



# ADB数据库在电信运营商系统中的应用



嘉宾：姜明俊  
公司：亚信软件



ADB系统架构简介



ADB实施案例介绍

ADB关键技术介绍

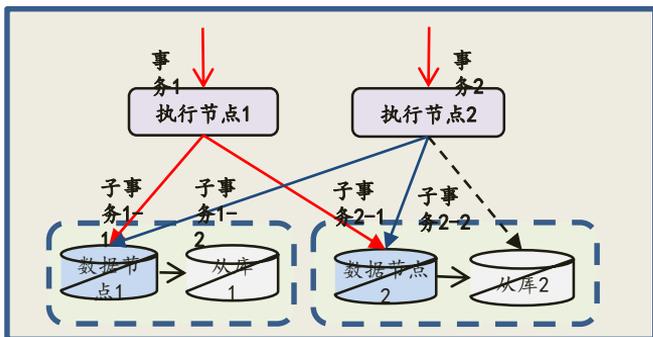




# 分布式数据库：两种技术架构选型

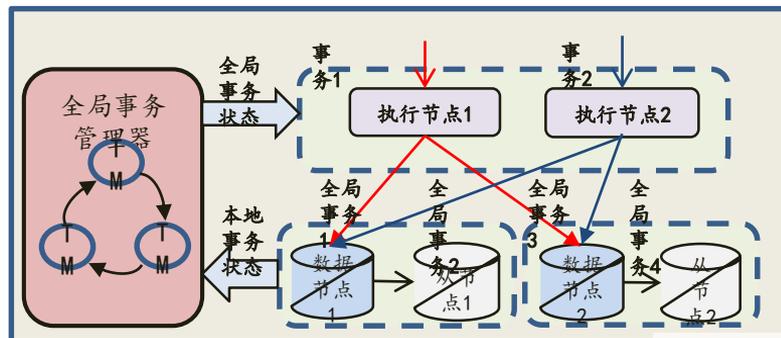
## 互联网级数据库架构

- **集群规模**：数百、上千节点存储百T以上数据，承载数百万TPS和上亿QPS，优先强调数据库的可扩展性
- **数据一致性**：弱化对数据一致性的要求，通过业务系统保证最终一致性
- **应用开发**：需要根据数据库架构进行定制开发



## 企业级数据库架构

- **集群规模**：单库规模为数十个节点，数据规模通常在10T以下，处理能力为数千TPS和上万QPS
- **数据一致性**：业务高度依赖数据库提供的ACID（原子性、一致性、隔离性、持久性）能力，必须保证数据在任何场景下的强一致性
- **应用开发**：已经过多年开发，需要支持透明、低成本的平滑迁移





# ADB产品目标和特性

## 产品目标

企业级应用

安全可靠

可扩展

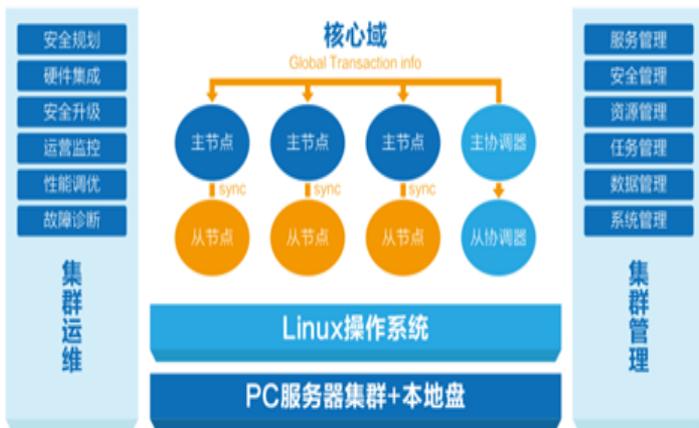
稳定

易用

分布式

事务型

关系型





### V2.1版本开发

- ✓ 大量数据一致性、稳定性Bug修复
- ✓ 重构连接池提升性能
- ✓ 75%的ORACLE语法兼容，降低应用迁移难度
- ✓ 支持和ORACLE异构容灾
- ✓ 数据备份恢复，支持基于任意时间点的恢复
- ✓ 通过移动集团分布式数据库测试

### V3.1版本发布

- ✓ 支持同步异步流复制模式自适应切换
- ✓ 分布式SQL查询引擎优化，提升复杂SQL执行效率
- ✓ 内核升级到PG9.6版本
- ✓ 秒级在线扩缩容
- ✓ 采用libpq改造pgxc的通讯方式

2014.08

2015.10

2016.12

2017.12

### 参与PGXC开源版本开发

- ✓ 日本NTT公司铃木先生2000年启动、2013年开源，2015年起处于停滞状态
- ✓ 基于PostgreSQL9.3的分布式数据库集群解决方案
- ✓ 存在问题：负载稳定性、数据一致性、应用易用性、运维支撑能力等

### V2.2版本发布

- ✓ 自主开发全局事务管理器，实现技术架构的完全可控
- ✓ 达到85%的ORACLE语法兼容
- ✓ 增强分布式事务的处理能力
- ✓ 增强集群管理和自动化运维工具
- ✓ 增加数据存储策略，可自定义数据分片
- ✓ 支持SQL2011标准



PostgreSQL



# ADB产品系统架构

应用可通过任何一个Coordinator进行读写，读写能力可同时扩展，所有事务具备一致的数据库视图

## AGTM：全局事务管理器（主，从节点内）

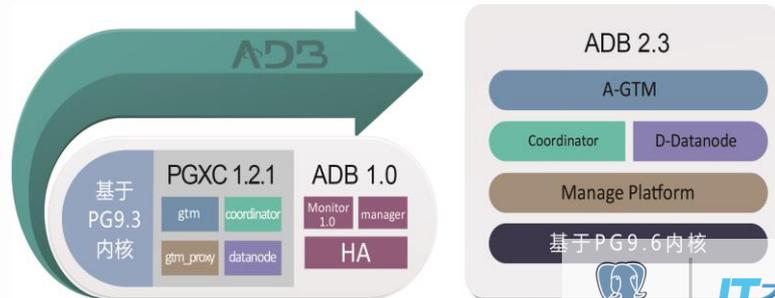
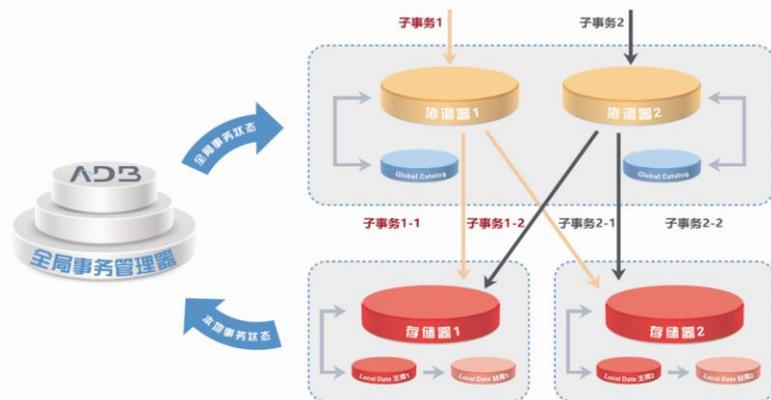
- AGTM保存事务ID和事务快照以及全局序列号、时间戳，参与2PC提供分布式MVCC能力；负载很小；可支持20个节点的集群规模，满足企业级应用需求

## 存储器：完成数据的存储和执行（主、从节点内）

- 支持数据节点的分组管理
- 提供应用透明的复制和分布两种存储方式
- 提供多种分片函数，支持定制开发
- 支持节点动态扩容和数据重平衡

## 协调器：处理客户端的连接请求（主、从节点内）

- 支持SQL2011标准：生成执行计划，将执行计划、全局事务ID和快照号发送给数据节点执行，对结果集归并处理
- 事务由Coordinator节点发起，并由Coordinator提交或回滚。
- 多协调节点同时接受客户端连接：提供读写可扩展性
- 对跨节点操作提供分布式事务支持
- 支持跨节点的关联、聚合类分析操作





# ADB实施案例介绍





# ADB的实施案例：某省案例介绍

## 项目背景：


2016年，某省移动在二期渠道管理系统的基础上建设渠道中心，支撑社会渠道和自有渠道的所有日常运营管理工作。渠道中心系统尝试去‘O’，采用DADB（总线）+ ADB（数据库）的分布式部署方案

## 项目目标：

300多张业务表，数据总量500G左右，公共库cmbase，资源库channel，报表库rpt，全部迁移到ADB中

## 使用效果：

- ◆ 1200个高并发业务读写，TPS最高5600，响应延时均低于2秒，性能提升明显，集群稳定
- ◆ 异构数据库容灾，与Oracle数据库实时同步





# ADB的实施案例：某省案例介绍

## 项目背景：

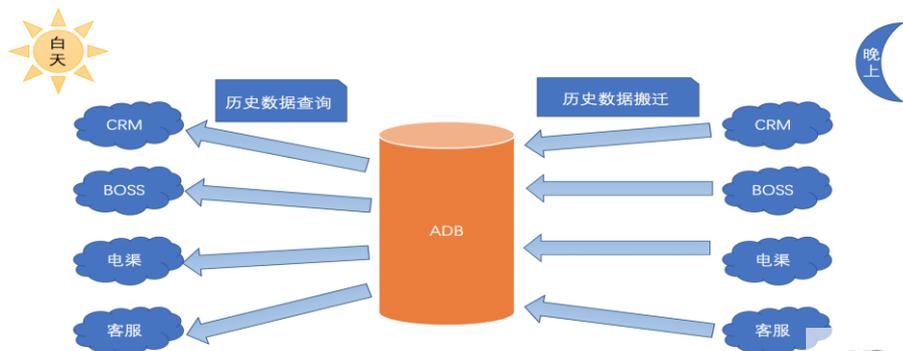
某省移动历史库去‘O’项目中，采用了ADB，存放CRM、账务、电渠、客服等系统的历史数据以及登陆日志、用户操作记录等信息。2w+张历史数据表，数据总量目前在40TB，包括原来Oracle历史库中的数据以及持续从在线库搬迁至ADB的数据，数据量年增长量20TB+。

## 项目目标：

6个月以上的业务数据通过ADB来查询，在线库只保留最近6个月的数据，以达到系统瘦身的目标。

## 使用效果：

- ◆ 业务查询压测，1000并发，sql响应在200ms以内
- ◆ 晚上task数据搬迁(根据业务规则，从在线Oracle库搬迁至ADB)，一分钟100w数据量





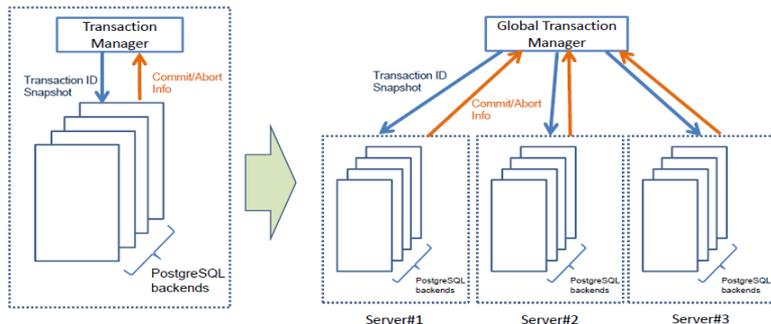
# ADB分布式事务实现





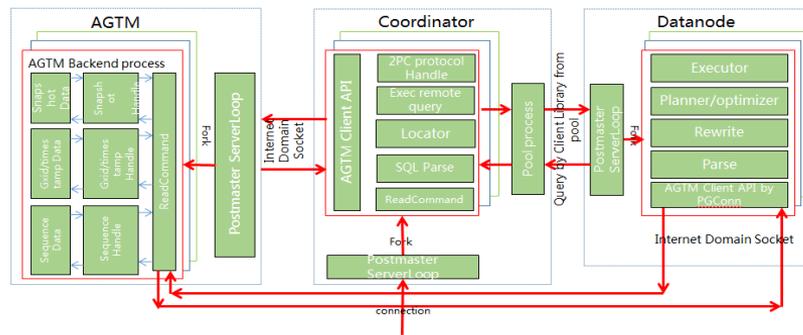
# 分布式事务处理机制

- GTM使用单进程多线程模型
- GTM只支持一主一从两副本模式
- 读写都需要分配GXID
- 事务提交分本地提交和全局提交
- GTM不参与全局2PC, 会出现数据写不一致
- Snapshot不完整, 会出现数据读不一致
- DataNode节点出现2PC事务状态不一致, 需要再使用pgxc\_clean进行手工清除遗留的两阶段事务
- 存在诸多数据异常、网络缓冲区未清除及锁不释放引起的宕机问题



PGXC分布式事务控制

- AGTM也会记录全局事务日志 ( WAL ) 参与2pc, 保证全局事务状态的一致性
- 多进程多listen模型, 充分利用资源, 一个进程挂了, 不会影响其他用户访问
- 使用PG流复制来实现HA, 并能获得更好的灵活性和集群的稳定性, 支持一主多从, 同步+异步的混合模式
- 消息通讯协议减少70%, 性能提升60%
- 不需要使用本地+全局两次提交, 大大减少了事务的冲突率
- 读操作不需要消耗全局GXID资源
- ADB新增remote xact manager进程, 用于自动解决分布式事务部分成功问题



ADB分布式事务控制





# 优化分布式引擎和集群通信





# 优化集群通讯

- ★ PGXC的通信接口与libpq在功能上类似，完全可以以代码质量更有保证的libpq接口实现相关功能
- ★ PGXC的通信状态DNConnectionState把握不准确，导致大量的断言错误
- ★ PGXC的通信接口效率低下，影响性能
- ★ 代码不够严谨，开发人员疲于应对相关bug

PGXC不足

- ✦ 引入PGconn作为通信句柄，复用libpq接口大量代码
- ✦ 按需扩展libpq协议消息
- ✦ 通过libpq的copy消息实现节间数据传输，相对于PGXC效率更高
- ✦ 引入InterXactState概念，保证节间事务逻辑。

ADB优化

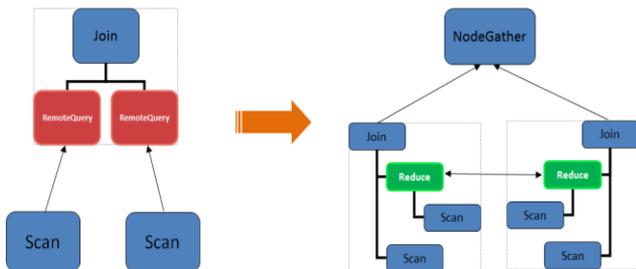




# 分布式执行计划改造

ADB相比PGXC实现了真正意义上的分布式执行，可以使聚集、排序、关联（尤其是内关联）及插入通过增加节点以倍数级提升性能  
在数据传输方面性能更高、不易出错、代码简洁

TPC-H性能对比



数据库版本	主机配置	集群
ADB3.1	CentOS 7.2 (Linux version: 2.6.32-642.6.1.el6.x86_64) CPU: Intel(R) Xeon(R) CPU E5-2609 v3 @ 1.90GHz 12核 MEM: 64G Disk: 1.6T SCSI 网卡: 1000Mb 数据量: 100GB	2个Coordinator, 3个DataNode master
GP5.0		1个Master instance, 3个 primary segment





# 语法兼容、分片、多副本、高可用





# Oracle语法兼容

- 服务器级别：通过修改数据库配置文件默认为Oracle语法
- 会话级别：通过设置会话级配置参数指定Oracle语法
- 语句级别：通过/\*ora\*/或/\*oracle\*/等前缀注释指定按Oracle语法执行SQL

## 兼容

- ROWID、ROWNUM、(+)、CONNECT BY、CASE WHEN、LIMIT、别名等Oracle特殊语法
- 80%的常见Oracle函数，数据类型，操作符，如“||”和对空字符串的处理以及正则表达式等
- 业务层常用的隐转规则，尽管Oracle和PG都不建议这样做
- OCI接口

**\*\*运营商CRM渠道中心使用ADB完整兼容业务SQL，不需要业务专门做SQL改动**





# 数据分布策略（复制、分片）

**复制表：**用于静态类配置小表，每个节点上都会存储相同的一份数据；

**分片表：**数据分布在各个节点上，用于大数据量的表根据分片字段进行分片；

## ➤ 支持用户自定义分片

- 用户可根据业务场景制定更匹配的分区规则
- 分区键可以为任意多个
- 可预知数据的分区情况
- 自定义分区函数的返回值需为整数

## ➤ 各个分片算法可进行互转

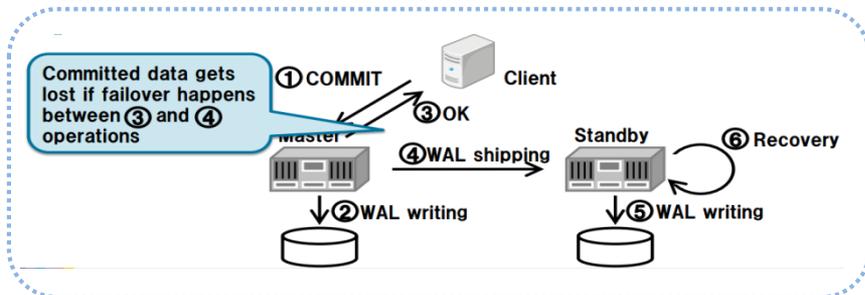
## ➤ 缺省供三种分片方式 hash(column)、modulo(column)、roundrobin

- 分区键至多1个
- 用户无法根据业务场景制定分区规则
- 用户无法预知数据的分布情况
- 可能会出现数据的倾斜
- 支持数据分组管理

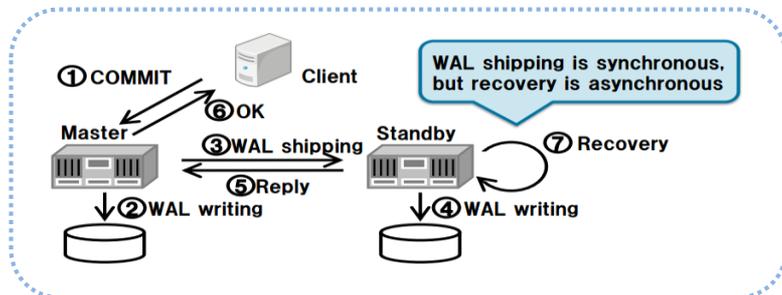


# 多副本和高可用

- 基于PG的流复制实现多副本同步，对应用访问透明
- 支持同步和异步两种模式，且支持同步和异步模式的自适应切换
- 支持四种同步复制级别：`on`，`remote_write`，`local`，`off`，应对不同的数据安全和性能要求
- AGTM和DN均无单点故障 AutoFailover
  - repmgrd进程实时监控
  - 监控到master节点异常后，连接ADB-MGR执行failover操作
  - 故障节点使用pg\_rewind恢复数据，并重新加入到集群中
- 秒级切换：数据无丢失



异步模式



同步模式



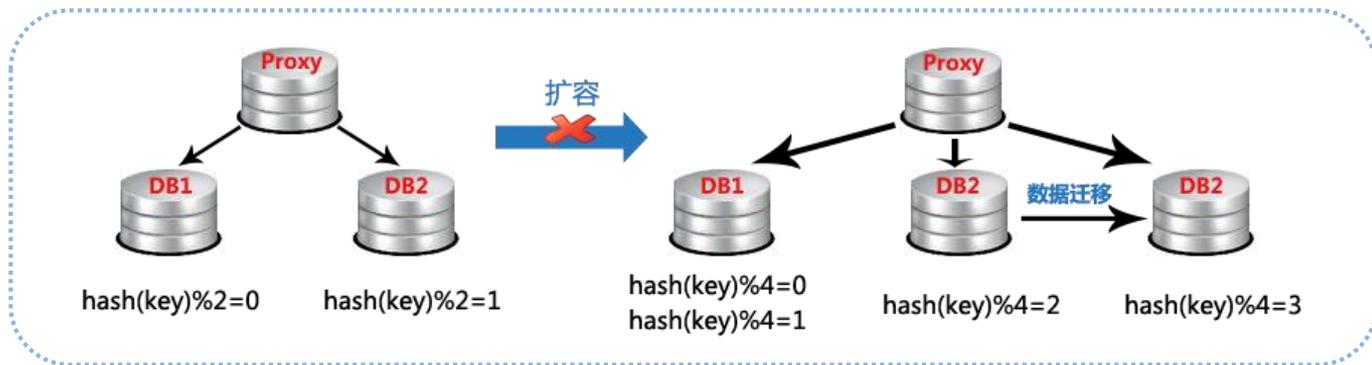
# 扩容、迁移、备份恢复、容灾





# PGXC的扩缩容问题

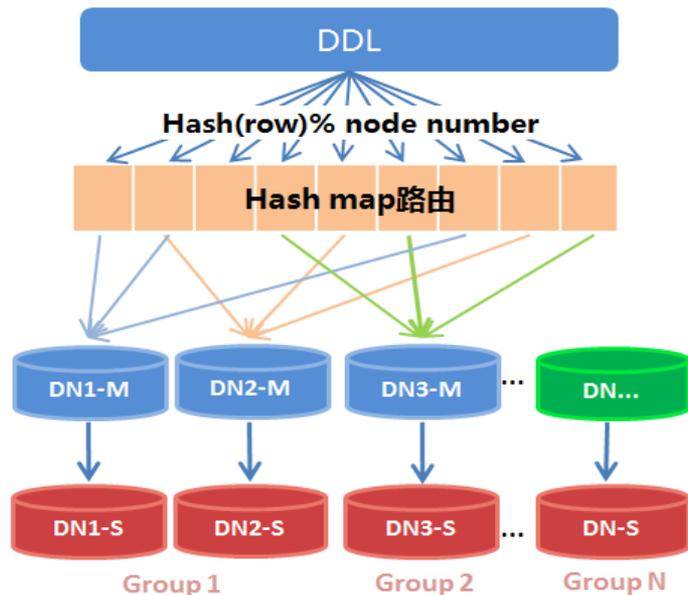
- 扩容过程中数据迁移时要锁集群，停止应用访问
- Rebalance操作，非常耗时，数据量大的场景无法接受，一张表2000w条记录，5个节点，完成平衡需要20-30分钟。
- 不支持单一节点扩容
- 缩容时先对数据进行备份，再删除节点，然后老数据再导入集群；
- 在线增加节点：新建表根据复制、分片策略存储到新节点；原有表数据仍然存储在老节点上；并没有解决节点数据倾斜的问题。





# ADB采用Hash+Map路由算法

- 将集群的数据划分为1024 (可设定) 个slot。对分片字段hash后, 除1024取模, 得到一个对应的slotid
- 系统表adb\_slotnodemap维护数据的映射和每个slot的状态, 包含如下字段
  - Slotid : 数据块ID
  - Nodeid: 节点编号
  - Status : slot的状态, 包括online, moving, switch
- 数据路由时, 通过slotid从映射表中找到对应的node





# 节点扩容过程

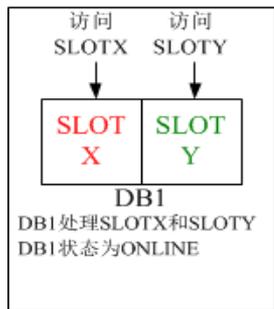


图1

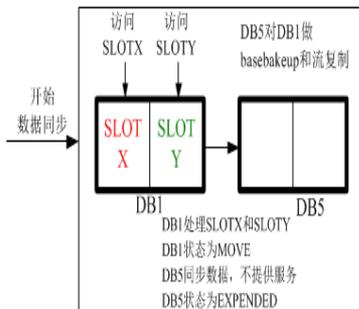


图2

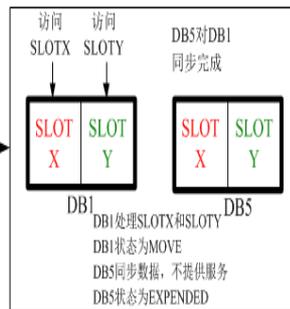


图3

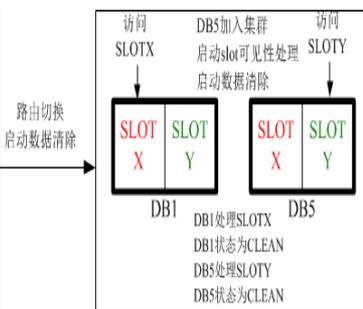


图4

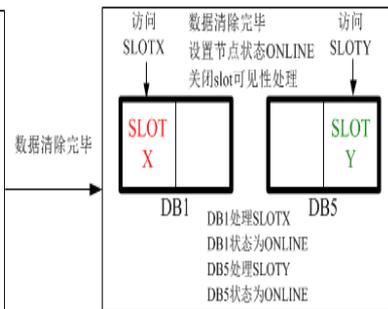


图5

## 扩容前

SlotId	NodeID
SlotX	Node1
SlotY	Node1



## 扩容后

SlotId	NodeID
SlotX	Node1
SlotY	Node5





# 某省移动扩容案例

## 项目背景：

某省移动历史库项目使用ADB做为基础数据库软件，目前存放CRM侧历史订单数据和实例数据，数据量大小40TB。前期规划局方提供了4台pc server，但由于单台pc server存储扩展有限以及后续接入系统的历史数据增长量大，局方随后追加4台pc server，年底会达到80T的总数据量。此时就面临需要对ADB集群进行扩容的操作，将40TB数据从4台分散到8台主机

## 扩容实施：

采用ADB提供的平滑扩容技术，可以很好的解决上述问题，对业务来说，只是在路由切换步骤中短暂的操作挂起，集群锁释放后，操作继续，时间非常地短暂，真正做到了平滑扩容

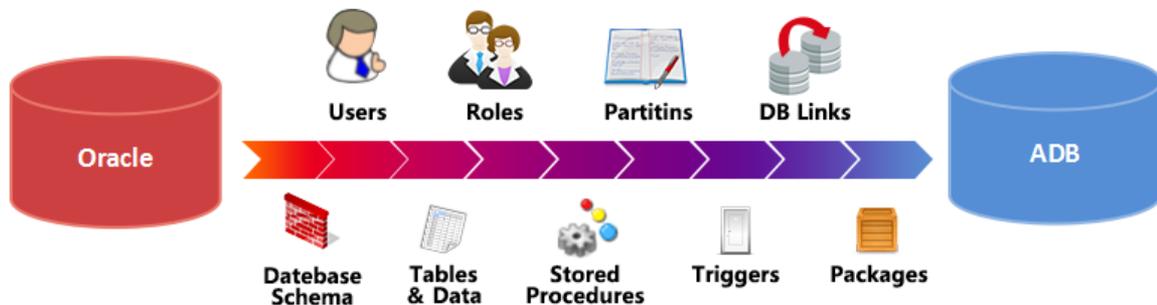
操作	用时	备注
数据同步 -- 4节点数据同步到8节点	2小时5分钟	不影响业务，正常访问
路由切换	18秒	需要锁集群
数据清理 – 按照数据分布规则，调用vacuum进程清理各个节点的数据	12小时	不影响业务，正常访问





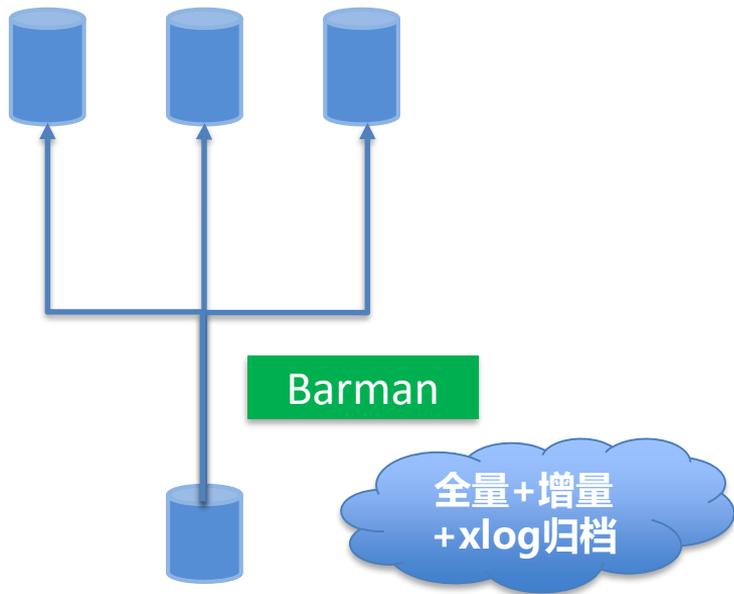
# 数据迁移

- 基于Ora2PG进行改造和优化，使其适应分布式场景，比如bug修复， distribute by语法，数据自动切片，过程跟踪，断点续抽，数据迁移完整性稽核等等
- 不分割导入100G的表到ADB，平均在50分钟，进行分割后多台并行导入，100G平均8-10分钟内完成





# 基于barrier的一致位点恢复



基于时间点的恢复，在集群中主机时间不一致的场景下，会导致部分节点的数据恢复丢失

## Barrier

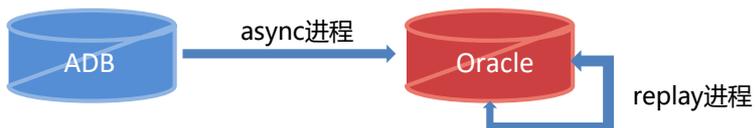
- 所有节点一致性位点
- 连接coordinator执行: `CREATE BARRIER <barrier_name>`

recovery.conf基于barrier的恢复，确保集群各个数据节点均恢复到一致的状态(全局barrier点)

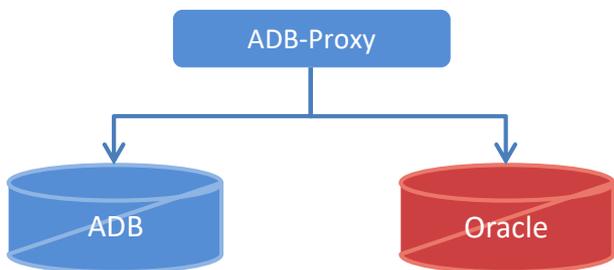


# 数据库容灾

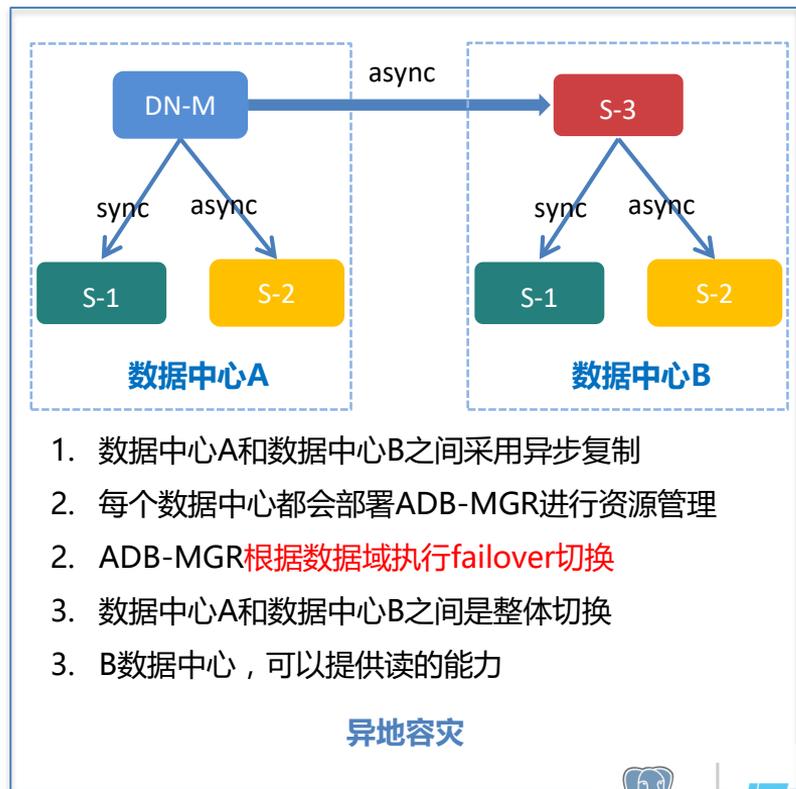
- ADB和Oracle之间的异步复制



- 通过数据库中间件实现ADB和Oracle的同步复制



异构容灾



1. 数据中心A和数据中心B之间采用异步复制
2. 每个数据中心都会部署ADB-MGR进行资源管理
2. ADB-MGR根据数据域执行failover切换
3. 数据中心A和数据中心B之间是整体切换
3. B数据中心，可以提供读的能力

异地容灾





Thanks!

