腾讯

专有云数据库 TDSQL

白皮书

V2.0

腾讯云

目 录

1 前言

本文档针对腾讯专有云数据库 TDSQL 的市场定位及特点，帮助用户从产品架构、产品优势、产品功能、应用场景等方面全面了解本产品。

本文档主要适用于以下工程师：

- 技术支持工程师
- 维护工程师

2 通用约定

表 1: 格式约定

格式	说明	样例
	该类警示信息将导致系统重大变更甚至故障，或者导致人身伤害等结果。	 危险：重置操作将丢失用户配置数据。
	该类警示信息可能导致系统重大变更甚至故障，或者导致人身伤害等结果。	 警告：重启操作将导致业务中断，恢复业务所需时间约10分钟。
	用于警示信息、补充说明等，是用户必须了解的内容。	 注意 ：导出的数据中包含敏感信息，请妥善保存。
	用于补充说明、最佳实践、窍门等，不是用户必须了解的内容。	 说明：您也可以通过按**Ctrl + A**选中全部文件。
>	多级菜单递进。	设置 > 网络 > 设置网络类型
粗体	表示按键、菜单、页面名称等UI元素。	单击 **确定**。
courier字体	命令。	执行 `cd /d C:/windows` 命令，进入Windows系统文件夹。
斜体	表示参数、变量。	`bae log list --instanceid` *Instance_ID*

[]或者[a|b]	表示可选项，至多选择一个。	ipconfig [-all|-t]
{}或者{a|b}	表示必选项，至多选择一个。	swich {stand | slave}

3 产品介绍

3.1 腾讯专有云数据库概述

腾讯专有云数据库（PCDB）是腾讯云数据库产品线的统称，腾讯云公有云已发布的绝大部分数据库都可实现企业用户可以在自有数据中心中部署。为了便于企业用户更好的选择，我们将专有云数据库拆解为 3 种类型的实现方案。

1. For ALL：即完整部署专有云数据库的全部引擎和模块，这意味着您将具有腾讯云数据库的完整能力。
2. For TDSQL/TBase：即主流的针对 MySQL 或 PostgreSQL 协议，分表部署 TDSQL 或 Tbase 产品，这意味着您将拥有 MySQL 或 PostgreSQL 协议的全部能力——关系型数据库（CDB）、分布式数据库（DCDB）、分析性数据库（ADB）——由于关系型数据库使用最广泛规模较大，因此这类方案可以给企业用户带来性价比较高的方案。
3. For MySQL、Redis、MongoDB 等：即企业用户可以根据需要，选择腾讯自研的某一种或几种引擎单独部署。

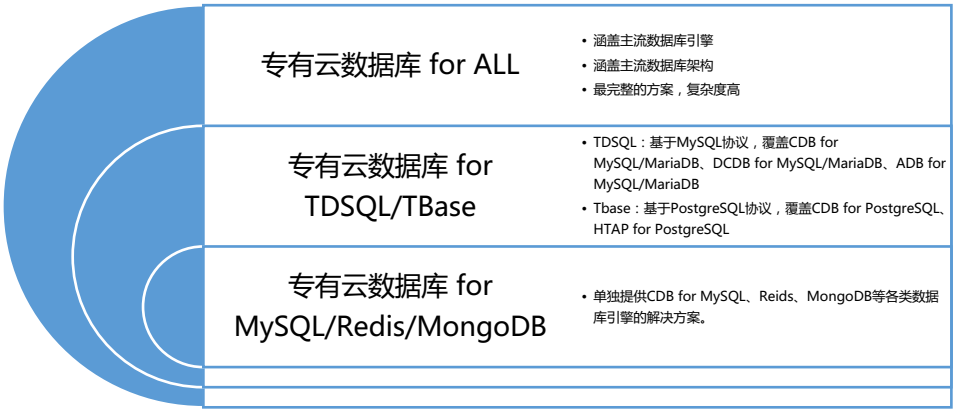

3.2 腾讯数据库 TDSQL 简介

腾讯数据库 TDSQL（Tencent Distributed MySQL，TDSQL）腾讯云数据库团队维护的金融级分布式架构和 MySQL 内核分支的统称，腾讯 90%的金融、计费、交易类业务核心系统承载在 TDSQL 中。目前已应用于众多政府、银行、保险、制造业、物流、电商等用户的核心系统中。TDSQL 可以提供专有云、公有云两种部署方案，可以分配 CDB（关系型数据库）实例、DCDB（数据库）实例、ADB（分析性数据库）实例，即 TDSQL 是腾讯专有云 MySQL 协议的 CDB、TDSQL、ADB 的集合；并提供数据复制（即强同步）、线程池、热点更新、内核优化等能力；并提供事前、事中、事后的全维度安全方案；以及获得多项国际和国家认证。

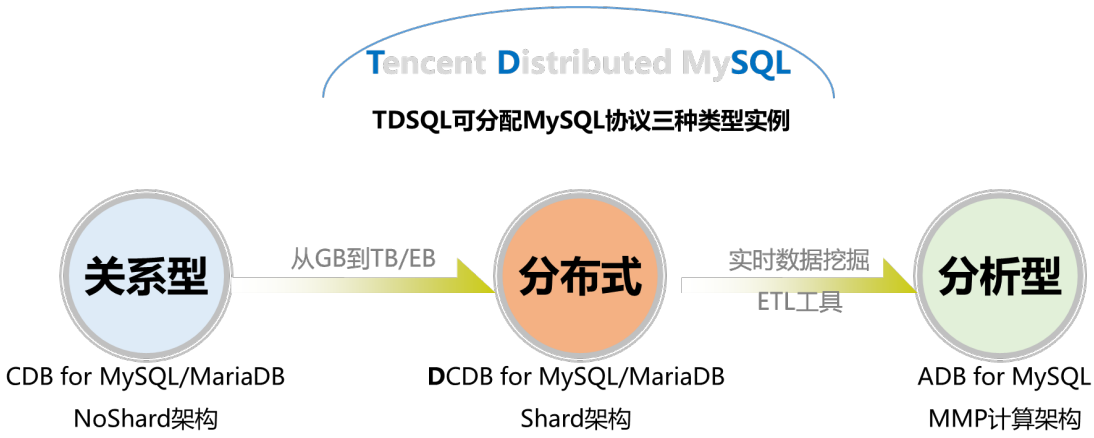

3.3 腾讯数据库 TDSQL 的发展历史

从 2004 年开始，腾讯核心业务便大规模使用分布式架构数据库，到目前已发展超过 13 年。目前，微众银行、理财通、微信支付、腾讯充值、阅文集团的众多核心业务都构建在腾讯分布式数据库之上。

腾讯公司99%金融计费的业务都采用TDSQL！

3.4 数据库相关概念

- **实例：** 用户实际使用的一个最小单位的数据库服务集合；一般来说，用户使用数据库可独立的享有数据库实例 IP、端口和账号；实例之间资源（权限、性能、数据空间）完全隔离；实例可能仅存于 1 台服务器上，也可能在不同的物理服务器上。一个数据库实例可以包含一个或多个用户创建的数据库等。
- **分片（Sharding）：** 在数据库中，由数据库引擎组成的物理实例，通常多个分片组成一个逻辑上的实例。
- **物理节点组（SET）：** 搭建数据集群的若干物理节点，通常这些节点基于数据库主从协议联结成若干组，这些物理节点组的统称叫做 SET。需要注意时，如果没有采用多租户（虚拟化技术），通常一个分片就等于一个 SET，如果采用多租户（虚拟化）技术，物理节点组（SET）中可能有多个分片。
- **数据库引擎、版本：** 每个数据库实例运行一个数据库引擎，数据库引擎是用于存储、处理和保护数据的核心服务，通常我们说的 MySQL、SQLServer、Oracle 就是引擎的叫法；每个数据库引擎又包括不同的软件版本，不同的数据库引擎版本都有自己支持的功能和特性。但请注意，innodb 等在本文中被叫做存储引擎，与数据库引擎并非相同概念。

  说明：TDSQL 当前支持的 MySQL 协议默认选择 Percona 或 MariaDB 分支（避免 Oracle 授权影响）。
- **集群：** 一个独立网络区域的 TDSQL 服务器集合集群；一般来说，先有集群才能在集群上分配实例。而集群中的设备互为冗余，集群通常包括主数据库服务器、多个备份数据库服务器、网络设备、数据备份集群等。通常多个集群可以共享一套管理系统。
- **实例规格：** 是定义数据库的使用大小、性能的一种综合指标。规格使用计算能力、内存、存储容量等多种指标进行定义。由于云计算的弹性能力，实例规格实际上是可以按需伸缩的，

用户可以选择在合适时机选择对规格进行扩容或缩小，以保障数据库引擎有足够的空间来写入内容和日志。

- **DDL**:数据库模式定义语言(Data Definition Language),主要的命令有 CREATE、ALTER、DROP 等。
- **DML**：数据库操纵语言（Data Manipulation Language），命令是 SELECT、UPDATE、INSERT、DELETE。
- **OLTP**：联机事务处理（On-Line Transaction Processing），是传统的关系型数据库的主要应用，主要是基本的、日常的事务处理，例如银行交易。
- **OLAP**：联机分析处理（On-Line Analytical Processing），是数据仓库系统的主要应用，支持复杂的分析操作，侧重决策支持，并且提供直观易懂的查询结果。
- **主机**：MySQL 数据节点中，直接承担读写的节点，简称主机（Master）；
- **从机**：以高可用高可靠为目的，让多个 MySQL 数据节点协同工作，并通过主从复制协议（REPLICATION）将主机数据复制一个协同节点中，简称从机（Slave）；从机通常只可读取数据，不可写入数据。
- 说明：部分文献中也称为“主从、从机”为“主备、备机”；为避免“备”一词与备份、冷备的定义产生混淆，本文一律采用“从”。
- **数据备份**：以容灾的基础，为防止灾难或故障导致数据丢失，而将全部或部分数据集合从应用主机的硬盘或阵列复制到其它的存储介质的过程；通常也叫做备份服务、数据冷备。
- **HDFS**：Hadoop 分布式文件系统，是一种被设计成适合运行在通用硬件(commodity hardware)上的分布式文件系统。
- **LVS**：一种常用的开源虚拟网络服务技术，在此处的作用类似于商用负载均衡服务 F5。

4 产品架构

4.1 数据库系统架构

TDSQL 采用集群架构，一套完整的腾讯数据库 TDSQL 系统由若干个分布架构子系统组成的集群，整个集群架构简图如下：

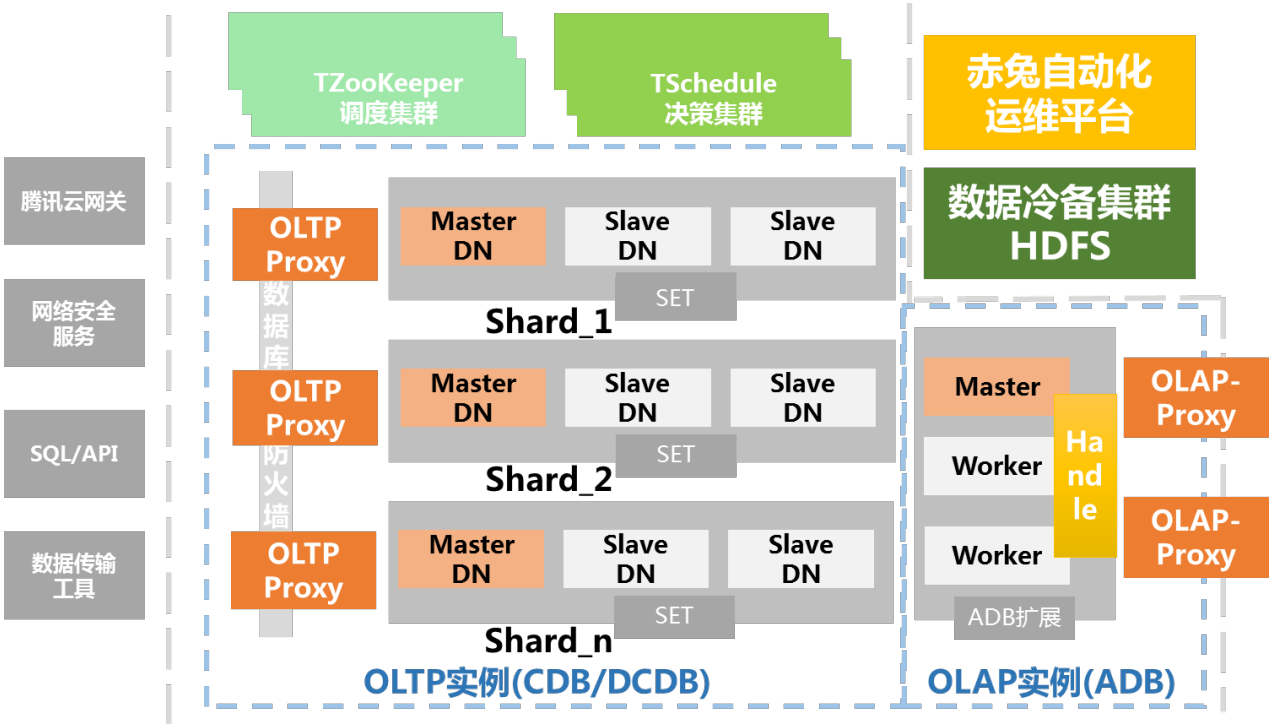

其中，TDSQL 最核心的五个主要模块是：调度集群（Tschedule）、物理节点组（SET）和接入网关集群（OLTP-Proxy），决策集群（TzooKeeper），赤兔自动化运维平台组成

- **物理节点组（SET）**：由 MySQL、监控和信息采集（TAgent）组成，通常情况下：
  1. SET 默认采用一主多从架构，通常部署在跨机架物理服务器中；
  2. 每个节点（DataNode）都部署 TAgent，并实时向决策集群上报，提供决策依据；
- **调度集群（TScheduler）：**帮助 DBA 或者数据库用户自动调度和运行各种类型的作业，比如数据库备份、收集监控、生成各种报表或者执行业务流程等等，TDSQL 把 Schedule、zookeeper、OSS（运营支撑系统）结合起来通过时间窗口激活指定的资源计划，完成数据库在资源管理和作业调度上的各种复杂需求。

- **决策集群（TzooKeeper）：**它是 TDSQL 提供配置维护、选举决策、路由同步等，并能支撑数据库节点组（分片）的创建、删除、替换等工作，并统一下发和调度所有 DDL（数据库模式定义语言）操作，通常决策集群需要采用奇数台，实际部署的时候应大于等于 3 组并跨机房部署。
- **赤兔自动化运维平台（CHITU）：**基于 TDSQL 定制开发的一套综合的业务运营和管理平台，同时也是真正融合了数据库管理特点，将网络管理、系统管理、监控服务有机整合在一起。
- **接入网关集群（OLTP-Proxy）：**在网络层连接管理 SQL 解析、分配路由。(请注意，OLTP-Proxy 并非腾讯云网关 TGW 集群)。

  1. OLTP-Proxy 通常与 MySQL 混合部署，也可以部署在不同物理设备中；
  2. 从配置集群（TzooKeeper）拉取数据库节点（分片）状态，提供分片路由，实现透明读写；
  3. 记录并监控 SQL 执行信息，分析 SQL 执行效率，记录并监控用户接入信息，进行安全性鉴权，阻断风险操作；
  4. OLTP-Proxy 通常可以直接访问，但仍然建议前端部署需部署可提供负载均衡能力网关，并由网关对用户提供唯一虚拟 IP 服务。

这种集群架构极大简化了各个节点之间的通信机制，也简化了对于硬件的需求，这就意味着即使是简单的 x86 服务器，也可以搭建出类似于小型机、共享存储等一样稳定可靠的数据库。

4.2 关系型数据库 CDB

4.2.1 关系型数据库（CDB）简介

MySQL/MariaDB 是世界上最流行的开源关系数据库，通过 TDSQL，您在几分钟内即可部署可扩展的 MySQL/MariaDB 数据库实例，为了便于与公有云概念相同，我们统一称其为关系

型数据库（CDB）实例。而且，TDSQL 系统为 CDB 实例提供自动化创建、销毁、备份、回档、监控、告警、快速扩容等数据库运维全套解决方案。

说明：MariaDB 由 MySQL 的创始人 Michael Widenius（英语：Michael Widenius）主导开发。MariaDB 是 MySQL 的最主要分支，主要由开源社区在维护，腾讯是其开源社区白金会员。MariaDB 采用 GPL 授权许可，完全兼容 MySQL，包括 API 和命令行，使之能轻松成为 MySQL 的代替品。由于 MySQL 所有权在 Oracle 公司手中，我们建议商用业务系统优先采用 MySQL 分支 MariaDB 或 Percona 等。

4.2.2 关系型数据库（CDB）实例的架构

关系型数据库只有一组分片（或 SET）组成（如下图），因此关系型数据库不存在跨节点操作，因此关系型数据库完全兼容 MySQL 协议，这意味着，已用于 MySQL 数据库的代码、应用程序、驱动程序和工具，您无需更改，即可与 CDB 实例配合使用。

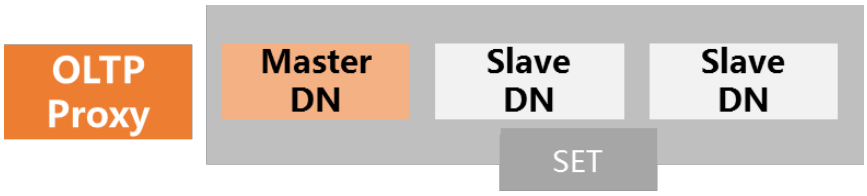

4.2.3 关系型数据库（CDB）的高可用

TDSQL 分配的所有实例都支持主从架构高可用架构，从单节点（一主零从）到一主多从，都可以支持。

高可用是构建大型，高性能业务系统是程序的基础。在绝大多数生产系统中，通常都需要用高可用方案来保证系统不间断运行；数据库作为系统数据存储和服务的核心能力，其可用要求高于计算服务资源。目前，常用的高可用方案通常是让多个数据库服务协同工作，当一台数据库故障，余下的立即顶替上去工作，这样就可以做到不中断服务或只中断很短时间；或者是让多台数据库同时提供服务，用户可以访问任意一台数据库，当其中一台数据库故障，立即更换访问另外

数据库即可。这类架构简称“**主从架构**”（也成为主备架构）。区别于共享存储、基于触发器、基于中间件的高可用架构方案，主从架构是目前使用最多、最广、性价比最高的方案。

由于数据库中记录了数据，想要在多台数据库中切换，数据必须是同步的，所以数据同步技术是数据库高可用方案的基础；当前，数据复制方式有以下三种方式：

- 异步复制：应用发起更新（含增加、删除、修改操作）请求，Master 完成相应操作后立即响应应用，Master 向 Slave 异步复制数据。因此异步复制方式下， Slave 不可用不影响主库上的操作，而 Master 不可用有概率会引起数据不一致。
- 强同步复制：应用发起更新请求，Master 完成操作后向 Slave 复制数据，Slave 接收到数据后向 Master 返回成功信息，Master 接到 Slave 的反馈后再应答给应用。Master 向 Slave 复制数据是同步进行的，因此 Slave 不可用会影响 Master 上的操作，而 Master 不可用不会引起数据不一致。

  注意:使用“强同步（不可蜕化）”复制时，如果主库与备库自建网络中断或备库出现问题，主库也会被锁住（hang），而此时如果只有一个主库或一个备库，那么是无法做高可用方案的。—— 因为单一服务器服务，如果股指则直接导致部分数据完全丢失，不符合金融级数据安全要求。
- 半同步复制（或强同步可蜕化）：半同步复制是 google 提出的一种同步方案，他的原理是正常情况下数据复制方式采用强同步复制方式，当 Master 向 Slave 复制数据出现异常的时候（Slave 不可用或者双节点间的网络异常）退化成异步复制。当异常恢复后，异步复制会恢复成强同步复制。半同步复制意味着 Master 不可用有概率会较小概率引起数据不一致。

4.3 分布式数据库 DCDB

4.3.1 分布式数据库（DCDB）简介

分布式数据库是当前所有大型互联网和大型系统的标配，TDSQL 提供 MySQL/MariaDB 协议的分布式数据库，为了便于与公有云概念相同，我们统一称其为分布式数据库（DCDB）实例。分布式数据库（DCDB）是支持自动水平拆分的高性能数据库服务——即业务感受完整的逻辑表，而数据却均匀的拆分到多个物理分片中，可以有效解决超大并发、超高性能、超大容量的 OLTP 类场景；DCDB 的每个分片默认采用主从高可用架构，提供弹性扩展、备份、恢复、监控等全套解决方案，为您有效解决业务快速发展时的数据库性能瓶颈，让您能更加专注于业务发展。而且，TDSQL 系统为 CDB 实例提供自动化创建、销毁、备份、回档、监控、告警、快速扩容等数据库运维全套解决方案。

4.3.2 分布式数据库（DCDB）实例的架构

分布式数据库 DCDB 由若干个分片（Shard）组成（如下图），因此分布式数据库可能存在大量的跨节点操作，因此分布式数据库并非完全兼容 MySQL 协议，这意味着，已用于 MySQL 数据库的代码、应用程序、驱动程序和工具，无法直接与 DCDB 实例配合使用。

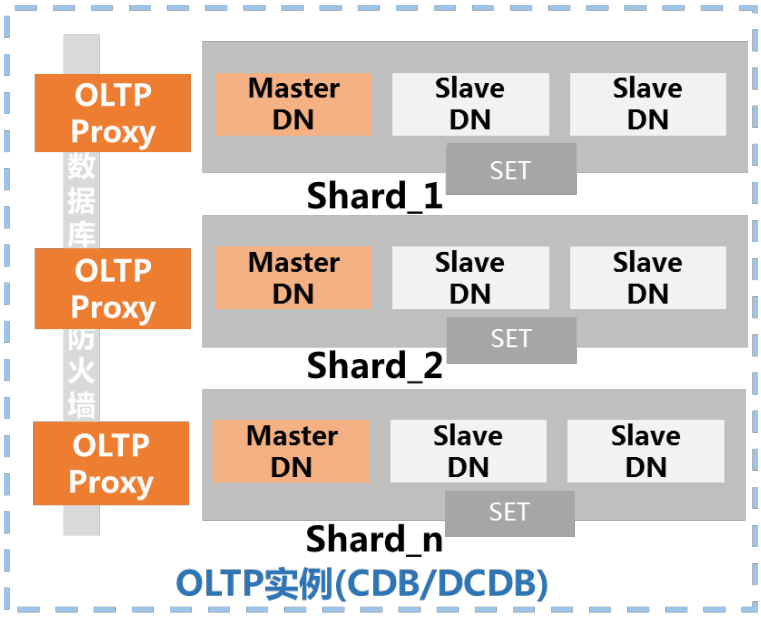

4.3.3 分库与分表介绍

在高性能并发互联网架构中，性能瓶颈往往出现在数据库服务器，特别是当业务(用户)达到百万级用户规模以后，通过在数据层进行合理的数据切分（shard），可以有效解决数据库性能、可伸缩等问题。数据库切分同样是从两个维度考虑：垂直切分(按功能切分)和水平切分。

4.3.3.1 分库

垂直切分(通常也叫做“分库”)也就是按功能切分数据库，这种切分方法跟业务紧密相关，实施思路也比较直接，比如“京东 JD”等电商平台，一个原有一个数据库实例，按功能切分为会员数据库、商品数据库、交易数据库、物流数据库等多个数据库实例，共同承担业务压力。

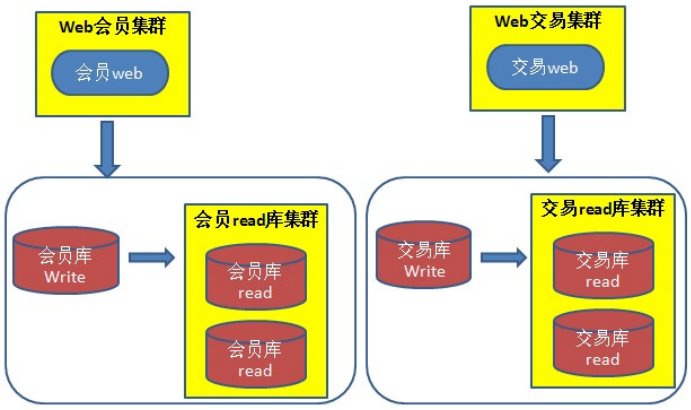

4.3.3.2 分表

有时候，垂直拆分并不能彻底解决压力问题，因为单台数据库服务器的负载和容量也是有限的，随着业务发展势必也会成为瓶颈，解决这些问题的常见方案就是水平切分了。

水平切分（又叫做“分表”、横向拆分等）是按照某种规则，将一个表的数据分散到多个物理独立的数据库服务器中，这些“独立”的数据库“分片”；多个分片组成一个逻辑完整的数据库实例。一般来说，分表的前提是分库。

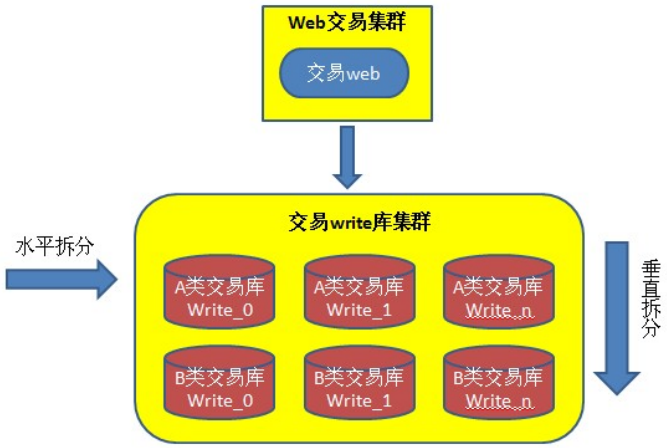

水平拆分的方案，实际上是分布式架构最直接体现，他与 RAC 等方案的最大不同点是，每个计算节点都参与计算和数据存储，每个计算节点都仅存储一部分数据。因此，数据库从架构上来讲，性能是可以线性增长的。

4.3.4 DCDB 分表原理简介

关系型数据库是一个二维模型，数据的切分通常就需要找到数据库表中某一字段作为拆分键（shardkey）以确定拆分维度，再通过定义规则来实现数据库的拆分，几种常见的分表规则如下：

- 基于日期顺序（Time），如取 shardkey 为时间字段，按年拆分，2015 年一个分片，2016 年一个分片。
- 基于某字段划分范围（Range），如取 shardkey 为用户 ID，0~1000 一个分片，1001~2000 一个分片。
- 基于某字段求模（HASH），如取 shardkey 为订单 ID，将求模（HASH）后按照 Range 方式分散到不同分片中。

无论是 Time、Range 都有个主要缺点就是可能导致严重数据倾斜，即多个分片之间负载和数据容量严重不均衡。例如，在大部分数据库系统中，数据有明显的冷热特征——显然当前的订单被访问的概率比半年前的订单要高的多——而单纯采用 Time 分表或 range 分表，就意味大部

分热数据将容易被路由在少数几个分片中，而存储冷数据的设备性能却被浪费掉了。

因此，DCDB 默认采用某个字段求模（HASH）的方案进行分表。因为 HASH 算法能够基本保证数据相对均匀的分散在不同的物理设备中。具体过程即记录(SQL)请求时被发起时，DCDB 会理解 SQL 语句的含义，然后按照拆分键的值和执行策略将 SQL 路由到对应分表进行执行，如下图所示，先通过 hash 算法计算，再路由到各个节点上。

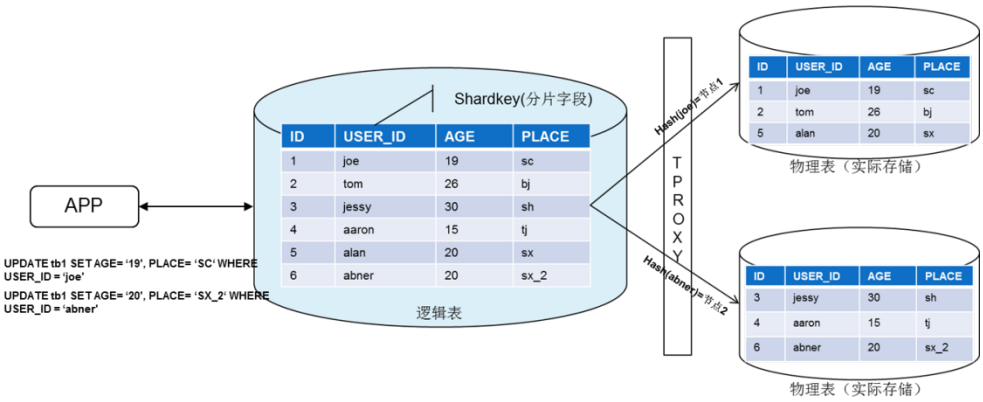

而如果一个查询 SQL 语句的数据涉及到多个分表，此时 SQL 会被路由到多个分表执行，DCDB 会将各个分表返回的数据按照原始 SQL 语义进行合并，并将最终结果返回给用户。

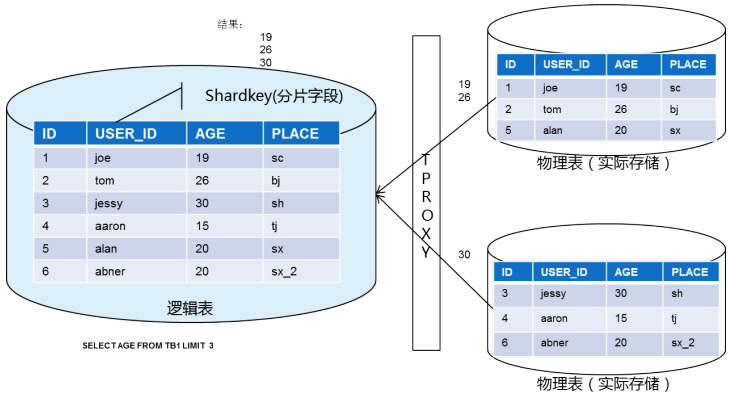

读取数据时（如果有明确 shardkey 值）：

- 业务发送 select 请求中含有 shardkey 时，网关通过对 shardkey 进行 hash
- 不同的 hash 值范围对应不同的分表

- 数据根据分表算法，将数据从对应的分表中取出

读取数据时（如果没有明确 shardkey 值）：

- 业务发送 select 请求没有 shardkey 时，将请求发往所有分表
- 各个分表查询自身内容，发回 Proxy；
- Proxy 根据 SQL 规则，对数据进行聚合，再答复给网关

从上述原理来看，查询 SQL 中含有 shardkey 值比不含 shardkey 值效率将会更高。

4.3.5 选择拆分键（shardkey）

拆分键是在水平拆分过程中用于生成拆分规则的数据表字段。DCDB 建议拆分键要尽可能找到数据表中的数据在业务逻辑上的主体，并确定大部分（或核心的）数据库操作都是围绕这个主体的数据进行，然后可使用该主体对应的字段作为拆分键，进行分表（该分表方案叫做 groupshard），如下图：

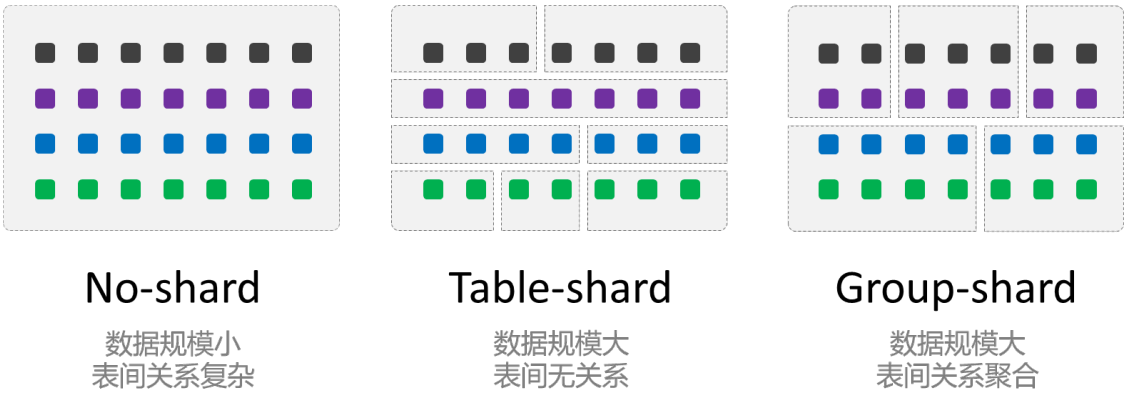

基于 Groupshard 的分表方案，确保可以确保某些复杂的业务逻辑运算，可以聚合到一个物理分片内。例如，某电商平台订单表和用户表都是基于用户维度（UserID）拆分，平台就可以很容易的通过联合查询（不会存在跨节点 join，或分布式事务）快速计算某个用户近期产生了多少订单。

下面的一些典型应用场景都有明确的业务逻辑主体，可用于拆分键：

- 面向用户的互联网应用 ,都是围绕用户维度来做各种操作 ,那么业务逻辑主体就是用户，可使用用户对应的字段作为拆分键；
- 电商应用或 O2O 应用，都是围绕卖家/买家维度来进行各种操作，那么业务逻辑主体就是卖家/买家，可使用卖家/买家对应的字段作为拆分键；但请注意，某些情况下几个超大卖家占到绝大多数交易额，这种情况会导致某几个分片的负载和压力明显高于其他分片，我们会在后面章节予以说明。
- 游戏类的应用，是围绕玩家维度来做各种操作，那么业务逻辑主体就是玩家，可使用玩家对应的字段作为拆分键；
- 物联网方面的应用 ,则是基于物联信息进行操作 ,那么业务逻辑主体就是传感器/SIM 卡，可使用传感器、独立设备、SIM 卡的 IMEI 作为对应的字段作为拆分键；
- 税务/工商类的应用，主要是基于纳税人/法人的信息来开展前台业务，那么业务逻辑主体就是纳税人/法人，可使用纳税人/法人对应的字段作为拆分键。

以此类推，其它类型的应用场景，大多也能找到合适的业务逻辑主体作为拆分键的选择。

4.3.6 同表不同拆分建的场景

在上面选择 shardkey 的例子都是基于一个维度查询，但如果是电商订单表，肯定即需要从用户维度查询，又需要从商户维度查询，那么如果这个系统会有多个主要的查询维度时，就会存在采用同表不同拆分建的场景；解决这类查询有两种方案

- 采用全表扫描，虽然这种场景会带来较大的读负载，但由于存在读写分离策略，此种方案也是可行的。
- 即使用异构索引表，其本质就是利用数据库多源同步工具，将原表内的每一次更新，都同步到数据库中的另一张结构相同，但拆分建不同的新的表中。这时，你只需要简单映

射一下，异构索引表的作用就基本等同于传统数据库中的索引概念。但此处由于经过了多源同步工具的，即新的表数据更新可能会有一定延迟。

4.3.7 拆分键选择的限制

普通的分表创建时必须在最后面指定 shardkey 的值，该值为表中的一个字段名字，会用于后续 SQL 的路由选择：

```
mySQL> create table test1 ( a int, b int, c char(20),primary key (a,b),unique key u_1(a,c) ) shardkey=a;
```

由于在 DCDB 下，shardkey 对应后端数据库的分区字段，因此必须是主键以及所有唯一索引的一部分，否则没法创建表，如下错误语句：mySQL> create table test1 (a int, b int, c char(20),primary key (a,b),unique key u_1(a,c),unique key u_2(b,c)) shardkey=a；此时有一个唯一索引 u_2 不包含 shardkey，没法创建表，会报如下错误：`ERROR 1105 (HY000): A UNIQUE INDEX must include all columns in the table's partitioning function`。因为主键索引或者 unique key 索引意味着需要全局唯一，而要实现全局唯一索引则必须包含 shardkey 字段。

除了上面的限制外，shardkey 字段还有如下要求：

a) shardkey 字段的类型必须是 int,bigint,smallint/char/varchar。

b) shardkey 字段的值不应该有中文，网关不会转换字符集，所以不同字符集可能会路由到不同的分区。

c) 不要 update shardkey 字段的值。

d) shardkey=a 放在 SQL 的最后面。

e) 访问数据尽量都能带上 shardkey 字段，这个不是强制要求，但是不带 shardkey 的 SQL

会路由到所有节点，消耗较多资源。

如果是广播表，此时该表在所有 set 中都是全量数据，这个主要方便于跨 set 的 join 操作，同时通过分布式事务保证修改操作的原子性，使得所有 set 的数据是完全一致的：

```
mySQL> create table global_table ( a int, b int key) shardkey=noshardkey_allset;
```

如果是单表，语法和 mySQL 完全一样，此时该表的数据全量存在第一个 set 中，所有该类型的表都放在第一个 set 中：

```
mySQL> create table noshard_table ( a int, b int key);
```

注意：更多详情详见腾讯云官网 DCDB 开发指南。

4.4 分析性数据库 ADB

4.4.1 分析性数据库（ADB）简介

随着业务系统的发展，越来越多的数据被产生，通过对数据的分析和挖掘是企业用户获得更大收益的必备要素。然而，关系型数据库和分布式数据库天然的擅长事务处理（OLTP），即支持频繁的数据插入和修改。但是，一旦需要进行复杂计算的数据量过大（多表，多维，数据量超大），关系型数据库和分布式数据库性能极低。而分析型数据库（ADB）是一种专门解决联机分析处理（OLAP）的数据库系统，高度兼容 MySQL 协议和语法，可以秒级针对万亿级数据进行即时的多维分析透视和业务探索。

4.4.2 分析性数据库（ADB）实例的架构

分析性数据库（ADB）基于 Spark 技术，通过读写分离方案直接读取 CDB/DCDB 中存储的数据。需要计算时，将 CDB/DCDB 中数据拉取到 Worker 节点中进行并行计算（MPP）；如果计

算性能不足，只需要增加一个 worker 节点并指向 master 即可。

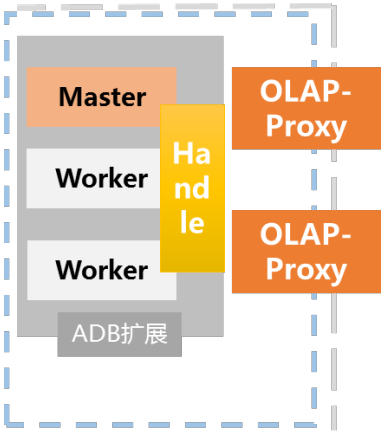

- **OLAP-Proxy：**专门用于接收并处理客户端发来的 OLAP 类型的 SQL，OLAP-Proxy 不与后端数据库相连，而是与运行在 Spark 集群上的 handle 交互。在获取到客户端发来的请求后，将 SQL 语句，以 JSON 的形式发送至 handle 进行处理，并等待 handle 的响应。
- **Handle：**负责接收 OLAP-Proxy 发来的 JSON 协议的请求，并给出响应。在接收到 OLAP-Proxy 的请求后，对 JSON 串进行解析，得到 SQL 语句，同时对 SQL 进行语法解析得到库表名，并封装成独立的 spark job 提交到 spark 集群进行计算，待 spark 得到结果后，将结果集转换成 MySQL 协议并返回给 OLAP-Proxy。
- **Master：** 是 Spark 计算集群的主控节点，负责各种信息，比如 Driver、Worker、Application 的注册；另一方面还负责 Executor 的启动，Worker 心跳等诸多信息的处理。
- **Worker**: 管理当前机器的内存和 CPU 等资源，接受 Master 的指令来启动 Driver，或者启动 Executor，Worker 是负责主要计算的节点。

4.4.3 分析性数据库（ADB）的主要特性

支持 MySQL 协议：全面兼容 MySQL 协议（包括数据元信息），天生具备与商业分析工具、应用

的兼容性，大幅度降低业务系统和商业软件的接入成本。

无需预先进行数据建模：通过 SQL 对海量数据灵活的进行多维分析、数据透视、数据筛选。支持标准 SQL 如 DDL/DML/DCL 进行数据定义、操作、控制，支持 JOIN、HAVING、DISTINCT 等。能够对任意字段进行组合查询。支持常规的聚合函数以及个性化的分段、抽样等统计分析函数。

极速的响应时间：秒级的亿级数据多维透视，支持毫秒级的多个大表关联计算，计算性能是 Hadoop 的 100 倍，是 MySQL 的 1000 倍以上。

4.5 数据库技术特征

4.5.1 自动水平拆分

只需在建表的时候设定 shardkey，即支持对数据库中大表自动水平拆分（分表），系统将基于 Hash 方案自动将写入数据均匀的分布到不同物理分片中，查询也自动聚合返回；分表而对业务系统透明，业务实际所见为一张逻辑完整的表，而无需感知后端的物理架构。

4.5.2 高度兼容 MySQL 语法

TDSQL 兼容绝大多数常用的 MySQL 语法，包括 MySQL 的语言结构、字符集和时区、数据类型、常用函数、预处理协议、排序、联合（join）、存储过程、索引、分区、事务、预处理协议、控制指令、等常用的 DDL、DML、DCL 语句语法。

4.5.3 补齐分布式架构的不足

因分布式架构的特殊性，在数据库高级功能与性能之间不能两全；为此 TDSQL 提供三种建表方案，提供（分布式）事务特性，提供全局唯一数字序列，支持 JSON 等能力，有效的弥补了分布式架构的不足，为开发者提供更加灵活的开发方案。针对 MySQL 协议只适合做 OLTP 数据库的特点，TDSQL 为解决用户复杂 OLAP 需求，向 ADB 扩展，通过自研 OLAP-Proxy 和 Spark 能力，无需增加额外存储，即可为用户提供一站式数据分析能力。

4.5.4 不停机弹性扩展

目前单一分片最大可支持 6TB 存储 ,如果性能或容量不足以支撑业务发展时 ,在控制台点击，即可自动升级完成。升级过程中，您无需关心分布式系统内的数据迁移，均衡和路由切换。升级完成后访问 IP 不变，仅在自动切换时存在秒级闪断，您仅需确保有重连机制即可。

4.5.5 基于数据强一致的高可用

TDSQL 默认采用主从架构，可确保 99.95%以上可用性；系统支持强同步复制已提供数据强一致，业务系统写入数据后，只有当从机同步后才给予应用事务应答，确保主从数据完全一致，不会因故障导致数据丢失、错乱，目前强同步复制性能已基本等于异步复制。

4.5.6 超高性能

TDSQL 深度定制开发 MySQL 内核，性能远超基于开源 MySQL；支持三种方案的读写分离，有效提供读扩展的同时提供开发灵活性；对线程池调度算法进行了优化，在重负载时表现更佳；并配置 PCI-E SSD 的硬盘，提供高于 SATA 三倍以上的 IO 配置，帮助您更轻松满足业务性能需求。

4.5.7 易于使用的托管部署

只需在腾讯云 TDSQL 管理控制台中单击几下，即可在几分钟内启动并连接到一个可以立即投入生产的 TDSQL 数据库。控制台提供常见的数据库运维操作 ,为您精细管理数据库提供便利；提供常见的系统监控数据和性能分析数据，祝您迅速识别运行异常的数据库。

4.5.8 支持 JSON

JSON 是一种轻量级的数据交换格式 ,采用了独立于语言的文本格式 ,类似 XML ,但是比 XML 简单，易读并且易编写。对机器来说易于解析和生成，并且会减少网络带宽的传输。目前诸如 MongoDB 等 NoSQL 的主要优势就是支持 JSON 等。而 TDSQL 支持原生的 JSON 类型 ,即 JSON

值将不再以字符串的形式存储，而是采用一种允许快速读取文本元素（document elements）的内部二进制（internal binary）格式。在 JSON 列插入或者更新的时候将会自动验证 JSON 文本，未通过验证的文本将产生一个错误信息。JSON 文本采用标准的创建方式，可以使用大多数的比较操作符进行比较操作，例如：=, <, <=, >, >=, <>, != 和 <=>。

注意：JSON 能力仅在内核为 MySQL 5.7 或以上版本支持。

5 产品优势

5.1 高可用与强同步

在生产系统中，通常都需要用高可用方案来保证系统不间断运行；数据库作为系统数据存储和服务的核心能力，其可用要求高于计算服务资源。由于数据库中记录了数据，想要在多台数据库中切换，数据必须是同步的，所以数据同步技术是数据库高可用方案的基础。

腾讯自主研发了的基于 MySQL 协议的异步多线程强同步复制方案（Multi-thread Asynchronous Replication MAR），相比于 Oracle 的 NDB 引擎，Percona XtraDB Cluster 和 MariaDB Galera Cluster，其性能、效率和适用性更据优势。简单来说，MAR 强同步方案强同步技术具有以下特点：

- 一致性的同步复制，保证节点间数据强一致性；
- 对业务层面完全透明，业务层面无需做读写分离或同步强化工作；
- 将串行同步线程异步化，引入线程池能力，大幅度提高性能
- 支持自动成员控制，故障节点自动从集群中移除；
- 支持自动节点加入，无需人工干预；
- 每个节点都包含完整的数据副本，可以随时切换；
- 无需共享存储设备，成本更低

腾讯强同步技术，只有当备机数据同步后，才由主机向应用返回事务应答，示意图如下：

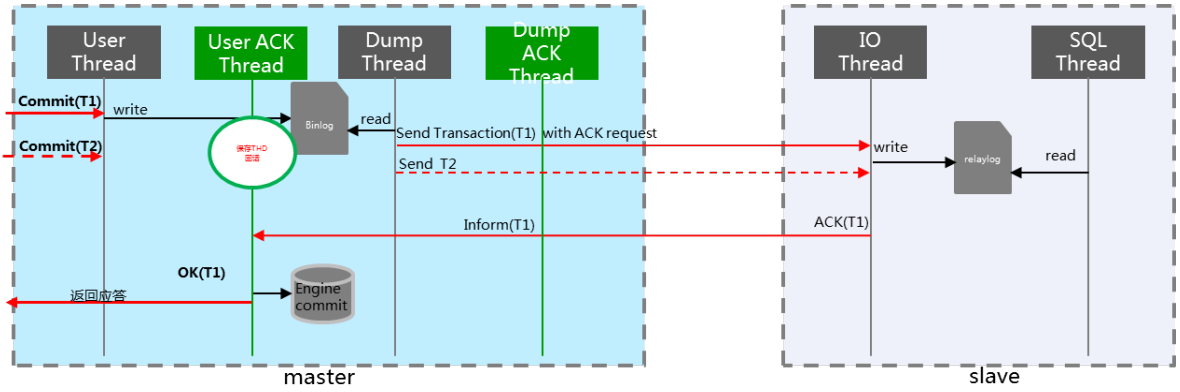

腾讯强同步从性能上优于其他主流同步方案，通过对比在跨可用区(IDC 机房，延迟约10~20ms)同样的测试方案下，我们发现其 MAR 技术性能优于 MySQL 5.6 半同步约 5 倍，优于 MariaDB Galera Cluster 性能 1.5 倍（此处测试使用 sysbench 标准用例测试）。

同步方案（跨 IDC 测试）	最大 QPS（100 并发水平）	平均耗时（ms）
TDSQL MAR 强同步	486004	26
MySQL 5.7 半同步	386513	32
MySQL 5.6 半同步	10720	42
TDSQL 异步同步	486004	13
MySQL 5.7 异步同步	418186	12

5.2 性能与容量线性增长

腾讯数据库 TDSQL 是天然的 MPP (Massively Parallel Processing，大规模并行处理系统)架构，采用分布式架构是随着分片（SET）的增加，每个分片各自承担一部分分布式任务，意味着并发性能、处理能力、存储容量将线性增长。

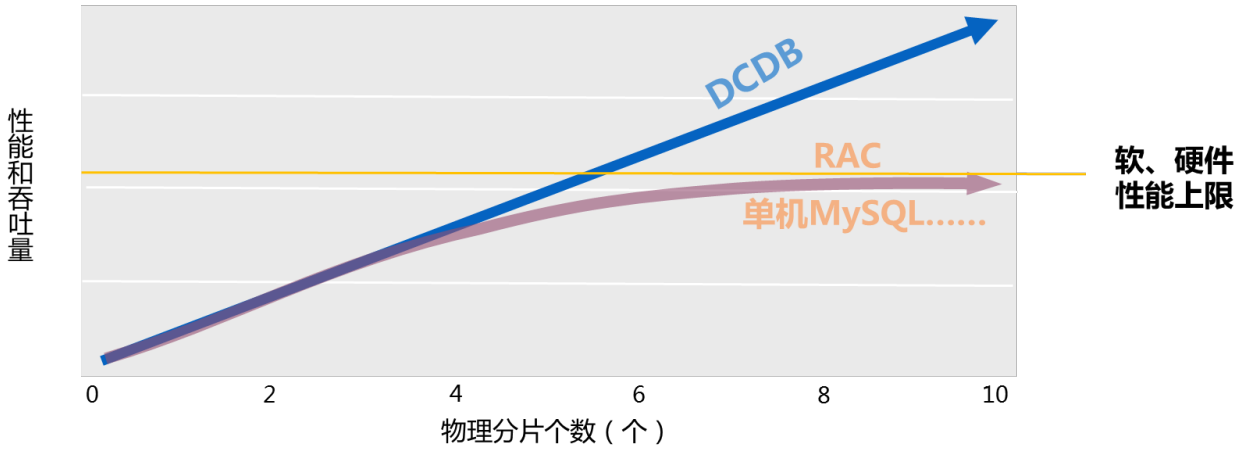

并且 TDSQL 默认采用线程池，且对调度算法进行了优化，改进当系统内核处于重负载时，查询和更新请求在线程组之间分布不均衡等极端情况下性能，并且能够更好地利用计算资源，减少无谓的线程切换，减少请求在队列中的等待时间，及时处理请求。类似的内核优化还有很多，通过 sysbench 的压力测试，TDSQL 单个分片纯写入操作能超过 12 万+TPS，纯查询操作能超过 48 万 QPS，是 MySQL5.6 性能的 4 倍，MySQL5.7 的 2 倍以上。

5.3 逻辑表/物理表结合

腾讯数据库 TDSQL 对应用来说，读写数据完全透明，对业务呈现的表实际上是逻辑表。逻辑表屏蔽了物理层实际存储规则，业务无需关心数据层如何存储，只需要基于业务表应该如何设计。

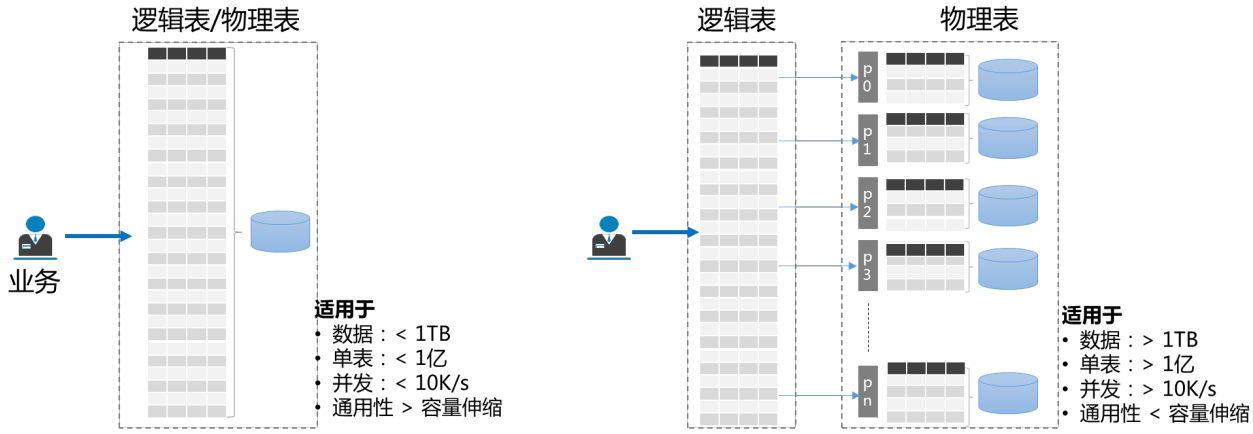

TDSQL 为用户提供了三种类似的表：分表，小表以及单表：

- **分表：**即水平拆分的表，通常适用于表规模大于一亿行、大于 100GB，且快速增长的表；

说明：需要拆分的标准并无一个准确值，通常取决于开发者对业务的判断和对性能的预期。

- **广播表：**即所有操作都将广播到所有逻辑分片（Shard）中，这意味着每个分片都有该表的全量数据，通常适用于配置表，或需要频繁 JOIN 的表，该类表数据更新相对较少，广播表可以两个表的联合查询（JOIN）、事务收敛到单节点中，以提高性能；
- **单表**：一些无需分片的表，通常适用于数据量较小的库表；由于单表并未拆分，这意味着单表使用完全兼容 MySQL。

5.4 实时监控告警

通过 TDSQL 的监控模块，TDSQL 所有的内部运营状态或数据都能实时采集并分析,数据一份上报到调度集群，一份上报到赤兔平台，如下图：

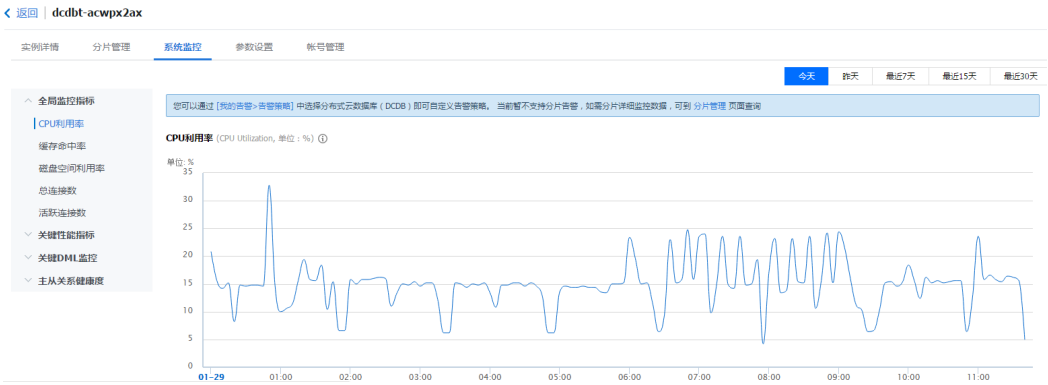

基于调度集群的自动分析，可以随时自动处理集群任意节点的故障，实现智能调度和自动切换。而通过监控系统和告警系统，数据库管理员（DBA）基本上可以随时获悉集群状态，并通过管理台进行所有常规的运营操作，而不需要登录设备实际检查。

5.5 高性能分布式事务

腾讯数据库 TDSQL 默认支持读写分离能力，架构中的每个从机都能支持只读能力，如果配置有多个从机，将由网关集群（OLTP-Proxy）自动分配到低负载从机上，以支撑大型应用程序的读取流量；我们提供多种读写分离方案供您选择，且您无需关注若干从机是否完全存活，因为

系统将根据策略自动调度

- **只读帐号**:您仅需要在创建帐号时,标记为只读帐号,系统将根据策略向将读请求发往从机;
- **/*slave*/注释:**您可以在编程过程中,通过注释/*slave*/,系统将把该条语句发往从机,常用于编程阶段将特殊的读逻辑嵌入代码。
- **只读实例(Watch 节点):**如果从机仍无法满足您的读需求,您可以添加只读实例。值得注意的是,只读实例并不参与高可用切换。

由此可为应用提高总的读取吞吐量;通过多种只读方案的组合,您可以配置出复杂的只读方案,以满足各种业务需求和开发的灵活性。

5.6 全局唯一数字序列

数据切分后,原有的关系数据库中的主键约束在分布式条件下将无法使用,因此需要引入外部机制保证数据唯一性标识,这种保证全局性的数据唯一标识的机制就是全局唯一数字序列(sequence)。

TDSQL 全局唯一数字序列(以下简称 sequence,使用的是 unsigned long 类型,8 个字节长),使用方法与 MySQL 的 AUTO_INCREMENT 类似。目前 TDSQL 可以保证该字段全局唯一和有序递增,但不保证连续性。

5.7 弹性扩展

TDSQL 支持在线实时扩容分为新增分片和对现有分片扩容两种方式。TDSQL 在线扩容过程对业务完全透明,无需业务停机。扩容时仅部分分片存在秒级的只读(或中断),整个集群不会受影响。

TDSQL 主要是采用腾讯自研的自动再均衡技术(rebalance)保证自动化的扩容和稳定,以新增分片为例,扩容过程如下下图:

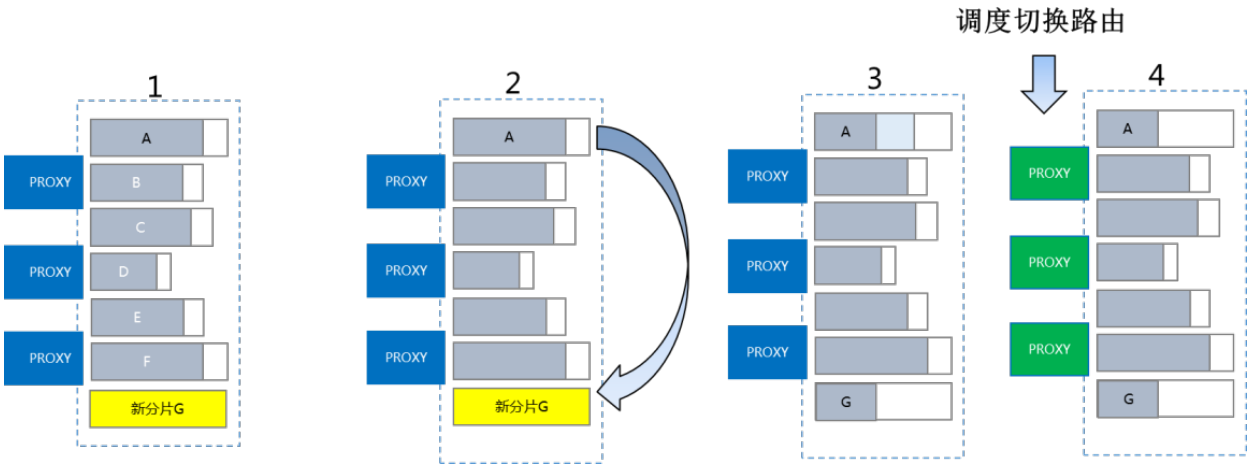

1) 控制台点击扩容后，系统根据负载和容量计算出 A 节点(可也手工指定节点)存在瓶颈。

2) 根据新加 G 节点配置，将 A 节点部分数据搬迁（备机）到 G 节点。

3) 数据完全同步后，AG 校验数据库，(存在 1~几十秒的只读)，但整个服务不会停止。

4) 调度通知 Proxy 切换路由。

为确保业务不停以及数据一致性，TDSQL 的整个迁移过程采用移存量数据、迁移增量数据、数据检验、再追增量、切换路由、清理六个步骤循环迭代进行。该能力经过腾讯内外海量业务迁移，至今未发生过一次数据异常错误或全集群停机。

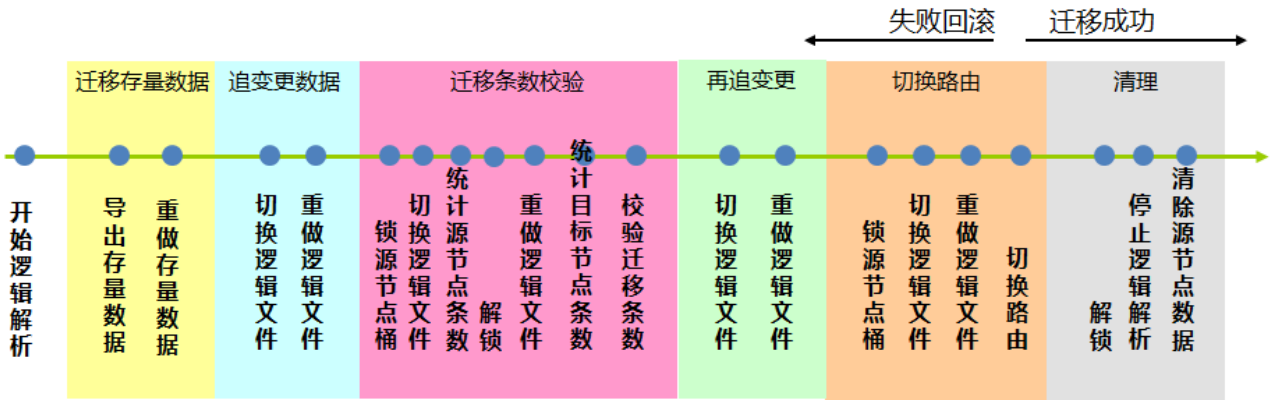

5.8 透明故障转移

TDSQL 的每一个分片都支持基于强同步的一主多从架构（默认为一主一从，异步同步），主数据库故障时备机立即顶替工作，切换过程对用户透明，且不改变访问 IP。并且对数据库和底层

物理设备提供 7X24 小时持续监控。发生故障时，TDSQL 将自动重启数据库及相关进程；如果节点崩溃无法恢复，将通过备份文件自动重建节点（如下图）。该功能持续保障数据库可用性在 99.99%以上，以帮助业务持续稳定的运行。

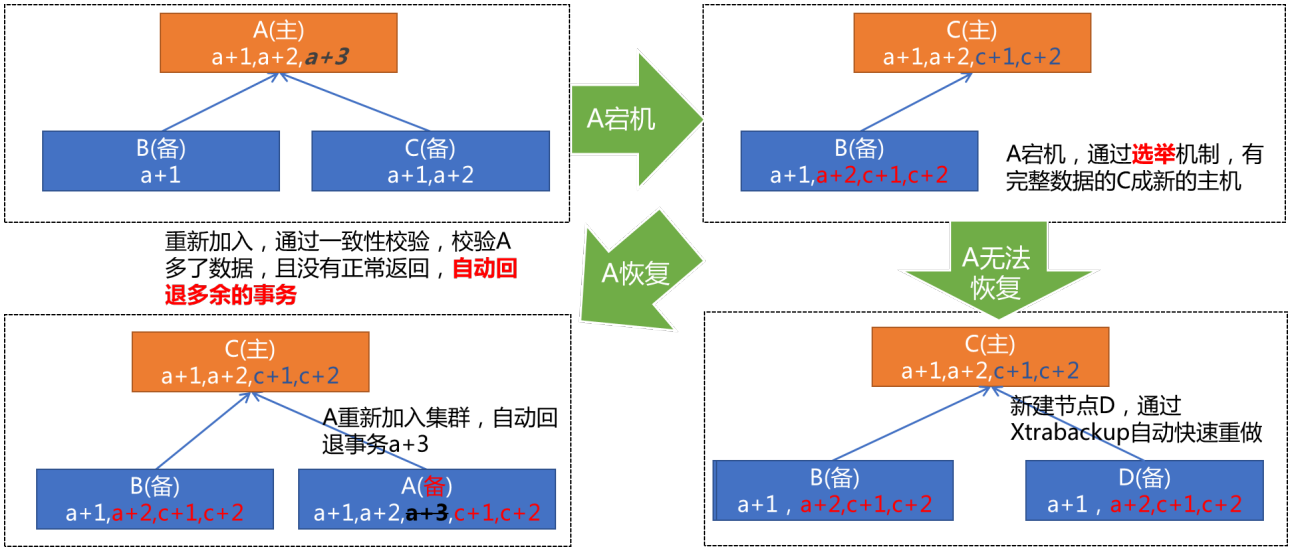

而 TDSQL 也支持定时备份您的数据库实例，自动备份保留期可配置，自动备份存储在统一的安全备份存储内，提供 99.99999%的数据持久性；在业务出现异常时，自动备份和恢复能力可使您的业务损失减少到最小。

5.9 同城双中心

TDSQL 支持同城双中心部署，其架构中关键模块都可以支持跨中心，以避免机房级故障影响整体数据库集群的稳定。TDSQL 同城双活解决方案是参考 GB/T 20988-2007《信息系统灾难恢复规范》第 6 级，GB/T 22239-2008《信息系统安全等级保护基本要求》三级/四级 标准设计，数据库双中心的设计标准为 RTO≤60 秒，RPO≤5 秒。一般来说，同城双活可采用主机房 2 节点，备机房 1 节点（简称 2+1），或 2+2 两种模式；并建议调度集群部署需位于 3 个不同的可用区，以保证某一机房级故障时，数据库节点能被正常调度并切换。

需要说明的，业务层的同城双活不仅是技术方案，还包括恢复策略、管理措施、资源要求、建设标准、恢复预案等一系列要求。即使数据库实现双活，也并不意味着在灾难时业务可以完全

正常的切换。包括某些重金打造的双活机房，主机房故障时“手软”的例子更是不胜枚举。究其根源，单纯硬件和软件方案很难完全解决业务连续性问题才是关键。事实上，大多数业务系统切换到灾备中心容易，但业务内部的关联、数据的完整性、配置和管理的复杂度，都是让决策者不敢切换的主要原因；因此，构建双活业务系统，需要业务在系统的设计、使用、管理、系统升级过程中时刻都以双中心为基础，双中心实时使用，这样才能做到故障后，业务做较少修改和配置，即可快速恢复运行。

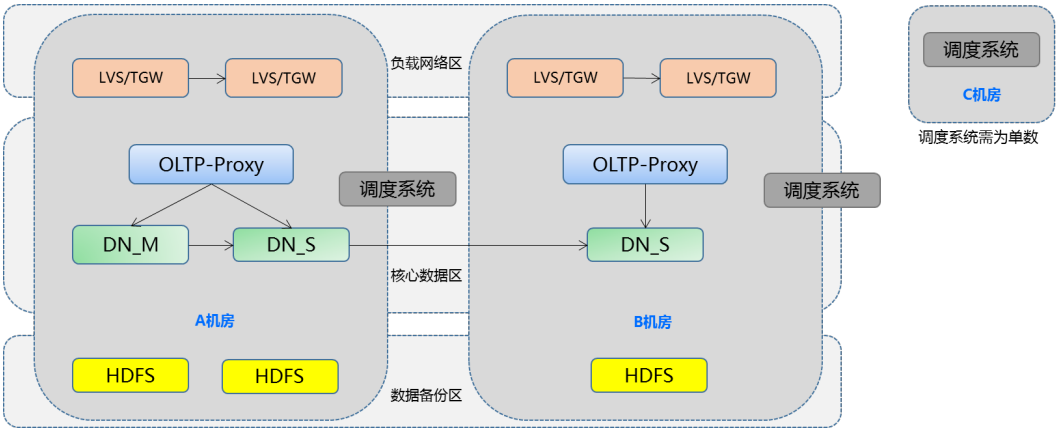

5.10 两地三中心

TDSQL 支持两地三中心方案部署，其架构中关键模块都可以支持跨中心，以避免机房级故障影响整体数据库集群的稳定。与同城双中心不同的是，由于异地数据中心物理距离过远，且异地通常作为数据级容灾中心来考虑，因此其设计标准为 RTO≤15 分钟，RPO≤60 秒。

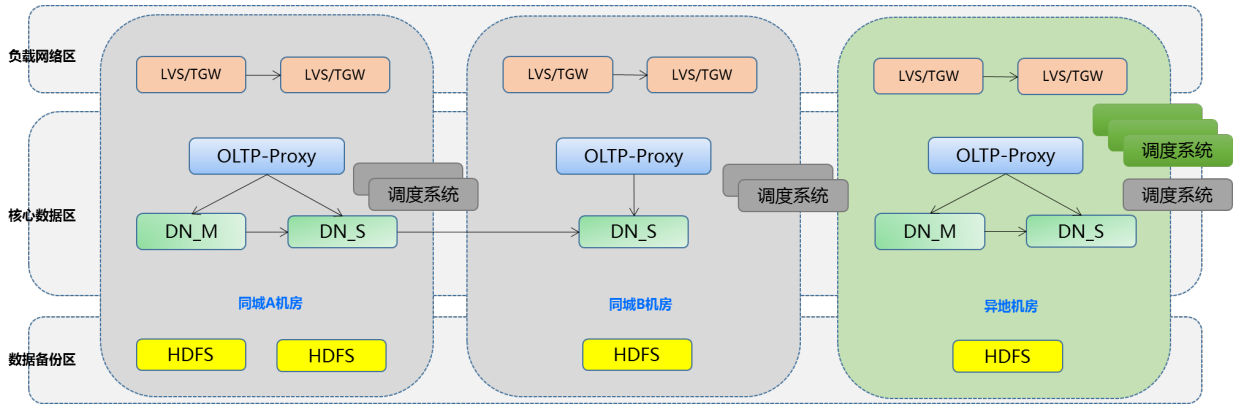

6 应用场景

6.1 电子商务类应用

几乎所有大型电子商务平台基于数据库，其中性能是最重要的考虑；当大流量推广的时候，只有分布式架构的数据库可免受物理硬件性能限制，性能线性扩展。2017 年，鹅漫 U 品上线不足一年，每个月都保持着高速的增长，到中期的日均单超过 1 万单时，普通数据库性能和扩展问题就显现出来了，经过 1 个月不到的改造，成功迁移到 TDSQL，最后顺利通过双 11，双 12 等各类大型推广活动。

6.2 金融类应用

随着手机银行、网上理财、数字货币等等具有互联网特色的金融业务兴起，单笔交易变小，交易次数变多等情况；传统架构逐渐不足以支撑业务发展，网络安全风险逐渐增加；TDSQL 不仅在性能容易扩展，强同步能力也确保数据不错不丢，是国内第一个将分布式事务应用于金融系统的产品，同时支持部署在腾讯金融云，支持物理独享，加密，审计等系列安全方案。

6.3 IoT 类应用

在工业监控和远程控制、智慧城市的延展、智能家居、车联网等物联网场景下，传感监控设备多，采样率高，数据存储要求高，数据规模存储规模问题凸显；TDSQL 容量的线性扩展不仅可有效解决容量问题；其支持 MySQL 协议和 JSON 也能让开发者用自己熟悉的协议开发系统；同时可扩展 RocksDB，让数据压缩率低至 20%以下，二级分区让冷热数据有效快速的分离处理，极大的降低了数据存储成本。

6.4 游戏应用

全区全服的 SNS 游戏，新进 IO 等游戏品类，PCU 很容易到达 10w 甚至 1000W 都是有可能的，所以在设计之初就要考虑所有的功能模块都要具有可平滑扩展的能力。GameSvr、MatchSvr 等

无状态服务器扩展相对容易，但记录游戏中全部好友关系链，全部历史战绩，游戏交易记录的 DBSvr 扩展就成为难题。而 TDSQL 能比较友好的解决类似全区全服的扩展问题。

6.5 成为去 O 的中坚力量

企业的核心业务系统一般都是 OLTP 为主的应用场景，在这个领域，Oracle 一直是市场的领导者，而开源数据库 MySQL、MariaDB、PostgreSQL 等似乎仅能提供给中小企业或个人站长使用。在互联网领域，以 TDSQL 为代表的数据库应用非常广泛，用普通 x86 服务器，轻松支撑起上亿的用户访问，经过验证的好的数据库在性能和稳定性上甚至高于用高端设备搭建的 Oracle RAC。

当然，对于企业而言，由于 Oracle 数据库和上层应用绑定比较紧密，通常会使用到 Oracle 的存储过程、自定义函数、触发器，这就需要涉及到应用迁移，这个工作的工作量和时间周期通常较大，但综合计算下来，即使加上软件改造成本，采用 TDSQL 的 TCO 仍然低于使用商业数据库，当前，不管是互联网和传统行业，去 O 的成功案例比比皆是。

6.6 分支业务聚合到总部

由于政务、银行、大型国企的组织架构通常采用总部-分部-分支的架构；因为各种原因，其某些核心 IT 系统建设也采用总部-分部-分支模式。随着业务互通，人员互通，信息互通等需求越来越强烈，业务逐渐向总部聚合。而业务聚合一个重要问题是数据库性能和容量无法承载。以某部委为例，其省级业务系统数据规模和性能已经在用最高端的商业数据库硬件承载。如果聚合到总部，一是设备性能扩无可扩，二是软件费用和硬件成本将会是天价。因此，到现在为止，不少业务也仅能做到数据汇总，而非业务聚合。

互联网分布式数据库架构在微信支付、京东等超大规模业务的应用证明，一个系统承载一个全国性复杂业务的可能性。在 2014 年马年春节，总共 800 万微信用户参与争抢 4000 万个红包，最高峰期间的 1 分钟有 2.5 万个红包被领取。2016 年大年初一每分钟有 55 万个红包被发出、165 万个红包被拆开，增长近百倍。