集团化企业开放数据平台构建之路

傅杰

2013年4月

大纲

- 企业集团化带来的数据挑战
- 开放数据平台的构建之路
- 优酷土豆集团开放数据平台

数据孤岛

集团化企业的数据孤岛现象更为明显！

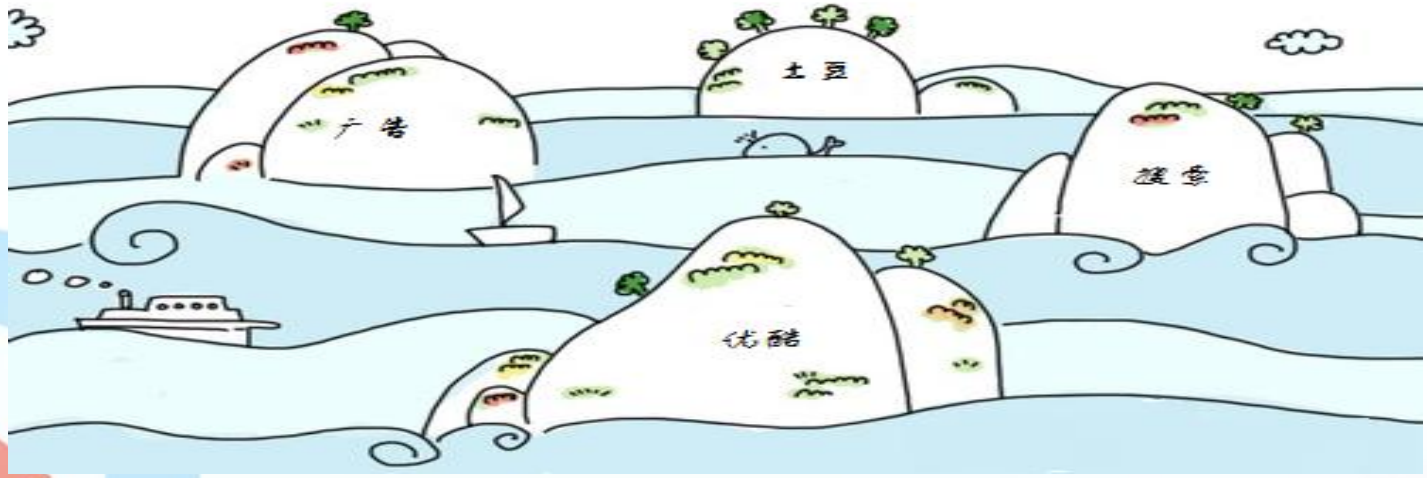

企业集团化带来的数据挑战

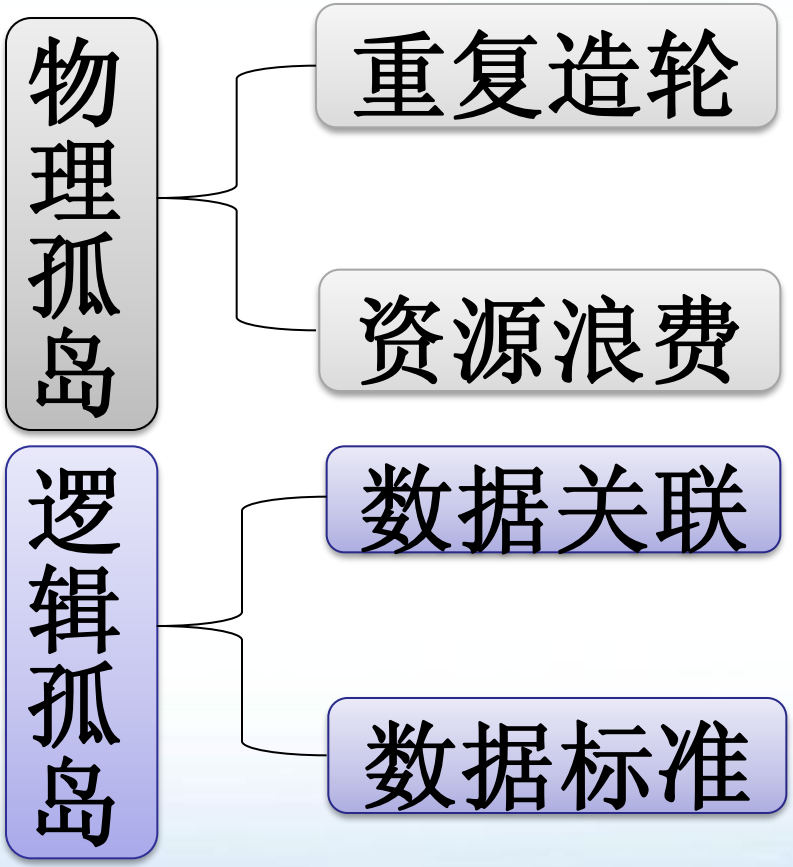

挑战物理孤岛

- 集中存储
- 统一采集
- 开放计算

开放Hadoop平台

开放三要素

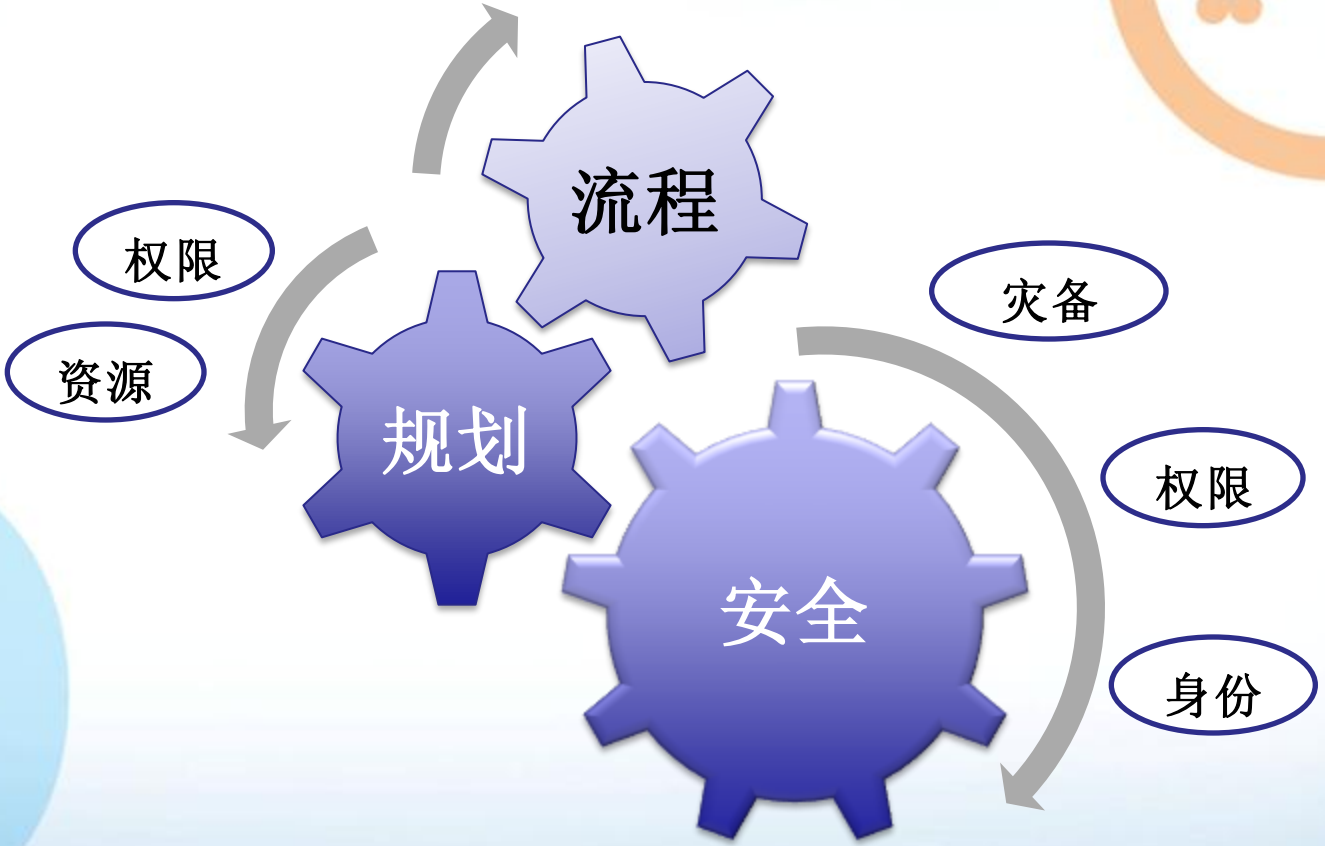

Hadoop安全开放

- 集成Kerberos
- 自定义用户组
- 监控报表
- 开放注册用户120、团队16

Hadoop集群规模

- 日增2T+原始日志
- 日均6000道作业
- 日扫描上百T数据
- CPU利用率50-60%、峰值95%

荆棘密布

- System.out
- 机房迁移(jaas bug)
- 公平调度器故障
- JobTracker 堆栈满
- IPV6

平台运营

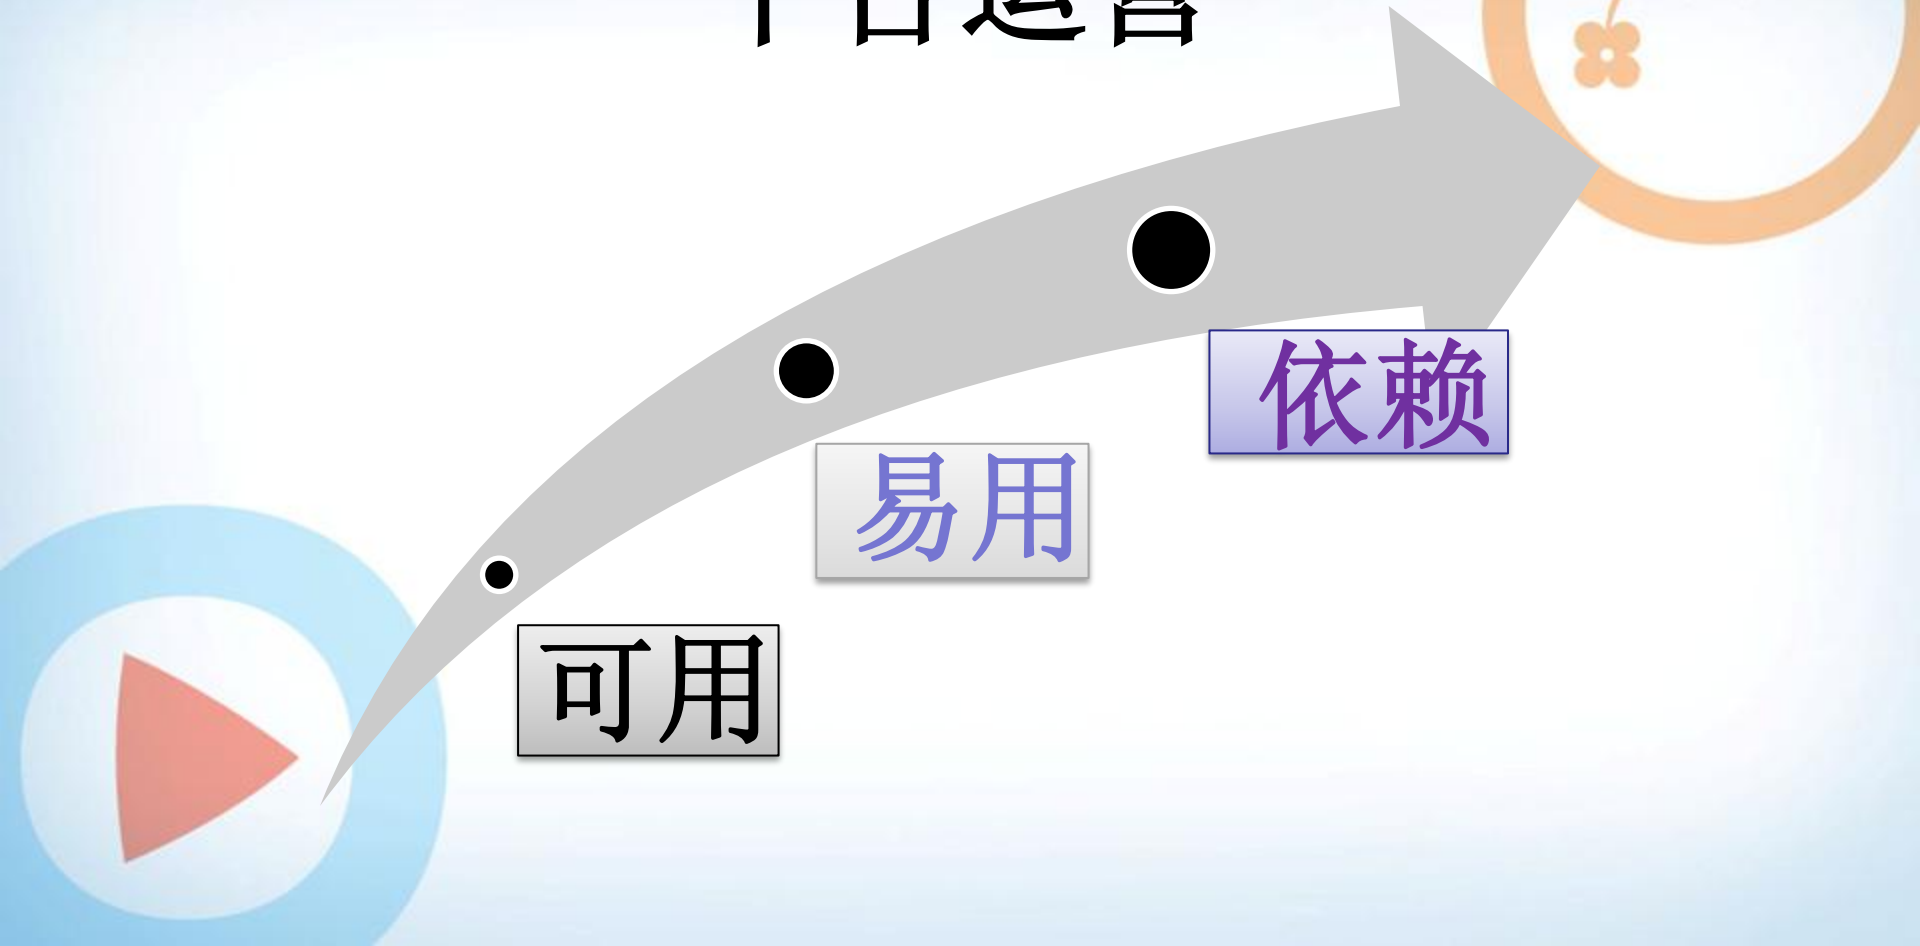

挑战逻辑孤岛

- 数据易用
- 封装数据服务
- 打造数据产品

开放数据平台

探索逻辑孤岛

- 制定业务数据标准
- 元数据定义
- HIVE库互通
- 数据产品

优酷土豆集团开放数据平台

DATA，SO EASY

数据平台辐射范围

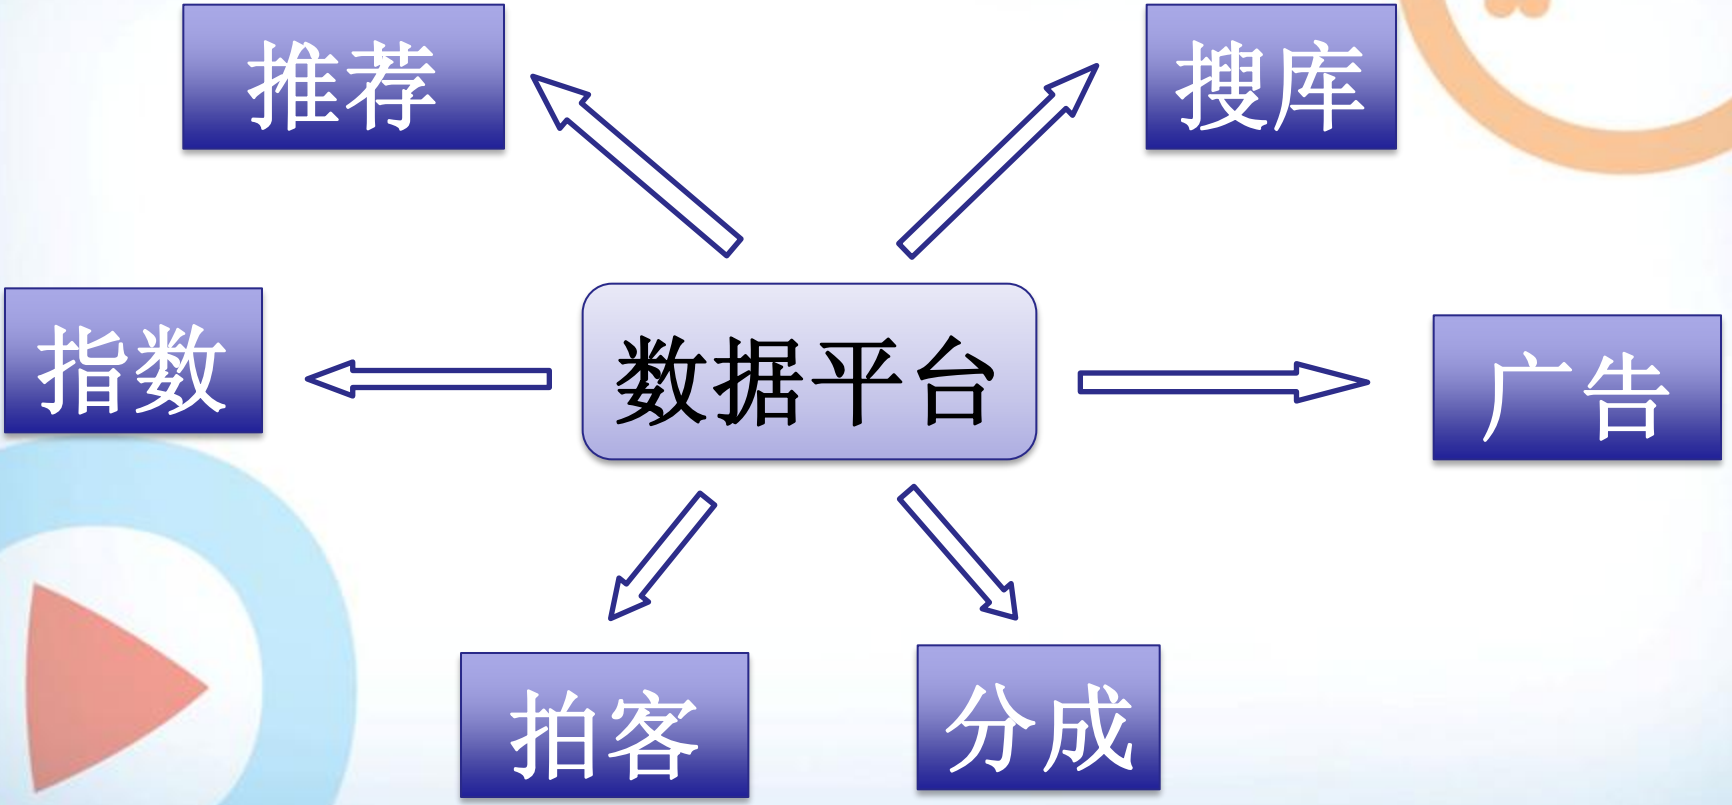

数据平台内部支撑

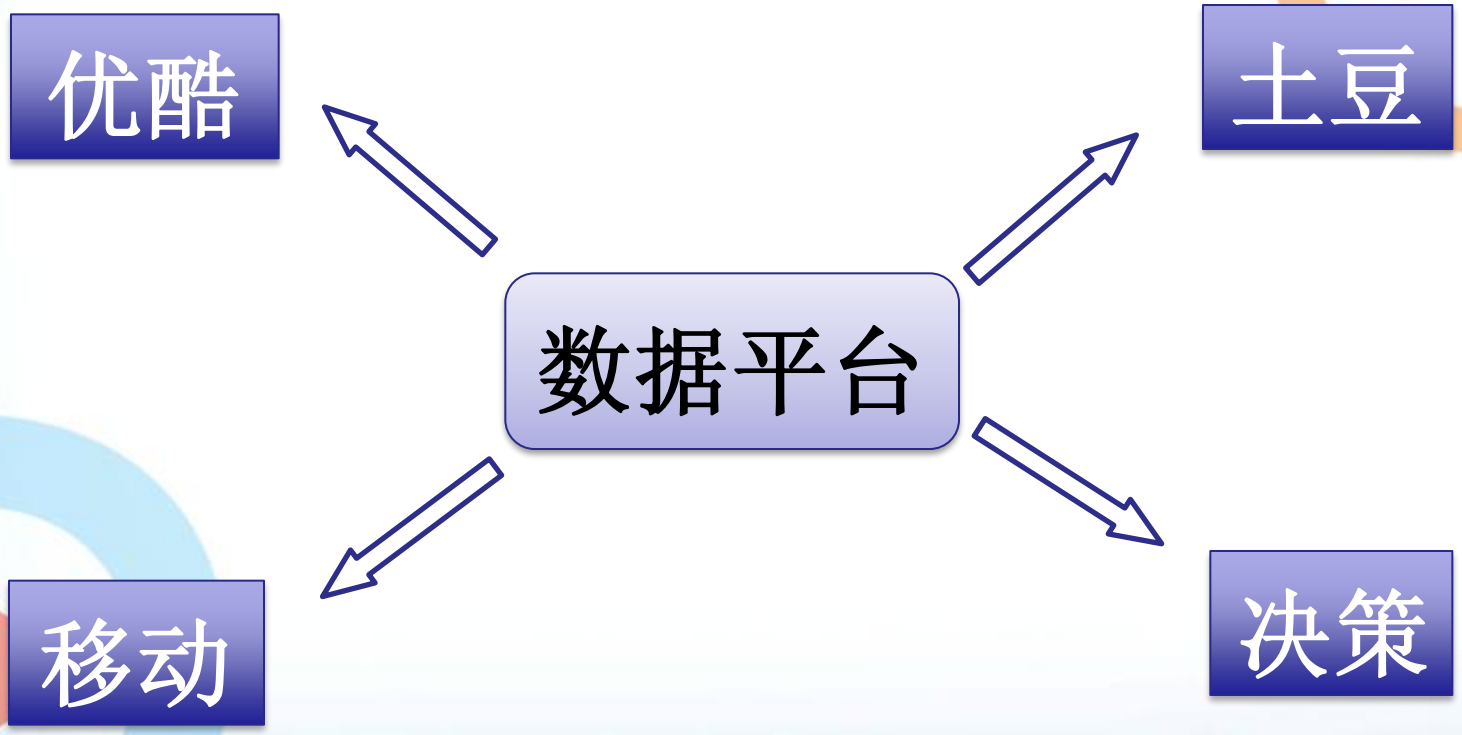

数据平台架构

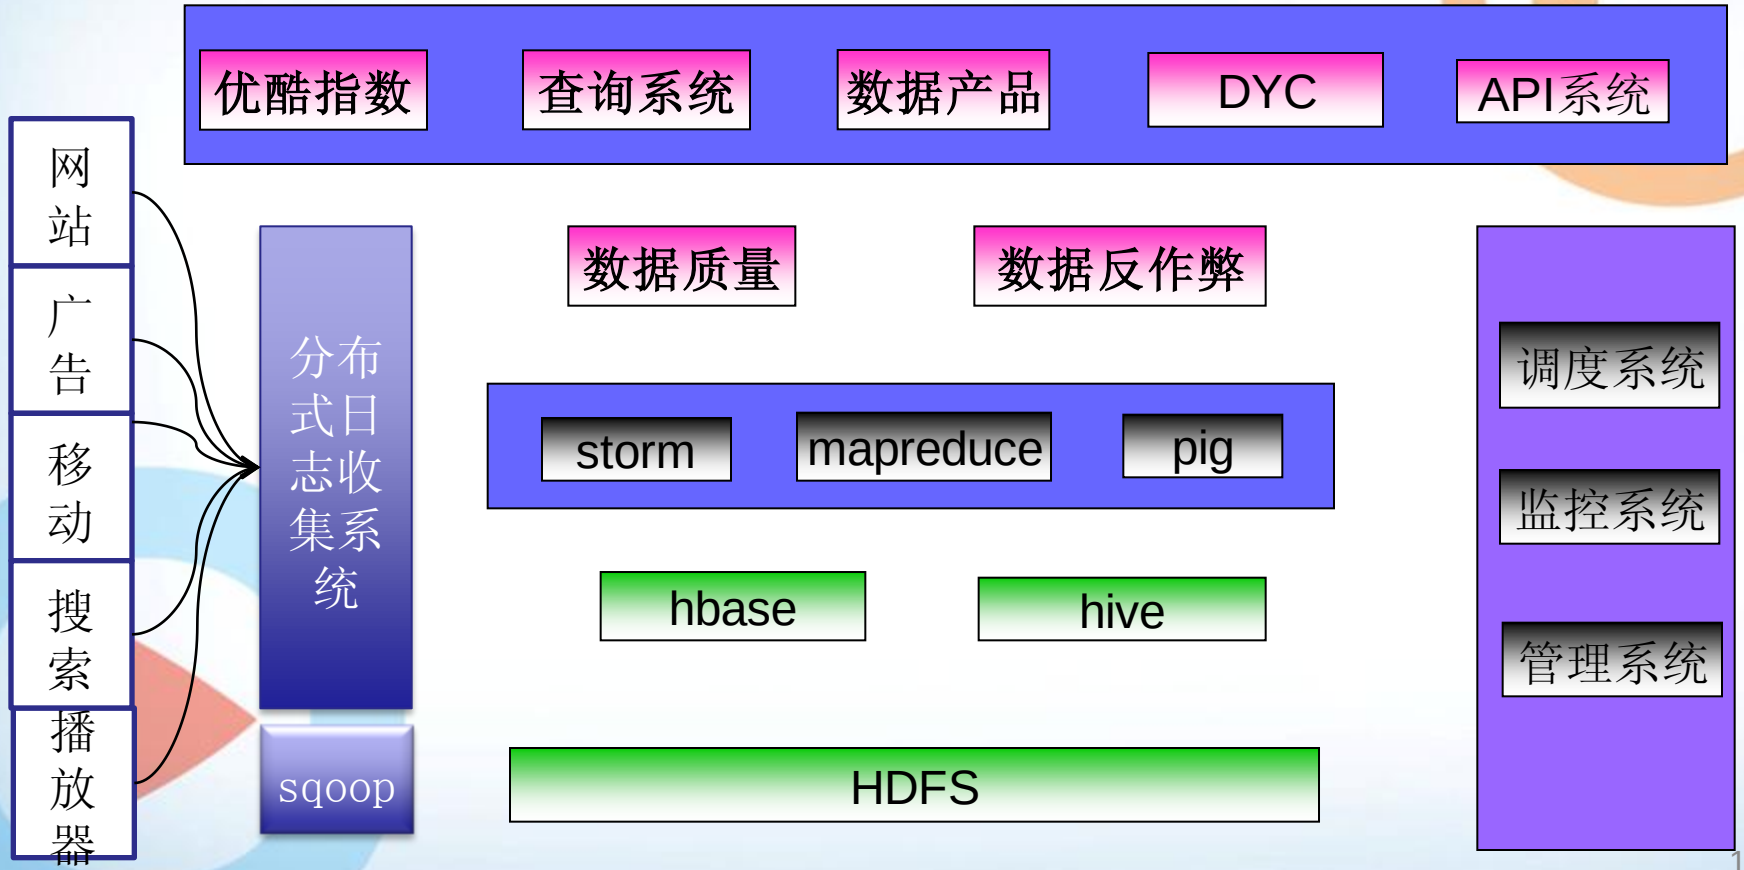
优酷指数
查询系统
数据产品
DYC
API系统
网站
广告
移动
搜索
播放器
分布式日志收集系统
sqoop
数据质量
数据反作弊
storm
mapreduce
pig
hbase
hive
HDFS
调度系统
监控系统
管理系统

平台服务

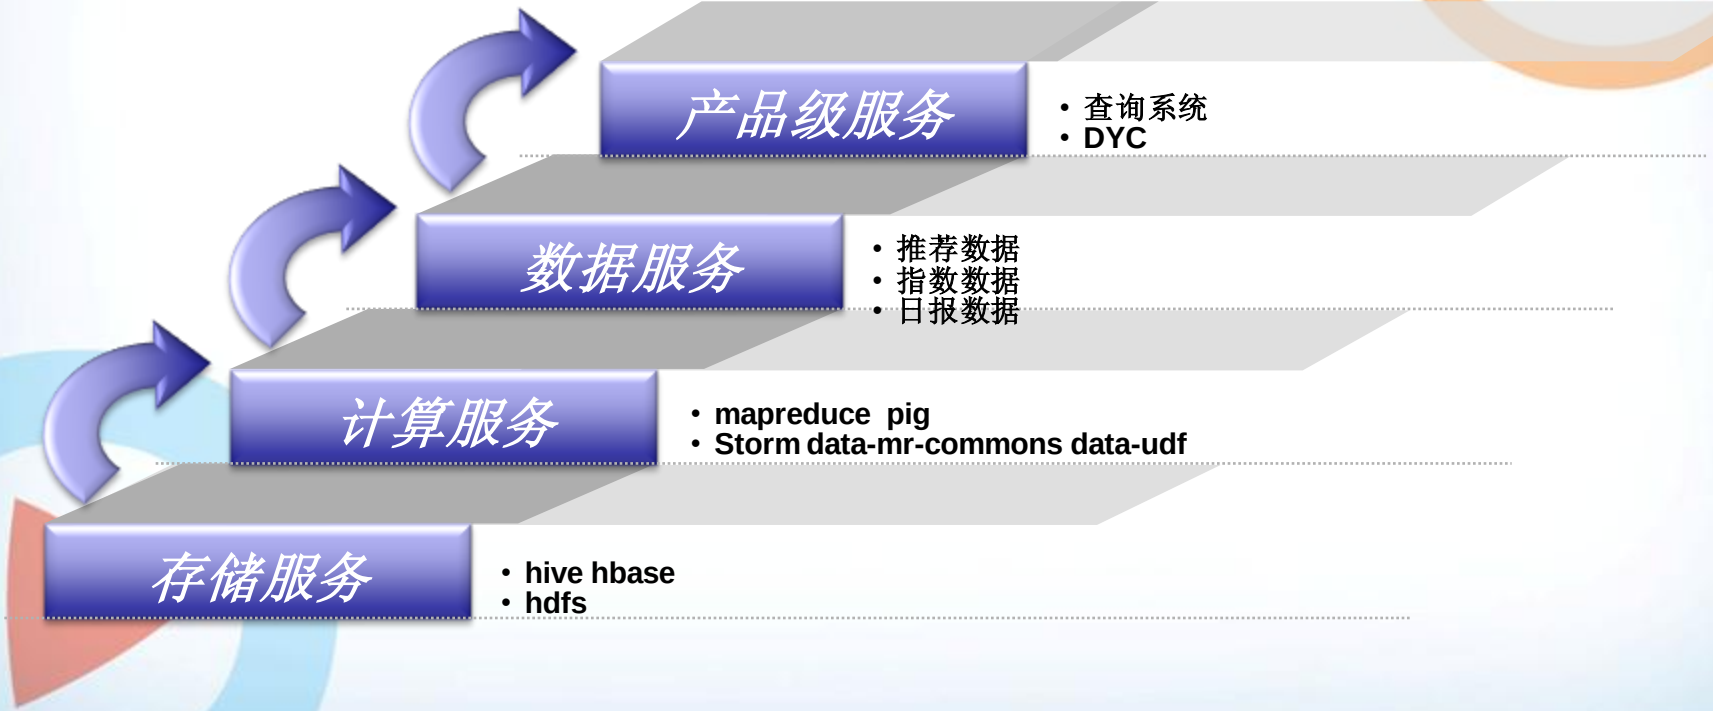
产品级服务
• 查询系统
• DYC
数据服务
• 推荐数据
• 指数数据
• 日报数据
计算服务
• mapreduce pig
• Storm data-mr-commons data-udf
存储服务
• hive hbase
• hdfs

回顾构建之路

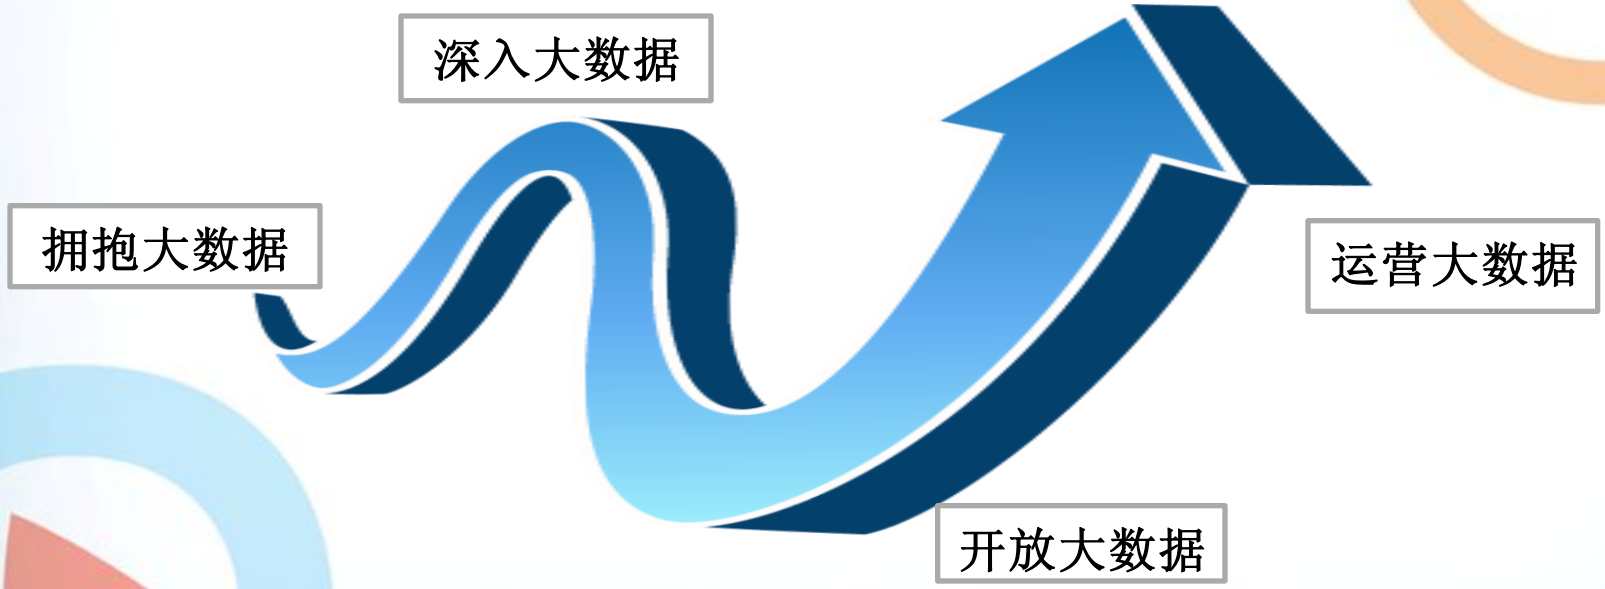

近期工作

- 监控运营报表
- 实时计算应用
- 日志采集系统优化
- API层架构规划

Q&A