

本文是作者在ACMUG 2016 MySQL年会上的演讲内容，版权归作者所有。

中国MySQL用户组（China MySQL User Group）简称ACMUG。

ACMUG是覆盖中国MySQL技术爱好者的一个技术社区，是Oracle User Group Community和MariaDB Foundation共同认可的MySQL技术社区。

我们关注MySQL, MariaDB, 以及其他一切周边的开源数据库和开源工具，我们交流使用经验，推广开源技术，为开源贡献力量。

我们是开放社区，欢迎任何关注MySQL及其相关技术的人加入，我愿意跟其他任何技术组织和团体保持沟通和展开合作。

我们期望在我们的活动中大家都能以开心的、轻松的姿态交流技术，分享技术，形成一个良性循环，从而每个人都可以有一份收获。

ACMUG的口号：开源，开放，开心

关注ACMUG公众号，参与社区活动，交流开源技术，分享学习心得，一起共同进步。





腾讯云

# 云数据库服务CDB技术演进和实践

CDB for MySQL：腾讯规模最大的关系型数据库服务



Tencent's Largest Relational Database Service

程彬 2016.12.10@ACMUG年会V0.9

# ||大纲

1. 云数据库概览

2. CDB之存储实践

3. CDB之复制实践

4. CDB之引擎实践

# 个人介绍

程彬  
bencheng

- 腾讯-技术工程事业群-基础架构部
- 08年加入腾讯，一直从事数据存储相关工作
- 11年开始从事MySQL Cloud相关研发工作
- 2016年4月16日，邂逅了ACMUG



# 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


- ✓ 随需应变自助服务
- ✓ 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

- 
- p 产品定义：满足云计算特征的数据库服务
  - p 技术定义：数据库内核+云化功能

# 云数据库概览 - 鹅厂的云数据库系列



p SQL



p NoSQL



# CDB For MySQL - 概览

PB+

1W+

1W+

90%+

- ✓ 腾讯基于MySQL的DBaaS(DataBase as a Service), 腾讯最大规模的关系型数据库服务
- ✓ PB级别存储规模, 万级别的机器数, 万级别的开发商数
- ✓ 占腾讯云所有关系型数据库类产品总收入的90%+
- ✓ 工信部认证: 99.95%可用性, 99.9996%数据可靠性
- ✓ 覆盖行业: 游戏、金融、移动、视频等




# CDB For MySQL - 腾讯内部业务代表



除了传统的社交、游戏之外，微信红包、微信支付、QQ彩票等金融交易类业务也是重要用户

# CDB For MySQL - 内核技术栈




- ✓ 路由(分片)
- ✓ 安全
- ✓ HA

- ✓ 数据库引擎
- ✓ 多副本复制

- ✓ 数据存储

# 存储篇 - 三次存储革命



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


# 存储篇 - 从本地SAS盘走向SSD集群1.0

## ✓ 本地SAS盘存储的主要矛盾

- ✓ 随机IO性能低
- ✓ 单机最大存储容量受限
- ✓ 贝佐斯定律玩不转-给用户降价慢

## ✓ 当时可能的解决方案


- ✓ 性能：优化存储引擎、采用SSD
- ✓ 容量：加更多的磁盘、换更大的盘
- ✓ 成本：存储压缩、高风险存储超卖



## ✓ 分布式存储能解决的问题

- ✓ 性能扩展
- ✓ 容量扩展
- ✓ 安全的超卖：按需分配、动态伸缩

# 存储篇 - 从本地SAS盘走向SSD集群1.0(Cont.1)




- ✓ 分布式存储遇到的问题
  - ✓ 网络IO延时、带宽
  - ✓ 存储集群的蝴蝶效应

# 存储篇 – 从SSD集群1.0走向本地SSD

## ✓ SSD集群1.0的主要矛盾

- ✓ IO密集型核心应用上云，更高性能要求
- ✓ SSD存储介质的发展：量大价低，单机12T



## ✓ 本地SSD存储下，数据库如何建立亮点

- ✓ 用好SSD：基础块设备调优、SPDK
- ✓ 选择新的技术制高点：数据库引擎本身的性能和稳定性



# 存储篇 - 从本地SSD走向SSD集群2.0

## ✓ 本地SSD的主要矛盾

- ✓ 金融、政企等数据库上云
- ✓ 容量无法与SAN\NAS\专有存储相比
- ✓ 中间件sharding解决了扩展性，但兼容性有问题

## ✓ SSD集群2.0思路


- ✓ 目标：100TB、SQL完全兼容的传统行业DB服务
- ✓ 思想：基于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
- ✓ 主从之间原生binlog复制被基于block的物理复制替代

# || 复制篇 - 三种复制模式



p 复制结合机房部署，灵活选择，达到最有效的容灾效果

# || 复制篇 - 数据同步的要求



数据库版本	同步类型	TPS	单事务耗时	同步RTT	性能基准对比
MySQL5.7	异步	33193	3.82ms	2.60ms	100%
MySQL5.7	半同步	15395	8.33ms	2.60ms	46.30%

强一致下的性能损耗

- ✓ 复杂业务环境下的数据同步要求
- ✓ 灵活的多zone部署下的一致性要求
- ✓ 强一致下的性能要求

# || 复制篇 - 同步性能优化分析

✓ 问题：跨园区下，同步性能损耗大

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	8.33	2.60	46.30%

✓ 分析：同步复制下，单个事务耗时

- ✓  $T_{total} = T_{sql} + T_{engine} + T_{replicate}$
- ✓  $T_{sql}$  和  $T_{engine}$  和复制无关，受限单机处理性能
- ✓  $T_{replicate} = T_{binlog\ 网络传输} + T_{slave\ 落地binlog}$ ,  $T_{binlog\ 网络传输}$  取决于RTT值
- ✓ 测试数据验证：

$$T_{slave\ 落地binlog} = 8.33ms - 3.82ms(\text{约等于sql加engine耗时}) - 2.60(\text{RTT耗时}) \\ = 1.91ms$$

- ✓ 模拟写binlog：SAS盘上顺序写512B的write+fsync的耗时为0.13ms
- ✓ 问题来了： $1.91 - 0.13 = 1.78ms$ 去哪儿呢？


# || 复制篇 - 同步性能优化实现

✓ 问题：MySQL slave的IO线程接收master的binlog延时比较大

✓ 分析：对slave IO线程耗时进行深入分析

- ✓ 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


✓ 方案：构建独立于MySQL的快速复制通道logbus



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

基于logbus的复制架构

# 引擎篇 – Tencent MySQL(TXSQL)



p 自研技术10+、社区红利30+

p 积极拥抱开源社区

# 引擎篇 - TXSQL特性功能概览





腾讯云

# CDB for MySQL：腾讯规模最大的关系型数据库服务

欢迎关注公众号：**腾讯云数据库CDB**



Tencent's Largest Relational Database Service