取得します。

このファンクションはトランザクションです。トランザクションの ROLLBACK を使用してエフェクトをロールバックできます。変更は現在のトランザクションに表示されます。

bdr.alter_replication_set

この機能は、既存のレプリケーションセットのオプションを変更します。

このコマンドのレプリケーションは、DDL フィルタリング設定を含む DDL レプリケーション構成の影響を受けます。

概要

```
bdr.alter_replication_set(set_name name,
                          replicate_insert boolean DEFAULT NULL,
                          replicate_update boolean DEFAULT NULL,
                          replicate_delete boolean DEFAULT NULL,
                          replicate_truncate boolean DEFAULT NULL,
                          autoadd_tables boolean DEFAULT NULL)
```

パラメーター

- set_name —既存のレプリケーションセットの名前。
- replicate_insert —このレプリケーションセット内のテーブルへの挿入をレプリケートするかどうかを示します。
- replicate_update —このレプリケーションセット内のテーブルの更新をレプリケートするかどうかを示します。
- replicate_delete —このレプリケーションセット内のテーブルからの削除をレプリケートするかどうかを示します。
- replicate_truncate —このレプリケーションセット内のテーブルのトランケートをレプリケートするかどうかを示します。
- autoadd_tables —新しく作成される将来のテーブルをこのレプリケーションセットに追加するかどうかを示します。

NULL デフォルトに設定されているオプションは、以前と同じままです。

注

このファンクションは、 DDL ステートメントと同じレプリケーションメカニズムを使用します。これは、レプリケーションが *ddl filters* の影響を受けることを意味します

構成。

ファンクションは DDL グローバルロックを取得します。

このファンクションはトランザクションです。トランザクションの ROLLBACK を使用してエフェクトをロールバックできます。変更は現在のトランザクションに表示されます。

bdr.drop_replication_set

この機能は、既存のレプリケーションセットを削除します。

このコマンドのレプリケーションは、DDL フィルタリング設定を含む DDL レプリケーション構成の影響を受けます。

概要

```
bdr.drop_replication_set(set_name name)
```

パラメーター

- set_name —既存のレプリケーションセットの名前。

注

このファンクションは、 DDL ステートメントと同じレプリケーションメカニズムを使用します。これは、レプリケーションが *ddl filters* の影響を受けることを意味します

構成。

ファンクションは DDL グローバルロックを取得します。

このファンクションはトランザクションです。トランザクションの ROLLBACK を使用してエフェクトをロールバックできます。変更は現在のトランザクションに表示されます。

警告: 少なくとも別のノードで使用されているレプリケーションセットを削除しないでください。削除すると、そのノードでレプリケーションが停止します。これが発生した場合は、影響を受けるノードをそのレプリケーションセットからサブスクライブ解除します。同じ理由で、参加されるノードがそのレプリケーションセットのメンバーである場合、参加操作が進行中のレプリケーションセットをドロップしないでください。レプリケーションセットのメンバーシップは、結合の開始時にのみチェッ

クされます。これは、レプリケーションセットの使用状況に関する情報が各ノードにローカルであるため、グループに参加する前にノードで構成できるために発生します。

alter_node_replication_sets を使用して、ノードのレプリケーションセットのサブスクリプションを管理できます。

bdr.alter_node_replication_sets

この機能は、ノードが公開およびサブスクライブするレプリケーションセットを変更します。

概要

```
bdr.alter_node_replication_sets(node_name name,
                                set_names text[])
```

パラメーター

- node_name —変更するノード。現在はローカルノードである必要があります。
- set_names —指定されたノードにレプリケートするレプリケーションセットの配列。空の配列を使用すると、グループのデフォルトレプリケーションセットが使用されます。

注

このファンクションはローカルノードでのみ実行され、どのような方法でもレプリケートされません。

このファンクションはノードが参加する前に実行するように設計されているため、リストされたレプリケーションセットの存在はチェックされません。エラーを回避するには、レプリケーションセット名を正しく指定するように注意してください。

これにより、PGD グループの一部であるノードでだけでなく、まだグループに参加していないノードでもファンクションを呼び出すことができます。このアプローチでは、結合中に同期されるデータを制限します。ただし、スキーマは、レプリケーションセット設定に関係なく、常に完全に同期されます。レプリケーションセットで指定されたテーブルだけでなく、すべてのテーブルがコピーされます。bdr.tables カタログテーブルを参照して、不要なテーブルを削除できます。これらは、PGD の新しいバージョンでは自動的に削除される可能性があります。これは、 *ddl filters*

それ以外の場合は、構成が DDL のレプリケーションを防止します。

この呼び出しの後にノードがサブスクライブするレプリケーションセットは、他のノードからこのファンクションが実行されるノードに変更を実際にレプリケートするために他のノードによって公開されます。

9.1.8 Replication set membership

bdr.replication_set_add_table

このファンクションは、テーブルをレプリケーションセットに追加します。

これにより、テーブルがレプリケーションセットに追加され、この瞬間またはトランザクションコミットから変更のレプリケートが開始されます。ノード上のテーブルが持っている既存のデータは同期されません。

このコマンドのレプリケーションは、DDL フィルタリング設定を含む DDL レプリケーション構成の影響を受けます。

概要

```
bdr.replication_set_add_table(relation regclass,
                              set_name name DEFAULT NULL,
                              columns text[] DEFAULT NULL,
                              row_filter text DEFAULT NULL)
```

パラメーター

- relation —テーブルの名前または OID。
- set_name —レプリケーションセットの名前。NULL デフォルトの場合、PGD グループのデフォルトレプリケーションセットが使用されます。
- columns —将来の使用のために予約されています。現在は何もしないため、NULL である必要があります。
- row_filter —レプリケートされた行をフィルタリングするために使用される SQL 式。この式が定義されていない場合、デフォルトの NULL に設定されている場合、すべての行が送信されます。

row_filter は、NULL を使用したブール結果を生成する式を指定します。True または Unknown と評価される式は、行をレプリケートします。False 値は行をレプリケートしません。式にサブクエリーを含めたり、レプリケートされる現在の行の列以外の変数を参照したりすることはできません。システム列を参照することはできません。

row_filter は、ターゲットノードではなく、オリジンノードで実行されます。これにより、この特定のテーブルのレプリケーションに追加の CPU オーバーヘッドがかかりますが、フィルターされた行のデータの送信が完全に回避されます。したがって、ネットワーク帯域幅が削減され、ターゲットノードのオーバーヘッドが適用されます。

row_filter は、特定のテーブルの TRUNCATE コマンドを削除することはありません。レプリケーションセットレベルで TRUNCATE コマンドをフィルタリングできます。

テーブルの一部の列のみをレプリケートできます。 差分を含むノード間のレプリケーションを参照してください。

注

このファンクションは、 DDL ステートメントと同じレプリケーションメカニズムを使用します。これは、レプリケーションが *ddl filters* の影響を受けることを意味します

構成。

row_filter が NULL でない場合、ファンクションはレプリケーションセットに追加されるリレーションで DML グローバルロックを取得します。それ以外の場合は、DDL グローバルロックのみを使用します。

このファンクションはトランザクションです。トランザクションの ROLLBACK を使用してエフェクトをロールバックできます。変更は現在のトランザクションに表示されます。

bdr.replication_set_remove_table

このファンクションは、レプリケーションセットからテーブルを削除します。

このコマンドのレプリケーションは、DDL フィルタリング設定を含む DDL レプリケーション構成の影響を受けます。

概要

```
bdr.replication_set_remove_table(relation regclass,
                                 set_name name DEFAULT NULL)
```

パラメーター

- relation —テーブルの名前または OID。
- set_name —レプリケーションセットの名前。 NULL デフォルトの場合、PGD グループのデフォルトレプリケーションセットが使用されます。

注

このファンクションは、 DDL ステートメントと同じレプリケーションメカニズムを使用します。これは、レプリケーションが *ddl filters* の影響を受けることを意味します

構成。

ファンクションは DDL グローバルロックを取得します。

このファンクションはトランザクションです。トランザクションの ROLLBACK を使用してエフェクトをロールバックできます。変更は現在のトランザクションに表示されます。

9.1.9 DDL replication filtering

DDL レプリケーションフィルタリング も参照

bdr.replication_set_add_ddl_filter

このファンクションは、 DDL フィルタをレプリケーションセットに追加します。

指定されたフィルターに一致する DDL は、そのセットをサブスクライブしているノードにレプリケートされます。これは、PGD 管理機能のレプリケーションにも影響します。

これは、ノードでの DDL の実行を妨げるものではありません。DDL を他のノードにレプリケートするかどうかのみを変更します。2 つのノードの間に、すべてのインデックスコマンドを除外するレプリケーションフィルタがあるとします。各ノードに直接接続し、そのノードで目的の DDL を実行することにより、インデックスコマンドを自由に実行できます。

DDL フィルターは command_tag および role_name を指定して、一部の DDL ステートメントのみのレプリケーションを許可できます。command_tag は、 *EVENT TRIGGERs* で使用されるものと同じです

通常の PostgreSQL コマンドの場合。典型的な例は、ロジカルスタンバイ上の追加のインデックスコマンドが他のすべてのノードにレプリケートされないようにフィルタを作成することです。

修飾されたファンクション名と一致するタグ名を使用して、使用される PGD 管理機能をフィルタリングできます。たとえば、bdr.replication_set_add_table は、同じ名前のファンクションのコマンドタグです。この場合、このタグにより、bdr.* を使用してすべての PGD ファンクションをフィルタリングできます。

role_name は、コマンドを実行している現在のロールとの照合に使用されます。command_tag と role_name は両方とも正規表現として評価され、大文字と小文字が区別されます。

概要

```
bdr.replication_set_add_ddl_filter(set_name name,
                                   ddl_filter_name text,
                                   command_tag text,
                                   role_name text DEFAULT NULL,
                                   base_relation_name text DEFAULT NULL,
                                   query_match text DEFAULT NULL,
                                   exclusive boolean DEFAULT FALSE)
```

パラメーター

- set_name —レプリケーションセットの名前。 NULL の場合、PGD グループのデフォルトのレプリケーションセットが使用されます
- ddl_filter_name —DDL フィルタの名前。これは PGD グループ全体で一意である必要があります
- command_tag —一致するコマンドタグの正規表現。NULL はすべてと一致することを意味します
- role_name —ロール名と一致するための正規表現。NULL はすべてのロールと一致することを意味します
- base_relation_name —将来の使用のために予約されており、NULL である必要があります
- query_match —クエリーと一致するための正規表現。NULL はすべてのクエリーと一致することを意味します
- exclusive —true の場合、他の一致したフィルタは考慮されませんつまり、排他的フィルタのみが適用され、複数の排他的フィルタが一致する場合、エラーをスローします。これは、メインレプリケーションセットを介してデフォルトのレプリケーションを維持しながら、特定のコマンドを特定のレプリケーションセットにルーティングする場合に役立ちます。

注

このファンクションは、 DDL ステートメントと同じレプリケーションメカニズムを使用します。これは、レプリケーションが *ddl filters* の影響を受けることを意味します

構成。これは、ddl フィルタ構成への変更のレプリケーションが既存の ddl フィルタ構成の影響を受けることも意味します。

ファンクションは DDL グローバルロックを取得します。

このファンクションはトランザクションです。トランザクションの ROLLBACK を使用してエフェクトをロールバックできます。変更は現在のトランザクションに表示されます。

定義されたレプリケーションフィルタを表示するには、ビュー bdr.ddl_replication を使用します。

例

PGD 管理機能のみを含めるには、次のようなフィルターを定義します。

```
SELECT bdr.replication_set_add_ddl_filter(mygroup, mygroup_admin, $$bdr\..*$$);
```

インデックス DDL 以外のすべてを除外するには

```
SELECT bdr.replication_set_add_ddl_filter(mygroup, index_filter,
                '^(?!(CREATE INDEX|DROP INDEX|ALTER INDEX)).*');
```

テーブルとインデックスに対するすべての操作を含め、その他のすべてを除外するには、2 つのフィルターを追加します。1 つはテーブル用、もう 1 つはインデックス用です。これは、複数のフィルタが、許可されるすべての DDL コマンドの和集合を提供することを示しています。

```
SELECT bdr.replication_set_add_ddl_filter(bdrgroup,index_filter, ^((?!INDEX).)*$);
SELECT bdr.replication_set_add_ddl_filter(bdrgroup,table_filter, ^((?!TABLE).)*$);
```

bdr.replication_set_remove_ddl_filter

このファンクションは、レプリケーションセットから DDL フィルターを削除します。

このコマンドのレプリケーションは、DDL フィルタリング設定自分自身を含む DDL レプリケーション構成の影響を受けます。

概要

```
bdr.replication_set_remove_ddl_filter(set_name name,
                                      ddl_filter_name text)
```

パラメーター

- set_name —レプリケーションセットの名前。NULL の場合、PGD グループのデフォルトのレプリケーションセットが使用されます。
- ddl_filter_name —削除する DDL フィルターの名前。

注

このファンクションは、 DDL ステートメントと同じレプリケーションメカニズムを使用します。これは、レプリケーションが *ddl filters* 構成の影響を受けることを意味します。これは、DDL フィルタ構成の変更のレプリケーションが既存の DDL フィルタ構成の影響を受けることも意味します。

ファンクションは DDL グローバルロックを取得します。

このファンクションはトランザクションです。トランザクションの ROLLBACK を使用してエフェクトをロールバックできます。変更は現在のトランザクションに表示されます。

9.1.10 Testing and tuning commands

EDB Postgres Distributed には、PGD クラスターのテストと調整に役立つツールが含まれています。バックグラウンドについては、

> *Testing and tuning PGD clusters* を参照してください。

pgd_bench

概要

EDB Postgres 分散展開のベンチマークツール。

```
pgd_bench [OPTION]... [DBNAME] [DBNAME2]
```

DBNAME は、次のフォーマットの conninfo 文字列です。"host=10.1.1.2 user=postgres dbname=master"

pgd_bench のオプションと使用例については、
> *pgd_bench in Testing and tuning* を参照してください。

オプション

pgd_bench コマンドは、pgbench コマンドのラッパーとして実装されています。これは、同じオプションの多くを共有し、テストを実行するときに pgbench という名前のテーブルを作成したことを意味します。

pgd_bench に固有のオプションには次のものが含まれます。

設定モード

-m または--mode

モードは regular 、camo 、または failover に設定できます。デフォルトは regular です。

- regular — pgd_bench を実行するために必要なノードは 1 つだけです。
- camo —CAMO パートナーとして機能するように 2 番目のノードを指定する必要があります。CAMO の設定が必要です。
- failover —フェールオーバーとして機能するように 2 番目のノードを指定する必要があります。

-m failover を使用する場合、追加オプション--retry を使用できます。このオプションは、フェイルオーバーが発生した場合にトランザクションを再試行するように pgd_bench に指示します。-m camo を使用する場合、 --retry オプションは自動的に有効になります。

GUC 変数の設定

-o または--set-option このオプションの後には、NAME=VALUE エントリが続きます。これらは、pgd_bench が接続する各サーバー、およびそれらのサーバーにのみ Postgres

SET コマンドを使用して適用されます。

他のオプションは Postgres pgbench コマンドと同じです。詳細については、PostgreSQL *pgbench* ドキュメントを参照してください。

オプション pgd_bench および pgbench の完全なリストが以下にあります。

初期化オプション

- -i, --initialize —初期化モードを呼び出します。
- -I, --init-steps=[dtgGvpf]+ (デフォルト"dtgvp") —選択した初期化手順を実行します。 - d — 既存の pgbench テーブルを削除します。 - t —標準の pgbench シナリオで使用されるテーブルを作成します。 - g —クライアントサイドでデータを生成し、標準テーブルにロードし、既に存在するデータを置き換えます。- G —サーバーサイドでデータを生成して標準テーブルにロードし、既に存在するデータを置き換えます。- v —標準テーブルで VACUUM を呼び出します。 - p —標準テーブルに主キーインデックスを作成します。 - f —標準テーブル間に外部キー制約を作成します。
- -F, --fillfactor=NUM —フィルファクターを設定します。
- -n, --no-vacuum —初期化中に VACUUM を実行しないでください。
- -q, --quiet —クワイエットロギング 5 秒ごとに 1 メッセージ。
- -s, --scale=NUM —スケーリング係数。
- --foreign-keys —テーブル間に外部キーコンストレインを作成します。
- --index-tablespace=TABLESPACE —指定されたテーブルスペースにインデックスを作成します。
- --partition-method=(range|hash) —このメソッドで pgbench_accounts をパーティション化します。デフォルトは range です。
- --partitions=NUM — pgbench_accounts を NUM パーツにパーティション化します。デフォルトは 0 です。
- --tablespace=TABLESPACE —指定されたテーブルスペースにテーブルを作成します。
- --unlogged-tables —ログを取らないテーブルとしてテーブルを作成します。注ログに記録されていないテーブルはレプリケートされません。

実行するものを選択するオプション

- -b, --builtin=NAME[@W] —W で重み付けされたビルトインスクリプト NAME を追加します。デフォルトは 1 です。-b list を使用して、使用可能なスクリプトをリストします。
- -f, --file=FILENAME[@W] — W で重み付けスクリプト FILENAME を追加します。デフォルトは 1 です。
- -N, --skip-some-updates —pgbench_tellers および pgbench_branches の更新。 -b simple-update と同じ。
- -S, --select-only — SELECT のみのトランザクションを実行します。-b select-only と同じ。

ベンチマークオプション

- -c, --client=NUM —同時データベースクライアントの数。デフォルトは 1 です。
- -C, --connect —トランザクションごとに新しい接続を確立します。
- -D, --define=VARNAME=VALUE —カスタムスクリプトで使用する変数を定義します。
- -j, --jobs=NUM —スレッド数。デフォルトは 1 です。
- -l, --log —トランザクション時間をログファイルに書き込みます。
- -L, --latency-limit=NUM —NUM ミリ秒を超えて続いたトランザクションを遅いものとしてカウントします。
- -m, --mode=regular|camo|failover —pgbench を実行するモード。デフォルトは regular です。
- -M, --protocol=simple|extended|prepared —クエリーを送信するためのプロトコル。デフォルトは simple です。
- -n, --no-vacuum —テストの前に VACUUM を実行しないでください。
- -o, --set-option=NAME=VALUE —ランタイム SET オプションを指定します。
- -P, --progress=NUM —NUM 秒ごとにスレッドの進行状況レポートを表示します。
- -r, --report-per-command —コマンドごとのレイテンシー、失敗、および再試行。
- -R, --rate=NUM — 1 秒ごとのトランザクションのターゲットレート。
- -s, --scale=NUM —このスケール係数を出力で報告します。
- -t, --transactions=NUM —各クライアントが実行するトランザクションの数。デフォルトは 10 です。
- -T, --time=NUM —ベンチマークテストの時間秒単位。
- -v, --vacuum-all —テストの前に 4 つの標準テーブルをすべてバキュームします。
- --aggregate-interval=NUM — NUM 秒以上のデータ。
- --failures-detailed —基本的なタイプごとにグループ化された障害を報告します。

- --log-prefix=PREFIX —トランザクション時間ログファイルの接頭辞。デフォルトは pgbench_log です。
- --max-tries=NUM —トランザクションを実行しようとする最大回数。デフォルトは 1 です。
- --progress-timestamp —進行状況には Unix エポックタイムスタンプを使用します。
- --random-seed=SEED —ランダムシード time 、rand 、integer を設定します。
- --retry — -m で使用される、フェイルオーバー時にトランザクションを再試行します。
- --sampling-rate=NUM —ログに記録するトランザクションの割合、たとえば、1%の場合 0.01。
- --show-script=NAME —ビルトインスクリプトコードを表示して、終了します。
- --verbose-errors —すべてのエラーのメッセージを出力します。

共通オプション

- -d, --debug —デバッグ出力を印刷します。
- -h, --host=HOSTNAME —データベースサーバホストまたはソケットディレクトリ。
- -p, --port=PORT —データベースサーバーのポート番号。
- -U, --username=USERNAME —指定されたデータベースユーザーとして接続します。
- -V, --version —バージョン情報を出力して終了します。
- -?, --help —ヘルプを表示して、終了します。

9.1.11 Global sequence management interfaces

PGD は、標準の PostgreSQL シーケンスと PGD グローバルシーケンスの間で変換するためのインターフェイスを提供します。

次のファンクションは DDL であると考えられるため、DDL レプリケーションとグローバルロックが適用されます。

シーケンスファンクション

bdr.alter_sequence_set_kind

シーケンスの所有者がシーケンスの種類を設定できます。設定すると、seqkind は bdr.sequences ビューを介してのみ可視されます。他のすべての方法では、シーケンスは通常のシーケンスとして表示されます。

PGD はこのファンクションを DDL として扱うため、現在アクティブな場合、DDL レプリケーションとグローバルロックが適用されます。 *DML and DDL replication and nonreplication* を参照してください。

概要

```
bdr.alter_sequence_set_kind(seqoid regclass, seqkind text)
```

パラメーター

- seqoid —変更するシーケンスの名前または Oid。
- seqkind —標準の PostgreSQL シーケンスの場合は local 、グローバルに一意の PGD シーケンスの場合は snowflakeid または galloc 、または古いグローバル一意シーケンスの場合は timeshard 。

注

シーケンス種類を galloc に変更すると、そのシーケンスの最初に割り当てられたレンジは、開始点としてシーケンス start 値を使用します。galloc に変更される前にシーケンスで使用された既存の値が存在する場合、次のコマンドを使用して、新しく生成された値が既存の値と競合しないように、開始ポイントを移動することをお勧めします。

```
ALTER SEQUENCE seq_name START starting_value RESTART
```

このファンクションは、 DDL ステートメントと同じレプリケーションメカニズムを使用します。これは、レプリケーションが *ddl filters* の影響を受けることを意味します

構成。

ファンクションはグローバル DDL ロックを取得します。また、シーケンスをローカルにロックします。

このファンクションはトランザクションです。トランザクションの ROLLBACK を使用してエフェクトをロールバックできます。変更は現在のトランザクションに表示されます。

bdr.backwards_compatibility が 30618 以下に設定されていない限り、シーケンスの所有者のみが bdr.alter_sequence_set_kind ファンクションを実行できます。

bdr.extract_timestamp_from_snowflakeid

このファンクションは、snowflakeid シーケンスのタイムスタンプコンポーネントを抽出します。戻り値の型は timestamptz です。

概要

```
bdr.extract_timestamp_from_snowflakeid(snowflakeid bigint)
```

パラメーター

- snowflakeid —スノーフレーク ID シーケンスの値。

注

このファンクションは、ローカルノードでのみ実行されます。

bdr.extract_nodeid_from_snowflakeid

このファンクションは、snowflakeid シーケンスの nodeid コンポーネントを抽出します。

概要

```
bdr.extract_nodeid_from_snowflakeid(snowflakeid bigint)
```

パラメーター

- snowflakeid —スノーフレーク ID シーケンスの値。

注

このファンクションは、ローカルノードでのみ実行されます。

bdr.extract_localseqid_from_snowflakeid

このファンクションは、snowflakeid シーケンスのローカルシーケンス値コンポーネントを抽出します。

概要

```
bdr.extract_localseqid_from_snowflakeid(snowflakeid bigint)
```

パラメーター

- snowflakeid —スノーフレーク ID シーケンスの値。

注

このファンクションは、ローカルノードでのみ実行されます。

bdr.timestamp_to_snowflakeid

このファンクションは、タイムスタンプ値をダミーのスノーフレーク ID シーケンス値に変換します。

これは、スノーフレーク ID 列および特定のタイムスタンプのインデックス付き検索または値の比較を行う場合に役立ちます。

たとえば、 snowflakeid シーケンスを使用している列 id を持つテーブル foo があると、次のように昨日の午前 0 時からの変更数を取得できます。

```
SELECT count(1) FROM foo WHERE id > bdr.timestamp_to_snowflakeid(yesterday)
```

この方法で定式化された照会は、列 id のインデックススキャンを使用します。

概要

```
bdr.timestamp_to_snowflakeid(ts timestamptz)
```

パラメーター

- ts —スノーフレーク ID シーケンスの生成に使用するタイムスタンプ。

注

このファンクションは、ローカルノードでのみ実行されます。

bdr.extract_timestamp_from_timeshard

このファンクションは、timeshard シーケンスのタイムスタンプコンポーネントを抽出します。戻り値の型は timestamptz です。

概要

```
bdr.extract_timestamp_from_timeshard(timeshard_seq bigint)
```

パラメーター

- timeshard_seq —タイムハードシーケンスの値。

注

このファンクションは、ローカルノードでのみ実行されます。

bdr.extract_nodeid_from_timeshard

このファンクションは、timeshard シーケンスの nodeid コンポーネントを抽出します。

概要

```
bdr.extract_nodeid_from_timeshard(timeshard_seq bigint)
```

パラメーター

- timeshard_seq —タイムハードシーケンスの値。

注

このファンクションは、ローカルノードでのみ実行されます。

bdr.extract_localseqid_from_timeshard

このファンクションは、timeshard シーケンスのローカルシーケンス値コンポーネントを抽出します。

概要

```
bdr.extract_localseqid_from_timeshard(timeshard_seq bigint)
```

パラメーター

- timeshard_seq —タイムハードシーケンスの値。

注

このファンクションは、ローカルノードでのみ実行されます。

bdr.timestamp_to_timeshard

このファンクションは、タイムスタンプ値をダミーのタイムハードシーケンス値に変換します。

これは、timeshard 列および特定のタイムスタンプのインデックス付き検索または値の比較を実行する場合に役立ちます。

たとえば、 timeshard シーケンスを使用している列 id を持つテーブル foo があると、次のように昨日の午前 0 時からの変更数を取得できます。

```
SELECT count(1) FROM foo WHERE id > bdr.timestamp_to_timeshard(yesterday)
```

この方法で定式化された照会は、列 id のインデックススキャンを使用します。

概要

```
bdr.timestamp_to_timeshard(ts timestamptz)
```

パラメーター

- ts — Timeshard シーケンス生成に使用するタイムスタンプ。

注

このファンクションは、ローカルノードでのみ実行されます。

KSUUID v2 ファンクション

KSUUID v2 データ、K-Sortable UUID データを操作するためのファンクション。 *KSUUID in the sequences documentation* も参照してください。

bdr.gen_ksuuid_v2

このファンクションは、引数として渡されたタイムスタンプの値、または NULL が渡された場合は現在のシステム時間を使用して、新しい KSUUID v2 値を生成します。システム時間を使用して KSUUID を自動的に生成する場合は、NULL 引数を渡します。

戻り値の型は UUID です。

概要

```
bdr.gen_ksuuid_v2(timestamptz)
```

注

このファンクションは、ローカルノードでのみ実行されます。

bdr.ksuuid_v2_cmp

このファンクションは、KSUUID v2 値を比較します。

最初の値の方が新しい場合は 1、2 番目の値が小さい場合は-1、または等しい場合は 0 を返します。

概要

```
bdr.ksuuid_v2_cmp(uuid, uuid)
```

パラメーター

- UUID — KSUUID v2 と比較します。

注

このファンクションは、ローカルノードでのみ実行されます。

bdr.extract_timestamp_from_ksuuid_v2

このファンクションは、KSUUID v2 のタイムスタンプコンポーネントを抽出します。戻り値の型は timestamptz です。

概要

```
bdr.extract_timestamp_from_ksuuid_v2(uuid)
```

パラメーター

- UUID — KSUUID タイムスタンプを抽出する v2 値。

注

このファンクションは、ローカルノードでのみ実行されます。

KSUUID v1 ファンクション

KSUUID v1 データ、K-Sortable UUID データ v1 を操作するためのファンクション。非推奨 - 詳細については、

KSUUID in the sequences documentation を参照してください。

bdr.gen_ksuuid

このファンクションは、現在のシステム時間を使用して、新しい KSUUID v1 値を生成します。戻り値の型は UUID です。

概要

```
bdr.gen_ksuuid()
```

注

このファンクションは、ローカルノードでのみ実行されます。

bdr.uuid_v1_cmp

このファンクションは、KSUUID v1 値を比較します。

最初の値の方が新しい場合は 1、2 番目の値が小さい場合は-1、または等しい場合は 0 を返します。

概要

```
bdr.uuid_v1_cmp(uuid, uuid)
```

注

このファンクションは、ローカルノードでのみ実行されます。

パラメーター

- UUID — KSUUID v1 と比較します。

bdr.extract_timestamp_from_ksuuid

このファンクションは、KSUUID v1 または UUIDv1 値のタイムスタンプコンポーネントを抽出します。戻り値の型は timestamptz です。

概要

```
bdr.extract_timestamp_from_ksuuid(uuid)
```

パラメーター

- UUID — KSUUID タイムスタンプを抽出する v1 値。

注

このファンクションはローカルノードで実行されます。

9.1.12 Autopartition

オートパーティションを使用すると、テーブルを複数のパーティションに分割できます。詳細については、 垂直スケーリングまたはスケールアップ を参照してください。

bdr.autopartition

bdr.autopartition ファンクションは、テーブルの自動 RANGE パーティションを構成します。

概要

```
bdr.autopartition(relation regclass,
        partition_increment text,
        partition_initial_lowerbound text DEFAULT NULL,
        partition_autocreate_expression text DEFAULT NULL,
        minimum_advance_partitions integer DEFAULT 2,
        maximum_advance_partitions integer DEFAULT 5,
        data_retention_period interval DEFAULT NULL,
        managed_locally boolean DEFAULT false,
        enabled boolean DEFAULT on);
```

パラメーター

- relation —テーブルの名前または OID。
- partition_increment —次のパーティション作成までのインターバルまたはインクリメント。
- partition_initial_lowerbound —テーブルにパーティションがない場合、この下限と partition_increment 離れた上限を持つ最初のパーティションが作成されます。
- partition_autocreate_expression —新しいパーティションを作成する時期が来たかどうかを検出するために使用される式。
- minimum_advance_partitions —システムは、常に少なくとも minimum_advance_partitions パーティションを持とうとします。
- maximum_advance_partitions —事前パーティションの数が minimum_advance_partitions を下回った後に、一度に作成するパーティションの数。
- data_retention_period —古いパーティションが削除されるまでの間隔定義されている場合。この値は migrate_after_period より大きい必要があります。
- managed_locally —true の場合、パーティションはローカルに管理されます。
- enabled —アクティビティを無効または一時停止し、後で再開または再有効化できます。

例

日次パーティション、データを 1 か月間保持します

```
CREATE TABLE measurement (
logdate date not null,
peaktemp int,
unitsales int
) PARTITION BY RANGE (logdate);

bdr.autopartition(measurement, 1 day, data_retention_period := 30 days);
```

あと 2 つのパーティションのみが残っている場合、5 つの高度なパーティションを作成します。各パーティションには、10 億の注文を保持できます。

```
bdr.autopartition(Orders, 1000000000,
        partition_initial_lowerbound := 0,
        minimum_advance_partitions := 2,
        maximum_advance_partitions := 5
    );
```

bdr.drop_autopartition

bdr.drop_autopartition() を使用して、特定のリレーションの自動パーティションルールを削除します。リレーションの保留中の作業項目はすべて削除され、新しい作業項目は作成されません。

```
bdr.drop_autopartition(relation regclass);
```

パラメーター

- relation —テーブルの名前または OID。

bdr.autopartition_wait_for_partitions

パーティションの作成は非同期プロセスです。AutoPartition は、ローカルまたはすべてのノードでパーティションが作成されるのを待機する一連の機能を提供します。

bdr.autopartition_wait_for_partitions() を使用して、ローカルノードでパーティションの作成を待機します。ファンクションは、パーティションテーブル名とパーティションキー列値を取得し、その値を保持するパーティションが作成されるまで待機します。

このファンクションは、パーティションがローカルに作成されるのをのみ待機します。パーティションがリモートノードにも存在することは保証されません。

すべての PGD ノードでパーティションが作成されるのを待機するには、bdr.autopartition_wait_for_partitions_on_all_nodes() ファンクションを使用します。このファンクションは、ローカルノードとすべてのリモートノードを内部的にチェックし、パーティションがどこでも作成されるまで待機します。

概要

```
bdr.autopartition_wait_for_partitions(relation regclass, upperbound text);
```

パラメーター

- relation —テーブルの名前または OID。
- upperbound —パーティションキー列の値。

bdr.autopartition_wait_for_partitions_on_all_nodes

概要

```
bdr.autopartition_wait_for_partitions_on_all_nodes(relation regclass, upperbound␣
↪text);
```

パラメーター

- relation —テーブルの名前または OID。
- upperbound —パーティションキー列の値。

bdr.autopartition_find_partition

bdr.autopartition_find_partition() ファンクションを使用して、指定されたパーティションキー値のパーティションを見つけます。その値を保持するパーティションが存在しない場合、ファンクションは NULL を結果ます。それ以外の場合、パーティションの Oid が返されます。

概要

```
bdr.autopartition_find_partition(relname regclass, searchkey text);
```

パラメーター

- relname —パーティション分割テーブルの名前。
- searchkey —検索するパーティションキー値。

bdr.autopartition_enable

bdr.autopartition_enable を使用して、指定されたテーブルで AutoPartitioning を有効にします。AutoPartitioning が既に有効になっている場合、アクションは発生しません。特定のテーブルで自動パーティションを無効にするには、

:ref:``bdr.autopartition_disable` <*bdr.autopartition_disable*>` を参照してください。

概要

```
bdr.autopartition_enable(relname regclass);
```

パラメーター

- relname — AutoPartitioning を有効にするリレーションの名前。

bdr.autopartition_disable

bdr.autopartition_disable を使用して、指定されたテーブルで自動パーティションを無効にします。AutoPartitioning が既に無効になっている場合、アクションは発生しません。

概要

```
bdr.autopartition_disable(relname regclass);
```

パラメーター

- relname — AutoPartitioning を無効にする関係の名前。

内部ファンクション

bdr.autopartition_create_partition

AutoPartition は、内部ファンクション bdr.autopartition_create_partition を使用して、親テーブルにスタンドアロンの AutoPartition を作成します。

概要

```
bdr.autopartition_create_partition(relname regclass,
                                   partname name,
                                     lowerb text,
                                     upperb text,
                                     nodes oid[]);
```

パラメーター

- relname —アタッチする親テーブルの名前または Oid。
- partname —新しい AutoPartition の名前。
- lowerb —パーティションの下限。
- upperb —パーティションの上限。
- nodes —新しいパーティションが存在するノードのリスト。このパラメーターは PGD の内部であり、将来の使用のために予約されています。

注

これは、AutoPartition がパーティション管理に使用する内部機能です。このファンクションを直接使用しないことをお勧めします。

bdr.autopartition_drop_partition

AutoPartition は、内部ファンクション bdr.autopartition_drop_partition を使用して、データ保持ポリシーに従って、不要になったパーティションを削除します。パーティションテーブルのドロップが成功した場合、ファンクションは true を結果ます。

概要

```
bdr.autopartition_drop_partition(relname regclass)
```

パラメーター

- relname —ドロップするパーティションテーブルの名前。

注

このファンクションは、選択したパーティションテーブルで DROP TABLE を使用する前に、親テーブルに DDL ロックを配置します。この機能は、AutoPartition がパーティション管理に使用する内部ファンクションです。このファンクションを直接使用しないことをお勧めします。

9.1.13 Stream Triggers Reference

参考:

ストリームトリガーの概要については、 *Stream triggers* 。 !!!

競合トリガー と *Transform* トリガー は、トリガー API が提供する事前定義された変数と PGD が提供する追加情報ファンクションを介して、行とメタデータに関する情報にアクセスします。

PL/pgSQL では、次の事前定義された変数とファンクションを使用できます。

- *Stream triggers row variables*
- *Row Information functions*
- *bdr.trigger_get_row*
- *bdr.trigger_get_committs*
- *bdr.trigger_get_xid*
- *bdr.trigger_get_type*
- *bdr.trigger_get_conflict_type*
- *bdr.trigger_get_origin_node_id*
- *bdr.ri_fkey_on_del_trigger*

ストリームトリガーの作成とドロップは、操作インターフェイスを介して管理されます。

- *Stream triggers manipulation interfaces*
- *bdr.create_conflict_trigger*
- *bdr.create_transform_trigger*
- *bdr.drop_trigger*

Stream triggers manipulation interfaces

ストリームトリガーは、 REPLICA IDENTITY FULL があるテーブル、または TOAST が適用される列のないテーブルにのみ作成できます。

bdr.create_conflict_trigger

このファンクションは、新しい競合トリガーを作成します。

概要

```
bdr.create_conflict_trigger(trigger_name text,
                            events text[],
                            relation regclass,
                            function regprocedure,
                            args text[] DEFAULT {})
```

パラメーター

- trigger_name —新しいトリガーの名前。
- events —このトリガーを起動するイベントの配列。有効な値は’INSERT ‘、’UPDATE ‘、および’DELETE ’です。
- relation —このトリガーを発射する関係。
- function —実行するファンクション。
- args —オプショナル。トリガーファンクションが実行時に受け取るパラメーターの配列 TG_ARGV 変数の内容を指定します。

注

このファンクションは、 DDL ステートメントと同じレプリケーションメカニズムを使用します。これは、レプリケーションが *ddl filters* 構成の影響を受けることを意味します。

ファンクションは、トリガーが作成されているリレーションでグローバル DML ロックを取得します。

このファンクションはトランザクションです。トランザクションの ROLLBACK を使用してエフェクトをロールバックできます。変更は現在のトランザクションに表示されます。

通常の PostgreSQL トリガーと同様に、bdr.create_conflict_trigger ファンクションには、relation の TRIGGER 特権とファンクションの EXECUTE 特権が必要です。これは、bdr.backwards_compatibility が 30619 以上の場合に適用されます。PGD では、追加のセキュリティルールが競合トリガーを含むすべてのトリガーに適用されます。

> *Security and roles* を参照してください。

bdr.create_transform_trigger

このファンクションは、変換トリガーを作成します。

概要

```
bdr.create_transform_trigger(trigger_name text,
                             events text[],
                             relation regclass,
                             function regprocedure,
                             args text[] DEFAULT {})
```

パラメーター

- trigger_name —新しいトリガーの名前。
- events —このトリガーを起動するイベントの配列。有効な値は’INSERT ‘、’UPDATE ‘、および’DELETE ’です。
- relation —このトリガーを発射する関係。
- function —実行するファンクション。
- args —オプショナル。トリガーファンクションが実行時に受け取るパラメーターの配列 TG_ARGV 変数の内容を指定します。

注

このファンクションは、 DDL ステートメントと同じレプリケーションメカニズムを使用します。これは、レプリケーションが *ddl filters* 構成の影響を受けることを意味します。

ファンクションは、トリガーが作成されているリレーションでグローバル DML ロックを取得します。

このファンクションはトランザクションです。トランザクションの ROLLBACK を使用してエフェクトをロールバックできます。変更は現在のトランザクションに表示されます。

通常の PostgreSQL トリガーと同様に、bdr.create_transform_trigger ファンクションには、relation の TRIGGER 特権とファンクションの EXECUTE 特権が必要です。PGD では、追加のセキュリティルールが変換トリガーを含むすべてのトリガーに適用されます。

> *Security and roles* を参照してください。

bdr.drop_trigger

このファンクションは、既存のストリームトリガー競合と変換の両方を削除します。

概要

```
bdr.drop_trigger(trigger_name text,
                 relation regclass,
                 ifexists boolean DEFAULT false)
```

パラメーター

- trigger_name —既存のトリガーの名前。
- relation —トリガーが定義されている関係。
- ifexists — true に設定されている場合、このファンクションは不足しているトリガーを無視します。

注

このファンクションは、 DDL ステートメントと同じレプリケーションメカニズムを使用します。これは、レプリケーションが *ddl filters* 構成の影響を受けることを意味します。

ファンクションは、トリガーが作成されているリレーションでグローバル DML ロックを取得します。

このファンクションはトランザクションです。トランザクションの ROLLBACK を使用してエフェクトをロールバックできます。変更は現在のトランザクションに表示されます。

relation の所有者のみが bdr.drop_trigger ファンクションを実行できます。

Stream triggers row functions

bdr.trigger_get_row

このファンクションは、識別子で指定されたトリガー行の内容を RECORD として結果ます。このファンクションは、不適切に呼び出された場合、つまり操作タイプ TG_OP が DELETE のときに SOURCE_NEW で呼び出された場合、NULL を結果ます。

概要

```
bdr.trigger_get_row(row_id text)
```

パラメーター

- row_id —行の識別子。トリガータイプと操作に応じて、SOURCE_NEW 、SOURCE_OLD 、および TARGET のいずれかになります。個々のトリガータイプの説明を参照してください。

bdr.trigger_get_committs

このファンクションは、識別子で指定されたトリガー行のコミットタイムスタンプを結果ます。行が固定されているか使用できないために使用できない場合、NULL を返します。行識別子 SOURCE_OLD の場合は、常に NULL を結果ます。

概要

```
bdr.trigger_get_committs(row_id text)
```

パラメーター

- row_id —行の識別子。トリガータイプと操作に応じて、SOURCE_NEW 、SOURCE_OLD 、および TARGET のいずれかになります。個々のトリガータイプの説明を参照してください。

bdr.trigger_get_xid

このファンクションは、識別子で指定された TARGET 行のローカルトランザクション ID を結果ます。行が固定されているか使用できないために使用できない場合、NULL を返します。 SOURCE_OLD および SOURCE_NEW 行識別子の場合は、常に NULL を結果ます。

競合トリガーでのみ使用できます。

概要

```
bdr.trigger_get_xid(row_id text)
```

パラメーター

- row_id —行の識別子。トリガータイプと操作に応じて、SOURCE_NEW 、SOURCE_OLD 、および TARGET のいずれかになります。個々のトリガータイプの説明を参照してください。

bdr.trigger_get_type

このファンクションは、現在のトリガータイプ、CONFLICT または TRANSFORM を結果ます。ストリームトリガーの外部で呼び出された場合、null を返します。

概要

```
bdr.trigger_get_type()
```

bdr.trigger_get_conflict_type

このファンクションは、競合トリガー内で呼び出された場合、現在の競合タイプを結果ます。それ以外の場合は、NULL を返します。

> 競合タイプのリスト を参照

このファンクションの考えられる戻り値については、

概要

```
bdr.trigger_get_conflict_type()
```

bdr.trigger_get_origin_node_id

このファンクションは、引数として渡されたトリガー row_id の起点に対応するノード ID を結果ます。オリジンが有効でない場合、行がローカルに生成されたことを意味します、トリガー行引数に応じて、ソースまたはターゲットノードのノード ID を結果ます。行識別子 SOURCE_OLD の場合は、常に NULL を結果ます。この機能を使用して、競合トリガーを定義して、常に信頼できるソースノードを優先できます。

概要

```
bdr.trigger_get_origin_node_id(row_id text)
```

パラメーター

- `row_id` —行の識別子。トリガータイプと操作に応じて、`SOURCE_NEW`、`SOURCE_OLD`、および `TARGET` のいずれかになります。個々のトリガータイプの説明を参照してください。

bdr.ri_fkey_on_del_trigger

BEFORE トリガーとして呼び出される場合、このファンクションは FOREIGN KEY 情報を使用して FK 異常を回避します。

概要

```
bdr.ri_fkey_on_del_trigger()
```

Stream triggers row variables

TG_NAME

データ型の名前。この変数には、実際に起動されたトリガーの名前が含まれています。実際のトリガー名には、トリガーの作成中に指定された名前と比較して、'_bdrt' または '_bdrc' サフィックストリガータイプによって異なります。

TG_WHEN

データ型テキスト。この変数は、競合トリガーと変換トリガーの両方で `BEFORE` を示します。 `bdr.trigger_get_type()` 情報ファンクションを呼び出すことにより、ストリームトリガータイプを取得できます。

bdr.trigger_get_type を参照してください。

TG_LEVEL

データ型 text ROW の文字列。

TG_OP

データタイプ text トリガーが起動されたオペレーションを識別する INSERT 、UPDATE 、または DELETE の文字列。

TG_RELID

データ型 oid トリガー呼び出しの原因となったテーブルのオブジェクト ID。

TG_TABLE_NAME

データ型名 トリガーの呼び出しを発生させたテーブルの名前。

TG_TABLE_SCHEMA

データ型名トリガー呼び出しの原因となったテーブルのスキーマの名前。パーティションテーブルの場合、これはルートテーブルの名前です。

TG_NARGS

データ型整数 bdr.create_conflict_trigger() または bdr.create_transform_trigger() ステートメントのトリガーファンクションに指定された引数の数。

TG_ARGV[]

テキストのデータ型配列 bdr.create_conflict_trigger() または bdr.create_transform_trigger() ステートメントの引数。インデックスは 0 からカウントします。無効なインデックス 0 未満または TG_NARGS 以上の場合、 NULL 値になります。

9.1.14 Internal catalogs and views

ここでは、カタログとビューがアルファベット順に表示されています。

bdr.ddl_epoch

DDL エポックごとの状態を保持する内部カタログテーブル。

bdr.ddl_epoch 列

Name	Type	Description
ddl_epoch	int8	単調増加のエポック番号
origin_node_id	oid	このエポックの作成を要求したノードの内部ノード ID
epoch_consume_timeout	timestamptz	このエポックのタイムアウト
epoch_consumed	boolean	ローカルノードがエポックを完全に処理するとすぐに true に切り替えます
epoch_consumed_lsn	boolean	ローカルノードがエポックを処理した LSN

bdr.event_history

特定の PGD ノードのクラスターメンバーシップイベントを追跡する内部カタログテーブル。具体的には、以下を追跡します。

*ノードがクラスターに参加します

- Raft の状態の変更つまりノードがコンセンサスプロトコルでのロールを変更するたびにリーダー、フォロワー、または候補からリーダーへ *Monitoring Raft* **コンセンサス** を参照してください

*ワーカーがエラーアウトしたとき *bdr.workers* を参照

および *PGD* **レプリケーションワーカーのモニタリング**)

bdr.event_history 列

Name	Type	Description
event_node_id	oid	イベントが参照するノードの ID
event_type	int	イベントのタイプノード、raft、またはワーカー関連イベント
event_sub_type	int	イベントのサブタイプ、つまり、参加、状態変更、またはエラーの場合
event_source	text	イベントがソースされたワーカープロセスの名前
event_time	timestamptz	イベントが発生したタイムスタンプ
event_text	text	イベントのテキスト表現ワーカーのエラーなど

次のページに続く

表 56 – 前のページからの続き

Name	Type	Description
event_detail	text	イベントのより詳細な説明今のところ、ワーカーエラーにのみ関連します

bdr.event_summary

より人に優しい形式で情報を表示する bdr.event_history カタログのビュー。具体的には、イベントタイプとサブタイプを整数ではなくテキスト表現として表示します。

bdr.node_config

ノードごとの構成オプションを含む内部カタログテーブル。

bdr.node_config 列

Name	Type	Description
node_id	oid	ノード ID
node_route_priority	int	このノードに割り当てられた優先度
node_route_fence	boolean	このノードをフェンスするように切り替えます
node_route_writes	boolean	書き込みを許可するスイッチ
node_route_reads	boolean	読み取りを許可するようにスイッチ
node_route_dsn	text	このノードのインターフェイス

bdr.node_group_config

ノードグループごとの構成オプションを含む内部カタログテーブル。

bdr.node_group_config 列

Name	Type	Description
node_group_id	oid	ノードグループ ID
route_writer_max_lag	bigint	受け入れられる最大書き込み遅延
route_reader_max_lag	bigint	受け入れられる最大読み取り遅延
route_writer_wait_flush	boolean	フラッシュを待機する必要がある場合にスイッチ

bdr.node_group_routing_config_summary

ノードグループごとのルーティング構成オプション。

bdr.node_group_routing_info

プロキシの現在のルーティング情報を保持する内部カタログテーブル。

bdr.node_group_routing_info 列

Name	Type	Description
node_group_id	oid	このプロキシが使用するノードグループ ID
write_node_id	oid	現在の書き込みノード
prev_write_node_id	oid	以前の書き込みノード
read_node_ids	oid[]	読み取りノード ID のリスト

bdr.node_group_routing_summary

情報をより分かりやすく表示する bdr.node_group_routing_info カタログのビュー

bdr.node_routing_config_summary

ノードごとのルーティング構成オプション。

bdr.proxy_config

プロキシ固有の構成を保持する内部カタログテーブル。

bdr.proxy_config 列

Name	Type	Description
proxy_name	name	プロキシの名前
node_group_id	oid	このプロキシが使用するノードグループ ID
listen_port	int	プロキシが使用するポート
max_client_conn	int	プロキシが受け入れる最大クライアント接続数
max_server_conn	int	サーバーが受け入れる最大接続数

次のページに続く

表 60 – 前のページからの続き

Name	Type	Description
server_conn_timeout	interval	サーバー接続のタイムアウト
server_conn_keepalive	interval	サーバー接続キープアライブ間の間隔
fall-back_group_timeout	interval	フォールバックに必要なタイムアウト
fallback_group_ids	oid[]	フォールバックに使用されるグループ ID のリスト
listen_addrs	text[]	リッスンアドレス

bdr.proxy_config_summary

プロキシインスタンスごとに固有の構成オプション。

bdr.sequence_kind

各非ローカルシーケンスのタイプを格納する内部状態テーブル。診断にはビュー `bdr.sequences` をお勧めします。

`bdr.sequence_kind` 列

Name	Type	Description
seqid	oid	シーケンスの内部 OID
seqkind	char	内部シーケンス種類'l'=local、't'=timeshard、's'=snowflakeid、'g'=galloc

9.1.15 Internal system functions

以下に内部システム機能をリストします。多くはさまざまなビューの作成に使用されます。ファンクションを直接使用せず、それらが提供するビューを使用することをお勧めします。

一般的な内部ファンクション

bdr.decode_message_response_payload

コンセンサスペイロードをより人間が読みやすい出力にデコードする PGD メッセージペイロードファンクション。主に `bdr.global_consensus_journal_details` デバッグビューによって使用されます。

bdr.decode_message_payload

コンセンサスペイロードをより人間が読みやすい出力にデコードする PGD メッセージペイロードファンクション。主に bdr.global_consensus_journal_details デバッグビューによって使用されます。

bdr.get_global_locks

このファンクションは、ローカルノードで保持されているグローバルロックに関する情報を表示します。

bdr.global_locks ビューを実装して、ロックのより詳細な概要を提供するために使用されます。

bdr.get_slot_flush_timestamp

特定のレプリケーションスロットの最後のフラッシュ位置確認のタイムスタンプを取得します。

bdr.node_slots ビューを実装するために内部で使用されます。

bdr.internal_alter_sequence_set_kind

さまざまなファンクション呼び出しのレプリケーションに内部で使用される PGD 内部ファンクション。

PGD の現在のバージョンでは使用されなくなりました。ローリングアップグレード中の下位互換性のためのみに存在します。

bdr.internal_replication_set_add_table

さまざまなファンクション呼び出しのレプリケーションに内部で使用される PGD 内部ファンクション。

PGD の現在のバージョンでは使用されなくなりました。ローリングアップグレード中の下位互換性のためのみに存在します。

bdr.internal_replication_set_remove_table

さまざまなファンクション呼び出しのレプリケーションに内部で使用される PGD 内部ファンクション。

PGD の現在のバージョンでは使用されなくなりました。ローリングアップグレード中の下位互換性のためのみに存在します。

bdr.internal_submit_join_request

新しいノードに参加するためのコンセンサス要求を送信します。

PGD グループの再構成の内部メカニズムに必要です。

bdr.isolation_test_session_is_blocked

グローバルロック上のブロックのチェックを追加して、元の pg_isolation_test_session_is_blocked を拡張および実際に呼び出すヘルパーファンクション。

分離/同時実行テストに使用されます。

bdr.local_node_info

このファンクションは、PGD グループ再構成の内部メカニズムが必要とするローカルノードの情報を表示します。

ビュー bdr.local_node_summary は、ユーザーの使用に役立つ同様の情報を提供します。

bdr.msgb_connect

コンセンサスプロトコルで使用される、別のノードの接続プーラーに接続する機能。

bdr.msgb_deliver_message

コンセンサスプロトコルで使用される、別のノードの接続プーラーにメッセージを送信する機能。

bdr.peer_state_name

このファンクションは、ノード状態 node_state をテキスト表現に変換し、主に bdr.node_summary ビューを実装するために使用されます。

bdr.request_replay_progress_update

’リプレイ進行状況の更新’Raft メッセージの即時書き込みを要求します。これは、主にテスト目的で使用されますが、コンセンサスメカニズムが機能しているかどうかをテストするために使用することもできます。

bdr.seq_nextval

シーケンスインクリメントの内部実装。

> *PGD* グローバルシーケンス と対話するクエリーで標準の nextval

の代わりにこのファンクションを使用します。

注

以下も内部 PGD シーケンス操作ファンクションです。 bdr.seq_currval および bdr.sql_lastval は自動的に使用されます。

bdr.show_subscription_status

サブスクリプションステータスに関する情報を取得し、主に bdr.subscription_summary ビューを実装するために使用されます。

bdr.get_node_conflict_resolvers

ローカルノード上のすべての競合リゾルバーのテキスト文字列を表示します。

bdr.reset_subscription_stats

bdr.stat_subscription によって表示される、サブスクリプションによって作成された統計をリセットした後、ブール結果を返します。

bdr.reset_relation_stats

bdr.stat_relation によって表示される、リレーション統計をリセットした後、ブール結果を返します。

bdr.pg_xact_origin

指定されたトランザクションのオリジン ID を返します。

概要

```
bdr.pg_xact_origin(xmin xid)
```

パラメーター

- xid —オリジンが返されるトランザクション ID、

bdr.difference_fix_origin_create

引数として渡された指定された名前を使用して、レプリケーションオリジンを作成しますが、bdr_ 接頭辞を追加します。オリジンの内部 ID を結果ます。これは、pg_replication_origin_create() と同じ機能を実行しますが、postgres スーパーユーザー権限ではなく bdr_superuser が必要です。

bdr.difference_fix_session_setup

現在のセッションを現在のオリジンから再生するものとしてマークします。ファンクションは、事前に作成された bdr_local_only_origin ローカルレプリケーションオリジンをセッションに暗黙的に使用します。これにより、再生の進行状況を報告でき、void を返します。このファンクションは、pg_replication_origin_session_setup() と同じ機能を実行しますが、このファンクションは postgres スーパーユーザー権限ではなく bdr_superuser を必要とする点が異なります。ファンクションの以前の形式 bdr.difference_fix_session_setup(text) は非推奨であり、今後のリリースで削除される予定です。

概要

```
bdr.difference_fix_session_setup()
```

bdr.difference_fix_session_reset

現在のセッションをオリジンから再生しないものとしてマークし、本質的に bdr.difference_fix_session_setup() のエフェクトをリセットします。void を返します。このファンクションは、pg_replication_origin_session_reset() と同じ機能がありますが、このファンクションは postgres スーパーユーザー権限ではなく bdr_superuser を必要とする点を除きます。

概要

```
bdr.difference_fix_session_reset()
```

bdr.difference_fix_xact_set_avoid_conflict

現在のトランザクションを、LSN ’0/0’ およびタイムスタンプ’2000-01-01’でコミットしたトランザクションを再生するものとしてマークします。このファンクションは、postgres スーパーユーザー権限ではなく bdr_superuser 権限を必要とすることを除き、`pg_replication_origin_xact_setup('0/0', '2000-01-01')` と同じ機能があります。

概要

```
bdr.difference_fix_xact_set_avoid_conflict()
```

bdr.resynchronize_table_from_node

リモートノードから関係を再同期します。

概要

```
bdr.resynchronize_table_from_node(node_name name, relation regclass)
```

パラメーター

- `node_name` —リレーションデータをコピーまたは再同期するノード。
- `relation` —リモートノードからのコピーに関する関係。

注

このファンクションは、リレーションのグローバル DML ロックを取得し、リレーションをローカルで切り捨て、リモートノードからデータをコピーします。

リレーションは、同じ名前と定義を持つ両方のノードに存在する必要があります。

以下がサポートされています。

- 同一のパーティション定義を使用したパーティションテーブルの再同期
- パーティション化されたテーブルと非パーティションテーブルへの再同期、およびその逆の再同期
- 外部キー制約を一時的に削除および再作成することによる参照テーブルの再同期

参照されるテーブルでファンクションを実行した後、参照される列データが参照列値と一致しない場合、エラーがスローされます。参照テーブルデータを再同期した後、ファンクションを再実行します。

さらに、リモートノードからデータをコピーした後、生成された列の値をローカルに計算することにより、生成された列とテーブルの再同期をサポートします。

現在、 row_filters はこのファンクションによって無視されます。

bdr.resynchronize_table_from_node ファンクションは、テーブルの所有者が bdr_superuser 権限を持っている場合にのみ実行できます。

bdr.consensus_kv_store

一貫した KV ストアに値を保存します。

値の有効期限のタイムスタンプを返します。これは ttl に依存します。ttl が NULL の場合、これは infinity を結果ます。値が削除された場合、-infinity を返します。

概要

```
bdr.consensus_kv_store(key text, value jsonb,
        prev_value jsonb DEFAULT NULL, ttl int DEFAULT NULL)
```

パラメーター

- key —挿入、更新、または削除する任意の一意のキー。
- value —保存する JSON 値。NULL の場合、既存のレコードは削除されます。
- prev_value —設定されている場合、書き込み操作は、現在の値が prev_value と等しい場合にのみ実行されます。
- ttl —新しい値の生存時間ミリ秒単位。

注

これは内部ファンクションであり、主に HARP によって使用されます。

> **警告:** ユーザアプリケーションではこのファンクションを使用しないでください。

bdr.consensus_kv_fetch

一貫した KV ストアから JSON 形式で値を取得します。

概要

```
bdr.consensus_kv_fetch(IN key text) RETURNS jsonb
```

パラメーター

- key —取得する任意のキー。

注

これは内部ファンクションであり、主に HARP によって使用されます。

> **警告:** ユーザアプリケーションではこの機能を使用しないでください。

タスクマネージャー機能

bdr.taskmgr_set_leader

指定された node をタスクマネージャーリーダーノードになるように要求します。リーダーノードは、新しいタスクを作成します。現在、自動パーティションのみがこの機能を利用します。監視ノード、ロジカルスタンバイ、またはサブスクライバ専用ノードは、リーダーになることはできません。このような要求は ERROR で失敗します。

概要

```
bdr.taskmgr_set_leader(node name, wait_for_completion boolean DEFAULT true);
```

bdr.taskmgr_get_last_completed_workitem

クラスター内のすべてのノードで正常に完了した最後の作業項目の id を返します。

概要

```
bdr.taskmgr_get_last_completed_workitem();
```

bdr.taskmgr_work_queue_check_status

この機能を使用すると、タスクを生成および終了するジョブを実行しているバックグラウンドワーカーのステータスを確認できます。

ステータスは、次のビューで確認できます。bdr.taskmgr_work_queue_local_status bdr.taskmgr_work_queue_global_status

概要

```
bdr.taskmgr_work_queue_check_status(workid bigint
                            local boolean DEFAULT false);
```

パラメーター

- workid —タスクのキー。
- local —ローカルステータスのみを確認します。

注

Taskmgr ワーカーは、bdr.autopartition ファンクションが初めて呼び出される前でも、常にバックグラウンドで実行されています。無効な workid が使用される場合、ファンクションは unknown を結果ます。In-progress は一般的なステータスです。

bdr.node_catchup_state_name

name のキャッチアップ状態コードを変換する

概要

```
bdr.node_catchup_state_name(catchup_state oid);
```

パラメーター

- catchup_state —キャッチアップ状態の OID コード。

bdr.bdr_track_commit_Decision

トランザクションのコミットステータスを共有メモリハッシュテーブルに保存します。これは、アップグレードスクリプトが bdr.node_pre_commit カタログに保存されたコミット決定を共有メモリハッシュテーブルに転送するために使用されます。これも WAL にログに記録されるため、WAL からリロードできます。

概要

```
bdr.bdr_track_commit_decision(OID, xid, xid, "char", timestamptz, boolean);
```

bdr.bdr_get_commit_decions

共有メモリの状態を検査する便利なルーチン

概要

```
bdr.bdr_get_commit_decisions(dbid OID,
            origin_node_id OID,
            origin_xid xid,
            local_xid xid,
            decision "char",
            decision_ts timestamptz,
            is_camo boolean)
```

bdr.show_workers

bdr ワーカーに関連する情報。

概要

```
bdr.show_workers(
    worker_pid int,
    worker_role int,
    worker_role_name text,
    worker_subid oid
```

bdr.show_writers

bdr.writers ビューで使用されるファンクション。

bdr.node_kind_name

ノード種類の人間にわかりやすい名前を返しますデータ|スタンバイ|Witness|サブスクライバーのみ