Новые технологии репликации в PostgreSQL

Александр Алексеев

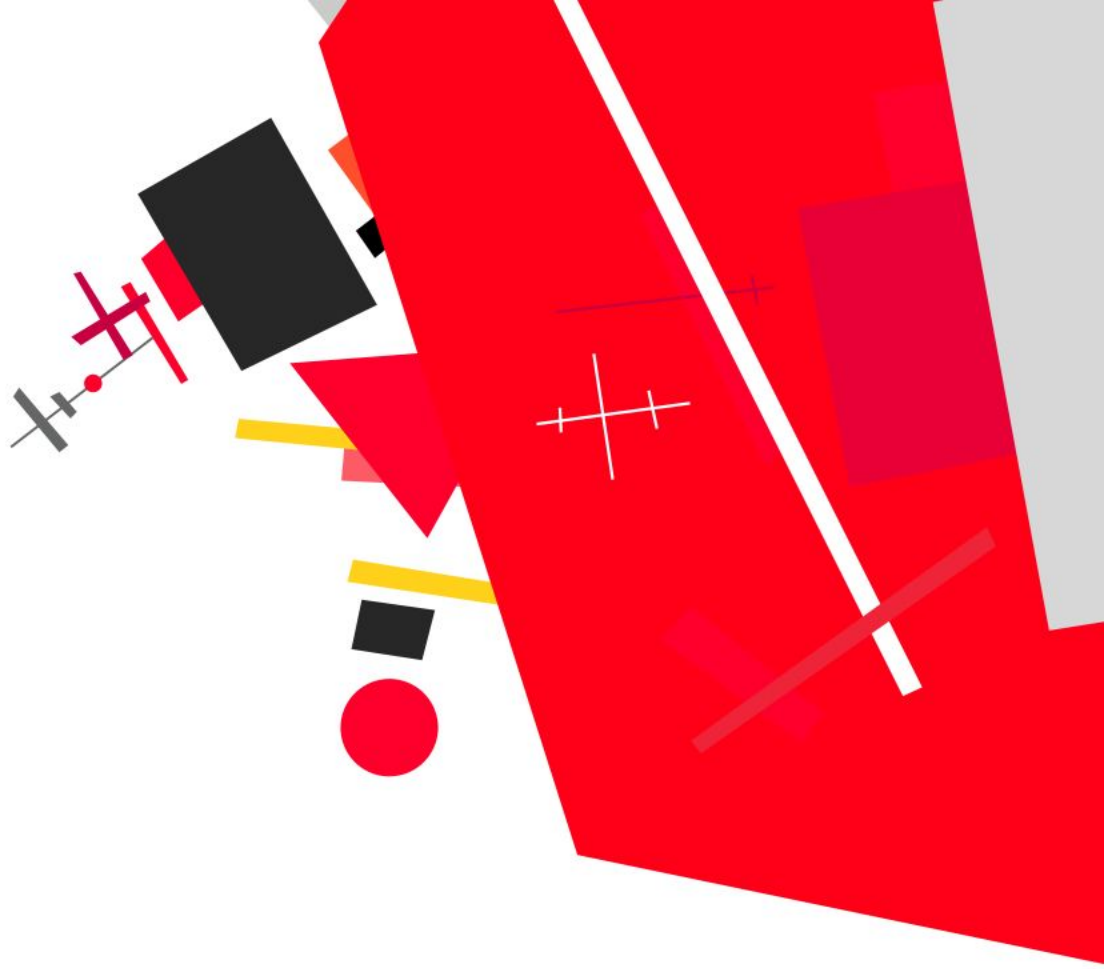

HighLoad++

Профессиональная конференция разработчиков высоконагруженных систем

Коротко о себе

DevZen
PODCAST

Для кого этот доклад

- Вы считаете, что репликация — это непостижимо сложно;
- Вы думаете, что масштабироваться можно только горизонтально;
- Вы никогда не настраивали физическую и/или логическую репликацию в PostgreSQL;
- Вы не знаете, как настроить фейловер;
- Вы хотели бы узнать, что нового здесь появилось у PostgreSQL в последнее время;
- Вы ищете идею для проекта =);

Чего в нем не будет

- Скучного пересказа документации на тему, что именно писать в конфигах. То есть доклад, скорее, обзорный;
- Для заинтересованных в конце приводятся ссылки на дополнительные материалы.

Небольшое отступление о железе

- В AWS инстанс x1.32xlarge (128 vCPU, 1952 Гб памяти, 2 x 1920 Гб SSD) стоит 9603$ в месяц [1];
- SSD на 1 Тб стоит от ~20 000 рублей [2].

[1]: https://aws.amazon.com/ec2/pricing/on-demand/

[2]: Samsung MZ-75E1T0BW, https://market.yandex.ru/product/11929060

Репликация

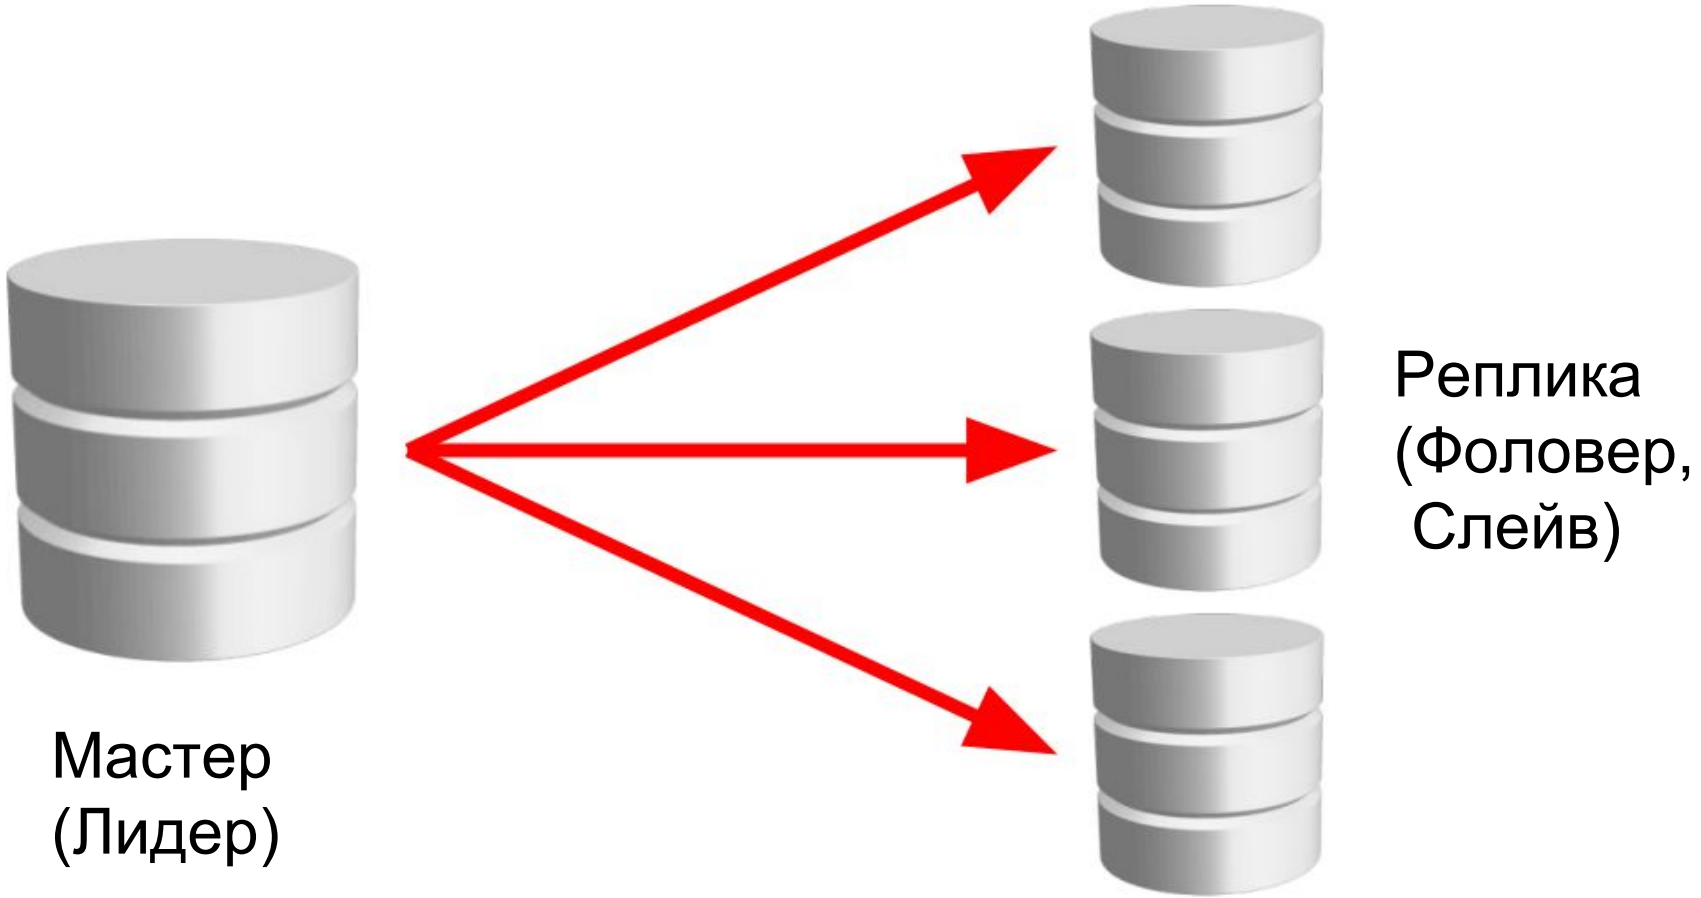

Зачем это нужно

- Распределение нагрузки
  - OLTP: на чтение ходим в реплики
  - OLAP: тяжелая аналитика на отдельной реплике
  - Снятие бэкапа с отдельной реплики
- Фейловер / High Availability
  - Бывает ручной и автоматический
- Отложенная репликация
- **Не заменяет резервное копирование!**

Потоковая (или физическая) репликация

- В сущности, заключается в передаче WAL по сети;
- Асинхронная
  - Быстро, но можно потерять данные;
- Синхронная
  - Медленнее (в рамках ДЦ не намного), но надежнее. Желательно иметь две реплики;
- Бывает еще каскадной (надо же было упомянуть об этом на каком-то слайде).

Fun facts!

Потоковая репликация:

- Не работает между разными архитектурами;
- Не работает между разными версиями PostgreSQL [1].

[1] Согласно https://simply.name/ru/upgrading-postgres-to-9.4.html типичное время даунтайма при обновлении версии составляет несколько минут.

Логическая репликация

- Начиная с PostgreSQL 10 — из коробки;
- Старые подходы: Slony, Londiste, pglogical;
  - Не рекомендуются, потому что медленные и/или плохо работают.

Зачем нужен еще один вид репликации?

- Репликация части данных, не всего подряд;
- Обновление без даунтайма;
- На реплике можно использовать временные таблицы, да и вообще писать все что угодно, в т.ч. в реплицируемые таблицы;
- Одна реплика может тянуть данные с двух мастеров;
- *В теории* — можно изобразить multimaster;
- И другие сценарии, когда физическая репликация не подошла.

Fun facts!

- Схема таблиц на мастере и на реплике может различаться;
- Может отличаться порядок столбцов;
- Реплика может иметь дополнительные nullable-столбцы;
- НО мастер не может иметь больше столбцов, чем реплика, даже если в этих столбцах всегда NULL.

Ограничения логической репликации

- Реплицируемые таблицы должны иметь primary key;
- DDL, TRUNCATE и sequences не реплицируются;
- Поддержка триггеров реализована не до конца [1].

[1]: https://postgr.es/m/20171009141341.GA16999@e733.localdomain

Logical decoding

```
$ pg_recvlogical --slot=myslot --dbname=eax --user=eax \
    --create-slot --plugin=test_decoding
$ pg_recvlogical --slot=myslot --dbname=eax --user=eax --start -f -
BEGIN 560
COMMIT 560
BEGIN 561
table public.test: INSERT: k[text]:'aaa' v[text]:'bbb'
COMMIT 561
```

Logical decoding: JSON

- Есть больше одного стороннего расширения...
- … но на сегодня все сломаны на 10-ке [1][2] :(

[1]: https://github.com/eulerto/wal2json/issues/33

[2]: https://github.com/posix4e/jsoncdc/issues/77

Фейловер

- Ручной
  - Имеет смысл, когда серверов БД не много (~10 штук);
  - Кстати, сейчас не проблема купить машину с сотнями Гб памяти и несколькими Тб места на диске;
- Автоматический
  - Может иметь смысл, когда вы приближаетесь к масштабам Google.

Решения для настройки автофейловера

- Физическая репликация
  - Своими велосипедами на Python ;)
  - Repmgr
  - Patroni
  - Stolon (нравится мне больше всего)
- Логическая репликация
  - Еще не написали :(

Stolon

Коротко о главном:

- Разрабатывается с 2015 года компанией Sorint.lab
- Написан на Go
- Полагается на Consul или etcd
- Умеет интегрироваться с Kubernetes
- Настраивается быстро и просто
- Корректно обрабатывает любые падения машин и нетсплиты

Stolon: как это работает?

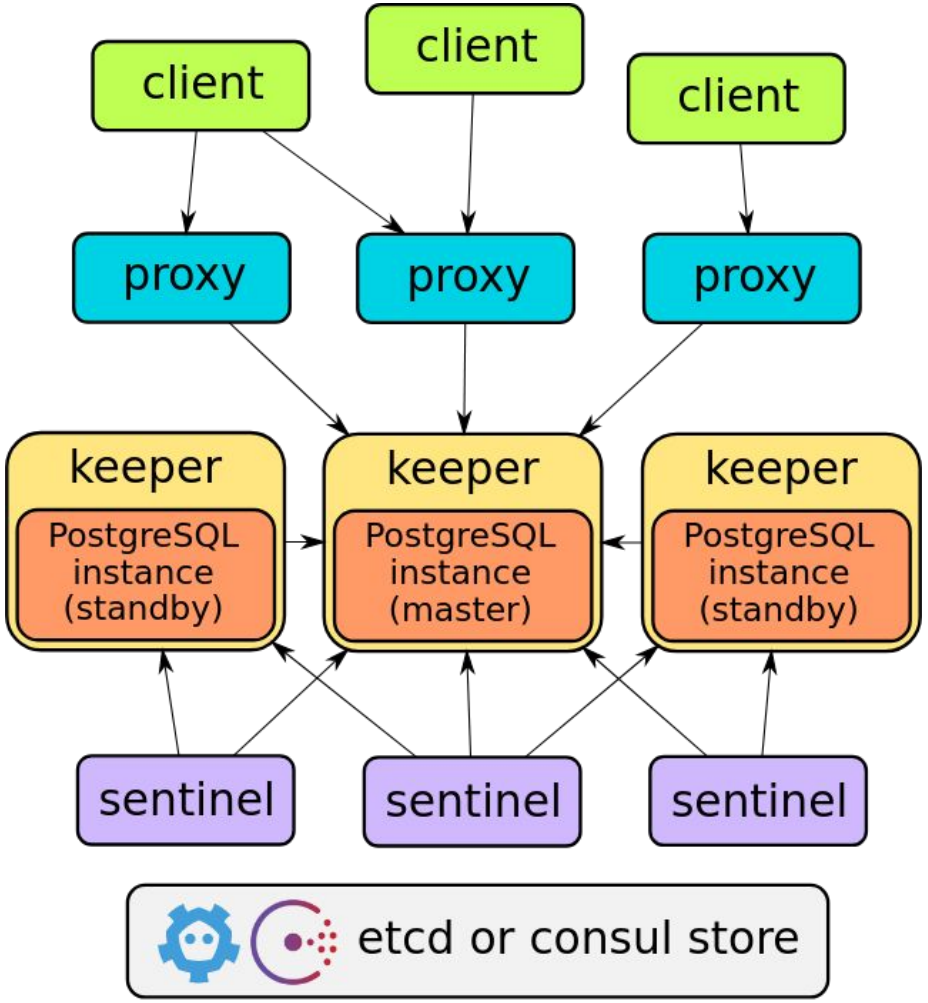

Fun facts!

- Stolon направляет и чтение, и запись в мастер. Но есть воркэраунд [1];
- Использует Consul или etcd чисто как key-value, в частности, не знает про поддержку Consul’ом DNS.

[1]: https://github.com/sorintlab/stolon/issues/132

Consul

Коротко о главном:

- Разрабатывается HashiCorp, подарившей миру Packer и Vagrant;
- Написан на языке Go, использует протокол Raft;
- Решение для service discovery, как ZooKeeper или etcd;
- Распределенное key-value хранилище с REST-интерфейсом;
- Имеет CAS, встроенный мониторинг, локи, подписки на обновления, …;
- Умеет отдавать информацию о сервисах по DNS;
- Тестируется Jepsen’ом [1].

[1]: https://www.consul.io/docs/internals/jepsen.html

Fun facts!

- У Consul есть красивый веб-интерфейс с информацией о зарегистрированных сервисах;
- Поверх него (ровно как и поверх Cassandra или Couchbase) можно довольно легко написать выбор лидера, используя подход под названием leader lease [1].

[1]: http://eax.me/go-leader-election/

synchronous_commit

- synchronous_commit = off
  - Не ждем записи в WAL, можно потерять часть последних изменений
  - В отличие от fsync = off не приведет к неконсистентности базы
- synchronous_commit = on
  - Ждем подтверждения записи в WAL — свой и синхронной реплики
- synchronous_commit = remote_write
  - Аналогично on, но не дожидаемся fsync() на реплике
- synchronous_commit = local
  - Не ждем записи на реплике, пишем только локально
- synchronous_commit = remote_apply (>= 9.6)
  - Ждем, когда данные попадут в WAL реплики *и применятся к данным*

Fun fact!

- synchronous_commit можно менять не только в postgresql.conf, но и в рамках сессии с помощью команды SET.

synchronous_standby_names

- synchronous_standby_names = ‘*’
  - Ждем подтверждения от одной любой реплики
- synchronous_standby_names = ANY 2(node1,node2,node3);
  - Коммит на кворум
  - Появилось в версии 10
- Другие варианты [1] не очень полезны.

[1]: https://www.postgresql.org/docs/current/static/runtime-config-replication.html

Что осталось за кадром

- Шардинг и решардинг
  - Реализуемы при помощи логической репликации и словаря на базе Consul;
- Распределенные транзакции
  - Percolator-like-транзакции достаточно просто реализуемы;
  - Дают snapshot isolation, возможна аномалия write skew;
  - Подойдет для большинства приложений, в частности Oracle только SI и предлагает;
  - **Важно!** Нужно использовать и при записи, и при чтении;
- Готовых решений нет, или я про них не знаю
- Если вам повезет, то никогда не придется всем этим заниматься
- Кое-какие подробности — http://eax.me/sharding/

Дополнительные материалы

- https://www.postgresql.org/docs/10/static/index.html
- https://www.consul.io/
- https://github.com/sorintlab/stolon/
- https://raft.github.io/
- https://jepsen.io/
- https://kubernetes.io/
- + есть статьи на http://eax.me/

Вопросы и ответы.

- a.alekseev@postgrespro.ru
- https://twitter.com/afiskon