




Российский опенсорс-пулер PgDoorman

Дмитрий Васильев

Эксперт по разработке информационных систем,
группа PostgreSQL DBA, Ozon



AGENDA

01

Пулер в Ozon



02

PgBouncer



02

Odyssey



04

Что было на рынке: PgCat



05

PgDoorman



06

**Получилось здорово, ХОТИМ
поделиться с сообществом**



01



Пулер в Ozon

PostgreSQL в Ozon сегодня



45K

Инстансов баз данных



10K/32K

В проде



~14 mil

Всего TPS



~10 PTV

Данных



~62K

Ядер CPU



А нужен ли вам DB-пулер?

threads/clients	TPS				
	direct connection	default_pool_size			
		14	56	112	600
56	4605,54	1498,70	1818,56	1821,72	1811,76
150	983,39	1562,12	1786,84	1783,84	806,72
300	337,87	1452,15	1791,35	1763,56	323,11
600	223,33	1535,95	1844,16	1768,83	253,99

02



PgBouncer


Задача: получить 15K tps с приемлемым p99

Мы жили с PgBouncer, пока на одном из проектов с 128 шардов не упёрлись в производительность:


- некоторые шарды отлично держали нагрузку
- некоторые резко деградировали в логах переподключения клиентов
- залить железом не получалось




PgBouncer: cancelation storm



PgBouncer: cancelation storm



PgBouncer: cancelation storm



Окей, добавляем multiple PgBouncers


Поднимаем несколько инстансов PgBouncer на одном порту: 2-4-8 штук

- Изменили $1 \times \text{pool_size} = 80 \rightarrow 8 \times \text{pool_size} = 10$
- Стресс-тесты начали проходить, но только после рестарта пулеров :)
- Заметили, что некоторые серверные бэкенды по нулям, а у некоторых PgBouncer'ов заметно меньше клиентов, чем у других (разница до 2-4 раз)




SO_REUSE распределяет R-R, а клиент отключается, когда захочет

t1



t2



PgBouncer — прощай!

К качеству исполнения и поддержки клиентов вопросов нет. Возможно, потому что это очень старый продукт: к нему все привыкли и знают все его баги.

- Долгое время практически не развивался до появления Odyssey
- Достаточно простой и имеет ограниченный функционал (v1.16)
- Однопоточный event-loop
- По ощущениям хватает до **5-10K tp/s**
- Не вывозит много TLS-соединений




Здравствуй, **Odyssey!**

Глоток свежего воздуха!

- Запросто держит **20-30K tp/s**
 - Запрос «;» — **120K tp/s**
- Переживает cancelation storm
- Базовая поддержка prepared statements




Окей, prepared_statements + pgx нам помогли



Окей, prepared_statements + pgx нам помогли



Мы достигаем целевых значений на Odyssey
после включения prepared




Окей, prepared_statements + pgx нам помогли



**Мы достигаем целевых значений на Odyssey
после включения prepared**



**Руководство довольно: теперь внедряем это на
всех**



03



Odyssey

Odyssey: проблемы при внедрении



Не работает SCRAM с dotnet Npgsql (channel binding)

- Маленький грязный патч помог



Отключаем prepared statements по дефолту, чтобы не навредить dotnet Npgsql :(




Не умеет HBA

- Достали старый патч и дотолкали в master



Odyssey: частые OOM



Odyssey: OOM

Odyssey: OOM

- ➔ После каждого OOM у клиента в пуле остаются коннекты с оборванным TCP-соединением, запись в него — 500'ка в сервисе

Odyssey: OOM

→ После каждого OOM у клиента в пуле остаются коннекты с оборванным TCP-соединением, запись в него — 500'ка в сервисе

→ Из-за LRU использования доступ к сломанному TCP-соединению происходит отложено, фон ошибок может продолжаться LifeTime/IdleTimeout


Odyssey: OOM

- После каждого OOM у клиента в пуле остаются коннекты с оборванным tcp-соединением, запись в него — 500'ка в сервисе
- Из-за LRU использования доступ к сломанному tcp-соединению происходит отложено, фон ошибок может продолжаться LifeTime/IdleTimeout
- Победили на стороне клиента — каждые N-секунд фоново пингуем открытый коннект


Odyssey: проблемы, выявленные в процессе эксплуатации

Баг очень редкий, ещё реже повторяется при TLS

t1




t2



Fixed

Odyssey: проблемы, выявленные в процессе эксплуатации

Баг очень редкий, ещё реже повторяется при TLS



Клиент асинхронно
скачивает ответы
в Read Buffer.

В итоге вся очередь ответов
в этом буфере отравлена
неправильными ответами не
на свой запрос.

Fixed

Включение TLS — воркэраунд, фоново ищем решение



Включение TLS — воркэраунд, фоново ищем решение



Учим разработчиков включать `sslmode` в приложении. Это тяжело (вкомпилено)!



Включение TLS — воркэраунд, фоново ищем решение

⚙️ Учим разработчиков включать `sslmode` в приложении. Это тяжело (вкомпилено)!

⚙️ Даём ручки для запрета подключения не по TLS




Odyssey: CPU usage при «толстом» ответе

```
time PGPORT=odyssey PGSSLMODE=require psql -Atc "select repeat( '1', 40000000)» > /dev/null  
real 0m20.812s  
time PGPORT=pgbouncer PGSSLMODE=require psql -Atc "select repeat( '1', 40000000)» > /dev/null  
real 0m0.714s
```

Fixed

Возвращаем пользователей с «ТОЛСТЫМ ОТВЕТОМ» на PgBouncer

Odyssey: обновления приносили сюрпризы



Мы поняли, что...



04




Что было на рынке:
PgCat

Реализации: PgCat




- Базовая поддержка **prepared statements**
- «Многопоточный» как Odyssey
- Поддержка шардинга
- Поддержка балансировки
- Auth passthrough
- Mirroring

PgCat внедряем?




Реализации: PgCat



Реализации: PgCat


 Для достижения уровня производительности
Odyssey базового перформанса не хватало



Реализации: PgCat

⚙ Для достижения уровня производительности Odyssey базового перформанса не хватало

⚙ Показался слишком жирным по функционалу




Реализации: PgCat

⚙ Для достижения уровня производительности Odyssey базового перформанса не хватало

⚙ Показался слишком жирным по функционалу

⚙ Ядро достаточно простое (3 файла)
• Асинхронность на Tokio




Реализации: PgCat

⚙️ Базового перформанса не хватало, чтобы достичь уровня производительности Odyssey

⚙️ Показался слишком жирным по функционалу

⚙️ Ядро достаточно простое (3 файла)
• Асинхронность на Tokio

⚙️ Хорошо покрыт тестами




05




PgDoorman

PgDoorman: что удалили из PgCat




Пиннинг тредов, настройка таймингов по умолчанию на OLTP




Если мы понимаем, что можем освободить серверный бэкенд, — освобождаем его, не дожидаясь записи в клиента

t1




t2



PgDoorman: что ещё добавили

Упор на производительность




PgDoorman: что ещё добавили

Упор на производительность



Заменяли пул bb2 на упрощенный форк deadpool

- Сделали пул не жадным (из-за connectivity check открывались все коннекты)



PgDoorman: что ещё добавили

Упор на производительность




Заменяли пул bb2 на упрощенный форк deadpool

- Сделали пул не жадным (из-за connectivity check открывались все коннекты)



Backend — LRU policy (достаётся максимально прогретый)



PgDoorman: что ещё добавили


Упор на производительность

Заменяли пул bb2 на упрощенный форк deadpool

- Сделали пул не жадным (из-за connectivity check открывались все коннекты)

Backend — LRU policy (достаётся максимально прогретый)

Добавили поддержку unix-socket (с регулировкой буферов)



PgDoorman: что ещё добавили

Упор на производительность


⚙️ **Заменяли пул bb2 на упрощенный форк deadpool**

- Сделали пул не жадным (из-за connectivity check открывались все коннекты)

⚙️ **Backend — LRU policy (достаётся максимально прогретый)**

⚙️ **Добавили поддержку unix-socket (с регулировкой буферов)**

⚙️ **Добавили несколько виртуальных пулов для уменьшения lock contention**



PgDoorman: окей, достигли перформанса Odyssey

- Тестировали на старом проекте из 128 шардов
- Общие тесты показали стабильность решения
- Позволило сэкономить много CPU-ядер на машинах
- Начальство дало добро — внедряем на всех!



PgDoorman: внедрение в Ozon происходило около года

- Это очень длинная история, заслуживающая отдельного доклада
- За это время мы сделали много улучшений, направленных на стабильность
- Добавили поддержку почти всех популярных языков

06



Получилось здорово,
хотим поделиться
с сообществом

Как мы позиционируем PgDoorman?

→ PgDoorman — это:







- Многопоточный PgBouncer
- Толерантный ко множеству драйверов: включил и работай
- Мы стремимся к тому, что у вас есть пулер и он просто работает, вы не знаете его имени :)

→ Чем PgDoorman **не является**:

- Балансировщиком нагрузки
- Инструментом для шардирования вашей базы



Почему PgDoorman?

	PgDoorman	PgBouncer	Odyssey
Высокая скорость выполнения запроса при большом кол-ве tps на один инстанс			
Эффективная работа в облаке			
Поддержка фичей драйвера NPGSQL			
Корректная работа со SCRAM			
Показатели p99	В 2 раза по сравнению с Odyssey*		

Попробуйте!



https://github.com/ozontech/pg_doorman



https://t.me/pg_doorman

На моём проекте нагрузка ниже 10K RPS.
Зачем мне PgDoorman?

На проекте с нагрузкой ниже 10K RPS можно
работать с PgBouncer, но, установив PgDoorman,
вы получите лучший 99-й процентиль

Как поставить PgDoorman?

14 строчек — минимальный пример
для запуска, несложная конфигурация



Спасибо за внимание! Вопросы?

Дмитрий Васильев

Эксперт по разработке информационных систем,
группа PostgreSQL DBA, Ozon

dmitrivasilyev@ozon.ru

