

金融级数据研发治理一体化平台实践

廖晓格

廖晓格 长期大数据平台、AI平台建设经验

- 平安银行数据资产管理及研发中心团队负责人，负责大数据基础平台、数据中台、BI及AI中台能力的建设
- 曾就职于PPTV、ebay、携程、华为，负责大数据平台应用的研发工作



目录

- 一、数据治理传统模式痛点
- 二、数据治理核心目标
- 三、开发治理一体化解决方案
- 四、未来展望

金融数据的特点及治理挑战

大数据服务应用数据质量**缺乏必要的监控和告警**

各业务的数据存在**孤岛**

数据多份存储，加大**数据成本**

PB级别大数据海量存储和计算，造成**极高的负载**，影响系统**稳定性**，**批量时效**难以有效保障

大数据测试数据难造，生产数据脱敏到测试环境又有**安全隐患**，**敏感数据多**，**安全管控难**

数据流量洪峰不断刷新记录，如何**提升实时化能力**

虽然提供了各种线上平台和工具，但**思维**和动作还未全面**数据化**

▼
安全

▼
提效


▼
降本

金融数据治理的价值

包袱?



资产!



数据治理传统模式的痛点

- 传统模式下的数据治理工作更多参考DAMA或者DCMM理论体系推行，但公司内部从哪里入手、以什么样的路径推进目前并没有结合自身企业和行业特点制定数据治理的标准体系，涉及效率、技术、管理、安全等，导致治理效果一直不佳，主要体现在以下几个方面：

1、运动式治理


通过**事后治理**，在短期内能看到一定成果，但因为并没有融入到日常数据生产流程中，导致治理效果不可持续，不能长久解决治理痛点

3、数据治理成效不可量化

治理成效**难量化、可视化**，治理推进工作难度会倍数加大

2、治理措施落地难

很多企业的数字治理管理规范只能**停留于纸面和规范文字层面**，没有治理工具支撑



目录

- 一、数据治理传统模式痛点
- 二、数据治理核心目标
- 三、开发治理一体化解决方案
- 四、未来展望

数据治理的目标是什么

- 金融行业数据治理核心目标在于兼顾安全、成本并最大化数据价值，因此数据治理需要解决四个使命：



治理DAMA方法论与工具结合，将治理方法论以及行内所有规范，通过平台工具结合，提供工具化的治理能力，实现治理线上化；



沉淀数据资产



全周期治理解决方案，数据治理涉及多个流程、多个平台、多方不同角色，整合各方在平台提供统一治理能力，实现治理标准流程；



集成规则策略，可以通过自动化治理能力识别安全风险、敏感数据，通过内置规则和策略提升治理效果；




提供高可用的数据服务



数据价值最大化，包括通过数据生命周期、成本/价值评估逆向推动成本治理，释放数据价值、降低数据应用成本



数据治理体系建设




目录

- 一、数据治理传统模式痛点
- 二、数据治理核心目标
- 三、开发治理一体化解决方案
- 四、未来展望

数据开发治理一体化解决方案

- 将数据研发与数据治理方法论结合，提供开发治理一体化解决方案平台，目标实现数据安全可控、高质量，最终驱动数据在业务场景释放更大价值




开发治理核心能力

- DataOps全周期数据研发**
将数据研发过程标准化，引入CI/CD方法融入数据研发流程；
- 数据治理嵌入研发过程**
改变以往先产生后治理的流程逻辑，将治理规范融入数据研发流程；
- 先设计再开发服务**
以数据服务和数据指标驱动数据研发过程，遵循先设计再研发的治理设计理念；
- 数治理技术工具**
面向数据自动校验端，提供数据质量/数据血缘/元数据管理/规范检查/开发测试一体/能力服务，实现线上数据的自动检核；


数据研发治理一体化平台全流程

- 统一数据研发全周期流程，标准化数据建模过程，降低模型研发过程中的人为风险同时，提升整个数据研发效率




数据开发治理一体化解决方案-DataOps全周期开发治理能力

- 将数据治理融入数据研发的全生命周期流程中，在数据开发过程中完成全域数据治理工作,最终实现数据开发过程中自动化治理的管控目标



数据开发治理一体化解决方案-元数据治理

- 数据模型设计阶段，元数据治理是核心治理对象，遵循数仓层级、命名规范、数据标准落标等通过开发治理工具执行，开发治理一体化平台针对事前、事后的自动盘点运营；



数据开发治理一体化解决方案-元数据治理-强制检查项(举例)

- 针对于数据治理中基础元数据管理，基于行内统一数据标准治理规范，在开发过程中实现对于元数据管理的各项自动落标，确保元数据可用、可管、可控；

检查1



基于数仓建设标准，平台层面强约束DWD/DWS/ADS分层的数据研发团队，通过平台约束分层落地

检查2



数据研发过程中明确分配归属部门管理

检查3

字段英文名称	字段中文名称
BECIF_CUSTID	12位客户号
PRE_LMT	预审额度标签
EXP_DATE	额度有效期
PRODUCT_TYPE	产品类型
CHINESE_NAME	中文姓名
BIRTHDAY	生日
TEL_NUM	电话号码

命名规范自动化，包括表名和字段名


检查4

码值	码值说明	码值排序
0	不详	码值排序
10	标准身份证	码值排序
11	临时身份证	码值排序
12	户口簿	码值排序
13	解放军军官证	码值排序
14	武警警官证	码值排序
15	护照	码值排序
16	港澳居民往来内地通行证/回乡证	码值排序
20	其他身份证明文件(个人)	码值排序
22	解放军士兵证	码值排序
23	解放军文职干部证	码值排序
24	解放军其他人员证件	码值排序

码值落标线上化，开发过程中实现码值落标

数据开发治理一体化解决方案-血缘治理能力

- 数据研发人员只需关注将自身需求的业务逻辑转换为开发逻辑，由开发治理平台自动进行脚本解析并生成血缘关系，同步实现**血缘链路**、**血缘层级依赖**、**数仓分层依赖**等治理事项自动化检查，确保数据血缘健康运营；



数据开发治理一体化解决方案-自动调度能力

- 开发治理一体化平台基于研发作业的依赖血缘，同时支持数据研发人员人工添加自定义依赖，实现对于调度的整体自动化平台管控，屏蔽人为控制影响，提升数据运行的自动性

1.血缘依赖调度



2.并发度调度管控

最新执行信息

时间	运行状态	详情
2022-06-17 19:21:42	CHECKING: 执行条件不满足	目标集群(PSA_SAMS_ES_CLUSTER)并发性已经达到上限[10/10]:2022-06-17 19:21:42,[235988605, 235975790, 235981828, 235987730, 235975796, 236099323, 236006737, 235975721, 235988907, 235975789], 当前实例需要排队等待

历史实例状态

下载jit_header_history

时间	运行状态	CHECK_CODE	LAST_CHECK_REASON
2022-06-17 19:21:42	CHECKING: 执行条件不满足	CHECK_CODE_13008	目标集群(PSA_SAMS_ES_CLUSTER)并发性已经达到上限[10/10]:2022-06-17 19:21:42,[235988605, 235975790, 235981828, 235987730, 235975796, 236099323, 236006737, 235975721, 235988907, 235975789], 当前实例需要排队等待
2022-06-17 19:21:42	CHECKING: 执行条件不满足	CHECK_CODE_13008	目标集群(PSA_SAMS_ES_CLUSTER)并发性已经达到上限[10/10]:2022-06-17 19:20:37,[235988605, 235982874, 235975790, 235987730, 235975796, 236099323, 236006737, 235975721, 235988907, 235975789], 当前实例需要排队等待
2022-06-17 19:21:41	CHECKING: 执行条件不满足	CHECK_CODE_13008	目标集群(PSA_SAMS_ES_CLUSTER)并发性已经达到上限[10/10]:2022-06-17 19:20:37,[235988605, 235982874, 235975790, 235987730, 235975796, 236099323, 236006737, 235975721, 235988907, 235975789], 当前实例需要排队等待
			目标集群(PSA_SAMS_ES_CLUSTER)并发性已经达到上限[10/10]:2022-06-17 19:20:37,[235988605, 235982874, 235975790, 235987730, 235975796, 236099323, 236006737, 235975721, 235988907, 235975789], 当前实例需要排队等待

3.自定义条件调度

数据周期: 每日 每周 每月

定时调度: ☐ 否 ☒ 是

* 指定时间: 20:00:00

自定义调度属性

仅当上游依赖作业完成,在指定时间启动

参数 ②

--NO_RELY=6368

--CHECK=EXPRESSION:[(' \${start|dd}' >= '15') 6368 (\$ {start|yyyyMMdd0000})]

自定义调度属性

正文部分

sql检查

需与上游共同创建发布单

二级分区: 请输入

SQL检查

语法检查

库表权限检查

解密函数检查

1 SELECT CUST_NO as CUS

2 FROM VIEW.T_IF_P_CUST

3 WHERE DT='\${start|yyy

limit 10

最新执行信息

时间	运行状态	详情
2022-06-17 19:27:28	CHECKING: 执行条件不满足	用户配置的Check条件不满足, {22:05=22:05}

历史实例状态

下载jit_header_history

时间	运行状态	CHECK_CODE	LAST_CHECK_REASON
2022-06-17 19:27:28	CHECKING: 执行条件不满足	CHECK_CODE_15001	用户配置的Check条件不满足, {22:05=22:05}
2022-06-17 19:27:27	CHECKING: 执行条件不满足	CHECK_CODE_15001	用户配置的Check条件不满足, {22:05=22:05}
2022-06-17 19:27:27	CHECKING: 执行条件不满足	CHECK_CODE_15001	用户配置的Check条件不满足, {22:05=22:05}
2022-06-17 19:22:25	CHECKING: 执行条件不满足	CHECK_CODE_15001	用户配置的Check条件不满足, {22:05=22:05}
2022-06-17 19:22:25	CHECKING: 执行条件不满足	CHECK_CODE_15001	用户配置的Check条件不满足, {22:05=22:05}
2022-06-17 19:22:24	CHECKING: 执行条件不满足	CHECK_CODE_15001	用户配置的Check条件不满足, {22:05=22:05}
2022-06-17 19:19:22	CHECKING: 执行条件不满足	CHECK_CODE_15001	用户配置的Check条件不满足, {22:05=22:05}

执行调度检查

数据开发治理一体化解决方案-质量治理能力

- 数据质量已经成为银行数据治理的核心组成部分，从治理视角而言，建立完整全流程的数据质量体系，及时发现质量问题->实时预警属主修复->事后复盘增强测试发布环节检测、提升银行数据整体质量，提供更精准的决策分析数据；

事前-质量核验规则

已有规则

监控规则

是否阻断

是否启用

告警方式

电话

短信

邮件

告警级别

设置

匹配方式

匹配下限

匹配上限

对比率名

操作

☐	表记录增长环比校验	否	是	✓	低	百分比			添加
☒	主键唯一	否	是	✓	低	百分比			修改
☒	表记录数非空校验	否	是	✓	低	百分比			修改
☐	表记录数增长环比校验	否	是	✓	低	百分比			添加
☐	两表记录数对比	否	是	✓	低	百分比			添加
☐	表记录数极值校验	否	是	✓	低	相对值			添加

字段规则

请输入查询的字段

DEVICE_ID

SERIAL_NUMBER

MODIFIED_BY

CREATED_BY

SYNCHRONIZATION_DATE

CUSTOMER_NAME

USER_NAME

DEVICE_TYPE

LOCATION_GROUP_ID

ENROLLMENT_STATUS_ID

CUSTOMER_CODE

UNENROLLMENT_DATE

ENROLLMENT_DATE

已有规则

监控规则

字段类型

是否阻断

是否启用

告警方式

电话

短信

邮件

告警级别

匹配方式

匹配下限

匹配上限

操作

☐	字段空值占比校验	all	否	是	✓	低	百分比		添加
☐	枚举字段环比校验	union	否	是	✓	低	百分比		添加
☐	字段字符非空校验	string	否	是	✓	低	百分比		添加
☐	字段长度校验	string	否	是	✓	低	相对值		添加
☐	字段只为数数字校验	string	否	是	✓	低	相对值		添加
☐	字段非空值校验	string	否	是	✓	低	百分比		添加
☐	字段空值占比校验	string	否	是	✓	低	百分比		添加
☐	枚举字段环比校验	union	否	是	✓	低	百分比		添加
☐	枚举字段空值占比校验	union	否	是	✓	低	百分比		添加
☐	枚举字段非空值占比校验	enum	否	是	✓	低	百分比		添加

自定义规则

添加规则

提交

取消

事中-质量核验

实时质量异常阻断(依据血缘依赖阻断下游自动调度)

可能报错原因:

当前作业表的数据质量监控监测异常，触发告警阻断

查询

作业ID: 6368 方向: 上游 请在下面表单中, 输入查询条件, 点击查询按钮进行查询。...

库名: 请选择库或输入关键词 表名: 请选择关键词 作业ID: 6368 方向: 上游

收起 ^

通过数据血缘关系, 实时呈现数据调度进度


事后-异常质量问题追踪复盘

基于过程质量问题，工单追踪异常整改

总体概览		待我处理	
作业监控			
客户用户数		2023 年 06 月 25 日	
截止当前总告警数		0	
截止当前待登记告警数		0	
数据质量监控			
实时告警		2023 年 06 月 25 日	
截止当前总告警数		3	
截止当前待登记告警数		3	

数据开发治理一体化解决方案-开发测试一体化

- 为解决大数据数据质量测试痛点，在测试环境无法完全复现生产问题，生产数据脱敏到测试环境仍有安全隐患，因此需要构建数据研发测试一体化平台，完善数据研发流程，满足监控合规的评审需求，数据需求闭环管理，数据开发、测试、变更流程统一管理，并和数据监控规则打通，保证全流程质量闭环



数据开发治理一体化解决方案-数据安全治理

- 从事前、事中、事后分别管控数据安全。以“事中数据脱敏”为例，是通过在SQL/作业埋点用户帐号，分析SQL/Job对应的元数据字段，判断用户权限，返回用户对应的脱敏数据。

事前


事前制度建设：数据安全“制度”先行，为此我行修改制定了“平安银行数据安全管理办法（2.0版，2019年）”；

事中

事中技术管控：采用“数据加密”、“数据脱敏”、“敏感客群保护”、“智能阻断”、“数据外发”等手段构筑强固的数据安全保护伞；


事后

事后监控审计：基于规则引擎建立数据访问审计平台——实时的\自动+人工的识别可能的异常访问；




数据开发治理一体化解决方案-数仓分层加密处理过程

- ODS 贴源层(raw): 敏感字段识别, 利用 正则+算法+人工, 识别出贴源数据表的敏感字段。
- ODS 加密层(mid): 高敏感字段加密, 将银行卡号, 手机号, 证件号进行加密储存。
- 数仓、集市等层: 利用字段级血缘关系, 标识出每张表敏感字段。
- 数据查询访问: 应用端查询数据时, 对统一查询中心(router), 根据访问的敏感字段及敏感脱敏类型进行脱敏处理。




数据开发治理一体化解决方案-敏感数据发现

- 源生产系统数据集成过程中，无论实时或者离线采集，开发治理一体化平台基于数据规则自动实现敏感数据发现；




数据开发治理一体化解决方案-基于元数据的加密方案

- 通过元数据标记、底层执行过程中即时加密的方式，兼顾数据安全的同时，提升处理效率。




- 编译阶段**，调用元数据获取加密信息，给 MapWork 增加 path 到加密信息的映射
- 执行阶段**，MapOperator 反序列化 map.xml，获取加密信息，并初始序列化工具类，序列化工具根据加密信息加密数据
- 任务执行完成后**，根据执行计划，计算字段血缘并更新元数据表分区加密状态

数据开发治理一体化解决方案-基于元数据的加密方案（举例）




数据开发治理一体化解决方案-数据沙箱实现数据流通、安全共享

- 基于沙箱数据只进不出和分析应用相互隔离两大原则构建数据沙箱环境，差异化数据融合模式，确保安全可靠要求下，提升训练和探索环节效率，便捷化数据应用通道。




数据开发治理一体化解决方案-沙箱环境数据流程

- 构建支持数据开发全流程的沙箱环境，确保与生产库分离，只进不出，数据采样。既满足应用系统的沙箱环境数据探索需求，同时提升数据研发使用效率。




数据开发治理一体化解决方案-成本价值管理能力

- 平台层面深化数据价值评估体系探索，实现数据成本与价值的多维度可量化分析，基于成本/价值实现数据资产的ROI分析以及成本治理。



数据资产沉淀-全周期数据资产化治理过程




目录

- 一、数据治理传统模式痛点
- 二、数据治理核心目标
- 三、开发治理一体化解决方案
- 四、未来展望

逻辑数仓- 从用户角度出发，基于数据使用情况自动化构建数据仓库

- 逻辑数仓以用户视角出发，以最大化数据价值和最优成本管控为目标，更敏捷响应用户需求，弱化繁琐的数据流ETL加工链路，让ETL工程师更专注企业通用模型设计，节约存储成本和管理成本



核心能力：

➤ 逻辑数仓层

构建面向用户和下游应用消费的逻辑数仓层，将逻辑表与物理表隔离，将物理表交给系统层优化

➤ 物理层智能调度

透明数据ETL逻辑和物理存储介质，由逻辑层用户行为和需求触发，实现数据生产链路的**智能编排**和**调度**，针对重复、相似计算进行**自动合并**，下线或降权无效、低频、低价值数据生产

➤ 性能自优化


基于用户查询行为实现自适应的查询性能优化，自动实现物化、缓存或构建Cube/索引

➤ 从被动到主动的数据治理，实现“数据自动驾驶”

逻辑层基于业务需求快速调整，物理层自适应上层调整，识别数据核心资产元数据

逻辑数仓-整体设计

- 改变数仓开发模式，让数据人员更关注业务开发，解决大数据平台成本暴增问题，让平台做到主动数据治理



想一想，我该如何把这些
技术应用在工作实践中？

THANKS