Репликация
Переключение на реплику

Авторы: Егор Рогов, Павел Лузанов, Илья Баштанов

Обратная связь
Отзывы, замечания и предложения направляйте по адресу:
edu@postgrespro.ru

Темы

Переключение на реплику

Особенности, связанные с файловым архивом

Возвращение в строй бывшего мастера

Переключение на реплику

Причины

плановое переключение (switchover):
останов основного сервера для проведения технических работ

аварийное переключение (failover):
переход на реплику из-за сбоя основного сервера

Процедура

убедиться, что мастер остановлен

`$ pg_ctl promote` или
promote_trigger_file или
`pg_promote()`

автоматическое переключение: отсутствует
(для автоматизации требуется стороннее кластерное ПО)

Причиной перехода на резервный сервер может быть необходимость проведения технических работ на основном сервере — тогда переход выполняется в удобное время в штатном режиме (switchover). А может быть сбой основного сервера, и в таком случае переходить на резервный сервер нужно как можно быстрее, чтобы сократить время простоя системы (failover).

В любом случае сначала нужно убедиться, что мастер остановлен. Это очень важно, иначе данные на разных серверах «разойдутся», и свести их потом воедино — нетривиальная и неавтоматизируемая задача. Скорее всего, часть данных придется просто потерять.

Затем выполняется переход на реплику в ручном режиме. Автоматизация этого процесса возможна, но требует стороннего кластерного программного обеспечения (это обсуждается в модуле «Кластерные технологии»).

Переключение состоит в разрыве цикла восстановления. Для этого реплике посылается команда promote: либо командой pg_ctl promote, либо вызовом функции pg_promote из SQL. Другой вариант — задать имя файла в параметре *promote_trigger_file*. При появлении в системе файла с таким именем восстановление прерывается.

Еще один вариант: удалить файл standby.signal и перезапустить резервный сервер. Это не вполне «честный» способ, поскольку в этом случае реплика не поймет, что восстановление завершено, и не перейдет на новую линию времени. Дальше мы будем рассматривать только два первых варианта.

Действия при переходе

Применяются журнальные записи

- уже полученные wal receiver, но еще не примененные startup

Завершаются процессы

- wal receiver
- startup

Запускаются процессы

- wal writer
- autovacuum launcher
- archiver (зависит от настройки)

Переход на новую линию времени

Получив сигнал, сервер завершает восстановление и переходит в обычный режим работы.

Для этого он применяет уже полученные журнальные записи, которые еще не были применены.

Процессы wal receiver и startup завершают свою работу — на основном сервере они не нужны. А вот процессы wal writer и autovacuum launcher, наоборот, запускаются.

Кроме того, сервер переходит на новую линию времени.

С точностью до некоторых деталей, все происходит так же, как при окончании восстановления из резервной копии.

Настройка потоковой репликации

Настроим реплику так же, как делали в предыдущей теме, а потом перейдем на нее.

Создаем автономную резервную копию, попросив утилиту создать слот и необходимые файлы (postgresql.auto.conf с настройками и standby.signal).

```
student$ pg_basebackup --pgdata=/home/student/backup -R --slot=replica --create-slot
```

Выкладываем копию в каталог PGDATA сервера beta:

```
student$ sudo mv /home/student/backup /var/lib/postgresql/13/beta
```

```
student$ sudo chown -R postgres:postgres /var/lib/postgresql/13/beta
```

Запускаем реплику:

```
student$ sudo pg_ctlcluster 13 beta start
```

Проверим настроенную репликацию. Выполним несколько команд на мастере:

```
α=> CREATE DATABASE replica_switchover;
```

```
CREATE DATABASE
```

```
α=> \c replica_switchover
```

```
You are now connected to database "replica_switchover" as user "student".
```

```
α=> CREATE TABLE test(s text);
```

```
CREATE TABLE
```

```
α=> INSERT INTO test VALUES ('Привет, мир!');
```

```
INSERT 0 1
```

Проверим реплику:

```
student$ /usr/lib/postgresql/13/bin/psql -p 5433 -d replica_switchover
```

```
β=> SELECT * FROM test;
```

```
      s
--------------
 Привет, мир!
(1 row)
```

Переход на реплику

Сейчас сервер beta является репликой (находится в режиме восстановления):

```
β=> SELECT pg_is_in_recovery();
```

```
 pg_is_in_recovery
-------------------
 t
(1 row)
```

Повышаем реплику. В версии 13 появилась функция pg_promote(), которая выполняет то же действие.

```
student$ sudo pg_ctlcluster 13 beta promote
```

Теперь бывшая реплика стала полноценным экземпляром.

```
β=> SELECT pg_is_in_recovery();
```

```
 pg_is_in_recovery
-------------------
 f
(1 row)
```

Мы можем изменять данные:

```
β=> INSERT INTO test VALUES ('Я - бывшая реплика (новый мастер).');
```

```
INSERT 0 1
```

Возвращение в строй

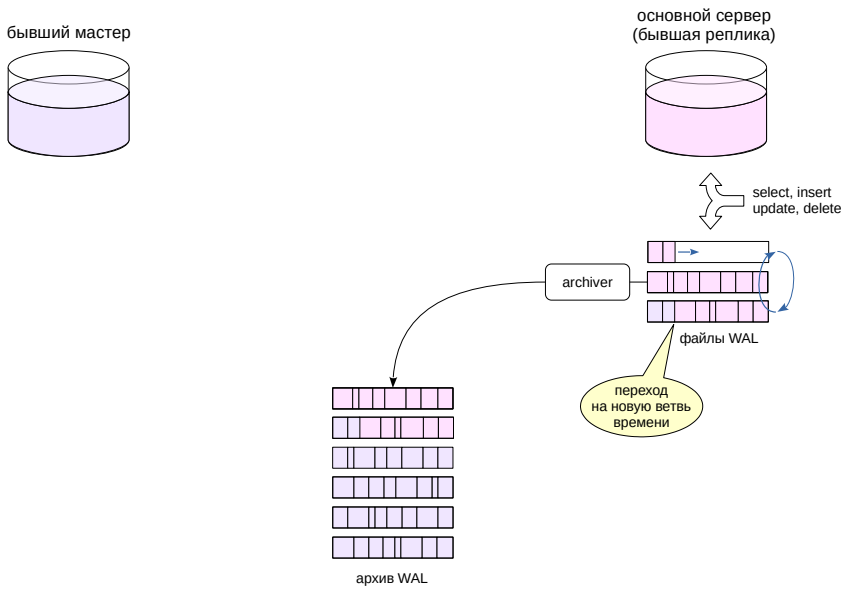

Если переход на реплику не был вызван выходом сервера из строя, то нужен способ быстро вернуть старый мастер в строй — теперь уже в качестве реплики (failback).

Простое подключение

Бывший мастер подключается к новому как реплика

допустимо, только если перед переключением реплика получила от мастера все журнальные записи

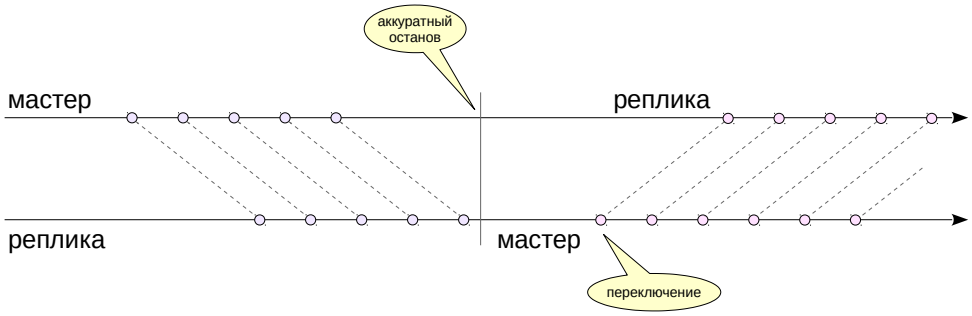

В случае аккуратной остановки мастера (останов в режимах fast или smart) все журнальные записи мастера скорее всего дойдут до реплики, хотя это и не гарантируется. Процесс останова организован таким образом, что сначала отключаются все обслуживающие процессы, затем выполняется контрольная точка, и только в самую последнюю очередь останавливается процесс wal sender, чтобы реплика успела получить запись WAL о контрольной точке.

Позицию в журнале мастера можно проверить с помощью утилиты pg_controldata («Latest checkpoint location»), а позицию на реплике покажет функция pg_last_wal_receive_lsn(). Поскольку функция pg_last_wal_receive_lsn() показывает *следующую* позицию, то ее значение должно *опережать* latest_checkpoint_location на длину записи (120 байт в PostgreSQL 13). Если это так, то бывший мастер можно непосредственно подключить к новому, изменив соответствующим образом конфигурационные параметры.

В случае останова мастера без выполнения контрольной точки (сбой или режим immediate), такое подключение в принципе невозможно: сервер не стартует, а в журнале сообщений будет зафиксирована ошибка.

Резервная копия

Бывший мастер восстанавливается из резервной копии

- абсолютно новая реплика, процесс занимает много времени
- можно ускорить rsync, если с момента сбоя прошло немного времени (но все равно долго для больших баз данных)

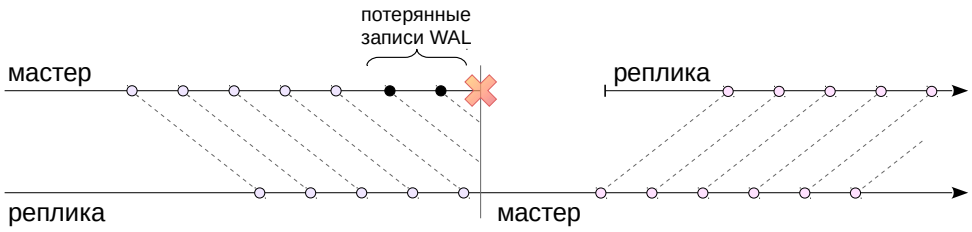

Если мастер был остановлен аварийно, велика вероятность того, что часть журнальных записей не успела дойти до реплики. В этом случае просто так подключать мастер нельзя.

Простой и надежный вариант — создать абсолютно новую реплику путем изготовления и развертывания базовой резервной копии. Однако для больших баз данных этот процесс может занимать много времени.

Вариант такого подхода — не использовать утилиту pg_basebackup, а сделать копию с помощью API резервирования с использованием утилиты rsync. Если выполнять копирование сразу после перехода на реплику, то большая часть файлов не должна успеть поменяться и процесс может пройти существенно быстрее. Но это, конечно, усложняет процесс.

Утилита pg_rewind

Подготовка к восстановлению

«откатывает» потерянные записи WAL, заменяя соответствующие страницы целевого сервера страницами с сервера-источника

копирует с сервера-источника все служебные файлы

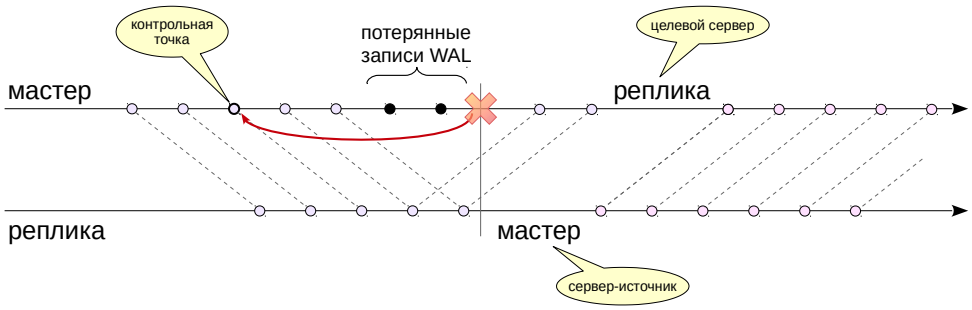

Еще более быстрый вариант состоит в использовании штатной утилиты pg_rewind.

Утилита определяет место расхождения между двумя серверами, определяет ближайшую к нему общую контрольную точку, и, просматривая журнал, определяет все страницы, измененные с момента этой контрольной точки.

Найденные страницы (которых должно быть немного) заменяются страницами с сервера-источника (нового мастера). Кроме того, утилита копирует с сервера-источника все служебные файлы.

Дальше применяются все необходимые записи WAL с нового мастера. Фактически, это выполняет уже не утилита, а обычный процесс восстановления после запуска сервера. Чтобы восстановление началось с нужного момента, утилита создает управляющий файл backup_label.

Ограничения pg_rewind

Целевой сервер

- все необходимые журнальные файлы должны сохраниться в pg_wal или в архиве (`--restore-target-wal`)
- должны быть включены контрольные суммы или *wal_log_hints* = on

Сервер-источник

- должен быть включен параметр *full_page_writes* = on

Утилита имеет ряд особенностей, ограничивающих ее применение. Необходимо, в числе прочего:

- Все сегменты WAL от текущего момента до найденной контрольной точки должны находиться в каталоге pg_wal целевого сервера или быть доступны для получения из архива, в этом случае надо задать параметр *restore_command* и ключ --restore-target-wal.

- Первое изменение данных после контрольной точки должно вызывать запись в WAL полной страницы. Параметра *full_page_writes* = on недостаточно, поскольку он не учитывает «незначительные» изменения страниц (hint bits). Дополнительно требуется, чтобы либо кластер был инициализирован с контрольными суммами страниц, либо нужно устанавливать параметр *wal_log_hints* = on.

- Целевой сервер должен быть остановлен аккуратно, с выполнением контрольной точки. Если это не так, утилита по умолчанию запустит целевой сервер и тут же остановит его корректно.

- На сервере-источнике заранее должен быть установлен параметр *full_page_writes* = on — причина та же, что и при восстановлении из резервной копии: утилита может скопировать страницы в рассогласованном состоянии.

Утилита pg_rewind

Между тем сервер alpha еще не выключен и тоже может изменять данные:

```
α=> INSERT INTO test VALUES ('Die hard');
```

```
INSERT 0 1
```

В реальности такой ситуации необходимо всячески избегать, поскольку теперь непонятно, какому серверу верить. Придется либо полностью потерять изменения на одном из серверов, либо придумывать, как объединить данные.

Наш выбор — потерять изменения, сделанные на первом сервере.

Мы планируем использовать утилиту pg_rewind, поэтому убедимся, что включены контрольные суммы на страницах данных:

```
α=> SHOW data_checksums;
```

```
 data_checksums
----------------
 on
(1 row)
```

Этот параметр служит только для информации; изменить его нельзя — подсчет контрольных сумм задается при инициализации кластера или утилитой pg_checksums на остановленном сервере.

И проверим, что параметр full_page_writes включен:

```
α=> SHOW full_page_writes;
```

```
 full_page_writes
------------------
 on
(1 row)
```

Остановим целевой сервер (alpha) некорректно.

```
student$ sudo head -n 1 /var/lib/postgresql/13/alpha/postmaster.pid
```

```
11289
```

```
student$ sudo kill -9 11289
```

Создадим на сервере-источнике (beta) слот для будущей реплики:

```
β=> SELECT pg_create_physical_replication_slot('replica');
```

```
 pg_create_physical_replication_slot
-------------------------------------
 (replica,)
(1 row)
```

Если целевой сервер не был остановлен корректно, утилита сначала запустит его в монопольном режиме и остановит с выполнением контрольной точки. Для запуска требуется наличие файла postgresql.conf в PGDATA.

```
postgres$ touch /var/lib/postgresql/13/alpha/postgresql.conf
```

В ключах утилиты pg_rewind надо указать каталог PGDATA целевого сервера и способ обращения к серверу-источнику: либо подключение от имени суперпользователя (если сервер работает), либо местоположение его каталога PGDATA (если он выключен).

```
postgres$ /usr/lib/postgresql/13/bin/pg_rewind -D /var/lib/postgresql/13/alpha --source-server='user=postgres port=5433' -R -P
```

```
pg_rewind: connected to server
pg_rewind: executing "/usr/lib/postgresql/13/bin/postgres" for target server to complete crash recovery
2022-05-06 22:07:03.906 GMT [11915] LOG:  database system was interrupted; last known up at 2022-05-06 22:06:56 GMT
2022-05-06 22:07:03.906 GMT [11915] LOG:  database system was not properly shut down; automatic recovery in progress
2022-05-06 22:07:03.907 GMT [11915] LOG:  redo starts at 0/5000E98
2022-05-06 22:07:03.908 GMT [11915] LOG:  invalid record length at 0/501BEF0: wanted 24, got 0
2022-05-06 22:07:03.908 GMT [11915] LOG:  redo done at 0/501BEC8

PostgreSQL stand-alone backend 13.6 (Ubuntu 13.6-1.pgdg22.04+1+b1)
backend> pg_rewind: servers diverged at WAL location 0/501BE88 on timeline 1
pg_rewind: rewinding from last common checkpoint at 0/5000ED0 on timeline 1
pg_rewind: reading source file list
pg_rewind: reading target file list
pg_rewind: reading WAL in target
pg_rewind: need to copy 54 MB (total source directory size is 86 MB)
    0/55371 kB (0%) copied
55371/55371 kB (100%) copied
pg_rewind: creating backup label and updating control file
pg_rewind: syncing target data directory
pg_rewind: Done!
```

В результате работы pg_rewind «откатывает» файлы данных на ближайшую контрольную точку до того момента, как пути серверов разошлись, а также создает файл backup_label, который обеспечивает применение нужных журналов для завершения восстановления.

Заглянем в backup_label:

```
student$ sudo cat /var/lib/postgresql/13/alpha/backup_label
```

```
START WAL LOCATION: 0/5000E98 (file 000000010000000000000005)
CHECKPOINT LOCATION: 0/5000ED0
BACKUP METHOD: pg_rewind
BACKUP FROM: standby
START TIME: 2022-05-07 01:07:04 MSK
```

Ключом -R мы попросили утилиту создать сигнальный файл standby.signal и задать в конфигурационном файле строку соединения и имя слота.

```
student$ sudo cat /var/lib/postgresql/13/alpha/postgresql.auto.conf
```

```
# Do not edit this file manually!
# It will be overwritten by the ALTER SYSTEM command.
primary_conninfo = 'user=student passfile=''/home/student/.pgpass'' channel_binding=prefer host=''/var/run/postgresql'' port=5432 sslmode=prefer sslcompression=0 sslsni=1 ssl_min_proto
primary_slot_name = 'replica'
primary_conninfo = 'user=postgres passfile=''/var/lib/postgresql/.pgpass'' channel_binding=prefer port=5433 sslmode=prefer sslcompression=0 sslsni=1 ssl_min_protocol_version=TLSv1.2 gs
```

```
student$ sudo ls -l /var/lib/postgresql/13/alpha/standby.signal
```

```
-rw------- 1 postgres postgres 0 мая  7 01:07 /var/lib/postgresql/13/alpha/standby.signal
```

Можно стартовать новую реплику.

```
student$ sudo pg_ctlcluster 13 alpha start
```

Слот репликации инициализировался и используется:

```
β=> SELECT * FROM pg_replication_slots \gx
```

```
-[ RECORD 1 ]-------+----------
slot_name           | replica
plugin              |
slot_type           | physical
datoid              |
database            |
temporary           | f
active              | t
active_pid          | 12102
xmin                |
catalog_xmin        |
restart_lsn         | 0/50378F0
confirmed_flush_lsn |
wal_status          | reserved
safe_wal_size       |
```

Данные, измененные на новом мастере, получены:

```
student$ /usr/lib/postgresql/13/bin/psql -p 5432 -d replica_switchover

α=> SELECT * FROM test;

                  s
-------------------------------------
 Привет, мир!
 Я - бывшая реплика (новый мастер).
(2 rows)
```

Проверим еще:

```
β=> INSERT INTO test VALUES ('Еще строка с нового мастера.');

INSERT 0 1

α=> SELECT * FROM test;

                  s
-------------------------------------
 Привет, мир!
 Я - бывшая реплика (новый мастер).
 Еще строка с нового мастера.
(3 rows)
```

Таким образом, два сервера поменялись ролями.

Переключение и архив

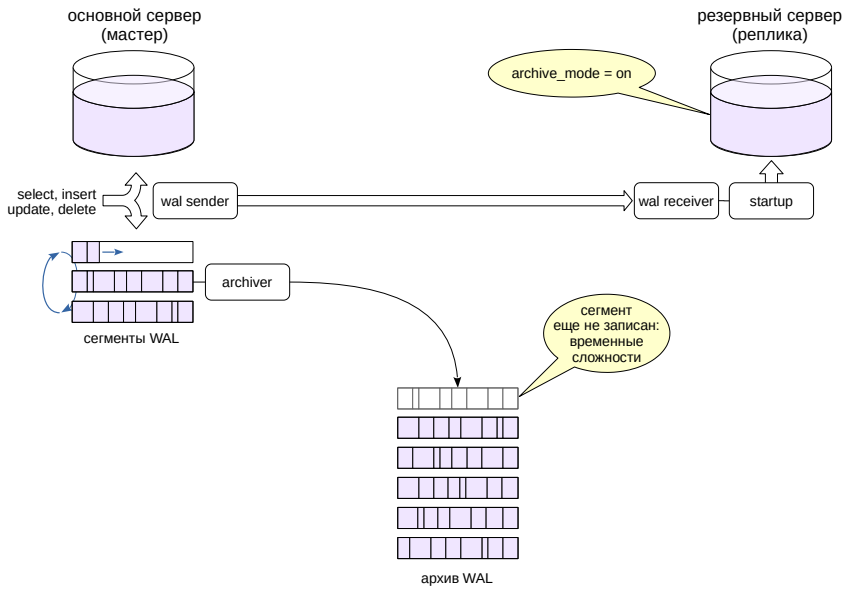

Архив файлов журнала предзаписи, наполняемый с помощью механизма непрерывного архивирования, имеет неприятную особенность в контексте потоковой репликации и переключении на реплику.

Допустим, при отказе мастера не все сегменты были записаны в архив. Например, могли возникнуть временные проблемы с доступным местом и *archive_command* возвращала ошибку.

Переключение и архив

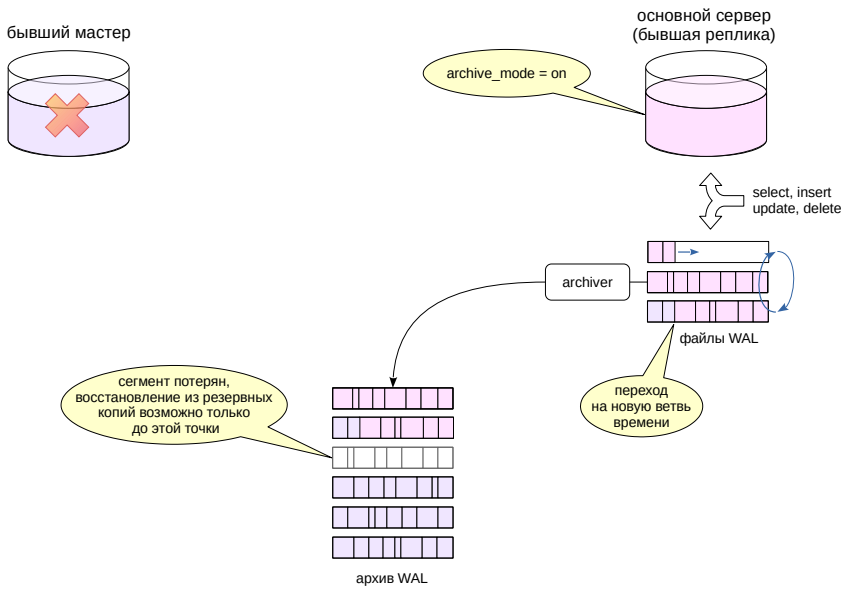

Но реплика не в курсе настроек архивирования на мастере. Когда бывшая реплика займет место мастера, она не запишет недостающие сегменты в архив (хотя они у нее есть), потому что рассчитывает на то, что архив работал без сбоев. В результате архив будет неполным.

А это означает, что из имеющихся резервных копий можно восстановить систему только до образовавшейся «дыры». Если такая ситуация возникла (а это еще нужно понять), требуется в срочном порядке выполнить резервное копирование.

Потоковый архив лишен этого недостатка, поскольку утилита pg_receivewal отслеживает содержимое каталога и запрашивает у сервера недостающие журнальные записи. Но, как отмечалось в модуле «Резервное копирование», использование этой утилиты сопряжено с поддержанием дополнительной инфраструктуры.

Проблемы с файловым архивом

Сейчас beta — основной сервер, а alpha — реплика. Настроим на обоих файловую архивацию в общий архив.

```
student$ /usr/lib/postgresql/13/bin/psql -p 5433 -d replica_switchover
```

```
student$ sudo mkdir /var/lib/postgresql/archive
```

```
student$ sudo chown postgres:postgres /var/lib/postgresql/archive
```

```
β=> \c - postgres
You are now connected to database "replica_switchover" as user "postgres".
β=> ALTER SYSTEM SET archive_mode = on;
ALTER SYSTEM
β=> ALTER SYSTEM SET archive_command = 'test ! -f /var/lib/postgresql/archive/%f && cp %p /var/lib/postgresql/archive/%f';
ALTER SYSTEM
```

```
α=> \c - postgres
You are now connected to database "replica_switchover" as user "postgres".
α=> ALTER SYSTEM SET archive_mode = on;
ALTER SYSTEM
α=> ALTER SYSTEM SET archive_command = 'test ! -f /var/lib/postgresql/archive/%f && cp %p /var/lib/postgresql/archive/%f';
ALTER SYSTEM
```

```
β=> \q
```

```
α=> \q
```

Перезапускаем оба сервера.

```
student$ sudo pg_ctlcluster 13 beta restart
```

```
student$ sudo pg_ctlcluster 13 alpha restart
```

Текущий сегмент журнала:

```
student$ /usr/lib/postgresql/13/bin/psql -p 5433 -d replica_switchover -U postgres
```

```
β=> SELECT pg_walfile_name(pg_current_wal_lsn());
     pg_walfile_name
--------------------------
 000000020000000000000005
(1 row)
```

Принудительно переключим сегмент WAL, выполнив какое-либо действие, а затем вызвав функцию pg_switch_wal.

```
β=> INSERT INTO test SELECT now(); SELECT pg_switch_wal();
INSERT 0 1
 pg_switch_wal
---------------
 0/503A1A8
(1 row)
```

Сегмент попал в архив:

```
β=> SELECT pg_walfile_name(pg_current_wal_lsn());
     pg_walfile_name
--------------------------
 000000020000000000000005
(1 row)
```

```
β=> SELECT last_archived_wal, last_failed_wal FROM pg_catalog.pg_stat_archiver;
    last_archived_wal     | last_failed_wal
--------------------------+-----------------
 000000020000000000000005 |
(1 row)
```

Теперь представим, что возникли трудности с архивацией. Причиной может быть, например, заполнение диска или проблемы с сетевым соединением, а мы смоделируем их, возвращая статус 1 из команды архивации.

```
β=> ALTER SYSTEM SET archive_command = 'exit 1';
SELECT pg_reload_conf();
```

```
ALTER SYSTEM
 pg_reload_conf
----------------
 t
(1 row)
```

Опять переключим сегмент WAL.

```
β=> INSERT INTO test SELECT now(); SELECT pg_switch_wal();
```

```
INSERT 0 1
 pg_switch_wal
---------------
 0/60000C0
(1 row)
```

Сегмент не архивируется.

```
β=> SELECT last_archived_wal, last_failed_wal FROM pg_catalog.pg_stat_archiver;
```

```
    last_archived_wal     | last_failed_wal
--------------------------+-----------------
 000000020000000000000005 |
(1 row)
```

Процесс archiver будет продолжать попытки, но безуспешно.

```
student$ tail -n 4 /var/log/postgresql/postgresql-13-beta.log
```

```
2022-05-07 01:07:15.372 MSK [12539] LOG:  received SIGHUP, reloading configuration files
2022-05-07 01:07:15.372 MSK [12539] LOG:  parameter "archive_command" changed to "exit 1"
2022-05-07 01:07:15.485 MSK [12545] LOG:  archive command failed with exit code 1
2022-05-07 01:07:15.485 MSK [12545] DETAIL:  The failed archive command was: exit 1
```

Alpha в режиме реплики не выполняла архивацию, а после перехода не будет архивировать пропущенный сегмент.

Остановим сервер beta, переключаемся на alpha.

```
β=> \q
```

```
student$ sudo head -n 1 /var/lib/postgresql/13/beta/postmaster.pid
```

```
12539
```

```
student$ sudo kill -9 12539
```

```
student$ sudo pg_ctlcluster 13 alpha promote
```

Еще раз принудительно переключим сегмент, теперь уже на alpha.

```
student$ /usr/lib/postgresql/13/bin/psql -U postgres -d replica_switchover
```

```
α=> INSERT INTO test SELECT now(); SELECT pg_switch_wal();
```

```
INSERT 0 1
 pg_switch_wal
---------------
 0/7002828
(1 row)
```

Что с архивом?

```
student$ ls -l /var/lib/postgresql/archive
```

```
total 32772
-rw------- 1 postgres postgres 16777216 мая  7 01:07 000000020000000000000005
-rw------- 1 postgres postgres 16777216 мая  7 01:07 000000030000000000000007
-rw------- 1 postgres postgres       83 мая  7 01:07 00000003.history
```

Сегмент отсутствует, архив теперь непригоден для восстановления и репликации.

Переключение и архив

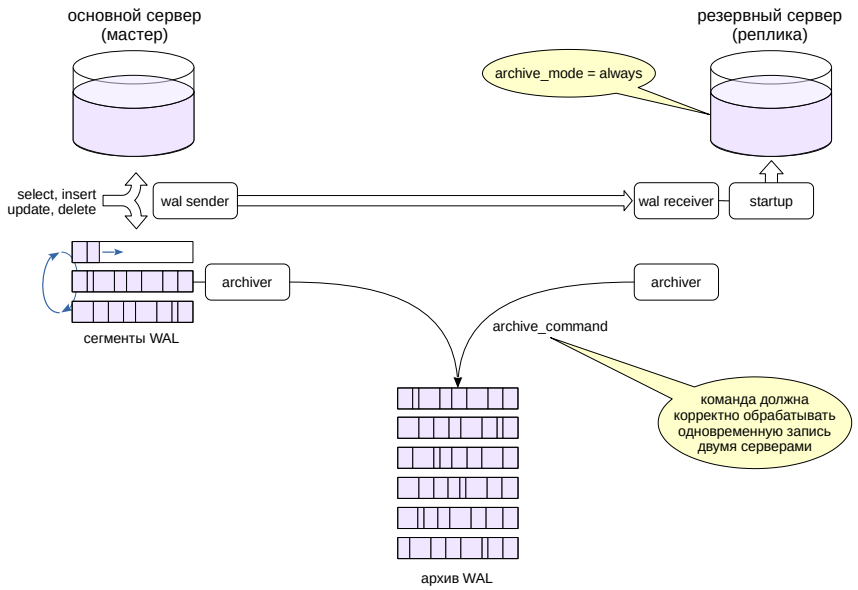

При установке *archive_mode* = always на реплике запускается процесс archiver, который записывает сегменты в архив наравне с мастером. Таким образом, один и тот же файл будет записан два раза: и мастером, и репликой. Это накладывает на команду *archive_command* серьезные требования:

- она не должна перезаписывать существующий файл, но должна сообщать об успехе, если файл с тем же содержимым уже есть в архиве;

- она должна корректно обрабатывать одновременный вызов с двух серверов.

При такой настройке сегмент не пропадет, поскольку реплика будет продолжать попытки записи даже после останова мастера.

(Разумеется, можно настроить *archive_command* и так, чтобы мастер и реплика сохраняли сегменты журнала в разные архивы, но вряд ли это практично.)

Архивация с реплики

Чтобы при переключении на реплику архив не пострадал, на реплике нужно использовать значение archive_mode = always.
При этом команда архивации должна корректно обрабатывать одновременную запись сегмента мастером и репликой.

Восстановим архивацию на сервере alpha. Команда архивации будет копировать файл, только если он отсутствует в архиве.

```
α=> ALTER SYSTEM SET archive_command = 'test -f /var/lib/postgresql/archive/%f || cp %p /var/lib/postgresql/archive/%f';
SELECT pg_reload_conf();
```

```
ALTER SYSTEM
 pg_reload_conf
----------------
 t
(1 row)
```

Добавим слот для реплики.

```
α=> SELECT pg_create_physical_replication_slot('replica');
```

```
 pg_create_physical_replication_slot
-------------------------------------
 (replica,)
(1 row)
```

Теперь настроим beta как реплику с архивацией в режиме always.

```
student$ cat << EOF | sudo -u postgres tee /var/lib/postgresql/13/beta/postgresql.auto.conf
primary_conninfo='user=student port=5432'
primary_slot_name='replica'
archive_mode='always'
archive_command='test -f /var/lib/postgresql/archive/%f || cp %p /var/lib/postgresql/archive/%f'
EOF
```

```
primary_conninfo='user=student port=5432'
primary_slot_name='replica'
archive_mode='always'
archive_command='test -f /var/lib/postgresql/archive/%f || cp %p /var/lib/postgresql/archive/%f'
```

Стартуем реплику.

```
postgres$ touch /var/lib/postgresql/13/beta/standby.signal
```

```
student$ sudo pg_ctlcluster 13 beta start
```

Повторим опыт. Переключаем сегмент:

```
student$ /usr/lib/postgresql/13/bin/psql -U postgres -d replica_switchover
```

```
α=> INSERT INTO test SELECT now(); SELECT pg_switch_wal();
```

```
INSERT 0 1
 pg_switch_wal
---------------
 0/8000170
(1 row)
```

Проверяем состояние архивации:

```
α=> SELECT last_archived_wal, last_failed_wal FROM pg_catalog.pg_stat_archiver;
```

```
    last_archived_wal     | last_failed_wal
--------------------------+-----------------
 000000030000000000000008 |
(1 row)
```

Заполненный сегмент попал в архив.

На сервере alpha возникли проблемы с архивацией, команда возвращает 1:

```
α=> ALTER SYSTEM SET archive_command = 'exit 1';
SELECT pg_reload_conf();
```

```
ALTER SYSTEM
 pg_reload_conf
----------------
 t
(1 row)
```

Alpha продолжает генерировать сегменты WAL.

```
α=> INSERT INTO test SELECT now(); SELECT pg_switch_wal();
```

```
INSERT 0 1
 pg_switch_wal
---------------
 0/90000C0
(1 row)
```

Но основной сервер их не архивирует:

```
α=> SELECT last_archived_wal, last_failed_wal FROM pg_catalog.pg_stat_archiver;
```

```
    last_archived_wal     |     last_failed_wal
--------------------------+--------------------------
 000000030000000000000008 | 000000030000000000000009
(1 row)
```

Однако архивация с реплики срабатывает, и сегмент оказывается в архиве:

```
student$ ls -l /var/lib/postgresql/archive
```

```
total 98308
-rw------- 1 postgres postgres 16777216 мая  7 01:07 000000010000000000000005
-rw------- 1 postgres postgres 16777216 мая  7 01:07 000000020000000000000005
-rw------- 1 postgres postgres 16777216 мая  7 01:07 000000020000000000000006
-rw------- 1 postgres postgres 16777216 мая  7 01:07 000000030000000000000007
-rw------- 1 postgres postgres 16777216 мая  7 01:07 000000030000000000000008
-rw------- 1 postgres postgres 16777216 мая  7 01:07 000000030000000000000009
-rw------- 1 postgres postgres       83 мая  7 01:07 00000003.history
```

Выполняем переключение на реплику.

```
α=> \q
```

```
student$ sudo head -n 1 /var/lib/postgresql/13/alpha/postmaster.pid
```

```
12586
```

```
student$ sudo kill -9 12586
```

```
student$ sudo pg_ctlcluster 13 beta promote
```

Beta стала основным сервером и генерирует файлы WAL.

```
student$ /usr/lib/postgresql/13/bin/psql -p 5433 -U postgres -d replica_switchover
```

```
β=> INSERT INTO test SELECT now(); SELECT pg_switch_wal();
```

```
INSERT 0 1
 pg_switch_wal
---------------
 0/A0028E0
(1 row)
```

Еще раз заглянем в архив:

```
student$ ls -l /var/lib/postgresql/archive
```

```
total 114696
-rw------- 1 postgres postgres 16777216 мая  7 01:07 000000010000000000000005
-rw------- 1 postgres postgres 16777216 мая  7 01:07 000000020000000000000005
-rw------- 1 postgres postgres 16777216 мая  7 01:07 000000020000000000000006
-rw------- 1 postgres postgres 16777216 мая  7 01:07 000000030000000000000007
-rw------- 1 postgres postgres 16777216 мая  7 01:07 000000030000000000000008
-rw------- 1 postgres postgres 16777216 мая  7 01:07 000000030000000000000009
-rw------- 1 postgres postgres       83 мая  7 01:07 00000003.history
-rw------- 1 postgres postgres 16777216 мая  7 01:07 00000004000000000000000A
-rw------- 1 postgres postgres      125 мая  7 01:07 00000004.history
```

В архиве появились файлы реплики, пропусков в нем нет, проблема решена.

Итоги

Переключение используется как в штатных,
так и в нештатных ситуациях

После переключения бывший мастер надо вернуть в строй

Обе процедуры должны быть заранее отработаны

Файловый архив журнала предзаписи требует внимания

Практика

1. Выполните необходимую настройку мастера и реплики для потоковой репликации с использованием слота, без непрерывного архивирования.
2. Имитируйте сбой основного сервера и переключитесь на реплику.
3. Верните в строй бывший основной сервер, выполнив резервную копию с нового мастера и настроив необходимые параметры.

   Убедитесь, что репликация работает и использует слот.
4. Переключитесь на новую реплику, чтобы бывший мастер снова стал основным сервером.

2. Для имитации сбоя можно остановить сервер в режиме immediate:

pg_ctlcluster 13 *имя_кластера* stop -- -m immediate

или завершить основной процесс postgres:

kill -9 *номер_процесса*

Номер процесса можно найти в первой строке файла PGDATA/postmaster.pid

1. Настройка репликации без архива

Настраиваем репликацию.

Создаем автономную резервную копию, предварительно создав слот.

```
student$ pg_basebackup --pgdata=/home/student/backup -R --slot=replica --create-slot
```

```
student$ sudo cat /home/student/backup/postgresql.auto.conf
```

```
# Do not edit this file manually!
# It will be overwritten by the ALTER SYSTEM command.
primary_conninfo = 'user=student passfile=''/home/student/.pgpass'' channel_binding=prefer host=''/var/run/postgresql'' port=5432 sslmode=prefer sslcompression=0 sslsni=1 ssl_min_proto
primary_slot_name = 'replica'
```

Выкладываем резервную копию в каталог PGDATA будущей реплики

```
student$ sudo mv /home/student/backup /var/lib/postgresql/13/beta
```

```
student$ sudo chown -R postgres:postgres /var/lib/postgresql/13/beta
```

Запускаем сервер в режиме реплики.

```
student$ sudo pg_ctlcluster 13 beta start
```

Проверим настройки. Выполним несколько команд на мастере:

```
α=> CREATE DATABASE replica_switchover;
```

```
CREATE DATABASE
```

```
α=> \c replica_switchover
```

```
You are now connected to database "replica_switchover" as user "student".
```

```
α=> CREATE TABLE test(s text);
```

```
CREATE TABLE
```

```
α=> INSERT INTO test VALUES ('Привет, мир!');
```

```
INSERT 0 1
```

Проверим реплику:

```
student$ /usr/lib/postgresql/13/bin/psql -p 5433 -d replica_switchover
```

```
β=> SELECT * FROM test;
```

```
      s
--------------
 Привет, мир!
(1 row)
```

2. Сбой основного сервера и переход на реплику

```
α=> \q
```

```
student$ sudo head -n 1 /var/lib/postgresql/13/alpha/postmaster.pid
```

```
23588
```

```
student$ sudo kill -9 23588
```

```
student$ sudo pg_ctlcluster 13 beta promote
```

3. Возвращение в строй бывшего мастера

Создаем автономную резервную копию, предварительно создав слот.

Удалим конфигурационный файл, иначе basebackup его скопирует и допишет параметры.

```
student$ sudo rm -rf /var/lib/postgresql/13/beta/postgresql.auto.conf
```

```
student$ rm -rf /home/student/backup
```

```
student$ pg_basebackup -p 5433 --pgdata=/home/student/backup -R --slot=replica --create-slot
```

Параметры конфигурации и сигнальный файл подготовлены утилитой pg_basebackup:

```
student$ sudo cat /home/student/backup/postgresql.auto.conf
```

```
primary_conninfo = 'user=student passfile=''/home/student/.pgpass'' channel_binding=prefer host=''/var/run/postgresql'' port=5433 sslmode=prefer sslcompression=0 sslsni=1 ssl_min_proto
primary_slot_name = 'replica'
```

```
student$ ls -l /home/student/backup/standby.signal
```

```
-rw------- 1 student student 0 мая  7 01:10 /home/student/backup/standby.signal
```

Выкладываем копию на бывший мастер и запускаем новую реплику.

```
student$ sudo rm -rf /var/lib/postgresql/13/alpha
```

```
student$ sudo mv /home/student/backup /var/lib/postgresql/13/alpha
```

```
student$ sudo chown -R postgres:postgres /var/lib/postgresql/13/alpha
```

```
student$ sudo pg_ctlcluster 13 alpha start
```

Слот репликации инициализировался и используется:

```
β=> SELECT * FROM pg_replication_slots \gx
```

```
-[ RECORD 1 ]-------+----------
slot_name           | replica
plugin              |
slot_type           | physical
datoid              |
database            |
temporary           | f
active              | t
active_pid          | 24175
xmin                |
catalog_xmin        |
restart_lsn         | 0/7000000
confirmed_flush_lsn |
wal_status          | reserved
safe_wal_size       |
```

Проверим еще:

```
β=> INSERT INTO test VALUES ('Я - бывшая реплика (новый мастер).');
```

```
INSERT 0 1
```

```
student$ /usr/lib/postgresql/13/bin/psql -p 5432 -d replica_switchover
```

```
α=> SELECT * FROM test;
```

```
                s
-----------------------------------
 Привет, мир!
 Я - бывшая реплика (новый мастер).
(2 rows)
```

4. Переключение на новую реплику

```
student$ sudo pg_ctlcluster 13 alpha promote
```

```
α=> select pg_is_in_recovery();
```

```
 pg_is_in_recovery
-------------------
 f
(1 row)
```

В итоге прежний мастер снова стал основным сервером.