

基于自动化治理实践驱动数据成本零增长


孙伟

快手 数据平台部 数据治理负责人&商业创新数据BP负责人



- 十多年大数据建设和应用经验，曾就职于百度、阿里，目前在快手负责数据治理和商业创新数据BP团队，专注打造高效的治理工具和可持续的治理机制，以及建设丰富易用的数据内容赋能业务

关于快手数据平台部



使命： 提升数据决策效率，利用数据助力业绩提升

职责： 通过大数据技术，对公司数据统一采集、存储、加工和挖掘形成高质量全域数据资产，以分析决策产品和服务的方式对外提供数据解决方案


集群规模	总数据量	日新增数据量	任务量
万级	EB级	PB级	十万级

目录


- 数据治理概述
- 成本治理方案
- 自动化治理实践
- 总结与展望

数据治理概述


- **Why:** 对抗大数据系统的熵增，让数据管理有序、可控，以及价值最大化
- **What:** 保障数据质量，合理降低数据成本，守住安全红线，优化数据架构
- **How:** 管理+治理，通过有效的评估体系配合组织与流程机制，以及工具能力，驱动可持续治理



成本治理方案：思路




成本治理方案：成本元数仓




成本治理方案：技术白盒化

- 计算用量公式 = 任务数 $\times$ 调度频次 $\times$ 申请计算资源数 $\times$ 运行时长 $\times$ 优先级权重
- 存储用量公式 = 单行单列存储量 $\times$ 列数量 $\times$ 行数量 $\times$ 表数量 $\times$ EC副本数量

成本治理方案：技术白盒化策略



自动化治理实践：生命周期自动纠正



生命周期规范

- 根据不同数据等级、不同数据分层，结合数据是否可恢复以及恢复的成本制定标准生命周期规范


避免误删数据

- 通过基础的数据血缘，结合数据的查询访问日志来判断，并且取最早分区和推荐生命周期的最大值

通知机制

- 三轮通知，过程用户可以申请加白，无反馈后，一周后进行治理纠正

自动化治理实践：0热度表/任务自动下线



避免误删数据

- 通过基础的数据血缘判断下游依赖，结合数据的查询访问日志和创建时间判断该表和任务是否真实在用

通知机制


- 三轮通知，过程用户可以申请加白，无反馈后，一周后进行治理删除和下线

数据恢复

- 对于自动下线任务和删除表，用户可以在工具上进行一键恢复

自动化治理实践：任务参数自动调优（HBO）

通过分析作业历史运行指标，以数据驱动的方式，自动化为每一个DAG推断最优的运行参数，以减少资源开销、提升运行效率



优化资源配额

- 通过自适应扩缩容 CPU/MEM，解决资源不足和分配过大的问题

优化任务分片

- 通过自适应调整 Map/Shuffle 分片，解决分片不够、过多的问题

优化功能参数




- 通过小文件合并等参数调整，提升性能

自动化治理实践：增量自动化归因

面临的问题

- 降本背景下，存储水位处于高位(95%)
- 日新增波动较大，缺少合理监控，每次发现很被动
- 波动原因无法快速定位，每次排查工作量大，不能快速修复问题


思路与方案




智能化相似模型检测

面临的问题

- 业务烟囱建设导致大量相似模型
- 难以定义相似模型
- 难以计算相似模型



成本治理运营机制



治理收益

成本 · 大数据成本节约上亿元

效率 · 治理效率提升N倍

总结

成本优化思路

- 成本管理（评估、流程、组织）
- 技术白盒化
- 业务白盒化



自动化治理方案

- 自动化生命周期纠正（标准规范、血缘准确率）
- 自动化下线任务
- 自动化删除表
- 自动化参数优化（HBO）

展望未来：规划

- 自动化治理覆盖提升
- 实时资源HBO
- 业务白盒化治理自动化诊断
- 数据湖治理

展望未来：思考



想一想，我该如何把这些
技术应用在工作实践中？

THANKS