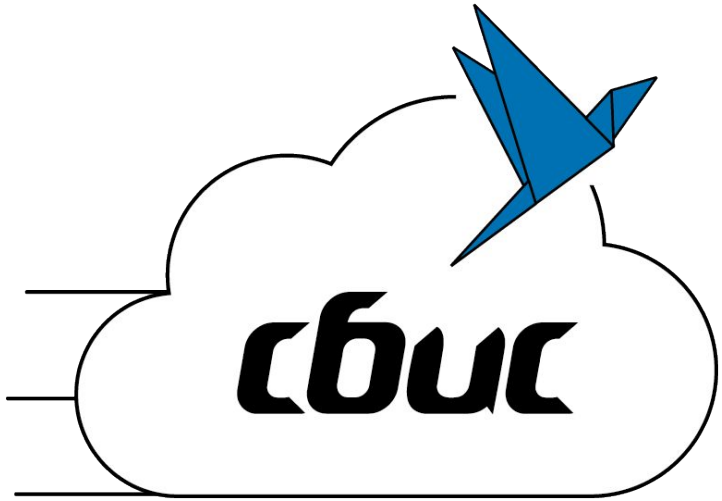

Массовая оптимизация запросов PostgreSQL – explain.sbis.ru

Кирилл Боровиков / Технический директор

«Тензор» – это СБИС

миллион клиентов

- 100+ проектов
- 10 центров разработки
- более 1000 сотрудников в них

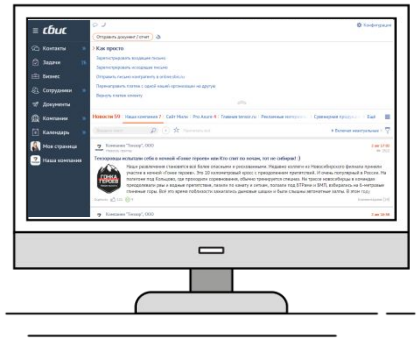

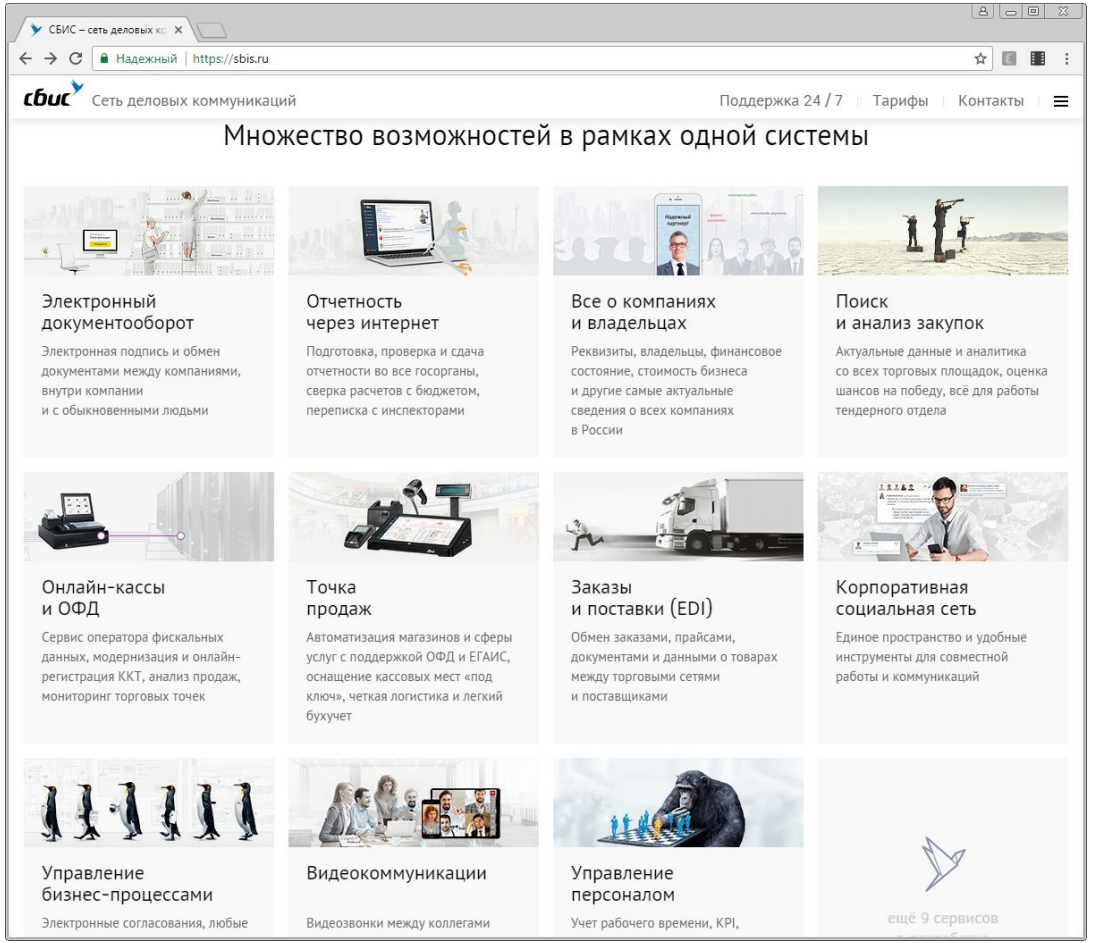

СБИС – data-centric application

Активно используем PostgreSQL

- ~400TB «рабочих» данных
- «в продакшене» с 2008 года
- уже более 250 серверов

СБИС – data-centric application

SQL – декларативный язык

- вы описываете, что хотите получить
- СУБД лучше «знает», как это сделать:

  какие индексы использовать, в каком порядке соединять таблицы, как накладывать условия...

СБИС – data-centric application

SQL – декларативный язык

- некоторые СУБД принимают «подсказки»
- PostgreSQL – нет, но...

  всегда готов рассказать, как конкретно он выполняет ваш запрос

СБИС – data-centric application

Классика: «А почему у нас тут выполнялось долго?»

- алгоритмически неэффективный запрос/план
- неактуальная статистика
- «затык» по ресурсам (процессор, диск, память)
- блокировки – для DML-запросов

СБИС – data-centric application

Классика: «А почему у нас тут выполнялось долго?»

- алгоритмически неэффективный запрос/план
- неактуальная статистика
- «затык» по ресурсам (процессор, диск, память)

«Нам нужен план!»

Получение плана

Получение плана

План запроса – дерево в текстовом представлении

- каждый элемент – одна из выполняемых операций

получение данных, построение битовых карт, обработка данных, операция над множествами, соединение, вложенный запрос

- выполнение плана – обход дерева

Получение плана

EXPLAIN (ANALYZE, BUFFERS) SELECT ...

- https://postgrespro.ru/docs/postgrespro/9.6/using-explain
- подходит только для локальной отладки

Получение плана

Модуль auto_explain

- https://postgrespro.ru/docs/postgresql/9.6/auto-explain
- анализирует все запросы ~~подряд~~ дольше XXXms
- фиксирует для них планы выполнения
- пишет все это в лог сервера

Получение плана

Модуль auto_explain

```
2017-09-05 17:06:25.638 MSK [57829:113/3890139] [profiles] 10.76.101.19(58818) sbis3mon : sbis3mon-ppc1.unix.tensor.ru [14899] LOG:  duration: 11.007 ms  plan:
        Query Text: SELECT
              extract(epoch FROM now())::integer ts
            , sum(CASE WHEN relkind IN ('r', 't', 'm') THEN pg_stat_get_numscans(oid) END) seq
            , sum(CASE WHEN relkind IN ('r', 't', 'm') THEN pg_stat_get_tuples_returned(oid) END) seq_tup_read
            , sum(CASE WHEN relkind IN ('r', 't', 'm') THEN pg_stat_get_tuples_hot_updated(oid) END) hot
            , sum(CASE WHEN relkind IN ('r', 't', 'm') THEN pg_stat_get_live_tuples(oid) END) live
            , sum(CASE WHEN relkind IN ('r', 't', 'm') THEN pg_stat_get_dead_tuples(oid) END) dead
            , sum(CASE WHEN relkind = 'i' THEN pg_stat_get_numscans(oid) END) idx
            , sum(CASE WHEN relkind = 'i' THEN pg_stat_get_tuples_fetched(oid) END) idx_tup_fetch
        FROM
            pg_class
        WHERE
            relkind IN ('r', 't', 'm', 'i');

        Aggregate  (cost=58.77..58.79 rows=1 width=228) (actual time=10.998..10.998 rows=1 loops=1)
          Buffers: shared hit=24
          ->  Seq Scan on pg_class  (cost=0.00..32.73 rows=443 width=5) (actual time=0.009..0.217 rows=443 loops=1)
                Filter: (relkind = ANY ('{r,t,m,i}'::"char"[]))
                Rows Removed by Filter: 139
                Buffers: shared hit=24
```

Получение плана

Модуль auto_explain

```
2017-09-05 17:06:25.638 MSK [57829:113/3890139] [profiles] 10.76.101.19(58818) sbis3mon : sbis3mon-ppc1.unix.tensor.ru [14899] LOG:  duration: 11.007 ms  plan:
        Query Text: SELECT
              extract(epoch FROM now())::integer ts
            , sum(CASE WHEN relkind IN ('r', 't', 'm') THEN pg_stat_get_numscans(oid) END) seq
            , sum(CASE WHEN relkind IN ('r', 't', 'm') THEN pg_stat_get_tuples_returned(oid) END) seq_tup_read
            , sum(CASE WHEN relkind IN ('r', 't', 'm') THEN pg_stat_get_tuples_hot_updated(oid) END) hot
            , sum(CASE WHEN relkind IN ('r', 't', 'm') THEN pg_stat_get_live_tuples(oid) END) live
            , sum(CASE WHEN relkind IN ('r', 't', 'm') THEN pg_stat_get_dead_tuples(oid) END) dead
            , sum(CASE WHEN relkind = 'i' THEN pg_stat_get_numscans(oid) END) idx
            , sum(CASE WHEN relkind = 'i' THEN pg_stat_get_tuples_fetched(oid) END) idx_tup_fetch
        FROM
            pg_class
        WHERE
            relkind IN ('r', 't', 'm', 'i');

        Aggregate  (cost=58.77..58.79 rows=1 width=228) (actual time=10.998..10.998 rows=1 loops=1)
          Buffers: shared hit=24
          ->  Seq Scan on pg_class  (cost=0.00..32.73 rows=443 width=5) (actual time=0.009..0.217 rows=443 loops=1)
                Filter: (relkind = ANY ('{r,t,m,i}'::"char"[]))
                Rows Removed by Filter: 139
                Buffers: shared hit=24
```

Получение плана

Логи и план текстом – ненаглядно:

- узел содержит сумму по ресурсам поддерева
- время необходимо умножать на loops
- ... так кто же «самое слабое звено»?

Получение плана

Логи и план текстом – ненаглядно:

- узел содержит сумму по ресурсам поддерева
- время необходимо умножать на loops
- ... так кто же «самое слабое звено»?

«Понимание плана – это искусство, и чтобы овладеть им, нужен определённый опыт...»

Получение плана

Логи и план текстом – ненаглядно:

- узел содержит сумму по ресурсам поддерева
- время необходимо умножать на loops
- ... так кто же «самое слабое звено»?

Нужна хорошая визуализация!

Визуализация плана

Визуализация плана

explain.depesz.com

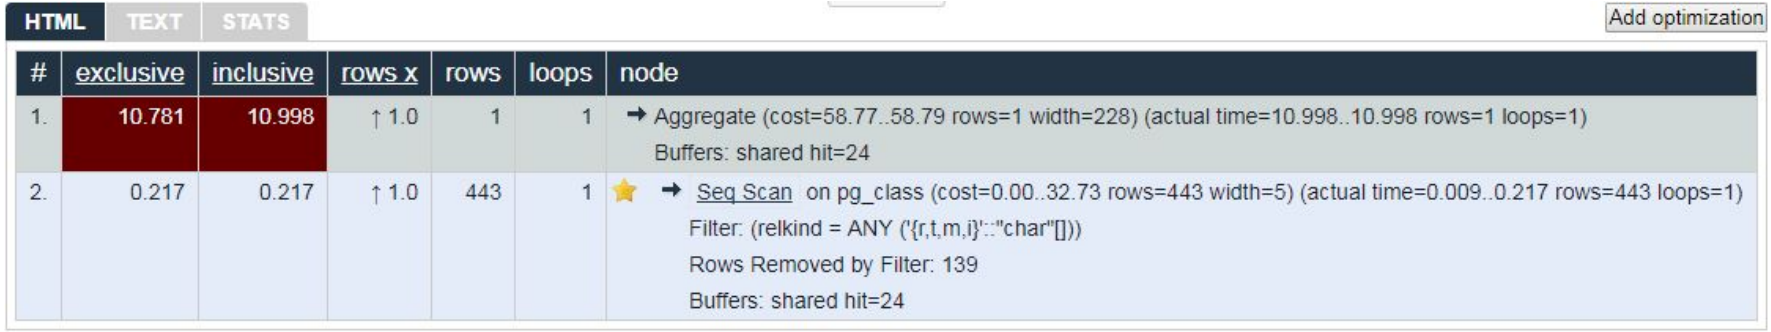

#	exclusive	inclusive	rows x	rows	loops	node
1.	10.781	10.998	↑ 1.0	1	1	→ Aggregate (cost=58.77..58.79 rows=1 width=228) (actual time=10.998..10.998 rows=1 loops=1) Buffers: shared hit=24
2.	0.217	0.217	↑ 1.0	443	1	→ Seq Scan on pg_class (cost=0.00..32.73 rows=443 width=5) (actual time=0.009..0.217 rows=443 loops=1) Filter: (relkind = ANY ('{r,t,m,i}'::"char"[])) Rows Removed by Filter: 139 Buffers: shared hit=24

Визуализация плана

explain.depesz.com – pro

- «собственное» время каждого узла
- отклонение от статистически-плановых rows
- количество повторов каждого узла
- архив планов (можно обмениваться ссылками)

Визуализация плана

explain.depesz.com – contra

- требует copy&paste планов из лога
- нет анализа ресурсов (buffers)
- код на Perl, нет развития
- ошибки анализа CTE/InitPlan :(

Визуализация плана

explain.depesz.com – ошибки анализа CTE Scan

HTML | TEXT | STATS

Add optimization

#	exclusive	inclusive	rows x	rows	loops	node
1.	6.406	? 6.406	↓ 1.0	12,213	1	→ CTE Scan on cl (cost=485.67..725.01 rows=11,967 width=197) (actual time=0.006..6.406 rows=12,213 loops=1) Buffers: shared hit=366
2.						CTE cl
3.	1.389	1.389	↓ 1.0	12,213	1	→ Seq Scan on pg_class (cost=0.00..485.67 rows=11,967 width=219) (actual time=0.004..1.389 rows=12,213 loops=1) Buffers: shared hit=366

Визуализация плана

explain.sbis.ru

- ура! мы пишем свое!
- Node.JS + Express + Twitter Bootstrap + D3.js
- прототип за 2 недели

Визуализация плана

explain.sbis.ru

- собственный парсер плана
- корректный анализ CTE Scan
- анализ распределения ресурсов (buffers)
- наглядность, подсветка синтаксиса

Визуализация плана

explain.sbis.ru – полный план

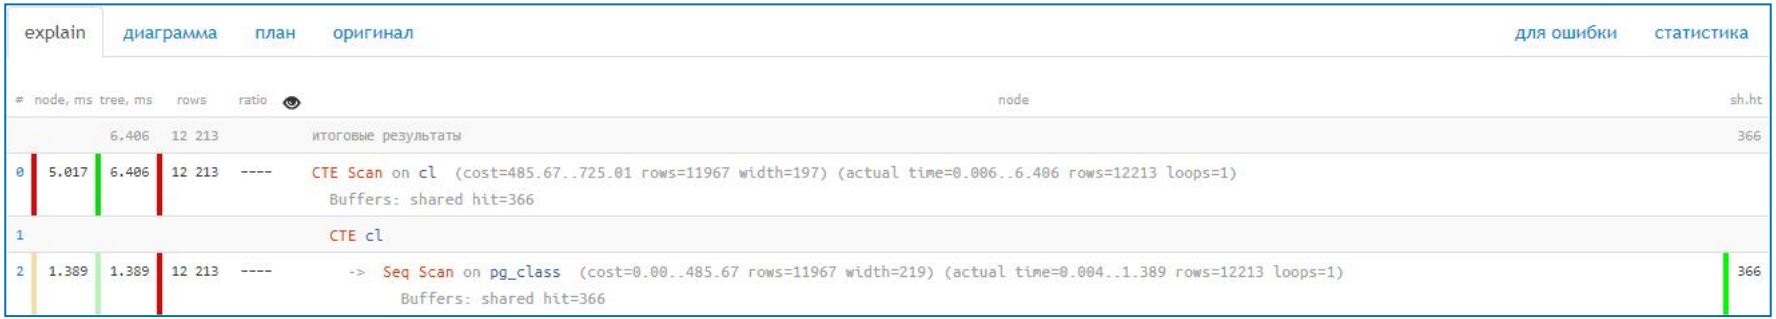

Визуализация плана

explain.sbis.ru – сокращенный план (шаблон)

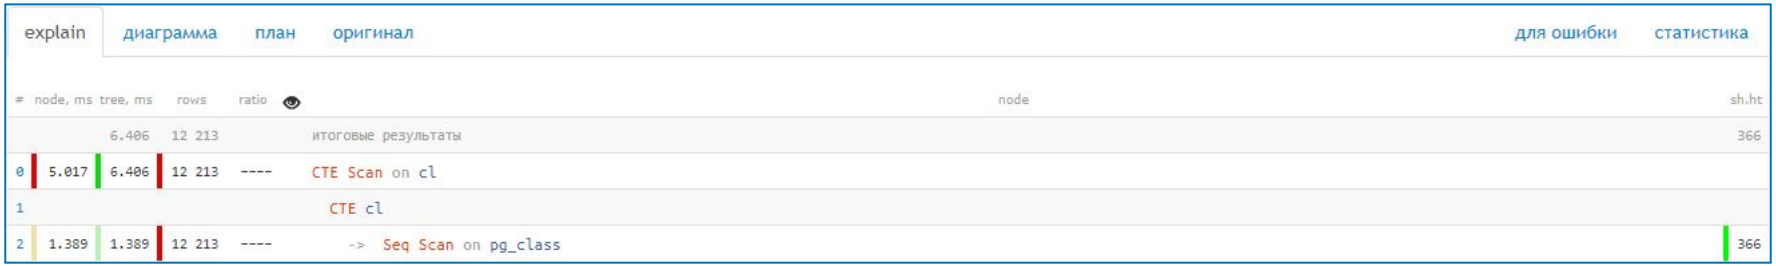

Визуализация плана

explain.sbis.ru – распределение затрат времени

Визуализация плана

explain.sbis.ru – распределение затрат времени

explain | диаграмма | план

#	node, ms	tree, ms	rows	ratio	RRbF	node
		651.914	1 000		3 723 969	итоговые результаты
0	0.086	651.914	1 000	----		Limit
1	0.691	651.828	1 000	1.7↑		-> Sort
2	46.168	651.137	1 945	1.2↓		-> Hash Join
3	188.476	223.124	324 690	----		-> Bitmap Heap Scan on "Пользователь" cli
4	34.648	34.648	325 094	----		-> Bitmap Index Scan on "iPolzovatel-VneshniyIdentifikator"
5	13.238	381.845	56 945	2.7↓		-> Hash
6	368.607	368.607	56 945	2.7↓	3 723 969	-> Seq Scan on "ПользовательРасширение" cli_ext

#6 **368.607**ms (56.5%), rows=56945, loops=1
Buffers узла (35050): shared hit=35050
Seq Scan on "ПользовательРасширение" cli_ext (cost=0.00..110649.52 rows=21125 width=20) (actual time=2.132..368.607 rows=56945 loops=1)
Filter: (("РазмерДанныхФакт" > '536870912'::bigint) AND ((now() - "ВремяОценкиРазмераДанных") < '1 mon'::interval))
Rows Removed by Filter: 3723969
Buffers: shared hit=35050

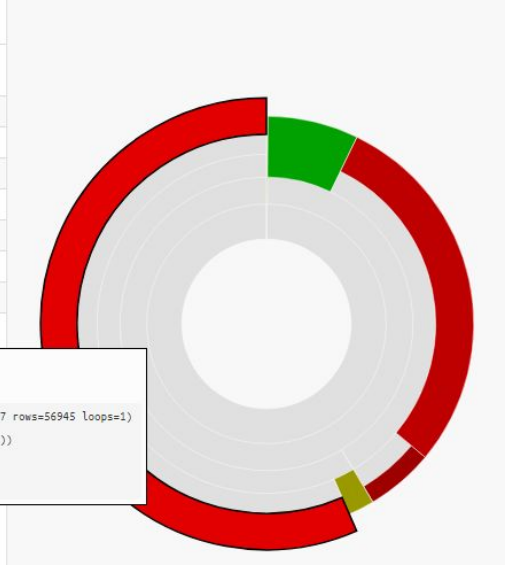

Визуализация плана

explain.sbis.ru – «грабли»

- проблемы округления

  0.001ms × (loops=1000) = 0.95ms .. 1.05ms

- распределение ресурсов CTE/InitPlan/SubPlan

  +4 недели отладки :(

Визуализация плана

explain.sbis.ru – «грабли»

```
WITH cl AS (
 TABLE pg_class
)
(TABLE cl LIMIT 1)
 UNION ALL
(TABLE cl LIMIT 1 OFFSET 100);
```

Визуализация плана

explain.sbis.ru – «грабли»

Визуализация плана

explain.sbis.ru – дерево выполнения

Визуализация плана

explain.sbis.ru – дерево выполнения

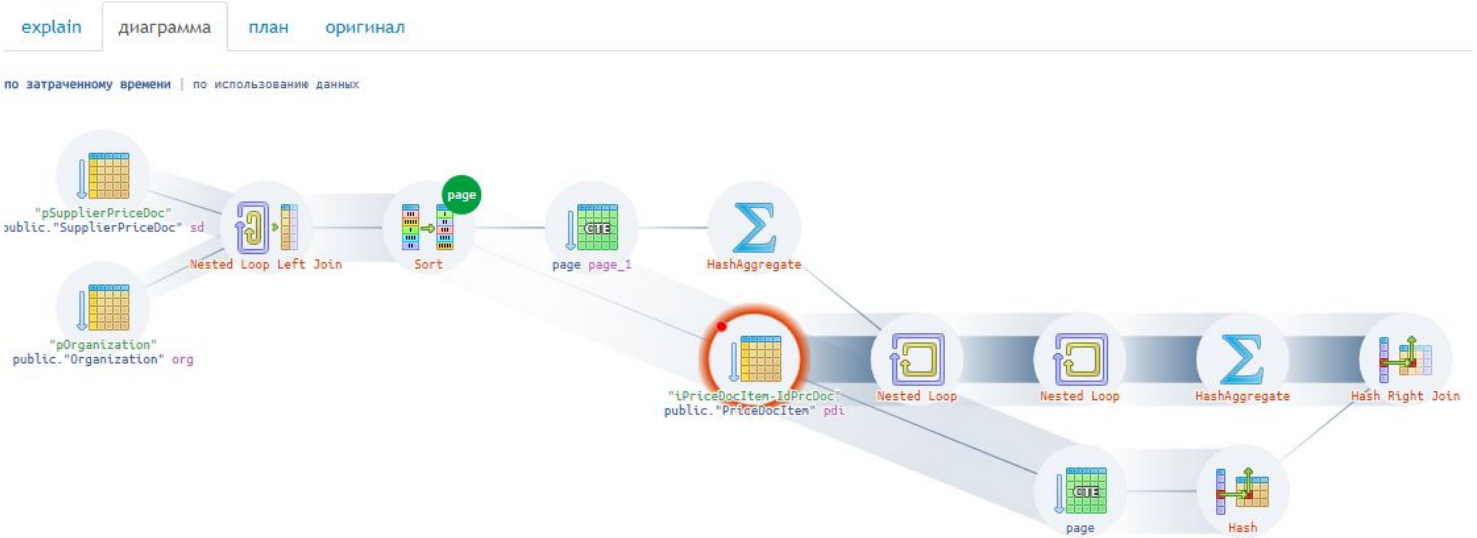

Визуализация плана

explain.sbis.ru – дерево выполнения

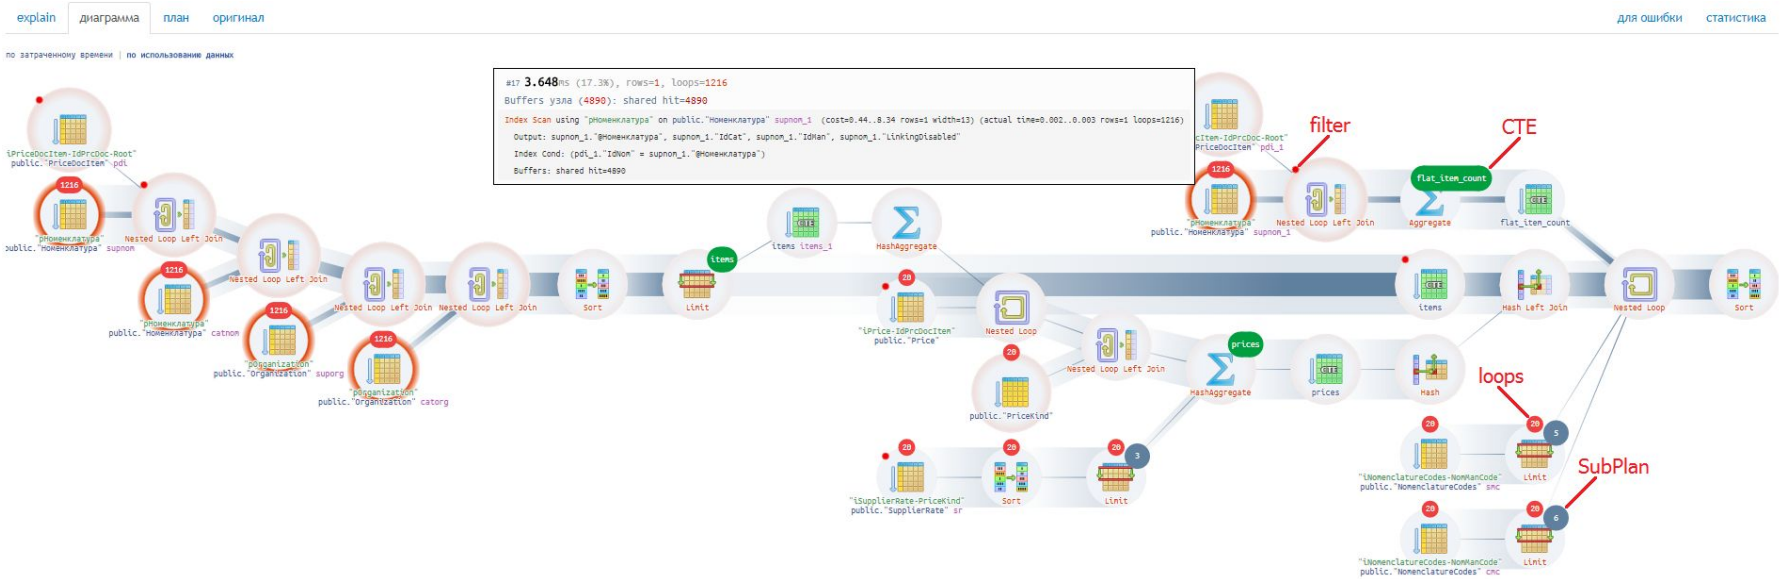

Визуализация плана

explain.sbis.ru

- «Теперь, Нео, ты знаешь кунг-фу»

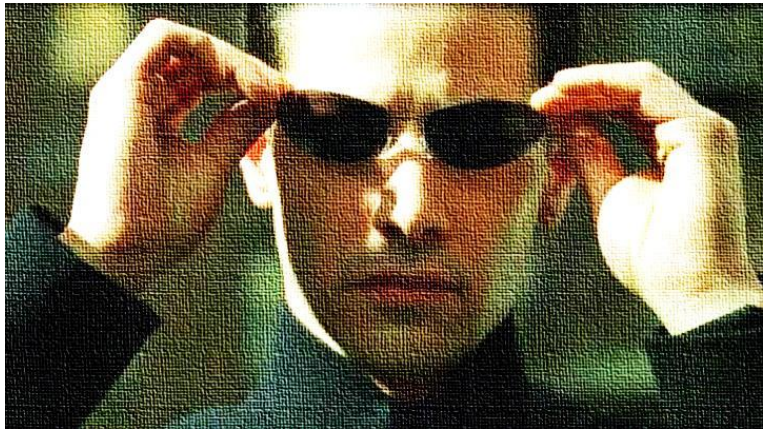

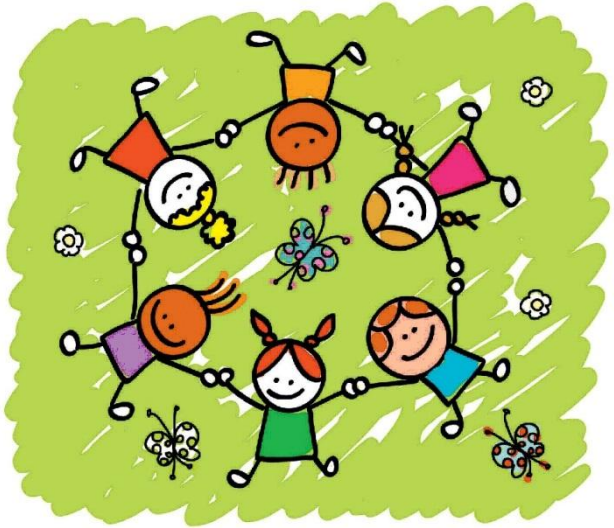

Консолидация логов

Консолидация логов

«Копипаста» – плохо

- 100+ серверов
- 1000+ разработчиков

Консолидация логов

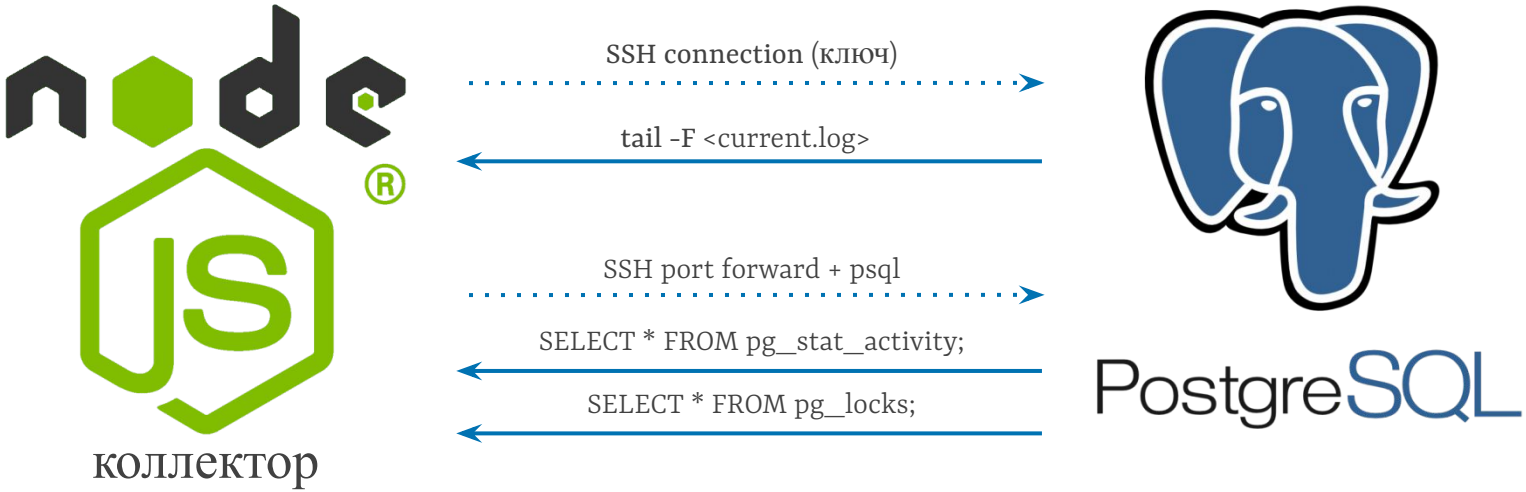

Консолидация логов

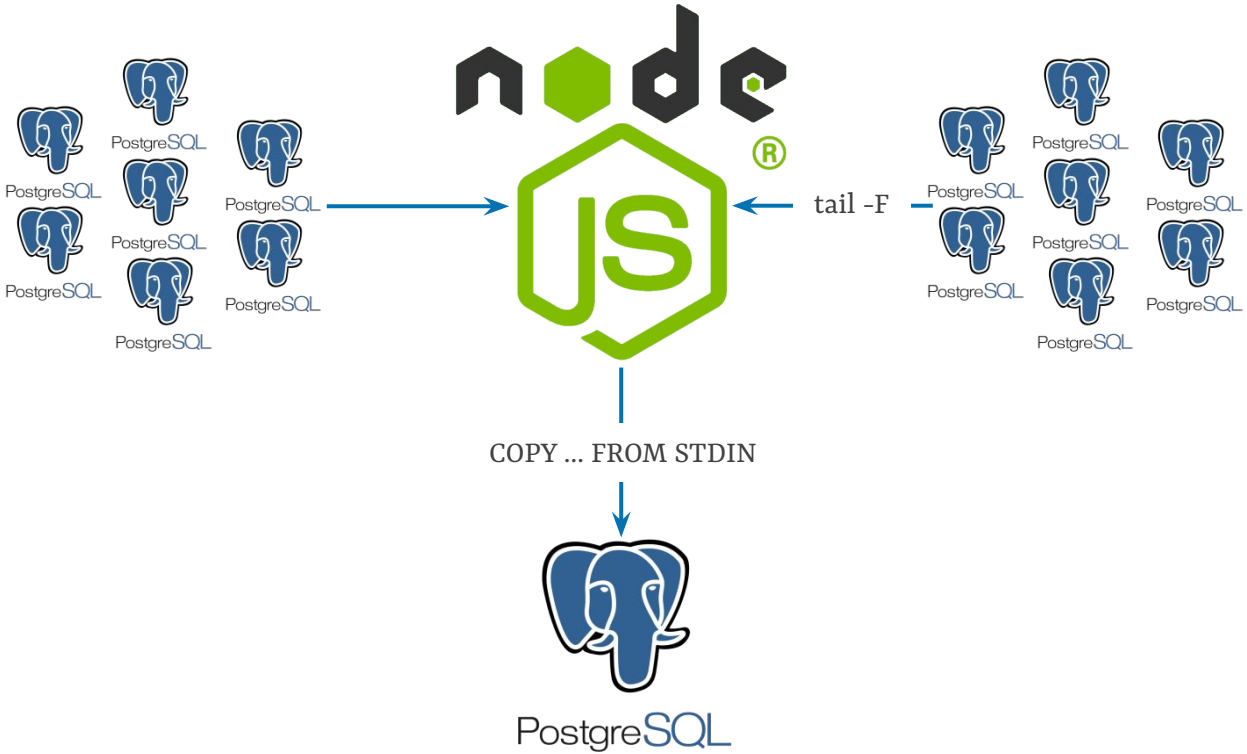

Консолидация логов

100+ серверов, 50Kqps, 100-150GB/день

- секционирование по дням (ждем 10.0!)
- очень-очень быстрый «потоковый» COPY
- отказались от триггеров (почти)

Консолидация логов

Отказались от триггеров

- нет ссылочной целостности (нет FK и их проверки)
- агрегация и хэширование на стороне коллектора
- каждая таблица наполняется «своим» потоком

Консолидация логов

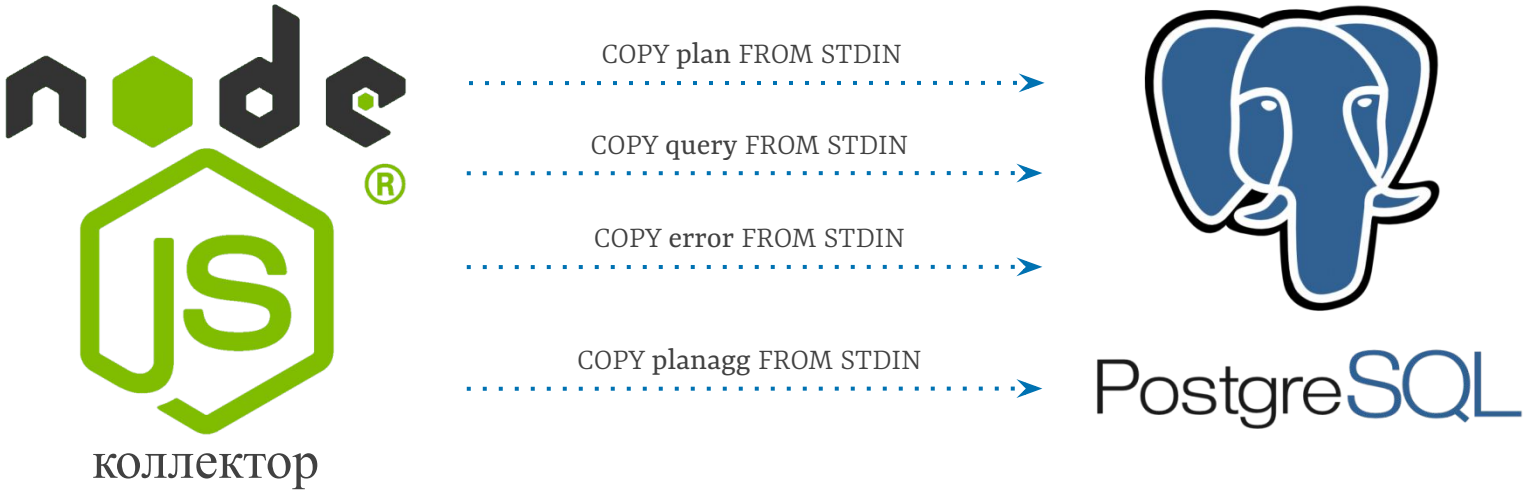

Консолидация логов

«Потоковый» COPY

- всегда открыт COPY-канал/пул на таблицу
- «переоткрывается» раз в XXXms для закрытия TX
- отправляем запись в канал сразу при получении

никакой дополнительной буферизации, да-да

Консолидация логов

«Потоковый» COPY

- таблицы-словари

  триггер BEFORE INSERT

  9.5+: INSERT … ON CONFLICT DO NOTHING

Консолидация логов

«Потоковый» COPY

- тогда: 4K write ops -> 1K write ops (в 4 раза!)
- сейчас: 6K write ops ~100MB/s, 10TB/3мес

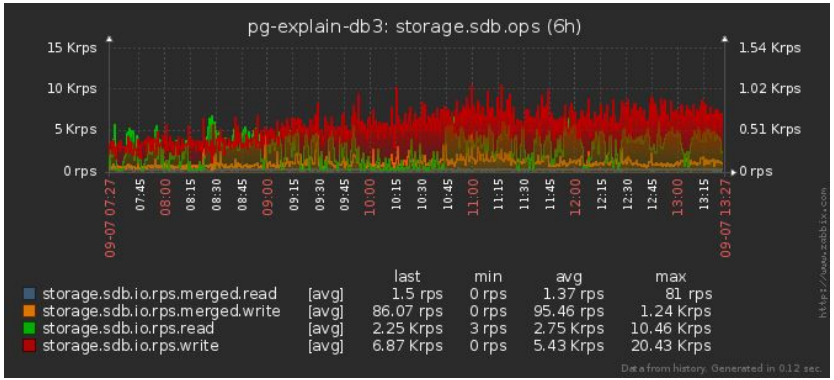

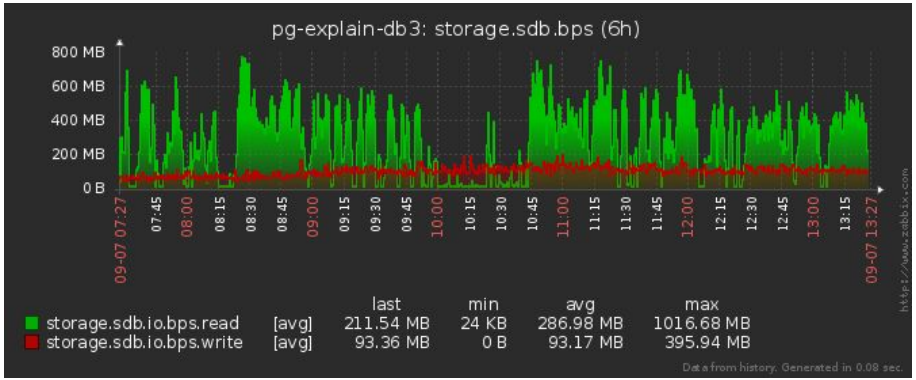

Понимаем проблемы

Понимаем проблемы

100+ серверов, 50Kqps, 100-150GB/день

- миллионы планов за сутки

Понимаем проблемы

100+ серверов, 50Kqps, 100-150GB/день

- миллионы планов за сутки

Понимаем проблемы

100+ серверов, 50Kqps, 100-150GB/день

- миллионы планов за сутки

Понимаем проблемы

100+ серверов, 50Kqps, 100-150GB/день

- кто? откуда этот запрос
- где? что за сервер, база
- как? в чем проблема в плане

Понимаем проблемы

«Хозяин» у каждого запроса

- SET application_name = '<*BL.host*>:<*BL.method*>'
- страдаем от ограничения в 63 байта (тип name)

Понимаем проблемы

«Хозяин» у каждого запроса

- log_line_prefix = ' %m [%p:%v] [%d] %r %a'
- https://postgrespro.ru/docs/postgrespro/9.6/runtime-config-logging

```
2017-09-05 17:06:25.638 MSK [57829:113/3890139] [profiles] 10.76.101.19(58818) sbis3mon : sbis3mon-ppc1.unix.tensor.ru [14899] LOG:
```

Понимаем проблемы

«Хозяин» у каждого запроса

Понимаем проблемы

Модель анализа

- экземпляр PostgreSQL (хост:порт), день
- шаблон, приложение/метод, узел плана

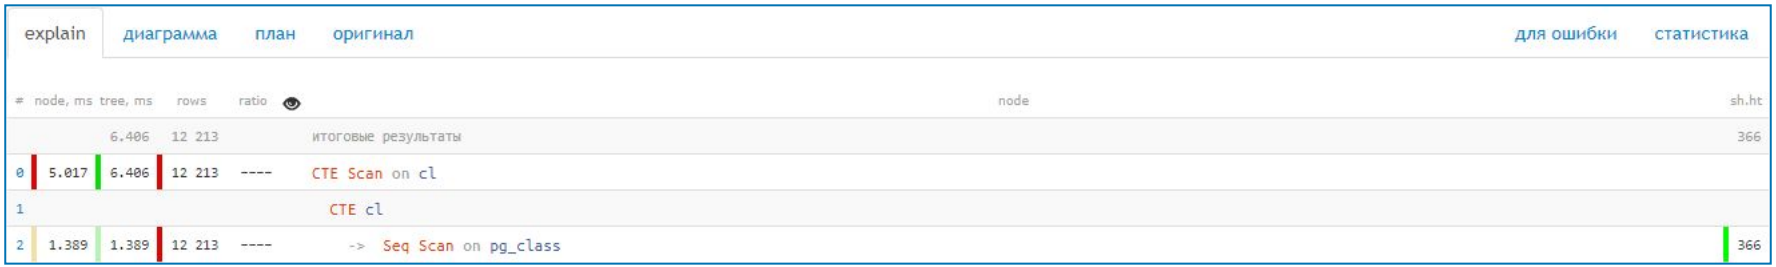

Понимаем проблемы

От планов – к шаблонам

- уменьшение количества анализируемых объектов
- вычленение общих паттернов поведения

	всего	шаблонов	Timeline
csr-history2-db1.unix.tensor.ru	1121	80	
csr-history3-db1.unix.tensor.ru	1889	131	

Понимаем проблемы

Разрезы анализа планов

- количество фактов по шаблону/методу
- суммарное и среднее время
- количество ресурсов (buffers hit/read)
- таймлайны

Понимаем проблемы

по шаблонам | по приложениям | по узлам плана | по длительности

Шаблон / метод(ы)	app	Кол-во	sum, мс	avg, мс	buf:mem	buf:dsk	%	last	Timeline
c8e7ef0c-397a-99b0-0844-7639196a061b	History.List	523	1 394 521.292	2 666.389	5 010 459	316 849	5.9	14:52:41	
75967c0e-e00c-561f-fd91-a077f8b4b83c	History.HandleHistory	196	272 312.940	1 389.352	42 677	47	0.1	14:05:40	

```
Update on "ИсторияЭкземпляраОбъекта" instance
  ->  Nested Loop
        ->  Subquery Scan on instance_update
              ->  LockRows
                    InitPlan 1 (returns $0)
                      ->  Limit
                            ->  Index Scan using "iИсторияОбъект-Объект" on "ИсторияОбъект"
                    ->  Sort
                          ->  Index Scan using "iIstoriyaEkzemplyarObekta-Ekzemplyar" on "ИсторияЭкземпляраОбъекта"
        ->  Index Scan using "pИсторияЭкземпляраОбъекта" on "ИсторияЭкземпляраОбъекта" instance
```

b160f01b-e4e1-7068-8780-262cf8986c4d	History.List	37	61 223.497	1 654.689	205 552	12 447	5.7	12:56:40	
a5910953-6a31-e236-bd0a-ba772d18f8b1	History.HandleHistory	43	53 989.315	1 255.565	5 545	175	3.1	13:53:49	

```
CTE Scan on next_event
  CTE next_event
    ->  Result
  CTE object_id_insert
    ->  Insert on "ИсторияОбъект" "ИсторияОбъект_1"
          ->  Subquery Scan on "*SELECT*"
                ->  Result
                      InitPlan 2 (returns $1)
                        ->  Index Only Scan using "iИсторияОбъект-Объект" on "ИсторияОбъект"
  CTE object_id_select
    ->  Limit
          ->  Index Scan using "iИсторияОбъект-Объект" on "ИсторияОбъект" "ИсторияОбъект_2"
  CTE object
    ->  Hash Full Join
```

Понимаем проблемы

по шаблонам | по приложениям | по узлам плана | по длительности

Метод / шаблон(ы)	ptr	Кол-во	sum, мс	avg, мс	buf:mem	buf:dsk	%	last	Timeline
History.List	75	878	2 067 254.483	2 354.504	7 803 874	423 873	5.2	14:52:41	
History.HandleHistory	4	242	331 096.412	1 368.167	48 654	255	0.5	14:05:40	
75967c0e-e00c-561f-fd91-a077f8b4b83c		196	272 312.940	1 389.352	42 677	47	0.1	14:05:40	
a5910953-6a31-e236-bd0a-ba772d18f8b1		43	53 989.315	1 255.565	5 545	175	3.1	13:53:49	
e8c26590-ad32-517c-3d58-4c165e4ef6d7		2	2 588.827	1 294.414	270	12	4.3	09:33:22	
3c1b7e84-63cd-b651-848e-17a6be43de7d			2 205.330	2 205.330	162	21	11.5	09:02:04	
5c168372-4fdf-6c25-2439-b9bce59758fc			1 251.113	1 251.113	128	38	22.9	17:12:01	
fd3fda54-8870-220a-21f1-68bbdfe11358			1 227.091	1 227.091	17	33	66.0	17:12:01	
History.HistoryCommonM	5274c013-bcc2-ed6e-68b1-2187sc6f55dd	2	2 075.775	1 037.888	73	6	7.6	08:54:26	

Понимаем проблемы

Разрезы анализа узлов

- Seq Scan, Index [Only] Scan, Bitmap (Index|Heap) Scan
- количество фактов/шаблонов по узлу
- loops, rows, RRbF (суммарно и в среднем)

Понимаем проблемы

по шаблонам | по приложениям | по узлам плана | по длительности

Тип узла	таблица	индекс		ptr	кол-во	loops	loops, avg	rows	rows, avg	RRbF	RRbF, avg	last	Timeline
Index Scan	ИсторияЭкземплярОбъекта	iИсторияЭкземплярОбъекта-ObjectChanges	72baee62-bf95-eeb3-23ff-2e4fd39a2982		11	11	1	965 844	87 804			12:26:32	
Index Scan	КонтекстИсполнения	iКонтекстИсполнения-id		57	830	21 180	25	21 174				14:52:41	
Bitmap Heap Scan	ИсторияДействие			64	809	21 131	26	21 131	1			14:52:41	
Bitmap Index Scan	ИсторияДействие	рИсторияДействие		64	809	21 131	26	21 131	1			14:52:41	
Index Only Scan	ИсторияЭкземплярОбъекта	iИсторияЭкземплярОбъекта-InstanceInfo		49	780	21 018	26	21 018	1			14:52:41	
Index Scan	ИсторияЭкземплярОбъекта	iIstoriyaEkzemplyarObekta-Ekzemplyar		49	1 055	66 531	63	8 401				14:52:41	
Seq Scan	ИсторияОбъект			12	26	26	1	7 029	270	3 505	134	14:17:44	
Index Scan	ИсторияОбъект	iИсторияОбъект-Объект		60	1 037	1 037	1	1 037	1			14:52:41	
Index Scan	ИсторияСобытие.$2017-09-08	iИсторияСобытие.$2017-09-08-last_changed		8	18	27	1	761	28			14:41:43	
a0142691-aea6-ef2d-5af2-72ac0710cdb0					7	7	1	2 291	327			17:07:05	
49719919-4b95-f044-b801-490e7cd2c2c5					3	3	1	82	27			15:54:02	
2e49565b-233f-1fd6-4638-e6aafa87980f					4	8	2	6				15:22:04	

... и устраняем причины

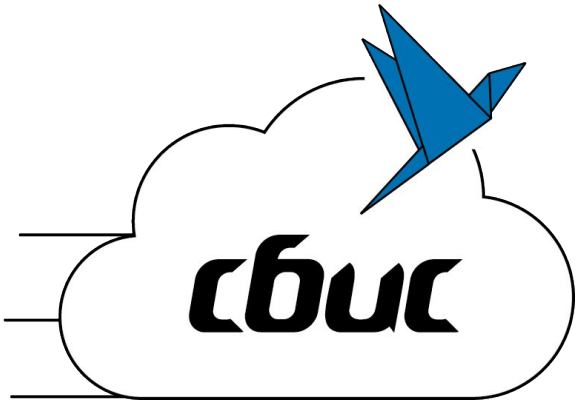

Спасибо за внимание!

Боровиков Кирилл

тел.: (4852) 262-000 вн. 2500, e-mail: kilor@tensor.ru

sbis.ru