



Ай-ТИ Фреш

ТЕХНИЧЕСКИЙ РАЗБОР

PostgreSQL 18: remote_apply, когда **SELECT не видит COMMIT**

WAL, сброшенный на диск реплики, ещё не значит «строка видна SELECT»

Июль 2026

itfresh.ru · ИТ-аутсорсинг для юридических лиц

Суть проблемы

Синхронная репликация включена ради защиты от потери транзакций при отказе primary. Приложение делает COMMIT и тут же читает данные с реплики — строки нет. Причина не в сети: `synchronous_commit=on` ждёт flush WAL на реплике, но не ждёт replay записей в таблицы, а видимость для SELECT даёт только replay. Точечный `remote_apply` закрывает разрыв, не удорожая поток коммитов.

Почему это важно бизнесу

- Кассовый или складской заказ на секунду «пропадает» на реплике — оператор создаёт дубликат вручную
- Отчёты на read-реплике расходятся с данными primary ровно в момент сверки
- Оплаты, отгрузки и медицинские записи требуют строгой согласованности чтения после записи
- Разбор инцидента затягивается: мониторинг показывает лаг 0 мс по flush, а проблема в replay
- Неверный уровень `synchronous_commit` либо режет производительность, либо не даёт нужной гарантии

Ключевые параметры реализации

18.x

версия кластера, на которой проверяем поведение `remote_apply` перед внедрением

PostgreSQL 18, разд. 19.5

5 значений

`synchronous_commit`:
`off/local/remote_write/on/remote_apply`,
по умолчанию `on`

PostgreSQL 18, разд. 19.5

30 с

`max_standby_streaming_delay` по умолчанию — до отмены конфликтующего запроса на реплике

PostgreSQL 18, разд. 19.6

10 с

`wal_receiver_status_interval` — с этим шагом реплика шлёт `write/flush/replay LSN`

PostgreSQL 18, разд. 19.6

60 с

`wal_receiver_timeout` — порог обрыва соединения приёмника WAL при молчании `primary`

PostgreSQL 18, разд. 19.6

ANY 2

наш шаблон `synchronous_standby_names` для кворума из трёх реплик

PostgreSQL 18, разд. 26.2.8.2

Настройка `synchronous_commit` под `read-after-write`

Что настраиваем

Кластер PostgreSQL 18: 1 primary + 2-3 synchronous standby, учётные и складские базы клиента

Как мы это делаем

- 1 Помечаем транзакции, которым нужна видимость: `SET LOCAL synchronous_commit = remote_apply` перед `COMMIT` оплаты или резерва склада
- 2 Фоновый трафик (логи, аналитика) оставляем на `synchronous_commit = on` — ожидание `replay` дороже ожидания `flush`
- 3 `synchronous_standby_names = 'ANY 2 (standby1, standby2, standby3)'` — кворум вместо приоритетного списка `FIRST`
- 4 Чтение сразу после записи шлём на `primary` либо на реплику, у которой `pg_last_wal_replay_lsn()` догнал `LSN` коммита
- 5 Разрыв `LSN` меряем под нагрузкой `pgbench`: `pg_current_wal_lsn()` против `pg_last_wal_replay_lsn()` до прод-релиза

РЕЗУЛЬТАТ

Связка «оплата — проверка статуса» перестаёт терять свежие строки, а фоновая аналитика не платит лишней задержкой коммита там, где строгая согласованность чтения не требуется

КЛЮЧЕВОЙ НЮАНС

`remote_apply` на весь кластер заставляет каждый `COMMIT` ждать самую медленную реплику по `replay`, а не по `flush` — это самый дорогой уровень, включаем его только на нужных транзакциях



Мониторинг разрыва write/flush/replay LSN

Что настраиваем

Все синхронные и асинхронные реплики кластера, метрики снимаются с *primary* из *pg_stat_replication*

Как мы это делаем

- 1 На *primary* опрашиваем *pg_stat_replication*: *sent_lsn*, *write_lsn*, *flush_lsn*, *replay_lsn*, *write_lag*, *flush_lag*, *replay_lag*, *sync_state*
- 2 Байтовый лаг применения считаем как *pg_wal_lsn_diff(pg_current_wal_lsn(), replay_lsn)* — это и есть невидимый COMMIT в байтах
- 3 На самой реплике снимаем *pg_last_wal_replay_lsn()* и *pg_last_xact_replay_timestamp()* — отставание в секундах для отчёта
- 4 Алерты на *flush_lag* и *replay_lag* заводим отдельно: *flush_lag* около нуля при растущем *replay_lag* — прямой признак разрыва чтения
- 5 *sync_state* отслеживаем в значениях *sync/quorum/potential/async*: уход реплики в *potential* меняет состав кворума молча

РЕЗУЛЬТАТ

На дашборде видно две разные величины — задержку записи WAL и задержку видимости данных, вместо одного усреднённого «лага репликации», который маскирует ровно ту проблему, из-за которой открыт тикет

КЛЮЧЕВОЙ НЮАНС

flush_lag и *replay_lag* в *pg_stat_replication* — разные метрики; жалобу «COMMIT прошёл, SELECT не видит» разбираем строго по *replay_lag* и *replay_lsn*



Отказоустойчивость кворума при деградации реплики

Что настраиваем

Продовые кластеры с 2-3 синхронными standby на разных площадках клиента

Как мы это делаем

- 1 `synchronous_standby_names` задаём как ANY N вместо одиночного имени — потеря одной реплики не останавливает запись
- 2 `max_standby_streaming_delay` и `max_standby_archive_delay` поднимаем выше дефолтных 30 с только на отчётных репликах
- 3 Отложенную копию держим отдельным `async standby` с `recovery_min_apply_delay = 15min` — защита от логической порчи данных
- 4 Гасим одну реплику на учениях: при ANY 2 из 3 коммиты продолжаются, пока живы любые две реплики
- 5 Прогоняем `pg_promote()` на кандидате и сверяем, что новый `primary` не потерял транзакции, подтверждённые `remote_apply`

РЕЗУЛЬТАТ

Кластер переживает деградацию одной реплики без остановки записи и без потери подтверждённых клиенту транзакций, а `delayed standby` закрывает сценарий UPDATE или DELETE без WHERE

КЛЮЧЕВОЙ НЮАНС

При `synchronous_commit = remote_apply` каждый COMMIT ждёт применения WAL, поэтому реплику с `recovery_min_apply_delay` держим асинхронной и вне `synchronous_standby_names`



Подводные камни

✗ **on принимают за гарантию видимости**

on ждёт flush WAL на реплике, но не replay: SELECT сразу после COMMIT может не увидеть строку. Для read-after-write нужен remote_apply

✗ **remote_apply включают на весь кластер**

Коммит начинает ждать самую медленную реплику по replay, а не по flush. Включаем через SET LOCAL только в нужных транзакциях

✗ **FIRST там, где нужен ANY**

FIRST требует живыми именно первые в списке реплики: падение одной блокирует запись, хотя кворум есть. Переводим на ANY N

✗ **hot_standby_feedback не включён**

По умолчанию off, и долгие SELECT на реплике падают с conflict with recovery. Включаем на отчётных репликах, следя за bloat на primary

✗ **мониторят только sync_state**

Значение sync ничего не говорит о величине отставания. Нужен отдельный алерт на replay_lag и pg_wal_lsn_diff по replay_lsn

✗ **delay ставят на синхронную реплику**

С recovery_min_apply_delay и remote_apply каждый COMMIT ждёт окончания задержки применения. Такую реплику держим асинхронной

✗ **wal_level занижают до minimal**

При minimal требуется max_wal_senders = 0, физическая репликация невозможна. Проверяем wal_level = replica (дефолт) или logical

✗ **путают flush_lsn и replay_lsn**

Разница по flush_lsn показывает нулевую задержку записи, тогда как проблема в задержке replay. В разборе посмотрим обе величины

Как правильно

МИНИМУМ

- `synchronous_commit = on` и хотя бы одна реплика в `synchronous_standby_names`
- Базовый съём `pg_stat_replication`: `sync_state`, `state` и состав активных реплик
- `wal_level = replica` и физический слот репликации на каждую реплику

НОРМАЛЬНО

- `synchronous_standby_names` в форме ANY N для кворума из 2–3 реплик
- Раздельные алерты на `flush_lag` и `replay_lag` вместо общего «лага репликации»
- `hot_standby_feedback = on` на репликах, которые держат отчётные SELECT
- `max_standby_streaming_delay` подобран под профиль запросов конкретной реплики

ХОРОШО

- SET LOCAL `synchronous_commit = remote_apply` для read-after-write транзакций
- Маршрутизация чтения по replay LSN вместо случайного round-robin
- Async standby с `recovery_min_apply_delay` как защита от логической порчи
- Учения `pg_promote()` с проверкой сохранности данных, подтверждённых `remote_apply`



Чек-лист самопроверки

- | | |
|---|--|
| ☐ Зафиксировано, какие транзакции требуют <code>synchronous_commit = remote_apply</code> , а какие обойдутся <code>on</code> ? | ☐ Есть отдельный <code>delayed standby</code> с <code>recovery_min_apply_delay</code> вне синхронного кворума? |
| ☐ <code>synchronous_standby_names</code> задан как ANY-кворум, а не как единственная точка отказа FIRST 1? | ☐ Чтение сразу после записи маршрутизируется по <code>replay LSN</code> , а не случайным <code>round-robin</code> ? |
| ☐ Мониторинг разделяет <code>flush_lag</code> и <code>replay_lag</code> , а не показывает один усреднённый лаг? | ☐ <code>wal_level</code> , <code>max_wal_senders</code> и слоты репликации перепроверены после апгрейда до 18.x? |
| ☐ <code>hot_standby_feedback</code> включён там, где реплика держит длинные отчётные запросы? | ☐ Проводились учения с выключением синхронной реплики без остановки записи на <code>primary</code> ? |

Если хотя бы на два вопроса ответ «нет» или «не знаю» — тема требует внимания.



Как поможет ITFresh

ITFresh — ИТ-аутсорсинг для юридических лиц до 50 рабочих мест в Москве и области. 15+ лет практики, собственная инфраструктура в дата-центре МТС (8 серверов Dell Xeon Platinum).

- Проектируем и настраиваем синхронную и асинхронную репликацию PostgreSQL под нагрузку клиента
- Разводим read-after-write трафик приложения между primary и репликами по replay LSN
- Строим мониторинг с отдельными метриками `flush_lag` и `replay_lag` и алертами до жалоб
- Настраиваем кворум ANY N и `delayed standby` как защиту от логических ошибок в данных
- Проводим учения `pg_promote()` и аудит конфигурации WAL и репликации при апгрейде кластера

15+

лет в ИТ-поддержке

50

рабочих мест — наш профиль

МТС

дата-центр, Москва



КОНТАКТЫ

Обсудить вашу задачу

Сайт **itfresh.ru**

Телефон **+7 903 729-62-41**

Telegram **@ITfresh_Boss**

Бесплатно посмотрим вашу инфраструктуру по этому чек-листу и скажем, где тонко — без обязательств.



itfresh.ru



Техническая база

- 01** 19.5 Write Ahead Log — `synchronous_commit`, `wal_level` (postgresql.org — 18)
- 02** 19.6 Replication — `hot_standby_feedback`, `standby delay` (postgresql.org — 18)
- 03** 26.2.8 Synchronous Replication (postgresql.org — 18)
- 04** 26.2.8.2 Multiple Synchronous Standbys — FIRST и ANY (postgresql.org — 18)
- 05** 26.2.6 Replication Slots и 26.2.7 Cascading Replication (postgresql.org — 18)
- 06** 26.4.2 Handling Query Conflicts (postgresql.org — 18)
- 07** 27.2.4 `pg_stat_replication` — write/flush/replay lag (postgresql.org — 18)
- 08** 28.4 Asynchronous Commit (postgresql.org — 18)

