

Вся правда о мультимастере

Рутман Михаил

PGConf.Сибирь 2022

PosgresPro

PGConf.Сибирь 2022



О докладчике:



Рутман
Михаил



PostgresPro

- Работаю в PostgresPro с 2021 года в проекте Multimaster.
- Более 20 лет в ИТ (СигнатеК, Eyeline, Navitel, Parallels, Plesk, Kublr).
- Преподаю в Новосибирском гос. университете курс “Операционные системы.”






Мультимастер это....

- высокая доступность
- отказоустойчивость
- симметричный кластер

Мультимастер это....



- расширение Postgres
- набор патчей в ядро Postgres

Расширение Postgres

- протокол логической репликации
- поддержка 3PC
- параллельный Executor
- PAXOS (Synod)
- failover


Расширение Postgres

```
/home/demo/postgrespro/postgres -D /home/demo/node1/pgdata --cluster-name=node1
\_ .....
\_ postgres: node1: mtm-dmq-sender
\_ postgres: node1: mtm-monitor
\_ postgres: node1: user demodb 127.0.0.1(47206) mtm-dmq-receiver node3
\_ postgres: node1: mtm-logrep-receiver-1-3
\_ postgres: node1: mtm-logrep-receiver-1-2
\_ postgres: node1: mtm-replier
\_ postgres: node1: mtm-campaigner
\_ postgres: node1: walsender user 127.0.0.1(47214) idle
\_ postgres: node1: walsender user 127.0.0.1(47298) idle
\_ postgres: node1: user demodb 127.0.0.1(47230) mtm-dmq-receiver node2
```


Набор патчей в ядро

- поддержка 3PC в logical decoding
- API для обнаружения deadlock
-


Мультимастер




Согласованность данных

- ACP (Atomic Commit Protocol). Каждая транзакция подтверждается консенсусом нод
- Поколения нод


Commit в Мультимастере



Конфликт при обновлении



Нарушение порядка транзакций



Поколения

- номер поколения - это пара `<gen_number, members>`
- только эти ноды могут делать транзакции
- нода стремится переключиться в поколение с большим номером
- нода в поколении может быть в нескольких состояниях:
 - ONLINE - нормальная работа
 - RECOVERY - нода вошла в поколение и должна применить недостающие транзакции
 - DEAD - не является членом текущего поколения

PGConf.Сибирь 2022

Поколение <1, {1, 2, 3}>

Node 1



Node 2



Node 3



Поколение <2, {1, 2}>

Node 1



Node 2



Node 3



Поколение <3, {1, 2, 3}>

Node 1



Node 2



Node 3



Поколение <3, {1, 2, 3}>

Node 1



Node 2



Node 3



Поколения

- Нода из поколения N не применяет транзакции поколения N-1
- Поколения состоят из большинства нод
- нода ONLINE в поколении N содержит все транзакции предыдущих поколений
- все новые транзакции будут в поколениях $\geq N$
- все транзакции поколения N будут применены до транзакций поколения M ($N < M$)
- порядок транзакций внутри поколения обеспечен ACID

Node 1



gen 1

Node 2



gen 1

Node 3



gen 1



Node 1



gen 1

Node 2



gen 1

Node 3



gen 1

Request Gen 2

Response Gen 2

Node 1



gen 1

Node 2



gen 2

Node 3



gen 2



DDL

- передаются с WAL-ом как текст
- есть нюансы (temp tables, ...)

Где взять мультимастер

- Postgres Pro Enterprise
- Postgresql

<https://github.com/postgrespro/mmts>



Подготовка к запуску мультимастера

- ПОДГОТОВИТЬ рабочие ноды
- ДОБАВИТЬ В КОНФИГ postgresql.conf:

```
shared_preload_libraries = 'multimaster'
```

```
wal_level = logical
```

```
max_connections = 100
```

```
max_prepared_transactions = 300
```

```
max_wal_senders = 10
```

```
max_replication_slots = 10
```

```
wal_sender_timeout = 0
```


Запуск мультимастера

на одной из НИХ ВЫПОЛНИТЬ:

```
> create extension multimaster;  
> select mtm.init_cluster(  
    'host=node1',  
    '{“host=node2”, host3=node3”}’);
```

Мониторинг мультимастера

Функция **mtm.ping()** - определение работоспособности кластера:

```
demodb=# select * from mtm.ping();
```

```
ping
```

```
-----
```

```
t
```

```
(1 row)
```

```
  
```


Мониторинг мультимастера

Функция **mtm.status()** - запрос статуса нод:

```
demodb=# select * from mtm.status();
```

my_node_id	status	connected	gen_num	gen_members	gen_members_online	gen_configured
1	online	{1,2,3}	3	{1,2,3}	{1,2,3}	{1,2,3}

(1 row)

Мониторинг мультимастера

Функция **mtm.nodes()** - запрос списка нод кластера их СОСТОЯНИЯ:

```
demodb=# select * from mtm.nodes();
```

id	conninfo	is_self	enabled	connected	sender_pid	receiver_pid	n_workers	receiver_mode
1	port=65432 host=127.0.0.1 dbname='demodb'	t	t	t				
2	port=65433 host=127.0.0.1 dbname='demodb'	f	t	t	1939895	1939795	0	normal
3	port=65434 host=127.0.0.1 dbname='demodb'	f	t	t	1939797	1939794	0	normal

Схема включения. 3-х нодовый кластер




Схема включения. 3-х нодовый кластер





Схема включения. 2 ноды + рефери



Применение мультимастера

Отказоустойчивый кластер	да
Катастрофоустойчивый кластер	нет
Виртуальные среды	да
Облачные сервисы	да
Непрерывность сервиса	да

Заключение. Особенности мультимастера

- быстрый failover
- не требуется дополнительного ПО
- запись на все ноды
- кластер доступен пока живо большинство нод
- можно добавить ноду “на лету”.
- автоматическое восстановление ноды после сбоя
- совместимость с Postgres

PGConf.Сибирь 2022


СПАСИБО!

Михаил В. Рутман:
m.rutman@postgrespro.ru

postgrespro.ru


Замеры

TPS от количества обновлений



Замеры

TPS от количества обновлений



Замеры

TPS от количества обновлений

