PostgreSQL sharding based on FDW

digoal
阿里云

目录

- 水平拆分可选开源方案
- why sharding based on fdw?
- 继承、触发器
- pg_pathman
- CASE

单节点性能指标参考数据

- 秒杀
  - 8 Core, 23万 qps
- KNN近邻查询
  - 16 Core, 100亿数据, 64并发, KNN查询平均响应时间0.848毫秒, qps 74151.
- 模糊查询、正则匹配
  - 8Host, 16Core, 1008亿数据, 前后模糊、正则匹配, 秒级响应
- 分词
  - 英语分词性能：~900万 words每秒 (Intel(R) Xeon(R) CPU X7460 @ 2.66GHz)
  - 中文分词性能：~400万 字每秒 (Intel(R) Xeon(R) CPU X7460 @ 2.66GHz)
  - 英文分词+插入性能：~666万 字每秒 (Intel(R) Xeon(R) CPU X7460 @ 2.66GHz)
  - 中文分词+插入性能：~290万 字每秒 (Intel(R) Xeon(R) CPU X7460 @ 2.66GHz)
- 并行计算
  - CPU并行 32Core, 16亿(90GB), count (*) 7秒, bit(and, xor) 16秒， 非并行(141秒, 488秒).
  - GPU并行 (1张 1亿 table join 9张 10万 table) 21秒， 非并行520秒.

单节点性能指标参考数据

- 数据装载
  - 32Core, 512G, 2*Aliflash SSD
  - 连续24小时多轮数据批量导入测试(平均每条记录长度360字节, 时间字段索引)
  - 每轮测试插入12TB数据
  - 506万行/s，1.78 GB/s，全天插入4372亿，154TB数据
  - (为什么这么快?) (BRIN, HEAP, 动态扩展FILE, prealloc XLOG, reuse XLOG)
- TPC-B (1 Select : 3 Update : 1 Insert)
  - 32Core, 512G, 2*Aliflash SSD 10亿数据量, 11万tps, 77万qps
  - Select-Only 100万tps (即使应用缓存失效，也无大碍)
- TPC-C (新建订单45,支付43,订单查询4,发货4,库存查询4)
  - 4000个仓库, 400GB数据, 平均每笔事务10几条SQL
  - 12Core, 256GB, intel SSD , 61万TPmC (IO瓶颈严重,理论上可以达到200万)
- LinkBench (Facebook 社交关系应用)
  - 1亿个node，4亿条关系，(32Core，2 SSD, 512G)
  - (添加NODE，更新NODE，删除NODE，获取NODE信息，添加关系，删除关系，更新关系，关系总数查询，获取多个关系，获取关系列表)
  - 12万 ops (默认测试用例)

水平拆分可选开源方案

- OLTP
  - plproxy
  - pgpool-II
  - citusdata
  - pg-x2
  - FDW
- OLAP
  - greenplum
  - hawq
  - pg-xl

FDW

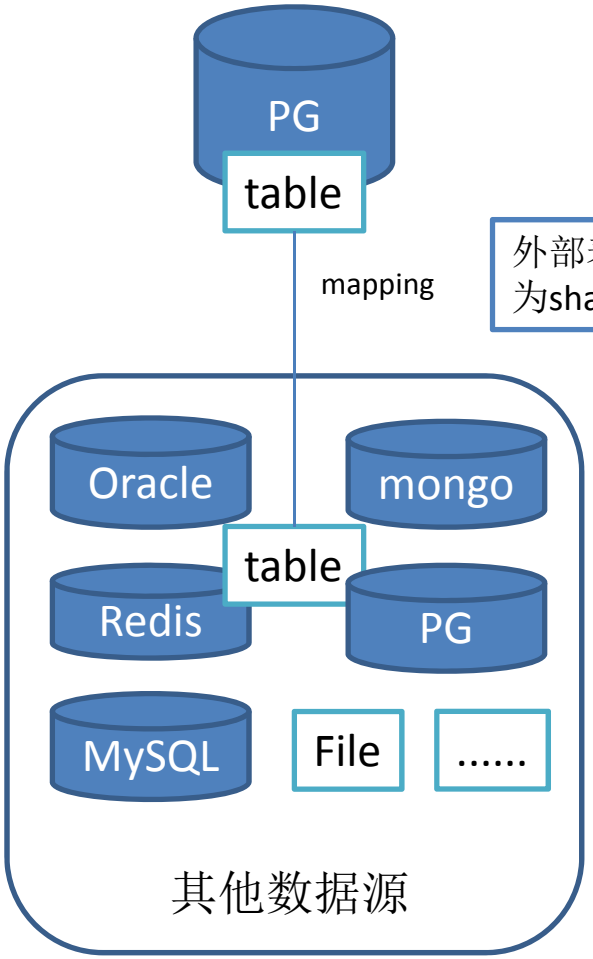

FDW API：
scan api
join api
post scan/join api
update api
row lock api
explain, analyze api
import api
parallel exec api

大象装进冰箱需要几步？

1. create server; -- host:port:dbname:other_ops
2. create user mapping; -- auth
3. create foreign table; -- table ddl mapping

FDW

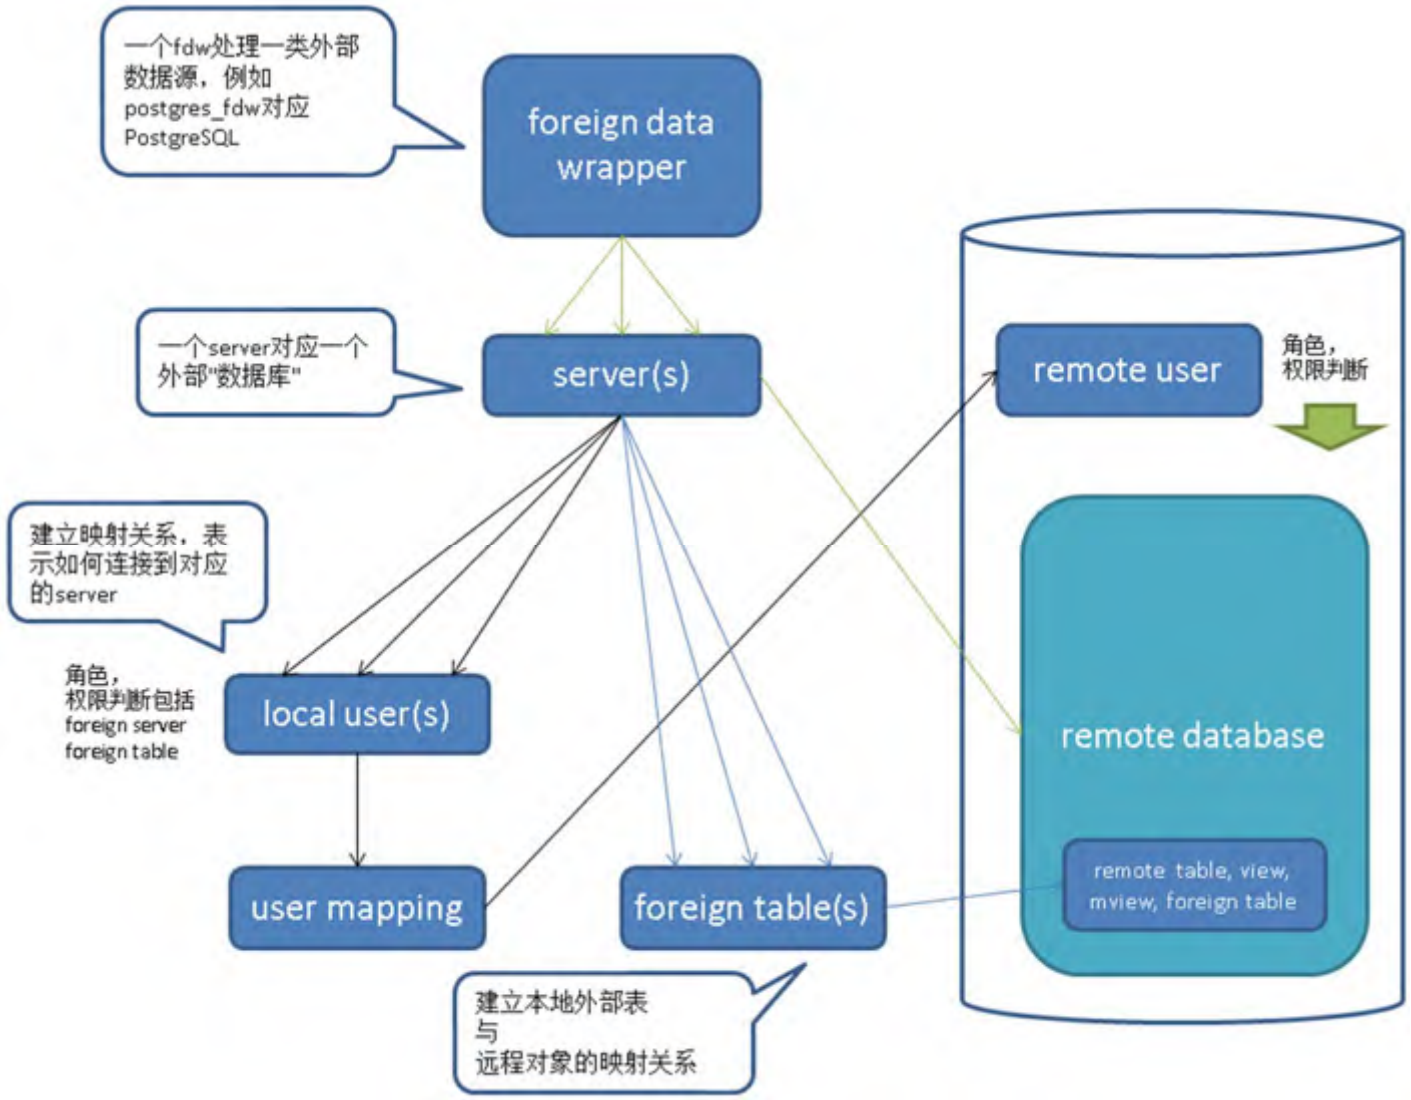
一个fdw处理一类外部数据源，例如postgres_fdw对应PostgreSQL
foreign data wrapper
一个server对应一个外部"数据库"
server(s)
建立映射关系，表示如何连接到对应的server
角色，权限判断包括foreign server foreign table
local user(s)
user mapping
foreign table(s)
建立本地外部表与远程对象的映射关系
remote user
角色，权限判断
remote database
remote table, view, mview, foreign table

why sharding based on fdw?

- postgres_fdw 9.6 增强
- 连接复用
  - 只要server相同, remote user相同, 就可以复用连接
- 支持server extension option
  - 除了支持build-in func\ops，也支持extension func\ops
- JOIN下推
  - server和user mapping相同的外表JOIN
  - JOIN的operation、function，必须buildin -func immutable；或者在server属性extension内，属于extension中的immutable function、operations
- SORT下推
- WHERE子句算子下推
  - buildin -func immutable；或者在server属性extension内，属于extension中的immutable function、operations
- DML下推
- 允许设置表级或server级别fetch_size
- 允许cancel请求传递给remote session

why sharding based on fdw?

SORT

```
mas1-> explain (analyze,verbose,timing,costs,buffers) select * from userinfo order by uid desc limit 10;
                                                                QUERY PLAN
------------------------------------------------------------------------------------------------------------------------------------------
 Limit  (cost=400.04..400.47 rows=10 width=48) (actual time=3.075..3.084 rows=10 loops=1)
   Output: userinfo_0.uid, userinfo_0.info, userinfo_0.crt_time
   ->  Merge Append  (cost=400.04..593.58 rows=4548 width=48) (actual time=3.073..3.080 rows=10 loops=1)
         Sort Key: userinfo_0.uid DESC
         ->  Foreign Scan on digoal.userinfo_0  (cost=100.00..140.38 rows=1137 width=48) (actual time=0.844..0.845 rows=5 loops=1)
               Output: userinfo_0.uid, userinfo_0.info, userinfo_0.crt_time
               Remote SQL: SELECT uid, info, crt_time FROM role0.userinfo_0 ORDER BY uid DESC NULLS FIRST
         ->  Foreign Scan on digoal.userinfo_1  (cost=100.00..140.38 rows=1137 width=48) (actual time=0.733..0.733 rows=1 loops=1)
               Output: userinfo_1.uid, userinfo_1.info, userinfo_1.crt_time
               Remote SQL: SELECT uid, info, crt_time FROM role1.userinfo_1 ORDER BY uid DESC NULLS FIRST
         ->  Foreign Scan on digoal.userinfo_2  (cost=100.00..140.38 rows=1137 width=48) (actual time=0.714..0.714 rows=4 loops=1)
               Output: userinfo_2.uid, userinfo_2.info, userinfo_2.crt_time
               Remote SQL: SELECT uid, info, crt_time FROM role2.userinfo_2 ORDER BY uid DESC NULLS FIRST
         ->  Foreign Scan on digoal.userinfo_3  (cost=100.00..140.38 rows=1137 width=48) (actual time=0.776..0.776 rows=3 loops=1)
               Output: userinfo_3.uid, userinfo_3.info, userinfo_3.crt_time
               Remote SQL: SELECT uid, info, crt_time FROM role3.userinfo_3 ORDER BY uid DESC NULLS FIRST
 Planning time: 0.261 ms
 Execution time: 4.007 ms
(18 rows)
```

```
mas1-> explain verbose update userinfo_1 set info=info where uid=1;
                                QUERY PLAN
---------------------------------------------------------------------------
 Update on digoal.userinfo_1  (cost=100.00..123.22 rows=5 width=54)
   ->  Foreign Update on digoal.userinfo_1  (cost=100.00..123.22 rows=5 width=54)
         Remote SQL: UPDATE role1.userinfo_1 SET info = info WHERE ((uid = 1))
(3 rows)
```

DML

继承、触发器问题

- 通过分区列约束筛选对应分区
- 通过触发器将数据写入对应分区
- 哈希分区的问题，查询时必须带上哈希函数

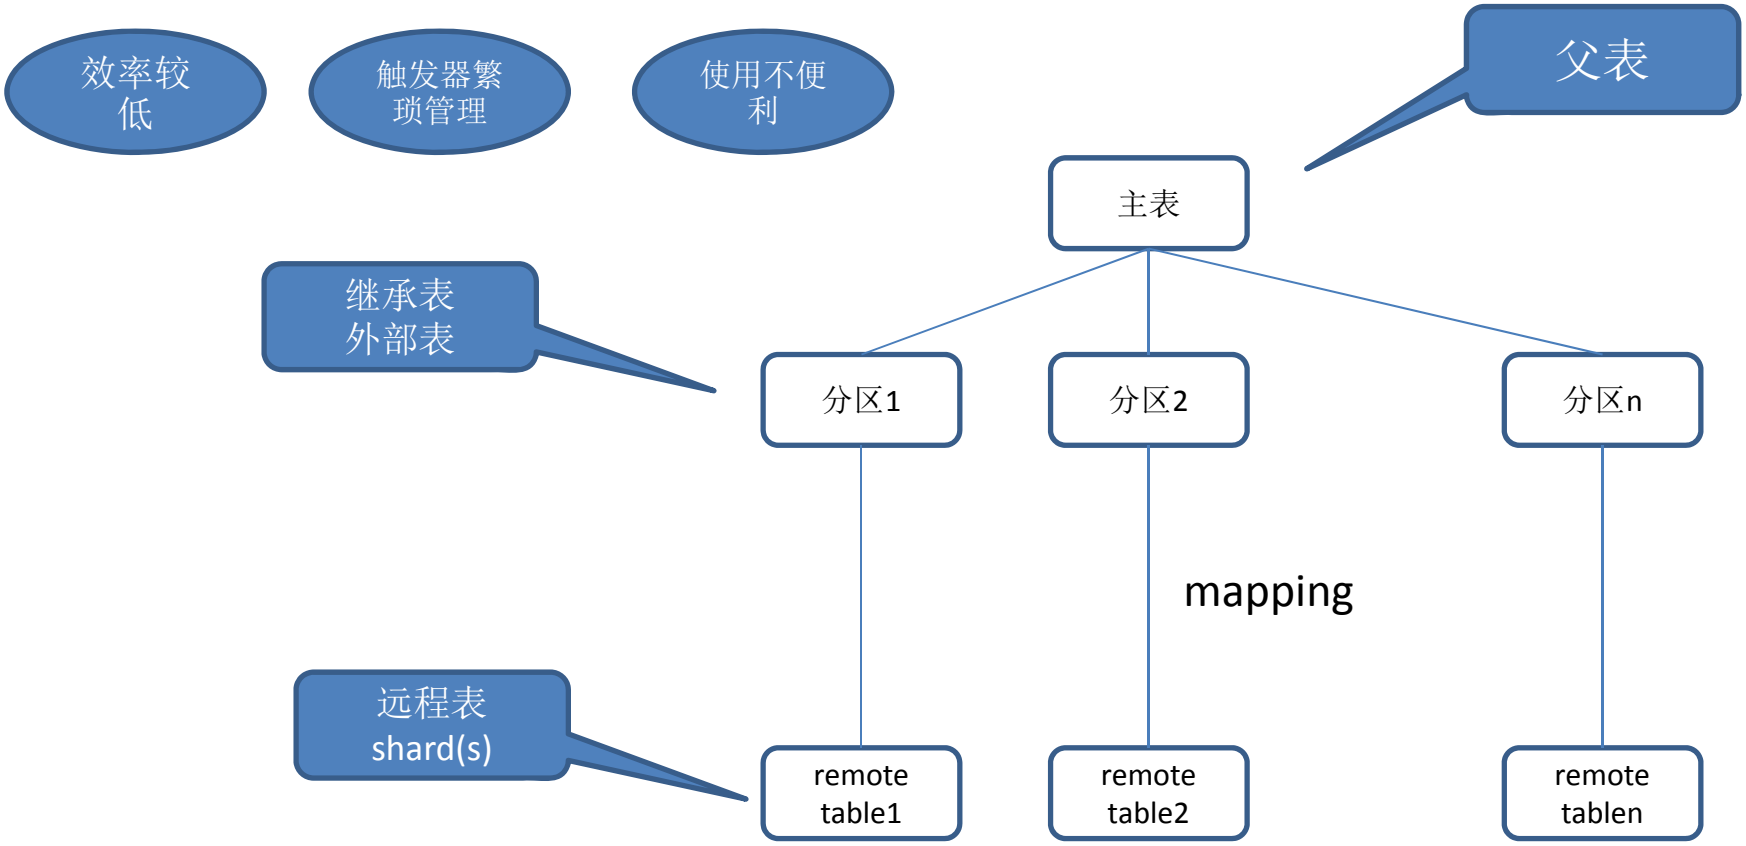

pg_pathman

- 支持HASH, range分区
- 支持自动分区、手动分区（合并、拆分、新增、删除、绑定）
- 支持大多数数据类型
- 执行计划高效（JOIN \ SUBQUERY）
- 动态选择分区（subquery）
- 高效插入、COPY FROM\TO（非触发器，使用HOOK替换rel oid）
- 支持自动扩展分区(范围分区)
- 支持更新分区列
- 支持分区DDL回调函数（如支持DDL逻辑复制）
- 非堵塞式迁移数据
- 支持FDW

CASE

segment 1 : 127.0.0.1:5281:db0:role0:pwd , schema_name role0
segment 2 : 127.0.0.1:5281:db1:role1:pwd , schema_name role1
segment 3 : 127.0.0.1:5281:db2:role2:pwd , schema_name role2
segment 4 : 127.0.0.1:5281:db3:role3:pwd , schema_name role3
master 1 : 127.0.0.1:5281:mas1:digoal:pwd , schema_name digoal
master 2 : 127.0.0.1:5281:mas2:digoal:pwd , schema_name digoal

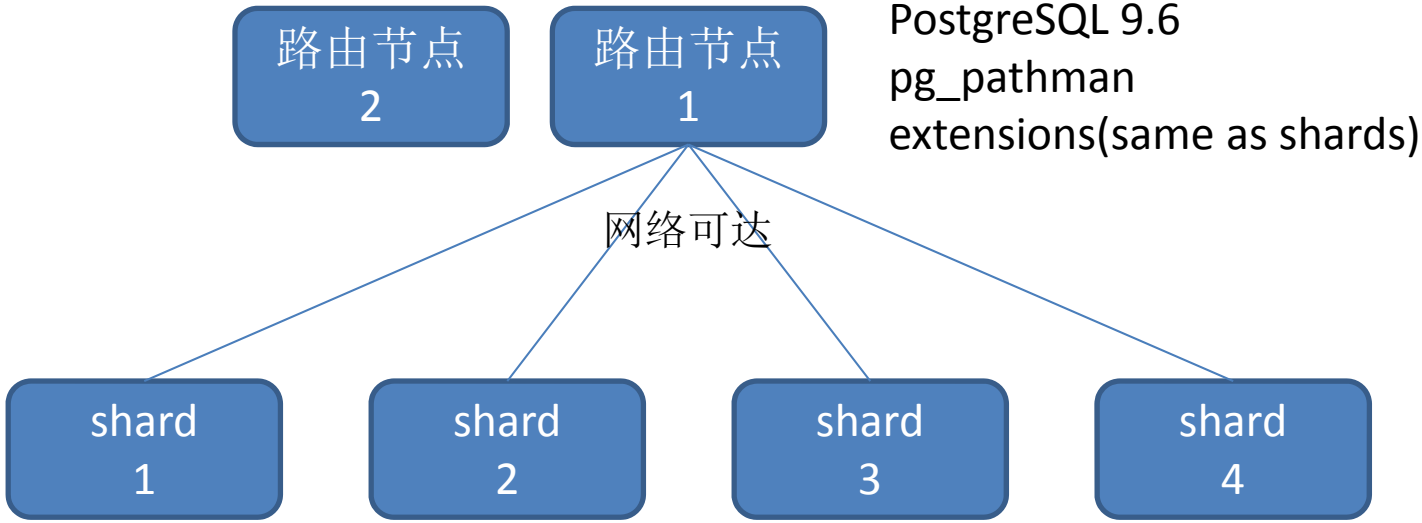

PostgreSQL 9.6
pg_pathman
extensions(same as shards)

PostgreSQL 任意版本
extensions (opt)
支持阿里云RDS PGSQL

场景设计

userinfo 增删改查
新增用户、销毁用户、
修改用户资料、查询用户资料

user_log 增查
新增用户登陆日志、查询用户日志

user_membership 增删查
新增用户关系，
删除用户关系，
查询用户关系

user_membership_rev 增删查
新增反向用户关系，
删除反向用户关系，
查询反向用户关系

mv_user_membership 刷新、查询
mv_user_membership_rev 刷新、查询
聚合物化视图，提高关系查询效率，
刷新物化视图，
查询物化视图

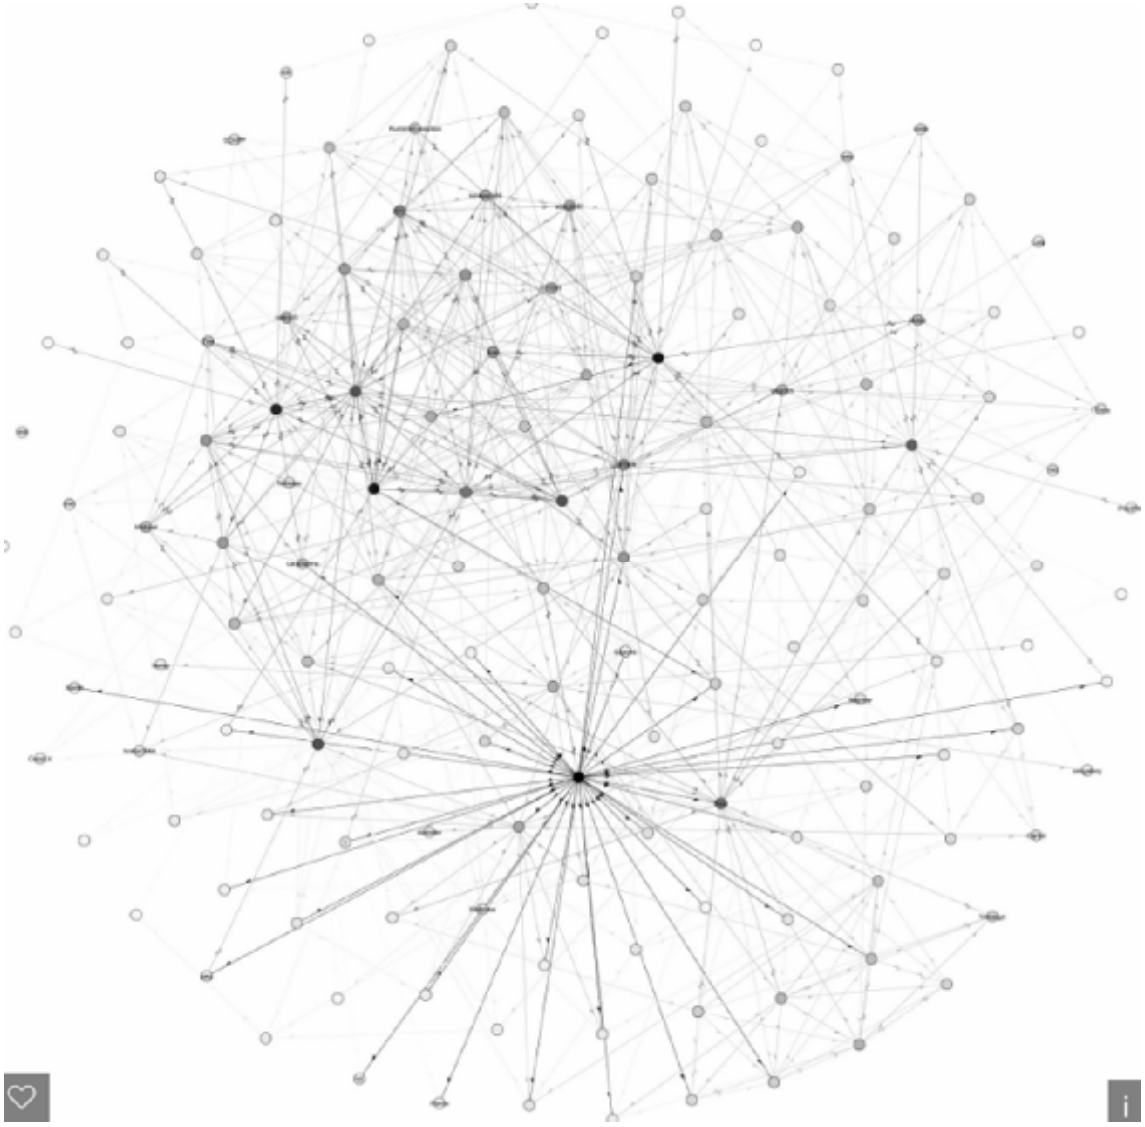

配置

- 准备路由节点、数据节点
- func (arg jsonb(url,ddl)) $$
  - create extension pg_pathman
  - create foreign server for all datanode on routenode
  - run DDL on all DATANODE
  - import foreign schema on routenode
  - create partition table on routenode
  - attach foreign table to partition table(specify range or hash bound)
- $$
- use partition table

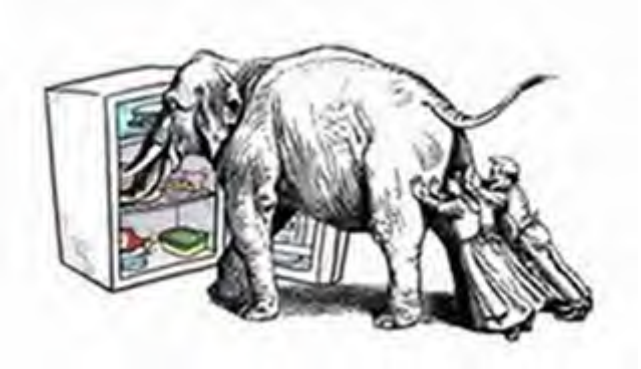

负载均衡、HA

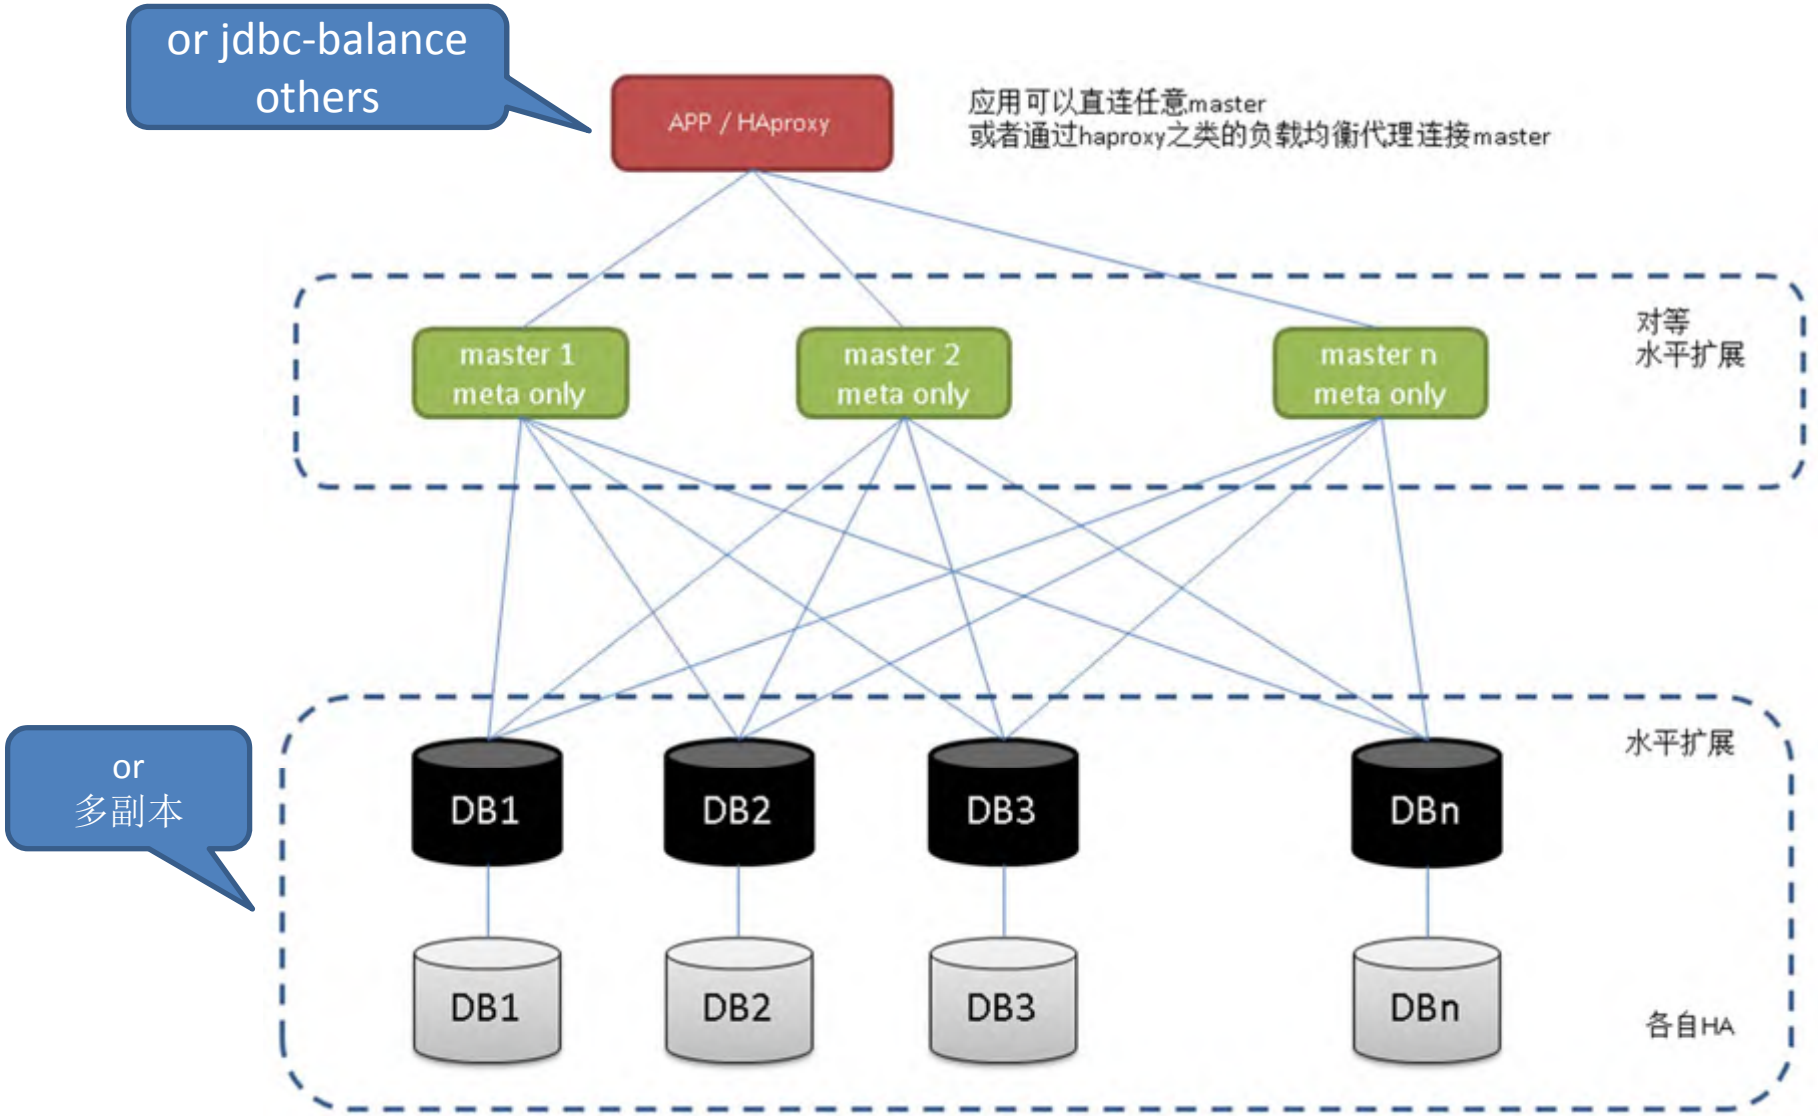
or jdbc-balance
others
APP / HAproxy
应用可以直连任意master
或者通过haproxy之类的负载均衡代理连接master
master 1
meta only
master 2
meta only
master n
meta only
对等
水平扩展
or
多副本
DB1
DB2
DB3
DBn
水平扩展
DB1
DB2
DB3
DBn
各自HA

路由节点/shard节点 扩容、缩容、迁移

- 路由节点
  - 扩容
  - 缩容
  - 迁移
- 数据节点
  - 扩容
  - 缩容
  - 迁移

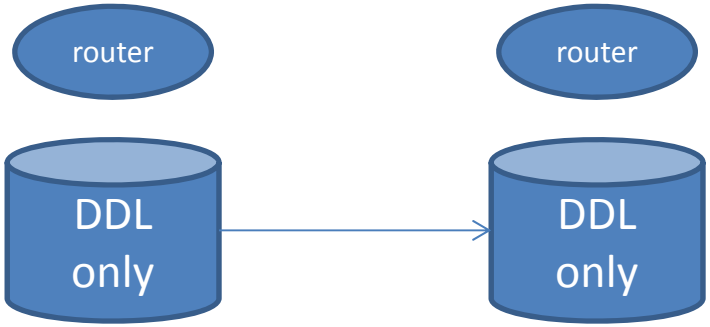

预分片
split 分片

logical replication
detach
attach

全局一致性备份

- barrier
- 时间点恢复

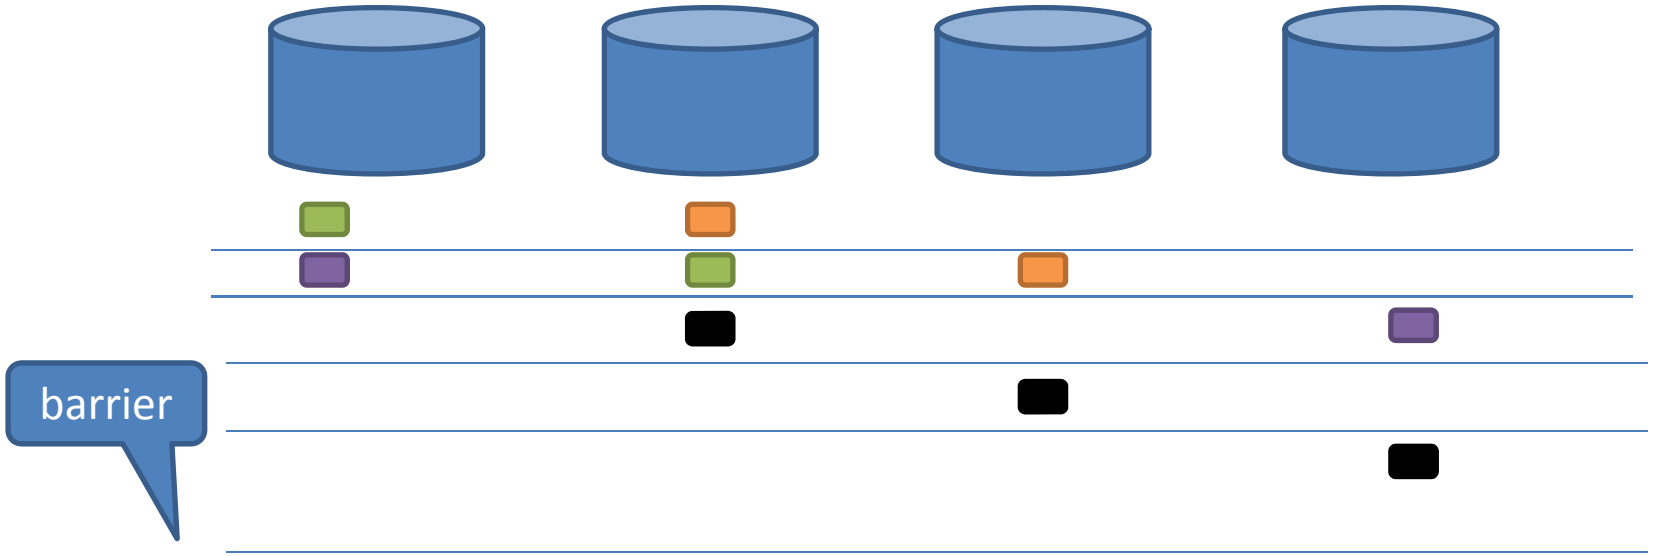

其他

- remote 连接稳定性，超时
  - 认证超时、TCP超时、QUERY超时、LOCK超时
- 分布式事务
- 聚合 pushdown (10.0)
- append 并行化

- 本案详细文档
- https://github.com/digoal/blog/blob/master/201610/20161004_01.md
- https://github.com/digoal/blog/blob/master/201610/20161005_01.md
- https://github.com/digoal/blog/blob/master/201610/20161024_01.md
- https://github.com/digoal/blog/blob/master/201610/20161027_01.md