



Шардирование больших баз данных

Забелин Андрей
a.zabelin@postgrespro.ru

27.05.2025

Shardman

Распределенная СУБД Postgres Pro Enterprise 17

- Postgres Pro Enterprise
- Расширение Shardman
- Расширение postgres_fdw
- Расширение BiHA

Shardmanctl – утилита управление


Etcdd – хранение состояния и конфигурации

BiHA – отказоустойчивость

Shardman: преимущества

- Прозрачное горизонтальное масштабирование
- OLTP нагрузка
- Доступ в кластер через любой узел
- Избыточность данных:
встроенная отказоустойчивость
- Целостность данных:
распределенные транзакции, строгие гарантии ACID

Shardman: распределённая БД




Каждый узел содержит только часть данных таблиц

Таблица состоит из набора секций, которые находятся физически на разных узлах кластера

Секции с других узлов доступны через fdw

Число секций фиксируется при создании таблицы

Shardman: масштабируемость БД




При добавлении узла
часть партиций
переезжает


Каждый узел отвечает за
обработку меньшего
количества данных

Производительность
линейно увеличивается

Архитектура Shardman



Масштабирование Shardman



Shardman: виды таблиц

- **Шардированная таблица** — это секционированная таблица, где часть секций являются обычными локальными секциями таблицы, а остальные — внешними секциями таблицы через fdw.
 - Количество секций определяется при создании шардированной таблицы, оно должно быть больше или равно планируемого количества узлов в распределенной СУБД. Количество секций нельзя изменить.
- **Несколько шардированных таблиц** могут быть размещены **совместно**.
 - Секции совмещённых таблиц, соответствующие одному и тому же ключу шардирования, находятся на одном узле. Совместное размещение необходимо для того, чтобы операция соединения нескольких таблиц (JOIN) выполнялись на узле, где находятся фактические данные.
- **Глобальные таблицы** дублируются на все узлы и используются для редко обновляемых данных
 - Например наиболее подходящими для этого являются таблицы справочники. Когда выполняется соединение шардированной таблицы с глобальной таблицей, оно выполняется на узле, где находятся данные. При изменении данных в глобальной таблице, изменения данных одновременно происходят на всех узлах кластера.

Shardman: схемы данных

Исходная схема данных:




Схема данных для Shardman:

```
CREATE TABLE booking
    (booking_id bigint NOT NULL, ... )
    with (distributed_by = 'booking_id');
alter table booking add constraint booking_pkey
    primary key (booking_id);
```

```
CREATE TABLE passenger
    (passenger_id integer NOT NULL,
     booking_id bigint NOT NULL, ...)
    with (distributed_by = 'booking_id',
          colocate_with = 'booking');
alter table passenger add constraint passenger_pkey
    primary key (passenger_id, booking_id);
```

```
CREATE TABLE boarding_pass
    (pass_id integer NOT NULL,
     booking_id bigint NOT NULL, ...)
    with (distributed_by = 'booking_id',
          colocate_with = 'booking');
alter table boarding_pass add constraint boarding_pass_pkey
    primary key (pass_id, booking_id);
```

Shardman: запрос с ключом шардирования

```
postgres=# explain(analyse)
SELECT *
FROM booking b
join passenger p on p.booking_id = b.booking_id
join boarding_pass bp on bp.passenger_id = p.passenger_id and bp.booking_id = p.booking_id
where b.booking_id = 1111;
```

QUERY PLAN

```
-----
Foreign Scan  (cost=0.99..1.00 rows=1 width=185) (actual time=3.854..3.855 rows=12 loops=1)
  Relations: ((booking_3_fdw b) INNER JOIN (passenger_3_fdw p)) INNER JOIN (boarding_pass_3_fdw bp)
  Foreign EXPLAIN:
    Nested Loop  (cost=1.29..270.02 rows=1 width=185)
      -> Nested Loop  (cost=0.86..261.56 rows=1 width=99)
        -> Index Scan using passenger_3_booking_id_idx on passenger_3 r7  (cost=0.43..35.81 rows=11 width=51)
            Index Cond: (booking_id = 1111)
        -> Index Scan using boarding_pass_3_passenger_id_idx on boarding_pass_3 r8  (cost=0.43..20.51 rows=1 width=48)
            Index Cond: (passenger_id = r7.passenger_id)
            Filter: (booking_id = 1111)
      -> Index Scan using booking_3_pkey on booking_3 r6  (cost=0.43..8.45 rows=1 width=86)
          Index Cond: (booking_id = 1111)
Planning Time: 0.600 ms
Execution Time: 3.887 ms
(14 rows)
```

Shardman: запрос с ключом шардирования

```
postgres=# explain(analyse)
SELECT *
FROM booking b
join passenger p on p.booking_id = b.booking_id
join boarding_pass bp on bp.passenger_id = p.passenger_id and bp.booking_id = p.booking_id
where b.booking_id = 1111;
```

Ключ шардирования

QUERY PLAN

```
Foreign Scan (cost=0.99..1.00 rows=1 width=185) (actual time=3.854..3.855 rows=12 loops=1)
  Relations: ((booking_3_fdw b) INNER JOIN (passenger_3_fdw p)) INNER JOIN (boarding_pass_3_fdw bp)
  Foreign EXPLAIN:
    Nested Loop (cost=1.29..270.02 rows=1 width=185)
      -> Nested Loop (cost=0.86..261.56 rows=1 width=99)
        -> Index Scan using passenger_3_booking_id_idx on passenger_3 r7 (cost=0.43..35.81 rows=11 width=51)
          Index Cond: (booking_id = 1111)
        -> Index Scan using boarding_pass_3_passenger_id_idx on boarding_pass_3 r8 (cost=0.43..20.51 rows=1 width=48)
          Index Cond: (passenger_id = r7.passenger_id)
          Filter: (booking_id = 1111)
      -> Index Scan using booking_3_pkey on booking_3 r6 (cost=0.43..8.45 rows=1 width=86)
        Index Cond: (booking_id = 1111)
Planning Time: 0.600 ms
Execution Time: 3.887 ms
(14 rows)
```

Shardman: запрос с ключом шардирования

```
postgres=# explain(analyse)
SELECT *
FROM booking b
join passenger p on p.booking_id = b.booking_id
join boarding_pass bp on bp.passenger_id = p.passenger_id and bp.booking_id = p.booking_id
where b.booking_id = 1111;
```

Ключ шардирования

QUERY PLAN

Foreign Scan (cost=0.99..1.00 rows=1 width=185) (actual time=3.854..3.855 rows=12 loops=1)

Relations: ((booking_3_fdw b) INNER JOIN (passenger_3_fdw p)) INNER JOIN (boarding_pass_3_fdw bp)

Foreign EXPLAIN:

Nested Loop (cost=1.29..270.02 rows=1 width=185)

-> Nested Loop (cost=0.86..261.56 rows=1 width=99)

 -> Index Scan using passenger_3_booking_id_idx on passenger_3 r7 (cost=0.43..35.81 rows=11 width=51)

 Index Cond: (booking_id = 1111)

 -> Index Scan using boarding_pass_3_passenger_id_idx on boarding_pass_3 r8 (cost=0.43..20.51 rows=1 width=48)

 Index Cond: (passenger_id = r7.passenger_id)

 Filter: (booking_id = 1111)

-> Index Scan using booking_3_pkey on booking_3 r6 (cost=0.43..8.45 rows=1 width=86)

 Index Cond: (booking_id = 1111)

Planning Time: 0.600 ms

Execution Time: 3.887 ms

(14 rows)

Выполнение JOIN
на другом шарде

Shardman: запрос с ключом шардирования

```
postgres=# explain(analyse)
SELECT *
FROM booking b
join passenger p on p.booking_id = b.booking_id
join boarding_pass bp on bp.passenger_id = p.passenger_id and bp.booking_id = p.booking_id
where b.booking_id = 1114;
```

Ключ шардирования

QUERY PLAN

```
-----
Nested Loop  (cost=1.29..292.87 rows=1 width=185) (actual time=1.183..3.233 rows=12 loops=1)
  -> Nested Loop  (cost=0.86..284.42 rows=1 width=99) (actual time=1.169..3.178 rows=12 loops=1)
    -> Index Scan using passenger_0_booking_id_idx on passenger_0 p  (cost=0.43..38.15 rows=12 width=51) (actual time=0.704..0.805 rows=3 loops=1)
        Index Cond: (booking_id = 1114)
    -> Index Scan using boarding_pass_0_passenger_id_idx on boarding_pass_0 bp  (cost=0.43..20.51 rows=1 width=48) (actual time=0.328..0.788 rows=4 loops=3)
        Index Cond: (passenger_id = p.passenger_id)
        Filter: (booking_id = 1114)
  -> Index Scan using booking_0_pkey on booking_0 b  (cost=0.43..8.45 rows=1 width=86) (actual time=0.003..0.004 rows=1 loops=12)
      Index Cond: (booking_id = 1114)
Planning Time: 0.441 ms
Execution Time: 3.262 ms
(11 rows)
```

Shardman: запрос с ключом шардирования

```
postgres=# explain(analyse)
SELECT *
FROM booking b
join passenger p on p.booking_id = b.booking_id
join boarding_pass bp on bp.passenger_id = p.passenger_id and bp.booking_id = p.booking_id
where b.booking_id = 1114;
```

Ключ шардирования

QUERY PLAN

```
-----
Nested Loop (cost=1.29..292.87 rows=1 width=185) (actual time=1.183..3.233 rows=12 loops=1)
  -> Nested Loop (cost=0.86..284.42 rows=1 width=99) (actual time=1.169..3.178 rows=12 loops=1)
    -> Index Scan using passenger_0_booking_id_idx on passenger_0 p (cost=0.43..38.15 rows=12 width=51) (actual time=0.704..0.805 rows=3 loops=1)
        Index Cond: (booking_id = 1114)
    -> Index Scan using boarding_pass_0_passenger_id_idx on boarding_pass_0 bp (cost=0.43..20.51 rows=1 width=48) (actual time=0.328..0.788 rows=4 loops=3)
        Index Cond: (passenger_id = p.passenger_id)
        Filter: (booking_id = 1114)
  -> Index Scan using booking_0_pkey on booking_0 b (cost=0.43..8.45 rows=1 width=86) (actual time=0.003..0.004 rows=1 loops=12)
      Index Cond: (booking_id = 1114)
```

Planning Time: 0.441 ms

Execution Time: 3.262 ms

(11 rows)

Выполнение на
локальном шарде

Shardman: запрос с ключом шардирования

```
postgres=# explain(analyse)
```

```
SELECT *  
FROM booking b  
join passenger p on p.booking_id = b.booking_id  
join boarding_pass bp on bp.passenger_id = p.passenger_id  
where b.booking_id = 1114;
```

```
QUERY PLAN
```

```
-----  
Nested Loop (cost=1.29..4821.72 rows=1815972 width=185) (actual time=1.821..3.743 rows=12 loops=1)  
  -> Nested Loop (cost=0.86..46.71 rows=12 width=137) (actual time=1.225..1.418 rows=3 loops=1)  
    -> Index Scan using booking_0_pkey on booking_0 b (cost=0.43..8.45 rows=1 width=86) (actual time=0.728..0.729 rows=1 loops=1)  
        Index Cond: (booking_id = 1114)  
    -> Index Scan using passenger_0_booking_id_idx on passenger_0 p (cost=0.43..38.15 rows=12 width=51) (actual time=0.491..0.682 rows=3 loops=1)  
        Index Cond: (booking_id = 1114)  
  -> Append (cost=0.43..397.76 rows=16 width=48) (actual time=0.346..0.770 rows=4 loops=3)  
    -> Index Scan using boarding_pass_0_passenger_id_idx on boarding_pass_0 bp_1 (cost=0.43..20.50 rows=4 width=48) (actual time=0.037..0.073 rows=4 loops=3)  
        Index Cond: (passenger_id = p.passenger_id)  
    -> Async Foreign Scan on boarding_pass_1_fdw bp_2 (cost=104.46..125.73 rows=4 width=48) (actual time=0.190..0.190 rows=0 loops=3)  
        Foreign EXPLAIN:  
          Index Scan using boarding_pass_1_passenger_id_idx on boarding_pass_1 (cost=0.43..20.50 rows=4 width=48)  
          Index Cond: (passenger_id = $1)  
    -> Async Foreign Scan on boarding_pass_2_fdw bp_3 (cost=104.46..125.73 rows=4 width=48) (actual time=0.072..0.072 rows=0 loops=3)  
    -> Async Foreign Scan on boarding_pass_3_fdw bp_4 (cost=104.46..125.73 rows=4 width=48) (actual time=0.060..0.060 rows=0 loops=3)
```

```
Planning Time: 2.493 ms
```

```
Execution Time: 3.945 ms
```

```
(17 rows)
```

Shardman: запрос с ключом шардирования

```
postgres=# explain(analyse)
SELECT *
FROM booking b
join passenger p on p.booking_id = b.booking_id
join boarding_pass bp on bp.passenger_id = p.passenger_id
where b.booking_id = 1114;
```

Ключ шардирования

QUERY PLAN

```
-----
Nested Loop (cost=1.29..4821.72 rows=1815972 width=185) (actual time=1.821..3.743 rows=12 loops=1)
  -> Nested Loop (cost=0.86..46.71 rows=12 width=137) (actual time=1.225..1.418 rows=3 loops=1)
    -> Index Scan using booking_0_pkey on booking_0 b (cost=0.43..8.45 rows=1 width=86) (actual time=0.728..0.729 rows=1 loops=1)
        Index Cond: (booking_id = 1114)
    -> Index Scan using passenger_0_booking_id_idx on passenger_0 p (cost=0.43..38.15 rows=12 width=51) (actual time=0.491..0.682 rows=3 loops=1)
        Index Cond: (booking_id = 1114)
  -> Append (cost=0.43..397.76 rows=16 width=48) (actual time=0.346..0.770 rows=4 loops=3)
    -> Index Scan using boarding_pass_0_passenger_id_idx on boarding_pass_0 bp_1 (cost=0.43..20.50 rows=4 width=48) (actual time=0.037..0.073 rows=4 loops=3)
        Index Cond: (passenger_id = p.passenger_id)
    -> Async Foreign Scan on boarding_pass_1_fdw bp_2 (cost=104.46..125.73 rows=4 width=48) (actual time=0.190..0.190 rows=0 loops=3)
        Foreign EXPLAIN:
          Index Scan using boarding_pass_1_passenger_id_idx on boarding_pass_1 (cost=0.43..20.50 rows=4 width=48)
              Index Cond: (passenger_id = $1)
    -> Async Foreign Scan on boarding_pass_2_fdw bp_3 (cost=104.46..125.73 rows=4 width=48) (actual time=0.072..0.072 rows=0 loops=3)
    -> Async Foreign Scan on boarding_pass_3_fdw bp_4 (cost=104.46..125.73 rows=4 width=48) (actual time=0.060..0.060 rows=0 loops=3)
Planning Time: 2.493 ms
Execution Time: 3.945 ms
(17 rows)
```

Shardman: запрос с ключом шардирования

```
postgres=# explain(analyse)
SELECT *
FROM booking b
join passenger p on p.booking_id = b.booking_id
join boarding_pass bp on bp.passenger_id = p.passenger_id
where b.booking_id = 1114;
```

Ключ шардирования

QUERY PLAN

```
Nested Loop (cost=1.29..4821.72 rows=1815972 width=185) (actual time=1.821..3.743 rows=12 loops=1)
-> Nested Loop (cost=0.86..46.71 rows=12 width=137) (actual time=1.225..1.418 rows=3 loops=1)
    -> Index Scan using booking_0_pkey on booking_0 b (cost=0.43..8.45 rows=1 width=86) (actual time=0.728..0.729 rows=1 loops=1)
        Index Cond: (booking_id = 1114)
    -> Index Scan using passenger_0_booking_id_idx on passenger_0 p (cost=0.43..38.15 rows=12 width=51) (actual time=0.491..0.682 rows=3 loops=1)
        Index Cond: (booking_id = 1114)
-> Append (cost=0.43..397.76 rows=16 width=48) (actual time=0.346..0.770 rows=4 loops=3)
    -> Index Scan using boarding_pass_0_passenger_id_idx on boarding_pass_0 bp_1 (cost=0.43..20.50 rows=4 width=48) (actual time=0.037..0.073 rows=4 loops=3)
        Index Cond: (passenger_id = p.passenger_id)
    -> Async Foreign Scan on boarding_pass_1_fdw bp_2 (cost=104.46..125.73 rows=4 width=48) (actual time=0.190..0.190 rows=0 loops=3)
        Foreign EXPLAIN:
            Index Scan using boarding_pass_1_passenger_id_idx on boarding_pass_1 (cost=0.43..20.50 rows=4 width=48)
                Index Cond: (passenger_id = $1)
    -> Async Foreign Scan on boarding_pass_2_fdw bp_3 (cost=104.46..125.73 rows=4 width=48) (actual time=0.072..0.072 rows=0 loops=3)
    -> Async Foreign Scan on boarding_pass_3_fdw bp_4 (cost=104.46..125.73 rows=4 width=48) (actual time=0.060..0.060 rows=0 loops=3)
```

```
Planning Time: 2.493 ms
Execution Time: 3.945 ms
```

(17 rows)

Выполнение на
локальном шарде

Shardman: запрос с ключом шардирования

```
postgres=# explain(analyse)
SELECT *
FROM booking b
join passenger p on p.booking_id = b.booking_id
join boarding_pass bp on bp.passenger_id = p.passenger_id
where b.booking_id = 1114;
```

Ключ шардирования

QUERY PLAN

```
Nested Loop (cost=1.29..4821.72 rows=1815972 width=185) (actual time=1.821..3.743 rows=12 loops=1)
-> Nested Loop (cost=0.86..46.71 rows=12 width=137) (actual time=1.225..1.418 rows=3 loops=1)
    -> Index Scan using booking_0_pkey on booking_0 b (cost=0.43..8.45 rows=1 width=86) (actual time=0.728..0.729 rows=1 loops=1)
        Index Cond: (booking_id = 1114)
    -> Index Scan using passenger_0_booking_id_idx on passenger_0 p (cost=0.43..38.15 rows=12 width=51) (actual time=0.491..0.682 rows=3 loops=1)
        Index Cond: (booking_id = 1114)
-> Append (cost=0.43..397.76 rows=16 width=48) (actual time=0.346..0.770 rows=4 loops=3)
    -> Index Scan using boarding_pass_0_passenger_id_idx on boarding_pass_0 bp_1 (cost=0.43..20.50 rows=4 width=48) (actual time=0.037..0.073 rows=4 loops=3)
        Index Cond: (passenger_id = p.passenger_id)
    -> Async Foreign Scan on boarding_pass_1_fdw bp_2 (cost=104.46..125.73 rows=4 width=48) (actual time=0.190..0.190 rows=0 loops=3)
        Foreign EXPLAIN:
            Index Scan using boarding_pass_1_passenger_id_idx on boarding_pass_1 (cost=0.43..20.50 rows=4 width=48)
                Index Cond: (passenger_id = $1)
    -> Async Foreign Scan on boarding_pass_2_fdw bp_3 (cost=104.46..125.73 rows=4 width=48) (actual time=0.072..0.072 rows=0 loops=3)
    -> Async Foreign Scan on boarding_pass_3_fdw bp_4 (cost=104.46..125.73 rows=4 width=48) (actual time=0.060..0.060 rows=0 loops=3)
```

```
Planning Time: 2.493 ms
Execution Time: 3.945 ms
```

(17 rows)

Выполнение на
локальном шарде

Выполнение на
других шардах

Shardman: запрос с ключом шардирования

```
postgres=# explain(analyse)
```

```
SELECT *
```

```
FROM booking b
```

```
join passenger p on p.booking_id = b.booking_id
```

```
join boarding_pass bp on bp.passenger_id = p.passenger_id
```

```
where b.booking_id = 1111;
```

```
QUERY PLAN
```

```
-----  
Nested Loop (cost=1.42..4378.09 rows=1664641 width=185) (actual time=5.079..7.489 rows=12 loops=1)
```

```
  -> Foreign Scan (cost=0.99..1.00 rows=11 width=137) (actual time=4.117..4.118 rows=3 loops=1)
```

```
    Relations: (booking_3_fdw b) INNER JOIN (passenger_3_fdw p)
```

```
    Foreign EXPLAIN:
```

```
      Sort (cost=44.56..44.59 rows=11 width=137)
```

```
        Sort Key: r7.passenger_id
```

```
        -> Nested Loop (cost=0.86..44.37 rows=11 width=137)
```

```
          -> Index Scan using booking_3_pkey on booking_3 r6 (cost=0.43..8.45 rows=1 width=86)
```

```
            Index Cond: (booking_id = 1111)
```

```
          -> Index Scan using passenger_3_booking_id_idx on passenger_3 r7 (cost=0.43..35.81 rows=11 width=51)
```

```
            Index Cond: (booking_id = 1111)
```

```
  -> Append (cost=0.43..397.76 rows=16 width=48) (actual time=1.045..1.117 rows=4 loops=3)
```

```
    -> Index Scan using boarding_pass_0_passenger_id_idx on boarding_pass_0 bp_1 (cost=0.43..20.50 rows=4 width=48) (actual time=0.072..0.072 rows=0 loops=3)
```

```
      Index Cond: (passenger_id = p.passenger_id)
```

```
    -> Async Foreign Scan on boarding_pass_1_fdw bp_2 (cost=104.46..125.73 rows=4 width=48) (actual time=0.139..0.139 rows=0 loops=3)
```

```
      Foreign EXPLAIN:
```

```
        Index Scan using boarding_pass_1_passenger_id_idx on boarding_pass_1 (cost=0.43..20.50 rows=4 width=48)
```

```
          Index Cond: (passenger_id = $1)
```

```
    -> Async Foreign Scan on boarding_pass_2_fdw bp_3 (cost=104.46..125.73 rows=4 width=48) (actual time=0.093..0.093 rows=0 loops=3)
```

```
    -> Async Foreign Scan on boarding_pass_3_fdw bp_4 (cost=104.46..125.73 rows=4 width=48) (actual time=0.074..0.074 rows=4 loops=3)
```

```
Planning Time: 3.933 ms
```

```
Execution Time: 7.743 ms
```

```
(22 rows)
```

Shardman: запрос с ключом шардирования

```
postgres=# explain(analyse)
SELECT *
FROM booking b
join passenger p on p.booking_id = b.booking_id
join boarding_pass bp on bp.passenger_id = p.passenger_id
where b.booking_id = 1111;
```

Ключ шардирования

QUERY PLAN

```
-----
Nested Loop (cost=1.42..4378.09 rows=1664641 width=185) (actual time=5.079..7.489 rows=12 loops=1)
  -> Foreign Scan (cost=0.99..1.00 rows=11 width=137) (actual time=4.117..4.118 rows=3 loops=1)
        Relations: (booking_3_fdw b) INNER JOIN (passenger_3_fdw p)
        Foreign EXPLAIN:
            Sort (cost=44.56..44.59 rows=11 width=137)
              Sort Key: r7.passenger_id
              -> Nested Loop (cost=0.86..44.37 rows=11 width=137)
                    -> Index Scan using booking_3_pkey on booking_3 r6 (cost=0.43..8.45 rows=1 width=86)
                          Index Cond: (booking_id = 1111)
                    -> Index Scan using passenger_3_booking_id_idx on passenger_3 r7 (cost=0.43..35.81 rows=11 width=51)
                          Index Cond: (booking_id = 1111)
            -> Append (cost=0.43..397.76 rows=16 width=48) (actual time=1.045..1.117 rows=4 loops=3)
                  -> Index Scan using boarding_pass_0_passenger_id_idx on boarding_pass_0 bp_1 (cost=0.43..20.50 rows=4 width=48) (actual time=0.072..0.072 rows=0 loops=3)
                        Index Cond: (passenger_id = p.passenger_id)
                  -> Async Foreign Scan on boarding_pass_1_fdw bp_2 (cost=104.46..125.73 rows=4 width=48) (actual time=0.139..0.139 rows=0 loops=3)
                        Foreign EXPLAIN:
                            Index Scan using boarding_pass_1_passenger_id_idx on boarding_pass_1 (cost=0.43..20.50 rows=4 width=48)
                                Index Cond: (passenger_id = $1)
                  -> Async Foreign Scan on boarding_pass_2_fdw bp_3 (cost=104.46..125.73 rows=4 width=48) (actual time=0.093..0.093 rows=0 loops=3)
                  -> Async Foreign Scan on boarding_pass_3_fdw bp_4 (cost=104.46..125.73 rows=4 width=48) (actual time=0.074..0.074 rows=4 loops=3)
Planning Time: 3.933 ms
Execution Time: 7.743 ms
(22 rows)
```

Shardman: запрос с ключом шардирования

```
postgres=# explain(analyse)
SELECT *
FROM booking b
join passenger p on p.booking_id = b.booking_id
join boarding_pass bp on bp.passenger_id = p.passenger_id
where b.booking_id = 1111;
```

Ключ шардирования

QUERY PLAN

```
-----
Nested Loop (cost=1.42..4378.09 rows=1664641 width=185) (actual time=5.079..7.489 rows=12 loops=1)
  -> Foreign Scan (cost=0.99..1.00 rows=11 width=137) (actual time=4.117..4.118 rows=3 loops=1)
    Relations: (booking_3_fdw b) INNER JOIN (passenger_3_fdw p)
    Foreign EXPLAIN:
      Sort (cost=44.56..44.59 rows=11 width=137)
        Sort Key: r7.passenger_id
        -> Nested Loop (cost=0.86..44.37 rows=11 width=137)
          -> Index Scan using booking_3_pkey on booking_3 r6 (cost=0.43..8.45 rows=1 width=86)
            Index Cond: (booking_id = 1111)
          -> Index Scan using passenger_3_booking_id_idx on passenger_3 r7 (cost=0.43..35.81 rows=11 width=51)
            Index Cond: (booking_id = 1111)
        -> Append (cost=0.43..397.76 rows=16 width=48) (actual time=1.045..1.117 rows=4 loops=3)
          -> Index Scan using boarding_pass_0_passenger_id_idx on boarding_pass_0 bp_1 (cost=0.43..20.50 rows=4 width=48) (actual time=0.072..0.072 rows=0 loops=3)
            Index Cond: (passenger_id = p.passenger_id)
          -> Async Foreign Scan on boarding_pass_1_fdw bp_2 (cost=104.46..125.73 rows=4 width=48) (actual time=0.139..0.139 rows=0 loops=3)
            Foreign EXPLAIN:
              Index Scan using boarding_pass_1_passenger_id_idx on boarding_pass_1 (cost=0.43..20.50 rows=4 width=48)
                Index Cond: (passenger_id = $1)
          -> Async Foreign Scan on boarding_pass_2_fdw bp_3 (cost=104.46..125.73 rows=4 width=48) (actual time=0.093..0.093 rows=0 loops=3)
          -> Async Foreign Scan on boarding_pass_3_fdw bp_4 (cost=104.46..125.73 rows=4 width=48) (actual time=0.074..0.074 rows=4 loops=3)
Planning Time: 3.933 ms
Execution Time: 7.743 ms
(22 rows)
```

Выполнение JOIN на
другом шарде

Shardman: запрос с ключом шардирования

```
postgres=# explain(analyse)
SELECT *
FROM booking b
join passenger p on p.booking_id = b.booking_id
join boarding_pass bp on bp.passenger_id = p.passenger_id
where b.booking_id = 1111;
```

Ключ шардирования

QUERY PLAN

```
-----
Nested Loop (cost=1.42..4378.09 rows=1664641 width=185) (actual time=5.079..7.489 rows=12 loops=1)
  -> Foreign Scan (cost=0.99..1.00 rows=11 width=137) (actual time=4.117..4.118 rows=3 loops=1)
        Relations: (booking_3_fdw b) INNER JOIN (passenger_3_fdw p)
        Foreign EXPLAIN:
          Sort (cost=44.56..44.59 rows=11 width=137)
            Sort Key: r7.passenger_id
            -> Nested Loop (cost=0.86..44.37 rows=11 width=137)
                  -> Index Scan using booking_3_pkey on booking_3 r6 (cost=0.43..8.45 rows=1 width=86)
                        Index Cond: (booking_id = 1111)
                  -> Index Scan using passenger_3_booking_id_idx on passenger_3 r7 (cost=0.43..35.81 rows=11 width=51)
                        Index Cond: (booking_id = 1111)
          -> Append (cost=0.43..397.76 rows=16 width=48) (actual time=1.045..1.117 rows=4 loops=3)
                -> Index Scan using boarding_pass_0_passenger_id_idx on boarding_pass_0 bp_1 (cost=0.43..20.50 rows=4 width=48) (actual time=0.072..0.072 rows=0 loops=3)
                      Index Cond: (passenger_id = p.passenger_id)
                -> Async Foreign Scan on boarding_pass_1_fdw bp_2 (cost=104.46..125.73 rows=4 width=48) (actual time=0.139..0.139 rows=0 loops=3)
                      Foreign EXPLAIN:
                        Index Scan using boarding_pass_1_passenger_id_idx on boarding_pass_1 (cost=0.43..20.50 rows=4 width=48)
                              Index Cond: (passenger_id = $1)
                -> Async Foreign Scan on boarding_pass_2_fdw bp_3 (cost=104.46..125.73 rows=4 width=48) (actual time=0.093..0.093 rows=0 loops=3)
                -> Async Foreign Scan on boarding_pass_3_fdw bp_4 (cost=104.46..125.73 rows=4 width=48) (actual time=0.074..0.074 rows=4 loops=3)
```

Выполнение JOIN на другом шарде

Выполнение на других шардах

```
Planning Time: 3.933 ms
Execution Time: 7.743 ms
(22 rows)
```

Shardman: запрос с ключом шардирования

```
postgres=# explain(analyse)
SELECT *
FROM booking b
join passenger p on p.booking_id = b.booking_id
join boarding_pass bp on bp.passenger_id = p.passenger_id
where b.booking_id = 1111;
```

Ключ шардирования

QUERY PLAN

```
Nested Loop (cost=1.42..4378.09 rows=1664641 width=185) (actual time=5.079..7.489 rows=12 loops=1)
-> Foreign Scan (cost=0.99..1.00 rows=11 width=137) (actual time=4.117..4.118 rows=3 loops=1)
    Relations: (booking_3_fdw b) INNER JOIN (passenger_3_fdw p)
    Foreign EXPLAIN:
        Sort (cost=44.56..44.59 rows=11 width=137)
        Sort Key: r7.passenger_id
        -> Nested Loop (cost=0.86..44.37 rows=11 width=137)
            -> Index Scan using booking_3_pkey on booking_3 r6 (cost=0.43..8.45 rows=1 width=86)
                Index Cond: (booking_id = 1111)
            -> Index Scan using passenger_3_booking_id_idx on passenger_3 r7 (cost=0.43..35.81 rows=11 width=51)
                Index Cond: (booking_id = 1111)
        -> Append (cost=0.43..397.76 rows=16 width=48) (actual time=1.045..1.117 rows=4 loops=3)
            -> Index Scan using boarding_pass_0_passenger_id_idx on boarding_pass_0 bp_1 (cost=0.43..20.50 rows=4 width=48) (actual time=0.072..0.072 rows=0 loops=3)
                Index Cond: (passenger_id = p.passenger_id)
            -> Async Foreign Scan on boarding_pass_1_fdw bp_2 (cost=104.46..125.73 rows=4 width=48) (actual time=0.139..0.139 rows=0 loops=3)
                Foreign EXPLAIN:
                    Index Scan using boarding_pass_1_passenger_id_idx on boarding_pass_1 (cost=0.43..20.50 rows=4 width=48)
                    Index Cond: (passenger_id = $1)
            -> Async Foreign Scan on boarding_pass_2_fdw bp_3 (cost=104.46..125.73 rows=4 width=48) (actual time=0.093..0.093 rows=0 loops=3)
            -> Async Foreign Scan on boarding_pass_3_fdw bp_4 (cost=104.46..125.73 rows=4 width=48) (actual time=0.074..0.074 rows=4 loops=3)
```


Выполнение JOIN на
другом шарде

Выполнение на
локальном шарде


Выполнение на
других шардах

```
Planning Time: 3.933 ms
Execution Time: 7.743 ms
(22 rows)
```

Shardman: мультиплексирование fdw




Загрузка данных в Shardman



Shardman: возможности Postgres Pro Enterprise 17

- механизм сжатия данных CFS,
- `pg_probackup` : инкрементальный бэкап на уровне страниц, используя PTRACK,
- расширение `pgpro_stats` : сбор статистики планирования и выполнения распределённых запросов, затрагивающих несколько узлов в кластере
- Встроенный отказоустойчивый кластер ViNA

BiHA: встроенный отказоустойчивый кластер



Встроен в ядро Postgres Pro Enterprise начиная с версии 16

Простая установка и конфигурирование

Не требуется установка дополнительного ПО

Лидер продолжает работать, если соблюдается кворум

BiHA: встроенный отказоустойчивый кластер

Встроен в ядро Postgres Pro Enterprise начиная с версии 16


Простая установка и конфигурирование

Не требуется установка дополнительного ПО

Лидер продолжает работать, если соблюдается кворум


В случае сбоя ведомые предлагают себя кандидатами и организуются выборы нового лидера

Защита от split-brain



`biha.nquorum= 2`

ВiHA: узел рефери




mode=
referee или
referee_with_wal

Рефери – легковесный экземпляр, который не содержит пользовательских данных, но является членом кластера ВiHA: сам кандидатом на звание нового лидера не выступает, но участвует в голосовании

Рефери может работать в режиме `referee_with_wal` :

- Получает весь WAL и фильтрует его, применяются только системные записи WAL без пользовательских данных
- При сбое лидера может отправлять WAL кандидату на нового лидера, если тот отстаёт от рефери

ВiНА: приоритеты кандидатов в лидеры




Можно установить приоритеты для выдвижения узла в качестве кандидата

Приоритет узла в секундах определяет тайм-аут, по достижении которого узел предложит себя в качестве кандидата на выборах.

Только в синхронном кластере

BiHA: синхронный режим



В Shardman отказоустойчивый кластер BiHA работает в синхронном режиме

Под капотом выполняется
`bihactl init ... --sync-standbys=<число_синхронных_ведомых_серверов>`

Кроме того, настраивается параметр `sync_standbys_min` - минимальное количество синхронных ведомых серверов, которые должны быть доступны, чтобы лидер продолжал работу.

Топология кластера Shardman

Чтобы создать кластер
с необходимой топологией
отказоустойчивости ВiНА,
нужно указать параметры
для каждого узла
в файле конфигурации
sdmspec.json
в разделе Topology

```
"Topology": {  
  "shard-1": [  
    {  
      "host": "host1",  
      "role": "leader",  
      "pgPort": 5432,  
      "silkPort": 8000,  
      "bihaPort": 25432,  
      "priority": 10  
    },  
    {  
      "host": "host2",  
      "role": "follower",  
      "pgPort": 5433,  
      "silkPort": 8001,  
      "bihaPort": 25433,  
      "priority": 1000  
    },  
    {  
      "host": "host3",  
      "role": "referee-with-wal",  
      "pgPort": 5434,  
      "silkPort": 8000,  
      "bihaPort": 25434  
    }  
  ],  
}
```

```
"shard-2": [  
  {  
    "host": "host2",  
    "role": "leader",  
    "pgPort": 5432,  
    "silkPort": 8000,  
    "bihaPort": 25432,  
    "priority": 10  
  },  
  {  
    "host": "host1",  
    "role": "follower",  
    "pgPort": 5433,  
    "silkPort": 8001,  
    "bihaPort": 25433,  
    "priority": 1000  
  },  
  {  
    "host": "host3",  
    "role": "referee-with-wal",  
    "pgPort": 5434,  
    "silkPort": 8000,  
    "bihaPort": 25435  
  }  
],  
}
```


Топология кластера Shardman

```
$ shardmanctl cluster topology
```

== REPLICATION GROUP shard-1, RGID - 1 ==				
HOST	PORT	KEEPER	STATUS	PRIORITY
host1	5432	keeper_1	LEADER_RW	10
host2	5433	keeper_2	FOLLOWER	1000
host3	5434	keeper_3	REFEREE_WITH_WAL	NOT SET

== REPLICATION GROUP shard-2, RGID - 2 ==				
HOST	PORT	KEEPER	STATUS	PRIORITY
host2	5432	keeper_1	LEADER_RW	10
host3	5433	keeper_2	FOLLOWER	1000
host1	5434	keeper_3	REFEREE_WITH_WAL	NOT SET

Резервное копирование Shardman



Дополнительная информация

- Описание
<https://postgrespro.ru/products/shardman>
- Документация
<https://postgrespro.ru/docs/shardman/14>
- Публикации
<https://habr.com/ru/companies/postgrespro/articles/811041/>
- Презентации
<https://pgconf.ru/talk/1687651>



Спасибо за внимание!