WOTA

51CTO

World Of Tech 2017

全球架构与运维技术峰会

2017年4月14日-15日　北京富力万丽酒店

ARCHITECTURE

WOTA

51CTO

出品人及主持人：

赖春波 滴滴出行平台技术部 高级技术总监

高可用架构

WOTA

51CTO

网易NDC高可用实践

主讲人：马进

WOTA

51CTO

马进

网易

资深工程师

分享主题：

网易数据传输服务NDC高可用实践

NDC是什么？

- NDC，直译为网易数据运河，为网易各大产品提供结构化数据实时迁移，同步和订阅服务。功能包括异构数据库在线迁移，OLTP到OLAP的实时数据整合，数据库增量数据实时订阅等。是网易分布式数据库DDB和大数据解决方案Mammut的依赖组件

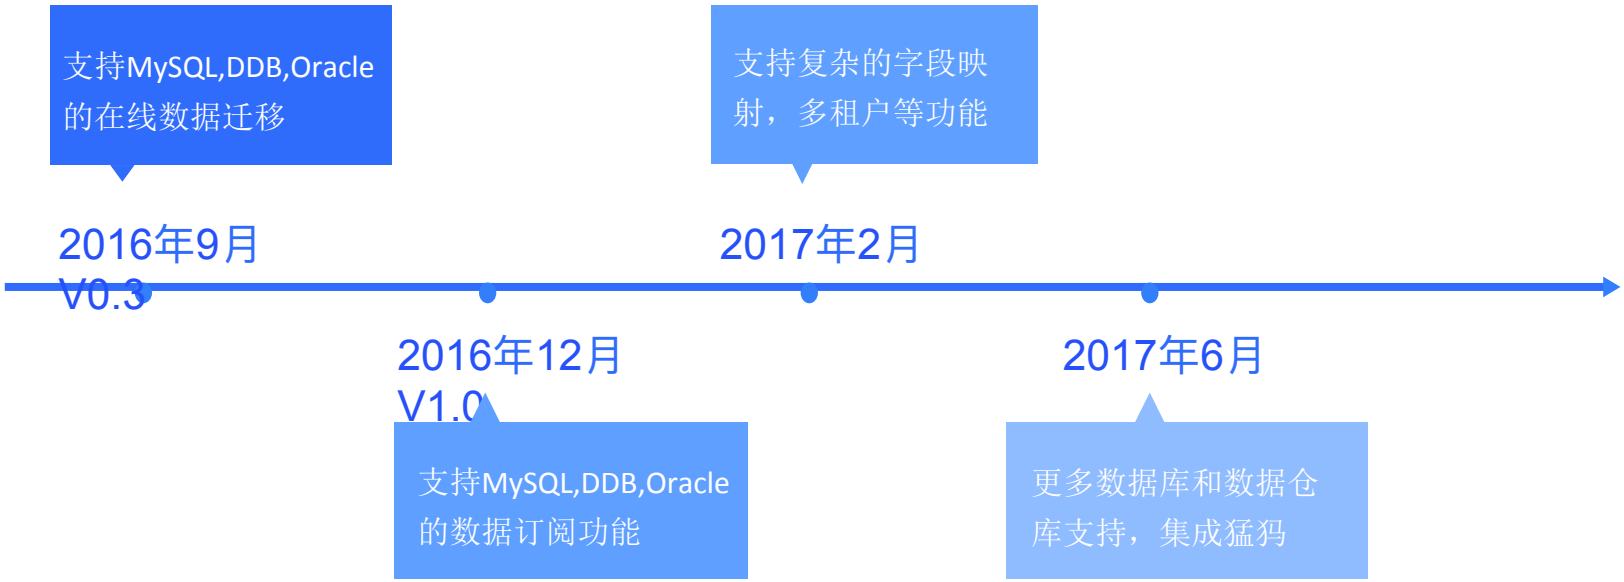

大纲

- 应用场景　why?
- 产品形态　what?
- 系统架构　how?
- 高可用实践

NDC应用场景

- OLAP数据同步
  - OLTP实时同步到OLAP系统（代表：Kudu, HBase, Greenplum）
  - OLTP同步到队列，定期merge到OLAP系统（代表：Hive，HDFS）

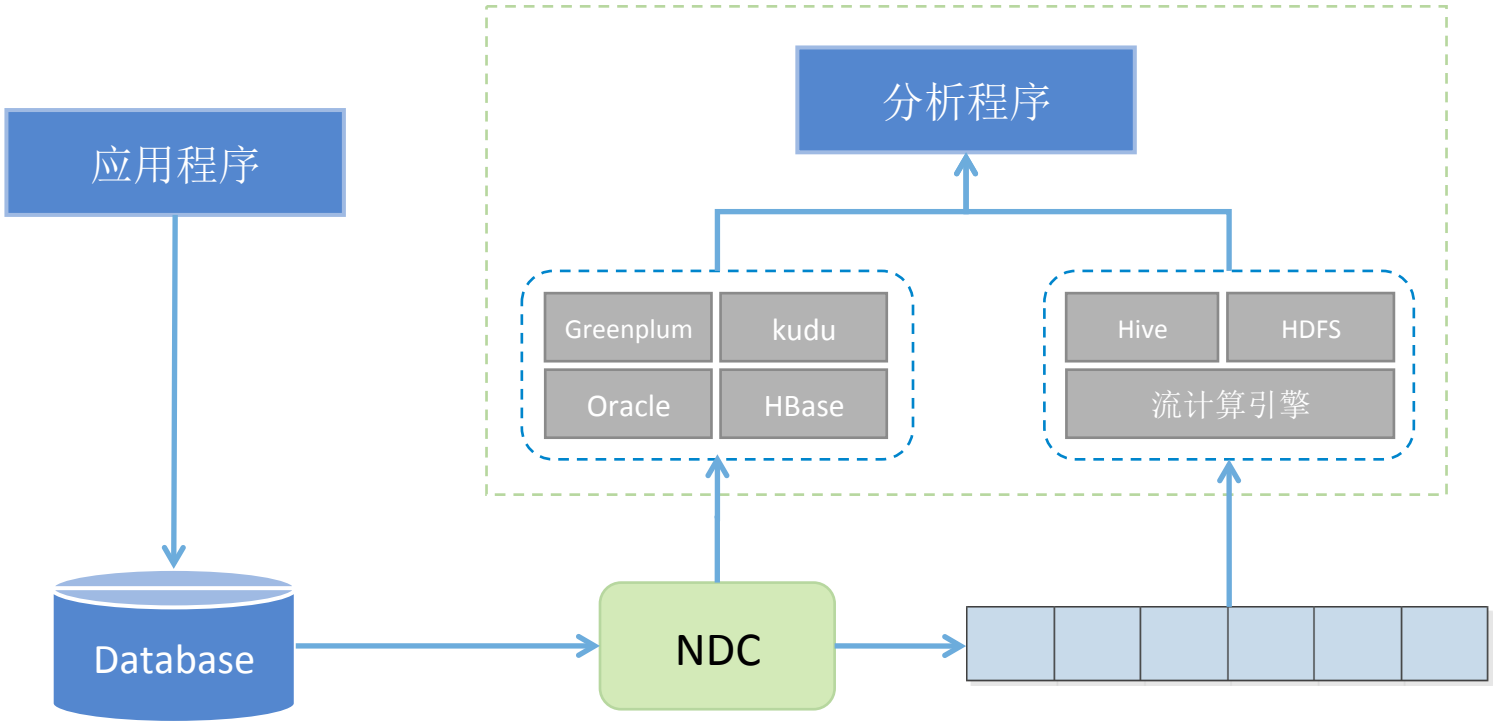

NDC应用场景

- DDB在线数据迁移
  - 场景：在线扩容，机器迁移，更改均衡字段……

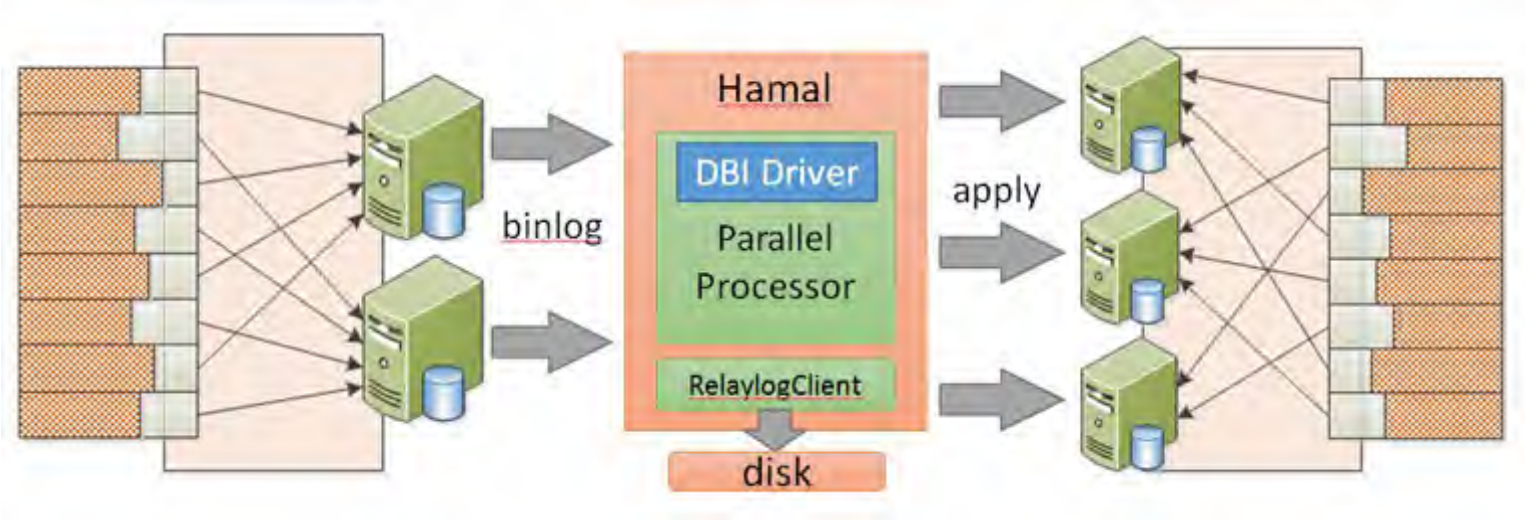

NDC应用场景

- 数据库第三方索引支持
  - 全文索引，地图索引等

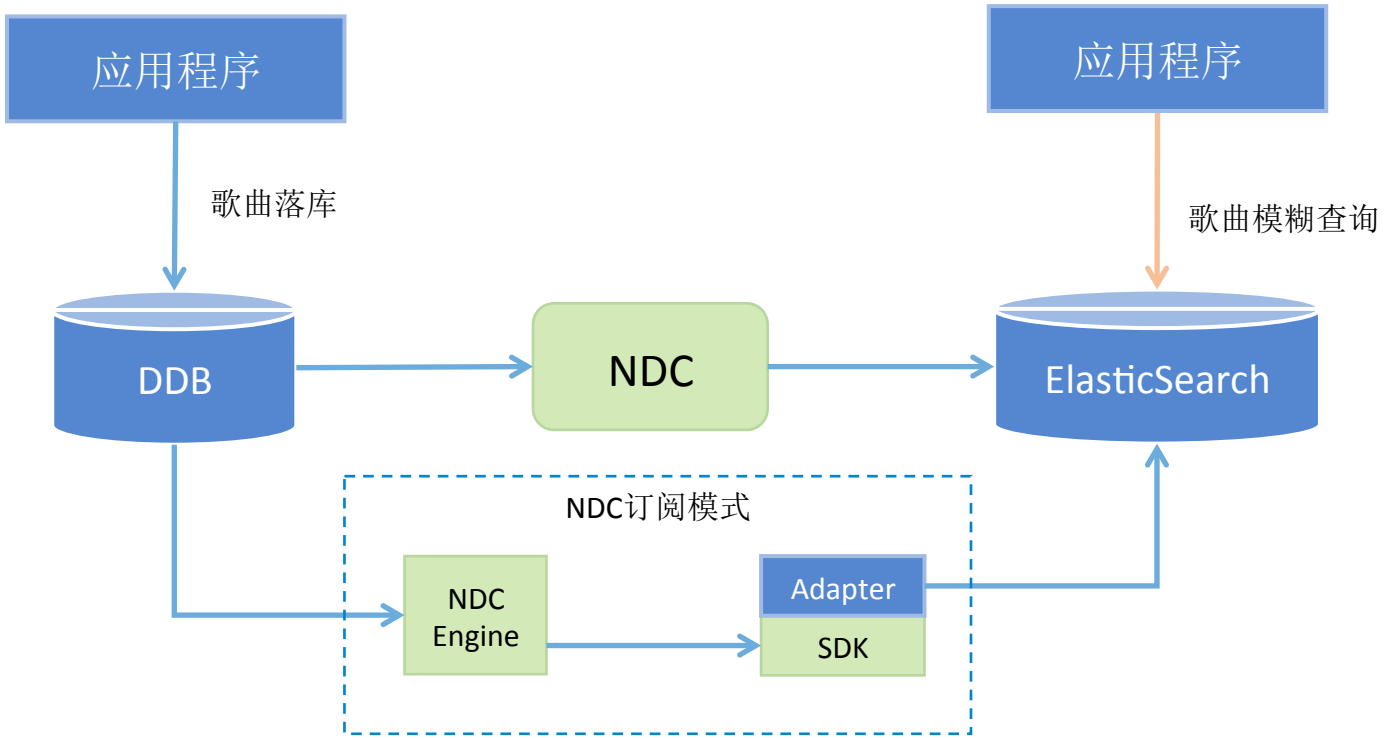

NDC应用场景

- 多机房缓存淘汰
  - 原则：同步先于淘汰

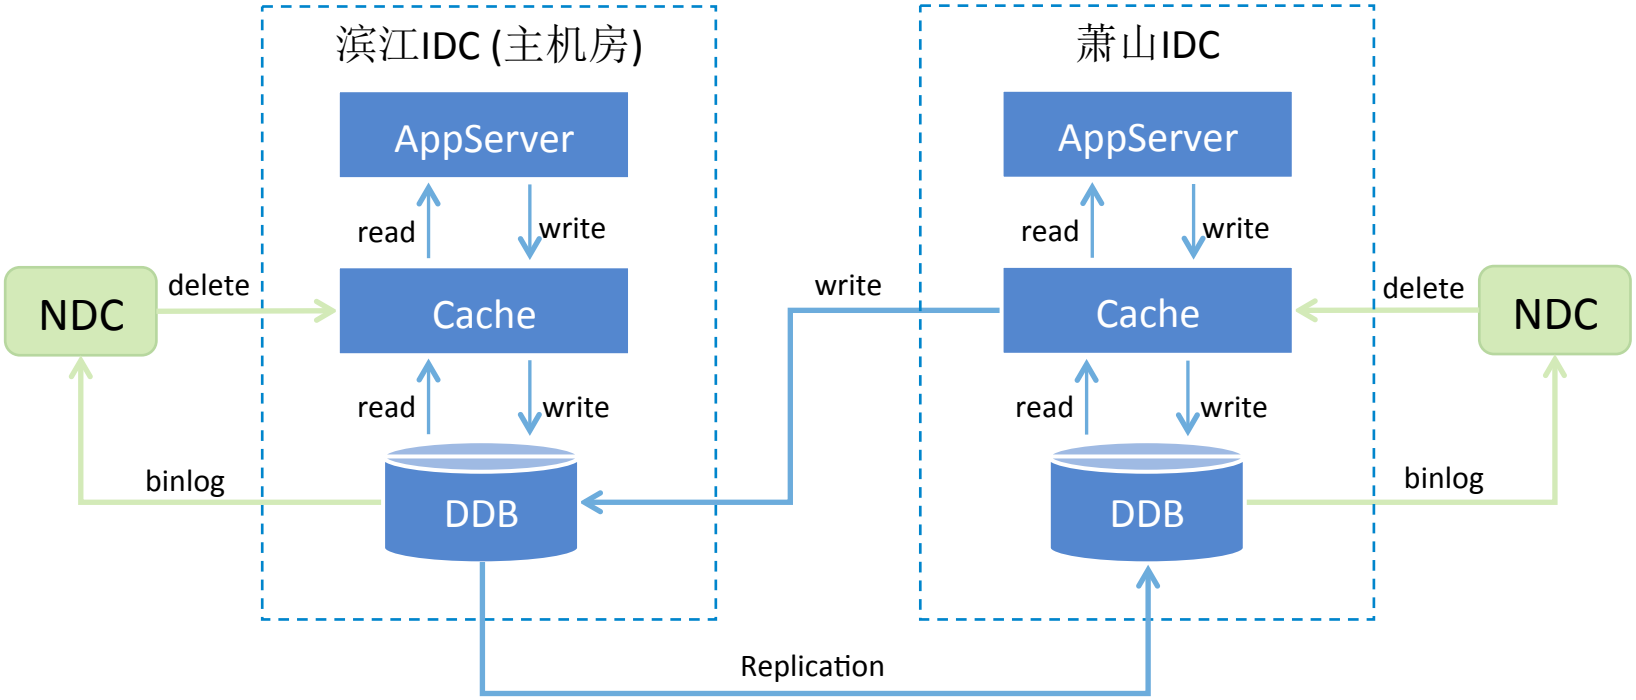

小结

- 应用方视角
  - 数据迁移：异构数据库在线迁移，在线扩缩容
  - 数据同步：跨机房，跨域，跨国的实时数据同步
  - 数据订阅：数据驱动业务，业务间异步解耦
- 大数据视角
  - 数据整合：OLTP到OLAP的数据整合
  - 数据集成：*“making all the data an organization has available in all its services and systems”*
- 核心需求
  - 获取数据库实时变更的能力
  - 数据发布的能力

NDC产品形态

- 平台化
  - 平台化的WEB管理工具
  - 平台化的资源管理和调度
  - 平台化报警监控

- 插件化
  - 不同数据源extractor插件化
  - 不同数据源applier插件化
  - 账号系统插件化

NDC产品形态

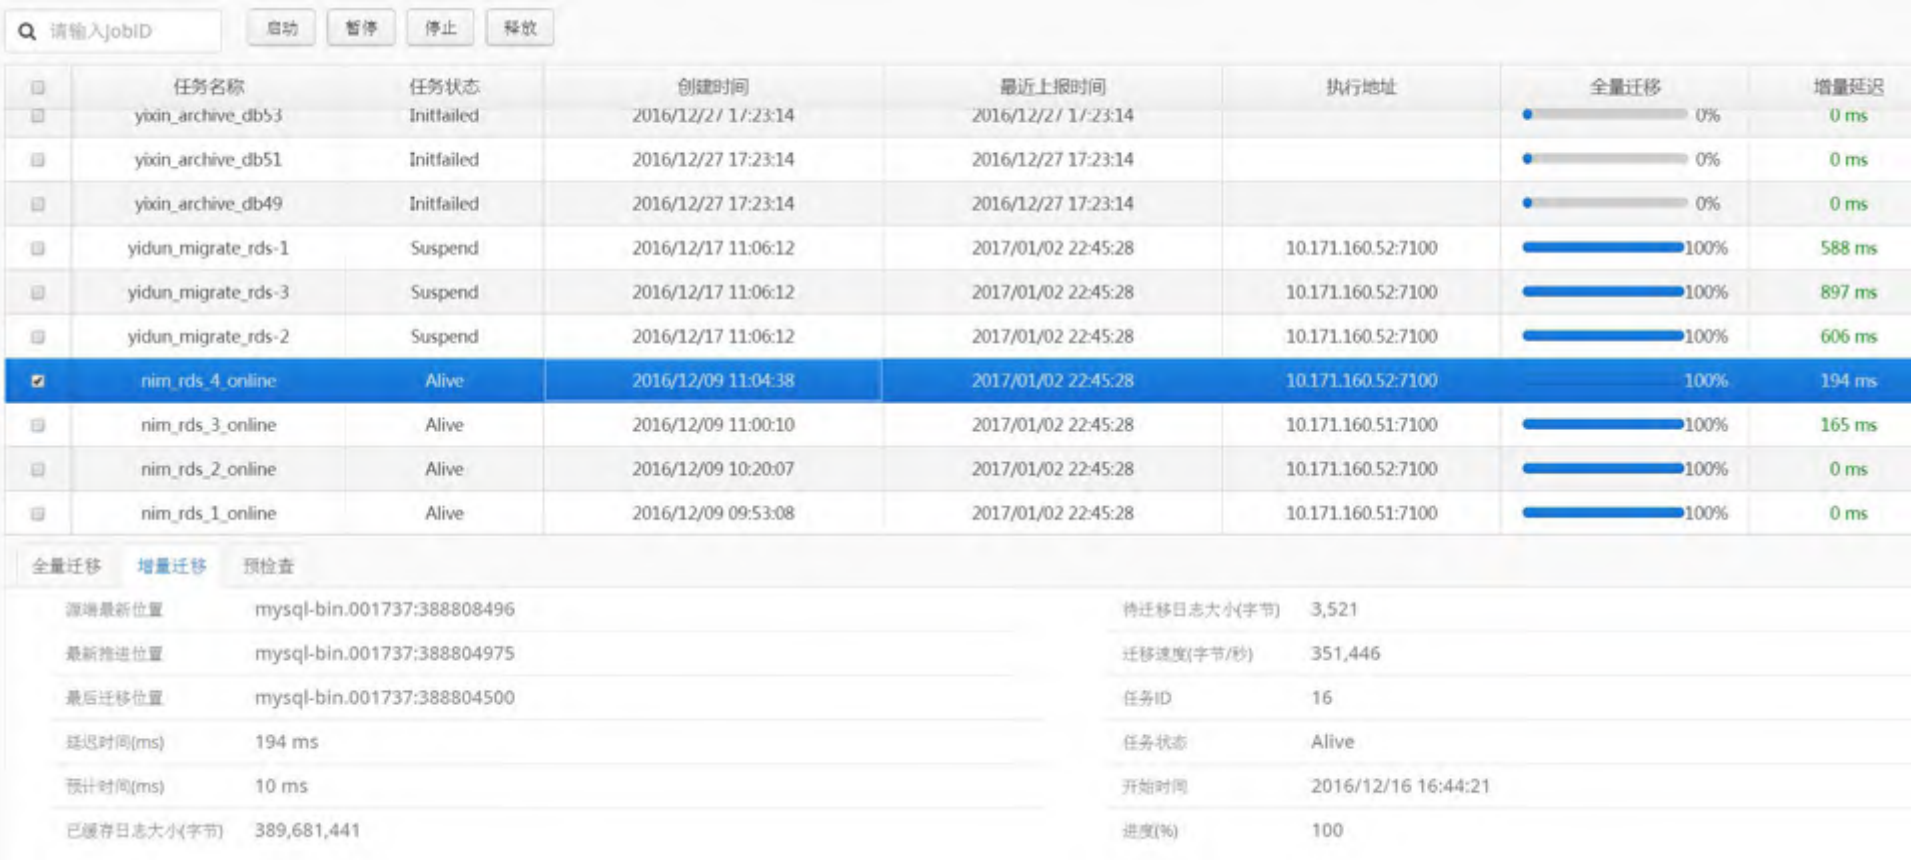
请输入jobID
启动
暂停
停止
释放
任务名称
任务状态
创建时间
最近上报时间
执行地址
全量迁移
增量延迟
yixin_archive_db53 Initfailed 2016/12/27 17:23:14 2016/12/27 17:23:14 0% 0 ms
yixin_archive_db51 Initfailed 2016/12/27 17:23:14 2016/12/27 17:23:14 0% 0 ms
yixin_archive_db49 Initfailed 2016/12/27 17:23:14 2016/12/27 17:23:14 0% 0 ms
yidun_migrate_rds-1 Suspend 2016/12/17 11:06:12 2017/01/02 22:45:28 10.171.160.52:7100 100% 588 ms
yidun_migrate_rds-3 Suspend 2016/12/17 11:06:12 2017/01/02 22:45:28 10.171.160.52:7100 100% 897 ms
yidun_migrate_rds-2 Suspend 2016/12/17 11:06:12 2017/01/02 22:45:28 10.171.160.52:7100 100% 606 ms
nim_rds_4_online Alive 2016/12/09 11:04:38 2017/01/02 22:45:28 10.171.160.52:7100 100% 194 ms
nim_rds_3_online Alive 2016/12/09 11:00:10 2017/01/02 22:45:28 10.171.160.51:7100 100% 165 ms
nim_rds_2_online Alive 2016/12/09 10:20:07 2017/01/02 22:45:28 10.171.160.52:7100 100% 0 ms
nim_rds_1_online Alive 2016/12/09 09:53:08 2017/01/02 22:45:28 10.171.160.51:7100 100% 0 ms
全量迁移
增量迁移
预检查
源端最新位置 mysql-bin.001737:388808496
最新推进位置 mysql-bin.001737:388804975
最后迁移位置 mysql-bin.001737:388804500
延迟时间(ms) 194 ms
预计时间(ms) 10 ms
已缓存日志大小(字节) 389,681,441
待迁移日志大小(字节) 3,521
迁移速度(字节/秒) 351,446
任务ID 16
任务状态 Alive
开始时间 2016/12/16 16:44:21
进度(%) 100

NDC猛犸定位


大数据应用开发层
大数据开发套件(可视化IDE)
数据加工
数据ETL
数据分析
数据挖掘
数据探索
数据提取
数据计算
离线计算
流式计算
内存计算
资源管理
统一资源管理与调度
数据存储
分布式文件系统
分布式数据库
数据集成
全量/非实时接入
实时/增量接入
数据源
结构化数据
如RDBMS备库
半结构化数据
如JSON
非结构化数据
作业流开发
权限管理
多租户管理
元数据管理
数据质量校验
秘钥管理
运维监控

系统架构

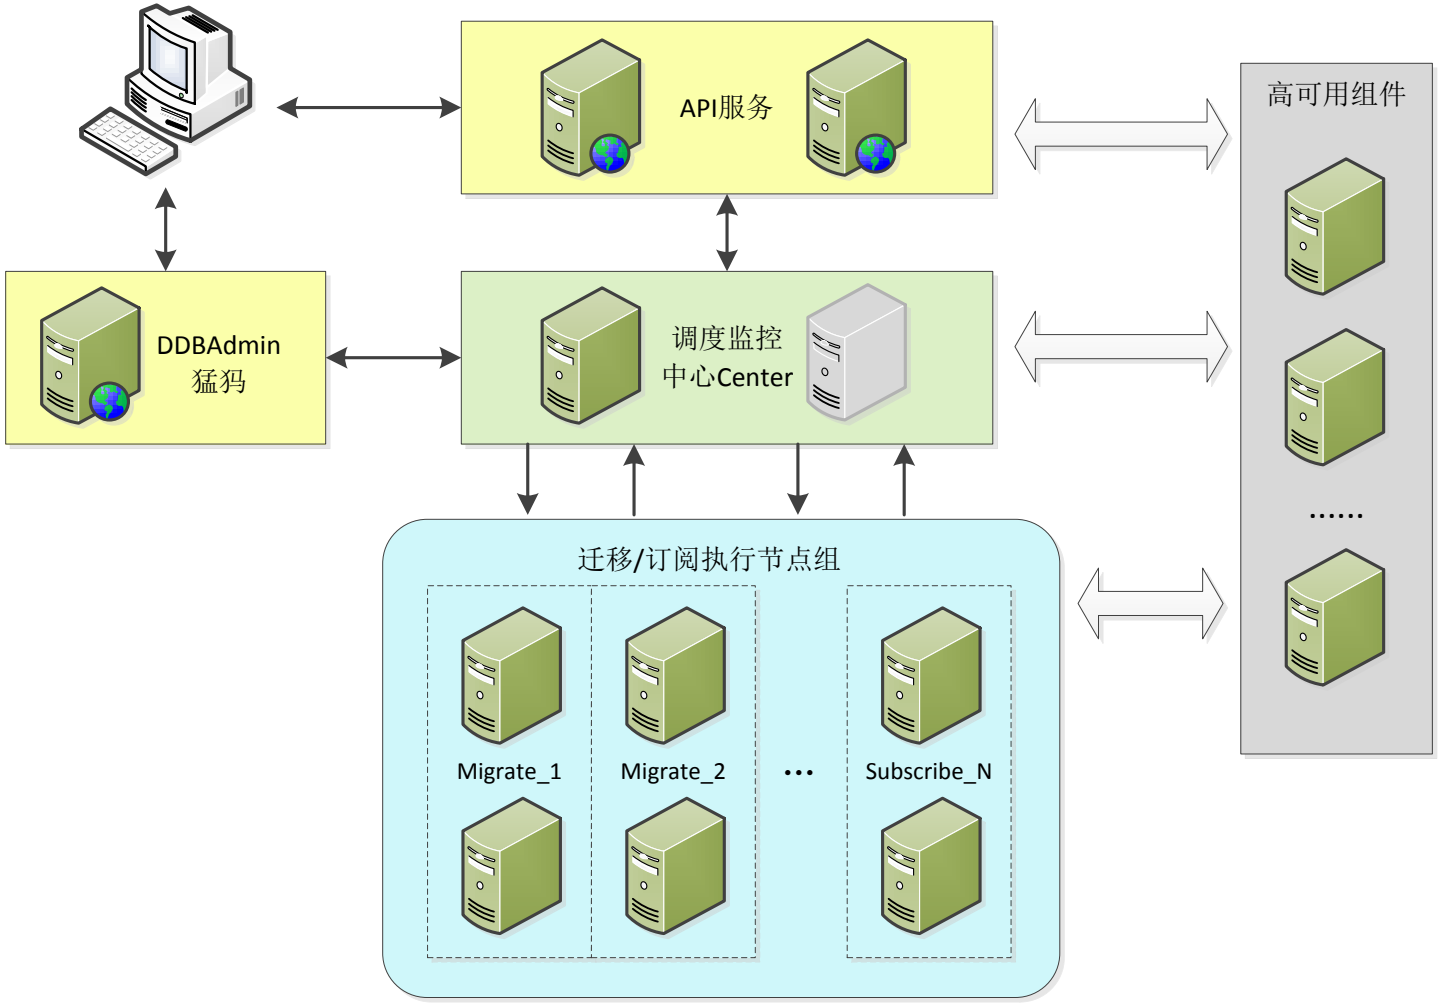
API服务
高可用组件
DDBAdmin
猛犸
调度监控
中心Center
.....
迁移/订阅执行节点组
Migrate_1
Migrate_2
...
Subscribe_N

系统架构

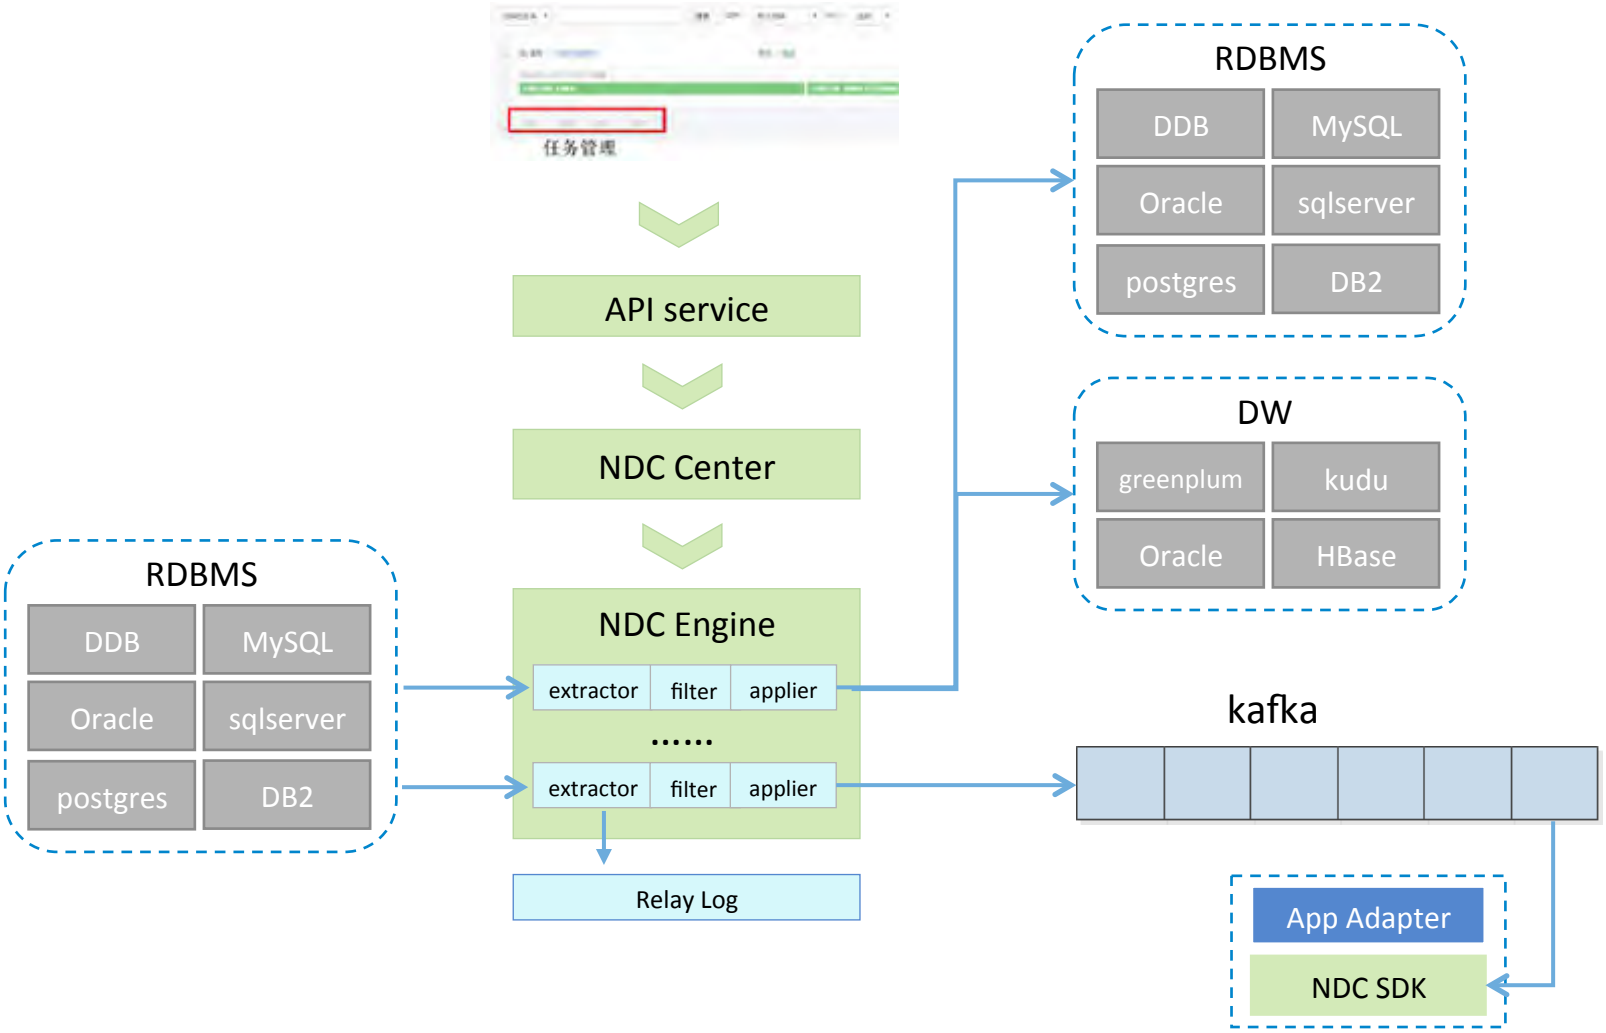
任务管理
API service
NDC Center
NDC Engine
extractor
filter
applier
.....
extractor
filter
applier
Relay Log
RDBMS
DDB
MySQL
Oracle
sqlserver
postgres
DB2
RDBMS
DDB
MySQL
Oracle
sqlserver
postgres
DB2
DW
greenplum
kudu
Oracle
HBase
kafka
App Adapter
NDC SDK

NDC原理

- 服务特色
  - 无锁迁移
  - 并发迁移
  - 并发回放
  - 断点续传

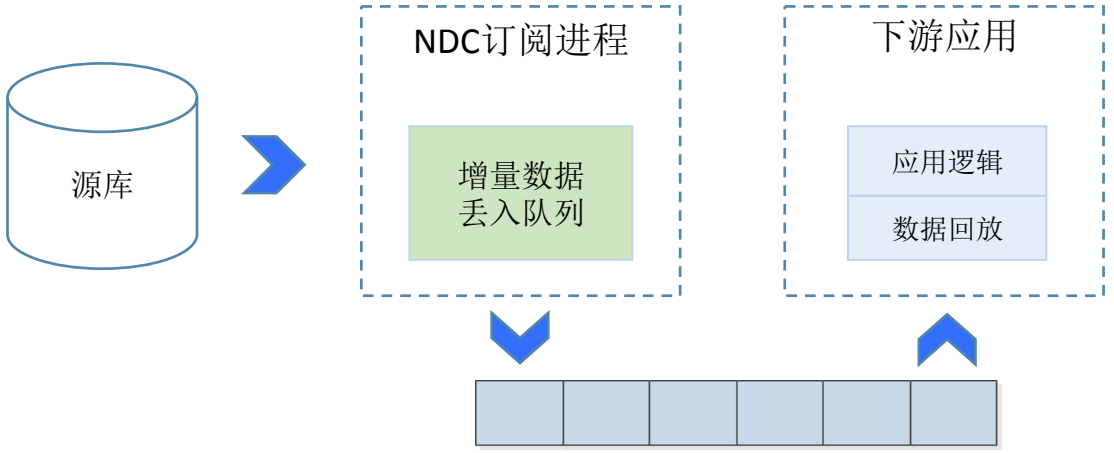

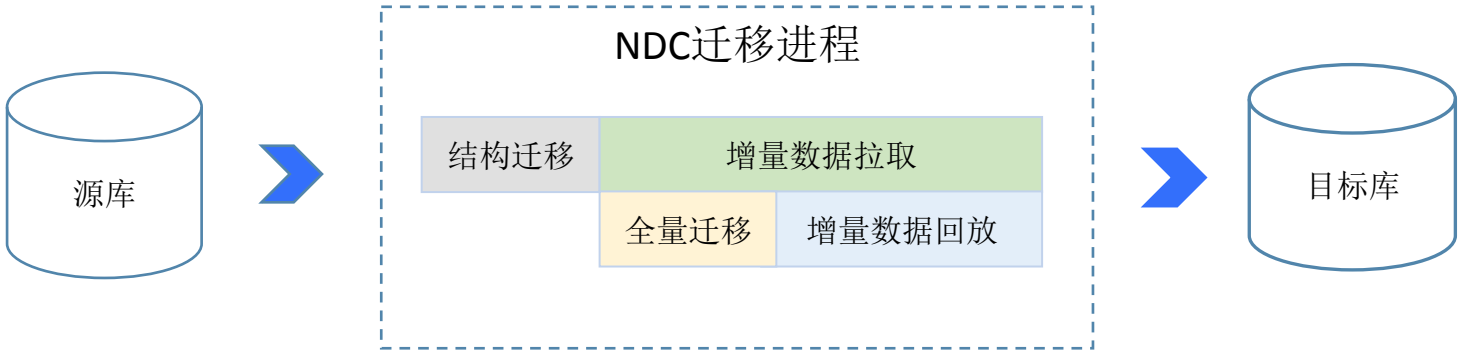

高可用实践

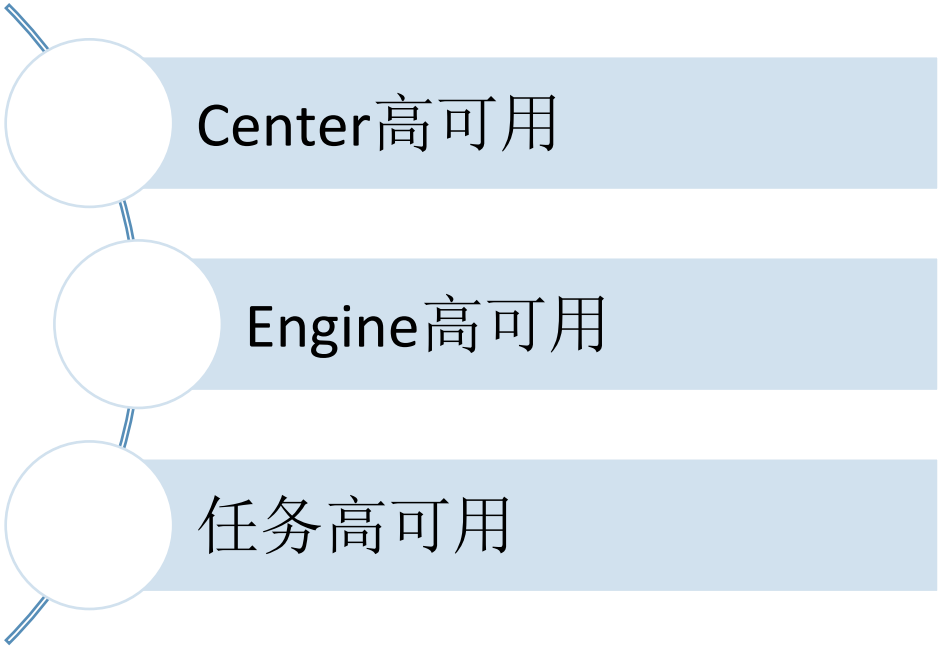

Center高可用

- 解决方案
  - Zookeeper + Cruator
  - LeaderSelector
  - PathCache
- 类似方案
  - Keepalived
- 存在问题
  - Brain split

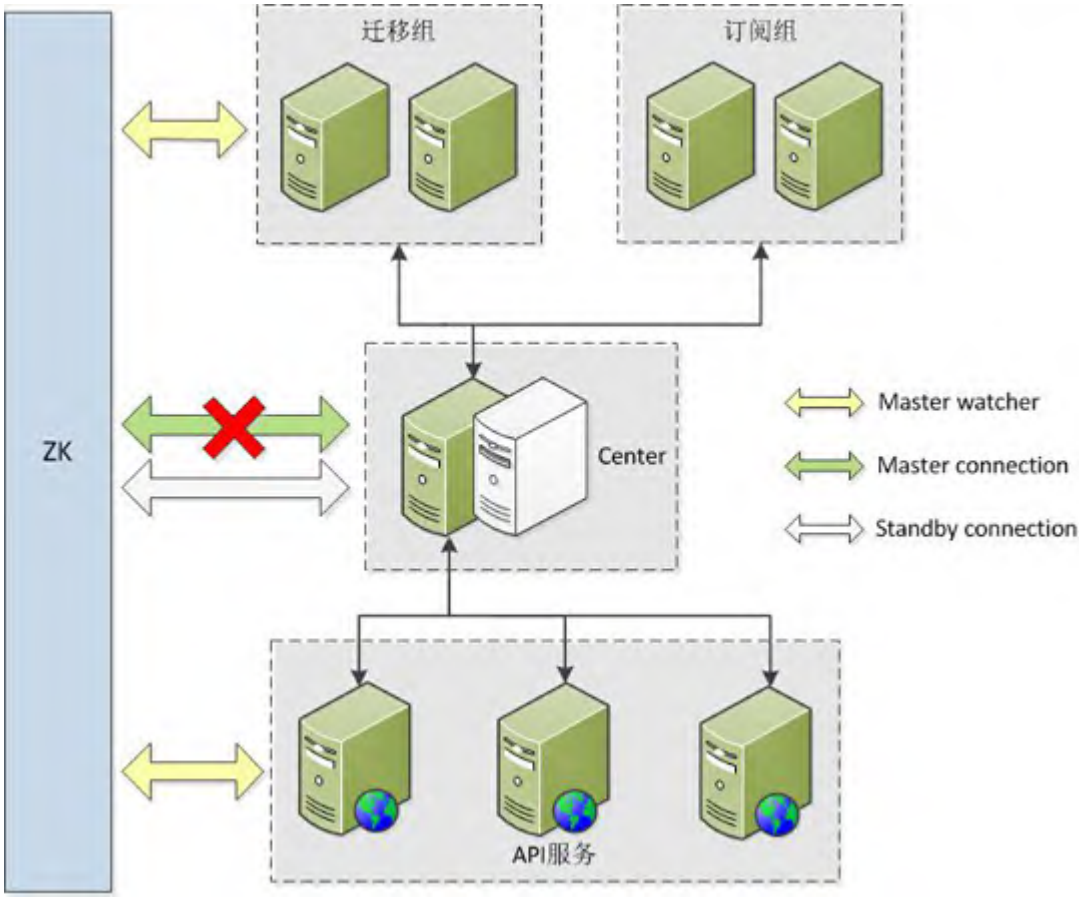

Center高可用

- 解决方案
  - Zookeeper + Cruator
  - LeaderSelector
  - PathCache
- 类似方案
  - Keepalived
- 存在问题
  - Brain split

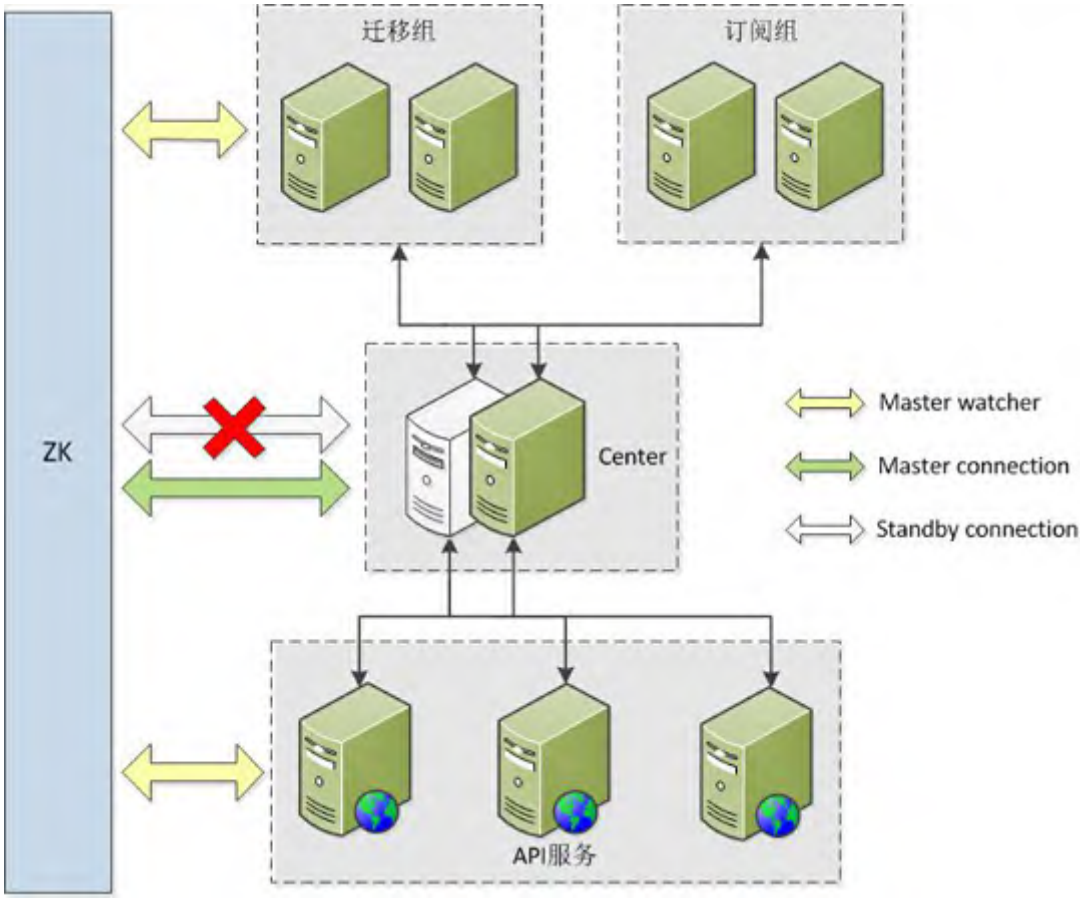

脑裂解决方案

- 基本前提
  - Center状态存在系统库
  - 系统库是高可用的
- 基本方案
  - Lock leader为每个操作上锁
  - Switch leader时先lock leader

Lock leader:
select id from leader for update

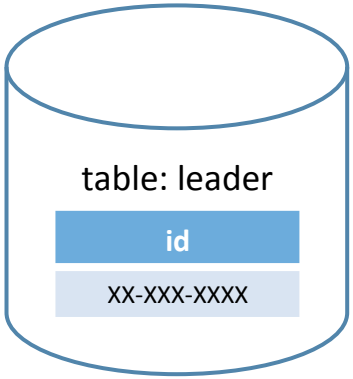

Center operation

```
lock leader;
if (leader id matched)
   Operate;
else
    return error;
commit/rollback;
```

Switch leader

```
lock leader;
update leader id;
Commit;
load meta data;
Initialize server
……
```

Center无脑裂

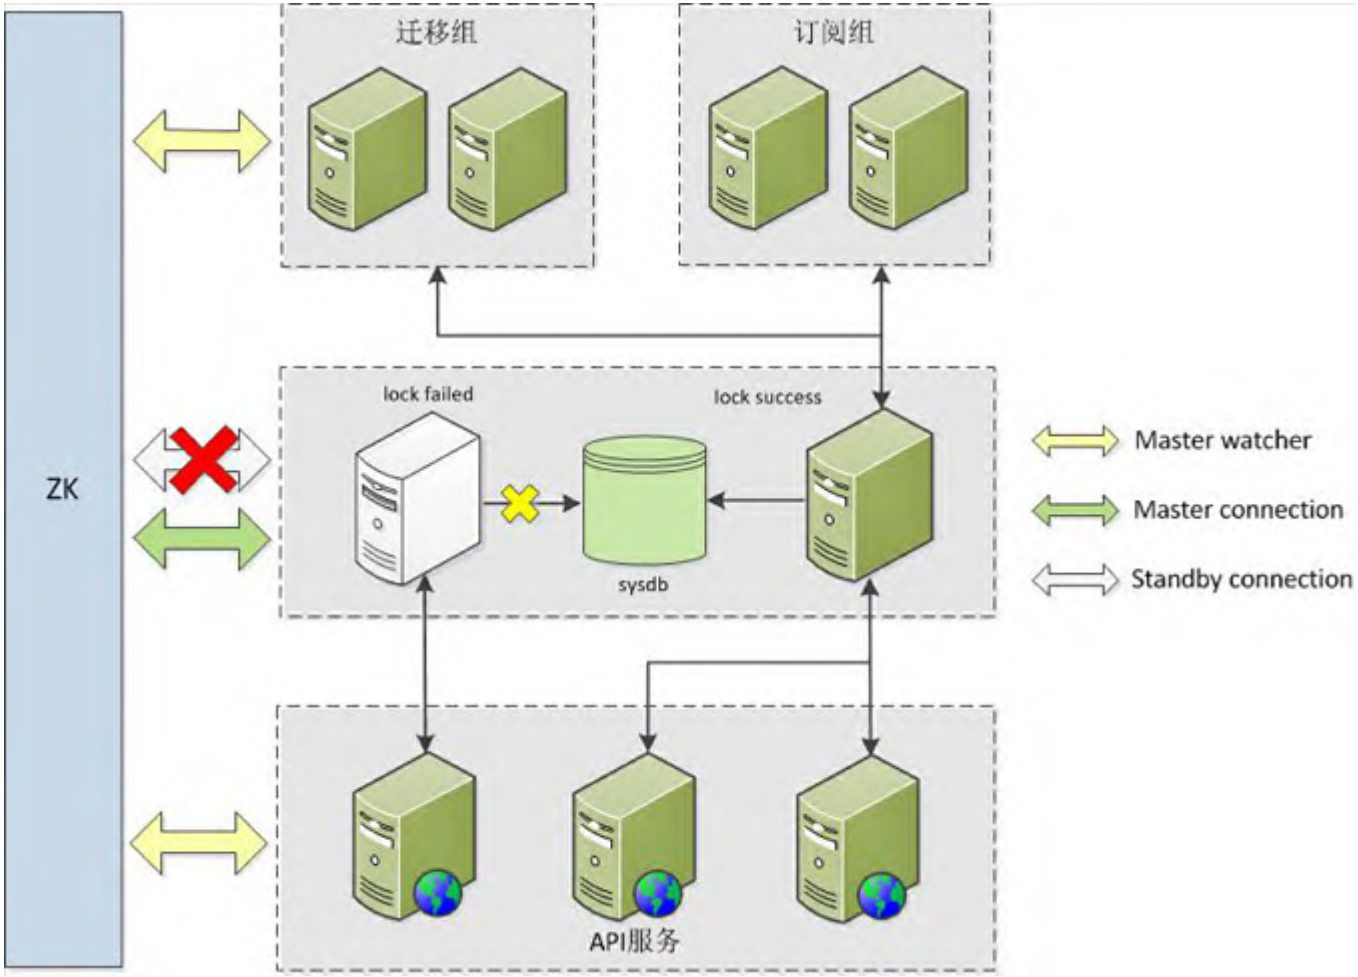
迁移组
订阅组
ZK
lock failed
lock success
sysdb
API服务
Master watcher
Master connection
Standby connection

Engine高可用

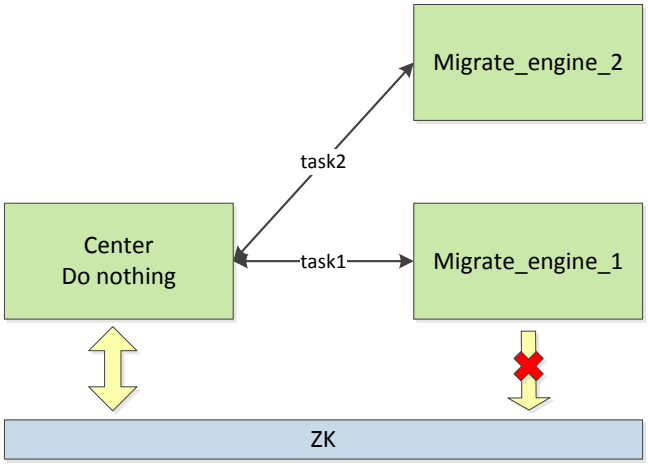

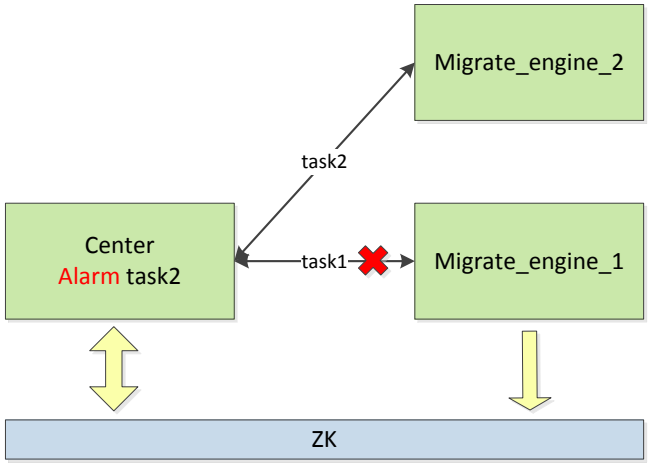

- 要点
  - 租约与ZK双重验证
  - kick out先于fail over

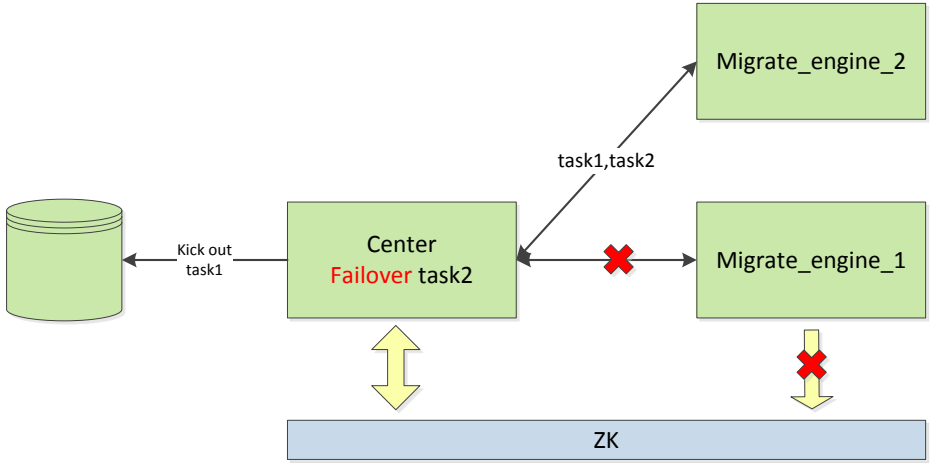

任务高可用

- 要点
  - 执行进程定期探活源端
  - 探活失败后先本地重试N次再上报

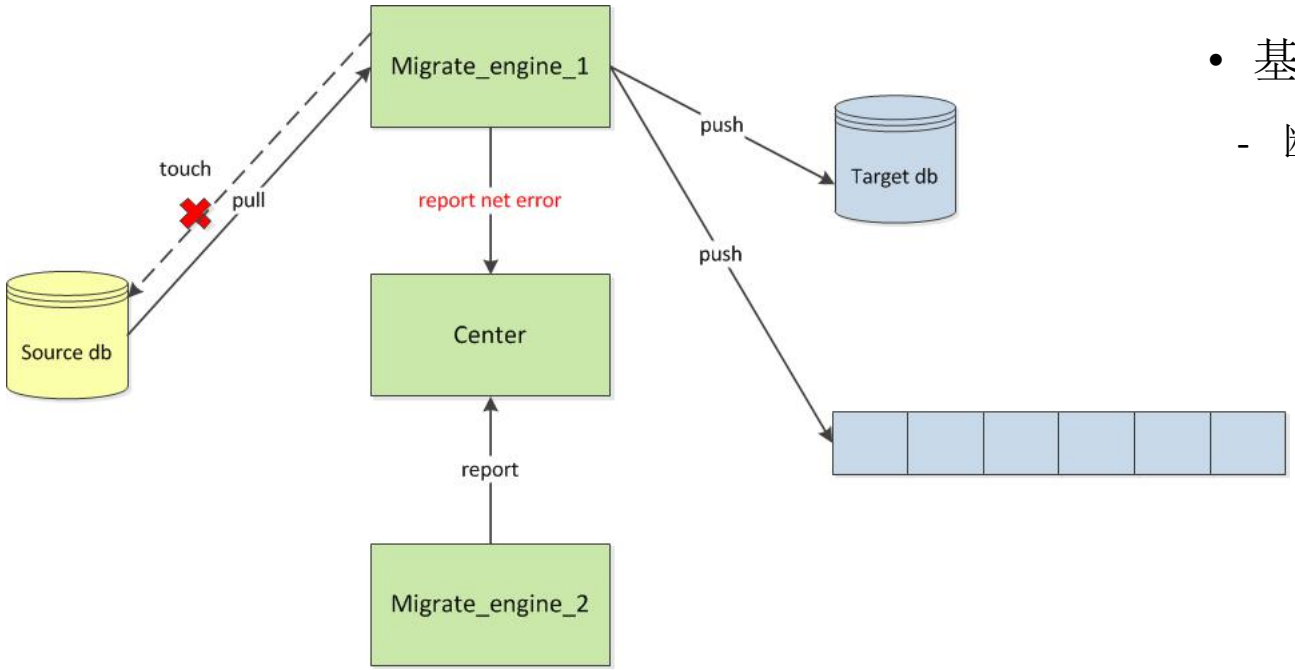

- 基本前提
  - 断点续传

任务高可用

- 要点
  - Center再次探活源端，成功
  - Job fail over到Engine2

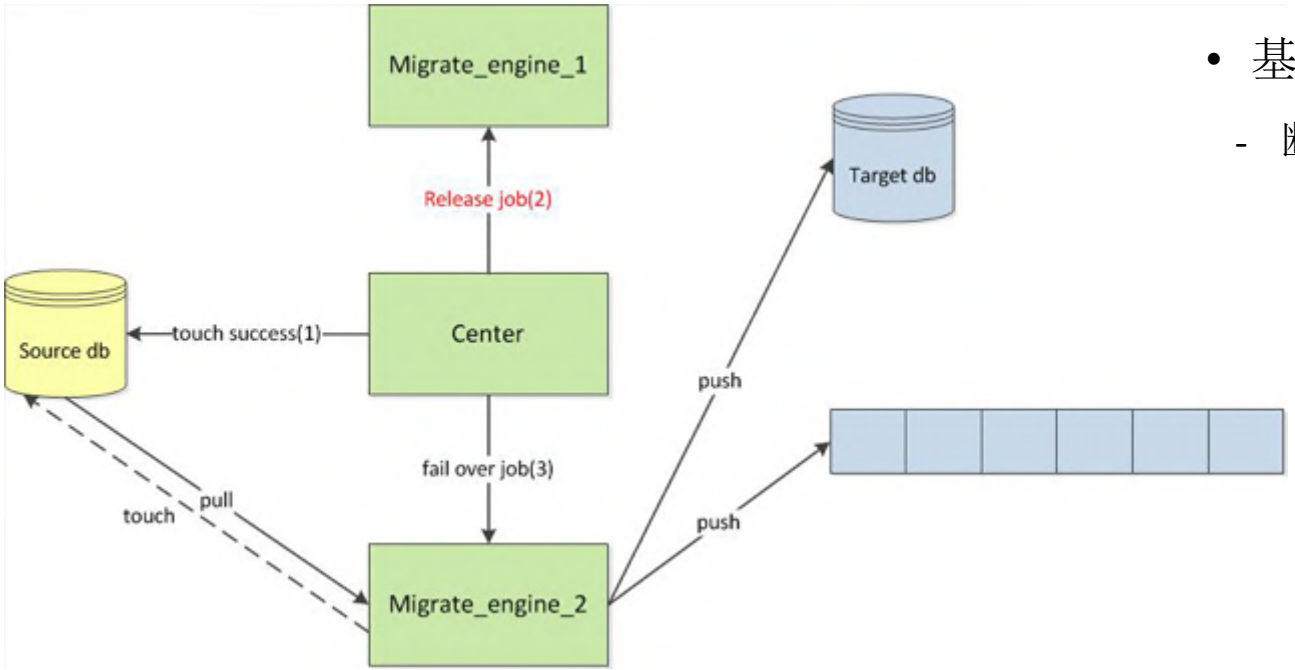

- 基本前提
  - 断点续传

源端漂移

- 要点
  - Center再次探活源端，成功
  - Job fail over到Engine2

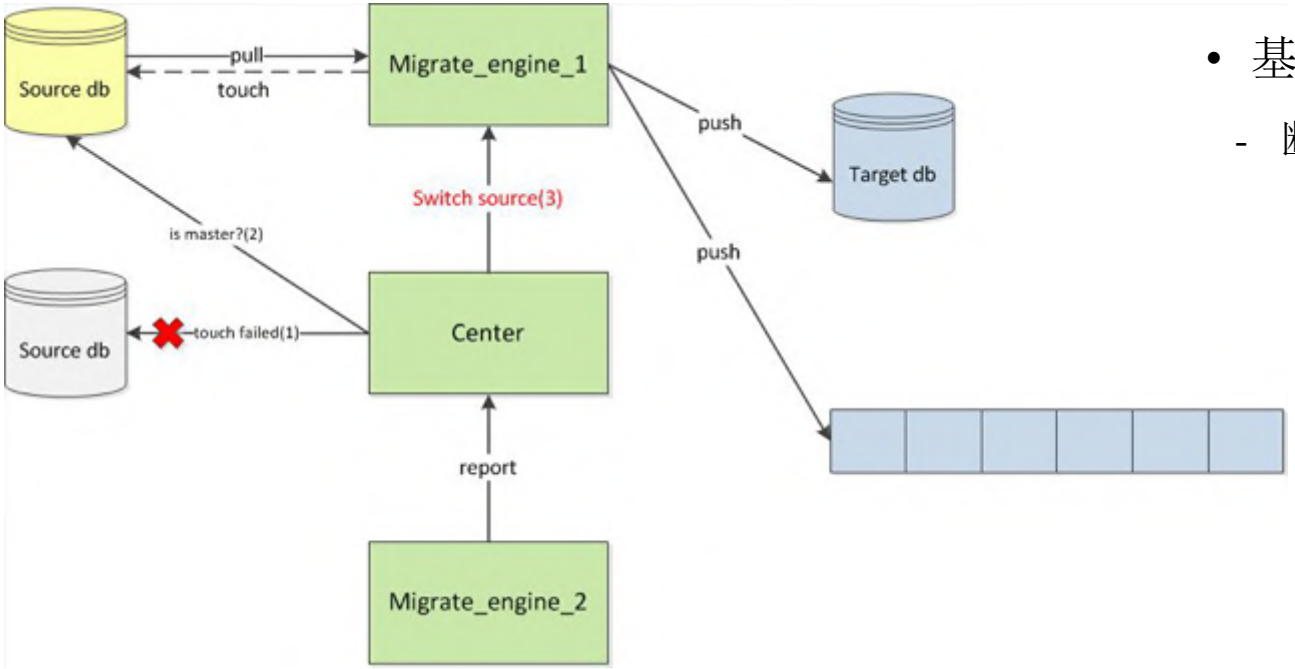

- 基本前提
  - 断点续传

小结

- 设计原则
  - 监控先于高可用
  - 高可用分层，不过度设计
  - 高可用插件化，保持系统精简
  - 多重验证，避免误切

- 源端漂移问题
  - 如何保证数据不丢？
  - GTID, 基于触发器


WOTA
51CTO
Thank you !