

大数据架构稳定性保障实践

顺丰科技有限公司

林国强 大数据架构负责人

引子

大数据发展至今，已经有近10年时间，在这10年时间里，大数据架构发生了很多变化
而这些变化，不断冲击当前企业大数据架构，给业务部门和信息部门都带来很大挑战

10

200TB

每天新增

+

200PB+

存量规模

如此数据规模下，**如何保证大数据架构稳定性？** 本次演讲将会分享顺丰科技大数据团队的相关实战经验

目录

一、大数据架构历史变迁

- 洪荒期
- 远古期
- 近古期
- 近现代
- 现如今

二、架构稳定的关键因素

- 扩展性
- 可用性
- 自适性
- 易用性
- 先进性

三、未来大数据架构畅想

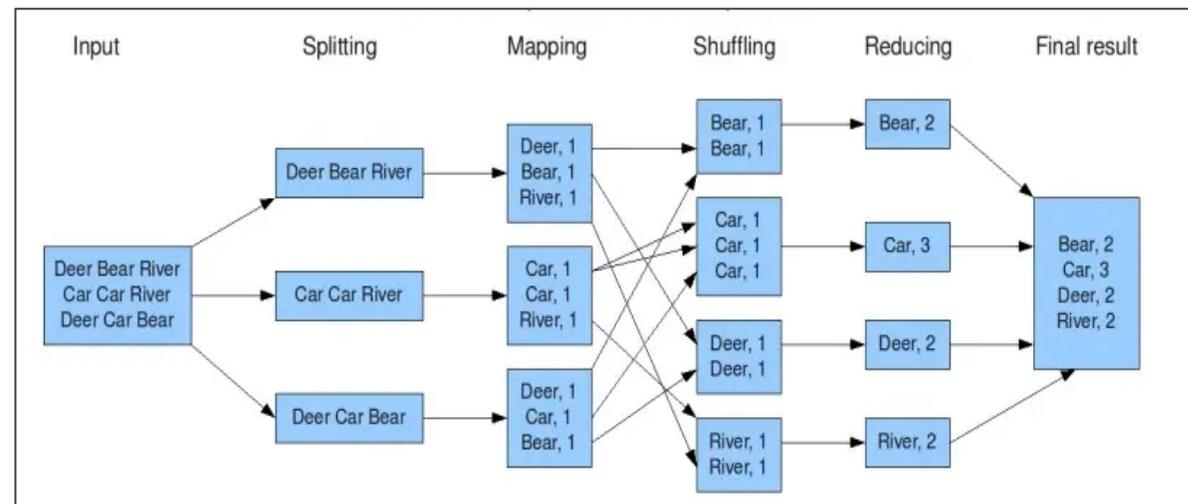
一、大数据架构历史变迁

洪荒期、远古期、近古期、近现代、现如今

大数据架构变迁-洪荒期&MR

MR原理

- Map/Reduce是一个用于大规模数据处理的分布式计算模型，它最初是由Google工程师设计并实现的，Google已经将它完整的MapReduce论文公开发布了
- 其中对它的定义是，**Map/Reduce是一个编程模型，是一个用于处理和生成大规模数据集的相关的实现。**用户定义一个map函数来处理一个key/value对以生成一批中间的key/value对，再定义一个reduce函数将所有这些中间的有着相同key的values合并起来。很多现实世界中的任务都可用这个模型来表达。



价值

- oracle、mysql、db2等传统数据库，无法处理海量数据，日增长100亿级，每天100TB左右的离线专题数据分析
- 引入hadoop mr架构解决离线跑批问题

变化

- Oracle存储全部需要改为MR/HSQL，重新编写后端调度

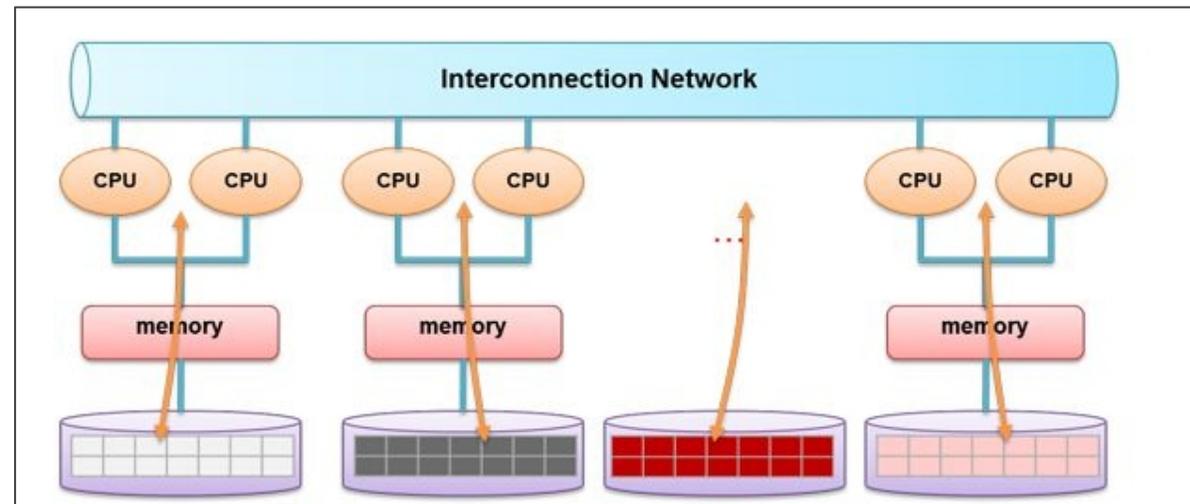
收益

- 公司解决了大规模数据分析问题，一部分员工因为解决了关键业务痛点，脱颖而出，成立最原始的大数据团队

大数据架构变迁-远古期&MPP

MPP原理

- MPP即大规模并行处理（Massively Parallel Processor）。每个节点都有独立的磁盘存储系统和内存系统，业务数据根据数据库模型和应用特点划分到各个节点上，每台数据节点通过专用网络或者商业通用网络互相连接，彼此协同计算，作为整体提供数据库服务。
- 非共享数据库集群有完全的可伸缩性、高可用、高性能、优秀的性价比、资源共享等优势



价值

- 架构简单，端到端解决湖和仓的问题，在中小规模场景下，比较有优势，解决了原来hadoop架构响应速度和并发度问题（Scalability: 100级别），并且开发人员只需掌握sql即可

变化

- 针对中小规模场景下，可以直接替换hadoop
- 在大规模场景下，需要作为hadoop的后端输出承载，面向业务侧提供高价值数据分析

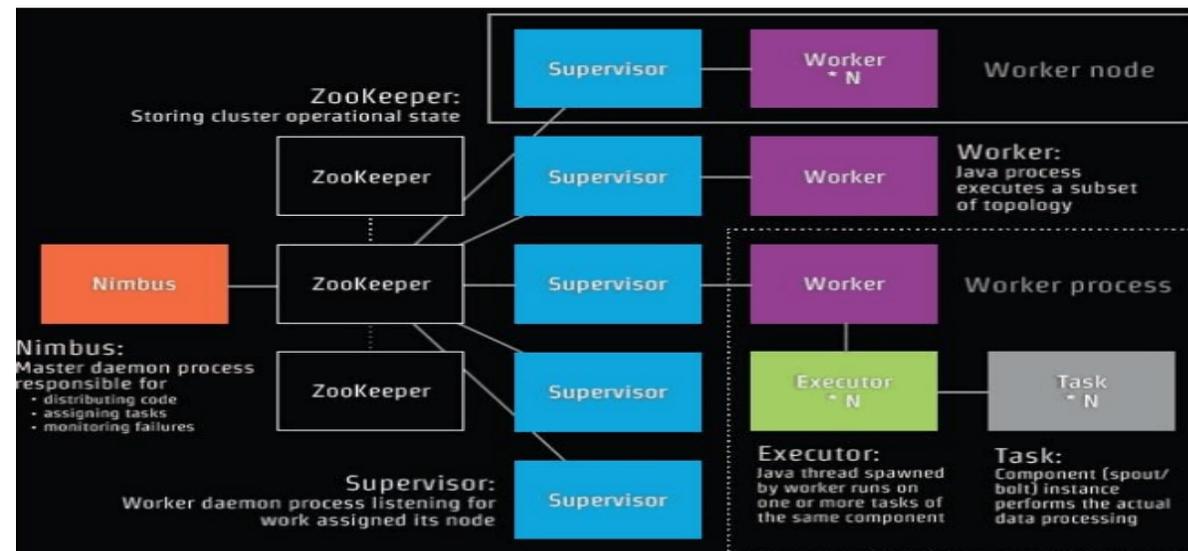
收益

- 公司使用更加简单架构，更简单的开发模式，应对不断变化的需求，一部分员工因为对mpp熟悉，独立一个团队，专注此项工作

大数据架构变迁-近古期&Storm

Storm原理

- Storm采用Master/Slave体系结构,分布式计算由Nimbus和Supervisor两类服务进程实现,Nimbus进程运行在集群的主节点,负责任务的指派和分发,Supervisor运行在集群的从节点,负责执行任务的具体部分。
- Nimbus: Storm集群的Master节点,负责资源分配和任务调度,负责分发用户代码,指派给具体的Supervisor节点上的Worker节点,去运行Topology对应组件(Spout/Bolt)的Task。
- Supervisor: Storm集群的从节点,负责接受Nimbus分配的任务,启动和停止属于自己管理的worker进程。通过Storm的配置文件中的supervisor.slots.ports配置项,可以指定在一个Supervisor上最大允许多少个Slot,每个Slot通过端口号来唯一标识,一个端口号对应一个Worker进程(如果该Worker进程被启动)



价值

- storm没出来之前,大家主要是写后端的预警程序,实现实时预警,需求响应时间长,且大规模场景下的处理非常复杂,storm之后,有一个相对好的架构,支撑实时流处理业务,能够更快速响应业务,处理海量实时数据

变化

- 需要把原先java、c、c++等编写的流处理程序,切换到storm,有一定的迁移工作,但是架构更稳定

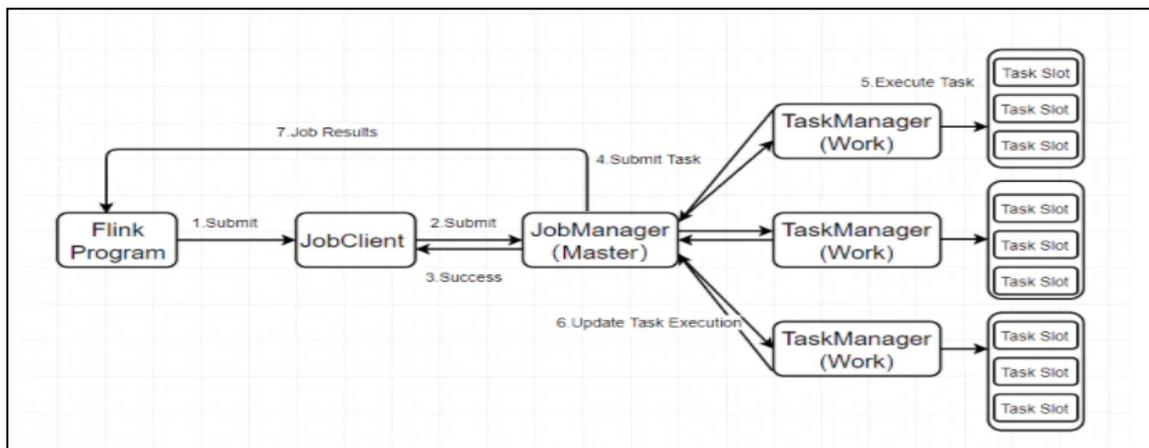
收益

- 公司有更弹性、更简单的架构处理实时流数据,能更快速应对业务需求,同时,一部分员工因为对这部分比较熟悉,成立实时数据团队

大数据架构变迁-近现代&Flink/Spark

Flink原理

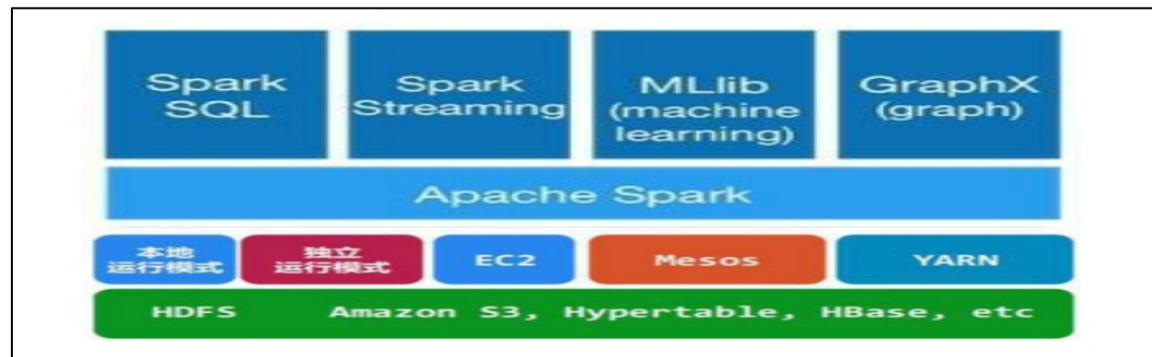
- Flink 是一个流处理框架，支持流处理和批处理，特点是流处理可容错、可扩展、高吞吐、低延迟。批处理是只有处理一批完成后，才会经过网络传输到下一个节点，流处理的优点是低延迟，批处理的优点是高吞吐



- **价值**: Flink比Storm的吞吐性能更强，具备一定的批处理能力，技术生态栈支持更广，架构更统一。
- **变化**: 需要把基于storm编写的实时流处理程序，迁移至flink，改造量还是比较多
- **收益**: 公司具备吞吐性能更强的流处理架构，基于flink能够做更多场景，如实时预测、实时TF；由原来实时流处理团队负责这部分架构

Spark原理

- Spark是一个围绕速度、易用性和复杂分析构建的大数据处理框架，最初在2009年由加州大学伯克利分校的AMPLab开发，并于2010年成为Apache的开源项目
- Spark基于内存的迭代计算框架，适用于需要多次操作特定数据集的应用场合。需要反复操作的次数越多，所需读取的数据量越大，受益越大

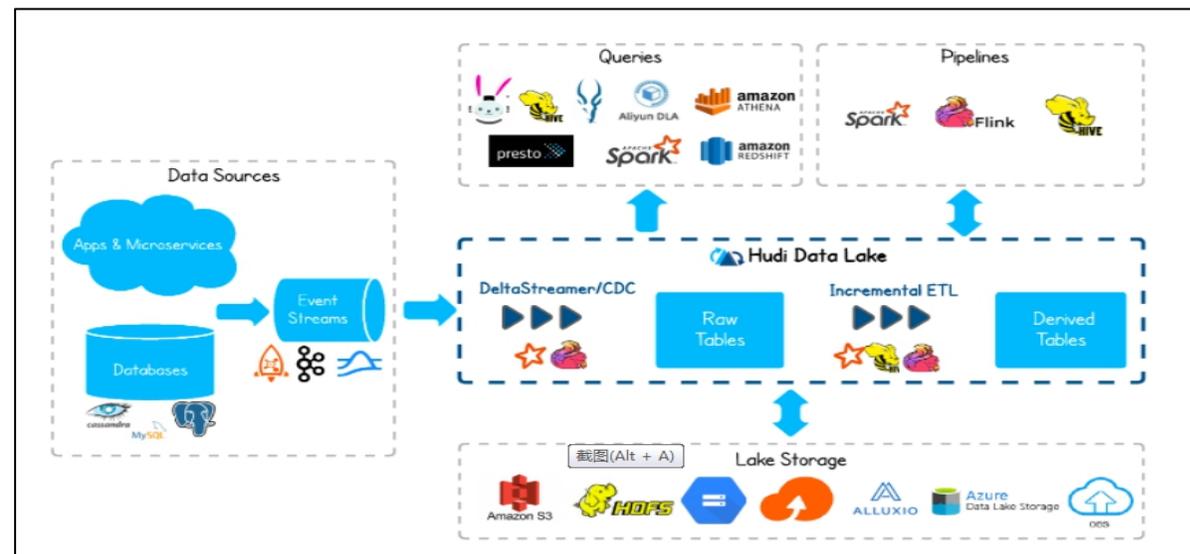


- **价值**: Spark相比Hadoop mr架构，计算过程不需要反复落盘，减少大量IO操作，大大提高计算速度。且技术生态栈较广，很好支持ML和流处理相关板块。
- **变化**: 从HSQL迁移至Spark SQL，最开始时，还是需要不少工作量；
- **收益**: 公司离线数据湖计算能力大致提高了2~3倍；成立一个新的算法团队，承担Spark计算框架业务

大数据架构变迁-现如今&实时数据湖架构

实时数据湖原理

- Hudi是Hadoop Updates and Incrementals的简写，它是由Uber开发并开源的Data Lakes解决方案，最初是用于解决数仓中 Lambda 架构中数据一致性的问题，将增量处理模型替代流式处理模型，并提供了 Upsert 和 Incremental Pull 两个非常重要的 feature
- Update/Delete记录：Hudi使用细粒度的文件/记录级别索引来支持 Update/Delete记录，同时还提供写操作的事务保证。查询会处理最后一个提交的快照，并基于此输出结果。
- 变更流：Hudi对获取数据变更提供了一流的支持：可以从给定的时间点获取给定表中已updated/inserted/deleted的所有记录的增量流



价值

- 解决了lambda架构指标一致性和资源重复投入问题，同时提高了指标分析时效性，提升了管理和运营的决策效率

变化

- 从hive/spark切换到hudi体系，会在数据接入侧需要进行调整，从overwrite切换为merge into，开发侧需要修改增量获取方式，代价不大，局部改动

收益

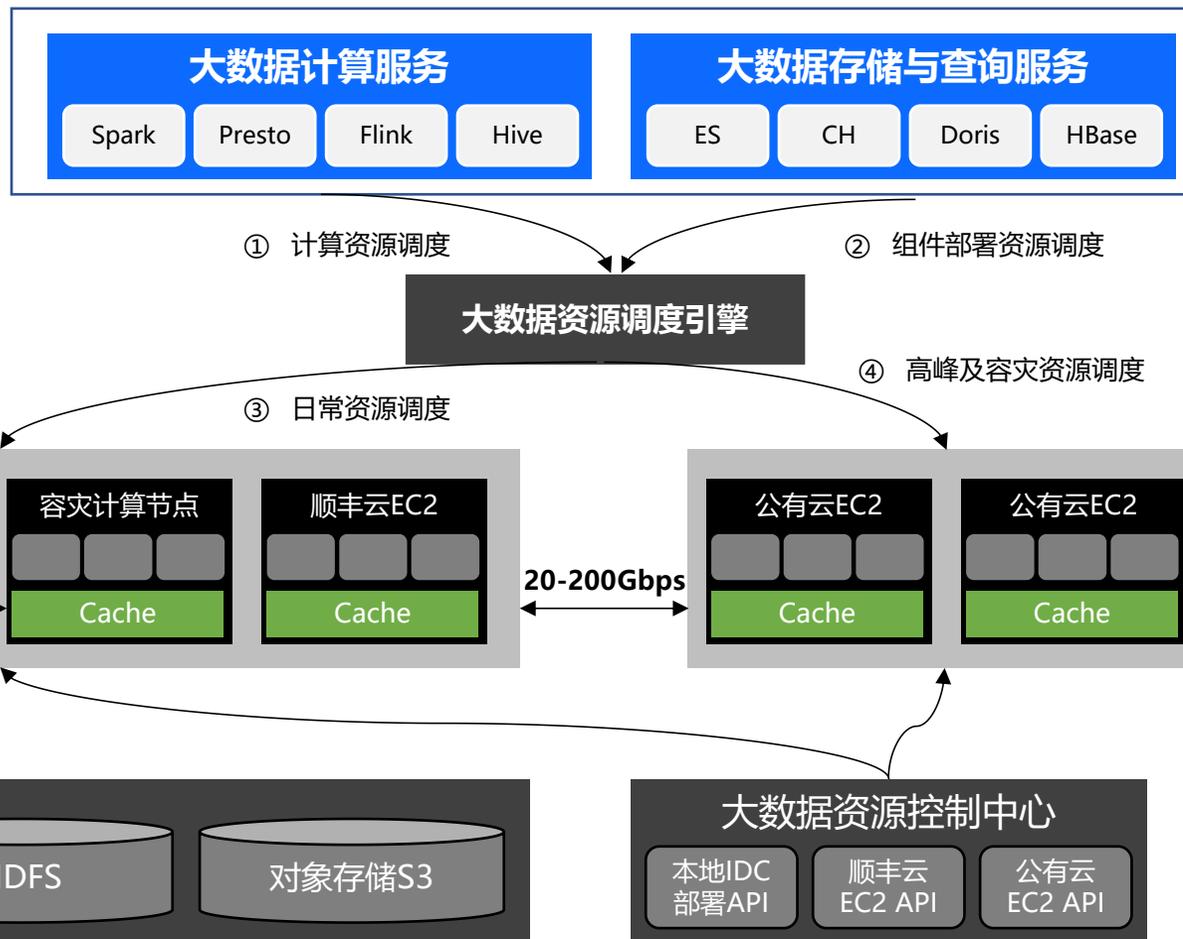
- **业务指标时效，从T+1天到T+0**，大大提升了指标时效，面向业务侧具备显性价值。同时，一部分员工因为比较熟悉，单独成立实时数据湖团队

二、架构稳定的关键因素

扩展性、可用性、自适性、易用性、先进性

架构稳定性关键因素-扩展性

- **纵向扩容** (增加单节点CPU、内存和存储)
- **横向扩容** (增加节点, 增大集群规模)
- **存算分离** (按计算或者存储分开扩容, 且复用容灾资源和公有云弹性资源)



弹性大数据服务

- 组件容器化
- 存储与计算分离
- 资源弹性伸缩

跨机房缓存

- 统一名字空间
- 数据分层存储及分布策略
- 数据加密存储

跨机房存储: HDFS

- 存储资源弹性上云
- 多云部署

资源弹性伸缩自动部署

架构稳定性关键因素-可用性&容灾双活

Yarn

难点: 跨机房部署带宽压力大

解决方案:

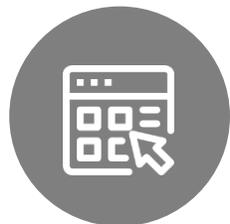
改造源码, 通过标签调度结合HDFS跨机房容灾、Alluxio, 实现跨机房双活

HBase

难点: 客户端与业务系统嵌入深, 切换难

解决方案:

建立HBase管理平台, 提供HBase SDK, 实现远程一键切换



HDFS

难点: 跨机房部署性能低、不稳定

解决方案:

改造源码实现双活

ElasticSearch

难点: 双活依靠双写, 有一致性问题, 效率低, 客户端不便切换

解决方案:

改造源码, 通过CCR方式实现数据主从同步; 建立数据服务平台, 让ES的使用服务化

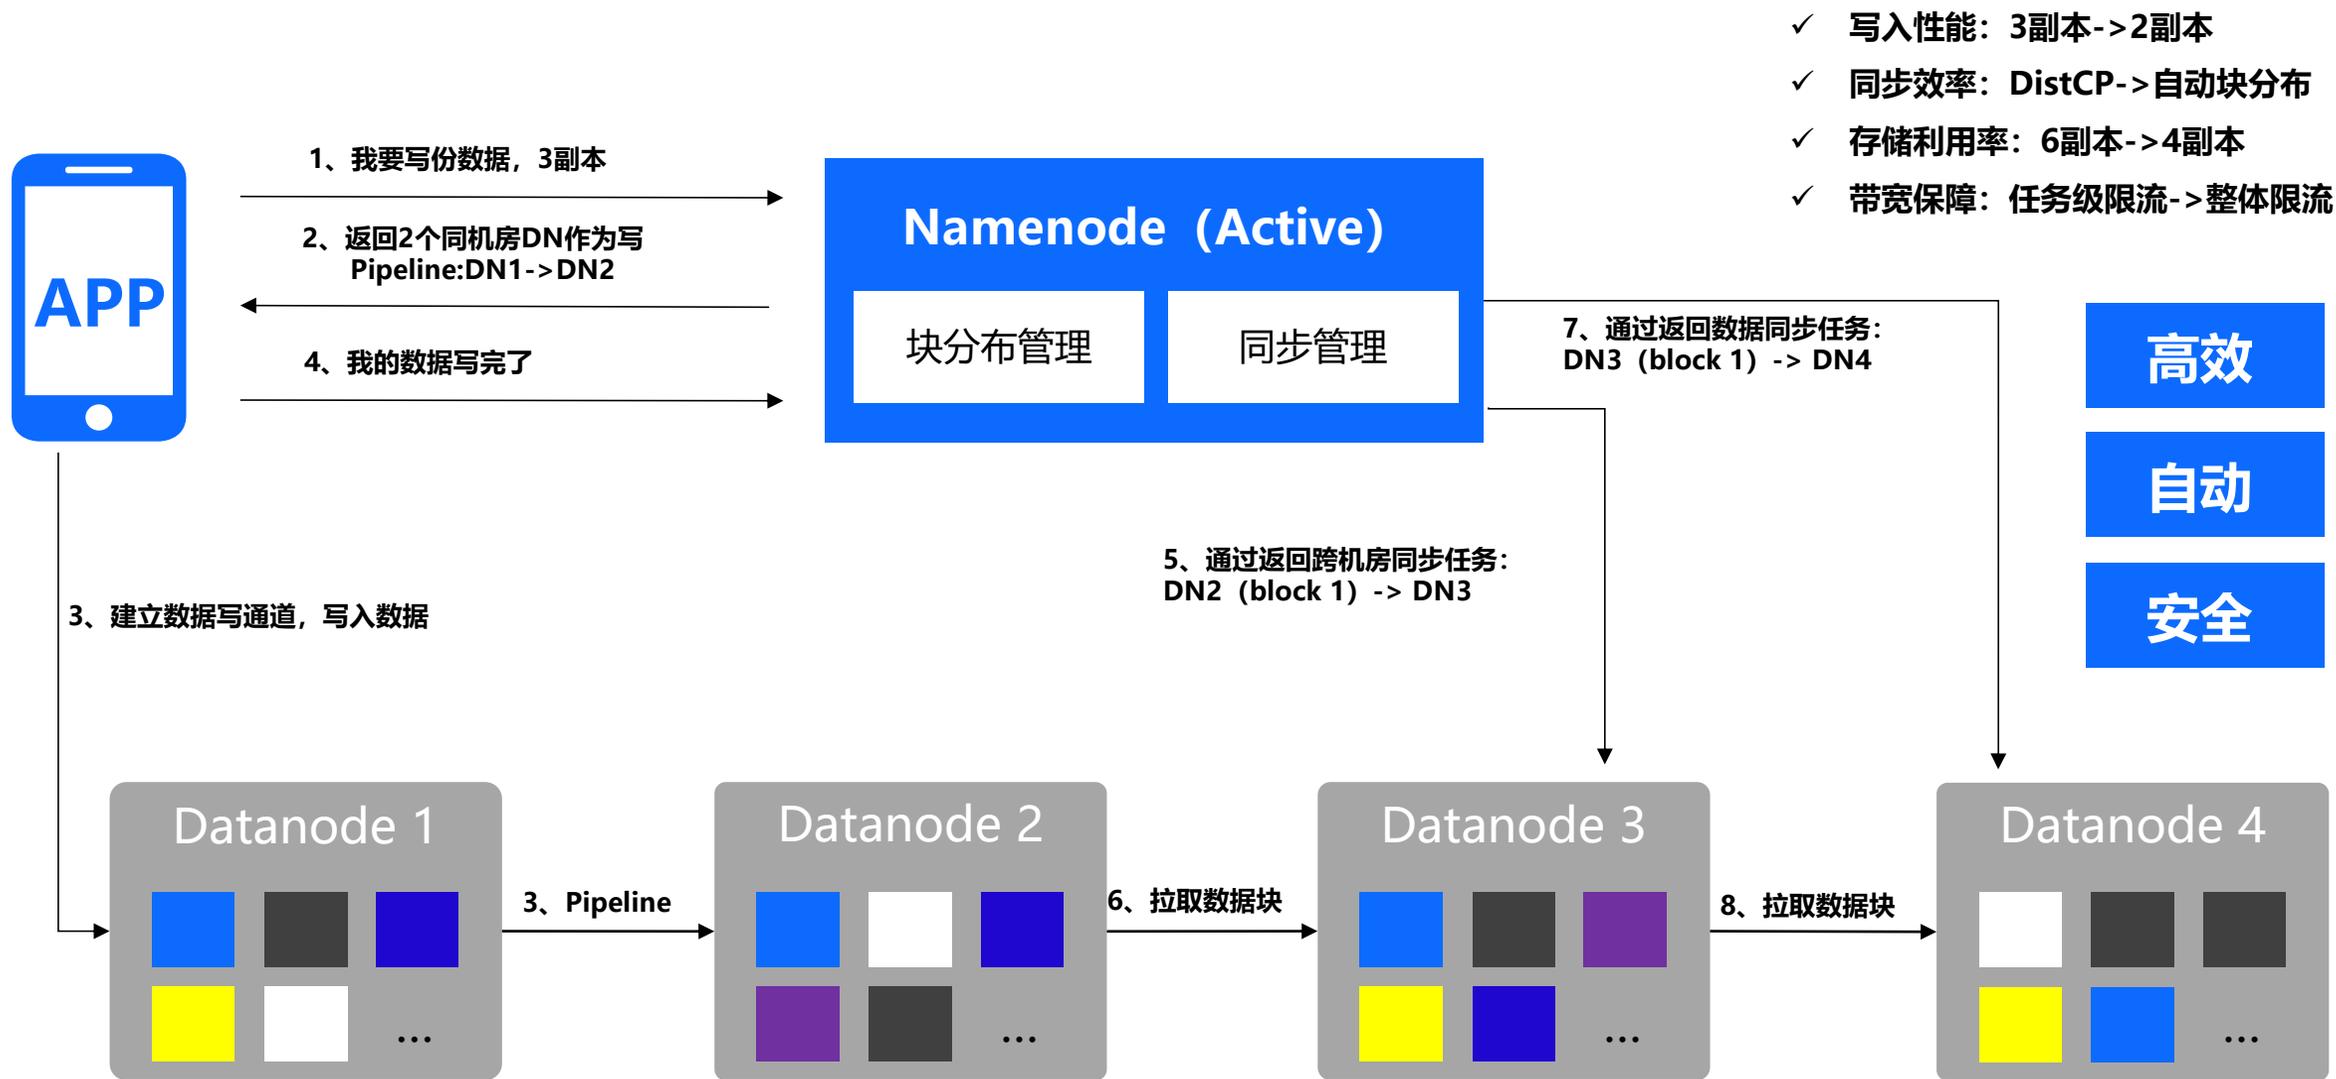
Kafka

难点: 主备集群间偏移量不一致, 客户端与业务系统嵌入深, 切换难

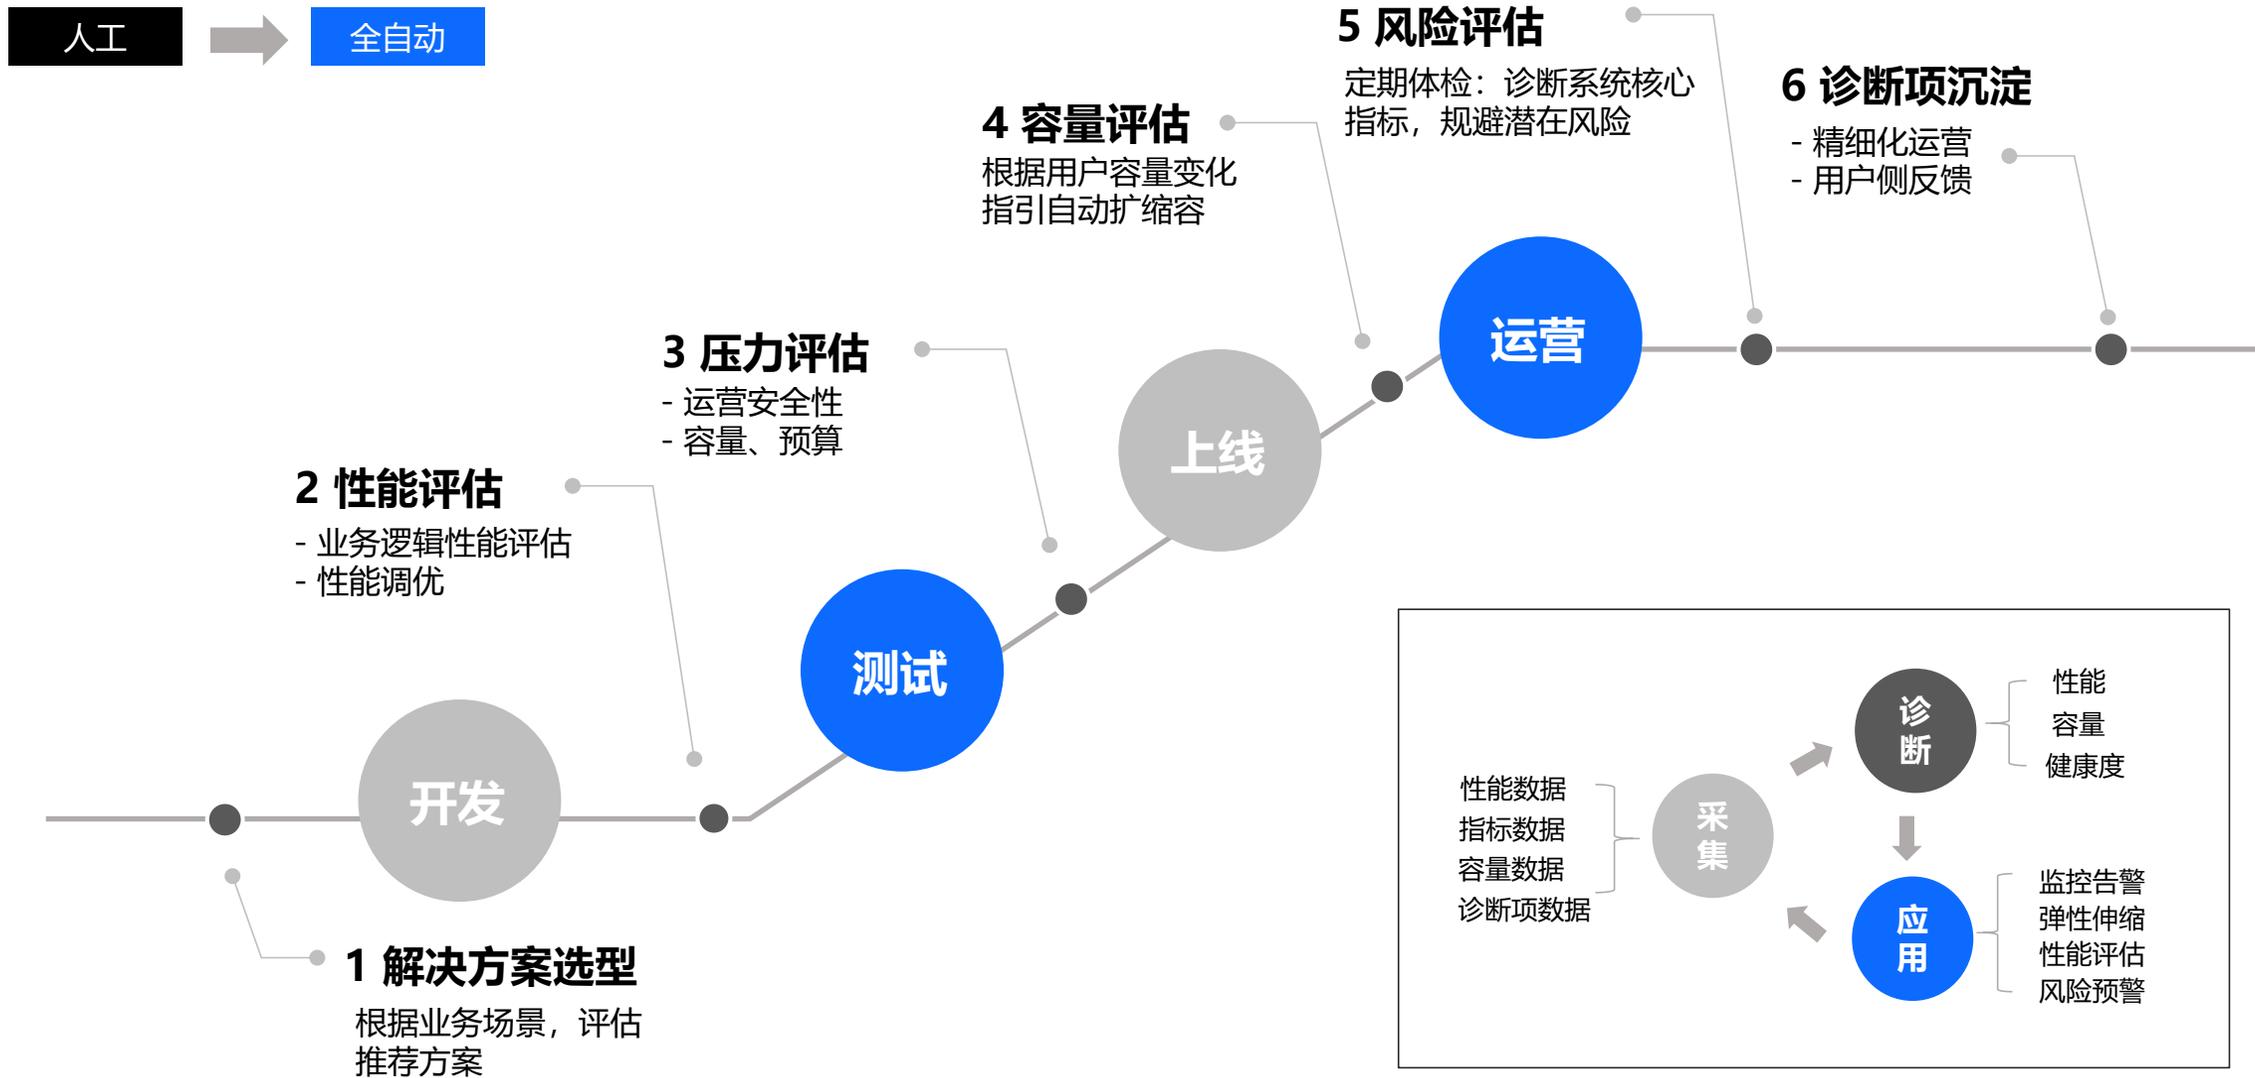
解决方案:

建立Kafka管理平台, 改造MirrorMaker, 实现偏移量的同步, 并提供Kafka SDK, 实现远程一键切换

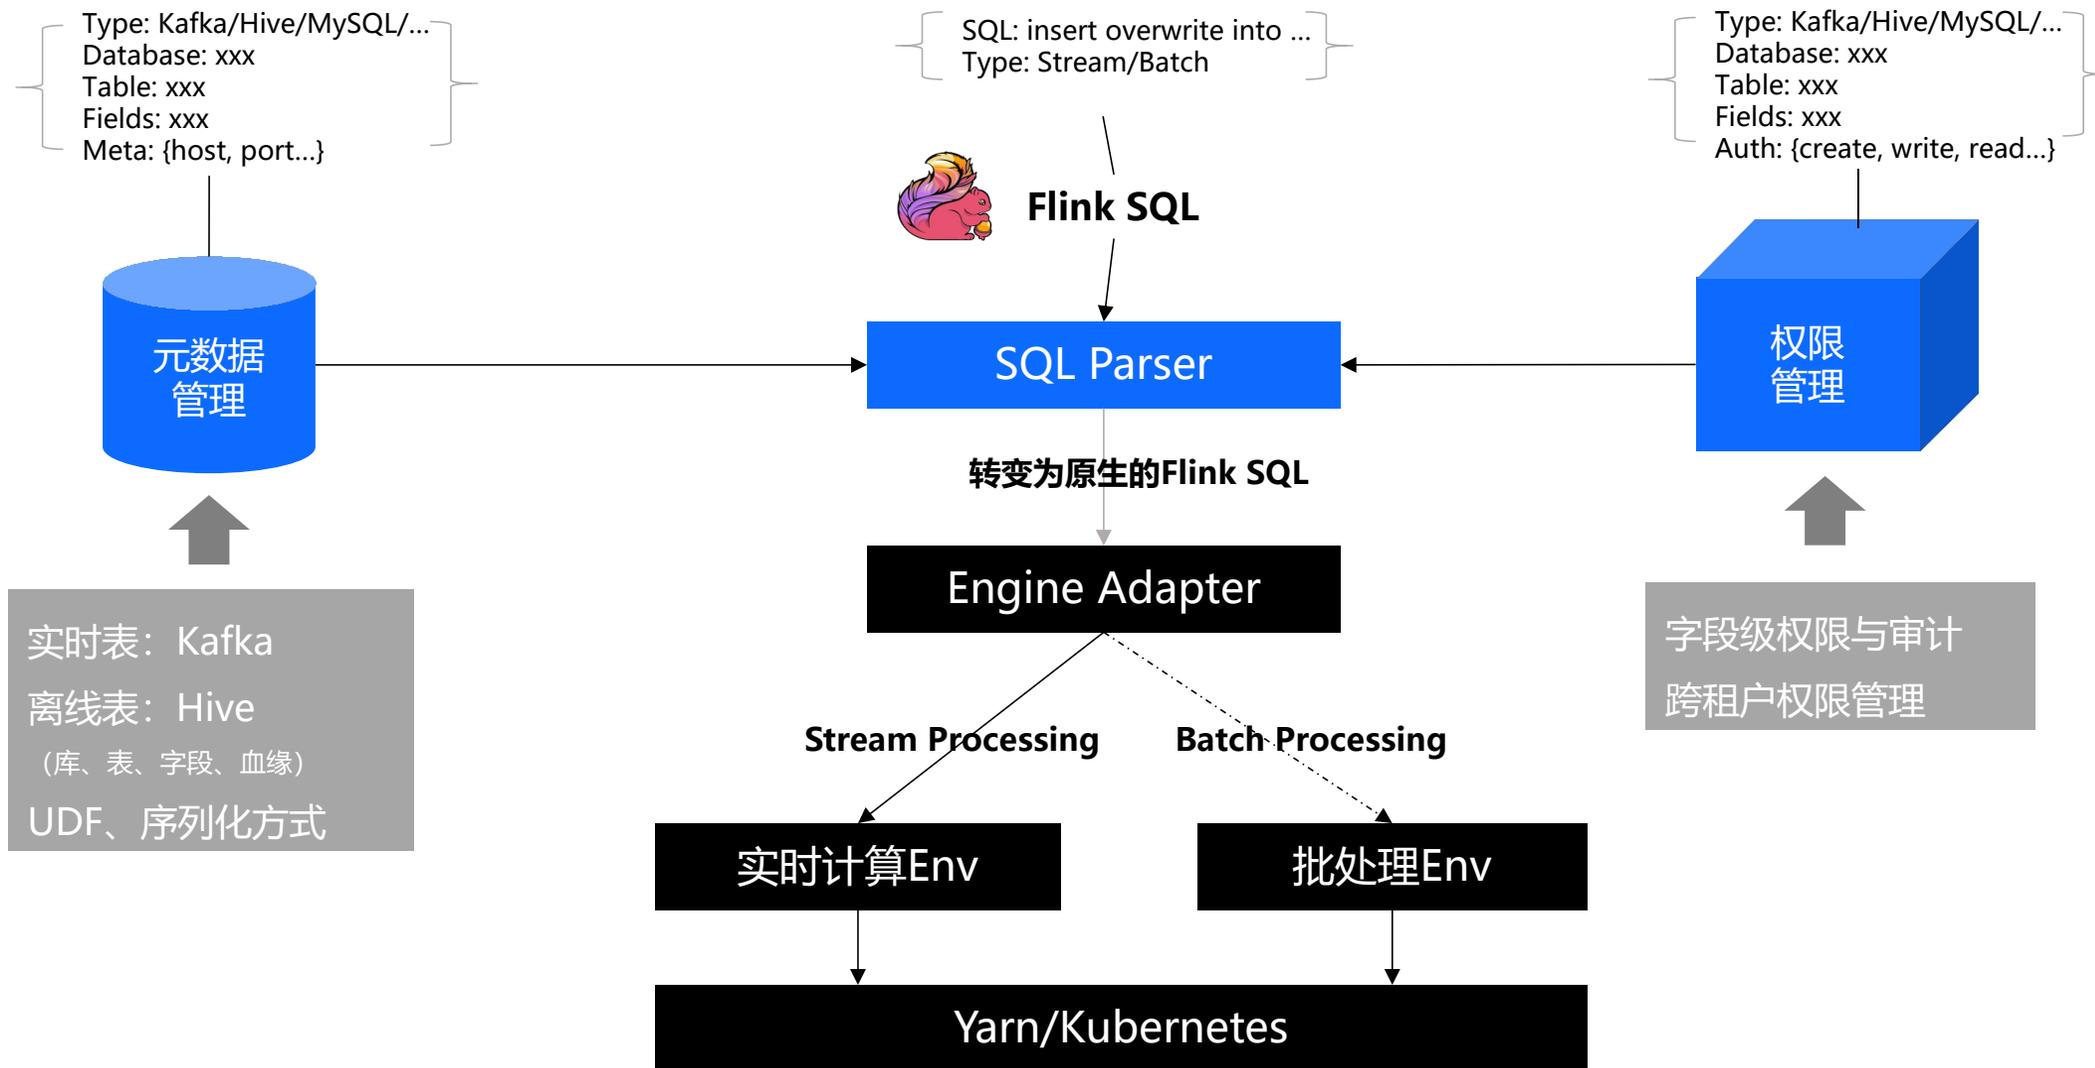
架构稳定性关键因素-可用性&容灾双活



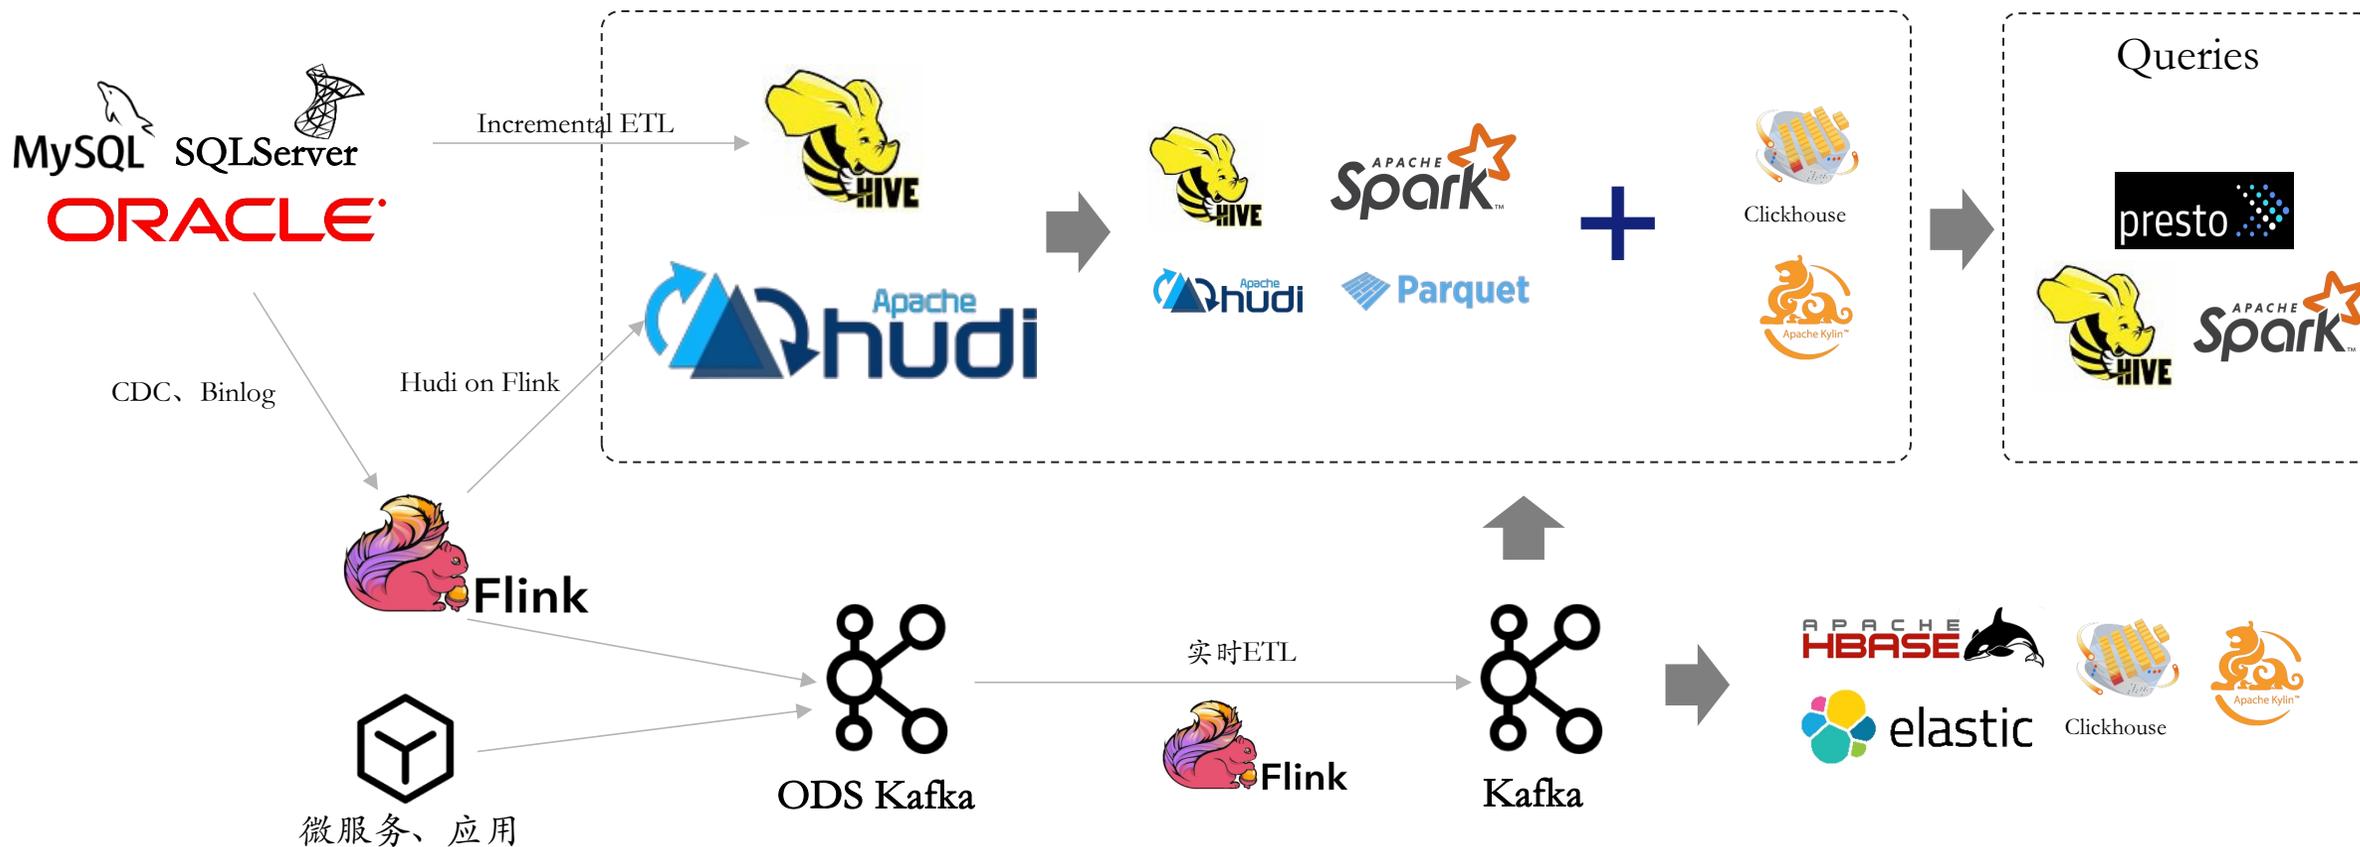
架构稳定性关键因素-自适性&自动化评估



架构稳定性关键因素-易用性&批流一体化



架构稳定性关键因素-先进性&数据仓库实时化



三、未来大数据架构畅想

产业趋势

传统大数据厂商

核心打法: 平台 (私有化为主) + 数据治理 + 定制化开发方式

发展情况: 基本没有太多创新, 更多是项目方式, 项目毛利平均在40%左右。行业上主要聚焦在金融、政府、零售、地产、制造, 平均实施周期2~3月

公有云厂商

核心打法: 云基础设施 + 生态能力

发展情况: 都布局云原生数据湖能力, 如datalake产品, 相对早期, 市场感知度不强。大数据EMR的布局相对成熟些, 行业打法上, 目前还是以生态为主, 聚焦IaaS。平均实施周期1~2天

新兴独角兽、科技公司 Snowflake、Databrick

核心打法: 聚焦单品

发展情况: 商业模式就是单品, 不承接数据治理和定制化开发, 做好标准化 (SQL) 支持、接口开放性和线上运营支持。聚焦金融、互联网、零售、央企、制造等行业, 平均实施周期1~2天。

第一代云上数仓 (发展期) 私有化数据湖

主要代表产品: ***等厂商, 相比传统oracle、db2, 解决大规模OLAP分析场景

- Hadoop技术路线, 存算一体
- 以私有化为主, 按节点license结算
- 除大数据节点外, 提供数据治理和定制化开发服务

第二代云上数仓 (成熟期) 云上数据湖

主要代表产品: AWS EMR、Alibaba EMR、Cloudera一定程度上增加弹性能力, 解放IT维护成本

- Hadoop技术路线, 存算一体
- 依托公有云IaaS资源, 以EMR形式对外提供服务
- 降低集群扩缩容和运维自动化成本

第三代云上数仓 (幻灭期) 云原生数据湖

主要代表产品如: ***Datalake通过存算分离、弹性伸缩等技术, 实现动态伸缩和精准计费

- 计算存储分离、精细化资源管理
- 具备DLF能力 (元数据迁移、对象存储元数据发现、元数据管理)
- 通过弹性伸缩, 降低计算成本, 同时提供DLF能力, 帮助客户快速建仓

第四代云上数仓 (萌芽期) 云原生实时数据湖

主要代表产品: snowflake、databricks等, 通过存算分离、实时数仓、多云融合等核心技术, 实现弹性伸缩和多云统一架构

- 多云适配, AWS、Azure、GCP、alibaba cloud、tencent cloud等
- 支持实时数仓统一架构, 实现批流合一和数仓指标实时化
- 兼顾私有云的数据安全需求和公有云的弹性资源需求

场景趋势

“实时数仓，批流合一” 场景

痛点

- 面向金融、快消零售和物流行业，**以前大部分指标是T+1天，少部分T+0**
- 客户需求大部分指标1分钟内呈现，使用离线+实时lambda架构，**不仅耗费大量资源，还会出现指标不一致情况，如某垂直电商**

说明

- 目前主流实时数仓技术hudi，虽已开源但是有不少生产问题，**包括性能和稳定性问题，离实际生产应用还有一段距离**
- 顺丰在这个基础上，已经解决了社区尚未解决的问题，**并在内部落地，数仓计算效率提高4倍，数仓时效到1分钟以内**

“存算分离，弹性伸缩” 场景

- 金融、快消零售和物流行业具备季节性属性，业务高峰时后台计算资源需求成本增长，**扩充IT资源耗资巨大且浪费**
- **容灾机房、公有云等资源池无法充分利用**，这两部分的闲置计算资源较多

- 目前国内主流公有云目前只聚焦**在自家单朵云的弹性伸缩能力上发展**
- 我们从客户角度出发，**目前已经具备混合云弹性伸缩能力**

“多云管理，跨云计算” 场景

- 跨国企业和大型央国企，**业务常涉及多朵云**，比如某化妆品企业两朵云、某零售头部企业三朵云、某奶制品巨头国内三朵云等
- 如何解决多云环境下，**统一数据湖管理和合规跨云计算，是客户最关心的问题**

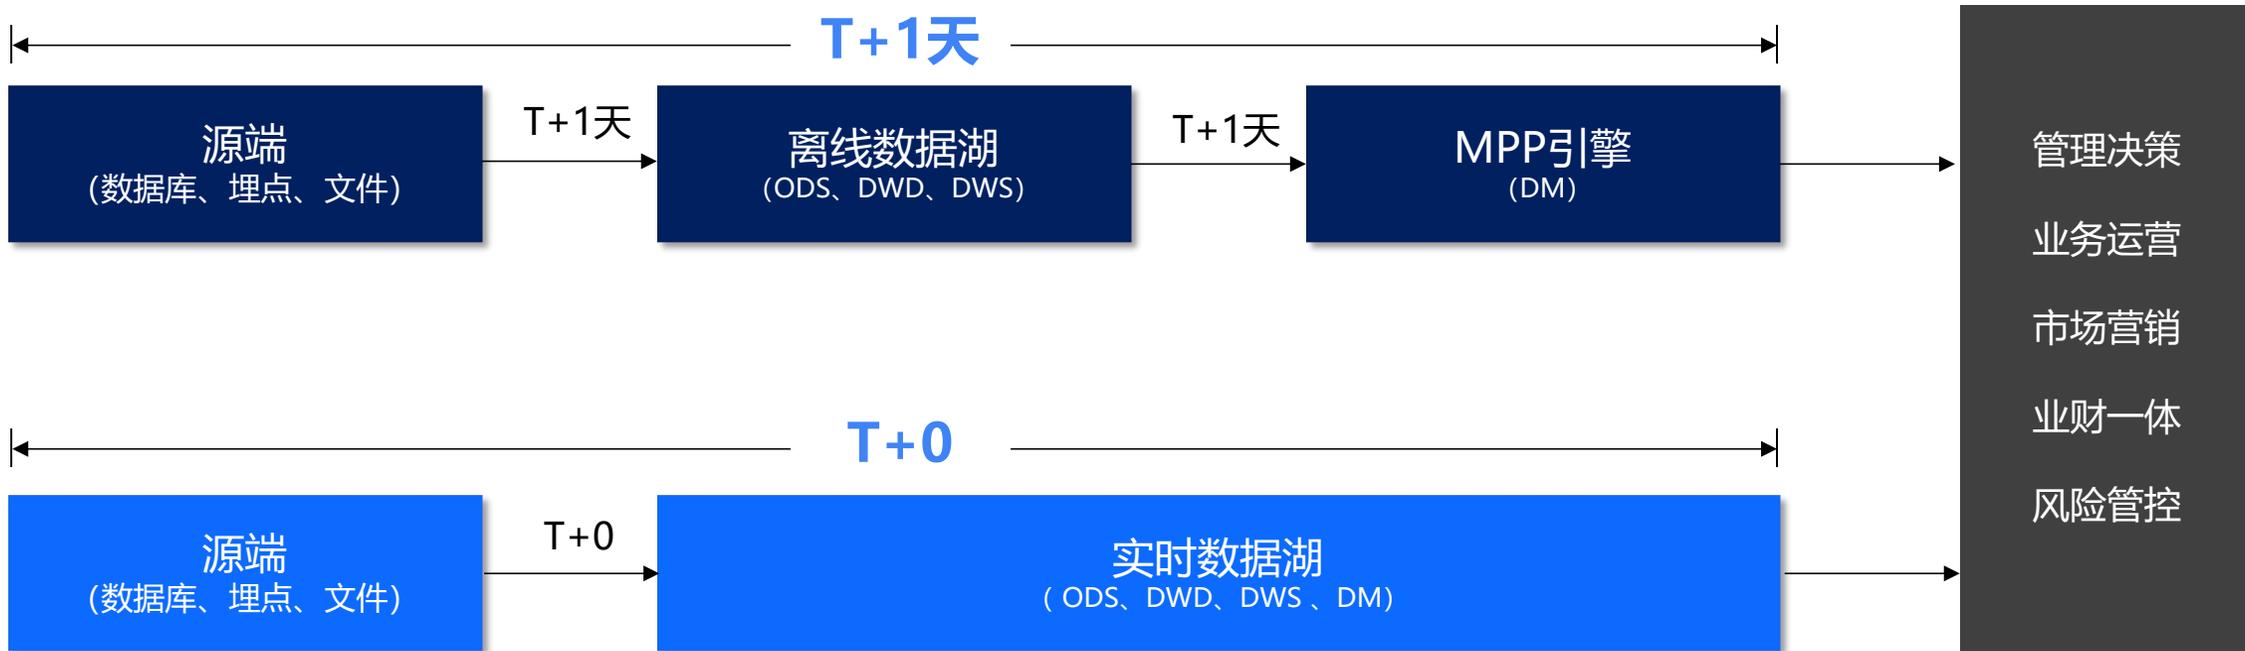
- 目前Snowflake和Databricks支持多云适配，但不支持跨云统一管理
- **顺丰已经支持多云管理和部分跨云计算**

架构趋势

云原生实时数据湖，打造**存算分离、实时数仓、湖仓一体**三大核心能力

客户价值：T+1-->T+0

天下武功、唯快不破，谁的数据结果出得快，谁赢的可能性就越大



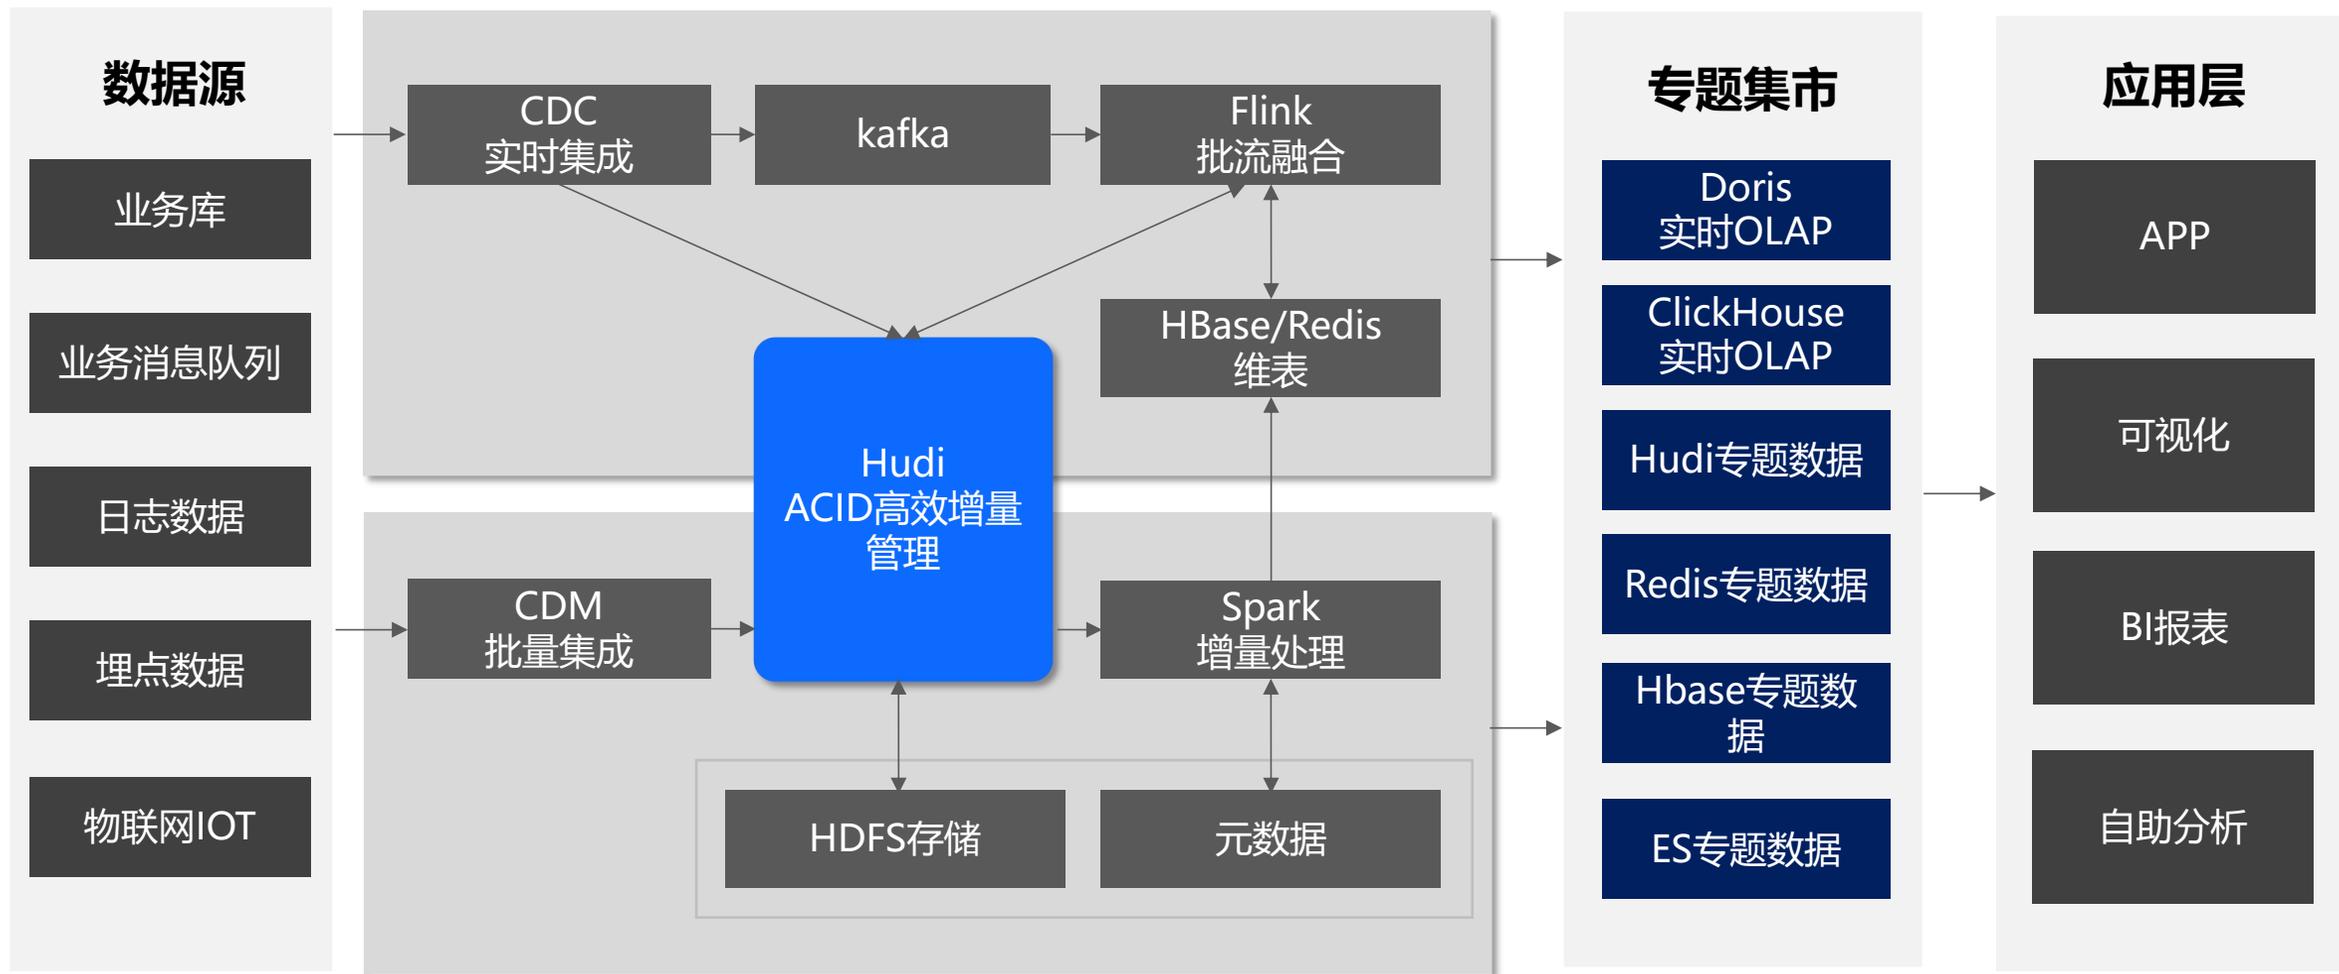
关键能力-极致弹性 (成本极致优化)

- 通过存算分离技术，复用容灾和公有云资源，确保了数据安全的同时，复用公有云弹性资源



关键能力-实时数据湖 (指标 T+1天->T+0)

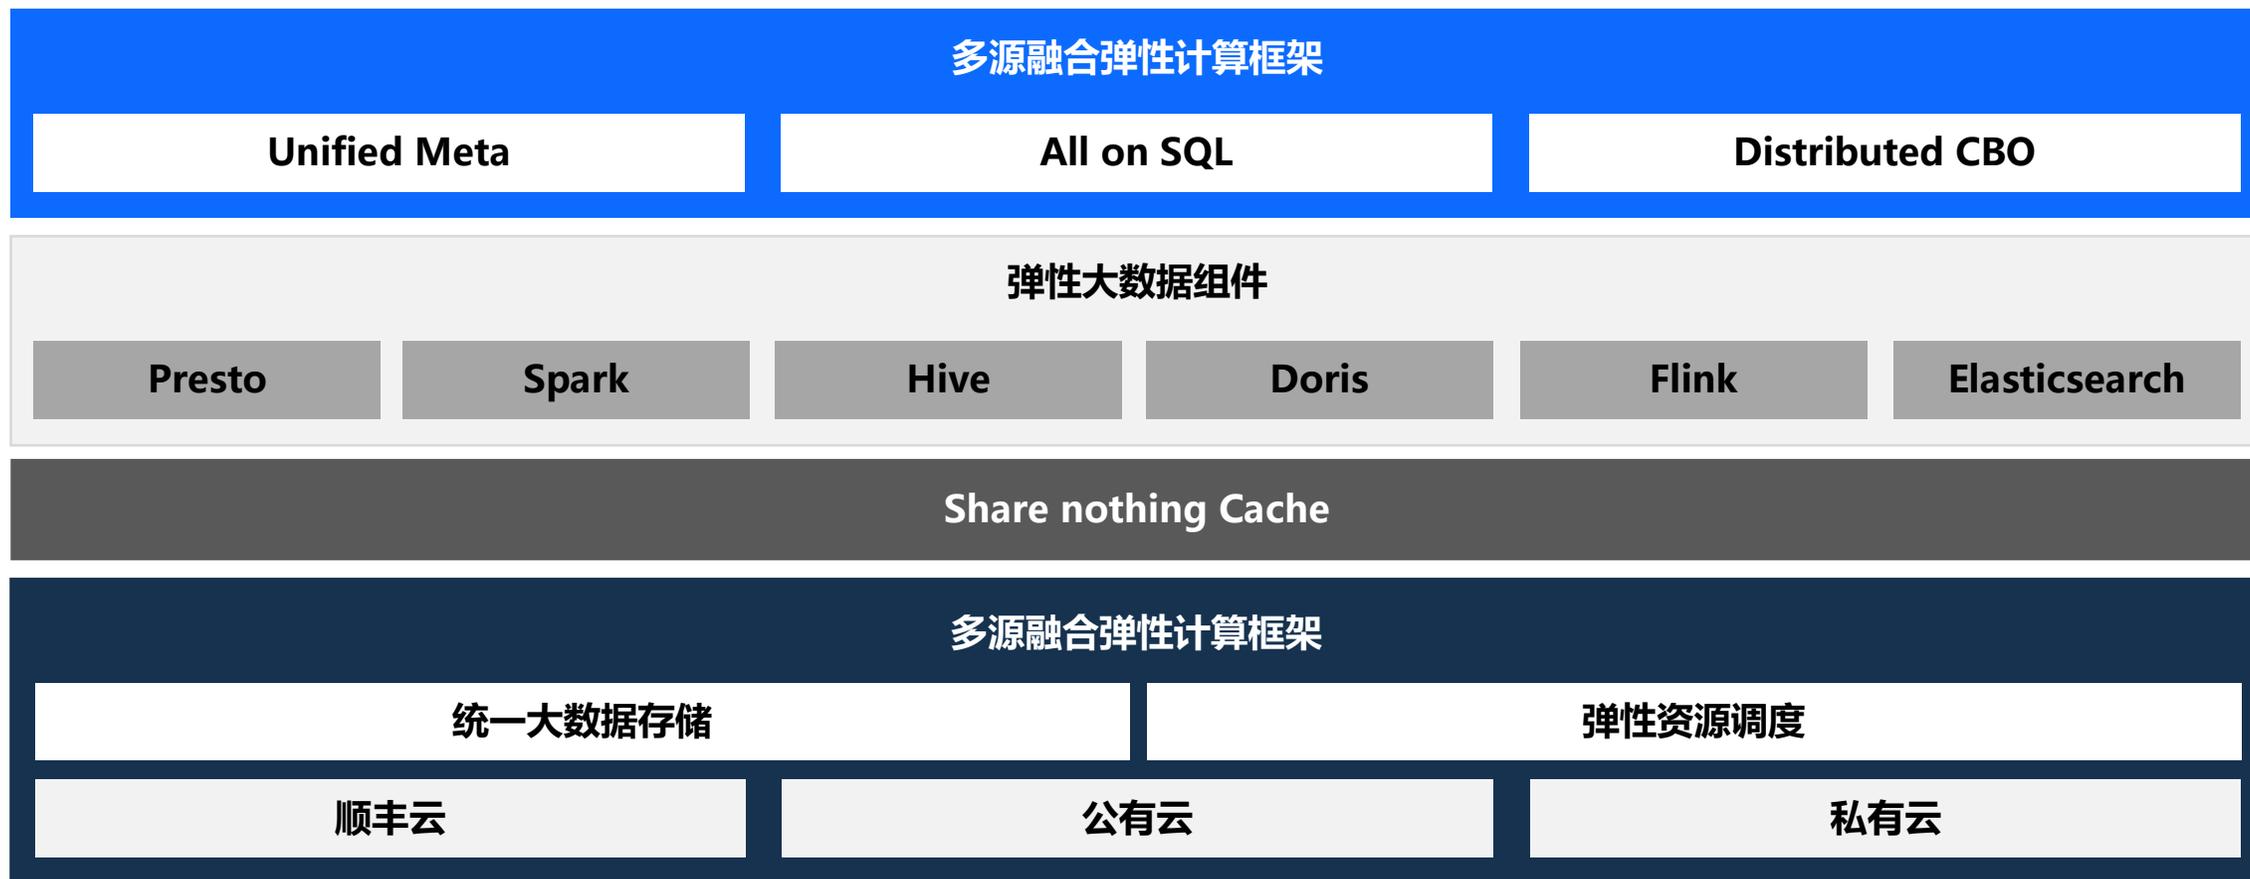
- 基于Hudi升级后大幅提升的数仓更新时效，由原来的“天”级别提升到“秒”级别



关键能力-统一SQL (开发更高效&高速)

跨云、跨大数据引擎全局统一元数据管理, 支持基于代价估算的全局解析执行引擎

- 支持跨云、跨大数据分析引擎的融合分析
- 支持无感优化用户大数据架构, 支撑已有技术生态, 实现向云上数仓的平滑过渡



关键能力-安全托管（安全计算）

确保客户对数据密钥有自主管理权

确保通信从南北向到东西向都是安全的，确保数据落地的加密程度是足够

密钥管理

KMS密钥生成

KMS密钥托管

生物密钥加盐生成器

RPC服务层

白名单过滤

南北向链路SSL

东西向链路SSL

库表列行权限控制

弹性存储层

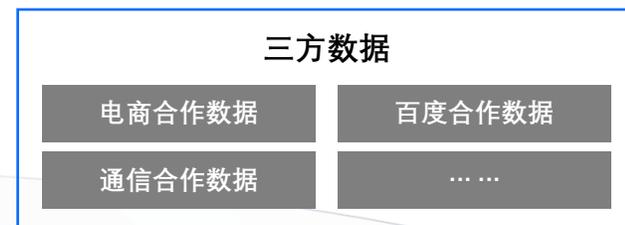
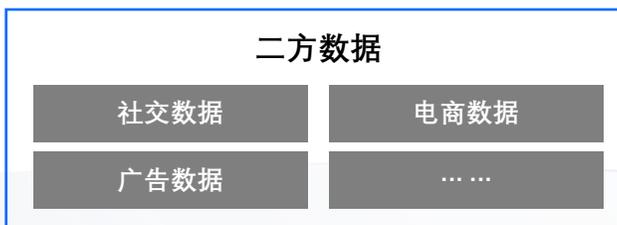
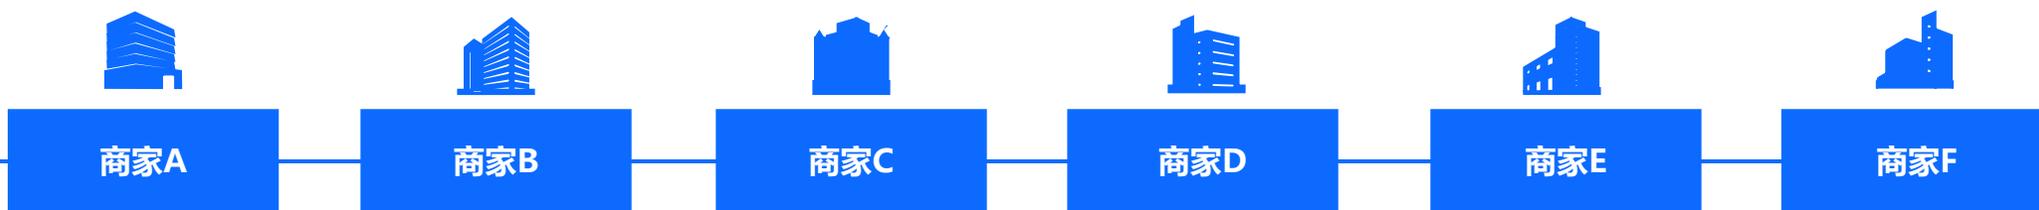
全数据AES256强加密

密钥周期性更新

数据定期重新加密

关键能力-数据生态 (数据生态共赢)

默认为每一个公有云和私有云客户部署一个联邦学习节点，数据不共享，但是模型参数共享，构建隐私计算数据交易市场



顺丰-云原生实时数据湖

我们的使命：

“让每个用户的数字化更简单、更安全、更高效，为全球数字经济和人类美好生活贡献力量”



扫码申请体验