



Опять говорим о партицировании

Дмитрий Иванов, Postgres Professional
Максим Милютин, Wildberries

Участники состязания


- Inheritance (check constraints)
- PostgreSQL 10
- PostgreSQL 11 **NEW!**
- TimescaleDB **NEW!**
- pg_pathman

На что будем смотреть


- Способы партицирования
- Работа с большим числом партиций
- API для управления партициями
- Доступные оптимизации запросов
- *Как решать возникающие проблемы*

Глава 1. Введение

Inheritance



Inheritance



TimescaleDB

my_table

my_table_1

CHECK (TIME), CHECK(HASH)

my_table_2

CHECK (...), CHECK (...)

my_table_3

CHECK (...), CHECK (...)

my_table_4

CHECK (...), CHECK (...)


my_table_5

CHECK (...), CHECK (...)


my_table_6

CHECK (...), CHECK (...)

PG 10




PG 11




pg_pathman

- HASH и RANGE секционирование
- Оптимизации планирования и исполнения
- PartitionFilter вместо триггеров (быстрый INSERT)
- Автоматическое создание секций при вставке
- Неблокирующее секционирование
- Поддержка FDW-партиций



0 100



200

300

400

500

600

700

partition: P1
min: 0
max: 100

Partition dispatch cache

0, 100

Partition bounds cache

- Не все prepared statements одинаково полезны
- Нет пула соединений? Good luck with that!
- FOR EACH ROW триггеры не наследуются от родителя
- Не работают primary keys (кроме ключа секционирования)
- Не работает INSERT ON CONFLICT (в vanilla тоже)

```
explain
select * from partitioned join dummy
using (id);
```

...

Planning time: **15.527 ms**

Execution time: 0.136 ms

...

Planning time: **4.194 ms**

Execution time: 0.145 ms

...

Planning time: **5.450 ms**

Execution time: 0.198 ms

TimescaleDB

- Собственный каталог для управления партициями
- Секционирование по timestamp по умолчанию
- Опциональное HASH-секционирование по другому полю
- Партиции создаются лениво (вместе с новыми данными)
- Свежие партиции и их индексы **попадают в кеш**
- Дополнительные функции для аналитики

PostgreSQL

- Декларативный синтаксис
- RANGE и LIST секционирование
- HASH секционирование **NEW!**
- Родительская таблица не хранится на диске
- INSERT и COPY кладут строки сразу в партиции
- Для “неудобных” данных существует DEFAULT-партиция **NEW!**
- Множество интересных оптимизаций **NEW!**

```
create table test (id int, value float8)  
partition by range (id, value);
```



```
create table test (id int, value float8)  
partition by range (id, value);
```

```
create table test_1 partition of test  
for values from (1, 0) to (10, 0);
```

```
create table test_2 partition of test  
for values from (10, 0) to (20, 0);
```

```
create table test (id int, value float8)  
partition by range (id, value);
```

```
create table test_1 partition of test  
for values from (1, 0) to (10, 0);
```

```
create table test_2 partition of test  
for values from (10, 0) to (20, 0);
```

```
create table test_3 (like test);  
alter table test attach partition test_3  
for values from (20, 0) to (30, 0);
```

\d+ test

...

Partition key: RANGE (id, value)

Partitions: test_1 FOR VALUES FROM (1, 0) TO (10, 0),
test_2 FOR VALUES FROM (10, 0) TO (20, 0),
test_3 FOR VALUES FROM (20, 0) TO (30, 0)

```
alter table test detach partition test_2;  
alter table test detach partition test_3;
```

```
insert into test_2 select * from test_3;  
drop table test_3;
```

```
alter table test attach partition test_2  
for values from (10, 0) to (30, 0);
```

```
\d+ test
```

```
...
```

```
Partition key: RANGE (id)
```

```
Partitions: test_1 FOR VALUES FROM (1, 0) TO (10, 0),  
            test_2 FOR VALUES FROM (10, 0) TO (30, 0)
```

```
insert into test values(100, 0);
```

ERROR: no partition of relation "test" found for row

```
create index on test (value);
```

ERROR: cannot create index on partitioned table "test"

```
insert into test values (1, 0) on conflict (id)
```

```
do update set value=1;
```

ERROR: ON CONFLICT clause is not supported with partitioned tables

```
update test set id=15 where id = 1;
```

ERROR: new row for relation "test_1" violates partition constraint

Новшества 11 версии

- Гибкое HASH-секционирование
- Партиция по умолчанию (default partition)
- Local partitioned indexes
- Оптимизации запросов
 - Sorted append
 - Parallel append **DONE!**
 - Partition-wise JOIN **DONE!**
 - Partition-wise aggregates
 - Faster partition pruning

```
create table foo (i int) partition by hash (i);
```

```
create table foo_1 partition of foo for values with (modulus 2, remainder 0);
```

```
create table foo_2 partition of foo for values with (modulus 2, remainder 1);
```

```
alter table foo detach partition foo_1;
```

```
create table foo_1_1 partition of foo for values with (modulus 6, remainder 0);
```

```
create table foo_1_2 partition of foo for values with (modulus 6, remainder 2);
```

```
create table foo_1_3 partition of foo for values with (modulus 6, remainder 4);
```

Затем распределяем данные из foo_1 между foo_1_{1,2,3}

Кроме того, огромную HASH-партицию можно разбить уже по другому критерию (multilevel)

Глава 2,
в которой случилось **много** партиций


```
explain (costs off, analyze, timing off) select * from foo where i = 1;
```

```
QUERY PLAN
```

```
-----
```

```
Append (actual rows=0 loops=1)
```

```
-> Seq Scan on foo (actual rows=0 loops=1)
```

```
Filter: (i = 1)
```

```
-> Seq Scan on foo_1 (actual rows=0 loops=1)
```


```
Filter: (i = 1)
```

```
Planning time: 48.881 ms
```


```
Execution time: 0.173 ms
```

```
(7 rows)
```

На минуточку, 10K партиций в таблице foo



Function: relation_excluded_by_constraints (7,193 samples, 49.00%)



```
select avg(i) from foo;  
(partition-wise aggregates)
```

Finalize Aggregate

-> Append

-> **Partial Aggregate**

-> Foreign Scan on public.f_foo_2018_01

Remote SQL: SELECT i FROM public.foo_2018_01

-> **Partial Aggregate**

-> Foreign Scan on public.f_foo_2018_02

Remote SQL: SELECT i FROM public.foo_2018_02

-> **Partial Aggregate**

-> Foreign Scan on public.f_foo_2018_03

Remote SQL: SELECT i FROM public.foo_2018_03

```
select * from foo where i = 100;  
      (parallel append)
```

Gather (actual rows=1022 loops=1)

Workers Planned: 2

Workers Launched: 2

-> **Parallel Append** (actual rows=341 loops=3)

Worker 0: actual rows=312 loops=1

Worker 1: actual rows=340 loops=1

-> Seq Scan on public.foo_1 (actual rows=340 loops=1)

Worker 1: actual rows=340 loops=1

Filter: (foo_2.j = 10)

-> Seq Scan on public.foo_2 (actual rows=174 loops=2)

Worker 0: actual rows=312 loops=1

Filter: (foo_2.j = 10)

-> Seq Scan on public.foo_3 (actual rows=334 loops=1)

Filter: (foo_3.j = 10)

```
select * from foo f join bar b using (i);  
      (partition-wise join)
```


Append

-> Hash Join

Hash Cond: (f.i = r.i)

-> Seq Scan on **foo_1** f

-> Hash

-> Seq Scan on **bar_1** r

-> Hash Join

Hash Cond: (r_1.i = f_1.i)

-> Seq Scan on **bar_2** r_1

-> Hash

-> Seq Scan on **foo_2** f_1

```
select i from foo order by t desc limit 10;  
      (sorted append)
```

Limit (actual rows=10 loops=1)

-> Append (actual rows=10 loops=1)


Sort Key: foo_2018_3.t **DESC**


-> Seq Scan on foo_2018_3 (actual rows=10 loops=1)

-> Seq Scan on foo_2018_2 (**never executed**)

-> Seq Scan on foo_2018_1 (**never executed**)

Latency of two partitions pruning





Глава 3, бонусная

<https://github.com/funbringer/YCSB>

- 72 физических ядра
- 500 партиций
- 3 млн строк по 1кбайт
- партиционирование по строке
- select, update, delete по ключу


```
shared_preload_libraries    = 'pg_pathman'  
dynamic_shared_memory_type = mmap
```

```
maintenance_work_mem      = 512MB  
shared_buffers             = 32GB  
max_locks_per_transaction = 512  
Bgwriter_flush_after      = 2MB  
max_wal_size              = 16GB
```

```
synchronous_commit = off
```


```
deadlock_timeout    = 60s
```


inserts a




50% reads
50% writes

workload a




95% reads
5% writes

workload b




100% reads

workload c




INSERT
SELECT most popular

workload d



SELECT small range

workload e



READ
MODIFY
WRITE

workload f

