


DBA1-17 Tantor: Администрирование PostgreSQL 17





Введение

Администрирование PostgreSQL 17

Предварительная подготовка

- Знакомство с SQL
- Навыки работы в операционной системе Linux
- Рекомендуется опыт работы с любой реляционной БД

Целевая аудитория

- Администраторы баз данных PostgreSQL
- Разработчики приложений для баз данных
- Сотрудники технической поддержки

Материалы курса

- Учебное пособие в форме книги в формате pdf, которое содержит теоретическую часть курса
- Практические задания
- виртуальная машина для выполнения практических заданий

Разделы курса

0. Введение
1. Установка и управление СУБД
2. Архитектура (5 частей)
3. Конфигурация
4. Базы данных (2 части)
5. Журналирование
6. Безопасность
7. Резервное копирование (2 части)
8. Репликация (2 части)
9. Платформа Tantor, обзор возможностей
10. Новые возможности Tantor Postgres 17.5

О курсе

- очное или дистанционное обучение с инструктором:
 - › продолжительность 5 дней
 - › начало в 10:00
 - › перерыв на обед 13:00-14:00
 - › окончание до 17:00 (последний день до 15:00)

О компании Тантор Лабс

- с 2016 года на международном рынке
- с 2021 года на российском рынке
- разработка СУБД Tantor Postgres
- разработка Платформы Tantor для мониторинга и управления СУБД семейства PostgreSQL, а также кластеров Patroni
- многолетний опыт эксплуатации высоконагруженных систем
- входит в Группу Астра

СУБД Tantor Postgres

Tantor BE



Новые возможности и доработки по сравнению с PostgreSQL, техническая поддержка

Tantor SE



СУБД Enterprise-уровня, подходит для наиболее нагруженных OLTP-систем или КХД размером до 100ТБ

Tantor SE 1C



СУБД для высоких нагрузок, оптимизированная и одобренная для работы с приложениями 1С

Tantor PipelineDB



Расширение, позволяющее непрерывно обрабатывать данные

В составе Tantor xData



Максимальная версия СУБД, оптимизированная для работы с 1С



ФИРМА "1С"
г. Москва, Дмитровское ш., 9, тел. (495) 681-73-81 1c@1c.ru

По месту требования

27 декабря 2022г. № *ДЗ/2022*

Настоящим письмом сообщаем, что Фирмой "1С" было проведено тестирование СУБД Tantor SE версии 14.4-5 совместно с платформой 1С:Предприятие версии 8.3.18.1959, 8.3.19.1726, 8.3.20.2184, 8.3.21.1644, 8.3.22.1709, 8.3.23.1437.

Тестирование было выполнено успешно, проблем в совместном использовании данных версий не выявлено.

С уважением,
Директор ООО «1С»



Нуралiev Б.Г.




Tantor xData

- Программно-Аппаратный Комплекс, с высокой производительностью, отказоустойчивостью, безопасностью
- версия 2A - процессоры AMD EPYC и x86-64
- версия 2B - процессоры Baikal-S
- высокая производительность и масштабируемость
- снижение затрат на инфраструктуру и администрирование
- в состав входит СУБД Tantor Postgres и Платформа Tantor



Платформа Tantor

- программное обеспечение для управления большим количеством СУБД и кластеров Patroni
- управляет СУБД Tantor Postgres и форками PostgreSQL
- сбор показателей работы экземпляров PostgreSQL, хранение и обработка показателей, рекомендации по настройке производительности
- интеграция с почтовыми системами, службами каталогов, мессенджерами



Расширение Tantor PipelineDB


- расширение для СУБД Tantor Postgres и PostgreSQL с открытым исходным кодом для непрерывного выполнения SQL-запросов на потоках данных с инкрементальным сохранением результатов в обычных таблицах
- высокопроизводительное агрегирование временных рядов
- позволяет соединять потоковые данные с историческими данными для сопоставления в режиме реального времени
- может использоваться в приложениях, где нужна незамедлительная реакция
- пример непрерывного представления **для вывода ежесуточного трафика**, используемого **топ десятью ip-адресов**:

```
CREATE VIEW heavy_hitters AS
SELECT day(arrival_timestamp), topk_agg(ip, 10, response_size)
FROM requests_stream GROUP BY day
```



Доработка расширений PostgreSQL

- 1. pg_cluster
- 2. pg_anon
- 3. pg_perfbench
- 4. ansible_tantor_agent
- 5. pg_configurator
- 6. pg_store_plans
- 7. ldap2pg
- 8. citus
- 9. wal-g
- 10. odyssey
- 11. plantuner
- 12. pg_orchestrator
- 13. pgtools
- 14. pipelinedb



Конференции PGBootCamp

- Тантор Лабс принимает участие в организации конференций
- Конференция PGBootCamp проводилась:
 - › Екатеринбург 10 апреля 2025
 - › Казань 17 сентября 2024
 - › Минск 16 апреля 2024
 - › Москва 5 октября 2023



1

1a

Установка

Предварительные требования

Для установки нужны:

- поддерживаемая операционная система
 - › рекомендуется операционная система Astra Linux
 - › поддерживается 10 операционных систем
- минимальные требования к оборудованию:
 - › 4 ядра CPU, 4Гб RAM, 40Гб SSD

Проверка возможности установки

- Дистрибутивы распространяются в виде файла для пакетных менеджеров Red Hat (rpm) и Дебиан (deb)
- В дистрибутивах указаны те пакеты, к функционалу которых могут обратиться утилиты и процессы экземпляра кластера
- в документации список зависимостей не указан, так как отличается для разных версий и сборок
- до установки можно получить список пакетов требующих установки

Инсталлятор

- проверяет возможные конфликты библиотек и предлагает команду для их устранения
- добавляет адрес репозитория в список apt и yum
- скачивает подходящий дистрибутив и выполняет установку, создание кластера, создание службы
- представляет собой текстовый скрипт:
 - можно ознакомиться с тем, какие действия выполняет инсталлятор
 - легко выяснить в чем ошибки и исправить их

Локальная установка

- Параметры инсталлятора `./db_installer.sh --help`
- при установке можно создать кластер
- дистрибутивы (пакеты rpm и deb) имеют стандартный формат, их можно разархивировать, выяснить какие изменения вносятся в операционную систему в процессе установки

Процесс установки

- создается пользователь с именем postgres
- создается служба запуска кластера
- создаются директории и файлы
- устанавливаются нужные разрешения на директории, файлы и их владельцы

После установки

- Установить переменную окружения PGDATA в профиле пользователя postgres
- создать кластер, если он не был ещё создан
- запустить экземпляр кластера
- установить начальные значения параметров кластера используя <https://tantorlabs.ru/pgconfigurator>
- установить инструменты управления и мониторинга (Платформа Tantor)

Конфигураторы

- утилита
pg_configurator
- веб-версия
<http://tantorlabs.ru/pgconfigurator>
- вводятся
характеристики хоста
и планируемой
нагрузки
- выдает параметры
конфигурации

The screenshot shows the web interface of the pg_configurator tool. The browser address bar displays `https://tantorlabs.ru/pgconfigurator`. The page features a navigation bar with links for 'Продукты', 'Документация', 'Обучение', 'Новости', 'Конфигуратор', 'О компании', and 'Контакты', along with a 'Связаться' button. The main heading reads 'Конфигуратор критически важных параметров производительности PostgreSQL'. The interface is divided into two main sections: a configuration form on the left and a configuration file preview on the right.

Configuration Form (Left):

- Доступное количество ядер CPU:** 8
- Доступное количество оперативной памяти RAM, МБ:** 1962
- Тип диска:** SSD
- Нагрузка базы данных:** ERPIC
- Платформа:** Linux
- Версия PostgreSQL:** 15
- Формат вывода:** (empty field)
- Скачать конфигурацию:** (button)

Configuration File Preview (Right):

```
Файл конфигурации
min_wal_size = 965MB
max_wal_size = 2865MB
max_replication_slots = 10
max_wal_senders = 2
wal_sender_timeout = 300s
wal_log_hints = on
hot_standby = on
wal_receiver_timeout = 300s
max_standby_streaming_delay = -1
wal_receiver_status_interval = 10s
hot_standby_feedback = on
checkpoint_timeout = 15min
checkpoint_warning = 3min
checkpoint_completion_target = 0.9
commit_delay = 571
commit_siblings = 12
bgwriter_delay = 54ms
bgwriter_lru_maxpages = 514
bgwriter_lru_multiplier = 4
effective_cache_size = 876MB
cpu_operator_cost = 0
default_statistics_target = 100
random_page_cost = 1.1
seq_page_cost = 1
join_collapse_limit = 10
from_collapse_limit = 10
geqo = on
geqo_threshold = 12
effective_io_concurrency = 128
max_worker_processes = 8
max_parallel_workers_per_gather = 0
max_locks_per_transaction = 179
max_pred_locks_per_transaction = 179
statement_timeout = 86400000
idle_in_transaction_session_timeout = 86400000
```

Создание кластера утилитой initdb

- Кластер создается утилитой командной строки initdb
- initdb запускается из под пользователя операционной системы postgres
- Перед запуском утилиты нужно создать директорию для файлов кластера
- выбрать настройки локализации
- ознакомиться с другими параметрами утилиты



1

1b

Управление

Утилита управления экземпляром pg_ctl

- Основные действия: остановка, перечитывание конфигурационных файлов, проверка статуса экземпляра, а также возможен запуск экземпляра
- преимущество в простоте использования и получения результата выполнения команды
- запускается под пользователем postgres

Процесс postgres

- `pg_ctl` запускает процесс postgres, который порождает остальные процессы экземпляра
- параметром `-o` утилиты `pg_ctl` можно передавать процессу postgres параметры командной строки и конфигурации кластера
- `postgres --single` позволяет использовать однопользовательский и однопроцессный режим. Режим используют для исправления содержимого кластера в сложных случаях повреждений
- для выхода из однопользовательского режима используется комбинация клавиш `ctrl+d`

Управление экземпляром через `systemctl`

- управляет только экземплярами запущенными ей, экземпляр, запущенный `pg_ctl` утилитой `systemctl` не управляется
- `systemctl` использует `pg_ctl` для запуска экземпляра
- ожидает запуска экземпляра 300 секунд (параметр `TimeoutSec=300` в файле-описателе службы)
- Запуск экземпляра:
 - › `systemctl start tantor-se-server-17`
 - › `systemctl start tantor-se-1c-server-17`
 - › `systemctl start tantor-be-server-17`

Работа в контейнере docker

- изменяемые файлы, в частности PGDATA, должны лежать на томах (volumes)
- работа в контейнере не добавляет высокой доступности
- процесс postgres не должен иметь PID=1
- при создании и запуске контейнера нужно использовать параметр `docker run -d --init`

```
root@tantor:~# docker exec имя_контейнера ps
PID USER      TIME COMMAND
  1 postgres  0:38 postgres
 31 postgres  0:09 postgres: logger
 32 postgres  0:45 postgres: checkpointer
 33 postgres  0:38 postgres: background writer
...
root@tantor:~# docker rm -f имя_контейнера
root@tantor:~# docker run --init -d -e POSTGRES_USER=postgres -e POSTGRES_PASSWORD=postgres -e
POSTGRES_INITDB_ARGS="--data-checksums" -e POSTGRES_HOST_AUTH_METHOD=trust -p 5434:5434 -e
PGDATA=/var/lib/postgresql/data -d -v /root/data:/var/lib/postgresql/data --name имя_контейнера postgres
```

Три режима остановки экземпляра

- `smart` - запрещает новые подключения и ждёт добровольного отсоединения существующих сессий. Этот режим не практичен
- `fast` - запрещаются новые подключения, всем серверным процессам отправляется сигнал прервать транзакции и завершиться. Это лучший выбор. Используется по умолчанию
- `immediate` - режим немедленного выключения

Остановка экземпляра

- Экземпляр можно остановить командой `pg_ctl stop` независимо от того каким способом был запущен экземпляр
- Использование `pg_ctl` - наиболее удобный и гарантированный способ погасить экземпляр
- Можно послать сигнал процессу `postgres` напрямую:
`kill -INT `head -1 $PGDATA/postmaster.pid``
- Не рекомендуется посылать сигнал `SIGKILL` (9) ни с одному процессу экземпляра
- `systemctl stop` не гарантирует остановки экземпляра

Остановка экземпляра

- В журнале кластера при выполнении контрольных точек (параметр `log_checkpoints=on`) будут присутствовать сообщения типа:

```
СООБЩЕНИЕ: начата контрольная точка: shutdown
immediate
```

или

```
LOG: checkpoint starting: shutdown immediate
```

- Текст в сообщении "shutdown immediate" относится к свойствам контрольной точки, а не к режиму остановки экземпляра. При остановке экземпляра в режиме immediate (команда `pg_ctl stop -m immediate`) контрольная точка не выполняется
- в PostgreSQL нет команды shutdown immediate

Утилиты управления (обёртки команд SQL)

- находятся в директории `/opt/tantor/db/17/bin`
- путь к директории включен в переменную окружения `PATH` пользователя `postgres` в Linux
- Часть утилит командной строки - обёртки для команд SQL
- Утилиты и соответствующие им команды:

`clusterdb` - `CLUSTER`

`createdb` - `CREATE DATABASE`

`createuser` - `CREATE ROLE`

`dropdb` - `DROP DATABASE`

`dropuser` - `DROP ROLE`

`reindexdb` - `REINDEX`

`vacuumdb` - `VACUUM`

Утилиты управления резервированием

- `pg_archivecleanup` - используется на репликах (резервных кластерах)
- `pg_basebackup` - создаёт физические бэкапы
- `pg_combinebackup` - накладывает инкрементальные бэкапы на полные
- `pg_dump`, `pg_dumpall`, `pg_restore` для логического резервирования (создания дампов)
- `pgcopydb` - утилита Tanor Postgres для логического резервирования
- `pg_receivewal` - для создания поточных архивов WAL
- `pg_resetwal` для изменения размера WAL-сегментов

Утилиты управления (другие)

- `pg_checksums` - включение/отключение подсчета контрольных сумм блоков данных и проверка блоков данных кластера
- `pg_rewind` - для синхронизации кластеров, например, после аварийного переключения на физическую реплику и в процедурах апгрейда
- `pg_upgrade` - для перехода на новую основную версию СУБД
- `pg_test_fsync` - измеряет скорость записи в WAL сегменты в разных режимах
- `pg_config` - информация о параметрах инсталляции и сборки СУБД
- `pg_controldata` - выводит в текстовом виде содержимое управляющего файла кластера `$PGDATA/global/pg_control`

Утилиты управления (продолжение)

- `pg_isready` - проверка что кластер принимает соединения
- `oid2name` - удобная утилита для поиска к какому объекту относится файл или директория
- `vacuum_maintenance.py` и другие скрипты на языке Python, используются расширением для секционирования `pg_partman` `pg_repack` - относится к одноимённому расширению, реализующему аналог `VACUUM FULL`, только без монопольной блокировки
- `pg_ctl` - управляет экземпляром кластера, была рассмотрена ранее
- `initdb` - создает кластера, была рассмотрена ранее



1

1с

Утилита psql

Терминальный клиент psql

- позволяет интерактивно вводить команды
- можно передавать команды и не интерактивно - команды могут быть взяты из файла или параметра командной строки
- есть файлы конфигурации
глобальный `/opt/tantor/db/17/etc/postgresql/psqlrc`
локальный по умолчанию `~/.psqlrc`
- Неинтерактивное выполнение команд:
`psql -f файл_скрипта.sql`
`psql -c "CREATE SCHEMA sh; CREATE TABLE sh.t (n numeric);"`
- описание параметров командной строки `psql --help`

psql: подключение к базе данных

- psql подключается к конкретной базе данных в кластере
- Для подсоединения к базе нужно пройти аутентификацию
- способы аутентификации рассматриваются в следующих главах
- Роль и пользователь синонимы и абсолютно одинаковые понятия
- Подключиться одновременно к нескольким базам даже расположенным в одном и том же кластере нельзя

psql: параметры подключения

- Параметры командной строки для подсоединения:
- -U **роль**, по умолчанию имя пользователя операционной системы
- -d **имя_базы**, по умолчанию имя **роли**
- -h **хост**, по умолчанию /var/run/postgresql
- -p порт, по умолчанию 5432
- Команды:
- Команда вывода деталей подсоединения:
`\conninfo`
- переподсоединение:
`\с имя_базы имя_роли хост порт`
- параметры текущего соединения можно передать, указав символ типа "-"
`\с - - localhost`

Получение справки по командам psql

- команды psql начинаются на обратный слэш \
- параметры командной строки psql --help
- справка по командам psql \?
- список команд SQL \h
после \h можно ввести начальные слова команды и получить по ней помощь
- по умолчанию если результат не помещается в окне терминала используется постраничный вывод
- для постраничного вывода используются утилиты операционной системы more или less, утилита less удобнее
- утилита устанавливается командой `\setenv PAGER 'less -XS'`
- режим постраничного вывода отключается командой `\pset pager off`
- в режиме постраничного вывода (после двоеточия):
q - выход, z - вперёд, b - назад, h - помощь

Форматирование вывода psql

- По умолчанию psql выводит результат запроса с псевдографикой:
`postgres=# select datname, datistemplate from pg_database;`

```
  datname  | datistemplate  
-----+-----  
postgres  | f  
template1 | t  
template0 | t  
(3 rows)
```

- можно детально настроить формат вывода параметрами `\pset` и переключателями `\a` `\t` `\x`
- посмотреть текущие настройки форматирования: `\pset`
- отображение времени выполнения команды, удобно для настройки производительности `\timing on`

Вывод результата в формате HTML

- `psql -c "команда;" -H -o f.html | xdg-open f.html`

```
# \pset format html
format is html.
=# \o file.html
=# show all;
=# \o
=# \! xdg-open file.html
=# \q
@education:~$ logout
```

Mozilla Firefox

/var/lib/postgresql/file.html × +

file:///var/lib/postgresql/file.html ☆

name	setting	description
allow_in_place_tablespaces	off	Allows tablespaces directly inside pg_tblspc, for testing.
allow_system_table_mods	off	Allows modifications of the structure of system tables.
application_name	psql	Sets the application name to be reported in statistics and logs.
archive_cleanup_command		Sets the shell command that will be executed at every archive change.
archive_command	(disabled)	Sets the shell command that will be called to archive a WAL file.
archive_mode	off	Allows archiving of WAL files using archive_command.
archive_timeout	0	Forces a switch to the next WAL file if a new file has not been archived within N seconds.
array_nulls	on	Enable input of NULL elements in arrays.
authentication_timeout	1min	Sets the maximum allowed time to complete client authentication.
auto_explain.log_analyze	on	Use EXPLAIN ANALYZE for plan logging.
auto_explain.log_buffers	on	Log buffers usage.
auto_explain.log_format	text	EXPLAIN format to be used for plan logging.
auto_explain.log_level	log	Log level for the plan.
auto_explain.log_min_duration	3s	Sets the minimum execution time above which plans are logged.
auto_explain.log_nested_statements	off	Log nested statements.
auto_explain.log_settings	off	Log modified configuration parameters affecting query execution.
auto_explain.log_timing	on	Collect timing data, not just row counts.
auto_explain.log_triggers	off	Include trigger statistics in plans.
auto_explain.log_verbose	on	Use EXPLAIN VERBOSE for plan logging.
auto_explain.log_wal	off	Log WAL usage.

Вывод результата в расширенном формате

- переключается командой \x

```
postgres=# \x
Expanded display is off.
postgres=# \x
Expanded display is on.
postgres=# select * from pg_settings limit 1;
-[ RECORD 1 ]-----+-----
name              | allow_in_place_tablespaces
setting           | off
unit              |
category          | Developer Options
short_desc        | Allows tablespaces directly inside pg_tblspc, for testing.
extra_desc        |
context           | superuser
vartype           | bool
source            | default
min_val           |
max_val           |
enumvals          |
boot_val          | off
reset_val         | off
sourcefile        |
sourceline        |
pending_restart   | f

postgres=# \x
Expanded display is off.
```

Приглашение к вводу команд (промт) psql

- Зачем? избегать выдачи команд "не в том окне"
- Приглашение (промт) можно менять командами
`\set PROMPT1` и `\set PROMPT2`

```
postgres=# \set PROMPT1 '%[%033
\set PROMPT2 '%[%033[0;31m%]%n%
postgres@postgres=# begin;
BEGIN
postgres@postgres *=# select 1;
```

- "-" вторая и последующие строки (PROMPT2)
- "*" открыта и не зафиксирована транзакция
- "!" транзакция в состоянии сбоя и может только откатиться, даже если набрать COMMIT;

```
postgres=# begin transaction;
BEGIN
postgres=*# select
postgres-*# tantor_version();
        tantor_version
-----
Tantor Special Edition 1C 17.2.1
(1 row)

postgres=*# Selec;
ERROR:  syntax error at or near "Selec"
LINE 1: Selec;
        ^
postgres=!# commit;
ROLLBACK
postgres=# █
```

Автофиксация транзакций и выполнение команд psql

- по умолчанию psql работает в режиме автоматической фиксации транзакции (AUTOCOMMIT)
- Изменение режима автофиксации:
`\set AUTOCOMMIT on`
`\set AUTOCOMMIT off`
- посмотреть переменные psql: команда `\set`
- очистка буфера набранных команд `\r`
- просмотр буфера или последней команды если буфер пуст `\p`
- `;<ENTER>` завершает команду SQL и посылает ее на выполнение серверному процессу

Переменные psql


- устанавливаются командой `\set` имя значение
- Срок жизни до выхода из psql или до выполнения команды `\unset` имя
- есть переменные окружения операционной системы на которые реагирует psql
- их можно устанавливать в psql или в файлах параметров (`~/.psqlrc`)
`\setenv PSQL_EDITOR /usr/bin/mcedit`

Выполнение командных файлов в psql

- `\! linux_command` - выполнить команду операционной системы
- `\o file.sql` - перенаправить вывод в файл
- `\o` - вернуть вывод на экран
- `\i file.sql` - выполнить команды из файла
- Еще примеры как выполнить команды из файла:
`psql < file.sql`
`psql -f file.sql`
- Выполнить каждую строку, формируемую запросом SELECT как команду в psql:
`SELECT 'checkpoint;' \gexec`


Графические приложения: DBeaver

- имеет свободно распространяемую версию
- написана на языке java и работает в Астра Линукс 1.8




Графические приложения: pgAdmin

- свободно распространяемая графическая программа для работы с кластерами PostgreSQL
- pgAdmin работает в Астра Линукс 1.8



Графические приложения: Платформа Tantor

- приложение для администрирования и мониторинга большого числа кластеров PostgreSQL и кластеров Patroni
- приложение класса Enterprise Manager



Демонстрация

- Скачивание инсталлятора
- Установка разрешения на исполнение инсталлятора
- Установка адреса расположения дистрибутивов
- Установка с созданием базы данных
- Проверка, что кластер работает
- Остановка служб
- Деинсталляция

Практика

1. Создание кластера
2. Создание кластера утилитой initdb
3. Режим одного пользователя
4. Передача параметров экземпляру в командной строке
5. Локализация
6. Однобайтные кодировки
7. Использование утилит управления
8. Настройка терминального клиента psql
9. Использование терминального клиента psql
10. Восстановление сохраненного кластера




2a

Архитектура PostgreSQL

Экземпляр PostgreSQL

- экземпляр PostgreSQL - процесс postgres, порожденные им процессы операционной системы, память, которую используют эти процессы
- пример процессов:




```
postgres@tantor:~$ ps -eLo ppid,pid,cmd | egrep 'PPID|postgres'
```

PPID	PID	CMD
1	743184	/opt/tantor/db/17/bin/postgres
743184	743185	postgres: logger
743184	743186	postgres: checkpointer
743184	743187	postgres: background writer
743184	743189	postgres: walwriter
743184	743190	postgres: autovacuum launcher
743184	743191	postgres: pg_stat_advisor BackgroundTaskManager
743184	743192	postgres: autoprewarm leader
743184	743193	postgres: logical replication launcher
644740	795748	psql -d demo -U alice -h /var/run/postgresql
743184	795749	postgres: alice demo [local] idle

основной процесс
процесс записи в журнал logging collector
фоновый процесс контрольной точки
процесс фоновой записи
процесс фоновой записи в журнал
процесс запуска автовакуума
процесс расширения
процесс расширения pg_prewarm
процесс запуска логической репликации
клиент, утилита psql
процесс, обслуживающий psql

Экземпляр PostgreSQL

- процессы, память, кластер



Запуск экземпляра, процесс postgres

- запускается процесс postgres
- считываются файлы параметров и комбинируются с параметрами, переданными в командной строке
- проверяются разрешения на директорию PGDATA
- проверяется наличие управляющего файла `pg_control`
- выделяется память, загружаются разделяемые библиотеки
- в PGDATA создается файл `postmaster.pid` наличие которого и правильность номера процесса проверяется раз в минуту
- процесс postgres регистрирует серверные сокеты, создается файл UNIX-сокета
- читается файл с параметрами аутентификации `pg_hba.conf`
- запускается процесс startup и фоновые процессы

Запуск серверного процесса

- для каждой сессии создается серверный процесс
- Инициализируются (выделяются и заполняются) три кэша в локальной памяти серверного процесса:
 - Кэш для быстрого доступа к таблицам (RelationCache)
 - Кэш таблиц системного каталога (CatalogCache)
 - Кэш планов выполнения команд (PlanCache)
- выделяется память под менеджер "порталов" TopPortalContext
- клиент аутентифицируется
- догружаются разделяемые библиотеки, указанные в параметрах `session_preload_libraries` и `local_preload_libraries`
- выделяется память MessageContext для текста команд и процесс готов к приему команд

Общая память процессов экземпляра

- большее 60 структур памяти
- размеры и список - в представлении `pg_shmem_allocations`
- размер части структур задаётся параметрами конфигурации

```
select * from (select *, lead(off) over(order by off) - off as true_size from
pg_shmem_allocations) as a order by 1;
```

name	off	size	allocated_size	true_size
<anonymous>		4946048	4946048	
Archiver Data	147726208	8	128	128
...				
XLOG Recovery Ctl	4377728	104	128	128
	148145024	2849920	2849920	

(74 rows)

Кэш таблиц системного каталога

- выделяется в локальной памяти каждого процесса в контексте CacheMemoryContext
- при создании или удалении объекта, процесс зафиксировавший транзакцию, посылает сообщение в кольцевой буфер shmInvalBuffer разделяемой памяти
- буфер хранит до 4096 сообщений
- процессы потребляют сообщения и обновляют свои локальные кэши
- если процесс пропустит сообщения, то полностью очистит свой локальный кэш таблиц системного каталога (CatalogCache) и будет его заново заполнять

```
select * from (select *, lead(off) over(order by off) - off as true_size
from pg_shmem_allocations) as a where name='shmInvalBuffer' order by 1;
```

name	off	size	allocated_size	true_size
shmInvalBuffer	146865024	68128	68224	68224

(1 row)

Представление pg_stat_slru

- в PGDATA есть поддиректории, в которых сохраняются служебные данные кластера
- для ускорения доступа на чтение-запись в файлы этих директорий используются кэши в разделяемой памяти экземпляра
- статистика используется для установки параметров конфигурации, задающих размеры SLRU-кэшей

select name, blks_hit, blks_read, blks_written, blks_exists, flushes, truncates from pg_stat_slru;							
name	blks_hit	blks_read	blks_written	blks_exists	flushes	truncates	
commit_timestamp	0	0	0	0	103	0	
multixact_member	0	0	0	0	103	0	
multixact_offset	0	3	2	0	103	0	
notify	0	0	0	0	0	0	
serializable	0	0	0	0	0	0	
subtransaction	0	0	26	0	103	102	
transaction	349634	4	87	0	103	0	
other	0	0	0	0	0	0	
(8 rows)							



Локальная память процесса

- доступна только одному процессу, поэтому блокировки для доступа к ней не нужны
- большая часть структур не занимает много памяти и интересны только для понимания алгоритмов работы процессов
- параметры, наиболее сильно влияющие на выделение локальной памяти процесса:
 - `work_mem` - выделяется для обслуживания узлов (шагов) плана выполнения (если шаги способны выполняться одновременно), в том числе каждым параллельным процессом. Вместе с параметром `hash_mem_multiplier` влияет на память, выделяемую каждым серверным и параллельным процессом.
 - `maintenance_work_mem` значение по умолчанию 64MB. Задаёт объем памяти, выделяемый каждым процессом (серверным, параллельным), участвующем в выполнении команд `VACUUM`, `ANALYZE`, `CREATE INDEX`, `ALTER TABLE ADD FOREIGN KEY`

Представление `pg_backend_memory_contexts`

- показывает память, выделенную серверным процессом, обслуживающим текущую сессию
- контекст памяти (memory contexts) - набор частей памяти (chunks), которые выделяются процессом для выполнения какой-то задачи
- для выполнения подзадачи может выделяться дочерний контекст
- Контексты образуют дерево (иерархию)
- в представлении иерархию отображают столбцы: name (название контекста памяти), parent (название родительского контекста памяти), level
- в столбце ident содержится детализация того, что хранится в контексте

```
select sum(total_bytes), sum(used_bytes), sum(free_bytes) from pg_backend_memory_contexts;
```

sum	sum	sum
2114816	1380760	734056

Функция `pg_log_backend_memory_contexts` (PID)

- начиная с 17 версии у команды EXPLAIN есть опция `memory` (по умолчанию отключена), которая выдает сколько памяти использовал планировщик и общую память серверного процесса
- память чужих сессий можно вывести в диагностический лог кластера функцией:


```
postgres=# SELECT pg_log_backend_memory_contexts(111);
 pg_log_backend_memory_contexts
-----
 t
(1 row)
LOG: statement: SELECT pg_log_backend_memory_contexts(111);
...
LOG: logging memory contexts of PID 111
LOG: level: 0; TopMemoryContext: 60528 total in 5 blocks; 16224 free (6 chunks); 44304 used
LOG: level: 1; TopTransactionContext: 8192 total in 1 blocks; 6728 free (0 chunks); 1464 used
...
LOG: level: 2; AV dblist: 8192 total in 1 blocks; 7840 free (0 chunks); 352 used
LOG: Grand total: 658848 bytes in 38 blocks; 270616 free (32 chunks); 388232 used
```

Структуры памяти, обслуживающие буферный кэш

- **Buffer Blocks** - сам буферный кэш
 - › выделяется память по числу буферов*8192 байта плюс 4096 байт
 - › параметр конфигурации `shared_buffers` задаёт число буферов
- **Buffer Descriptors** - описатели (заголовки) буферов
 - › выделяется память по числу буферов * размер описателя (64 байта)
- в каждом описателе хранится:
 - › адрес блока на диске в виде метки блока (BufferTag)
 - адрес блока содержит: ТБС, БД, файл, форк, номер блока от начала первого файла
 - › адрес буфера в виде порядкового номера буфера в буферном кэше
- описатель связан 1:1 (один к одному) с буфером
- данных в 20 байтах которые занимает BufferTag достаточно (не нужно никуда обращаться), чтобы считать блок с диска


Структуры памяти, обслуживающие буферный кэш

- после запуска экземпляра, пока все буфера свободны freeNext указывает на следующий по порядку буфер.




Поиск свободного буфера

- если процесс хочет работать с блоком, то он его ищет в буферном кэше. Если находит, то закрепляет. Множество процессов может закрепить буфер. Если процессу буфер не нужен, то процесс снимает закрепление.
- закрепление препятствует замене в буфере блока другим блоком.
- буфера могут возвращаться в список свободных. Обычно список свободных буферов пуст



Алгоритм вытеснения грязных буферов

- процесс checkpointer перед посылкой грязных блоков на запись сортирует их отдельно по каждому файлу



Стратегии замены буферов

- число записей в BufTable это сумма NBuffers и NUM_BUFFER_PARTITIONS
- методы замены блоков в буферном кольце (buffer cache replacement strategy):
 - BULKREAD. Для последовательного чтения блоков таблиц (Seq Scan) размер которых не меньше 1/4 кэша буферов используется набор буферов в буферном кэше размером 256Кб
 - VACUUM. Грязные страницы не убираются из кольца, а посылаются на запись. Размер кольца задается параметром конфигурации `vacuum_buffer_usage_limit`. По умолчанию 256Кб.
 - BULKWRITE. Используется командами COPY и CREATE TABLE AS SELECT. Размер кольца 16Мб.
- в буферном кэше блок может находиться только в одном буфере
- если буфер стал грязным, он исключается из буферного кольца.

Поиск блока в буферном кэше

Процесс экземпляра:

- создает в своей локальной памяти экземпляр структуры BufferTag
- вычисляет 4-байтный хэш от BufferTag
- по значению хэша определяет номер партиции в хэш-таблице **Shared Buffer Lookup Table**
- запрашивает легковесную (LWLock) блокировку типа BufMappingLock партиции таблицы в которую попало значение хэша
- в хэш-таблице находит порядковый номер блока в кэше буферов или -1 если блока нет в кэше

Закрепление буфера (pin) и блокировка content_lock

- закрепление (pin) используется для того, чтобы блок в буфере не был заменен на другой
- для чтения или изменения содержимого блока в буфере нужна легковесная блокировка content_lock, ссылка на которую сохраняется в описателе блока `Buffer Descriptors`
- блокировка должна удерживаться короткое время, в отличие от pin
- для удаления места занимаемого строкой (HOT cleanup или vacuum) после pin и Exclusive процесс дожидается, чтобы у других процессов не стало pin (то есть pincount=1)
- для добавления в блок новой строки или изменения xmin, xmax существующих строк процесс должен получить блокировку content_lock типа Exclusive
- если процесс имеет pin и Shared content_lock, то он может менять некоторые биты в t_infomask, в частности статус фиксации/отката

Освобождение буферов при удалении файлов

- при удалении базы данных выполняется **полное сканирование всех дескрипторов буферов**
- полное сканирование дескрипторов выполняется, если размер удаляемого relation больше 1/32 пула буферов
- в остальных случаях поиск дескрипторов идет через хэш-таблицу
- при увеличении кэша буферов с 1Гб до 16Гб время на поиск буферов при удалении таблицы увеличивается на порядок
- поиск выполняется при удалении файлов в результате DROP, TRUNCATE и вакуума (если не отключено усечение файлов)

```
pgbench --file=CreateAndDrop.sql -j 1 -c 1 -T 10
TPS для HP 128MB 417
TPS для HP 1GB 375
TPS для HP 4GB 227
TPS для HP 8GB 127
TPS для HP 16GB 55
TPS для HP 18GB 33
```

CreateAdndDrop.sql:

```
create table x(id int);
insert into x values (1);
drop table x;
```

Процесс фоновой записи bgwriter

- процесс bgwriter записывает (writeback) грязные буфера и помечает их как чистые
- работа bgwriter снижает вероятность того, что процессы натолкнутся на грязные блоки при поиске буфера-кандидата (victim) на вытеснение (eviction) для замены другим блоком
- "поиск свободного блока" это обычно буфера-кандидата на вытеснение из буфера блока, так как все буфера обычно заняты и список свободных блоков пуст
- при вытеснении грязного блока из буфера обращения к шине ввода-вывода нет, это "writeback": копирование из памяти (буфер) в память (страничный кэш linux)

```
select name, setting, context, max_val, min_val from pg_settings where name ~ 'bgwr';
```

name	setting	context	max_val	min_val
bgwriter_delay	200	sighup	10000	10
bgwriter_flush_after	64	sighup	256	0
bgwriter_lru_maxpages	100	sighup	1073741823	0
bgwriter_lru_multiplier	2	sighup	10	0

Очистка кэша буферов процессом bgwriter

- буфер не попадает в список свободных буферов, грязный буфер становится чистым
- на диск записываются только грязные, незакрепленные блоки с `usage_count=0`
- **bgwriter не меняет `usage_count`**
- при включенном подсчете контрольных сумм блок копируется из кэша буферов в локальную память процесса bgwriter и в локальной памяти подсчитывается и сохраняется в заголовке блока контрольная сумма

Контрольная точка

- выполняет процесс checkpoint:
 - › периодически по истечении `checkpoint_timeout`
 - › по разрастанию журнала `max_wal_size`
 - › в конце процедуры остановки или запуска экземпляра
 - › продвижении реплики
 - › командам `checkpoint`, `create database`
 - › при резервировании

```
postgres=# checkpoint;  
CHECKPOINT  
LOG:  checkpoint starting: immediate force wait  
LOG:  checkpoint complete: wrote 5 buffers (0.0%);
```

Шаги выполнения контрольной точки


- если экземпляр останавливается, в файл `pg_control` записывается статус о начале гашения экземпляра
- вычисляется LSN следующей журнальной записи. Это будет LSN начала контрольной точки
- ждёт снятия процессами признака `DELAY_CHKPT_START`
- на диск сбрасываются `slru` буфера и другие структуры разделяемой памяти
- `checkpointer` в цикле пробегает все описатели буферов и для грязных блоков устанавливает флаг `BM_CHECKPOINT_NEEDED`, сохраняет адрес блока (5 чисел) в структуре памяти `Checkpoint BufferIds` для последующей сортировки
- после установки флага `checkpointer` не блокирует буфер и блок в буфере может быть сброшен на диск и заменен другим

Шаги выполнения контрольной точки

- сохраненные идентификаторы блоков сортируются в порядке: tblspc, relation, fork, block
- блоки посылаются по одному в страничный кэш linux
- Если `checkpoint_flush_after` не равен нулю, то выполняется синхронизация по уже отсортированным диапазонам блоков по каждому файлу
- в WAL сохраняется моментальный снимок со списком активных транзакций
- формируется журнальная запись окончания контрольной точки, содержащая LSN журнальной записи, которая была сформирована на момент начала контрольной точки
- в файле `pg_control` сохраняется LSN сформированной журнальной записи
- удаляются WAL-сегменты, которые не должны удерживаться

Взаимодействие процессов экземпляра с диском

- блоки по 8Кб считываются в разделяемую память через страничный кэш (блоки по 4Кб)
- блоки записываются на диск через страничный кэш
- для записи используется оптимизированный алгоритм синхронизации



Практика

1. Транзакция в psql
2. Список фоновых процессов
3. Буферный кэш, команда EXPLAIN
4. Журнал предзаписи
5. Контрольная точка
6. Восстановление после сбоя



2b Архитектура PostgreSQL

Многоверсионность

Многоверсионность строк

- В блоках таблицы хранятся версии строк (rows), которые называют кортежами (tuple)
- Запросы (SELECT) должны выдавать данные на один момент времени ("консистентные"), что называют "целостность по чтению" (read consistency)
- Все версии строк физически хранятся в файлах таблицы по возможности рядом друг с другом (в тех же блоках файлов данных)

id	col1	col2	col3
1	a	b	c
2	b	c	a

tuple, строка,
версия строки
(синонимы)


Таблицы

- объект в котором хранятся данные
- несколько видов: обычные таблицы (heap tables, строки хранятся неупорядоченно), нежурналируемые, временные, секционированные
- расширения могут создавать новые способы хранения данных и методы доступа к ним
- число и порядок следования столбцов задаются при создании таблицы
- после создания таблицы можно добавлять и удалять столбцы. При добавлении столбца он добавляется последним - после всех существующих столбцов
- можно поменять тип столбца

Служебные столбцы

- `xmin` - номер транзакции (`xid`), создавшей версию строки
- `xmax` - номер транзакции (`xid`), удаляющей или пытавшейся (транзакция не была зафиксирована по любой причине: вызван `rollback`, серверный процесс прерван) удалить строку или ноль
- `ctid` адрес физического расположения строки
- `tableoid` - `oid` таблицы, в которой физически содержится строка. Значения имеют смысл для секционированных и унаследованных таблиц
- `cmin` порядковый номер команды внутри транзакции начиная с нуля, создавшей версию строки
- `cmx` порядковый номер команды внутри транзакции начиная с нуля, удаляющей или пытавшейся удалить строку

Структура блока данных



```
select * from page_header
(get_raw_page('t','main',0));
-[ RECORD 1 ]-----
lsn          | 0/110DCF10
checksum      | 0
flags        | 0
lower        | 928
upper        | 944
special      | 8176
pagesize     | 8192
version      | 5
prune_xid    | 0
```

Заголовок версии строки

- xmin - xid транзакции, создавшей версию строки
- xmax - xid транзакции, удалившей версию строки
- ctid - ссылка на следующую версию этой строки
- bits - битовая карта пустых значений
- hoff - смещение до начала данных строки
- lp_off смещение до начала строки

xmin	xmax	field3	ctid	infomask2	infomask	hoff		данные строки	pad
333	334	0	(0,2)	01000000000000010	0000000100000010	24		\x0100000009666f6f	
xmin	xmax	field3	ctid	infomask2	infomask	hoff	bits	данные строки	pad
334	0	0	(0,2)	10000000000000010	00101000000000001	24	10000000	\x01000000	

```
select * from heap_page_items(get_raw_page('t','main',0));
lp|lp_off|lp_flags|lp_len|t_xmin|t_xmax|t_field3|t_ctid|t_infomask2|t_infomask|t_hoff| t_bits |t_oid
-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+
1| 8144|      1|   32|  333|  334|    0|(0,2)| 16386|   258|   24|      |
2| 8112|      1|   28|  334|   0|    0|(0,2)| 32770| 10241|   24|10000000|
```



Вставка строки


- xmin - xid транзакции, вставившей строку
- xmax - ноль
- ctid - ссылка на себя
- транзакция, вставившая строку не помечает в infomask то, что она была зафиксирована. Это будет сделано при последующем обращении к строке в другой транзакции или другим запросом

xmin	xmax	field3	ctid	infomask2	infomask	hoff		данные строки	pad
333	0	0	(0,1)	00000000000000010	0000100000000010	24		\x0100000009666f6f	

```
select * from heap_page_items(get_raw_page('t','main',0));
lp|lp_off|lp_flags|lp_len|t_xmin|t_xmax|t_field3|t_ctid|t_infomask2|t_infomask|t_hoff| t_bits |t_oid
-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+
1| 8144| | 1| 32| 333| 0| 0 | (0,1)| 2 | 2050 | 24 | |
```

Обновление строки

- ctid прежней версии указывает на адрес новой версии строки
- ctid актуальной версии строки указывает сам на себя
- xmax прежней версии меняется с нуля на номер транзакции, которая создала новую версию строки



```
select * from heap_page_items(get_raw_page('t','main',0));
lp|lp_off|lp_flags|lp_len|t_xmin|t_xmax|t_field3|t_ctid|t_infomask2|t_infomask|t_hoff| t_bits |t_oid
---+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----
1| 8144|      1|   32|  333|  334|    0|(0,2)| 16386|    258|   24|      |
2| 8112|      1|   28|  334|    0|    0|(0,2)| 32770|  10241|   24|10000000|
```

Удаление строки

- xmax актуальной версии строки (xmax=0) устанавливается в xid удаляющей транзакции

xmin	xmax	field3	ctid	infomask2	infomask	hoff		данные строки	pad
333	334	0	(0,2)	01000000000000010	00000000100000010	24		\x0100000009666f6f	
xmin	xmax	field3	ctid	infomask2	infomask	hoff	bits	данные строки	pad
334	335	0	(0,2)	10000000000000010	00101000000000001	24	10000000	\x01000000	

```
select * from heap_page_items(get_raw_page('t','main',0));
lp|lp_off|lp_flags|lp_len|t_xmin|t_xmax|t_field3|t_ctid|t_infomask2|t_infomask|t_hoff| t_bits |t_oid
---+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----
1| 8144|      1|   32|  333|  334|    0|(0,2)| 16386| 1282|   24|      |
2| 8112|      1|   28|  334|  335|    0|(0,2)| 40962| 8449|   24|10000000|
```



Типы данных наименьшего размера: `boolean`, `"char"`, `char`, `smallint`

- список типов данных и их характеристики есть в таблице `pg_type`
- если столбец будет использоваться для поиска, стоит оценить эффективность индексирования столбцов, составных индексов, эффективность сканирования индекса доступными способами (Bitmap Index Scan, Index Scan, Index Only Scan)
- Типы данных, занимающие наименьшее место:
 - › `boolean` занимает 1 байт
 - › `"char"` занимает 1 байт, хранит символы ASCII
 - › `char` занимает 2 байта,
 - хранит символы в кодировке базы данных
 - › `smallint`, занимает 2 байта
 - хранит целые числа от -32768 до 32767

Типы данных переменной длины

- для строк переменной длины стоит использовать тип `text`
- размерность для `text` не указывается
- занимаемое место:
 - один байт, если длина поля меньше 127 байт и строка пустая ''
 - если кодировка UTF8, то ASCII символы занимают 1 байт. Поэтому значение '1' займет 2 байта: \x0531. Значение '11' займёт 3 байта: \x073131. поле состоящее из буквы 'э' займет 3 байта: \x07d18d
 - если длина поля больше 126 символов, то заголовок поля станет 4 байта и поля будут выравниваться по 4 байта
- поля могут сжиматься и оставаться в блоке
- поля могут выноситься в TOAST, оставляя при этом в блоке 18 байт (не выравниваются)
- двоичные данные стоит хранить в типе данных `bytea`. Это тип данных переменной длины и его поведение такое же, как у типа `text`

Целочисленные типы данных

- целые числа можно хранить в типах `int(integer, int4)`, `bigint(int8)`, `smallint(int2)`
- обычно используются для столбцов PRIMARY KEY
- `bigint` выравнивается по 8 байт
- `int` для первичного или уникального ключа ограничит число строк в таблице 4млрд (2^{32})
- для генерации значений для типов `smallint`, `int` и `bigint` используются последовательности и есть синонимы `smallserial(serial2)`, `serial(serial4)`, `bigserial(serial8)`
- для хранения чисел может использоваться тип переменной длины `numeric` (синоним `decimal`), накладные расходы 4 байта на хранение длины поля

Хранение дат, времени, их интервалов

- для хранения дат, времени, интервалов используются типы:
 - › `date` (4 байта, с точностью до дня)
 - › `timestamp`, `timestampz`, `time` точность до микросекунды, размер одинаковый 8 байт, содержимое одинаковое
 - › `timetz` - длина 12 байт, `interval` - длина 16 байт
- ТИПЫ ДАННЫХ `timestamp`, `timestampz` **не хранят часовой пояс**
- `timestampz` приводит хранимое время к временной зоне клиента
- `timestampz` физически хранит значения в UTC

```
create table t(t TIMESTAMP, ttz TIMESTAMPTZ);
insert into t values (CURRENT_TIMESTAMP, CURRENT_TIMESTAMP);
set timezone='UTC';
select t, ttz from t;
  2024-11-25 23:19:47.833968 | 2024-11-25 20:19:47.833968+00
update t set ttz=t;
select lp_off, lp_len, t_hoff, t_data from heap_page_items(get_raw_page('t','main',0)) order by lp_off;
 lp_off | lp_len | t_hoff |          t_data
-----+-----+-----+-----
   8096 |    40 |    24 | \x70580939c1ca020070580939c1ca0200
   8136 |    40 |    24 | \x7044c4bcc3ca020070580939c1ca0200
select t, ttz from t;
  2024-11-25 20:19:47.833968 | 2024-11-25 20:19:47.833968+00
```

Типы данных для вещественных чисел

- фиксированной длины, с плавающей точкой, с округлением до 6 или 15 разрядов (значащих чисел в десятичном формате):
 - float4 , real , float(1..24) - в 4 байтах хранит не менее 6 разрядов
 - float8 , float , double precision , float(25..53) в 8 байтах хранит не менее 15 разрядов

```
select 12345678901234567890123456789.1234567890123456789::float4::numeric;  
12345700000000000000000000000000  
select 12345678901234567890123456789.1234567890123456789::float8::numeric;  
12345678901234600000000000000000
```

- переменной длины, без потери точности при вычислениях:
 - numeric , decimal
 - точность можно задать параметрами: numeric(precision, scale)

```
select 1234567890123456789.123456789::numeric + 0.00000000000000000000123456789::numeric;  
1234567890123456789.12345678900000000000123456789
```

- пример экспоненциальной записи одинаковых чисел с разной мантиссой и порядком:

```
select 12345.6::float4, '12.3456e+03'::float4, '123.456e+02'::float4, '1234.56e+01'::float4;  
1.235e+04 | 1.235e+04 | 1.235e+04 | 1.235e+04
```

Моментальный снимок

- представляет собой согласованное состояние базы данных на момент времени
- В снимок данных входит:
 - xmin - номер самой старой активной транзакции
 - xmax - значение, на единицу больше номера последней завершенной транзакции
 - xip_list - список активных транзакций
- Функция, возвращающая содержимое моментального снимка и функция экспортирующая его для другой сессии:

```
postgres=# BEGIN TRANSACTION;
postgres=# select pg_current_snapshot();
 pg_current_snapshot
-----
 362:362:
postgres=# select pg_export_snapshot();
 pg_export_snapshot
-----
00000024-0000000000000000A-1
```

Транзакция

- Транзакция - набор команд
- Начинается явно или неявно
- Завершается одним из двух действий: фиксация (команды COMMIT, END) или откатом (команда ROLLBACK)
- Результат прерванной (aborted) транзакции такой же как откатенной командой
- Пример неявного начала транзакции:

```
postgres=# do $$  
begin  
  SET TRANSACTION ISOLATION LEVEL REPEATABLE READ;  
  perform 1;  
end $$;  
ERROR: SET TRANSACTION ISOLATION LEVEL must be called before any query  
CONTEXT: SQL statement "SET TRANSACTION ISOLATION LEVEL REPEATABLE READ"  
PL/pgSQL function inline_code_block line 3 at SQL statement
```

```
postgres=# do $$  
begin  
  ROLLBACK;  
  SET TRANSACTION ISOLATION  
LEVEL REPEATABLE READ;  
  perform 1;  
  ROLLBACK AND CHAIN;  
  perform 1;  
  COMMIT AND NO CHAIN;  
end $$;  
DO
```

Свойства транзакций

- Атомарность (Atomicity) - при фиксации выполнены все команды без исключений, при откате - ни одна команда не выполнена
 - после фиксации, изменения моментально становятся видны другим сессиям
- Целостность (consistency) - отсутствие нарушения декларативных ограничений целостности
- Изоляция (isolation) транзакций друг от друга
 - Реализуется одним из уровней изоляции
- Отказоустойчивость (Durability) - если клиент получил подтверждение об успешности фиксации транзакции (COMMIT COMPLETE), то может быть уверен, что результат транзакции не пропадет

Уровни изоляции транзакций

- READ UNCOMMITTED - чтение незафиксированных данных. В PostgreSQL не используется
- READ COMMITTED - чтение зафиксированных данных. Используется по умолчанию
- REPEATABLE READ - повторяемость по чтению. Стоит использовать только для чтения, а не изменения данных (READ ONLY)
- SERIALIZABLE - упорядоченное выполнение
 - › на уровнях REPEATABLE READ и REPEATABLE READ, если менялись данные, возможна ошибка сериализации (serialization failure): "не могу сериализовать доступ" (can't serialize access), транзакция переходит в состояние сбоя и не может зафиксироваться

Феномены изоляции транзакций

- в стандарте ISO SQL-92 и последующих определено три феномена конкурентного доступа, которые должны отсутствовать на уровнях изоляции
- на всех уровнях не могут нарушаться ограничения целостности
- грязное чтение в PostgreSQL не допускается ни на одном из уровней изоляции, поэтому уровень Read uncommitted не отличается от Read committed

Уровень изоляции	Грязное чтение (P1)	Неповторяемое чтение (P2)	Фантомное чтение (P3)	Нарушение сериализации
Read uncommitted	Допускается, но не в PG	Возможно	Возможно	Возможно
Read committed	нет	Возможно	Возможно	Возможно
Repeatable read	нет	нет	Допускается, но не в PG	Возможно
Serializable	нет	нет	нет	нет

Пример ошибки сериализации

- Пример ошибки сериализации:

```
postgres=# drop table if exists a;  
DROP TABLE  
postgres=# create table a (x int);  
CREATE TABLE  
1 postgres=# begin transaction isolation  
level serializable;  
BEGIN  
3 postgres=# insert into b select count(*)  
from a;  
INSERT 0 1  
5 postgres=# commit;  
COMMIT
```

```
postgres=# drop table if exists b;  
DROP TABLE  
postgres=# create table b (x int);  
CREATE TABLE  
  
2 postgres=# begin transaction isolation level  
serializable;  
BEGIN  
4 postgres=# insert into a select count(*) from b;  
INSERT 0 1  
  
6 postgres=# commit;  
ERROR:  could not serialize access due to read/write  
dependencies among transactions  
DETAIL:  Reason code: Canceled on identification as  
a pivot, during commit attempt.  
HINT:  The transaction might succeed if retried.
```

- В Oracle Database на уровне SERIALIZABLE ошибки нет

Статусы транзакций (CLOG)

- Журнал представляет собой битовый массив, в котором для каждой транзакции отведено два бита
- Значения битов:
 - 00 - транзакция в процессе
 - 01 - зафиксирована
 - 10- прервана (aborted, откачена)
 - 11 - подтранзакция зафиксирована, но родительская транзакция не завершена
- К CLOG обращаются процессы, в том числе вакуум, выполняющий заморозку версий строк, чтобы узнать статус транзакций
- Максимальный размер файлов CLOG зависит от параметра конфигурации `autovacuum_freeze_max_age`

с	а
0	0
1	0
0	1

Фиксация транзакции

- При фиксации транзакции выполняется запись в журнал транзакций (WAL) о фиксации транзакции
- Выполняется запись бита в буфер журнала CLOG
- Освобождаются ресурсы, которые использовались в процессе транзакции: блокировки, курсоры (кроме курсоров WITH HOLD), контексты (частей) локальной памяти процесса
- Файлы CLOG сохраняются в WAL в начале контрольной точки и изменения в них до следующей контрольной точки не журналируются. При восстановлении после сбоя содержимое CLOG восстанавливается по записям WAL

Подтранзакции

- подтранзакции это точки сохранения
 - › используются чтобы откатиться, а не переводить транзакцию в состояние сбоя
- создаются
 - › командой SAVEPOINT
 - › секцией EXCEPTION в блоке на языке pl/pgsql
 - › в psql при открытии транзакции при установке параметра
`\set ON_ERROR_ROLLBACK interactive`
- в структуре PGPROC сохраняется до 64 номеров подтранзакций
- подтранзакциям, которые только читают данные присваивается виртуальный номер
- если встречается команда изменения данных, то подтранзакциям вплоть до основной транзакции присваиваются реальные номера

Типы блокировок

- spinlock (циклическая проверка)
 - › Используются для очень краткосрочных действий - не дольше нескольких десятков инструкций процессора
 - › Средств мониторинга нет
- легковесные (LWLocks)
 - › Используются для доступа к структурам в разделяемой памяти
 - › Имеют монопольный (на чтение и изменение) и разделяемый режим (чтение)
 - › не больше 200 одновременно
- обычные (тяжеловесные)
 - › Автоматически освобождаются по окончании транзакции
 - › Есть несколько уровней блокировок
 - › Обслуживают блокировки 12 типов, в том числе advisory locks.
- предикатные блокировки (SIReadLock) используются транзакциями с уровнем изоляции SERIALIZABLE

Блокировки объектов

- При выполнении команд запрашивается блокировка на объекты, затрагиваемые командой
 - SELECT автоматически запрашивает блокировки ACCESS SHARE на таблицы, индексы, представления
- Пока блокировки не будут получены, команда не начнет выполняться
- Блокировки на уровне объектов используют "честную" очередь блокировок. Это означает, что блокировки будут обслуживаться в порядке их запроса независимо от уровней запрашиваемых блокировок и нет приоритетов
- параметром конфигурации `lock_timeout` можно установить максимальное время ожидания получения блокировки на объекты или строки


Совместимость блокировок

- **слабые блокировки** могут быть получены по быстрому пути
- **сильные блокировки** таблиц препятствуют установке слабых блокировок по быстрому пути
- автовакуум и автоанализ не мешают использовать быстрый путь
- автовакуум и автоанализ не блокируют команды, в случае конфликта блокировок рабочий процесс автовакуума прерывает обработку таблицы

	ACCESS SHARE	ROW SHARE	ROW EXCL.	SHARE UPDATE EXCL.	SHARE	SHARE ROW EXCL.	EXCL.	ACCESS EXCL.
ACCESS SHARE								X
ROW SHARE							X	X
ROW EXCLUSIVE					X	X	X	X
SHARE UPDATE EXCL.				X	X	X	X	X
SHARE			X	X		X	X	X
SHARE ROW EXCLUSIVE			X	X	X	X	X	X
EXCLUSIVE		X	X	X	X	X	X	X
ACCESS EXCLUSIVE	X	X	X	X	X	X	X	X

Блокировки объектов

- Блокировки на уровне объектов формируют очереди



Блокировки строк

- Таблица совместимости


запрашиваемый режим	строка заблокирована в режиме			
	FOR KEY SHARE	FOR SHARE	FOR NO KEY UPDATE	FOR UPDATE
FOR KEY SHARE				X
FOR SHARE			X	X
FOR NO KEY UPDATE		X	X	X
FOR UPDATE	X	X	X	X

Мультитранзакции

- блокировка FOR NO KEY UPDATE устанавливается командой UPDATE, которая не вносит изменения в ключевые столбцы
- блокировка FOR KEY SHARE устанавливается командой DELETE и UPDATE которая обновляет значения ключевых столбцов
- также разделяемые блокировки устанавливаются командами SELECT .. FOR SHARE, FOR NO KEY UPDATE, FOR KEY SHARE
- разделяемые блокировки позволяют одновременно работать со строкой нескольким транзакциям
- одновременная работа реализуется "мультитранзакциями", которые имеют свой счетчик `xid`, свои файлы и кэши
- соответствие между `xid` транзакций и мультитранзакций хранятся в директории `PGDATA/pg_multixact`
- advisory locks не являются заменой блокировок строк, так как их количество ограничено

Очередь при блокировке строки

- есть первый в очереди и остальные
- первого в очереди может обогнать транзакция, чей уровень блокирования строки совместим с уровнем транзакции, уже заблокировавшей строку
- если первый в очереди получает блокировку, то на его место выбирается транзакция случайным образом независимо от длительности ожидания



Практика

1. Вставка, обновление и удаление строки
2. Видимость версии строки на различных уровнях изоляции
3. Состояние транзакции по CLOG
4. Блокировка таблицы
5. Блокировка строки



2с Архитектура PostgreSQL

Регламентные работы

Автовакуум

- выполняется рабочими процессами автовакуума
- выбираются таблицы, в которых было обновлено или вставлено больше 20% от размера таблицы
- если давно не было заморозки версий строк, то выполняется заморозка
- после ваккумирования таблицы выполняет автоанализ
- Автовакуум запрашивает блокировку уровня SHARE UPDATE EXCLUSIVE и если не может получить блокировку на таблицу, то эта таблица не вакуумируется в этом цикле автовакуума
- временные таблицы автовакуум не обрабатывает

Представление `pg_stat_progress_vacuum`

- содержит по одной строке для каждого серверного процесса, выполняющего команду VACUUM и каждого autovacuum worker выполняющих вакуумирование в момент обращения к представлению
- в столбце `phase` отражается текущая фаза вакуума: `initializing` (подготовительная, проходит быстро), `scanning heap`, `vacuuming indexes`, `vacuuming heap`, `cleaning up indexes`, `truncating heap`, `performing final cleanup` (финальная)
- по столбцам `heap_blks_total` , `heap_blks_scanned` , `heap_blks_vacuumed` оценить ход выполнения очистки
- `num_dead_tuples` - число TID, которые сейчас помещены в структуру памяти. Если достигнет `max_dead_tuples` увеличится значение в `index_vacuum_count`
- VACUUM **FULL** отслеживается через `pg_stat_progress_cluster`
- ANALYZE отслеживается через `pg_stat_progress_analyze`

Параметры команды VACUUM

- `DISABLE_PAGE_SKIPPING` обрабатывает все блоки таблиц без исключения
- `SKIP_LOCKED false` - не дает пропускать заблокированные объекты, секции таблиц, блоки
- `INDEX_CLEANUP auto/on/off` указывает нужно ли обрабатывать индексы. OFF используется если нужно быстрее убрать мертвые строки из блоков таблиц
- `PROCESS_TOAST false` - отключает обработку таблиц TOAST
- `TRUNCATE false` - отключает пятую фазу
- `PARALLEL n`. Число *n* ограничивает число фоновых процессов
- `FULL` полная очистка, использует монопольные блокировки, последовательно устанавливаемые на каждую обрабатываемую таблицу

Параметры команды VACUUM

- SKIP_DATABASE_STATS отключает обновление `pg_database.datfrozenxid`
 - позволяет не выполнять полное сканирование таблицы `pg_class`
- VERBOSE - выводит статистику выполнения команды
- FREEZE - выполняет заморозку строк во всех блоках, кроме тех в которых все строки актуальны и заморожены
- BUFFER_USAGE_LIMIT размер буферного кольца вместо `vacuum_buffer_usage_limit`
 - в отличие от параметра конфигурации, BUFFER_USAGE_LIMIT можно установить в значение ноль и буферное кольцо не будет использоваться

Параметр `default_statistics_target`

- устанавливает
 - число наиболее часто встречающихся значений в столбцах таблиц (`pg_stats.most_common_vals`)
 - количество корзин в гистограммах распределения значений в столбцах (`pg_stats.histogram_bounds`)
 - число строк (`default_statistics_target * 300`) случайной выборки по которым собирается статистика
- по умолчанию 100
- максимальное значение 10000
- можно установить для конкретного столбца таблицы или индекса по выражению:

```
alter table test alter column id set statistics 10000;  
alter index test alter column 1 set statistics 10000;
```

Раздувание (bloat) таблиц и индексов

- автовакуум может не обработать таблицу из-за того, что:
 - › горизонт базы данных долго не сдвигался
 - › в момент обращения автовакуума к таблице на ней была установлена несовместимая с автовакуумом блокировка
- после того как автовакуум отработает, размеры файлов вряд ли уменьшатся
- блоки будут использоваться в будущем под новые версии строк
- слишком часто заниматься мониторингом не нужно, более актуальна проверка свободного места на дисках
- расширение для оценки числа версий строк:

```
create extension pgstattuple;  
\dx+ pgstattuple  
select relname, b.* from pg_class, pgstattuple_approx(oid) b WHERE relkind='r';  
select relname, b.* from pg_class, pgstatindex(oid) b WHERE relkind='i' order by 10;
```

Оптимизация Heap Only Tuple

- при обновлении (`UPDATE`) строки в индексы могут не вноситься изменения
- изменения не выходят за пределы блока таблицы (heap only)
- условия:
 - изменяются только поля, не входящие ни в один из индексов (кроме индексов типа `brin`) на таблицу
 - новая версия строки размещается в том же блоке, что и прежняя версия
- если новая версия строки размещается в блоке, отличном от того в котором находится прежняя версия строки, то:
 - прежняя версия станет последней в цепочке НОТ-версий
 - во всех индексах на таблице будут созданы новые записи, указывающие на новую версию строки

Мониторинг HOT update

- статистика HOT доступна в представлениях `pg_stat_all_tables` и `pg_stat_user_tables`
- счетчик HOT обновлений собирается по каждой таблице и отражается в столбце: `n_tup_hot_upd`
- все обновления отражаются в столбце `n_tup_upd`
- случаи, если при обновлении не нашлось места для новой версии строки и цепочка HOT была оборвана, а новая версия была вставлена в другой блок показывает `n_tup_newpage_upd`
- статистика по базе обнуляется вызовом функции `pg_stat_reset()`;
 - после вызова функции рекомендуется выполнить `ANALYZE` по всей базе

```
select relname, n_tup_upd, n_tup_hot_upd, n_tup_newpage_upd,  
round(n_tup_hot_upd*100/n_tup_upd,2) as hot_ratio from pg_stat_all_tables where n_tup_upd<>0  
order by 5;
```

relname	n_tup_upd	n_tup_hot_upd	n_tup_newpage_upd	hot_ratio
pg_rewrite	14	9	5	64.00
pg_proc	33	23	10	69.00
pg_class	71645	63148	8351	88.00

Влияние FILLFACTOR на HOT cleanup

- чтобы HOT cleanup выполнялся, предыдущий UPDATE строки должен превысить границу `min(90%, FILLFACTOR)`
- если размер строк в таблице такой, что в блок помещается меньше 9 строк, то восьмая строка не превысит границу 90%, а девятая строка будет больше 11% размера блока и она не поместится в блок
- наиболее эффективно при проектировании схем хранения данных делать размер строк небольшими. Разумный размер строки не больше 600 байт

Внутристраничная очистка в таблицах

- выполняя SELECT и UPDATE, серверный процесс может удалить **dead tuples** (версии строк, вышедшие за горизонт видимости базы данных, xmin horizon), выполнив реорганизацию версий строк внутри блока
- внутристраничная очистка совместима с HOT и может предварительно освободить место, которое будет использоваться новыми версиями строк, появляющимися в результате UPDATE
- выполняется, если:
 - › блок заполнен более чем на 90% или FILLFACTOR (по умолчанию 100%)
 - › ранее выполнявшийся UPDATE не смог разместить новую версию строки в этом блоке
- приблизительная оценка по версиям строк, которые могут быть очищены:
`pg_stat_all_tables.n_dead_tup`

Внутристраничная очистка в индексах

- выполняется при **индексном сканировании**
- если строка в таблице удалена, индексная запись на строку или цепочку версий может быть помечена флагом LP_DEAD
- пометка может ставиться командой SELECT
- журнальная запись не создается, но блок грязнится
- помеченная индексная запись игнорируется на мастере, но не на реплике
- помеченная индексная запись будет очищена при выполнении команд, которые меняют данные в таблице

```
create table t (id int primary key, c text) with (autovacuum_enabled = off);
insert into t SELECT i, 'simple delete ' || i from generate_series(1, 1000000) as i;
delete from t where id between 100 and 900000;
analyze t;
explain (analyze, buffers, costs off) select * from t where id between 1 and 900000;
  Index Scan using t_pkey on t (actual time=0.010..218.477 rows=99 loops=1)
    Buffers: shared hit=11489
  Execution Time: 218.600 ms
```


Эволюция индексов: создание, удаление, перестройка

- команды `create/drop/reindex index имя_индекса` устанавливают блокировку `SHARE`, не совместимую с внесением изменений в строки таблицы
- эти команды могут выполняться одновременно, они совместимы сами с собой, при этом с `concurrently` не совместимы
- автовакуум не совместим ни с `concurrently`, ни без
- для временных индексов на временные таблицы не надо использовать `concurrently`, так как блокировок на временные объекты нет
- `create/reindex concurrently` сканирует таблицу **два раза**, без `concurrently` **один раз**
- `concurrently` позволяет выполняться командам `SELECT`, `WITH`, `INSERT`, `UPDATE`, `DELETE`, `MERGE` и позволяет использовать быстрый путь (`fastpath`) блокирования объектов (таблиц, индексов, секций)

Частичные (partial) индексы

- создаются по части строк таблицы
- предикат WHERE указывается при создании индекса и определяет индексируемые строки
- полезны тем, что позволяют избежать индексирования наиболее часто встречающихся значений
- частичный индекс может быть уникальным
- размер частичного индекса обычно меньше
- пример создания частичного индекса:

```
create unique index t1_idx1 ON t1 (c2 desc nulls first, upper(c1))  
include (c3,c4) WHERE c2>0;
```

Команда REINDEX

- перестраивает индексы
- REINDEX блокирует практически любые запросы, кроме подготовленных, план которых был закэширован и которые не используют перестраиваемый индекс
- Для перестройки одного индекса:
 - REINDEX INDEX имя_индекса;
- Если необходимо перестроить все индексы по таблице:
 - REINDEX TABLE имя_таблицы;
- Также можно перестроить индексы в рамках конкретной схемы или даже всей базы данных:
 - REINDEX SCHEMA имя_схемы;
 - REINDEX DATABASE; перестроить можно индексы на таблицы только текущей базы данных, кроме индексов таблиц системного каталога
 - REINDEX SYSTEM; перестройка индексов на таблицы системного каталога

REINDEX CONCURRENTLY

- неблокирующее перестроение индексов
- для каждого перестраиваемого индекса выполняется первый проход, на котором строится индекс
- выполняется второй проход, на котором в индекс вносятся записи, добавленные в таблицу во время первого прохода
- ограничения целостности, использовавшие перестраиваемые индексы, переключаются на определение нового индекса и меняются имена индексов
- удаляются старые структуры индексов
- снимаются блокировки
- Перестройка может завершиться ошибкой, в этом случае REINDEX CONCURRENTLY прерывается, но оставляет после себя нерабочий новый индекс в дополнение к перестраиваемому. Этот индекс будет игнорироваться запросами, но будет обновляться при изменении данных, что повлечёт накладные расходы

Расширение HypoPG

- устанавливается командой `CREATE EXTENSION hypoPg;`
- используется при настройке выполнения команд SQL
- позволяет создать определение индексов, существующих только в текущей сессии и не влияющие на работу других сессий
- позволяет выяснить будет ли планировщик использовать индекс при выполнении конкретных команд без создания индекса
- расширение позволяет скрыть любые существующие индексы в текущей сессии чтобы они не влияли на планировщик
- гипотетические индексы создаются функцией `hypoPg_create_index('CREATE INDEX...')`, которой передаётся текст команды создания индекса

Счетчик транзакций

- Для 32-битного счетчика транзакций (xid) максимальное значение равно 4млрд.
- когда этот предел достигается, счетчик транзакций переходит "через ноль" и нумерация транзакций начинается со значения 3
- Чтобы не происходило переполнение счетчика версии строк "замораживаются" (freeze), что означает, что версия строки единственная, актуальная, видна во всех моментальных снимках

Практика

1. Обычная очистка таблицы
2. Анализ таблицы
3. Перестройка индекса
4. Полная очистка
5. Расширение НуроPG



2d Архитектура PostgreSQL

Выполнение запросов

SQL - декларативный язык

- SQL - декларативный язык программирования для работы с базами данных, где пользователь описывает желаемые результаты запроса, не указывая конкретные шаги выполнения
- Когда пользователь отправляет запрос SQL системе управления базами данных (СУБД) PostgreSQL, происходит следующее:
 - › Парсинг (синтаксический и семантический разбор) запроса
 - › Переписывание
 - › Планирование
 - › Выполнение

Синтаксический разбор

- Синтаксический разбор включает в себя следующие шаги:
 - › лексический анализ
 - › построение синтаксического дерева
 - › проверка на соответствие грамматике

```
SELECT col1, col2 FROM table1 WHERE col2='test1';
```

тест запроса синтаксически верен

Семантический разбор

- определение смысла (семантики), проверка существования таблиц, столбцов, согласованность типов данных
- проверка прав доступа: имеет ли пользователь право на выполнение команды, права доступа к объектам, указанным в запросе: схемам, таблицам, функциям, представлениям и т.п.
 - идёт обращение к таблицам системного каталога, в которых хранятся определения объектов. Например, `pg_class`, `pg_attribute`, `pg_type`, `pg_depend`, `pg_constraint`, `pg_namespace`, `pg_inherits`, `pg_attrdef`, `pg_sequence`
 - Выбранные данные кэшируются в локальной памяти процесса, обслуживающего сессию пользователя

Трансформация (переписывание) запроса

- преобразование исходной структуры запроса в аналогичную с точки зрения получения результата в целях лучшей оптимизации на этапах планирования и выполнения в целях лучшей оптимизации на этапах планирования и выполнения
 - имена представлений, если такие были в запросе, заменяются запросами, на основе которых созданы представления

```
LOG:  rewritten parse tree:
DETAIL:  (
        {QUERY
        :commandType 1
        :querySource 0
        :canSetTag true
        :utilityStmt <>
        :resultRelation 0
        :hasAggs false
        :hasWindowFuncs false
        ...
    )
```

Планирование выполнения (оптимизация)

- Цель этого шага - получить наилучший способ (план) выполнения запроса
- Генерируются возможные способы выполнения запроса, оценивается трудоемкость выполнения и выбирается способ (план) выполнения с наименьшей стоимостью
- Для оценки стоимости используется
 - статистика, описывающая объекты
 - весовые коэффициенты из параметров конфигурации
 - параметры конфигурации, разрешающие использовать способы выборки и обработки строк
- В расчет стоимости включаются две части:
вычислительная сложность (процессор) и ввод-вывод

Выполнение запроса

- Чтение данных: читаются строки из блоков таблиц, индексов, функций
- Обработка данных: фильтрации, сортировки, группировки, вычисления
- Соединение наборов строк: если запрос включает в себя соединение таблиц или других источников данных
- Группировка строк: например, если используются групповые функции типа COUNT, SUM, AVG
- Возврат результата: возврат строк клиенту или в код, пославший запрос на выполнение
- Освобождение ресурсов: снимаются блокировки с объектов и освобождается память, использованная при выполнении запроса

Команда EXPLAIN

- выдаёт план выполнения запроса
 - › по умолчанию запрос не выполняется.
- Если указать опцию **analyze**, то запрос выполнится, после выполнения будет показан план с деталями выполнения.
 - › без опции **timing** off "**Execution Time**" может выдать время выполнения, превышающее реальное в несколько раз
 - › опция **buffers** показывает число буферов, которые считывались при планировании и выполнении

```
postgres=# explain (analyze, buffers) select * from t limit 1;
          QUERY PLAN
-----
Limit  (cost=0.03..0.04 rows=1 width=8) (actual time=0.048..0.067 rows=1 loops=1)
 Buffers: shared hit=2
-> Seq Scan on t  (cost=0.00..14425.00 rows=1000000 width=8) (actual time=0.015..0.020 rows=1 loops=1)
 Buffers: shared hit=2
Planning Time: 0.040 ms
Execution Time: 0.198 ms
(6 rows)
```

Параметры команды EXPLAIN

- 12 параметров, указываются в круглых скобках

```
postgres=# EXPLAIN (analyze, verbose, buffers, serialize text, settings, memory, wal) SELECT *
FROM t WHERE i = 100 AND j = 10;
               QUERY PLAN
-----
Gather  (cost=1000.00..11676.00 rows=10 width=8) (actual time=0.421..65.852 rows=10 loops=1)
  Output: i, j
  Workers Planned: 2
  Workers Launched: 2
  Buffers: shared hit=4425
  ->Parallel Seq Scan on public.t(cost=0.00..10675.00 rows=4 width=8) (actual
time=37.521..57.814 rows=3 loops=3)
    Output: i, j
    Filter: ((t.i = 100) AND (t.j = 10))
    Rows Removed by Filter: 333330
    Buffers: shared hit=4425
    Worker 0:  actual time=55.948..55.955 rows=0 loops=1
                Buffers: shared hit=1396
    Worker 1:  actual time=56.416..56.422 rows=0 loops=1
                Buffers: shared hit=1399
Query Identifier: 687797574221341570
Planning:
  Memory: used=11kB  allocated=16kB
Planning Time: 0.054 ms
Serialization: time=0.042 ms  output=1kB  format=text
Execution Time: 66.150 ms
```


Параметры команды EXPLAIN

- 12 параметров, указываются в круглых скобках

```
postgres=# EXPLAIN (analyze, verbose, buffers, serialize text, settings, memory, wal) SELECT *
FROM t WHERE i = 100 AND j = 10;
               QUERY PLAN
-----
Gather  (cost=1000.00..11676.00 rows=10 width=8) (actual time=0.421..65.852 rows=10 loops=1)
  Output: i, j
  Workers Planned: 2
  Workers Launched: 2
  Buffers: shared hit=4425
  ->Parallel Seq Scan on public.t(cost=0.00..10675.00 rows=4 width=8) (actual
time=37.521..57.814 rows=3 loops=3)
    Output: i, j
    Filter: ((t.i = 100) AND (t.j = 10))
    Rows Removed by Filter: 333330
    Buffers: shared hit=4425
    Worker 0:  actual time=55.948..55.955 rows=0 loops=1
                Buffers: shared hit=1396
    Worker 1:  actual time=56.416..56.422 rows=0 loops=1
                Buffers: shared hit=1399
Query Identifier: 687797574221341570
Planning:
  Memory: used=11kB  allocated=16kB
Planning Time: 0.054 ms
Serialization: time=0.042 ms  output=1kB  format=text
Execution Time: 66.150 ms
```

Индексы для ограничений целостности

- для ограничений целостности PRIMARY KEY и UNIQUE необходим уникальный индекс типа **btree** со столбцами, входящими в ограничение целостности.
- остальные индексы могут использоваться для ускорения запросов ("аналитические индексы"), полнотекстового поиска
- индексы ускоряют поиск строк и замедляют добавление, изменение, удаление строк
- индексы используют место на диске, размер сопоставим с размером таблицы
- пример замены индекса другим индексом:

```
create table t3 (n int4 primary key, m int4);
Indexes:
    "t3_pkey" PRIMARY KEY, btree (n)
create unique index concurrently t3_pkey1 on t3 (m,n);
ALTER TABLE t3 DROP CONSTRAINT t3_pkey, ADD CONSTRAINT t3_pkey PRIMARY KEY USING INDEX t3_pkey1;
NOTICE:  ALTER TABLE / ADD CONSTRAINT USING INDEX will rename index "t3_pkey1" to "t3_pkey"
Indexes:
    "t3_pkey" PRIMARY KEY, btree (m, n)
```

Способы доступа к данным в плане запроса

- способы, которыми процесс получает данные (строки, записи) из источников данных
- источниками могут быть таблицы, внешние таблицы, функции и т.п.
- расширения могут создавать свои методы доступа
- для способа Bitmap строится битовая карта по индексу
 - › построение карты отмечается строкой **Bitmap Index Scan**
 - › по битовой карте сканируются строки или блоки таблицы, что отмечается строкой **Bitmap Heap Scan** в плане:

```
Bitmap Heap Scan on tab (cost=10..1000.51 rows=998 width=11)
  Recheck Cond: (col1 < '1000'::numeric)
    -> Bitmap Index Scan on t_col1_idx (cost=0.00..9.60 rows=998 width=0)
      Index Cond: (col1 < '1000'::numeric)
```

Методы доступа к строкам

- два типа "методов" (способов) доступа к строкам таблиц: табличный и индексный
- Методы доступа можно добавлять расширениями:
 - > `create extension pg_columnar;`
 - > `create extension bloom;`
- Табличные методы доступа определяют способ хранения данных в таблицах и обычно считывают все строки
- Индексные методы обычно считывают часть блоков таблицы
- Для индексных методов (способов) нужно создать вспомогательный объект, называемый индексом
- Индексы создаются на **один** или **несколько** столбцов **таблицы**:

\dA	
List of access methods	
Name	Type
-----+-----	
bloom	Index
brin	Index
btree	Index
columnar	Table
gin	Index
gist	Index
hash	Index
heap	Table
spgist	Index
(9 rows)	

```
create table t (id int8, d date, s text);
create index t_idx on t using btree (id int8_ops, d date_ops);
create index t_idx1 on t using btree (s text_ops);
create index if not exists t_idx2 on t (id, d);
```

Способы соединения наборов строк

- Способы:
 - Соединение вложенным циклом (Nested Loop Join) с мемоизацией и без
 - Соединение хешированием (Hash Join) с использованием временных файлов и без использования
 - Соединение слиянием (Merge Join)
- Наборы строк всегда соединяются попарно

Кардинальность и селективность

- кардинальным числом отношения (сокращенно кардинальностью) или мощностью отношения называется число строк (они же tuples, кортежи)
 - › в плане rows и actual rows
 - › с 18 версии PostgreSQL rows - десятичное число

```
Gather (actual rows=2.00 loops=1)
-> Parallel Seq Scan on bookings (actual rows=0.67 loops=3)
```

- Селективность - доля (от нуля до 1) строк из выборки

postgresql.org/docs/18/release-18.html#RELEASE-18-CHANGES

Modify EXPLAIN to output fractional row counts (Ibrar Ahmed, Ilia Evdokimov, Robert Haas) 5 5

Стоимость плана запроса

- Стоимость (cost) - числовая оценка трудоемкости выполнения узла плана или всего запроса
- Состоит из двух чисел, между которыми две точки
 - `cost=0.00..14425.00`
- Первое число (startup cost) - стоимость отдачи первой строки в выборке
- Второе число (total cost) - стоимость отдачи всех строк
- Значение стоимости имеет смысл только для сравнения планов одного и того же запроса
- Для всех запросов, кроме курсоров, выбирается план с наименьшим вторым числом
- Стоимость одного и того же запроса коррелирует с временем выполнения этого запроса, но нелинейно

Статистики

- используется планировщиком при выборе плана
- базовая и расширенная статистика хранится в таблицах системного каталога
- сбор расширенной статистики устанавливается вручную командой `CREATE STATISTICS` или автоматически расширением `pg_stat_advisor`
 - после установки расширенная статистика собирается вместе с базовой автовакуумом (автоанализом) или при выполнении команд `VACUUM (ANALYZE)`
- накопительная статистика хранится в разделяемой памяти, доступна через представления `pg_stat_all_*` и функциями `pg_stat_get*`
 - при остановке экземпляра сохраняется в файл в директории `PGDATA/pg_stat/`
 - используется автовакуумом

Таблица pg_statistic

- Таблица pg_statistic хранит базовую статистику
- Собирается автоанализом и командой ANALYZE , используется для оптимизации запросов планировщиком
- По умолчанию пересобирается по default_statistics_target * 300 = 30000 строк
- содержатся данные по каждому столбцу таблиц
- Пример: доля строк с NULL в **третьем** столбце таблицы **test**:

```
select stanullfrac from pg_statistic
where starelid = 'test'::regclass and staattnum = 3;
stanullfrac
-----
0.9988884
```

Накопительная статистика

- по таблицам:

```
select schemaname||'.'||relname name, seq_scan, idx_scan, idx_tup_fetch, autovacuum_count, autoanalyze_count from
pg_stat_all_tables where idx_scan is not null order by 3 desc limit 1;
```

name	seq_scan	idx_scan	idx_tup_fetch	autovacuum_count	autoanalyze_count
public.pgbench_accounts	0	11183162	11183162	1512	266

```
select relname name, n_tup_ins ins, n_tup_upd upd, n_tup_del del, n_tup_hot_upd hot_upd, n_tup_newpage_upd
newblock, n_live_tup live, n_dead_tup dead, n_ins_since_vacuum sv, n_mod_since_analyze sa from pg_stat_all_tables
where idx_scan is not null order by 3 desc limit 1;
```

name	ins	upd	del	hot_upd	newblock	live	dead	sv	sa
pgbench_tellers	0	5598056	0	5497197	100859	10	1456051	0	165

- В представлении pg_statio_all_tables статистика по всем индексам на таблицу. Статистику (чтение с подгрузкой с диска и из кэша буферов) по конкретному индексу можно посмотреть в представлении pg_statio_all_indexes.

Расширение pg_stat_statements

- детальная статистика работы экземпляра с точностью до команд SQL
- для установки нужно загрузить библиотеку и установить расширение:

```
alter system set shared_preload_libraries = pg_stat_statements;  
create extension pg_stat_statements;
```

- в расширение входят 3 функции и 2 представления:

```
\dx+ pg_stat_statements  
function pg_stat_statements(boolean)  
function pg_stat_statements_info()  
function pg_stat_statements_reset(oid,oid,bigint,boolean)  
view pg_stat_statements  
view pg_stat_statements_info
```

- команды объединяются в одну строку в pg_stat_statements, когда они выполняются одним и тем же пользователем и имеют идентичные структуры запросов, то есть семантически равнозначны, за исключением литералов и переменных подстановки (**literal constants**)
- Например: `select * from t where id = 'a'` и `select * from t where id = 'b'` объединятся в `select * from t where id = $1`

Параметры `pg_stat_statements`

- `pg_stat_statements.max` задаёт максимальное число команд, отслеживаемых расширением, то есть, максимальное число строк в представлении `pg_stat_statements`
- `pg_stat_statements.save` определяет, должна ли статистика сохраняться после перезагрузки сервера
- `pg_stat_statements.track` определяет, какие команды будут отслеживаться: `top` отслеживаются только команды верхнего уровня
- `pg_stat_statements.track_planning` устанавливает будут ли отслеживаться операции планирования и длительность фазы планирования
- `pg_stat_statements.track_utility` будут ли отслеживаться команды, **ОТЛИЧНЫЕ ОТ SELECT, INSERT, UPDATE, DELETE, MERGE**

```
select name, setting, context, min_val, max_val from pg_settings where name like 'pg_stat_statements%';
```

name	setting	context	min_val	max_val
pg_stat_statements.max	5000	postmaster	100	1073741823
pg_stat_statements.save	on	sighup		
pg_stat_statements.track	top	superuser		
pg_stat_statements.track_planning	on	superuser		
pg_stat_statements.track_utility	on	superuser		

Практика

1. Создание объектов для запросов
2. Извлечение данных последовательно
3. Возвращение данных по индексу
4. Низкая селективность
5. Использование статистики
6. Представление `pg_stat_statements`



2e Архитектура PostgreSQL

Расширения PostgreSQL

Расширяемость PostgreSQL

- добавление функционала без внесения изменений в файлы исходного кода и перекомпиляции
- можно создавать типы данных, операторы, групповые функции, приведения типов
- создание хранимых подпрограмм на большом числе языков программирования
- создание и использование расширений (extensions)
 - › набор любых объектов базы данных, который можно установить или удалить как единое целое
- расширение функционала разделяемыми библиотеками
- обёртки внешних данных (FDW)

Директории файлов расширений и библиотек

- Файлы библиотек находятся в директории:
- /opt/tantor/db/17/lib/**postgresql**
- Файлы расширений (*.control и *.sql) находятся в директории:
- /opt/tantor/db/17/share/postgresql/**extension**
- Узнать местоположение можно командами:

```
postgres@tantor:/opt/tantor/db/17/lib$ pg_config --libdir
/opt/tantor/db/17/lib
postgres@tantor:/opt/tantor/db/17/lib$ pg_config --sharedir
/opt/tantor/db/17/share/postgresql
```

- Установка способом "PGXS":

```
root@tantor:~# export PATH=/opt/tantor/db/17/bin:$PATH
root@tantor:~# export USE_PGXS=1
root@tantor:~# cd директория_расширения
root@tantor:~# make
root@tantor:~# make install
```

- обычно расширения, библиотеки, утилиты, приложения устанавливаются пакетами deb и rpm

Установка расширений

- Расширения могут включать в себя разделяемую библиотеку и/или текстовые файлы: управляющий файл расширения и один или более файлов скриптов
- библиотеки загружаются параметрами или командой:

```
postgres=# \dconfig *librar*
archive_library          |
dynamic_library_path     | $libdir
local_preload_libraries |
session_preload_libraries |
shared_preload_libraries | pg_stat_statements
postgres=# load 'библиотека';
LOAD
postgres=# \dx
```

- объекты расширения устанавливаются командой:

```
postgres=# create extension имя;
CREATE EXTENSION
```

- доступные к установке расширения перечислены в представлении `pg_available_extentions`

Файлы расширений

- пример управляющего файла `pg_stat_kcache--2.3.0.control`


```
# pg_stat_kcache extension
comment = 'Kernel statistics gathering'
default_version = '2.3.0'
requires = 'pg_stat_statements'
module_pathname = '$libdir/pg_stat_kcache'
relocatable = true
```

- пример файла скрипта `pg_stat_kcache--2.3.0.sql`

```
-- complain if script is sourced in psql, rather than via CREATE EXTENSION
\echo Use "CREATE EXTENSION pg_stat_kcache" to load this file. \quit
SET client_encoding = 'UTF8';
CREATE FUNCTION pg_stat_kcache_reset()
    RETURNS void
    LANGUAGE c COST 1000
    AS '$libdir/pg_stat_kcache', 'pg_stat_kcache_reset';
REVOKE ALL ON FUNCTION pg_stat_kcache_reset() FROM public;
...
```

Foreign Data Wrapper

- ЦОбертка внешних данных) - функционал для обращения к данным, находящимся вне базы данных из сессии с базой данных PostgreSQL стандартизованным и относительно простым способом
- В PostgreSQL включены две обертки (драйвера): `postgres_fdw` для работы с таблицами в базах данных PostgreSQL и `file_fdw` к содержимому текстовых файлов
- FDW устанавливается как расширение
- Существуют расширения: `mysql_fdw`, `oracle_fdw`, `sqlite_fdw`, `mongo_fdw`, `redis_fdw`
- команды `psql` для просмотра объектов FDW: `\dew`, `\des`, `\deu`, `\det`



Расширение file_fdw

- file_fdw позволяет создавать виртуальные таблицы на основе данных, хранящихся в текстовых файлах
- вносить изменения в файлы нельзя, только читать
- индексов нет, при каждом SELECT просматривается весь файл
- пример создания объектов FDW:

```
CREATE EXTENSION file_fdw;  
CREATE SERVER csv_server FOREIGN DATA WRAPPER file_fdw;  
CREATE FOREIGN TABLE t1 (  
    column1 text,  
    column2 numeric,  
    ...  
)  
SERVER csv_server OPTIONS (filename '/path/to/file.csv', format 'csv');
```

Расширение dblink

- позволяет посылать команды на выполнение и получать результат

```
SELECT * FROM dblink('dbname=postgres user=postgres', $$ select 7; $$ ) as (col1 int);
7
SELECT * FROM dblink_connect('connection1','host=/var/run/postgresql port=5432');
OK
SELECT * FROM dblink_send_query('connection1', $$ select 8 from pg_sleep(1); $$ );
1
SELECT dblink_is_busy('connection1');
1
SELECT * FROM dblink_get_result('connection1') as t(col1 int);
8
SELECT dblink_is_busy('connection1');
0
SELECT * FROM dblink_exec('connection1', $$ CHECKPOINT; $$);
CHECKPOINT
SELECT * FROM dblink_disconnect('connection1');
OK
```

Практика

1. Определение директории с файлами расширения
2. Просмотр установленных расширений
3. Просмотр доступных расширений
4. Установка и удаление произвольного обновления
5. Просмотр доступных версий расширений
6. Обновление до актуальной версии
7. Обертки внешних данных



3

Конфигурирование PostgreSQL

Обзор

- имеется около 370 параметров
- влияют на работу экземпляра
- название нечувствительно к регистру
- расширения и приложения могут использовать свои параметры конфигурации, у таких параметров в названии присутствует точка
- настройка экземпляра - установка значений параметров конфигурации так, чтобы работа экземпляра была оптимальной при текущей нагрузке

Параметры конфигурации

- Первым просматривается основной файл конфигурации `postgresql.conf`
Параметры могут дублироваться применяется последний
- Далее применяются параметры `$PGDATA/postgresql.auto.conf`
- Параметры командной строки передаваемые процессу `postgres` -с превалируют над установленными в файлах параметров
`pg_ctl start -o "-c config_file=/opt/postgresql.conf"`

Просмотр параметров

- Команда `psql \dconfig`
 - можно искать по шаблону `\dconfig *имя*`
 - можно использовать клавишу табуляции
- Команда `SHOW имя_параметра;`
 - можно использовать клавишу табуляции
 - нужно посылать на выполнение набрав `;"`
 - только один параметр
- функция `current_setting('имя параметра')`

Просмотр параметров

- Представления `pg_settings` `pg_file_settings`
- Команда `SHOW ALL;`
 - аналог `SELECT * FROM pg_settings;`
 - нельзя отфильтровать параметры

- Файлы `postgresql.conf` `postgresql.auto.conf`

```
ls -CF /var/lib/postgresql/tantor-se-16/data
```

```
base/          pg_logical/    pg_stat/       pg_wal/
global/        pg_multixact/  pg_stat_tmp/   pg_xact/
pg_commit_ts/  pg_notify/     pg_subtrans/   postgresql.auto.conf
pg_dynshmem/   pg_replication/ pg_tblspc/     postgresql.conf
pg_hba.conf    pg_serial/     pg_twophase/   postmaster.opts
pg_ident.conf  pg_snapshots/  PG_VERSION     postmaster.pid
```

- просмотр одного параметра на запущенном или остановленном экземпляре
`postgres -C имя_параметра`

Просмотр параметров

- Представления `pg_settings` `pg_file_settings`
- Команда `SHOW ALL;`
 - аналог `SELECT * FROM pg_settings;`
 - нельзя отфильтровать параметры

- Файлы `postgresql.conf` `postgresql.auto.conf`

```
ls -CF /var/lib/postgresql/tantor-se-16/data
```

base/	pg_logical/	pg_stat/	pg_wal/
global/	pg_multixact/	pg_stat_tmp/	pg_xact/
pg_commit_ts/	pg_notify/	pg_subtrans/	postgresql.auto.conf
pg_dynshmem/	pg_replslot/	pg_tblspc/	postgresql.conf
pg_hba.conf	pg_serial/	pg_twophase/	postmaster.opts
pg_ident.conf	pg_snapshots/	PG_VERSION	postmaster.pid

- просмотр одного параметра на запущенном или остановленном экземпляре
`postgres -C имя_параметра`

Основной файл параметров postgresql.conf

- основной файл, в котором хранятся параметры конфигурации кластера
- может содержать более 370 параметров плюс параметры расширений и разделяемых библиотек (*.so)
- Создаётся на основе файла postgresql.conf.sample утилитой initdb
- Можно редактировать
- Можно включать содержимое других файлов параметрами конфигурации include и include_dir заданными внутри postgresql.conf

Файл параметров postgresql.auto.conf

- Расположен в директории PGDATA
- Параметры добавляются командой
 - › `ALTER SYSTEM SET параметр = значение;`
- Параметры убираются командой
 - `ALTER SYSTEM RESET параметр;`
 - `ALTER SYSTEM RESET ALL;`
- Чтобы новые значения вступили в силу после изменения командой `ALTER SYSTEM` нужно перечитать конфигурацию или перезагрузить кластер

Применение изменений параметров

- Для применения изменений перечитываются все файлы конфигурации и применяются изменения которые можно провести без перезагрузки кластера
- Способы:
 - › `SELECT pg_reload_conf();`
 - › `pg_ctl reload`
 - › `sudo killall -1 postgres`
- Параметры в `postgresql.auto.conf` перекрывают значения параметров `postgresql.conf`
- Если в `postgresql.conf` параметр указан несколько раз, применяется указанный ближе к концу файла

Привилегии на изменение параметров

- Тип параметра указан в столбце `context` представления `pg_settings`
- Команду `ALTER SYSTEM` может выполнять роль с атрибутом `SUPERUSER` и те роли, которым была дана привилегия `GRANT ALTER SYSTEM on PARAMETER имя_параметра to роль;`
- Посмотреть список привилегий можно командой `psql:`

```
\dconfig+ имя_привилегии
```

Parameter	Value	Type	Context	Access privileges
update_process_title	off	bool	superuser	postgres= sA /postgres+ user1= s /postgres

- или запросом `select * from pg_parameter_acl;`
- **A** - право на `ALTER SYSTEM`, **s** - право на `SET`

Классификация параметров: Контекст

- internal - параметры только для чтения
- postmaster - нужен перезапуск экземпляра кластера
- sighup - достаточно перечитать файлы конфигурации
- superuser - могут устанавливаться на уровне сессии, но у пользователя должен быть атрибут SUPERUSER или привилегия на изменение этого параметра
- superuser-backend - не могут быть изменены после создания сессии, но могут быть установлены для конкретной сессии в момент подключения, если есть привилегии
- backend - как и предыдущий, но привилегий не нужно
- user - можно менять в течение сессии или на уровне кластера

Параметры контекста internal

- 19 параметров в 17 версии
- только для чтения

```
postgres=# select name, setting from pg_settings where context='internal' order by 1;
```

name	setting
block_size	8192
data_checksums	on
data_directory_mode	0700
debug_assertions	off
huge_pages_status	off
in_hot_standby	off
integer_datetimes	on
max_function_args	100
max_identifier_length	63
max_index_keys	32
segment_size	131072
server_encoding	UTF8
server_version	17.2
server_version_num	170002
shared_memory_size	189
shared_memory_size_in_huge_pages	95
ssl_library	OpenSSL
wal_block_size	8192
wal_segment_size	16777216

(19 rows)

Классификация параметров: Уровни

- Кластера командой
 - › `ALTER SYSTEM SET параметр = значение;`
- Базы данных
 - › `ALTER DATABASE имя SET параметр = значение;`
- Роли
 - › `ALTER ROLE роль SET параметр = значение;`
- Сессии создаваемой ролью, подключающейся к конкретной базе данных
 - › `ALTER ROLE роль IN DATABASE имя SET параметр = значение;`

Классификация параметров: Уровни

- **Внутри сессии**

- › `SET work_mem to '16MB';`
- › `SELECT set_config('work_mem', '16MB', false);`

- **Транзакции**

- › `SET LOCAL work_mem to '16MB';`
- › `SELECT set_config('work_mem', '16MB', true);`

- **На время выполнения функции или процедуры**

- › `CREATE {FUNCTION|PROCEDURE} ..`
 `SET параметр {TO значение | = значение | FROM CURRENT}`
- › `ALTER {PROCEDURE | FUNCTION} ..`
 `SET параметр {TO | = } {значение | DEFAULT};`

Параметры хранения на уровне таблиц

- Устанавливаются командой
 - `ALTER TABLE имя SET (параметр_хранения = значение);`
- Можно установить в команде `CREATE TABLE`
- Перекрывают аналогичные параметры конфигурации при работе автовакуума с конкретной таблицей и/или её TOAST таблицей
- Команда перекрывающая значение параметра конфигурации `default_statistics_target` для столбца таблицы:
 - `ALTER TABLE имя ALTER COLUMN имя SET STATISTICS число;`

Классификация параметров: Категории

- Категории описывают для чего предназначены параметры

```
select category, count(name) from pg_settings group by category order by
2 desc;
```

category	count
Client Connection Defaults / Statement Behavior	31
Developer Options	25
Resource Usage / Memory	22
Query Tuning / Planner Method Configuration	22
Reporting and Logging / What to Log	21
Preset Options	18
Write-Ahead Log / Settings	15
Connections and Authentication / SSL	14
Autovacuum	13
Query Tuning / Planner Cost Constants	13
...	
(42 rows)	

Категория: "Для разработчиков"

- Категория параметров `Developer Options`
- Параметры этой категории не должны использоваться при промышленной эксплуатации
- Параметры из этой категории могут помочь получить данные в сложных случаях повреждения страниц
- `ignore_system_indexes` - игнорировать системные индексы при чтении системных таблиц (но все же обновлять индексы при изменении таблиц). Может пригодиться, если повреждения в системных индексах не позволяют создать сессию для устранения повреждений
- `zero_damaged_pages` - повреждения в служебной области блока не даёт прочесть данные из этого блока. Параметр позволяет считать блок пустым, как будто в нем нет строк

Категория: "Пользовательские настройки"

- Категория параметров `Customized Options`
- В категорию входят параметры расширений, библиотек или просто произвольные параметры, в названии которых присутствует точка
- разработчики библиотек и расширений дают возможность стандартным образом настраивать их функционал

```
SET myapp.par1 = '20';
```

```
SET
```

```
SHOW myapp.par1;
```

```
myapp.par1
```

```
-----
```

```
20
```

```
(1 row)
```


Названия и значения параметров конфигурации

- Названия параметров нечувствительны к регистру
- Значения параметров - один из пяти типов:
- `boolean`: значения можно указывать как `on`, `off`, `true`, `false`, `yes`, `no`, `1`, `0`
- `строка`: значения лучше задать в апострофах
- `целое или десятичное число`: в единицах измерения из столбца `unit` представления `pg_settings` или просто число
- `enum`: значение из списка в столбце `enumvals` представления `pg_settings`

Параметр конфигурации `transaction_timeout`

- позволяет отменить любую транзакцию, длительность которой превышает указанный период времени
- действие параметра распространяется как на явные транзакции (начатые с помощью команды `BEGIN`), так и на неявно начатые транзакции, соответствующие отдельной команде
- Значение ноль (по умолчанию) отключает таймаут
- Позволяет устанавливать ограничение на длительность транзакций
- `statement_timeout` позволяет установить максимальное время выполнения отдельной команды

Автономные транзакции

- В Tantor Postgres SE есть автономные транзакции
- используются в подпрограммах на plpgsql
- позволяют выполнить команды и сохранить результат их выполнения независимо от того зафиксировается, откатится или прервётся транзакция, в которой была вызвана автономная транзакция

```
postgres=# CREATE TABLE t (a int);
CREATE TABLE
postgres=# CREATE OR REPLACE PROCEDURE p()
LANGUAGE plpgsql
AS $$
DECLARE
    PRAGMA AUTONOMOUS_TRANSACTION;
BEGIN
    INSERT INTO t VALUES (1);
END;
$$;
CREATE PROCEDURE
postgres=# BEGIN TRANSACTION;
BEGIN
postgres=*# CALL p();
CALL
postgres=*# ROLLBACK;
ROLLBACK
postgres=# SELECT * FROM t;
 a
---
 1
(1 row)
```

Параметр конфигурации transaction_buffers

- задаёт размер общей памяти, используемый для кэширования содержимого PGDATA/pg_xact - подкаталога со статусом фиксации транзакций
- Значение по умолчанию - 0, что равно размеру разделяемого пула буферов, деленному на 512 (shared_buffers/512)

Параметры multixact_members_buffers и multixact_offsets_buffers

- задают размер общей памяти, используемой для кеширования содержимого двух поддиректорий PGDATA/pg_multixact
- Убедиться, что в кластере используются 64-битные идентификаторы транзакций можно по значениям параметров:

```
\dconfig autovacuum_*age
```

List of configuration parameters

Parameter	Value
-----+-----	
autovacuum_freeze_max_age	10000000000
autovacuum_multixact_freeze_max_age	20000000000

- если значения больше 4 миллиардов, то используются 64-битные счетчики транзакций и мультитранзакций

Параметр конфигурации subtransaction_buffers

- задаёт размер общей памяти, используемой для кеширования содержимого PGDATA/pg_subtrans
- подтранзакция создается:
 - › командой SAVEPOINT
 - › если в блоке на языке plpgsql присутствует секция EXCEPTION
 - › в psql неявно перед каждой командой в транзакции, если включён (interactive или on) параметр командой:
`\set ON_ERROR_ROLLBACK interactive`
- наличие секции EXCEPTION неявно устанавливает точку сохранения перед началом блока (перед BEGIN)

Параметр конфигурации notify_buffers

- задаёт размер общей памяти, используемой для кеширования содержимого PGDATA/pg_notify
- Значение по умолчанию 8 блоков (64Кб)
- Используются в архитектуре NOTIFY/LISTEN обмена данными между процессами:

```
postgres=# listen abc;
```

```
LISTEN
```

```
postgres=# notify abc;
```

```
NOTIFY
```

```
Asynchronous notification "abc" received from  
server process with PID 1234.
```

Задание параметров при создании кластера

- переменными окружения и параметрами утилиты initdb
- параметры initdb --lc-collate, --lc-ctype, --encoding нельзя изменить после создания кластера
- значения параметров локализации можно посмотреть командой `psql \1`
- Параметр initdb -k или --data-checksums задает подсчет контрольных сумм в страницах файлов данных
- включить и отключить подсчет контрольных сумм можно после создания кластера
- проверить статус в `psql \dconfig data_checksums`
- проверка контрольных сумм блоков данных выполняется утилитами `pg_checksums` и `pg_verifybackup`

Разрешения на директорию PGDATA

- Параметр `initdb -g` или `--allow-group-access` устанавливает разрешения 0750 (`rwX r-X ---`)
- если не указать, то пересоздавать кластер не нужно, можно поменять разрешения на PGDATA (и поддиректории) на допустимые значения
- Допустимые значения **0750** и **0700**:
- **`pg_ctl start`**

```
waiting for server to start....
```

```
FATAL:  data directory
```

```
    "/var/lib/postgresql/tantor/se16/data" has invalid  
permissions
```

```
DETAIL:  Permissions should be u=rwx (0700) or u=rwx,g=rX  
        (0750) .
```

```
stopped waiting
```

Размер блока данных PostgreSQL

- размер 8192 байт = 8Кб задан при компиляции
- синоним "страница"
- при нахождении в памяти занимает буфер в буферном кэше

Ограничения PostgreSQL

размер базы данных	не ограничен
количество баз данных в кластере	4,294,950,911
отношений в одной базе	1,431,650,303
размер отношения	32ТБ (блок 8КБ)
блоков в таблице	4,294,950,911
столбцов в таблице	1600
столбцов в выборке (SELECT)	1664
размер поля (в том числе text, bytea)	1ГБ
размер больших объектов (lo)	4ТБ
общий объем lo в базе	32ТБ (блок 8КБ)
длина идентификатора	63 байта
индексов на таблицу	не ограничено
размер строкового буфера	1ГБ-1
столбцов в составном индексе	32

Параметр `enable_large_allocations`

- параметр СУБД Tantor Postgres, который увеличивает размер `StringBuffer` с 1 гигабайта до 2 гигабайт

```
postgres=# select * from pg_settings where name like '%large%'\gx
name          | enable_large_allocations
setting       | off
category      | Resource Usage / Memory
short_desc    | whether to use large memory buffer greater than 1Gb, up to 2Gb
context       | superuser
vartype       | bool
boot_val      | off
```

- может устанавливаться на уровне сессии и утилитами `pg_dump`, `pg_dumpall`

```
postgres@tantor:~$ pg_dump --help | grep alloc
--enable-large-allocations  enable memory allocations with size up to 2Gb
```

- проблема возникает со строкой таблицы `config` приложений 1С:ERP, Комплексная автоматизация, Управление производственным предприятием

Ограничения на длину идентификаторов

- Максимальная длина идентификаторов (например, имен таблиц, столбцов, индексов и т. д.) составляет 63 символа
- Например, вы можете создать таблицу с именем, содержащим до 63 символов:
- `CREATE TABLE
my_really_long_table_name_with_63_characters (...);`
- Или столбец с именем, также содержащим до 63 символов:
- `ALTER TABLE my_table_name ADD COLUMN
my_really_long_column_name_with_63_characters
INTEGER;`
- идентификаторы превышающие этот размер усекаются, о чем выдается предупреждение

Конфигурационные параметры

- установлены при сборке и не меняются
- можно посмотреть:
- утилитой командной строки `pg_config`
- в представлении `pg_config`
- функцией `pg_config()`
- Параметр `SHAREDIR` определяет директорию с файлами расширений
- `PKGLIBDIR` указывает на директорию разделяемых библиотек по умолчанию
- `BINDIR` определяет директорию с исполняемыми файлами

Демонстрация

- Просмотр параметров конфигурации

Практика

1. Обзор параметров конфигурации
2. Параметры конфигурации с единицей измерения
3. Параметры конфигурации логического типа
4. Конфигурационные параметры
5. Файл служб



4

4a

Логическая структура кластера

Кластер баз данных

- Кластер это набор или объединение баз данных
- В кластере есть общие объекты для всех баз данных
- Приложение подсоединяется к одной базе данных и имеет доступ к её объектам
- Кластер создаётся утилитой командной строки `initdb`
- Кластер создаётся в физическом месте хранения - директории, обозначаемой `"PGDATA"` по названию переменной окружения для утилит
- Базы данных в кластере можно создавать и удалять

Экземпляр

- Экземпляр это набор процессов и используемой ими памяти, обслуживающие один кластер баз данных
- Кластер баз данных обслуживается только одним экземпляром
- Первый и основной процесс экземпляра называется `postgres` или `postmaster`
- Необходимый параметр экземпляра - порт (`port`), по которому `postmaster` прослушивает входящие соединения по протоколам TCP и локально
- По умолчанию параметр конфигурации `port` имеет значение 5432

База данных

- База данных - логическое место хранения объектов SQL
- База данных - часть кластера
- Содержимое базы данных может быть выгружено на логическом уровне (в виде команд SQL) и загружено в другую базу данных этого или другого кластера
- Приложение создаёт сессию (session) с одной базой данных
- В сессии есть доступ к объектам одной базы данных
- Доступа к объектам других баз данных кластера в одной сессии нет

Список баз данных

- Получение списка это команда psql:
`\l` или `\l+`

```
postgres=# \l
                                List of databases
   Name   | Owner   | Encoding | Locale Provider | Collate  | Ctype    |
-----+-----+-----+-----+-----+-----+
 postgres | postgres | UTF8     | libc             | en_US.UTF-8 | en_US.UTF-8 |
 template0 | postgres | UTF8     | libc             | en_US.UTF-8 | en_US.UTF-8 |
 template1 | postgres | UTF8     | libc             | en_US.UTF-8 | en_US.UTF-8 |
 testdb   | postgres | UTF8     | libc             | en_US.UTF-8 | en_US.UTF-8 |
(4 rows)

postgres=# SELECT datname FROM pg_database;
 datname 
-----
 postgres
 template1
 template0
 testdb
```

Создание базы данных

- команда `CREATE DATABASE` или утилита `createdb`
- два режима создания базы: `WAL_LOG` и `FILE_COPY`
- создание базы это клонирование другой базы со всем содержимым
- у базы есть роль-владелец (`OWNER`)
- владельца и имя базы можно сменить после её создания
- можно создать базу со своими параметрами локализации (кодировкой)
- кодировку после создания базы изменить нельзя
- свойство базы "шаблонная" (`IS_TEMPLATE`) влияет на возможность ее клонирования непривилегированной ролью и удаление

Изменение свойств базы данных

- Командой `ALTER DATABASE` имя можно поменять некоторые свойства существующей базы данных
- Часть свойств можно поменять только если нет ни одной сессии к базе данных
- Командой `ALTER DATABASE SET` можно поменять конфигурационные параметры сессий, создаваемых с этой базой
- на уровне базы данных можно установить около 190 параметров конфигурации
- база данных - общий объект кластера и менять её свойства можно, подсоединившись к любой базе данных в кластере

Команда ALTER DATABASE

- Синтаксис команды по которому видно какие свойства **МОЖНО ПОМЕНЯТЬ**:
- ALTER DATABASE имя_базы
ALLOW_CONNECTIONS true|false
CONNECTION LIMIT -1/число
IS_TEMPLATE true|false
RENAME TO новое
OWNER TO новый
SET TABLESPACE новое
REFRESH COLLATION VERSION
SET параметр=значение

Удаление базы данных

- Выполняется командой `DROP DATABASE` или утилитой-оберткой `dropdb`
- Для выполнения команды нужно подсоединиться к любой базе кластера, отличной от удаляемой
- База данных удаляется со всем содержимым
- Команда нетранзакционна - откатить её нельзя
- Физически удаляются файлы в которых хранятся данные объектов базы

Схемы в базе данных

- синоним схемы - пространство имён (namespace)
- используются для упорядочивания хранения объектов базы данных
- Схема - локальный объект базы данных
- Схемы позволяют иметь несколько таблиц и других типов объектов с одинаковыми именами в одной и той же базе данных
- Объект не может находиться в нескольких схемах
- Схемы могут использоваться для логики объединения (пакетирования) подпрограмм
- Объектов "пакеты" в PostgreSQL нет

Создание и изменение схем

- Схемы не связаны с ролями, но имеют владельца
- При создании схемы можно назначить роль-владельца:
`CREATE SCHEMA имя_схемы AUTHORIZATION владелец;`
- Можно сменить владельца:
`ALTER SCHEMA имя_схемы OWNER TO роль;`
- Можно переименовать схему:
`ALTER SCHEMA имя_схемы RENAME TO имя;`
- На схемы можно выдавать привилегии `CREATE`, `USAGE` ролям

Путь поиска объектов в схемах

- задаёт список схем, в которых ищется объект
- устанавливается параметром `search_path`, который может быть изменён на любом уровне
- значение по умолчанию `"$user", public`

Специальные схемы

- `pg_catalog` - в этой схеме расположены объекты "системного каталога"
- `information_schema` - схема, описанная в стандарте SQL
- `pg_toast` - схема для особых таблиц TOAST
- `pg_temp` (ссылка на `pg_tempN` где N число) - схема для временных таблиц
- `pg_toast_temp` (ссылка на `pg_toast_tempN` где N число) - схема для временных TOAST таблиц на временные таблицы

Определение текущего пути поиска

- командой `psql SHOW search_path;`
 - выдает установленный для этого места путь поиска
- функцией `current_schemas(false)`
 - выдает действующий в этом месте путь поиска в виде массива
- функция `current_schemas(true)`
 - добавляет служебные схемы, а именно `pg_catalog` и `pg_temp_N`
- функция `current_schema` или `current_schema()`
 - выдает одно имя первой по порядку схемы в пути поиска или `NULL`, если путь поиска пустой

В какой схеме будет создан объект

- имя этой схемы для обычных объектов выдает функция `current_schema()`
- временные объекты создаются в служебных схемах
- служебные схемы для временных объектов создаются автоматически

Путь поиска в подпрограммах SECURITY DEFINER

- при использовании `$user` в пути поиска в теле подпрограммы будет подставлено имя владельца подпрограммы
- перед вызовом такой подпрограммы вызывающий ее может поменять значение в пути поиска и убрать `$user`, в этом случае в теле подпрограммы будет использоваться значение установленное вызывающим и подпрограмма может начать работать с другими объектами
- На уровне любой (INVOKER и DEFINER) подпрограммы можно установить значение для параметров конфигурации, которые могут меняться на уровне сессии

Маскировка объектов схем

- Если в командах перед именем объектов не используется имя схемы, добавление в путь поиска имея схемы, где создан объект с тем же именем маскирует исходный объект
- По умолчанию временная схема, схема системного каталога неявно присутствуют в начале пути поиска и создание временного объекта маскирует любую таблицу, представление, последовательность

```
postgres=# \dt pg_authid
               List of relations
 Schema | Name      | Type  | Owner
-----+-----+-----+-----
 pg_catalog | pg_authid | table | postgres
(1 row)

postgres=# create temporary table pg_authid(t text);
CREATE TABLE
postgres=# select * from pg_authid;
 t
---
(0 rows)

postgres=# select current_schemas(true);
      current_schemas
-----
 {pg_temp_4,pg_catalog,public}
(1 row)
```

Системный каталог

- Системный каталог это таблицы, представления, функции, индексы и другие объекты которые используются для хранения метаданных
- Объекты системного каталога располагаются в схеме `pg_catalog`
- Объекты системного каталога (кроме глобальных) всегда располагаются в табличном пространстве по умолчанию для базы данных
- названия объектов приводятся к нижнему регистру
- Таблицы системного каталога неявно используют процессы кластера на этапе выполнения команд SQL

Общие объекты кластера

- это объекты (таблицы и вспомогательные объекты) системного каталога, хранящие данные об общих объектах кластера
- располагаются в табличном пространстве `pg_global`
- Общие объекты кластера:
 - базы данных
 - роли
 - табличные пространства
 - подписки логической репликации
 - источники логической репликации

Использование системного каталога

- из таблиц и представлений системного каталога можно получать информацию командами SELECT, WITH, командами psql (начинаются на символ \), графическими приложениями и Платформой Tantor
- \? справка по командам psql
- Вносить изменения в таблицы системного каталога если, это не описано в документации нежелательно
- Зная архитектуру PostgreSQL, понятия, термины вы сможете легко получать информацию командами psql

Обращение к системному каталогу

- Выполняется командами SELECT и WITH
- можно соединять таблицы и представления
- столбец с именем oid - первичный ключ
- для связей между таблицами используется столбец oid
- максимальное число строк в таблицах системного каталога **4 миллиарда**
- первые три символа в названии столбцов - сокращенное название таблицы

reg-типы


- созданы для 11 таблиц системного каталога
- используются для приведения текстового имени объекта к значению типа oid и обратно
- позволяют проще писать запросы к таблицам системного каталога уменьшая количество соединений таблиц
- Пример: найти название TOAST таблицы созданной для таблицы pg_tablespace:

```
SELECT reltoastrelid, reltoastrelid::regclass
   FROM pg_class where relname='pg_tablespace';
reltoastrelid |      reltoastrelid
-----+-----
          4185 | pg_toast.pg_toast_1213
```

Часто используемые команды psql

- \l - список баз данных
- \du \dg - список ролей кластера
- \dn - список схем базы
- \db - список табличных пространств
- \dconfig *имя* - список параметров конфигурации
- \dfS pg* - список системных функций и процедур, полезных для администрирования. Часть информации о работе экземпляра и кластера можно получить только с помощью функций. Некоторые служебные представления используют функции
- \dvS pg* - полезные служебные представления
- символ + в конце команды показывает больше информации
пример: \db+ покажет размер и привилегии

Инспектор баз данных в Платформе Tantor



Демонстрация

- Просмотр списка баз данных кластера
- Создание базы данных
- Переименование базы данных
- Ограничение на соединение с базой
- форматирование вывода psql

Практика

1. Установка параметров конфигурации на различных уровнях
2. Установка пути поиска в функциях и процедурах



4

4b

Физическая структура кластера

Директория файлов кластера PGDATA

- Кластер хранит свои файлы в файловой системе
- Директория кластера называется PGDATA
- Директория или её поддиректории могут быть точками монтирования, жесткими, символическими ссылками
- Блочные устройства и неформатированные разделы жесткого диска не используются
- По умолчанию при работе с файлами кластера используется кэш операционной системы

Директория файлов кластера PGDATA

- содержит файлы параметров
- поддиректории

< ~/tantor-se-1c-17/data .[^]>		
.n	Name	Name
../	/pg_serial	autoprewarm.blocks
/base	/pg_snapshots	current_logfiles
/global	/pg_stat	pg_hba.conf
/log	/pg_stat_tmp	pg_ident.conf
/pg_commit_ts	/pg_subtrans	postgresql.auto.conf
/pg_dynshmem	/pg_tblspc	postgresql.conf
/pg_logical	/pg_twophase	postmaster.opts
/pg_multixact	/pg_wal	postmaster.pid
/pg_notify	/pg_xact	
/pg_replslot	PG_VERSION	

Временные объекты

- создаются в директориях табличных пространств
- табличные пространства для временных файлов задаются параметром `temp_tablespaces`
- рекомендуется создать отдельное табличное пространство для временных файлов
- временные файлы создаются если обрабатываемые данные не помещаются в память процесса
- временные файлы создаются для временных таблиц и их индексов, при выполнении команд SQL обрабатывающих большие объемы данных (например, сортировка, создание индекса)

Табличные пространства

- предназначены для того, чтобы кластер мог располагаться на нескольких устройствах хранения
- физически это директория в файловой системе
- являются общими объектами кластера
- могут хранить файлы нескольких баз данных кластера

Табличные пространства: характеристики

- Поддиректории создаются автоматически
- При создании кластера создаются табличные пространства `pg_global` и `pg_default`
- Список табличных пространств:
команда `\db` и таблица `pg_tablespace`
- содержимое списка одинаково во всех базах данных кластера
- `pg_tablespace` - глобальная таблица системного каталога

Табличные пространства: характеристики

- Без кластера не существуют
- Не могут перемещаться между кластерами
- Не могут резервироваться отдельно от кластера
- Не являются объектами схем
- Имеют роль-владельца
- Директория табличного пространства:
 - создаётся вручную в операционной системе
 - должна располагаться в файловых системах, устойчивых к потере питания
- рекомендуется создавать вне PGDATA
- в директории не стоит удалять вручную файлы, они удаляются автоматически командами SQL

Команды управления табличными пространствами

- Команда создания:

```
CREATE TABLESPACE имя [ OWNER роль ] LOCATION  
'директория'  
[ WITH ( параметр = значение [, ...] ) ]
```

- Смена владельца:

```
ALTER TABLESPACE имя OWNER TO роль;
```

- Переименование:

```
ALTER TABLESPACE имя RENAME TO имя;
```

- База данных имеет табличное пространство "по умолчанию", в нем находятся файлы объектов системного каталога этой базы данных
- Команда изменения табличного пространства по умолчанию для базы данных:

```
ALTER DATABASE база SET TABLESPACE имя;
```

Изменение директории табличного пространства

- Кластер определяет директорию табличного пространства по символической ссылке в директории PGDATA/pg_tblspc
- Процедура замены:
 - › Найдите название символической ссылки в директории PGDATA/pg_tblspc, указывающую на директорию табличного пространства
 - › Остановите экземпляр
 - › Переместите директорию табличного пространства
 - › Обновите символическую ссылку
 - › Запустите экземпляр


Параметры табличных пространств

- Четыре параметра: `seq_page_cost`, `random_page_cost`, `effective_io_concurrency`, `maintenance_io_concurrency`
- Перекрывают значения параметров, установленных на уровне кластера
- Влияют на стоимость плана выполнения команд SQL
- Можно задать при создании табличного пространства:
`CREATE TABLESPACE имя WITH ( параметр = значение [, ...] );`
- Можно изменить позже:
`ALTER TABLESPACE имя SET ( параметр = значение [, ...] );`
- Можно сбросить установленное значение:
`ALTER TABLESPACE имя RESET ( параметр [, ...] );`

	Read (MB/s)	Write (MB/s)
RND8K Q32T1	494.43	336.17
RND8K Q64T1	504.69	297.60

Работа с файлами журнала

- Параметры `wal_recycle` и `wal_init_zero` определяют работу с файлами WAL журнала
- По умолчанию файлы повторно используются, вновь создаваемые заполняются нулями
- PGDATA/pg_wal хранит файлы журнала, ее можно смонтировать на отдельный раздел
- Рекомендуется включить сжатие образов страниц параметром `wal_compression`
- При использовании SSD большая часть раздела файловой системы должна быть свободна



Основной слой хранения данных

- состоит из файлов размером до 1Гб
- новые файлы создаются при достижении предыдущего файла слоя 1Гб
- Максимальный размер файлов слоя 32Тб
- Работа с файлами всех слоёв объектов постоянного хранения происходит через буферный кэш
- Работа с файлами всех слоёв временных объектов происходит через буфер в локальной памяти серверного процесса
- Файлы всех слоёв располагаются в одной директории одного табличного пространства

Дополнительные слои

Карта свободного пространства (fsm)

- не создается для хэш-индексов
- создается вакуумированием

Карта видимости (vm)

- не создается для индексов
- создается вакуумированием
- два бита на блок основного слоя
- установленный первый бит означает что все строки блока актуальны и нет старых версий
- установленный второй бит означает что все строки блока заморожены

Слой инициализации (init)

- создается для нежурналируемых таблиц и индексов
- файл размером один блок без данных

Расположение файлов объектов

- Если объект расположен в `pg_default` то файлы располагаются в директории:
`PGDATA/base/{oid базы данных}`
- Если в других табличных пространствах (значение столбца `reltablespace` в `pg_class` не равно нулю), то:
`PGDATA/pg_tblspc/{reltablespace}/{oid базы данных}`
- Имена файлов объектов начинаются на `relfilenode`
- Для получения местоположения (относительно PGDATA) первого файла данных объекта используется функция `pg_relation_filepath(oid)`

Размеры табличных пространств и баз данных

- размер табличных пространств кластера \db+ или функция `pg_tablespace_size()`

```
postgres=# \db+
                               Список табличных пространств
   Имя      | Владелец | Расположение | Права доступа | Параметры | Размер
-----+-----+-----+-----+-----+-----
pg_default | postgres |              |               |           | 30 MB
pg_global  | postgres |              |               |           | 565 kB
postgres=# SELECT spcname, pg_size_pretty(pg_tablespace_size(oid)) FROM pg_tablespace;
 spcname | pg_size_pretty
-----+-----
pg_default | 30 MB
pg_global  | 565 kB
```

- размер баз данных: \l+ или функция `pg_database_size()`

```
postgres=# SELECT datname, pg_size_pretty(pg_database_size(datname)) FROM pg_database;
 datname | pg_size_pretty
-----+-----
postgres | 7737 kB
template1 | 7609 kB
template0 | 7377 kB
lab01iso88595 | 7537 kB
```

Функции определения размера

- Для получения размера файлов объектов есть набор функций
- `pg_relation_size(regclass, 'main' | 'vm' | 'fsm' init')` выдает размеры слоёв
- `pg_indexes_size()` размер всех индексов созданных на таблицу
- `pg_table_size()` размер таблицы (TOAST и всех слоёв) без индексов
- `pg_total_relation_size()` размер таблицы включая TOAST, все индексы и слои

Перемещение объектов

- можно переместить файлы таблиц, индексов, материализованных представлений
- в новые файлы копируется содержимое файлов всех слоёв
- устанавливает монопольную блокировку, несовместимую даже с командой `SELECT`
- Команда `ALTER тип ALL IN TABLESPACE` перемещает все объекты одного типа в текущей базе данных

Смена схемы и владельца

- можно менять владельца объекта и схему у тех объектов, у которых они должны быть
- Для смены владельца используется команда:
`ALTER тип_объекта имя OWNER TO роль;`
- Для смены схемы используется команда:
`ALTER тип_объекта имя SET TO схема;`
- Для массового переназначения всех объектов ролей в одной базе на другую роль используется команда:
`REASSIGN OWNED BY роль TO роль;`
- удаление объектов принадлежащих роли в базе:
`DROP OWNED BY имя [CASCADE];`

Реорганизация и перемещение таблиц утилитой pg_repack

- утилита командной строки pg_repack
- имеется в Tantor Postgres
- нужно установить расширение в базах данных, где нужно реорганизовать таблицы
- реорганизация файлов таблиц с перемещением в другое табличное пространство или без перемещения
- в процессе реорганизации устанавливается блокировка ACCESS SHARE, позволяющая выполнять команды VACUUM, ANALYZE, SELECT, DML
- в конце реорганизации на короткое время устанавливается эксклюзивная блокировка

Уменьшение размера файлов таблиц утилитой `pgcompacttable`

- Утилита написанная на языке Perl
- использует стандартное расширение `pgstattuple`
- Отличия от `pg_repack`:
 - свободное место равно размеру самого большого индекса, а не двойной размер таблицы и индексов
 - таблицы обрабатываются с адаптивной задержкой, а не с полной нагрузкой
 - не может перемещать файлы в другое табличное пространство

TOAST (The Oversized-Attribute Storage Technique)

- Обычные таблицы (heap tables) хранят данные "построчно"
- Если строка не помещается в блоке данных, то используется технология TOAST
- Четыре режима хранения на уровне каждого столбца: PLAIN, EXTERNAL, EXTENDED, MAIN
- Для типов данных небольшого размера не предусмотрено хранение в TOAST и режим единственный: PLAIN
- для большинства остальных типов данных по умолчанию установлен режим EXTENDED
- используется сжатие на уровне полей, для полей небольшого размера сжатие неэффективно

TOAST (The Oversized-Attribute Storage Technique)

- TOAST это техника хранения "атрибутов" (полей) большого размера
- поля большого размера - это поля не помещающиеся в блок
- позволяет хранить поля размером до 1Гб
- если в таблице есть заведомо большое поле или вставляется строка с большим полем, то создается toast-таблица и индекс на toast-таблицу
- в TOAST выносятся отдельные поля строк
- вынесенные поля делятся на части (chunk) по 1996 байт:

```
postgres@tantor:~$ pg_controldata | grep TOAST
Maximum size of a TOAST chunk:          1996
postgres@tantor:~$ /usr/lib/postgresql/15/bin/pg_controldata
-D /var/lib/postgresql/15/main | grep TOAST
Maximum size of a TOAST chunk:          1988
postgres@vanilla-x32:~$ pg_controldata | grep TOAST
Maximum size of a TOAST chunk:          2000
```


Поля переменной длины

- строка должна поместиться в один блок
- поля `varlena`, которые не помещаются в блок выносятся в таблицу TOAST
- типы данных фиксированной длины не сжимаются и не выносятся в TOAST
- стратегию хранения можно установить командой `ALTER TABLE имя ALTER COLUMN имя SET STORAGE { PLAIN | EXTERNAL | EXTENDED | MAIN | DEFAULT }`.
- сжатие поддерживается для MAIN и EXTENDED
- 1 байт в начале поля переменной длины хранит длину поля длиной до 127 байт
- 4 байта в начале поля переменной длины хранит длину поля для полей длиннее 126 байт

Вытеснение полей в TOAST

- выносятся поля строк длиной больше 2032 байт
 - при этом поля режутся на части по 1996 байт
- алгоритм (очередность) вытеснения зависит от порядка следования столбцов
- при доступе к каждому вытесненному полю дополнительно читается 2-3 блока TOAST-индекса

```
select reltoastrelid, reltoastrelid::regclass
from pg_class where relname='t';
reltoastrelid | reltoastrelid
-----+-----
74295 | pg_toast.pg_toast_74292
\d+ pg_toast.pg_toast_74292
TOAST table "pg_toast.pg_toast_74292"
  Column | Type | Storage
-----+-----+-----
 chunk_id | oid | plain
 chunk_seq | integer | plain
 chunk_data | bytea | plain
Owning table: "public.t"
Indexes:
    "pg_toast_74292_index" PRIMARY KEY,
                        btree (chunk_id, chunk_seq)
Access method: heap
select chunk_id, chunk_seq, length(chunk_data)
from pg_toast.pg_toast_74292;
 chunk_id | chunk_seq | length
-----+-----+-----
74297 | 0 | 1996
74297 | 1 | 9
```

Алгоритм вытеснения полей в TOAST

- при вставке строки в таблицу она полностью размещается в памяти серверного процесса в строковом буфере размера 1Гб (или 2Гб)
- при обновлении строки обработка выполняется по затрагиваемым командой полям в пределах строкового буфера. Поля, не затрагиваемые командой, представлены в буфере заголовком длиной 18 байт.
- после обработки (сжатия или выноса) каждого поля проверяется размер строки. Если размер не превышает `toast_tuple_target` (по умолчанию 2032 байт) строка сохраняется в буфер и обработка строки заканчивается
- обработка начинается с поля EXTENDED и EXTERNAL от наибольшего размера к меньшему
- сжатие и вынос полей MAIN выполняется только после выноса всех полей EXTENDED и EXTERNAL

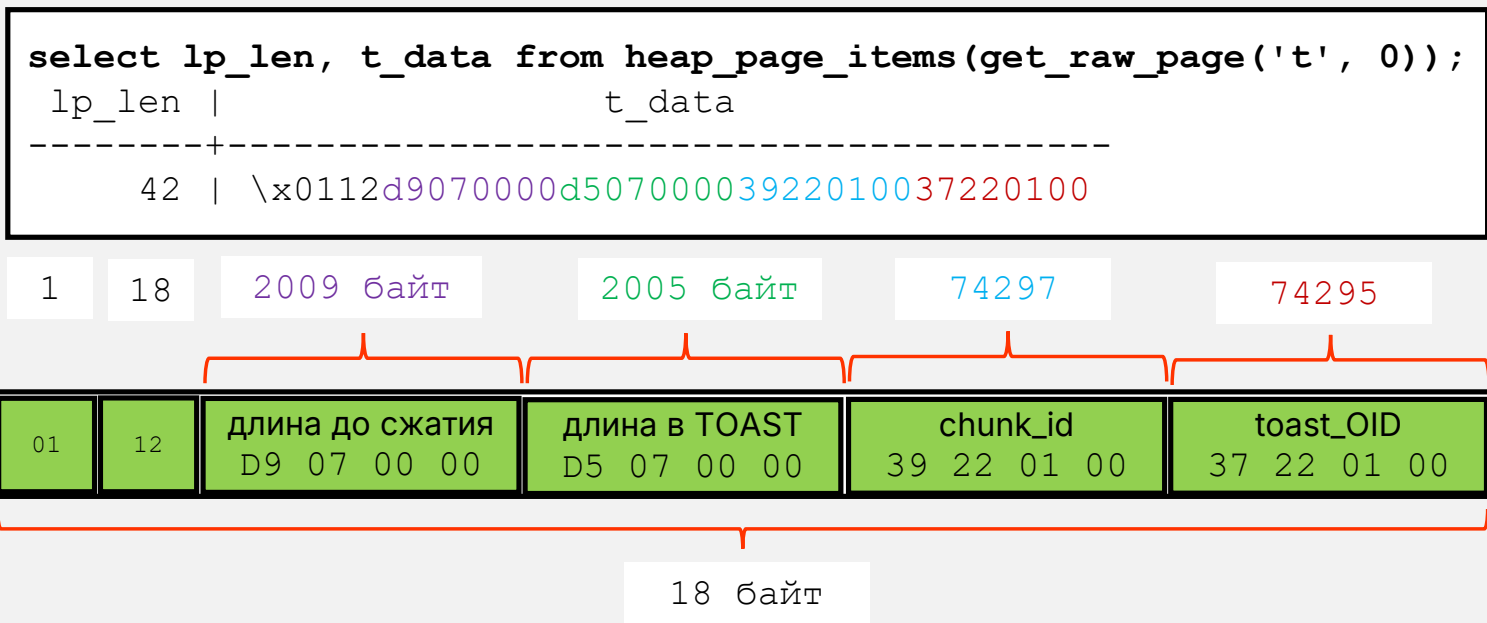
TOAST chunk

- при использовании EXTERNAL поля размером от 1997 байт создают **второй** чанк небольшого размера из-за которого в блок TOAST помещается только 3 чанка большого размера
- для полей EXTERNAL с размером от 1997 до ~2300 байт есть вероятность менее плотного хранения

```
select reltoastrelid, reltoastrelid::regclass
from pg_class where relname='t';
 reltoastrelid |          reltoastrelid
-----+-----
          74295 | pg_toast.pg_toast_74292
\d+ pg_toast.pg_toast_74292
TOAST table "pg_toast.pg_toast_74292"
  Column | Type | Storage
-----+-----+-----
 chunk_id | oid | plain
 chunk_seq | integer | plain
 chunk_data | bytea | plain
Owning table: "public.t"
Indexes:
    "pg_toast_74292_index" PRIMARY KEY,
                        btree (chunk_id, chunk_seq)
Access method: heap
select chunk_id, chunk_seq, length(chunk_data)
from pg_toast.pg_toast_74292;
 chunk_id | chunk_seq | length
-----+-----+-----
    74297 |          0 |    1996
    74297 |          1 |         9
```

Ограничения TOAST

- в любой таблице в TOAST может быть вынесено не больше 2^32 полей (~4млрд.)
- для вынесенного в TOAST поля в блоке таблицы хранится 18 байт, они не выравниваются, но вся строка выравнивается
- значение, остающееся в блоке таблицы, после выноса поля в TOAST:



Параметры `toast_tuple_target` и `default_toast_compression`

- на вытеснение влияют два макроса: `TOAST_TUPLE_THRESHOLD` и `TOAST_TUPLE_TARGET`
 - по умолчанию равны **2032**
- если размер строки больше `TOAST_TUPLE_THRESHOLD`, то начинается сжатие и/или вытеснение полей строки
- поля будут сжиматься и рассматриваться на предмет хранения в TOAST, пока оставшиеся поля не поместятся в `TOAST_TUPLE_TARGET`
- `TOAST_TUPLE_TARGET` можно переопределить только на уровне таблицы:
 - `ALTER TABLE t SET (toast_tuple_target = 2032);`
 - **`TOAST_TUPLE_THRESHOLD` не переопределяется**
 - параметр конфигурации `default_toast_compression` устанавливает алгоритм сжатия:
 - `ALTER SYSTEM SET default_toast_compression = pglz;`

Колоночное хранение: общая информация

- снизить трудоёмкость доступа к данным в столбцах путём совместного хранения значений столбцов
- возможно эффективно сжимать данные по сравнению со сжатием полей в heap tables
- Для использования колоночного способа хранения достаточно указать при создании таблицы:
`CREATE TABLE имя (... ) USING columnar;`
- расширение создаёт табличный метод доступа `columnar`
- список методов доступа есть в таблице `pg_am`

Колоночное хранение: особенности использования

- поддерживаются UPDATE и DELETE
- поддерживаются команды: TRUNCATE, INSERT (в том числе одной строки), COPY
- параллельное сканирование реализовано
- поддерживаются типы индексов, используемые в ограничениях целостности: btree, hash
- остальные типы индексов не поддерживаются: gist, gin, spgist, brin
- совместимость с секционированием таблиц: секции могут иметь разные форматы хранения
- нет служебных столбцов xmin, xmax
- есть служебный столбец ctid

Колоночное хранение: параметры

- у расширения есть параметры с префиксом "`columnar.`"
- последовательная запись в таблицу упорядоченных данных может улучшить сжатие, значительно сократить размер индексов и объем сканируемых блоков данных
- данные часто упорядочиваются по времени и называются "Time Series"
- наиболее эффективный алгоритм сжатия `zstd`, он установлен по умолчанию
- при чтении небольших объемов данных использование индексов может оказаться более эффективным

Демонстрация

- Директория для временных файлов
- Перемещение директории табличного пространства

Практика

1. Создание соединения с базой данных
2. Содержимое табличного пространства
3. Файл последовательности
4. Перемещение таблицы в другое табличное пространство
5. Перемещение таблицы в другое табличное пространство утилитой `pg_repack`
6. Использование `pgcompacttable`
7. Колоночное хранение `pg_columnar`



5

Диагностический журнал

Диагностический журнал

- накапливает диагностические сообщения от процессов экземпляра
- используется для:
 - › диагностики проблем
 - мониторинга и настройки производительности
 - › аудита безопасности
 - › исторического анализа того, что происходило при работе экземпляра
 - › анализа выполнения запросов

```
postgres@tantor:~$ cat $PGDATA/log/postgresql-*.log
23:17:09.415 [784] LOG:  database system is ready to accept connections
23:17:09.732 [791] LOG:  autotwewarm successfully twewarmed 13763 of 13763 previously-loaded blocks
23:27:09.762 [786] LOG:  checkpoint starting: time
23:27:19.982 [800] STATEMENT:  select * from tickets1 where ticket_no='0005432020304';
23:27:21.200 [800] ERROR:  index "tickets1_ticket_no_idx" contains unexpected zero page at block 3
23:27:21.200 [800] HINT:  Please REINDEX it.
```

Уровни важности сообщений

- В коде ядра PostgreSQL, коде библиотек расширений, коде plpgsql сообщения помечаются уровнями важности (severity level)
- **log_min_messages** устанавливает сообщения каких уровней важности будут передаваться в диагностический журнал
 - допустимые значения и порядок важности для **этого** параметра: DEBUG5, DEBUG4, DEBUG3, DEBUG2, DEBUG1, INFO, NOTICE, **WARNING**, **ERROR**, **LOG**, **FATAL**, **PANIC**
- **client_min_messages** устанавливает сообщения каких уровней важности будут передаваться клиенту, создавшему сессию
 - допустимые значения и порядок важности для **этого** параметра: DEBUG5, DEBUG4, DEBUG3, DEBUG2, DEBUG1, LOG, **NOTICE**, **WARNING**, **ERROR**

```
postgres=# \dconfig *_min_messages
List of configuration parameters
  Parameter  | Value
-----+-----
client_min_messages | notice
log_min_messages   | warning
(2 rows)
```

Расположение журнала

- `log_destination` определяет местоположение, куда будут выводиться диагностические сообщения
 - допустимые значения: `stderr`, `csvlog`, `jsonlog`, `syslog`
- если местоположений несколько, то они будут выводиться одновременно во все местоположения
- `logging_collector=on` запускает фоновый процесс **logger**, который перехватывает `stderr` и направляет сообщения в директорию `log_directory`
- в корне `PGDATA` создаётся текстовый файл с названием `current_logfiles`, в который записывается местоположение и текущие (куда сейчас идет запись) названия файлов диагностического журнала
- `log_filename` задаёт название файла (в `log_destination` одно значение `stderr`) или файлов лога
 - удобно значение `log_filename = postgresql-%F.log`

Передача сообщений syslog

- при `log_destination = syslog` сообщения передаются службе операционной системы syslog
- в вывод syslog попадают не все сообщения, в **logger** все
 - **logger** предпочтительнее - он не теряет сообщения
- параметры конфигурации для взаимодействия с syslog:

```
postgres=# \dconfig syslog*
List of configuration parameters
Parameter | Value
-----+-----
syslog_facility | local0
syslog_ident | postgres
syslog_sequence_numbers | on
syslog_split_messages | on
(4 rows)
```


Ротация файлов диагностического журнала

- при использовании `logger` файлы журнала могут ротироваться
 - старые файлы не удаляются
- Параметр `log_truncate_on_rotation` позволяет при ротации по времени (но не при ротации по размеру или при запуске экземпляра) перезаписывать существующие файлы лога, а не дописывать в их конец
- Параметр `log_file_mode` задаёт разрешения на файлы диагностического журнала (по умолчанию `0600`)
 - значение `0640` разрешит читать файлы членам группы `postgres`

```
postgres=# \dconfig *rotation*
List of configuration parameters
Parameter          | Value
-----+-----
log_rotation_age    | 1d
log_rotation_size    | 10MB
log_truncate_on_rotation | off
(3 rows)
```

Диагностический журнал

- `logging_collector` (по умолчанию `off`) рекомендуется установить значение `on`
- запустится фоновый процесс `logger`, который собирает (collect) сообщения, отправленные в `stderr` и записывает их в файлы лога
- `log_min_messages=WARNING` по умолчанию, что означает логирование сообщений с уровнями `ERROR`, `LOG`, `FATAL`, `PANIC`
- `log_min_error_statement=ERROR` по умолчанию. Минимальный уровень важности для команд SQL, которые завершились с ошибкой
- `log_directory=log` (`PGDATA/log`) по умолчанию. Задаёт путь к директории файлов лога, можно поменять на точку монтирования, скорость и объем которых достаточны для приема логов. Есть параметры, настраивающие ротацию файлов лога

```
psql -c "alter system set logging_collector = on;"
sudo systemctl restart tantor-se-server-16
ps -ef | grep logger
postgres    21861    21860    0 09:37   00:00:00 postgres: logger
```

Параметры диагностики

- параметров конфигурации логирования больше 35
- также есть больше 8 параметров для отладки команд SQL
- расширения могут иметь параметры для логирования
- основные параметры:

```
alter system set logging_collector=on;
alter system set log_min_duration_statement='8s';
alter system set log_statement=ddl;
alter system set log_min_error_statement=ERROR;
alter system set log_temp_files='1MB';
alter system set cluster_name='main';
alter system set log_autovacuum_min_duration='10s';
alter system set log_disconnections=on;
alter system set log_connections=on;
alter system set log_lock_waits=true;
alter system set deadlock_timeout='60s';
alter system set log_recovery_conflict_waits=on;
select pg_reload_conf();
```

\dconfig *debug*	
debug_assertions	off
debug_discard_caches	0
debug_io_direct	
debug_logical_replication_streaming	buffered
debug_parallel_query	off
debug_pretty_print	on
debug_print_plan	off
debug_print_rewritten	off
debug_print_support	off
(10 rows)	
\dconfig log*	
log_autovacuum_min_duration	10min
log_checkpoints	on
log_connections	off
log_disconnections	off
log_duration	off
log_error_verbosity	default
log_executor_stats	off
logging_collector	off
log_lock_waits	off
log_file_mode	0600
log_filename	postgresql-
%Y-%m-%d_%H%M%S.log	
logging_collector	on
log_hostname	off
logical_decoding_work_mem	64MB
log_line_prefix	%m [%p]
log_lock_waits	off
log_min_duration_sample	-1
log_min_duration_statement	-1

Отслеживание использования временных файлов

- `cluster_name = 'main'` По умолчанию пусто. Рекомендуется установить. Значение добавляется к названию процессов экземпляра, что упрощает их идентификацию. На реплике по умолчанию используется для идентификации `wal_receiver`
- `log_temp_files='1MB'` (по умолчанию отключено) логирует имена и размеры создаваемых временных файлов в момент их удаления
- при нулевом значении логируются файлы любого размера
- временные файлы создаются в директории табличных пространств, указанных в параметре `temp_tablespaces`
 - › можно ограничить параметром `temp_file_limit`
 - › рекомендуется установить `log_temp_files` и `temp_file_limit`
- пример сообщения о том, что временный файл дорос до **97MB**:

```
STATEMENT:  CREATE INDEX ON test(id);  
LOG:  temporary file: path "base/pgsql_tmp/pgsql_tmp137894.0.fileset/0.0",  
size 101810176
```

Отслеживание работы автовакуума и автоанализа

- `log_autovacuum_min_duration`, по умолчанию установлен в 10 минут. Если автовакуум превысит это время при обработке таблицы, то в лог кластера запишется сообщение. При возникновении таких сообщений стоит выяснять причину долгого вакуумирования таблицы

```
LOG:  automatic vacuum of table "postgres.public.test": index scans: 37
pages: 0 removed, 88496 remain, 88496 scanned (100.00% of total)
tuples: 10000000 removed, 10000000 remain, 0 are dead but not yet removable
removable cutoff: 799, which was 0 XIDs old when operation ended
new relfrozenxid: 798, which is 2 XIDs ahead of previous value
frozen: 1 pages from table (0.00% of total) had 82 tuples frozen
index scan needed: 44249 pages from table (50.00% of total) had 10000000 dead item identifiers removed
index "test_id_idx": pages: 54840 in total, 0 newly deleted, 0 currently deleted, 0 reusable
avg read rate: 518.021 MB/s, avg write rate: 47.473 MB/s
buffer usage: 385747 hits, 1864788 misses, 170895 dirtied
WAL usage: 231678 records, 83224 full page images, 248448578 bytes
system usage: CPU: user: 25.72 s, system: 0.38 s, elapsed: 28.12 s
```

```
LOG:  automatic analyze of table "postgres.public.test"
avg read rate: 498.808 MB/s, avg write rate: 0.018 MB/s
buffer usage: 2906 hits, 27199 misses, 1 dirtied
system usage: CPU: user: 0.42 s, system: 0.00 s, elapsed: 0.42 s
```

Наблюдение за контрольными точками

- **первая запись** передаётся в лог, когда начинается контрольная точка
- `total = 09:31:35.070 - 09:27:05.095`
 - примерно соответствует 270 секундам, которые получаются перемножением `checkpoint_completion_target * checkpoint_timeout` ($0.9 \cdot 300 = 270$)
- `total=write+sync` время записи в WAL-файлы
- `sync=` время затраченное на вызовы `fdatasync` по WAL-файлам

```
09:27:05.095 LOG:  checkpoint starting: time
09:31:35.070 LOG: checkpoint complete: wrote 4315 buffers (26.3%); 0 WAL file(s) added, 0 removed,
6 recycled; write=269.938 s, sync=0.009 s, total=269.976 s; sync files=15, longest=0.003 s, average=0.001 s;
distance=109699 kB, estimate=109699 kB; lsn=8/1164B2E8, redo lsn=8/BC98978
```

- `sync files=15` (синхронизировано файлов) - число файлов данных (в табличных пространствах, чьи блоки располагаются в буферном кэше) в которые велась запись и по ним в конце контрольной точке посылался вызов `fsync`
- `longest=0.003 s` (самая_долгая синхр.) - наибольшая длительность обработки одного файла

```
LOG:  checkpoint complete: wrote 8596 buffers (52.5%); 0 WAL file(s) added, 0 removed, 33 recycled;
write=25.057 s, sync=9.212 s, total=35.266 s; sync files=4, longest=9.181 s, average=2.303 s;
distance=540552 kB, estimate=550280 kB; lsn=9/16BC03F0, redo lsn=8/F82504B0
```

Описание записей log_checkpoints

- `wrote 4315 buffers` число грязных буферов, которые записаны по контрольной точке. Одновременно с checkpointer грязные блоки могут записывать серверные процессы и bgwriter
- `(26.3%)` процент от общего количества буферов буферного кэша, задаваемых параметром `shared_buffers`
- `file(s) added, 0 removed, 6 recycled` число созданных, удалённых, повторно использованных WAL сегментов
- `distance=109699 kB` (расстояние) - объем записей WAL между **началом предыдущей** контрольной точки и **началом текущей**

```
09:22:05.087 LOG: checkpoint starting: time
09:26:35.066 LOG: checkpoint complete: wrote 3019 buffers (18.4%); 0 WAL file(s) added, 0 removed, 6 recycled;
write=269.951 s, sync=0.009 s, total=269.980 s; sync files=14, longest=0.004 s, average=0.001 s;
distance=99467 kB, estimate=108859 kB; lsn=8/AA004C8, redo lsn=8/5177990
09:27:05.095 LOG: checkpoint starting: time
09:31:35.070 LOG: checkpoint complete: wrote 4315 buffers (26.3%); 0 WAL file(s) added, 0 removed, 6 recycled;
write=269.938 s, sync=0.009 s, total=269.976 s; sync files=15, longest=0.003 s, average=0.001 s;
distance=109699 kB, estimate=109699 kB; lsn=8/1164B2E8, redo lsn=8/BC98978
```

Описание записей log_checkpoints

- `estimate=109699 kB` (расстояние которое ожидалось) рассчитывается, чтобы оценить сколько WAL сегментов будет использовано в следующей контрольной точке
- если нули в "`0 WAL file(s) added, 0 removed`", то оценка `estimate` верная. Сколько файлов удалить определяется параметрами `min_wal_size`, `max_wal_size`, `wal_keep_size`, `max_slot_wal_keep_size`, `wal_init_zero=on`, `wal_recycle=on`

```
09:22:05.087 LOG: checkpoint starting: time
09:26:35.066 LOG: checkpoint complete: wrote 3019 buffers (18.4%); 0 WAL file(s) added, 0 removed, 6 recycled;
write=269.951 s, sync=0.009 s, total=269.980 s; sync files=14, longest=0.004 s, average=0.001 s;
distance=99467 kB, estimate=108859 kB; lsn=8/AA004C8, redo lsn=8/5177990
09:27:05.095 LOG: checkpoint starting: time
09:31:35.070 LOG: checkpoint complete: wrote 4315 buffers (26.3%); 0 WAL file(s) added, 0 removed, 6 recycled;
write=269.938 s, sync=0.009 s, total=269.976 s; sync files=15, longest=0.003 s, average=0.001 s;
distance=109699 kB, estimate=109699 kB; lsn=8/1164B2E8, redo lsn=8/BC98978
```


Утилита `pg_waldump` и записи `log_checkpoints`

- для просмотра записей в WAL-файлах используется утилита `pg_waldump`. По умолчанию утилита ищет WAL-файлы в "." (текущей директории откуда она запущена), дальше в `./pg_wal`, `$PGDATA/pg_wal`
- в **логе** и выводе `pg_controldata` в LSN ведущие нули после "/" не печатаются
- в выводе `pg_waldump` в **lsn** и **prev** ноль печатется, а в **redo** не печатается

```
pg_controldata | grep check | head -n 3
Latest checkpoint location:      8/1164B2E8
Latest checkpoint's REDO location: 8/0BC98978
Latest checkpoint's REDO WAL file: 000000010000000800000000B
```

```
pg_waldump -s 8/0B000000 | grep CHECKPOINT
rmgr: XLOG len (rec/tot): 148/148, tx: 0,
lsn: 8/1164B2E8, prev 8/1164B298, desc: CHECKPOINT_ONLINE redo 8/0BC98978;
tli 1; prev tli 1; fpw true; xid 8064948; oid 33402; multi 1; offset 0; oldest xid 723 in DB 1;
oldest multi 1 in DB 5; oldest/newest commit timestamp xid: 0/0; oldest running xid 8064947; online
pg_waldump: error: error in WAL record at 8/1361C488: invalid record length at 8/1361C4B0:
expected at least 26, got 0
```

```
09:27:05.095 LOG:  checkpoint starting: time
09:31:35.070 LOG:  checkpoint complete: wrote 4315 buffers (26.3%); 0 WAL file(s) added, 0 removed,
6 recycled; write=269.938 s, sync=0.009 s, total=269.976 s; sync files=15, longest=0.003 s, average=0.001 s;
distance=109699 kB, estimate=109699 kB; lsn=8/1164B2E8, redo lsn=8/0BC98978
```

Утилита `pg_waldump` и записи `log_checkpoints`

- `lsn 8/1164B2E8` запись о конце контрольной точки
- `redo 8/0BC98978` запись о начале контрольной точки, с которой начнется восстановление в случае сбоя экземпляра
- `prev 8/1164B298` адрес начала предыдущей записи в журнале
- `distance` объем журнала от начала предыдущей до начала заверченной контрольной точки `'8/0BC98978'::pg_lsn-'8/05177990'::pg_lsn`

```
pg_controldata | grep check | head -n 3
```

```
Latest checkpoint location:      8/1164B2E8
Latest checkpoint's REDO location: 8/BC98978
Latest checkpoint's REDO WAL file: 000000010000000800000000B
```

```
pg_waldump -s 8/0B000000 | grep CHECKPOINT
```

```
rmgr: XLOG len (rec/tot): 148/148, tx: 0,
lsn: 8/1164B2E8, prev 8/1164B298, desc: CHECKPOINT_ONLINE redo 8/BC98978;...
```

```
09:26:35.066 LOG: checkpoint complete: wrote 3019 buffers (18.4%); 0 WAL file(s) added, 0 removed, 6 recycled;
write=269.951 s, sync=0.009 s, total=269.980 s; sync files=14, longest=0.004 s, average=0.001 s;
distance=99467 kB, estimate=108859 kB; lsn=8/AA004C8, redo lsn=8/5177990
09:27:05.095 LOG: checkpoint starting: time
09:31:35.070 LOG: checkpoint complete: wrote 4315 buffers (26.3%); 0 WAL file(s) added, 0 removed,
6 recycled; write=269.938 s, sync=0.009 s, total=269.976 s; sync files=15, longest=0.003 s, average=0.001 s;
distance=109699 kB, estimate=109699 kB; lsn=8/1164B2E8, redo lsn=8/BC98978
```

Логирование соединений

- выявляет нет ли слишком частых соединений и коротких сессий
- порождение сессии для выполнения одного запроса не оптимально
- Для логирования соединений используются параметры:

```
log_connections=on
```

```
log_disconnections=on
```

```
pgaudit.log_connections=on
```

```
pgaudit.log_disconnections=on
```

```
LOG: connection received: host=[local]
```

```
LOG: connection authorized: user=postgres database=db2 application_name=psql
```

```
FATAL: database "db2" does not exist
```

```
LOG: connection received: host=[local]
```

```
LOG: connection authorized: user=alice database=alice application_name=psql
```

```
FATAL: role "alice" does not exist
```

Параметр log_connections

- log_connections=on записывает в диагностический журнал кластера попытки подключения к экземпляру, попытки аутентификации и успешную аутентификацию
- изменить значение можно только на уровне кластера
- ни на уровне роли, ни на уровне базы данных параметра не может устанавливаться:

```
postgres=# alter user alice set log_connections = on;  
ERROR:  parameter "log_connections" cannot be set after connection start
```

- пример сообщений:

```
LOG:  connection received: host="10.0.2.15"  
LOG:  connection authorized: user=fff database=fff application_name=psql  
FATAL:  role "fff" does not exist
```

Параметр log_disconnections

- `log_disconnections=on` записывает в диагностический журнал одно сообщение при остановке серверного процесса, обслуживавшего сессию
- изменить значение можно только на уровне кластера, а также на клиенте перед установкой соединения:

```
export PGOPTIONS="-c log_disconnections=on"
```

- ни на уровне роли, ни на уровне базы данных параметра не может устанавливаться:

```
postgres=# alter database postgres set log_disconnections = on;  
ERROR:  parameter "log_disconnections" cannot be set after connection start
```

- пример сообщений:

```
LOG:  disconnection: session time: 0:00:00.007 user=postgres database=postgres  
host=127.0.0.1 port=34298
```

Расширения pgaudit и pgaudittofile

- расширениями `pgaudit` и `pgauditlogtofile` можно направить сообщения о создании сессий и их длительности в отдельный файл или файлы аудита
- для работы расширений нужно загрузить их библиотеки:

```
alter system set shared_preload_libraries = pgaudit, pgauditlogtofile;
```

- Расширения работают независимо и параллельно с журналом кластера и управляются собственными параметрами, которые имеют префикс "`pgaudit.`"
- параметры `pgaudit.log_connections` и `pgaudit.log_disconnections` аналогичны одноимённым параметрам PostgreSQL и могут создавать аналогичные записи в отдельном файле аудита

Конфигурирование расширений pgaudit и pgaudittofile

- **семь** параметров относятся к библиотеке `pgauditlogtofile`
- чтобы создавался журнал аудита нужно установить параметр `pgaudit.log` как минимум в значение `'misc'`
 - > `'none'` - файл журнала аудита не создаётся
 - > `'role'` и `'ddl'`
`pgaudit.log_connections` и `pgaudit.log_disconnections` не действуют

```
postgres=# \dconfig pgaudi*
          List of configuration parameters
          Parameter                      |      Value
-----+-----
pgaudit.log                            | none
pgaudit.log_autoclose_minutes           | 0
pgaudit.log_catalog                     | on
pgaudit.log_client                      | off
pgaudit.log_connections                 | off
pgaudit.log_directory                  | log
pgaudit.log_disconnections              | off
pgaudit.log_filename                    | audit-%F.log
pgaudit.log_level                       | log
pgaudit.log_parameter                   | off
pgaudit.log_parameter_max_size          | 0
pgaudit.log_relation                   | off
pgaudit.log_rotation_age                | 1d
pgaudit.log_rotation_size               | 0
pgaudit.log_rows                        | off
pgaudit.log_statement                   | on
pgaudit.log_statement_once              | off
pgaudit.role                            |
(18 rows)
```

Диагностика частоты соединений с базой данных

- `log_disconnections=on` записывает в лог событие завершения сессии. Записывается та же информация, что `log_connections` плюс **длительность сессии**.
 - преимущество в том, что выводится одна строка, что не замусоривает лог
 - позволяет идентифицировать короткие по времени сессии
 - пример сообщения о длительности сессии сессии **4** секунды:

```
LOG: disconnection: session time: 0:00:04.056 user=oleg database=db1 host=[vm1]
```

- `log_connections=on` записывает в лог попытки установить сессию
 - недостаток в том, что неудачные попытки отличаются только **дополнительной строкой**:

```
LOG: connection received: host=[local]
LOG: connection authorized: user=postgres database=db2 application_name=psql
FATAL: database "db2" does not exist
LOG: connection received: host=[local]
LOG: connection authorized: user=alice database=alice application_name=psql
FATAL: role "alice" does not exist
```


Диагностика блокирующих ситуаций

- `log_lock_waits=true`. По умолчанию отключен. Рекомендуется включить, чтобы получать сообщения в диагностический журнал что какой-либо процесс ждет дольше, чем: `deadlock_timeout`
- `deadlock_timeout='60s'`. По умолчанию 1 секунда, что слишком мало и на нагруженных экземплярах создает значительные издержки
- `log_startup_progress_interval='10s'` не стоит отключать
- `log_recovery_conflict_waits=on`. По умолчанию `off`. Процесс `startup` запишет сообщение в лог реплики, если не сможет применить WAL к реплике дольше, чем `deadlock_timeout`

```
LOG: recovery still waiting after 60.555 ms: recovery conflict on lock
DETAIL: Conflicting process: 5555.
```

- Наличие конфликтов можно увидеть в представлении (мало деталей):

```
select * from pg_stat_database_conflicts where datname='postgres';
datid|datname |tblspc|confl_lock|confl_snapshot|confl_bufferpin|deadlock
-----+-----+-----+-----+-----+-----+-----
13842|postgres|    0 |         0 |              1 |              1 |         0
```

Практика

1. Какая информация попадает в журнал
2. Расположение журналов сервера
3. Как информация попадает в журнал
4. Добавление формата csv
5. Включение коллектора сообщений



6

6

Безопасность

Пользователи (роли) в кластере баз данных


- накапливает диагностические сообщения от процессов экземпляра
- используется для:
 - › диагностики проблем
 - мониторинга и настройки производительности
 - › аудита безопасности
 - › исторического анализа того, что происходило при работе экземпляра
 - › анализа выполнения запросов

```
postgres@tantor:~$ cat $PGDATA/log/postgresql-*.log
23:17:09.415 [784] LOG:  database system is ready to accept connections
23:17:09.732 [791] LOG:  autotwewarm successfully twewarmed 13763 of 13763 previously-loaded blocks
23:27:09.762 [786] LOG:  checkpoint starting: time
23:27:19.982 [800] STATEMENT:  select * from tickets1 where ticket_no='0005432020304';
23:27:21.200 [800] ERROR:  index "tickets1_ticket_no_idx" contains unexpected zero page at block 3
23:27:21.200 [800] HINT:  Please REINDEX it.
```

Пользователи (роли)

- Список ролей можно посмотреть командами `\duS` `\dgs`
- Список ролей хранится в глобальной таблице `pg_authid`
- Есть псевдороль `public`, в которую входят все роли
 - ей можно выдавать привилегии
- Атрибуты роли postgres:

```
postgres=# select * from pg_authid where rolname='postgres'\gx
-[ RECORD 1 ]-----
oid          | 10
rolname      | postgres
rolsuper     | t
rolinherit   | t
rolcreaterole | t
rolcreatedb  | t
rolcanlogin  | t
rolreplication | t
rolbypassrls | t
rolconnlimit | -1
rolpassword  | SCRAM-SHA-256$4096:oejDqb5wqdHcuVXBU0H/VA==$AwimWKZOQ...
rolvaliduntil |
```



Атрибуты (параметры, свойства) ролей

- есть 7 атрибутов типа включён/выключен
- LOGIN - право создания начального соединения с базами данных
- SUPERUSER - обходит проверки прав доступа, кроме начального соединения
- REPLICATION LOGIN - роль с этими атрибутами (без атрибута LOGIN атрибут REPLICATION бесполезен) имеет право подсоединяться по протоколу репликации и резервировать весь кластер
- CREATEROLE - роль может создавать роли
 - › у ролей нет владельца
 - › созданная роль грантуется создающей роли с опцией ADMIN OPTION
 - › ни грант WITH ADMIN, ни атрибут CREATEROLE не позволяют поднять своей роли привилегии путем создания и переключения в созданную роль
- Грант с ADMIN OPTION не даёт право менять атрибуты CREATEROLE, BYPASSRLS, REPLICATION, CREATEDB, SUPERUSER
 - › эти атрибуты роль сможет менять у ролей, на которые есть ADMIN OPTION, только, если у неё имеется такой же атрибут

Атрибут INHERIT и GRANT WITH INHERIT

- Атрибут INHERIT устанавливается по умолчанию
- Позволяет наследовать права, выданные на объекты баз данных
- Если роли установить атрибут NOINHERIT, то она не будет наследовать привилегии ролей, которые ей даны
- При выдаче роли можно явно задать
 - будут ли работать права грантованной роли у сессий грантуемого
 - может ли грантуемый переключиться в грантованную роль

```
postgres=# grant postgres to alice with inherit false, set true;
GRANT ROLE
postgres=# \c postgres alice
You are now connected to database "postgres" as user "alice".
postgres=> set role postgres;
SET
postgres=#
postgres=# grant postgres to bob with inherit true, set false;
GRANT ROLE
postgres=# \c postgres bob
You are now connected to database "postgres" as user "bob".
postgres=> set role postgres;
ERROR:  permission denied to set role "postgres"
```

Переключение сессии в другую роль и смена ролей

- `SET [SESSION | LOCAL] SESSION AUTHORIZATION роль;`
переключает сессию в другую роль
- Команду может выполнить только суперпользователь
 - › используется для того, чтобы суперпользователь мог переключить сессию в другого пользователя и затем вернуться в исходную
- Текущего пользователя можно изменить командой `SET ROLE`
 - › проверка прав на объекты выполняется для текущего пользователя

```
postgres=# set session authorization alice;
postgres=> select current_user, session_user, current_role, user;
 current_user | session_user | current_role | user
-----+-----+-----+-----
alice        | alice        | alice        | alice
postgres=> set role bob;
postgres=> select current_user, session_user, current_role, user;
bob          | alice        | bob          | bob
postgres=> reset role;
postgres=> select current_user, session_user, current_role, user;
alice        | alice        | alice        | alice
postgres=> reset session authorization;
postgres=# select current_user, session_user, current_role, user;
postgres     | postgres     | postgres     | postgres
```


Предопределённые (служебные) роли

- появились в PostgreSQL начиная с версии 14
- 15 ролей плюс псевдороль public
- может грантовать роль с атрибутами SUPERUSER или роль, имеющая право WITH ADMIN на грантуемую роль
- удалить служебные роли нельзя
- полезны чтобы не давать привилегию суперпользователя для выполнения востребованных действий

```
postgres=# \duS
```

```
      List of roles
```

```
Role name
```

```
Attributes
```

Role name	Attributes
pg_checkpoint	Cannot login
pg_create_subscription	Cannot login
pg_database_owner	Cannot login
pg_execute_server_program	Cannot login
pg_maintain	Cannot login
pg_monitor	Cannot login
pg_read_all_data	Cannot login
pg_read_all_settings	Cannot login
pg_read_all_stats	Cannot login
pg_read_server_files	Cannot login
pg_signal_backend	Cannot login
pg_stat_scan_tables	Cannot login
pg_use_reserved_connections	Cannot login
pg_write_all_data	Cannot login
pg_write_server_files	Cannot login

Права на объекты

- При создании объекта назначается владелец
- По умолчанию владелец и суперпользователь имеют права на созданный объект
- Другим ролям нужны права
- Для каждого типа объекта есть свой набор прав
 - названия прав приведены в таблице
- Права выдаются и отзываются командами GRANT и REVOKE

право	типы объектов
SELECT	r LARGE OBJECT, SEQUENCE, TABLE (и подобные им), COLUMN
INSERT	a TABLE, столбец
UPDATE	w LARGE OBJECT, SEQUENCE, TABLE, COLUMN
DELETE	d TABLE
TRUNCATE	D TABLE
REFERENCES	x TABLE, COLUMN
TRIGGER	t TABLE
CREATE	C DATABASE, SCHEMA, TABLESPACE
CONNECT	c DATABASE
TEMPORARY	T DATABASE
EXECUTE	X FUNCTION, PROCEDURE
USAGE	U DOMAIN, FDW, FOREIGN SERVER, LANGUAGE, SCHEMA, SEQUENCE, TYPE
SET	s PARAMETER
ALTER SYSTEM	A PARAMETER
MAINTAIN	m TABLE

Просмотр прав на объекты в psql

- Права выводятся в виде списка:
- кому_дана=привилегии/кто_дал
- Если перед значком "=" пусто, это означает public (предоставлено всем)
- Значок "*" после буквы означает, что право предоставлено с правом передачи WITH GRANT OPTION.
- Значок "+" в конце обозначает, что это не последний элемент и список продолжается на следующей строке

```
postgres=# \l
               List of databases
  Name | Owner  | Access privileges
-----+-----+-----
 demo | postgres | postgres=Ctc/postgres+
      |         | alice=C*c/postgres
postgres=# GRANT ALL PRIVILEGES ON ALL TABLES IN
SCHEMA public TO alice, bob WITH GRANT OPTION;
GRANT
```

Тип объекта	Все права	Права PUBLIC	Команда psql
DATABASE	Ctc	Tc	\l
DOMAIN	U	U	\dD+
FUNCTION, PROCEDURE	X	X	\df+
FDW	U	нет	\dew+
FOREIGN SERVER	U	нет	\des+
LANGUAGE	U	U	\dL+
LARGE OBJECT	rw	нет	\dl+
PARAMETER	sA	нет	\dconfig+
SCHEMA	UC	нет	\dn+
SEQUENCE	rwU	нет	\dp
TABLE (и подобные им)	arwdDxtm	нет	\dp
COLUMN	arwx	нет	\dp
TABLESPACE	C	нет	\db+
TYPE	U	U	\dT+

Привилегии по умолчанию (DEFAULT PRIVILEGES)

- ALTER DEFAULT PRIVILEGES позволяет задавать права, применяемые к объектам, которые будут создаваться в будущем для схем, таблиц, представлений, внешних таблиц, последовательностей, подпрограмм, типов (включают в себя домены)
- роль public получает права:
 - CONNECT и TEMPORARY (создание временных таблиц) для баз данных
 - EXECUTE для функций и процедур
 - USAGE для языков, типов данных, доменов

```
alter default privileges REVOKE ALL on routines from public;
alter default privileges REVOKE ALL on types from public;
revoke all on database demo from public;
revoke connect on database p2 from public;
\l
```

List of databases			
Name	Owner	..	Access privileges
-----+-----+-----+-----			
demo	postgres	..	postgres=CTc/postgres+
		..	alice=c/postgres
p2	postgres	..	=T/postgres +
		..	postgres=CTc/postgres

```
revoke all on language plpgsql from public;
\dL+
```

List of languages				
Name	Owner	Trusted	..	Access privileges
-----+-----+-----+-----+-----				
plpgsql	postgres	t	..	postgres=U/postgres
(1 row)				



Защита на уровне строк (Row-level security, RLS)

- по умолчанию отключена
- RLS не является мандатным контролем доступа (MAC)
- если RLS включается, а разрешающих политик нет, то доступ запрещён
- политики создаются командой CREATE POLICY, например:
CREATE POLICY имя ON таблица AS PERMISSIVE FOR ALL TO роль
USING (предикат) ;
 - политик на таблице может быть несколько, они могут быть PERMISSIVE и/или RESTRICTIVE и могут комбинироваться AND и OR
- RLS включают на уровне таблиц командой:
ALTER TABLE имя [ENABLE | DISABLE | FORCE | NO FORCE] ROW
LEVEL SECURITY;
- включение с опцией ENABLE:
 - RLS действуют на всех, кроме владельца и ролей с атрибутом SUPERUSER или BYPASSRLS
- RLS не применяется к проверкам ограничений целостности
 - ограничения целостности не могут нарушаться

Подсоединение к экземпляру

- Параметры начальной аутентификации устанавливаются в двух файлах `pg_hba.conf` и `pg_ident.conf`
- Файлы редактируются вручную
- содержимое файла `pg_hba.conf` можно в представлении `pg_hba_file_rules`
- Расположение файлов можно посмотреть параметрами конфигурации `hba_file` и `ident_file`:

```
postgres=# \dconfig *_file
```

Parameter	List of configuration parameters	Value
config_file		/var/lib/postgresql/tantor-se-1c-17/data/postgresql.conf
enable_delayed_temp_file		off
external_pid_file		
hba_file		/var/lib/postgresql/tantor-se-1c-17/data/pg_hba.conf
ident_file		/var/lib/postgresql/tantor-se-1c-17/data/pg_ident.conf

Файл pg_hba.conf

- Формат файла - одна запись на строку
- Запись состоит из нескольких полей, разделённых пробелами и/или символами табуляции
- Содержимое полей может быть заключено в двойные кавычки
- записи (строки) ближе к началу файла превалируют, в отличие от файлов параметров (postgresql.conf)
- Текущее содержимое файла можно посмотреть через представление:

```
postgres=# select rule_number r, right(file_name, 11) file_name, line_number l, type, database, user_name
user, address, left(netmask, 15) netmask, auth_method auth, options opt, error from pg_hba_file_rules;
 r | file_name | l | type | database | user | address | netmask | auth | opt | error
---+-----+---+-----+-----+-----+-----+-----+-----+-----+-----
 1 | pg_hba.conf | 117 | local | {all} | {all} | | | | trust | | 
 2 | pg_hba.conf | 119 | host | {all} | {all} | 127.0.0.1 | 255.255.255.255 | trust | | 
 3 | pg_hba.conf | 121 | host | {all} | {all} | ::1 | ffff:ffff:ffff: | trust | | 
 4 | pg_hba.conf | 124 | local | {replication} | {all} | | | | trust | | 
 5 | pg_hba.conf | 125 | host | {replication} | {all} | 127.0.0.1 | 255.255.255.255 | trust | | 
 6 | pg_hba.conf | 126 | host | {replication} | {all} | ::1 | ffff:ffff:ffff: | trust | | 
(6 rows)
```

Содержимое pg_hba.conf

- тип соединения:
 - local - соединение через UNIX-сокеты
 - host - любые (с шифрованием и без) соединения по TCP/IP
- название базы данных:
 - all - все базы
- replication - подключение по протоколу физической репликации
- IP-адрес с маской подсети или без маски:
 - all - все адреса IPv4 и IPv6
 - samehost - с IP-адресов хоста, на котором работает экземпляр

```
postgres@tantor:~$ tail $PGDATA/pg_hba.conf
# TYPE DATABASE          USER            IP-ADDRESS      IP-MASK         METHOD
local  sameuser          all             
local  samerole           all              md5
host   all                 all             127.0.0.1/32    trust
host   db1,db2,@file1       +bob,@file2     10.0.0.0        255.0.0.0       scram-sha-256
host   "/^db\d{2,4}$"      /^.*desk$       samehost        ident map=omicron
host   all                 all             all              reject
```


Содержимое pg_hba.conf (продолжение)

- метод аутентификации:
- `trust` - установить соединение без проверок, в том числе пароля
- `reject` - безусловный отказ в соединении
- `peer` - имя пользователя операционной системы клиента должно совпадать с именем роли, есть опциональный параметр `map`
- `scram-sha-256` или `md5` - проверить пароль
- `gss` - аутентификация по протоколу kerberos
- `ldap` - аутентификация ldap-сервером
- `cert` - запрашивать у клиента сертификат SSL

```
postgres@tantor:~$ tail $PGDATA/pg_hba.conf
# TYPE      DATABASE      USER      IP-ADDRESS      IP-MASK      METHOD
local       sameuser      all
local       samerole      all
host        all           all        127.0.0.1/32
host        db1,db2,@file1 +bob,@file2 10.0.0.0       255.0.0.0     scram-sha-256
hostssl     "/^db\d{2,4}$" /^.*desk$   localhost
host        all           all        1.1.0.0/16
```

Файл сопоставления имён pg_ident.conf

- Для методов peer, gss, ident можно сопоставить имя, возвращаемое службой аутентификации и роли кластера, под которой хочет установить сессию клиент
- на названия `MAPNAME` ссылается параметр `map=map1` в записях файла `pg_hba.conf`
- Представление `pg_ident_file_mappings` позволяет посмотреть текущее содержимое файла:

```
postgres=# select map_number r, right(file_name, 13) file_name, line_number l,
map_name, sys_name, pg_username, error from pg_ident_file_mappings;
 r |   file_name   | l | map_name | sys_name | pg_username | error
---+-----+---+-----+-----+-----+-----
 1 | pg_ident.conf | 73 | map1     | astra    | postgres   |
 2 | pg_ident.conf | 75 | map1     | astra    | alice      |
(2 rows)

postgres=# \! tail -n 4 $PGDATA/pg_ident.conf
# MAPNAME SYSTEM-USERNAME PG-USERNAME
map1      astra             postgres
# astra также может подключаться с ролью alice
map1      astra             alice
```

Практика

1. Создание новой роли
2. Установка атрибутов
3. Создание групповой роли
4. Создание схемы и таблицы
5. Выдача роли доступа к таблице
6. Удаление созданных объектов
7. Расположение файлов конфигурации
8. Просмотр правил аутентификации
9. Локальные изменения для аутентификации
10. Проверка корректности настройки
11. Очистка ненужных объектов



7a

Физическое резервирование

Виды резервных копий

- Горячие - без простоя, без остановки экземпляра, без приостановки обслуживания клиентских сессий
- Холодные - на корректно (с финальной контрольной точкой) остановленном экземпляре
- Автономные или самодостаточные

Инкрементальные бэкапы

- могут быть полезны, если размер кластера большой
- увеличивает сложность процедур резервирования, вероятность ошибки и невозможности восстановить кластер
- Процедура:
 - первым создается полный бэкап утилитой `pg_basebackup`
 - позже создаются инкрементальные бэкапы утилитой `pg_basebackup` с параметром `-i` манифест или `--incremental=манифест`
 - для восстановления инкрементальные бэкапы накладываются на полный утилитой `pg_combinebackup`
- при создании инкрементальных бэкапов используются файлы директории `PGDATA/pg_wal/summaries`

Что резервируется

- директория PGDATA
- директории табличных пространств
- Не резервируются файлы, известные утилите pg_basebackup как временные

Процедура восстановления

- Остановить экземпляр
- Восстановить из полной резервной копии её содержимое
- Применить инкрементальные бэкапы, если они создавались
- Запустить экземпляр

Файлы журнала предзаписи

- находятся в PGDATA/pg_wal
- файлы журнала не дублируются
- размер текущего файла журнала такой же как остальных
- в файлы журнала пишут серверные и фоновые процессы экземпляра

LSN (Log Sequence Number)

- Журнал можно представить себе как конкатенированный набор файлов журнала (большой части которых уже удалены) начиная с самого первого файла, сформированного при создании кластера
- LSN - 64битное число, монотонно возрастающее, указывающее адрес (смещение от первого байта первого файла журнала) с точностью до байта в журнале кластера
- Процессы экземпляра пишут в журнал записи переменной длины, LSN используется для указания адреса начала журнальной записи
- физически запись в файлы осуществляется блоками по 8Кб (wal_block_size)

Названия журнальных файлов и LSN

- LSN представляют в виде двух 32-битных чисел, записанных в шестнадцатеричной форме (HEX), разделенных слэшем: `XXXXXXXXXX/YYZZZZZZ`
- `XXXXXXXXXX` - "старшие" 32 бита LSN
- `YY` - "старшие" 8 бит "младшего" 32-битного числа
- `ZZZZZZZ` - смещение в файле 16-мегабайтного журнала относительно его начала
- Размер файла журнала определяет максимальный размер журнального буфера (`wal_buffers`)
- `0000000NXXXXXXXXXX000000YY` - названия 16мегабайтных файлов журнала

Процесс восстановления startup

- startup - процесс восстановления файлов кластера с помощью журнала
- при изменении линии времени в директории PGDATA/pg_wal создаются текстовые файлы `0000000N.history` с информацией о линиях времени, их нельзя стирать и они будут резервироваться
- новая линия времени появляется если выполнялось восстановление или реплика стала мастером
- цель линий времени - чтобы при восстановлении на момент в прошлом новые файлы журналов не затирали прежние и чтобы была возможность вернуться на прежние линии времени

Функции для работы с журналами

- `pg_switch_wal()` переключает запись на новый WAL-файл
- `pg_create_restore_point('текст')` создаёт в журнале запись LSN с текстовой меткой
- `pg_walfile_name('LSN')` выдаёт Название WAL-файла в котором есть запись LSN
- `pg_current_wal_flush_lsn()` LSN конца последней журнальной записи, которая считается надёжно сохранённой
- `pg_wal_lsn_diff(LSN,LSN)` байт между двумя LSN

Холодное резервирование

- экземпляр должен быть корректно остановлен
- утилита `pg_basebackup` не может резервировать кластер, если экземпляр погашен
- используются утилиты операционной системы `cp`, `rsync`, `tar`
- Копируется целиком PGDATA и директории табличных пространств
- создается автономная копия, на которой можно запустить экземпляр
- преимущество - простота
- основной недостаток - прерывание обслуживания клиентов кластера

Параметр конфигурации `full_page_writes`

- по умолчанию включён
- защищает от разрыва (torn) страниц
- не рекомендуется отключать
- включается на время резервирования утилитой `pg_basebackup`
- при резервировании реплики должен быть включён на мастере

Утилита резервирования pg_basebackup

- создаёт резервную копию кластера на работающем экземпляре
- создать копию отдельных баз данных или объектов базы нельзя, только всего кластера
- использует протокол репликации
- использует более безопасный режим резервирования "pull" - принимает файлы, а не "push" - передача файлов
- может создавать инкрементальные бэкапы

Утилита `pg_verifybackup`

- проверяет файлы в бэкапах созданных утилитой `pg_basebackup`
- рассчитывает контрольные суммы файлов (CRC32C) и сравнивает со значениями в файле `manifest_file`
- сравнивает файлы со списком файлов в файле манифеста
- без файла манифеста не работает
- Проверяет наличие журнальных записей нужных для синхронизации файлов бэкапа - автономность бэкапа
- не проверяет файлы `postgresql.auto.conf`, `standby.signal`, `recovery.signal`

Архив журналов

- Способы организации архива журналов:
- копирование WAL-сегментов командой в параметре `archive_command`
- прием потока журнальных записей и сохранение утилитой `pg_receivewal`
- использование физических реплик
- использование утилиты `wal-g` для передачи журналов по протоколу S3

Отсутствие потерь (Durability)

- Архитектура резервирования должна гарантировать полное восстановление зафиксированных транзакций
- Архитектура резервирования должна защищать от удаления бэкапов в случае взлома хоста с экземпляром кластера: инициатором бэкапов должен быть хост отличный от того на котором работает экземпляр кластера
- Текущий журнальный файл не должен быть единственной точкой сбоя (single point of failure)
- Использование `pg_reseivewal` или физической реплики - возможность гарантировать отсутствие потерь при повреждении текущего журнала

Утилита pg_receivewal

- подключается по протоколу репликации
- принимает журнальные записи без задержек
- рекомендуется использовать слот репликации
- может получать журналы как с мастера, так и с физической реплики
- скрипты для автозапуска (systemd) отсутствуют
- может сжимать журнальные записи
- преимущество в том, что является инициатором соединения, что позволяет обеспечить безопасность
- может подтверждать транзакции в режиме синхронной фиксации
- текущему журнальному файлу даёт суффикс .partial

Слот репликации

- три вида: физический, временный физический, логический
- используются для удержания журнальных файлов
- Если клиент не принимает журнальные данные (остановился), то файлы журналов будут удерживаться и заполнят всё свободное место в директории `PGDATA/pg_wal`. Чтобы этого не произошло стоит установить ограничение параметром `max_slot_wal_keep_size`
- представление `pg_replication_slots` содержит список всех слотов репликации

Создание базовой резервной копии

- `pg_basebackup` лучше запустить на хосте, где будет храниться резервная копия (резервный хост)
- параметр `-D` задает путь к директории
- по умолчанию создаёт два соединения к двум процессам `wal-sender`. По первому соединению передаются файлы с данными, по второму журналы
- Можно ограничить скорость резервирования первого соединения
- инициирует контрольную точку перед началом копирования
- создаёт файлы `backup_manifest` и `backup_label`

Утилита резервирования wal-g

- дополнительно поставляемое с Tantor Postgres клиентское приложение
- Используется для резервирования кластера и файлов журналов по протоколу S3
- поддерживает создание "дельта-копий" (инкрементальные копии)
- поддерживает ограничение скорости резервирования, проверку целостности файлов, настройку уровня параллелизма для загрузки и выгрузки файлов

Демонстрация

- Изменение размера WAL файлов

Практика

1. Создание базовой резервной копии кластера
2. Запуск экземпляра на копии кластера
3. Файлы журнала
4. Проверка целостности резервной копии
5. Согласованная резервная копия
6. Удаление файлов журнала
7. Создание архива журнала утилитой `pg_receivewal`
8. Синхронная фиксация транзакций и `pg_receivewal`
9. Минимизация потерь данных транзакций



7b

Логическое резервирование

Логическое резервирование

- формирование текстового файла или файлов позволяющие воссоздать объекты
- Сохраняет объекты в том состоянии, в котором они были на начало выгрузки
- Используются утилиты:
 - › pg_dump
 - › pg_restore
 - › pg_dumpall
 - › psql
 - › команда COPY
 - › команда psql \copy

Примеры использования

- Переход на новую основную версию
- Смена параметров кластера, которые не меняются после его создания
- Проверка целостности данных
- Получение скрипта воссоздания объектов
- Резервирование объектов
- Выгрузка части кластера: отдельной базы данных, содержимого схемы и других объектов

Сравнение **л**огического и **ф**изического резервирования

ВОЗМОЖНОСТЬ	Л	Ф
выгрузить содержимое отдельной базы данных	+	-
восстановление части объектов	+	-
восстановление на произвольный момент времени	-	+
не зависит от версии, сборки, производителя софта	+	-
обеспечение отказоустойчивости (Durability)	-	+
использует репликационный протокол	-	+
резервирование по сети	+	+
простота использования	+	+

Команда COPY .. TO

- используется для высокоэффективной выгрузки и загрузки данных в одну таблицу
- Можно выгрузить содержимое таблицы или результат любой команды SQL, возвращающей данные
- Данные выгружаются в:
 - а) файл в файловой системе сервера
 - б) передаются на стандартный вход (stdin) утилите командной строки сервера
 - в) стандартный вывод stdout. Если команда COPY вызывается через сетевое соединение, то стандартный вывод передается через сетевое соединение клиентской программе

Команда COPY .. FROM

- Загрузка выполняется в одну таблицу
- Данные загружаются из:
 - › файла на хосте где запущен экземпляр
 - › стандартного вывода произвольной исполняемой программы
 - › из стандартного ввода stdin
- В процессе загрузки можно сразу установить признак заморозки строк
- Можно задать опциональное выражение WHERE. В выражении нельзя использовать подзапросы
- представление `pg_stat_progress_copy` - отслеживание работы команды и при загрузке и при выгрузке

Команда `psql \copy`

- `\copy` это команда `psql`
- синтаксис похож на команду `COPY`
- команда использует нижний регистр и чувствительна к нему
- набирается одной строкой
- ";" в конце команды ставить не нужно
- работает с файлами там, где запущена утилита `psql`, команда `COPY` работает с файлами через серверный процесс на хосте сервера
- для больших объемов данных `COPY` эффективнее

Утилита pg_dump

- создаёт логическую резервную копию (дамп) базы данных или её части
- выгружает данные одной базы данных согласованно - на один момент времени
- для выгрузки данных из таблиц по умолчанию использует команду COPY
- выгружает в одном из четырёх форматов: plain, custom, directory, tar
- в формате directory может выгружать в несколько потоков
- для custom и directory параметром -Z можно выбрать алгоритм и уровень сжатия zstd, lz4, gzip, 0
- можно не создавать файл, а использовать **пайп** (pipe):
pg_dump параметры | psql параметры
pg_dump -F с параметры | pg_restore параметры

Параллельная выгрузка

- возможна только в режиме `directory`
- количество рабочих процессов задаётся параметром `-j` или `--jobs`
- прервётся, если после начала выгрузки будут даны команды, устанавливающие эксклюзивную блокировку на выгружаемые объекты
- На время выгрузки устанавливаются блокировки **ACCESS SHARE** на все выгружаемые объекты
- При большом количестве объектов можно увеличить значения параметров `max_locks_per_transaction`, `max_connections`

Утилита pg_restore

- обрабатывает дампы в формате `custom`, `directory`, `tar`
- может создавать из архивов текстовый файл формата `plain`
- можно восстановить только определения объектов, не загружая данные указав параметр `--schema-only`
- есть специфический вариант загрузки с помощью файла "оглавления" (TOC, title of contents):
 - › сформировать файл оглавления архива параметром `--list`
 - › закомментировать (удалить, переместить) строки объектов
 - › загрузить архив указав оглавление `--use-list`
 - › объекты, не указанные в оглавлении, не будут загружены

Возможности pg_restore

- можно восстановить только определения объектов не загружая данные
- загрузить объекты только части схем
- не восстанавливать права владения
- загружать в табличное пространство по умолчанию для базы данных
- восстановить часть секций секционированных таблиц
- восстановить только указанные таблицы, индексы, представления, последовательности, функции, процедуры, триггера

Утилита pg_dumpall

- Создаёт единственный скрипт, позволяющий восстановить образ всего кластера
- Выгружает общие объекты кластера
- Последовательно запускает pg_dump в режиме plain для всех баз данных, которые нужно выгрузить
- Скрипт текстовый, содержит команды SQL
- Скрипт можно выполнить в psql
- В скрипте нет команды создания кластера, кластер нужно создать, запустить экземпляр и указать любую базу данных для начального подключения psql
- большая часть параметров утилиты относится к pg_dump, который будет запускать утилита
- выгружает в один поток
- можно использовать **пайп** (pipe):
pg_dumpall параметры | psql параметры

Возможности pg_dumpall

- имеет много параметров, большая часть из них является параметрами `pg_dump`
- можно выгрузить только общие объекты кластера
`--globals-only`
- можно выгрузить только определения ролей
`--roles-only`
- можно выгрузить только определения табличных пространств `--tablespaces-only`
- можно не выгружать часть баз данных
`--exclude-database=шаблон`
- не добавлять в команды имена табличных пространств
`--no-tablespaces`

Строки большого размера

- Типы данных `text` и `bytea` могут хранить данные размером до 1Гб
- Строки размером больше 1Гб могут требовать особого обращения
- Поля при выгрузке в текстовом виде могут увеличиваться в размерах

Параметр `enable_large_allocations`

- параметр СУБД Tantor Postgres, который увеличивает размер `StringBuffer` с 1 гигабайта до 2 гигабайт

```
postgres=# select * from pg_settings where name like '%large%'\gx
name          | enable_large_allocations
setting       | off
category      | Resource Usage / Memory
short_desc    | whether to use large memory buffer greater than 1Gb, up to 2Gb
context       | superuser
vartype       | bool
boot_val      | off
```

- может устанавливаться на уровне сессии и утилитами `pg_dump`, `pg_dumpall`

```
postgres@tantor:~$ pg_dump --help | grep alloc
--enable-large-allocations  enable memory allocations with size up to 2Gb
```

- проблема возникает со строкой таблицы `config` приложений 1С:ERP, Комплексная автоматизация, Управление производственным предприятием

Демонстрация

- Обработка строк большого размера

Практика

1. Использование утилиты pg_dump
2. Формат custom и утилита pg_restore
3. Формат directory
4. Сжатие и скорость резервирования
5. Команда COPY



8

8a


Физическая репликация

Физическая репликация

- Один основной (primary, master, ведущий) кластер баз данных - допускает внесение изменений в данные
- Один или несколько резервных (standby, ведомых) кластеров
- Резервные кластера (физические реплики или просто реплики) получают журнальные данные и применяют к своим файлам
- Реплики могут обслуживать запросы на чтение - режим горячего резерва (hot standby)
- Реплики являются физической резервной копией основного кластера, которая обновляется

Мастер и реплика

- мастер и реплики должны использовать ту же основную версию PostgreSQL
- кластер реплицируется целиком
- директории табличных пространств могут отличаться



Реплики и архив журнала

- Обычно используется поточная репликация с использованием слота репликации: процесс `walreceiver` подключается к процессу `walsender`
- Может использоваться архив журналов, заполняемый командой в параметре `archive_command` или утилитой `pg_receivewal` (со слотом репликации)
- реплика может использовать и слот репликации и если не сможет получить через него файл журнала, то директорию с архивом журналов если она есть

Настройка мастера

- Настроить возможность подключения реплик по протоколу репликации
- Проверить значения параметров конфигурации:
 - › `wal_level` по умолчанию `replica`
 - › `max_walsenders` по умолчанию 10
 - › `max_replication_slots` по умолчанию 10
 - › `max_slot_wal_keep_size` по умолчанию -1 без ограничений, стоит установить ограничение

Создание реплики

- создание резервной копии утилитой `pg_basebackup`
- параметр `-R` устанавливает конфигурационные параметры для реплики
- параметр `--create-slot (-C)` и `--slot=имя (-S)` создаёт слот для удержания WAL-журналов до запуска экземпляра реплики
- установить параметр конфигурации `cluster_name`
- проверить значения параметров конфигурации приведя их в соответствие с возможностями хоста реплики
- Настроить службу для автоматического запуска экземпляра реплики и запустить экземпляр реплики

Слоты репликации

- используются репликами
- список слотов в представлении `pg_replication_slots`
- Функция создания
`pg_create_physical_replication_slot('имя')`
- Удаление слота любого типа
`pg_drop_replication_slot('имя')`
- Создание копии слота
`pg_copy_physical_replication_slot('имя',
'имя_создаваемого')`

Параметры конфигурации на репликах

- на мастере не играют роли, но могут быть заранее установлены
- многие не меняются без рестарта экземпляра реплики
- по умолчанию:
- реплика обслуживает запросы (`hot_standby=on`)
- обратная связь отключена (`hot_standby_feedback=off`)
- реплика применяет журнальные записи без задержки (`recovery_min_apply_delay=0`)

Горячая реплика

- по умолчанию включена (параметр `hot_standby=on`)
- реплика принимает соединения и выполняет запросы
- утилита `pg_basebackup` может выполнять резервирование реплики вместо мастера (backup offloading)
- временные таблицы на реплике нельзя использовать, расширение `pg_variables` можно

Обратная связь с мастером

- обратная связь по умолчанию отключена
`hot_standby_feedback=off`
- обратная связь удерживает горизонт очистки всего мастера в длительность самого долгого запроса на базах реплики или транзакции (уровень транзакций REPEATABLE READ)
- Вместо обратной связи можно использовать параметры
 - › `max_standby_streaming_delay` и
 - › `max_standby_archive_delay`

Мониторинг горизонта

- Оценка горизонта текущей базы данных:
 - backend_xmin из pg_stat_activity
 - Длительность самого долгого запроса или транзакции: max(now()-xact_start) из pg_stat_activity
 - Столбец xmin представления pg_replication_slots при использовании слотов репликации
 - Столбец backend_xmin представления pg_stat_replication на мастере - что получили walsender по обратной связи

```
select age(backend_xmin), extract(epoch from (clock_timestamp()-xact_start)) secs, pid, datname database,
state from pg_stat_activity where backend_xmin IS NOT NULL OR backend_xid IS NOT NULL order by
greatest(age(backend_xmin), age(backend_xid)) desc;
```

age	secs	pid	database	state
175455	1425.651346	255554	postgres	idle in transaction
1	0.001878	255547	postgres	active
1	0.001213	255626	postgres	active

Мониторинг горизонта

- горизонт баз данных кластера в количестве номеров транзакций, отстоящих от текущей:

```
select datname, greatest(max(age(backend_xmin)), max(age(backend_xid))) from pg_stat_activity
where backend_xmin is not null or backend_xid is not null group by datname order by datname;
```

- длительность самого долгого запроса или транзакции, который и удерживает горизонт:

```
select datname, extract(epoch from max(clock_timestamp()-xact_start)) from pg_stat_activity
where backend_xmin is not null or backend_xid is not null group by datname order by datname;
```

- удержание горизонта (удерживают на всех базах) физическими слотами репликации, если включена обратная связь (hot_standby_feedback=on

```
select max(age(xmin)) from pg_replication_slots;
select backend_xmin, application_name from pg_stat_replication order by age(backend_xmin) desc;
```

- в самих репликах искать процессы, выполняющие команды, удерживающие горизонт можно так же, как и на мастере - запросом к pg_stat_activity

```
select age(backend_xmin), extract(epoch from (clock_timestamp()-xact_start)) secs, pid, datname database,
state from pg_stat_activity where backend_xmin IS NOT NULL OR backend_xid IS NOT NULL order by
greatest(age(backend xmin), age(backend xid)) desc;
```

Параметры `max_slot_wal_keep_size` и `transaction_timeout`

- `max_slot_wal_keep_size` по умолчанию -1 (без ограничений) максимальный размер журнальных файлов, который может оставаться в каталоге `pg_wal` после выполнения контрольной точки для слотов репликации
- `transaction_timeout` по умолчанию ноль (таймаут отключен). Позволяет отменить любую транзакцию или одиночную команду, длительность которой превышает указанный период времени, а не только простаивающую. Защищает от удержания горизонта базы данных и раздувания файлов (bloat)

Параметры мастера, которые должны быть синхронизированы с репликами

- Если менять значения этих параметров на мастере, то на репликах эти значения должны соответствовать значениям на мастере
- Изменения в этих параметрах записываются в журнал
- если реплика обнаружит, что значение на мастере стало больше, то наложение журнальных записей приостановится или экземпляр реплики остановится
- Список параметров:
- `max_connections`, `max_prepared_transactions`, `max_locks_per_transaction` ограничивают максимальное количество блокировок на уровне объектов
- `max_wal_senders`
- `max_worker_processes`

Смена ролей мастер-реплика

- запланированная когда мастер работоспособен называют switchover
- если мастер неработоспособен называют failover
- убедиться что мастер остановлен перед тем как дать сигнал одной из реплик стать мастером
- исключить или минимизировать потерю транзакций
- `pg_last_wal_replay_lsn()` - журнальная запись, которая была восстановлена последней
- `pg_last_wal_receive_lsn()` - последний полученный LSN на реплике

Повышение реплики до мастера

- запустить утилиту `pg_ctl promote`
- вызвать функцию `pg_promote()`
- повышение до мастера увеличивает линию времени на единицу
- при переходе на новую линию времени в директории кластеров `PGDATA/pg_wal` создаётся текстовый файл `0000000N.history`

Файлы истории линий времени

- Находятся в директории `PGDATA/pg_wal`
- Имеют название `0000000N.history`
- Удалять эти файлы не стоит
- при повышении реплики до мастера создаётся новая линия времени и новый файл истории линий времени
- используются утилитами и процессами в целях резервирования и восстановления
- запрашиваются и передаются по протоколу репликации наравне с файлами журналов
- резервируются наравне с файлами журналов

Утилита `pg_rewind`

- синхронизирует директорию `PGDATA` и табличных пространств с исходным кластером, в том числе заменяет файлы параметров
- используется для того, чтобы вернуть в работу бывший мастер после незапланированной смены ролей
- смена ролей должна быть выполнена с переходом на новую линию времени
- требует включенных `full_page_writes`, подсчета контрольных сумм (или `wal_log_hints`)
- создаёт файл `backup_label` в котором указываются параметры для восстановления согласованности

Процессы экземпляра реплики

- **postgres** основной процесс, запускает другие процессы, принимает соединения
- **checkpointer** выполняет точки рестарта
- **background writer** записывает грязные страницы на диск
- **startup** накатывает журнальные записи из файлов в `PGDATA/pg_wal`
- **walreceiver** принимает поток журнальных записей и записывает их в файлы в `PGDATA/pg_wal`

Отложенная репликация

- Можно установить задержку для реплики в применении журнальных записей
- по умолчанию задержки нет
- устанавливается параметром `recovery_min_apply_delay`
- параметр устанавливается на уровне кластера, при изменении достаточно перечитать файлы параметров

Восстановление повреждённых блоков данных с реплики

- Расширение `page_repair` содержит функцию `pg_repair_page` для восстановления повреждённых блоков
- за один вызов процедуры восстанавливается один блок
- можно восстановить блоки слоёв `main`, `vm`, `fsm`
- в процессе восстановления на отношение устанавливается монопольная блокировка
- блок запрашивается с реплики через соединение
- параметры соединения передаются функции

Демонстрация

- Создание реплики и запуск её экземпляра

Практика

1. Создание реплики
2. Слоты репликации
3. Изменение имени кластера
4. Создание второй реплики
5. Выбор реплики на роль мастера
6. Подготовка к переключению на реплику
7. Переключение на реплику
8. Включение обратной связи
9. Утилита `pg_rewind`



8

8b

Логическая репликация

Логическая репликация

- поддерживает репликацию изменений в строках обычных и секционированных таблиц
- Логическая и физическая репликация могут работать одновременно
- Создаётся два типа объектов: публикации и подписки
- Публикация включает в себя набор таблиц одной базы данных
- Набор таблиц можно менять без остановки репликации
- Реплицируются изменения, а не команды
- Одна и та же таблица быть источником и приемником изменений

Применение логической репликации

Используется для:

- переноса данных в архивные или аналитические базы данных
- консолидации данных: переноса данных из региональных баз данных в центральную
- организации резервной базы данных на случай потери основной
- снижения нагрузки на базу данных за счёт переноса части запросов на резервные базы данных

Физическая и логическая репликация

Возможности логической репликации:

- можно реплицировать наборы таблиц, а не весь кластер целиком
- нечувствительность к основным версиям, платформам, сборкам
- передаются журнальные записи не всего кластера, а только по реплицируемым таблицам
- есть двунаправленная репликация
- журнальные данные **могут** передаваться с физической реплики

Идентификация строк

- для репликации только вставок строк (INSERT) и TRUNCATE идентификаторы строк не нужны
- для обновления и удаления строк в таблице должен быть:
- первичный ключ
- либо уникальный индекс и ограничения целостности NOT NULL на каждом из столбцов уникального индекса
- либо использовать все столбцы для идентификации строки

Способы идентификации строк

- Если в таблице нет первичного ключа, нужно установить способ идентификации строк командой
`ALTER TABLE имя REPLICA IDENTITY`
 - › `DEFAULT`; использовать первичный ключ
 - › `USING INDEX имя`; уникального, не частичного, не отложенного индекса, на всех индексируемых столбцах установить `NOT NULL`
 - › `FULL`; передавать значения всех столбцов
 - › `NOTHING`; установлено для таблиц системного каталога, для пользовательских таблиц не имеет смысла

Действия для создания логической репликации

- Установить значение параметра `wal_level=logical` на мастере и физической реплике к которой будет подсоединяться подписка (изменение параметра требует рестарт экземпляра)
- выбрать таблицы для репликации
- проверить наличие первичных ключей или выбрать способ идентификации строк
- создать таблицы в базах данных-приёмниках
- создать публикации на базе данных-источнике
- создать подписки на базах данных-приёмниках и выбрать параметры подписки

Создание публикации

- выбрать таблицы, которые будут включены в одну публикацию
- Можно указать какие команды будут реплицироваться: вставки, изменение, удаление строк, усечение таблиц
- В публикацию можно включить:
 - › все таблицы базы данных
 - › все таблицы в схемах
 - › список таблиц
- При задании списка таблиц можно указать набор столбцов и фильтр для строк

Создание подписки


- Подписка создаётся в базе данных где находятся таблицы-приёмники изменений
- Каждая подписка должна использовать свой слот логической репликации в базе данных-источнике
- Таблицы источника и приёмника и их столбцы сопоставляются по именам и должны быть одинаковыми
- В таблице-приёмнике могут быть дополнительные столбцы. Они могут заполняться значениями по умолчанию или триггерами

Создание подписки

- При создании подписки указывается строка соединения с базой публикации
- В одной подписке можно указать несколько публикаций если они в одной базе
- При создании подписки строки таблиц публикации можно скопировать в таблицы-приемники
- Логическая репликация работает только через слот
- Слот может быть создан заранее и указан при создании подписки
- Слот может быть создан при создании подписки
- По умолчанию имя слота такое же как имя подписки

Нагрузка на экземпляр


- Для каждой подписки запускается процесс `walsender`, выполняющий буферизацию и логическое декодирование



Получение журнальных данных с реплики

- При создании подписки достаточно указать адрес физической реплики:

```
CREATE SUBSCRIPTION s CONNECTION 'dbname=имя  
host=реплики port=реплики' PUBLICATION p;
```



Конфликты

- Конфликт - если процесс `logical replication worker` не может внести изменения из-за нарушения ограничений целостности или по другой причине
- репликация во всей подписке приостанавливается
- Автоматического разрешения конфликтов нет
- Устранить конфликт можно вручную изменив данные или пропустить (не применять) транзакцию, в которой выполняется команда, приведшая к ошибке
- Информация об ошибке попадает в лог кластера

Двунаправленная репликация

- Если менять значения этих параметров на мастере, то на репликах эти значения должны соответствовать значениям на мастере
- Изменения в этих параметрах записываются в журнал
- если реплика обнаружит, что значение на мастере стало больше, то наложение журнальных записей приостановится или экземпляр реплики остановится
- Список параметров:
- `max_connections`, `max_prepared_transactions`, `max_locks_per_transaction` ограничивают максимальное количество блокировок на уровне объектов
- `max_wal_senders`
- `max_worker_processes`

Демонстрация

- Однонаправленная репликация
- Двунаправленная репликация

Практика

1. Репликация таблицы
2. Репликация без первичного ключа
3. Добавление таблицы в публикацию
4. Двухнаправленная репликация



9

Обзор Платформы Tantor

Сценарии использования

Классический


1. Посмотреть имеющуюся систему мониторинга, локализовать **bottleneck** (CPU, RAM, Disk)
2. Подключится к серверу по ssh
3. Открыть терминальный клиент **psql**
4. Проанализировать статистику на основе системных представлений (**pg_stat_statements**)
5. Найти в файлах логов БД планы запросов (**auto_explain**)
6. Разместить интересующий план запроса в online визуализаторе
7. Определить проблемные операции в запросе
8. Принять решение

Продвинутый

1. Открыть платформу Tantor в браузере
2. Централизованно выбрать наблюдаемую БД
3. Локализовать список наиболее ресурсоемких запросов
4. Открыть лог БД за интересующий интервал времени
5. Открыть визуальный план запроса
6. Прочитать рекомендации по оптимизации
7. Принять решение

Инструменты мониторинга

Универсальные системы мониторинга,
неадаптированные для PostgreSQL



Платформа "Tantor"




Платформа Tantor

- Функциональное ПО с графическим пользовательским интерфейсом, созданное для удобного администрирования кластеров PostgreSQL
- Необходима организациям, которые используют множество БД, каждая из которых обслуживает определенную информационную систему или сервис
- Российские компании переходят на российские аналоги


Настройки пользователей

- Управление пользователями и их ролями




Рабочие пространства

- Управление экземплярами PostgreSQL и кластерами Patroni




Обзор экземпляра

- Консолидация всей важной информации об инстансе PostgreSQL и её представление в упрощенном виде




Кластера Patroni

- Визуализация и наглядное управление кластерами Patroni




Профилировщик запросов

- Отслеживание параметров выполнения запросов и их планы на выбранном промежутке времени.
- Анализ и выявление проблемных запросов в БД




Репликация

- Отображение состояния репликации на Primary сервере, и на сервере Standby



Табличные пространства


- Контроль занимаемого места табличными пространствами в базе данных



НАЗВАНИЕ ТАБЛИЧНОГО ПРОСТРАНСТВА	МОНТИРОВАТЬ	РАЗМЕР ТАБЛИЧНОГО ПРОСТРАНСТВА	ДОСТУПНЫЙ ОБЪЕМ ДЛЯ МОНТИРОВАНИЯ	ОБЩИЙ ОБЪЕМ ДЛЯ МОНТИРОВАНИЯ
pg_global	/	532 KB	107 GB	118 GB
pg_default	/	2 GB	107 GB	118 GB

Оповещения

- Формирование уведомлений о критичных ситуациях с БД




The screenshot displays the Tantor Labs Alerts interface. At the top, there's a header with the Tantor logo, the word 'Alerts', and several icons including a settings gear, a share icon, a notification bell with a red badge, and a user profile icon labeled 'A'. Below the header is a table listing various alerts. The table has columns for ID, Creation Time, Workspace, Resource, Criticality, Trigger, and Status. Each row represents an alert, with criticality levels like 'Предупреждение' (Warning) in yellow and 'Проблема' (Problem) in red. The status column shows whether the alert is 'Открыто' (Open) or 'Закрото - Автоматическое восстановление' (Closed - Automatic recovery).

ИД	ВРЕМЯ СОЗДАНИЯ	РАБОЧЕЕ ПРОСТРАНСТВО	РЕСУРС	КРИТИЧНОСТЬ	ТРИГГЕР	СТАТУС
168685	17/05/2024 12:52.00	Tantor SE 14.6	10.128.0.34	Предупреждение	CPU IOWait Time > 20%, Last value: 24.5%	Открыто
168687	17/05/2024 12:52.00	Tantor SE 14.6	10.128.0.34	Проблема	Cache Hit Ratio	Открыто
168686	17/05/2024 12:52.00	Tantor SE 14.6	10.128.0.34	Проблема	Cache Hit Ratio < 80%, Last value: 59.05%	Открыто
168684	17/05/2024 12:51.00	Tantor SE 14.6	10.128.0.35	Предупреждение	CPU IOWait Time > 20%, Last value: 27.6%	Открыто
168683	17/05/2024 12:51.00	Tantor SE 15.2	10.128.0.36	Предупреждение	CPU Load Average AVG 1 minutes > 150.0%, Last value: 199.00%	Открыто
168681	17/05/2024 12:42.00	Tantor SE 15.2	10.128.0.36	Проблема	Cache Hit Ratio < 80%, Last value: 53.50%	Закрото - Автоматическое восстановление
168682	17/05/2024 12:42.00	Tantor SE 15.2	10.128.0.36	Проблема	Cache Hit Ratio	Закрото - Автоматическое восстановление
168680	17/05/2024 12:42.00	Tantor SE 15.2	10.128.0.36	Предупреждение	CPU IOWait Time > 20%, Last value: 36.0%	Закрото - Автоматическое восстановление
168679	17/05/2024 12:41.00	Tantor SE 15.2	10.128.0.37	Предупреждение	CPU IOWait Time > 20%, Last value: 22.4%	Закрото - Автоматическое восстановление
168677	17/05/2024 12:32.00	Tantor SE 14.6	10.128.0.34	Проблема	Cache Hit Ratio < 80%, Last value: 59.95%	Закрото - Автоматическое восстановление

Конфигурация мониторинга

- Настройка списков баз данных для мониторинга.
- Настройка триггеров для каждой базы данных



Аналитика

- Сбор, анализ и визуализация событий из логов базы данных

The screenshot displays the Tantor Labs SE 15.2 Advanced analytics interface. The left sidebar contains navigation links: ОБЗОР, НАСТРОЙКИ, ОБСЛУЖИВАНИЕ, ИССЛЕДОВАТЬ БД, ПРОФИЛИРОВЩИК ЗАПРОСОВ, ТЕКУЩАЯ АКТИВНОСТЬ, РЕПЛИКАЦИЯ, ТАБЛИЧНЫЕ ПРОСТРАНСТВА, ГРАФИКИ, НАСТРОЙКИ МОНИТОРИНГА, РАСШИРЕННАЯ АНАЛИТИКА, and ЗАДАЧИ. The main panel shows a table of database events with columns: PID, dbname, backend, xact, host / sname, client, changed, query, state, and query. The table is filtered by active = 1, idle = 0, and pg_stat = 9. The table contains 10 rows of data, including events for postgres and test_db databases, with various states like active, idle, and error.

PID	dbname	backend	xact	host / sname	client	changed	query	state	query
18090	postgres	2024-05-23 21:00:20.498074	2h 59m 50s 333.482ms pg-monitor pgstat	127.0.0.1	2h 59m 50s 334.000ms 09:37:29.666	2h 59m 50s 334.000ms 09:37:29.666	SELECT clock_timestamp(), * FROM pg_stat_get_activity(NULL);	active	
18091	postgres	2024-05-23 21:00:20.507475	-----	127.0.0.1	3h 50s 132.102ms 09:36:29.867898	3h 50s 135.000ms 09:36:29.865		idle	
18092	test_db	2024-05-23 21:00:20.52074	-----	127.0.0.1	2h 59m 51s 140.244ms 09:37:28.859759	2h 59m 51s 142.277ms 09:37:28.857723		idle	
18104	postgres	2024-05-23 21:00:27.298416	9h 47m 32s 610ms 162 pg-monitor pgstat	127.0.0.1	2h 59m 50s 422.167ms 09:37:29.577833	2h 59m 50s 422.386ms 09:37:29.577614	SELECT clock_timestamp(), * FROM pg_stat_get_activity(NULL);	idle	
18105	postgres	2024-05-23 21:00:27.309156	-----	127.0.0.1	2h 59m 51s 502.298ms 09:37:24.497702	2h 59m 51s 504.365ms 09:37:24.496635		idle	
18106	test_db	2024-05-23 21:00:27.313739	-----	127.0.0.1	2h 59m 56s 508.968ms 09:37:23.49032	2h 59m 56s 510.975ms 09:37:23.489025		idle	
18119	postgres	2024-05-23 21:00:38.407723	9h 47m 32s 610ms 113 pg-monitor pgstat	127.0.0.1	2h 59m 51s 214.033ms 09:37:28.785987	2h 59m 51s 215.000ms 09:37:28.785	SELECT clock_timestamp(), * FROM pg_stat_get_activity(NULL);	idle	
18120	postgres	2024-05-23 21:00:38.417525	-----	127.0.0.1	2h 59m 55s 047.07ms 09:37:24.529953	2h 59m 55s 472.078ms 09:37:24.527922		idle	
18121	test_db	2024-05-23 21:00:38.422426	-----	127.0.0.1	2h 59m 56s 475.865ms 09:37:23.524135	2h 59m 56s 477.768ms 09:37:23.522232		idle	

Активности фоновых процессов

- Онлайн-мониторинг состояния пользовательских сессий в базе данных PostgreSQL

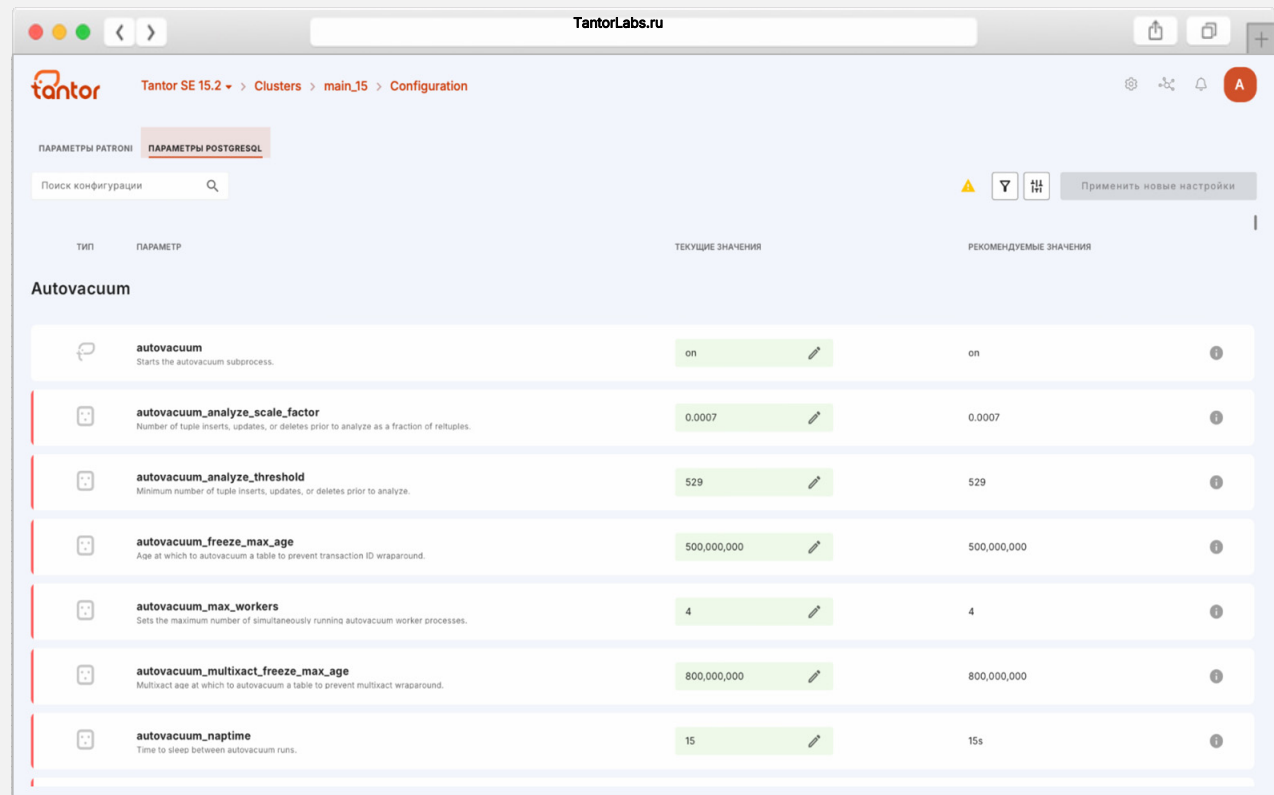
The screenshot shows the Tantor Labs web interface for monitoring PostgreSQL database activity. The breadcrumb navigation indicates the path: Tantor SE 15.2 > Cluster > main_15 > Instances > demo-db-004.tantorlabs.ru: 5432 > Текущая активность > test_db. The left sidebar contains navigation links: Обзор, Настройки, Исследовать БД, Профилировщик запросов, Текущая активность (selected), Репликация, Табличные пространства, Графики, Настройки мониторинга, Расширенная аналитика, and Задачи. The main content area shows a table of active sessions with the following columns: PID, Имя пользователя, ЦПУ%, ОЗУ%, Чтение (Б/с), Запись (Б/с), Ожидание I/O, Ожидание, Состояние, Длительность, Запрос, and Действие. Two sessions are listed:

PID	Имя пользователя	ЦПУ%	ОЗУ%	Чтение (Б/с)	Запись (Б/с)	Ожидание I/O	Ожидание	Состояние	Длительность	Запрос	Действие
26293	postgres	N/A	1.65	N/A	N/A	Нет	Нет	idle	55.94 sec	WITH nspjs AS (...)	Завершить
26278	postgres	N/A	1.41	N/A	N/A	Нет	Нет	idle	17.2 sec	WITH nspjs AS (...)	Завершить

At the bottom right, a note indicates: * Частота обновления данных - 5 секунд.

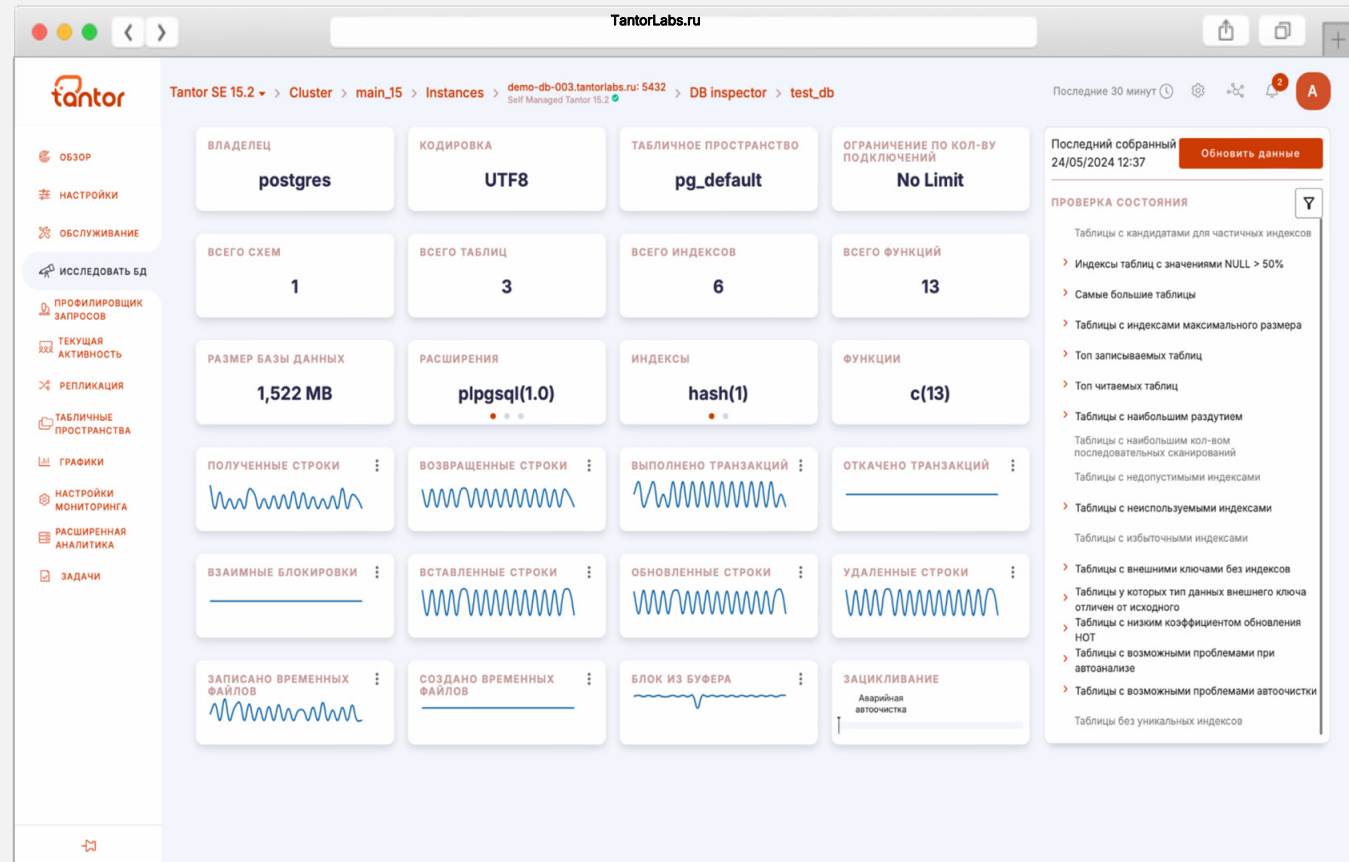
Настройки

- Просмотр и изменение файла конфигурации postgresql.conf, и конфигурации кластерного программного обеспечения Patroni




Анализ схемы данных

- Анализ схемы данных базы PostgreSQL




Регламентное обслуживание

- Исправление раздутия таблиц и индексов, а также устранение переполнения счетчика транзакций



Планировщик задач

- Автоматизация и планирование выполнения различных операций. Настройка запуска действий по заданному расписанию, включает выполнение системных команд или SQL-скриптов



Курс по Платформе Tantor

- Возможности Платформы Tantor изучаются в учебном курсе
 - › длительность курса 2 дня
- Темы курса:
 - › Введение
 - › Подготовка к работе
 - › Мониторинг
 - › Задачи конфигурирования и обслуживания
 - › Установка Платформы и Агента



10

Новые возможности Tantor Postgres 17 версии

Tantor Postgres - ветвь PostgreSQL

СУБД Tantor Postgres включает в себя:

- все возможности "ванильного" PostgreSQL
- возможности, которые появятся в будущих версиях PostgreSQL
- дополнительные расширения и утилиты
- изменения в ядре PostgreSQL, которые нужны для высоконагруженных СУБД и приложений, формирующих сложные запросы (1C:ERP)
- собственные доработки

Доработки в Tantor Postgres

- Доработки позволяют улучшить производительность и отказоустойчивость при промышленной эксплуатации
- Доработки вносятся так, чтобы Tantor Postgres минимально отличался от основной ветви PostgreSQL
 - › выбирается реализация, которая имеет наибольшую вероятность появления в основной ветви
 - › наименее меняющая код PostgreSQL и его настройки по умолчанию
- Администрируя Tantor Postgres можно применять опыт администрирования PostgreSQL
- Тантор Лабс избегает доработок, которые могли бы привязать приложения ("vendor lock") и затруднить работу приложений в ванильном PostgreSQL

Дополнительные параметры конфигурации

- В Tantor Postgres 17.5 есть 15 дополнительных параметров, влияющих на создание и выбор планов запросов и функционал:

```
postgres=# \dconfig enable_*
          Parameter          | Value
-----+-----
enable_convert_exists_as_lateral_join | on
enable_convert_in_values_to_any      | on
enable_group_by_reordering           | on
enable_index_path_selectivity         | on
enable_join_pushdown                  | on
enable_self_join_removal              | on
```

```
backtrace_on_internal_error | off
enable_delayed_temp_file    | off
enable_large_allocations    | off
enable_temp_memory_catalog  | off
libpq_compression           | off
wal_sender_stop_when_crc_failed | off
pg_stat_statements.sample_rate | 1
pg_stat_statements.mask_const_arrays | off
pg_stat_statements.mask_temp_tables | off
```

- Параметры, появившиеся в PostgreSQL 17 версии:

```
allow_alter_system, commit_timestamp_buffers, huge_pages_status, io_combine_limit,
max_notify_queue_pages, ultixact_member_buffers, multixact_offset_buffers, notify_buffers,
restrict_nonsystem_relation_kind, serializable_buffers, subtransaction_buffers,
summarize_wal, sync_replication_slots, synchronized_standby_slots,
trace_connection_negotiation, transaction_buffers, transaction_timeout, wal_summary_keep_time
```

Расширения Tantor Postgres SE и SE 1C

- Ядра Tantor Postgres SE и SE 1C унифицированы
 - › все возможности и расширения SE 1C есть в SE
- Tantor Postgres SE и SE 1C включают:
 - › расширения `credcheck`, `cube`, `fasttrun`, `fulleq`, `hypopg`, `mchar`, `page_repair`, `pg_cron`, `pg_hint_plan`, `pg_repack`, `pg_stat_kcache`, `pg_store_plans`, `pg_trace`, `pg_uuidv7`, `pg_wait_sampling`, `pgaudit`, `pgaudittofile`, `transp_anon`
 - › библиотеки `dbcopies_decoding`, `oauth_base_validator`, `online_analyze`, `pg_query_id`, `pg_stat_advisor`, `plantuner`, `wal2json`
 - › утилиты `pgcompacttable`, `pgcopydb`, `pg_diag`, `pg_repack`
- В отдельных пакетах поставляются программы: `pg_anon`, `wal-g`, `pg_configurator`, `pg_cluster`, `pg_diag_setup`, `pg_sec_check`
- Tantor Postgres SE дополнительно включает расширения:
 - › `http`, `orafce`, `pgl_ddl_deploy`, `pgq`, `vector`, `pg_archive`, `pg_columnar`, `pg_ivm`, `pg_partman`, `pg_qualstats`, `pg_tde`, `pg_throttle`, `pg_variables`, `pg_background`

Параметры оптимизатора запросов

- В 17 версии Tantor Postgres появилось 6 параметров, которыми можно включать оптимизации планирования запросов
- Оптимизации позволяют существенно уменьшать время выполнения встречающихся на практике запросов
- Параметры добавлены, чтобы была гибкость настройки оптимизатора запросов
- По умолчанию оптимизации включены

```
postgres=# \dconfig enable_*
          Parameter                               | Value
-----+-----
enable_convert_exists_as_lateral_join          | on
enable_convert_in_values_to_any                 | on
enable_group_by_reordering                     | on
enable_index_path_selectivity                  | on
enable_join_pushdown                           | on
enable_self_join_removal                      | on
```

Библиотека pg_stat_advisor

- автоматически обнаруживает запросы, где планировщик **недооценивает** или **переоценивает** число возвращаемых строк (actual rows отличается от планируемых rows)
- Если коэффициент расхождения превышает заданный порог создает расширенную статистику на таблицу

```
set pg_stat_advisor.suggest_statistics_threshold = 0.33;
create table t (i int, j int);
insert into t select i/10, i/100 from generate_series(1, 1000000) i;
analyze t;
explain (analyze, buffers, timing off) select * from t where i = 100 and j = 10;
select pg_sleep(1);
\dx
```

List of extended statistics

Schema	Name	Definition	Ndistinct	Dependencies	MCV
public	t_i_j_stat	i, j FROM t	defined	defined	defined

```
\i cat $PGDATA/log/postgresql-*.log | grep pg_stat_advisor
```

```
LOG:  pg_stat_advisor: successfully created extended statistics  from public.t
```

Параметры `enable_temp_memory_catalog` и `enable_delayed_temp_file`

- `enable_temp_memory_catalog` позволяет сохранять метаданные временных объектов в локальной памяти того процесса, который работает с ними и не вносить изменения в таблицы системного каталога
 - › скорость доступа к метаданным уже созданной временной таблицы выше
 - › способ хранения данных во временных объектах и способ доступа к данным не меняются
- `enable_delayed_temp_file` ускоряет работу с временными таблицами, позволяя не создавать файлы временных таблиц, пока хватает памяти локального буфера серверного процесса

Параметр enable_large_allocations

- увеличивает размер StringBuffer с 1 гигабайта до 2 гигабайт

```
postgres=# select * from pg_settings where name like '%large%'\gx
name          | enable_large_allocations
setting       | off
category      | Resource Usage / Memory
short_desc    | whether to use large memory buffer greater than 1Gb, up to 2Gb
context       | superuser
vartype       | bool
boot_val      | off
```

- может устанавливаться на уровне сессии и утилитами
pg_dump, pg_dumpall

```
postgres@tantor:~$ pg_dump --help | grep alloc
--enable-large-allocations  enable memory allocations with size up to 2Gb
```

- проблема возникает со строкой таблицы config приложений
1C:ERP, Комплексная автоматизация, Управление
производственным предприятием

Алгоритм сжатия pglz

- В Tantor Postgres оптимизирован алгоритм сжатия данных pglz
- Оптимизация удаляет потенциально избыточные операции, повышая скорость сжатия в 1.4 раза.
- Сжатие используется только для типов данных переменной ширины и используется по умолчанию для большинства типов данных, которые могут использовать сжатие
- Алгоритм сжатия **pglz** применяется по умолчанию для сжатия TOAST

```
postgres=# \dconfig *compress*
```

Список параметров конфигурации

Параметр	Значение
default_toast_compression	pglz
libpq_compression	off
wal_compression	off

Параметр `libpq_compression`

- значение по умолчанию `off`
- определяет список поддерживаемых алгоритмом сжатия сетевого трафика
- допустимые значения: `off`, `on`, `lz4`, `zlib`
- можно задавать уровень сжатия, например:

```
alter system set libpq_compression =  
'lz4:1,zlib:2';
```


Параметр `wal_sender_stop_when_crc_failed`

- снижает вероятность передачи поврежденных журнальных записей на реплики
- по умолчанию отключен
- при включении процессы `walsender` будут проверять контрольные суммы журнальных записей перед передачей клиентам. Если контрольная сумма не совпадёт, то процессы попытаются прочесть запись из журнального буфера (WAL buffer). Если в журнальном буфере уже не будет записи или контрольная сумма не совпадёт, то `walsender` остановится

Параметр `backtrace_on_internal_error`

- Параметр относится к группе Developer Options, то есть не используется при промышленной эксплуатации
- Если этот параметр включен и возникает ошибка с кодом XX000 (`internal_error`), то трассировка стека записывается в диагностический журнал вместе с сообщением об ошибке
 - Это полезно при отладке внутренних ошибок, которые обычно не возникают в рабочей среде
- По умолчанию выключен.

Расширение uuid_v7

- расширение добавляет функцию высокоскоростной генерации uuid_v7
- uuid_v7 генерирует возрастающие значения, что позволяет использовать оптимизацию вставки в индекс btree
 - при очень частых вставках в сессии высокая скорость, не медленнее, чем с bigserial
 - структура индекса остаётся оптимальной и компактной
- uuid занимает 16 байт, bigint 8 байт
- пример использования:

```
create extension if not exists "uuid-oss";
create extension if not exists pg_uuidv7;
create table tt1 (id uuid default uuidv7() primary key, data bigint);
create table tt2 (id bigint generated by default as identity primary key, data bigint);
select count(*), pg_indexes_size('tt1') from tt1;
```

Расширение pg_tde (Transparent Data Encryption)

- Реализует "прозрачное" шифрование данных (Transparent Data Encryption)
- Прозрачность означает, что клиент получает и передает незашифрованные данные
- Не шифрует данные в памяти (в буферном кэше) и при передаче по сети
- Шифрование выполняется протоколами: AES, Magma, Kuznyesich, ChaCha20
- Физическая и логическая репликация поддерживаются
- Таблицы системного каталога не шифруются
- pg_rewind пока не работает с зашифрованным WAL
- WAL шифруются полностью

Валидатор oauth_base_validator

- В Tantor Postgres 17 есть способ аутентификации **oauth** (OAuth 2.0), который появится в PostgreSQL 18 версии
- Этот способ использует внешнюю службу для аутентификации
- Метод **oauth** вставляется в четвертое поле строки в файле `pg_hba.conf`

```
#TYPE DATABASE USER ADDRESS METHOD
local all      all          oauth issuer="http://1.1.1.1:80/realms/a" scope="openid" map="o1"
```

- Для использования способа аутентификации **oauth** нужно на языке С написать "валидатор"
- В Tantor Postgres библиотека с валидатором поставляется
- Пример аутентификации в psql:

```
psql "user=alice dbname=postgres oauth_issuer=http://1.1.1.1:80/realms/a oauth_client_id=user1
oauth_client_secret=AbCdEf123GhIjKl"
Visit http://1.1.1.1:80/realms/a/device and enter the code: XYZX-XYZO
postgres=>
```

Библиотека credcheck

- Использует библиотеку, которая может загружаться на уровне кластера (параметр `shared_preload_libraries`) и для одной сессии (командой `LOAD credcheck`)
- При загрузке регистрирует 30 параметров конфигурации, которыми можно задать проверки сложности пароля, защиту от подбора пароля, параметры повторного использования паролей, список ролей на которые проверки не действуют и т.п.
- В расширении 8 функций и 2 представления
- Расширение срабатывает при создании роли, переименовании, изменении пароля, аутентификации

postgres=# \dconfig credcheck.*	
Parameter	Value
-----+-----	
credcheck.auth_delay_ms	0
credcheck.encrypted_password_allowed	off
credcheck.max_auth_failure	0
...	
credcheck.whitelist	
(30 rows)	

Расширения fastrun и online_analyze

- Усечение временных таблиц обновляет таблицу pg_class
- Расширение fastrun содержит функцию **fasttruncate**
 - › у файлов не меняется название
 - › таблицы системного каталога не меняются
 - › может использоваться вместо команды TRUNCATE
 - › работает только с временными таблицами
- После усечения или других команд можно собрать статистику
- Для автоматического **сбора статистики** можно использовать расширение online_analyze
 - › расширение настраивается параметрами конфигурации

```
select fasttruncate('tt');
INFO:  analyzing "pg_temp_5.tt"
INFO:  "tt": scanned 0 of 0 pages, containing 0 live rows and 0 dead rows; 0 rows in sample, 0 estimated
total rows
INFO:  analyze "tt" took 0.00 seconds
 fasttruncate
-----

(1 row)
```

Расширение mchar

- Добавляет поддержку типов mchar, mvarchar для совместимости с Microsoft SQL Server
- Для типов mchar и mvarchar определяет функции и операторы:
 - › length()
 - › substr(str, pos[, length])
 - › || конкатенация с разными типами (mchar || mvarchar)
 - › < <= = >= > сравнение без чувствительности к регистру (ICU)
 - › &< &<= &= &>= &> сравнение с чувствительностью к регистру (ICU)
 - › LIKE
 - › SIMILAR TO
 - › ~ (регулярные выражения)
- Добавляют неявное приведение типов mchar к mvarchar и обратно
- поддержку типов индексами b-tree и hash
- Использование индексов для выполнения оператора LIKE

Расширение `fulleq`

- При использовании оператора `"=`" для сравнения значений, если хотя бы один из операндов имеет значение `NULL`, результатом будет `NULL`
- В приложениях 1С часто используется оператор `"=="`, который возвращает `true`, когда операнды равны или оба имеют значение `NULL`, что удобно при работе с базами данных, особенно с 1С, где операторы и семантика работы с `NULL` отличаются от стандарта SQL
- Оператор `"=="` из расширения `fulleq` позволяет высокоэффективно выполнять сравнение значений с использованием нужной логики

Расширение orafce

- Расширение, предоставляющее функции, упрощающие миграцию кода приложений с Oracle Database
- orafce эмулирует часть функционала и пакетов Oracle Database
- Создаёт большое количество функций и других объектов и типов данных, которые работают так же, как их аналоги в Oracle Database
- Расширение упрощает миграцию кода приложений в Tantor Postgres с Oracle Database
- Расширение создаёт 15 схем, в которых находятся объекты расширения. Имена восьми схем соответствуют именам пакетов в Oracle Database

Расширение http

- Расширение http предоставляет возможность выполнять HTTP и HTTPS запросы прямо из SQL
- Устанавливается в базу данных командой `create extension http;`
- можно создать триггер, обращающийся к веб-службе, передать данные и получить результат, который можно использовать в логике триггера
- pgsql-http может быть полезен в:
- Интеграции с внешними API
- Интерактивных приложениях
- Обработке данных в реальном времени

Расширение pg_store_plans

- Расширение для отслеживания статистики выполнения SQL-запросов
- сохраняет полные планы запросов, а не только их статистику или текст
- использование pg_store_plans может увеличить нагрузку на систему из-за сбора и хранения дополнительных данных

Расширение pg_variables

- Расширение, позволяющее создавать и использовать переменные в SQL-запросах
- по умолчанию не транзакционны, но могут быть транзакционными
- хранятся в памяти серверного процесса
- существуют только в текущем сеансе пользователя
- могут использоваться на физических репликах, временные таблицы не могут
- скорость работы сравнима с временными таблицами
- отсутствие накладных расходов (не требуют реальный номер транзакции, не создают файлы)

Производительность при использовании pg_variables

- При сравнении скорости доступа к таблицам в памяти, временным, обычным результаты не очевидны
- Расширение pg_variables не является стандартным и не пользуется популярностью из-за неудобного синтаксиса использования и невятной производительности

```
select * from pgv_select('bookings', 'tickets', '0005432020304'::char(13)) as (ticket_no character(13),  
book_ref character(6), passenger_id character varying(20), passenger_name text, contact_data jsonb);  
Time: 0.281 ms  
select * from tickets where ticket_no='0005432020304';  
Time: 0.266 ms  
select book_ref from tickets where passenger_name like '%G IVANOV' limit 1;  
Time: 0.463 ms  
select book_ref from tickets1 where passenger_name like '%G IVANOV' limit 1;  
Time: 1.169 ms  
select book_ref from pgv_select('bookings', 'tickets', '0005432020304'::char(13)) as (ticket_no  
character(13), book_ref character(6), passenger_id character varying(20), passenger_name text, contact_data  
jsonb) where passenger_name like '%G IVANOV' limit 1;  
Time: 0.185 ms
```

Преимущества расширения pg_variables

- Временные таблицы нельзя использовать на репликах
- функции расширения pg_variables можно использовать на репликах точно так же, как на мастере
- pg_variables хранит данные только в локальной памяти серверного процесса и не использует временные файлы
- Переменные могут быть транзакционными и нет
- На сохраняемые объекты действует ограничение строкового буфера - 1Гб

```
select pgv_insert('bookings','t2', pgbench_branches) from pgbench_branches;
select * from pgv_select('bookings','t2',1) as (bid int, bbalance int, filler character(88));
  bid | bbalance | filler
-----+-----+-----
    1 |         0 |
select pgv_select('bookings','t2',1);
 pgv_select
-----
(1,0,)
```

Расширение pg_stat_kcache

- дополняет pg_stat_statements и зависит от него
- собирает статистику linux, выполняя системный вызов getrusage после выполнении каждой команды
- в отличие от утилит операционной системы, расширение собирает статистики с детальностью до команды
- позволяет различать читался блок с диска или из страничного кэша
- использует два буфера в разделяемой памяти

```
select * from (select *,lead(off) over(order by off)-off as diff from pg_shmem_allocations) as a where name like 'pg_%';
```

name	off	size	allocated_size	diff
pg_stat_statements	148162816	64	128	128
pg_stat_statements hash	148162944	2896	2944	2188544
pg_stat_kcache	150351488	992	1024	1024
pg_stat_kcache hash	150352512	2896	2944	1373056

```
select name, setting, context, min_val, max_val from pg_settings where name like '%kcache%';
```

name	setting	context	min_val	max_val
pg_stat_kcache.linux_hz	333333	user	-1	2147483647
pg_stat_kcache.track	top	superuser		
pg_stat_kcache.track_planning	off	superuser		

Статистики, собираемые pg_stat_kcache

Статистики в представлениях `pg_stat_kcache` и `pg_stat_kcache_detail`:

- `reads_blks` reads, in 8K-blocks
- `writes_blks` writes, in 8K-blocks
- `user_time` user CPU time used
- `system_time` system CPU time used
- `minflts` page reclaims (soft page faults)
- `majflts` page faults (hard page faults)
- `nswaps` swaps
- `msgsnds` IPC messages sent
- `msgrcv` IPC messages received
- `nsignals` signals received
- `nvcs` voluntary context switches
- `nivcs` involuntary context switches

```
alter system set shared_preload_libraries = pg_stat_statements, pg_wait_sampling, pg_stat_kcache;  
create extension pg_stat_kcache;  
\dx+ pg_stat_kcache  
function pg_stat_kcache()  
function pg_stat_kcache_reset()  
view pg_stat_kcache  
view pg_stat_kcache_detail
```

Расширение `pg_wait_sampling`

- входит во все сборки Tantor Postgres
- выдает статистику по событиям ожиданий всех процессов экземпляра
- для установки нужно загрузить библиотеку и установить расширение:

```
alter system set shared_preload_libraries = pg_stat_statements, pg_stat_kcache, pg_wait_sampling;  
create extension if not exists pg wait sampling;
```

- библиотека `pg_wait_sampling` должна быть указана позже `pg_stat_statements`, чтобы расширение не перезаписало идентификаторы запросов (queryid)
- расширение использует фоновый процесс `pg_wait_sampling collector`
- процесс опрашивает состояние всех процессов экземпляра
- в расширение входят 4 функции и 3 представления:

```
\dx+ pg_wait_sampling  
function pg_wait_sampling_get_current(integer)  
function pg_wait_sampling_get_history()  
function pg_wait_sampling_get_profile()  
function pg_wait_sampling_reset_profile()  
view pg_wait_sampling_current  
view pg_wait_sampling_history  
view pg_wait_sampling_profile
```

История событий ожидания

- расширение использует "сэмплирование" с частотой от 1 миллисекунды (по умолчанию 10 миллисекунд)
- история доступна через представление:

```
select count(*) from pg_wait_sampling_history;  
count  
-----  
5000
```

- по умолчанию сохраняется история 5000 последних событий ожидания
- расширение также использует разделяемую память под хранение своих трёх структур:
 - очередь (MessageQueue) фиксированного размера 16Kб
 - память под список PID
 - память под идентификаторы команд (queryid), выполняющихся процессами

```
select * from (select *, lead(off) over(order by off)-off as diff from pg_shmem_allocations) as a  
where name like '%wait%';  
  
      name      |      off      | size  | allocated_size | diff  
-----+-----+-----+-----+-----  
pg_wait_sampling | 148145920 | 17536 |          17536 | 17536
```

Расширение pg_background

- Расширение позволяет асинхронно (в фоновом режиме) выполнять произвольную команду и реализовать произвольные задачи, которые нужно выполнить приложению или администратору. Задачи будут выполняться фоновыми процессами экземпляра.
- Расширение содержит функции :
 - `pg_background_launch()`
 - `pg_background_result()`
 - `pg_background_detach()`

Расширения pgaudit и pgaudittofile

- расширениями `pgaudit` и `pgauditlogtofile` можно направить сообщения о создании сессий и их длительности в отдельный файл или файлы аудита
- для работы расширений нужно загрузить их библиотеки:

```
alter system set shared_preload_libraries = pgaudit, pgauditlogtofile;
```

- Расширения работают независимо и параллельно с журналом кластера и управляются собственными параметрами, которые имеют префикс "`pgaudit.`"
- параметры `pgaudit.log_connections` и `pgaudit.log_disconnections` аналогичны одноимённым параметрам PostgreSQL и могут создавать аналогичные записи в отдельном файле аудита

Конфигурирование расширений pgaudit и pgaudittofile

- **семь** параметров относятся к библиотеке pgauditlogtofile
- чтобы создавался журнал аудита нужно установить параметр pgaudit.log как минимум в значение 'misc'
 - > 'none' - файл журнала аудита не создаётся
 - > 'role' и 'ddl' pgaudit.log_connections и pgaudit.log_disconnections не действуют

```
postgres=# \dconfig pgaudi*
          List of configuration parameters
          Parameter                      |      Value
-----+-----
pgaudit.log                            | none
pgaudit.log_autoclose_minutes          | 0
pgaudit.log_catalog                    | on
pgaudit.log_client                     | off
pgaudit.log_connections                | off
pgaudit.log_directory                 | log
pgaudit.log_disconnections             | off
pgaudit.log_filename                   | audit-%F.log
pgaudit.log_level                      | log
pgaudit.log_parameter                  | off
pgaudit.log_parameter_max_size         | 0
pgaudit.log_relation                   | off
pgaudit.log_rotation_age               | 1d
pgaudit.log_rotation_size              | 0
pgaudit.log_rows                       | off
pgaudit.log_statement                  | on
pgaudit.log_statement_once             | off
pgaudit.role                           |
(18 rows)
```

Утилита pgcopydb

- Утилита автоматизирует копирование базы данных на другой кластер
- Типичный случай использования pgcopydb - миграция на новую основную версию PostgreSQL с минимизацией простоя
- Утилита реализует задачу распараллеливания с поточной передачей данных по логике "pg_dump -jN | pg_restore -jN" между двумя работающими кластерами, дирижируя этими утилитами
- Поддерживает параллельное создание индексов, отслеживание изменений и их применение, возобновление прерванной перегрузки, фильтрацию объектов
- Проектом с открытым исходным кодом

Утилита pg_anon

Программа, написанная на языке python выполняет:

- поиск конфиденциальных данных в базе данных
- создание словаря на основе результатов поиска
- сохранение и восстановление с использованием словаря
- синхронизация содержимого или структуры указанных таблиц между исходной и целевой базами данных
- выгрузка данных с маскировкой (обезличиванием, анонимизацией) по заданным шаблонам

Утилита pg_configurator

- Представляет собой скрипт pg_configurator на языке python, устанавливаемый по пути /usr/bin
- предлагает рекомендуемые параметры конфигурации на основе характеристик аппаратных ресурсов, таких как доступная память, количество процессоров и дисковое пространство и т.д. Это позволяет оптимально использовать имеющиеся ресурсы и увеличить производительность экземпляра

Утилита `pg_diag_setup.py`

- Задача, решаемая утилитой: вызвать утилиту на хосте кластера баз данных, которая установит и настроит параметры расширений в соответствии с шаблоном и резервирует значения параметров, чтобы можно было восстановить изменения
- Проверяет доступность расширений через `pg_available_extensions`
- Обновляет значение `shared_preload_libraries` без перезаписи существующих библиотек
- Добавляет новые параметры в конец `postgresql.conf`
- Создает текстовый файл бэкапа со значениями конфигурируемых параметров с временной меткой
- Позволяет откатить изменения к любому бэкапу

Утилита pg_sec_check

- позволяет автоматизировать процесс проверки параметров безопасности: от настроек операционной системы до параметров конфигурации PostgreSQL
- создаёт отчеты о выявленных проблемах и рекомендации по их устранению
- проверки выполняются скриптами `.sql` и `.sh`
- результаты проверок валидируются скриптами на языке Lua, ими же формируются отчеты и рекомендации
- проверяет целостность своих файлов контрольными суммами
- В утилите имеется 68 проверок
- можно создавать собственные проверки путем написания скриптов `.sql` `.sh` `.lua`

Утилита WAL-G (Write-Ahead Log Guard)

- утилита для создания зашифрованных резервных копий кластера баз данных (полных и инкрементальных) и архивирования WAL-сегментов, их высокоэффективной отправки/получения по протоколу S3 "из" и "в" хранилища (облачные в сети предприятия или внешние) напрямую без создания промежуточных файлов в файловой системе.
- Используя утилиту WAL-G можно:
 - › создавать резервные копии кластера и WAL-сегментов
 - › восстанавливать кластер на выбранный момент времени в прошлом
 - › управлять резервными копиями по протоколу S3: удалять ненужные бэкапы и связанные с ними файлы журналов

Другие расширения

- `dbcopies_decoding` - библиотека 1С, предоставляет слоты логической репликации при копировании баз данных баз данных 1С
- `vector` - полная поддержка типа данных векторов большой размерности
- `pg_partman` - автоматизация поддержки секционированных таблиц
- `pg_qualstats` - ведёт статистику по предикатам, найденным в операторах `WHERE` и в предложениях `JOIN`
- `pg_hint_plan` - подсказки оптимизатору в запросах
- `plantuner` скрывает индексы от планировщика
- `pg_cron` - планировщик внутри экземпляра
- `pg_throttle` - ограничение объема читаемых строк в запросах, позволяющее снизить конкуренцию за ввод-вывод
- `pg_trace` - трассировки работающих запросов, может быть полезна для анализа запросов в 1С
- `pg_ddl_deploy` - расширение для логической репликации
- `pqg` - очередь в базе данных

Практика

1. Расширение orafce
2. Расширение pg_variables
3. Расширение page_repair
 1. Подготовка реплики
 2. Подготовка таблицы
 3. Восстановление страницы с помощью page_repair
 4. Обнуление страницы
4. Отладка подпрограмм
 1. Установка расширения из исходных кодов на примере pldebugger
 2. Отладка функции в pgAdmin
 3. Отладка подпрограмм в DBeaver
5. Обработка строк большого размера StringBuffer
6. Поиск осиротевших файлов