

SACC 第八届中国系统架构师大会
2016 SYSTEM ARCHITECT CONFERENCE CHINA 2016

架构 创新之路

腾讯云数据库CDB技术演进之路

目录

- 云数据库概览
- CDB之存储篇
- CDB之复制篇
- CDB之引擎篇

云数据库概览-什么是云数据库



NIST关于云计算服务的基本特征定义

- ✓ 按需应变自助服务
- ✓ 随时随地用任何网络设备访问
- ✓ 多人共享资源池
- ✓ 快速重新部署灵活度
- ✓ 可被监控与量测的服务

□ 满足云计算特征的数据库服务

□ 数据库内核+云化功能

云数据库概览-鹅厂的云数据库

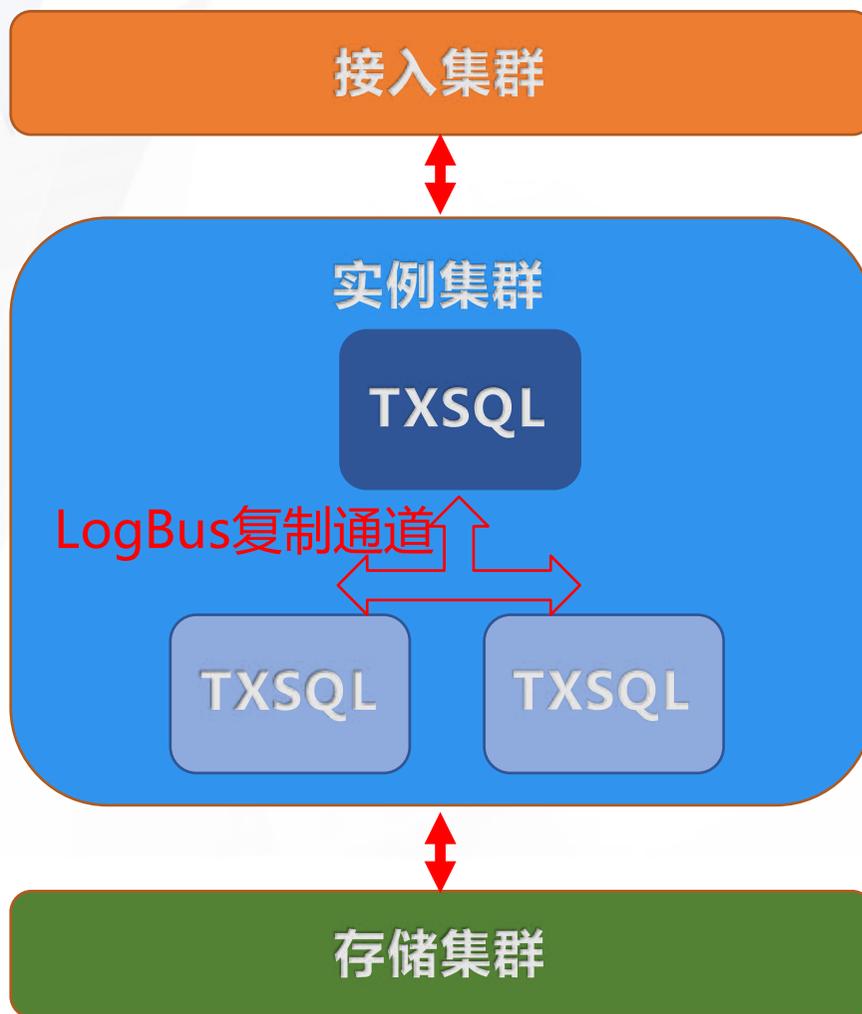


□ SQL



□ NoSQL

云数据库概览-CDB内核技术栈



- ✓ 路由
- ✓ 安全
- ✓ HA

- ✓ 数据库引擎
- ✓ 多副本复制

- ✓ 数据存储

CDB之存储篇-三次存储革命



- 根据存储介质特性，进行数据库存储技术设计
- 数据库存储的本质：面向块的存储

CDB之存储篇-第一次革命

□ SAS Raid存储的主要矛盾

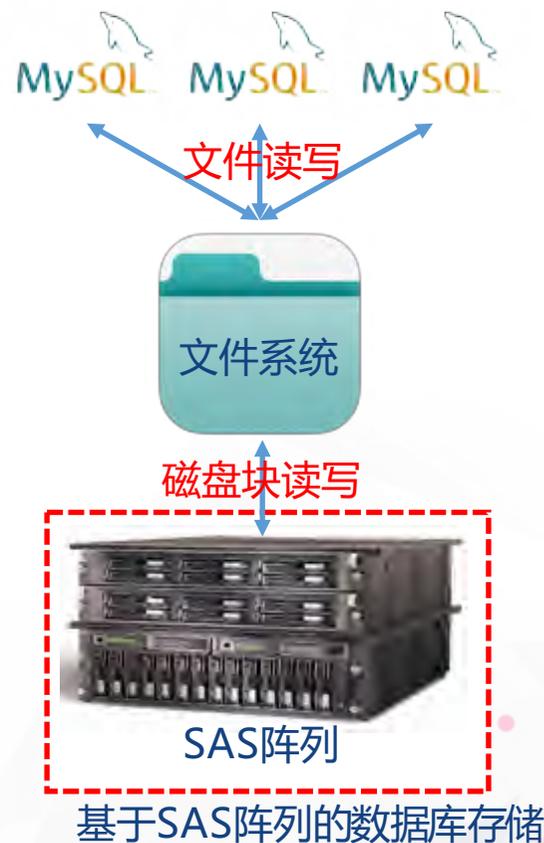
- ✓ 性能问题：随机IO性能不高
- ✓ 扩展性问题：单机最大存储容量受限
- ✓ 成本问题：价格贝佐斯定律带给成本的挑战

□ SSD Raid存储可行性

- ✓ 选择SATA SSD：2011年PCI-E SSD刚刚兴起
- ✓ 性能问题：随机IO性能有较大提升
- ✓ 扩展性问题：依旧存在
- ✓ 成本问题：单位存储成本更高
- ✓ SSD使用的问题：写放大、写性能下降

□ 解决问题的思路

- ✓ 基于SSD的存储系统有吗？分布式KV
- ✓ 分布式KV解决了性能、扩展性、SSD使用问题
- ✓ 分布式KV和数据库存储的联系：block
- ✓ 块block的数据模型(Disk, LBA, Value) <-> (Key, Value)



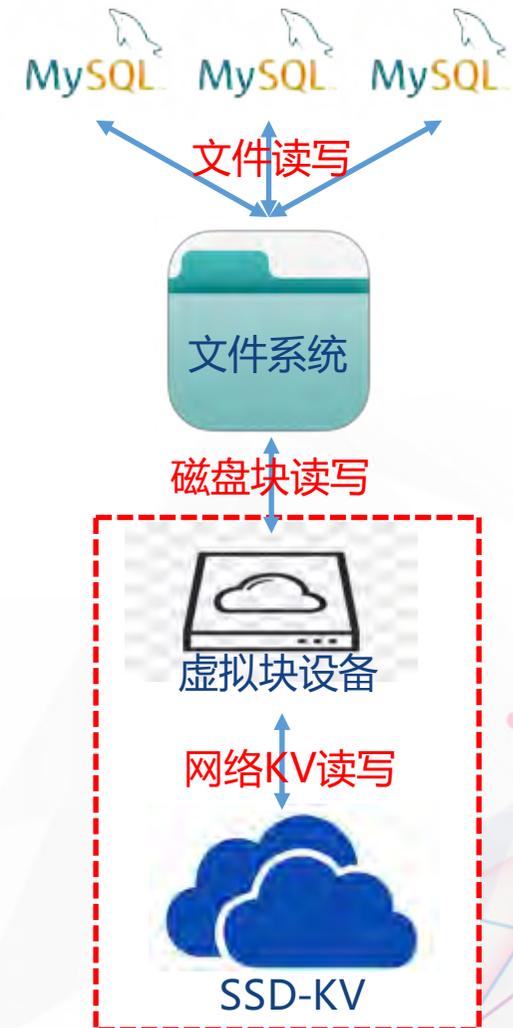
CDB之存储篇-第一次革命(Cont.1)

□ SSD Cluster1.0存储

- ✓ 虚拟块设备+IO网络化→块读写转化为KV操作
- ✓ 适配SSD特性的KV存储系统
- ✓ MySQL层优化：千兆网络瓶颈 & 去double write
- ✓ 文件系统&块设备调优
- ✓ 成本问题：按需分配、动态伸缩、

□ 运营中的故事

- ✓ 存储集群的蝴蝶效应



基于SSD Cluster1.0的数据库存储

CDB之存储篇-第二次革命

□ SSD Cluster1.0的主要矛盾

- ✓ 开发商的变化：IO密集型核心应用上云
- ✓ 存储介质的变化：PCI-E SSD量大价低
- ✓ 性能不够，性价比没优势

□ PCI-E SSD Cluster存储可行性

- ✓ IO性能：相比本地，网络和分布式带来额外开销
- ✓ 扩展性：单机最大本地存储6T
- ✓ SSD使用的问题：SSD FTL的进一步优化
- ✓ 成本问题：相比本地，优势有，但已不是主要矛盾
- ✓ 运维成本：相比本地，更高

□ 解决问题的思路

- ✓ 选择本地PCI-E SSD
- ✓ 选择新的技术制高点：数据库引擎本身的性能和稳定性



CDB之存储篇-第三次革命

□ PCI-E SSD的主要矛盾

- ✓ 开发商的变化：金融、政企等数据库上云
- ✓ DB要求：兼容性、RTO、RPO、扩展性四个都不能少
- ✓ 扩展性问题：容量无法和SAN\NAS\专有存储相比
- ✓ 中间件sharding解决了扩展性问题，但兼容性有问题

□ 解决问题的思路

- ✓ 主要目标：100TB以下，SQL完全兼容的传统行业DB服务
- ✓ **SDP：Shared Disk Parallel**
- ✓ 数据库节点和存储分离，数据库节点有主从之分
- ✓ 尽量减少IO次数：主数据库节点才能写存储集群，从节点不会写

CDB之复制篇-三种复制模式

异步复制

半同步复制

强一致复制

阶段1

阶段2

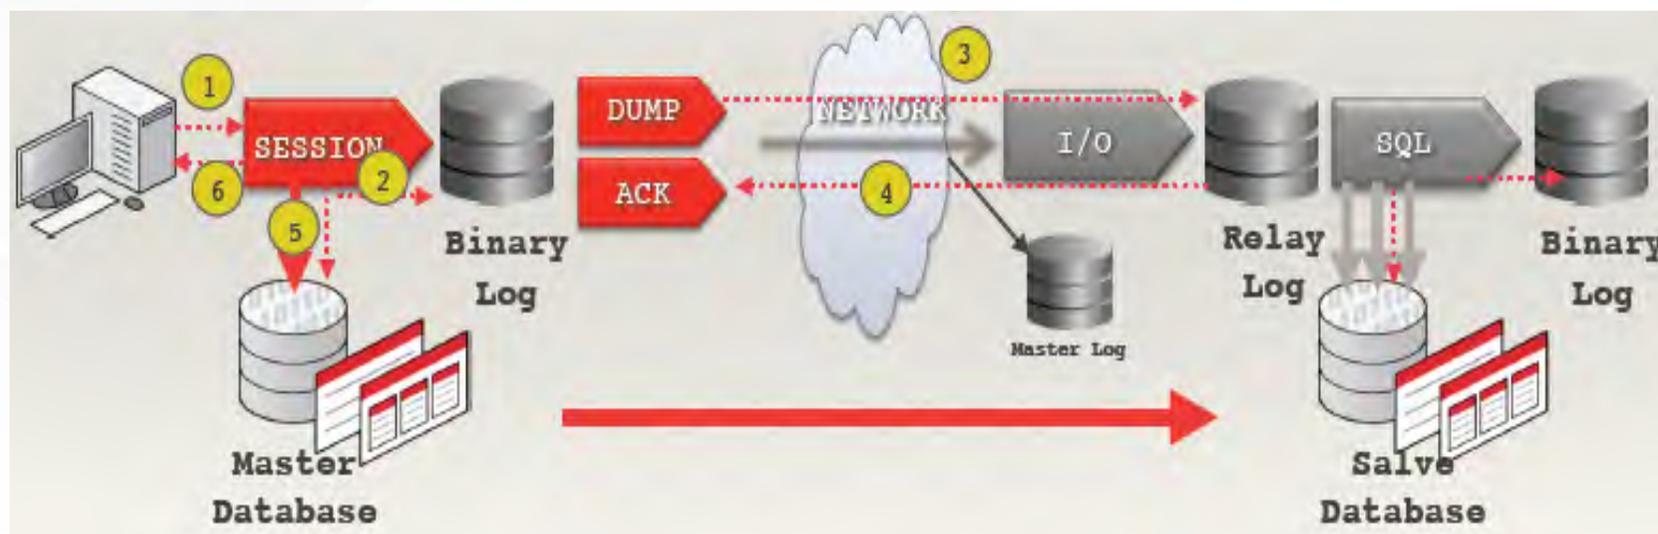
阶段3

□ 复制结合机房部署，灵活选择，达到最有效的容灾效果

CDB之复制篇-半同步的一些问题

□ MySQL半同步的主要问题

- ✓ 无法做到**强一致**：自动降级、灵活的多zone部署下的一致性要求
- ✓ 半同步下**性能**下降多



MySQL Native Semi Sync Replication

CDB之复制篇-性能优化

□ 性能关键因子

- ✓ 单个事务耗时：用户层面的响应时间，每个事务耗时多少ms
- ✓ 系统整体吞吐：服务层面的处理能力，一台机器每秒能处理事务数(TPS)

□ 单个事务耗时

- ✓ $T_{total} = T_{sql} + T_{engine} + T_{replicate}$
- ✓ T_{sql} 和 T_{engine} 在同步复制下不是关键瓶颈
- ✓ $T_{replicate} = T_{binlog网络传输} + T_{slave落地binlog}$ ， $T_{binlog网络传输}$ 取决于RTT值
- ✓ 测试数据：
 - ✓ 全cache下MySQL异步单事务耗时3.37ms；
 - ✓ 半同步单事务耗时8.33ms，测试环境RTT值2.6ms， $T_{slave落地binlog}$ 为1.9ms
 - ✓ 测试机器顺序512B的write+fsync延时0.13ms， $T_{slave落地binlog}$ 优化空间大

□ 系统整体吞吐

- ✓ 吞吐=并发数/单个事务耗时
- ✓ 并发数取决于各种资源的利用率，如master的事务线程、master的binlog发送/响应线程、slave的binlog接收线程等利用率情况

CDB之复制篇-性能优化(Cont.1)

□ MySQL slave的IO线程接收binlog耗时原因

- ✓ 锁冲突：IO/SQL线程间的锁冲突，如元数据文件锁
- ✓ 小IO消耗：IO线程离散小磁盘IO消耗过多的IOPS
- ✓ 串行化：IO线程接收和落盘操作串行

□ 构建独立于MySQL的快速复制通道logbus

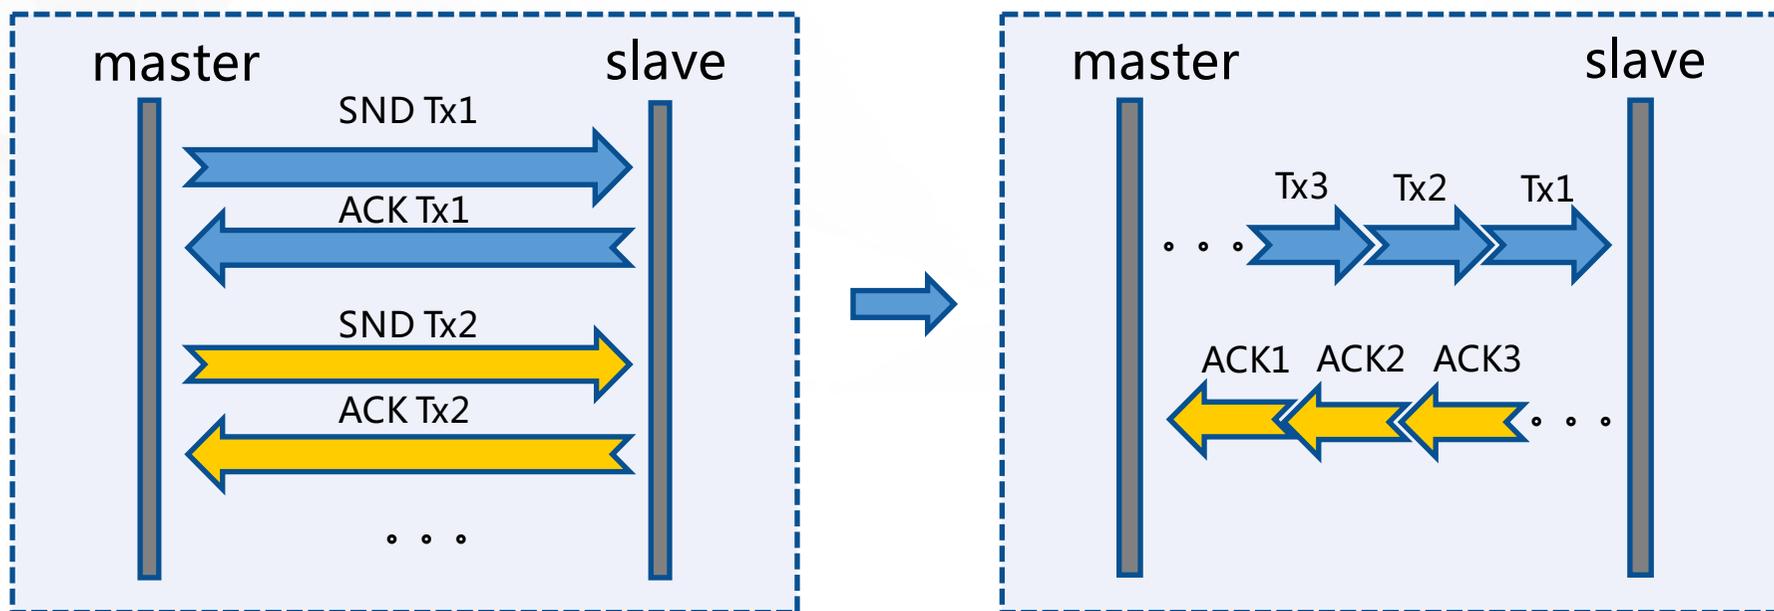
- ✓ 基于semisync协议，模拟slave向master建立主从关系，同步binlog
- ✓ 避免原生相关耗时瓶颈
- ✓ 外置logbus，减少对MySQL的侵入，方便各种分支兼容

数据库版本	同步类型	TPS	单事务耗时(ms)	同步RTT	性能基准对比
MySQL5.7	异步	33193	3.82	2.60	100%
MySQL5.7	半同步	15395	8.32	2.60	46.30%
MySQL5.7	logbus	22169	5.92	2.60	66.79%

CDB之复制篇-性能优化(Cont.2)

□ 优化MySQL 5.6的binlog发送、响应

- ✓ binlog同步阻塞传输模型：master binlog dump线程发送某个事务binlog后，等待slave回包后，再发送下一个事务binlog。理论上最大QPS=1000/RTT(ms)。一般情况同城跨园区之间RTT为3ms左右，QPS_{峰值}约330
- ✓ 方案：master binlog发送和接收异步化，dump线程负责发送，ack线程负责处理回包，通知事务线程继续提交



CDB之引擎篇-TXSQL

面向运维优化

面向bug优化

面向性能优化

深度定制

阶段1

阶段2

阶段3

阶段4

□ 自研技术：20+

□ 社区红利：30+

THANKS

SequeMedia
盛拓传媒

IT168.com
中国网络 16 年

ChinaUnix

ITPUB
www.itpub.net