

PGConf.Сибирь 2023



Способы решения проблем PostgreSQL путём отладки и профилирования

Михаил Жилин

План встречи

- Проблемы и что с ними делать?
- Пара слов о PostgreSQL и об OS
- Профилирование
- Примеры

- Функциональные
 - Всё сломалось
 - Ошибки в логах
 - Ошибки в ответах системы
- Первые шаги
 - Код ошибки
 - Сообщение об ошибке
 - Stack traces


Проблемы

- Нефункциональные
 - Тормоза
 - Нехватки ресурсов, частичные отказы системы
- Houston, we have problems with performance

Проблемы

- У кого-то слишком узкие двери!
- Нет! Всё потому, что кто-то слишком много ест!








Data partially collected by M. Horowitz, F. Labonte, O. Shacham, K. Olukotun, L. Hammond

Что делать?

- Сложность растёт
 - SMT → SMP → NUMA
 - ISA → PCI → PCIx
 - Железо → HyperVizor
 - Local Storage → SAN → SDS
 - VLAN/Routing → Fabrics → SDN (VNF)
 - Standalone Database → Replication → Sharding

Что делать?

- Узких дверей становится больше...



Что делать?

- Узких дверей становится больше...



Что делать?

- Узких дверей становится больше...



Что делать?

- Узких дверей становится слишком много...




Что делать?

- Метрики ресурсов
 - Utilization, Saturation, Errors (USE)
- Метрики нагрузки
 - Rate, Errors, Durations (RED)
- Смешанный вариант
 - Latency, Traffic, Errors, Saturation (LTES)


PGConf.Сибирь 2023

Что делать?



- Собственные ресурсы
 - Shared Buffers
 - WAL
 - Autovacuum
- Ресурсы OS
 - Диск
 - CPU
 - Network
 - mem

Postgres Observability



Пара слов о PostgreSQL

- **pg_stat_activity** – список сессий и их состояние
 - *state, wait_event* – блокировки / много ел / узкие двери?

Пара слов о PostgreSQL


- **pg_stat_statements** – статистика по отдельным запросам
 - *planning / execution time* – топ запросов
- **explain analyze / pgpro_stats** – получения плана запроса
 - *SQL Tuning*
 - <https://use-the-index-luke.com/>



USE THE INDEX, LUKE!
A Guide to Database Performance for Developers

PGConf.Сибирь 2023

Пара слов об OS




- top -с
 - workload и утилизация системы
- iostat -x
 - workload и утилизация диска
- mpstat, vmstat, netstat
 - workload и утилизация процессора / памяти / сети

Промежуточный итог

- Формулировку причины
 - массовый поток запрос X
 - потребляет много ресурсов Y
- Увы, нам не помог SQL Tuning и тюнинг базы и OS
- Что не хватает?
 - Профилирования!

- gdb (lldb)
 - attach подключиться к процессу
 - bt стек вызова
 - print вывод данных из памяти
- Poor man's profiler



- Инструменты
 - Execution (CPU): DTrace, perf , eBPF
 - Disk (Block devices): blktrace, ioprof, eBPF
 - Memory: Valgrind, perf, eBPF
 - Network: tcpdump, wireshark, eBPF
- Способы
 - sampling – снимки с определенной частотой
 - timing (call/exit) – замер времени

Профилирование Perf + CPU

- Sampling
- Быстрый вариант
 - `perf top`
- Шпаргалка
 - `perf record -F 99 -a -g --call-graph=dwarf sleep 2`
 - `perf script --header --fields comm,pid,tid,time,event,ip,sym,dso`
- Требуется установки debuginfo для PostgreSQL
- Требуется perf-сборку с libunwind (проблема с RHEL-based)

Профилирование Perf + CPU

- FlameGraph



Профилирование Perf + CPU

- Grafana-like - <https://pyroscope.io/>



Примеры

Пример №1: Unique vs Group By

- **select distinct X** или **select X group by X**
- Денис Смирнов (darthunix) в pgsql-hackers от 30 августа 2023:
 - Обсуждение
<https://www.postgresql.org/message-id/flat/3EC-4930-A4EE-F06DC1F12C96%40gmail.com>
 - Патч
<https://commitfest.postgresql.org/44/4531/>



Пример №1: Unique vs Group By

-- создаём таблицу из 1 числовой колонки

```
create table t(a int, primary key(a));
```



Пример №1: Unique vs Group By

```
create table t(a int, primary key(a));
```

-- вставляем несколько миллионов случайных чисел

```
insert into t select random() * 5000000
```

```
from generate_series(1, 5000000)
```

```
on conflict do nothing;
```



Пример №1: Unique vs Group By

-- Unique

```
explain analyze select distinct a from t;  
latency average = 737.680 ms
```

```
pgbench -n -c 1 -j 1 -T 60 -P 1  
-f unique.sql
```



Пример №1: Unique vs Group By

-- Unique

```
explain analyze select distinct a from t;
```

latency average = 737.680 ms


-- Group By

```
explain analyze select a from t group by a
```


latency average = 633.737 ms




Пример №1: Group By




Пример №1: Group By



Пример №1: Unique



Пример №1: Unique



Пример №1: Unique vs Group By

- Патч от Дениса Смирнова

```
diff --git a/src/backend/executor/nodeUnique.c b/src/backend/executor/nodeUnique.c
index 45035d74fa..c859add6e0 100644
--- a/src/backend/executor/nodeUnique.c
+++ b/src/backend/executor/nodeUnique.c
@@ -141,7 +141,7 @@ ExecInitUnique(Unique *node, EState *estate, int eflags)
     * Initialize result slot and type. Unique nodes do no projections, so
     * initialize projection info for this node appropriately.
     */
-    ExecInitResultTupleSlotTL(&uniquestate->ps, &TTSOpsMinimalTuple);
+    ExecInitResultTupleSlotTL(&uniquestate->ps, &TTSOpsVirtual);
     uniquestate->ps.projInfo = NULL;
```



Пример №2: SysCache

```
load average: 71.76, 72.36, 72.54
0 stopped, 0 zombie
0.1 wa, 0.0 hi, 0.9 si, 0.0 st
304 used, 10989072+buff/cache
308 used. 49603376 avail Mem
```

%CPU	%MEM	TIME+	COMMAND
70.0	1.1	0:00.38	postgres:(21047) BIND
65.0	0.5	0:00.14	postgres:(21449) BIND
60.0	0.9	0:00.19	postgres:(21391) BIND
60.0	0.5	0:00.12	postgres:(21459) idle
60.0	0.5	0:00.12	postgres:(21461) idle
55.0	0.5	0:00.13	postgres:(21421) BIND
55.0	0.5	0:00.14	postgres:(21431) BIND

- BIND – это обработка сетевого пакета со связанными переменными запроса, включая **иногда планирование**

Пример №2: SysCache



- В кэше КАТАЛОГА что-то не нашлось...
- Но оно там наверняка было секунду назад...
- Куда же оно делось...

Пример №2: SysCache

- Инвалидация кэша
 - DDL- и utility-команды
 - on-commit рассылает **всем** процессам в виде сообщений
- Отключение кэша
 - `debug_discard_caches` (DEVELOPER GUC)
- Мониторить инвалидации с помощью `pgpro_stats`:
 - <https://postgrespro.ru/docs/postgrespro/13/pgpro-stats#PGPRO-STATS-INVAL-MSG>

Пример №3: Commit

-- создаём 1000 временных таблиц каждая по 1000 строк

Пример №3: Commit

-- создаём 1000 временных таблиц каждая по 1000 строк

```
create temp table t_tab_%s  
    on commit delete rows
```

```
as  
    select id::bigint, repeat('x', 1023)  
    from generate_series(1,1000) id;
```

...

Пример №3: Commit

```
postgres=# begin;
```

```
Time: 0.230 ms
```

```
postgres=# select 1 from t_tab_100;
```

```
Time: 0.317 ms
```

```
postgres=# commit;
```

```
Time: 180.267 ms
```

Пример №3: Commit

```
postgres=# begin;
```

```
Time: 0.230 ms
```

```
postgres=# select 1 from t_tab_100;
```

```
Time: 0.317 ms
```

```
postgres=# commit;
```

```
Time: 180.267 ms
```

Диск не тормозит, commit потребляет CPU

[illegible]

```
TRUNCATE TABLE T_TAB_001
TRUNCATE TABLE T_TAB_002
TRUNCATE TABLE T_TAB_003...
```

TRUNCATE TABLE T_TAB_001 TRUNCATE TABLE T_TAB_002 TRUNCATE TABLE T_TAB_003...										
try ..	xas ..									
com.. r..	dele..									
pat.. ext..	tru..									
do f.. ex.	tru..	Rec..								
do .. ext4	setattr	Loc..								
x.. notify	cha..	rela..								
do .. do truncate		inde..								
entr.. do sys	ftr..	syst..								
fmtint li..	do syscall..	Rela..								
dopr Bas..	entry SYS..	Allo..	Rela..							
pg .. Pat..	ftruncate	RelationC..	Allo..							
pvs.. md..	FileTruncate	LocalExec..	Me..							
pspr.. mdn..	mdtruncate	ProcessInv..	Allo..							
md.. mdt..	smgrtrunc..	Command..	btbu..							
mde.. smg..	RelationTr..	index_build								
RelationTr..	RelationTruncateIndexes									
heap_truncate one_rel										
heap_truncate										
PreCommit on commit actions										
CommitTransaction										
CommitTransactionCommand										

Пример №3: Commit

on commit delete rows

```
precommit:
for (i = 0; i < 1000; i++) {
    truncate table t_tab_%i
}
commit transaction;
```

Пример №3: Commit

```
postgres=# begin;
```

```
Time: 0.230 ms
```

```
postgres=# select 1 from t_tab_100;
```

```
Time: 0.317 ms
```

```
postgres=# commit;
```

```
Time: 180.267 ms
```

Выводы / советы

- Сначала посмотрите на метрики, найдите проблему в них
- Не надо профилировать CPU, если тормозит дисковая система и наоборот
- Анализируйте! Метрики, flamegraph-ы – лишь инструменты анализа
- Обогащайте свои знания чтением документации и иногда исходного кода

PGConf.Сибирь 2023

PosgresPro

Спасибо!