

Диагностика postgresql с точки зрения системного администратора


Николай Сивко

okmeter.io

Кто говорит

- Очень долго работал админом
- Руководил эксплуатацией в hh.ru
- Основал и работаю в okmeter.io – сервис мониторинга

Проблема



Проблема

- Для хорошего uptime нужно понимать, как работает **каждый** компонент вашей инфраструктуры
- БД обычно самый сложный компонент, непросто масштабируется, непросто добиться отказоустойчивости
- Лучше если БД управляют профессиональные DBA, но это доступно не всем проектам
- По верхам понимать, как работает БД нужно любому админу

Что хочет знать админ

- БД для остального проекта – ресурс: работает ли он штатно или есть проблемы?
- БД потребляет ресурсы сервера:
 - на что тратятся ресурсы?
 - пора добавлять или можно как-то снизить?
 - какой именно запрос просить ускорить?

Не затронем:

- Backup/restore
- Репликацию
- Оптимизацию запросов

Как сейчас работает БД

- Работа БД – выполнять запросы
- Время выполнения очень хороший показатель:
 - если уперлись в ресурсы: **время растет**
 - появились тяжелые запросы: уперлись в ресурсы -> **время растет**
 - ждем на блокировках: **время растет**
 - пропали запросы: **время падает** (запросы от мониторинга быстрые)

Время выполнения запросов

- **pg_stat_activity** – мгновенный снимок всех исполняющихся запросов

extract(epoch from (now()-xact_start)) – время в текущем состоянии (active, idle in transaction)

- **pg_stat_statements** – счетчики по **завершенным** запросам
total_time – кумулятивная сумма времен выполнения запроса
- Сниффинг сети между клиентами и pg

Смотрим по pg_stat_statements

- Время выполнения запроса обычно ~1ms, получить полную картину периодическими запросами в **pg_stat_activity** нереально


- По pg_stat_statements мы к сожалению не можем посчитать гистограмму, придется смотреть на среднее

[rate(total_time)/rate(calls)]

- Для общей картины смотрим на суммарное среднее:

[sum(rate(total_time))/sum(rate(calls))]

Среднее плохо. Но видно же аномалию?





Среднее по-прежнему плохо

- Любая аномалия (выброс/провал) на среднем **не обязательно проблема**


НО

- Скорее всего любую проблему будет видно на среднем!

Не пропали соединения?




Сколько запросов?



Как работает БД?


- Однозначно сложно сказать
- По 3-4 графикам можно понять
- **Хорошо бы** иметь гистограмму, тогда было бы проще:




Если проблема есть

- Что с ресурсами: CPU, disk, net?
- Может их съел какой-то другой процесс?
- Ресурсов стало меньше (деградация сервера)


Другой процесс?



Деградация сервера



Деградация сервера



Ресурсы изнутри postgresql

- Убедились, что потребляет сам PG
- Хотим больше конкретики: запросы/таблицы/индексы

Ресурсы: cpi

- Будем считать, что


$$\text{total_query_time} = \text{disk_wait_time} + \text{cpu_time}$$

- Это **вранье**, если
 - существенное время ожидаем блокировок – потребляем меньше CPU
 - parallel query (9.6+) – потребляем больше CPU

Ресурсы: сри


- **Не нужно** смотреть на “медленные” запросы, когда говорим про ресурсы
- Правильно смотреть на **сумму времени**

CPU: запросы



СРУ: нужно исключить блокировки

- Выбросы на `сру_time` могут быть из-за локов
- Перепроверяем по `pg_stat_activity`
- `pg_stat_activity` + `pg_locks`: можем узнать, кто залочил и кто ждет




Ресурсы: диск.чтение

- **shared_blks_read**: чтение страниц с диска в случае buffer cache miss (до диска дойдет, если будет еще page cache miss)
- **local_blks_read**: чтение данных временных таблиц
- **temp_blks_read**: чтение временных файлов (когда для запроса нужно больше памяти, чем **work_mem**)


Сложности мониторинга диска

- Процесс делает системный вызов `read()`
- Он отражается в `/proc/<pid>/io`
- Но до диска может не дойти, если прочитался из `page cache`
- С другой стороны в `/proc/<pid>/io` попадает например чтение из `stdin`



Диск: кто грузит по чтению?



Диск: кто грузит по чтению?



Диск: blks_read VS templ_blks_read



Диск: blks_read VS templ_blks_read

- Разные запросы: нужно видеть и одни и другие
- Чиним по-разному:
 - heap: добавляем памяти/меняем запрос/перекладываем данные по-другому/ускоряем дисковую подсистему
 - temp: увеличиваем work_mem/меняем запрос/переносим на аналитическую реплику



Ресурсы: диск.запись

- WAL
- Синхронизация “грязных” страниц
- Временные файлов
- Запись временных таблиц



Ресурсы: диск.запись

- Любые изменения “пачкают” страницы и записываются в WAL
- Можем ориентироваться только по dirty pages
- Запись “грязных” страниц на диск **не синхронна**
- Пишет или **backend** или **checkpointner** или **bgwriter**


Диск: dirty pages - checkpointer



Диск: checkpointer – disk traffic




WTF: SELECT пачкает страницы?




WTF: SELECT пачкает страницы?



WTF: SELECT пачкает страницы?!?!



- INSERT в транзакции txid1 -> tuple (t_xmin=txid1)
- SELECT не знает завершилась ли txid1 (committed/aborted)
 - Идем в CLOG узнавать статус txid1 (**это достаточно дорого**)
 - Если txid1 завершена, сохраняем **hint bits** в tuple (t_infomask)
 - Помечаем **страницу** как “грязную”



А ещё SELECT может
вызывать синхронную запись

SELECT может вызывать запись

- Если при чтении нам нужно прочитать страницу, которой нет в buffer cache, мы читаем ее с диска
- Если в buffer cache нет свободного места, нужно что-то вытеснить
- Если кандидат на вытеснение помечен как dirty, **мы его пишем на диск**

Ресурсы: сеть

- PG не предоставляет информацию по количеству результирующих байт по запросу
- Можно **очень примерно** посчитать по `pg_stat_statements.rows`

Итого:

- Нужно хорошо понимать, как PG работает с ресурсами сервера
- Осознавать физический смысл метрик, на которые вы смотрите
- Обязательно нужно объяснять для себя найденные аномалии, это позволит полностью разобраться с деталями реализации той или иной подсистемы

Спасибо за внимание!

Вопросы?

Николай Сивко

nsv@okmeter.io