

Tencent 腾讯 | CSIG
云与智慧产业事业群

释放数据潜能 驱动业务增长

WeData 数据治理介绍及内部实践

腾讯云 史汉发

2022.7

目录

1. 数据治理挑战
2. 腾讯内部数据治理实践
3. WeData 数据治理平台能力
4. 行业案例

01

数据治理挑战

企业网DINet
2022全国CIO大会

企业网DINet
2022全国CIO大会

企业网DINet
2022全国CIO大会



数据信息分散

- 业务系统不清晰
- 数据资产不明晰



元数据不全

- 需要有业务接口人维护补全业务信息
- 数据多样化，缺少统一标准



数据质量差

- 上游是一张空表，或者无效字段，总靠人肉来判别
- 修改一张表，不清楚带来哪些影响



维护困难

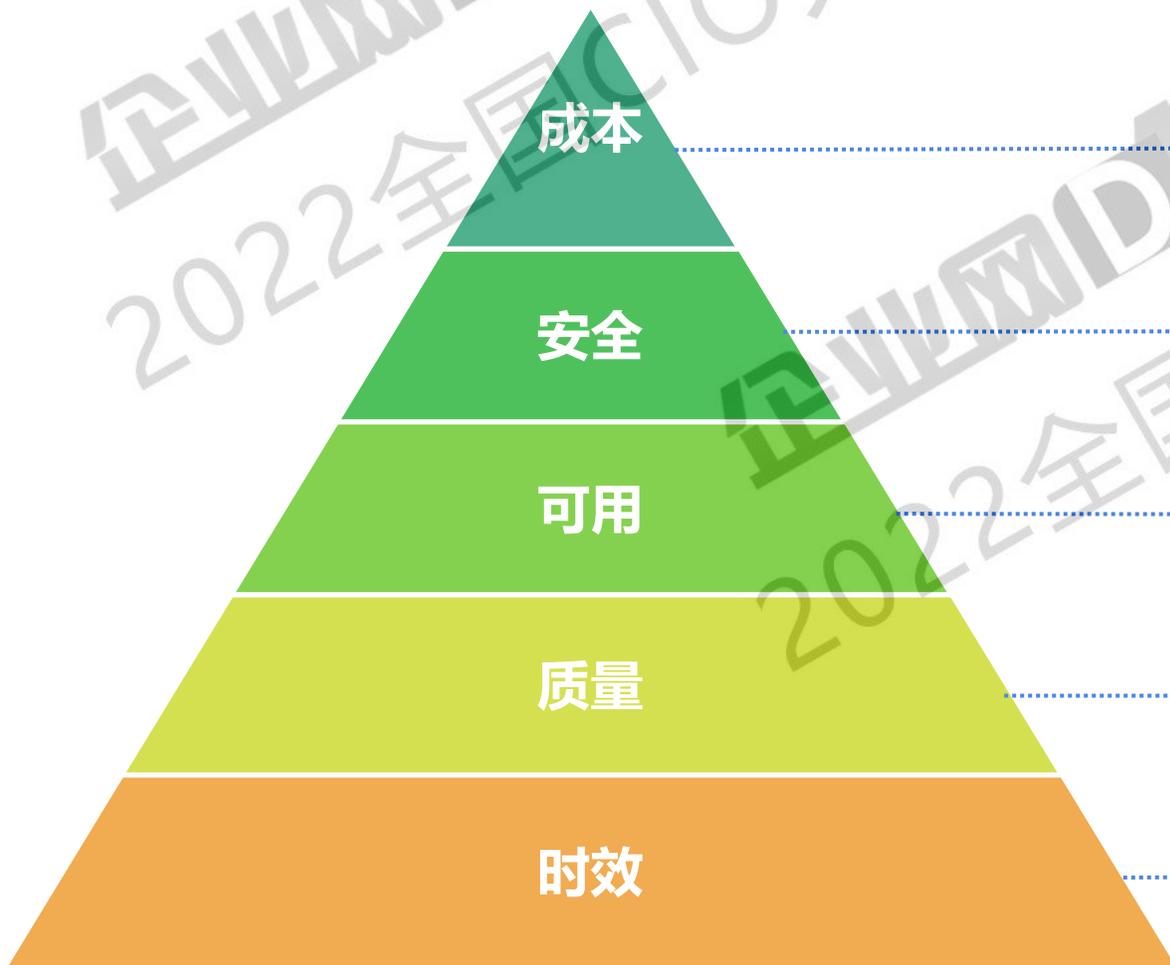
- 数据有问题，总是事后才知道
- 不知该由谁去维护预防



无法审计和度量

- 用数据的人这么多，如何保障公司数据访问是可靠安全的
- 数据成本是什么样

数字化不同阶段，数据治理关注的核心需求不同



数据存储、使用的成本优化和控制

数据安全、敏感数据识别、合规保证

数据易查找、好理解、可复用

数据有保障，准确、完整、有效

数据产出及时性

02

腾讯内部数据治理实践



数百产品线

数千数据分析师

数万业务场景

离线计算 千万级/天

实时计算 千万级/秒

总存储 EB级

腾讯内部实践——组织支撑

基于Oteam协同共建，建立全集团大数据统一体系



元数据管理企标 数据质量管理企标 数据安全企标 数据价值管理企标 数据共享管理企标 数据模型管理企标 数据运营管理企标 数据标准管理企标

协同共建

(18+大数据协同共建组织，涉及大数据全栈技术)

统一数据接入层 统一数据存储层 统一资源管理层 统一计算引擎层 统一作业调度层 统一数据应用层



标准先行

三位一体

评测量化

工具协同

表现	
5级 (卓越)	体系非常成熟,可快速接入业务;具备智能化设施,科学的分析设施能够自我改进完善;
4级 (优秀)	有体系,数据驱动
3级 (可控)	有平台,管理可复制 平台接入2个以上业务
2级 (基础)	有方法、有工具、有流程
1级 (初始)	依赖人工,使用Excel等工具

信息安全部-用户资料表-天全量

dwd_teg_infosec_user_uin_info_df

数据分层 BG 业务域 主题域 业务描述 刷新周期,存储策略

dws_wxg_game_gamecenter_click_di

微信增值业务部-游戏中心点击表-天级增量



腾讯内部实践：如何进行标准制定？

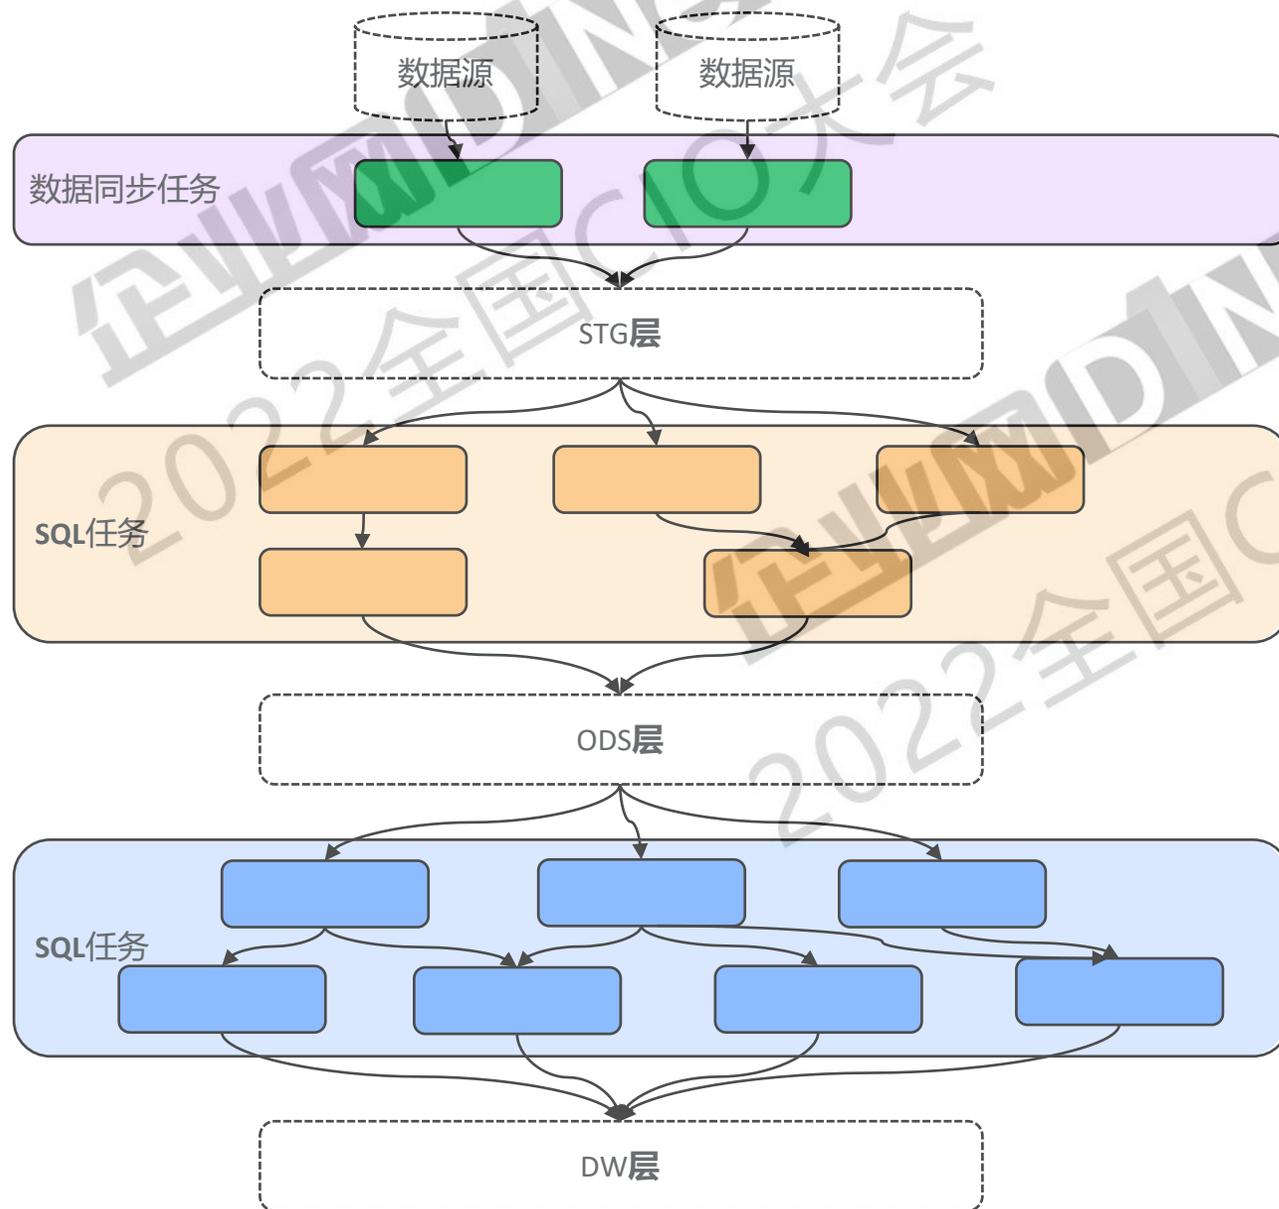
资产健康分评估

资产指标维度	指标名称	指标引导目的	指标计算口径	不及格分标准(0分)	60分标准	80分标准	90分标准	100分标准	单项权重
规范性评估	1)表命名规范性指标	表命名更加规范	a)表模型层级前缀不符合规范 b)表后缀命名不符合规范 c)表主键命名不符合规范	命中a,b,c	命中b,c	命中c或者b	命中c	无任何命中	x%
	2)表和字段注释规范性指标	表注释更加规范易懂	a)表没有注释 b)表有注释,但是注释太短 c)字段没有注释 d)字段部分有注释,或者有注释的字段占比(目前定90%)	命中a	未命中a,但命中b或c	未命中a,b,c,只命中d	-	无任何命中	x%
	3)字段安全等级性指标	表权限管理符合规范	a)该表字段有安全等级配置占比<10% b)该表字段有安全等级配置占比<40%,但>=10%; c)该表字段有安全等级配置占比<60%,但>=40%; d)该表字段有安全等级配置占比<80%,但>=60%;	命中a	命中b	命中c	命中d	无任何命中	x%
	4)责任人符合规范	表责任人合理有人管	a)表归属离职人员 b)表owner和owner的BU不一致 c)表owner和任务生产owner不一致 d)表owner和最近一次DDL的owner不一致(目前后者元数据不准确,暂废弃)	命中a	命中b,无a	命中c,无a,b	命中d,无a,b,c	无任何命中	x%
	5)依赖加工规范	引导表依赖和计算加工更加规范	a)逆层依赖,违背了数据模型主体流程依赖的顺序,ods->dwd->dws->ads/dm的顺序,出现直接或者跨多级逆序的; b)底层依赖,出现除dwd以外依赖ods层的,如dws依赖ods, ads/dm依赖ods的; c)加工链路过长,数仓模型中,从源头到该表的任务层数>N的(此扣分项识别但不扣分);	命中a	未命中a,命中b;	未命中a, b,命中c; (调整为不扣分,即此条规则作废)	-	无任何命中	x%
保障性评估	1)有监控保障指标	引导任务有监控管理	a)表没有任何监控 b)表仅有非强制性监控,且监控数=1 c)表仅有非强制性监控,但监控数>1 d)表有强制性报错监控,且监控数=1 e)表有强制性报错监控,且监控数>1	命中a	命中b	命中c	命中d	命中e	x%
	2)有DQC报警保障指标	引导资产产出有DQC保障	a)表没有报警owner配置 b)表没有短信、企微报警配置 c)表没有电话报警配置 d)表没有产出承诺配置	命中a	没有命中a,命中b	没有命中a,b,命中c	没有命中a,b,c,命中d	无任何命中	x%
	3)有基线保障指标	资产生产有资源或承诺保障	a)表没有任何基线 b)表有普通任务基线 c)表有高优先级任务基线	命中a	-	命中b	-	命中c	x%
准确性评估	1)DQC达标指标	引导数据产出准确	a)最近一天出现数据为空报警 b)最近一天出现数据重复报警 c)最近一天表资产出现强阻塞报警	命中a,b,c,命中d	-	命中a	命中b	无任何命中	x%

- 荣获2019年度中国信通院大数据“星河奖”
- DQMIS 2019中国《数据质量卓越实践奖》
- 首家互联网企业通过DCA大数据管理平台基础能力测评
- 参与制定国家《大数据资产管理实践白皮书》行业标准
- 信通院《数据标准管理白皮书2019版》
- 企业标准建立《腾讯数据治理元数据管理规范》
- DAMA数据治理最佳实践

数仓规范体系





基于【数仓分层】做质量监控，让数据有保障

入口层/数据引入层/基础层

- 业务主外键是否唯一
- 周期性数据波动是否过大/特殊类（如日志等）
- 无周期性则判断、数据是否大于固定值

数据清洗层/整合加工层

- 增加一些对清洗逻辑的监控
- 对于整合的数据判断其数据唯一性、重复性

轻度/高度汇总层

- 根据汇总逻辑做平衡值监控

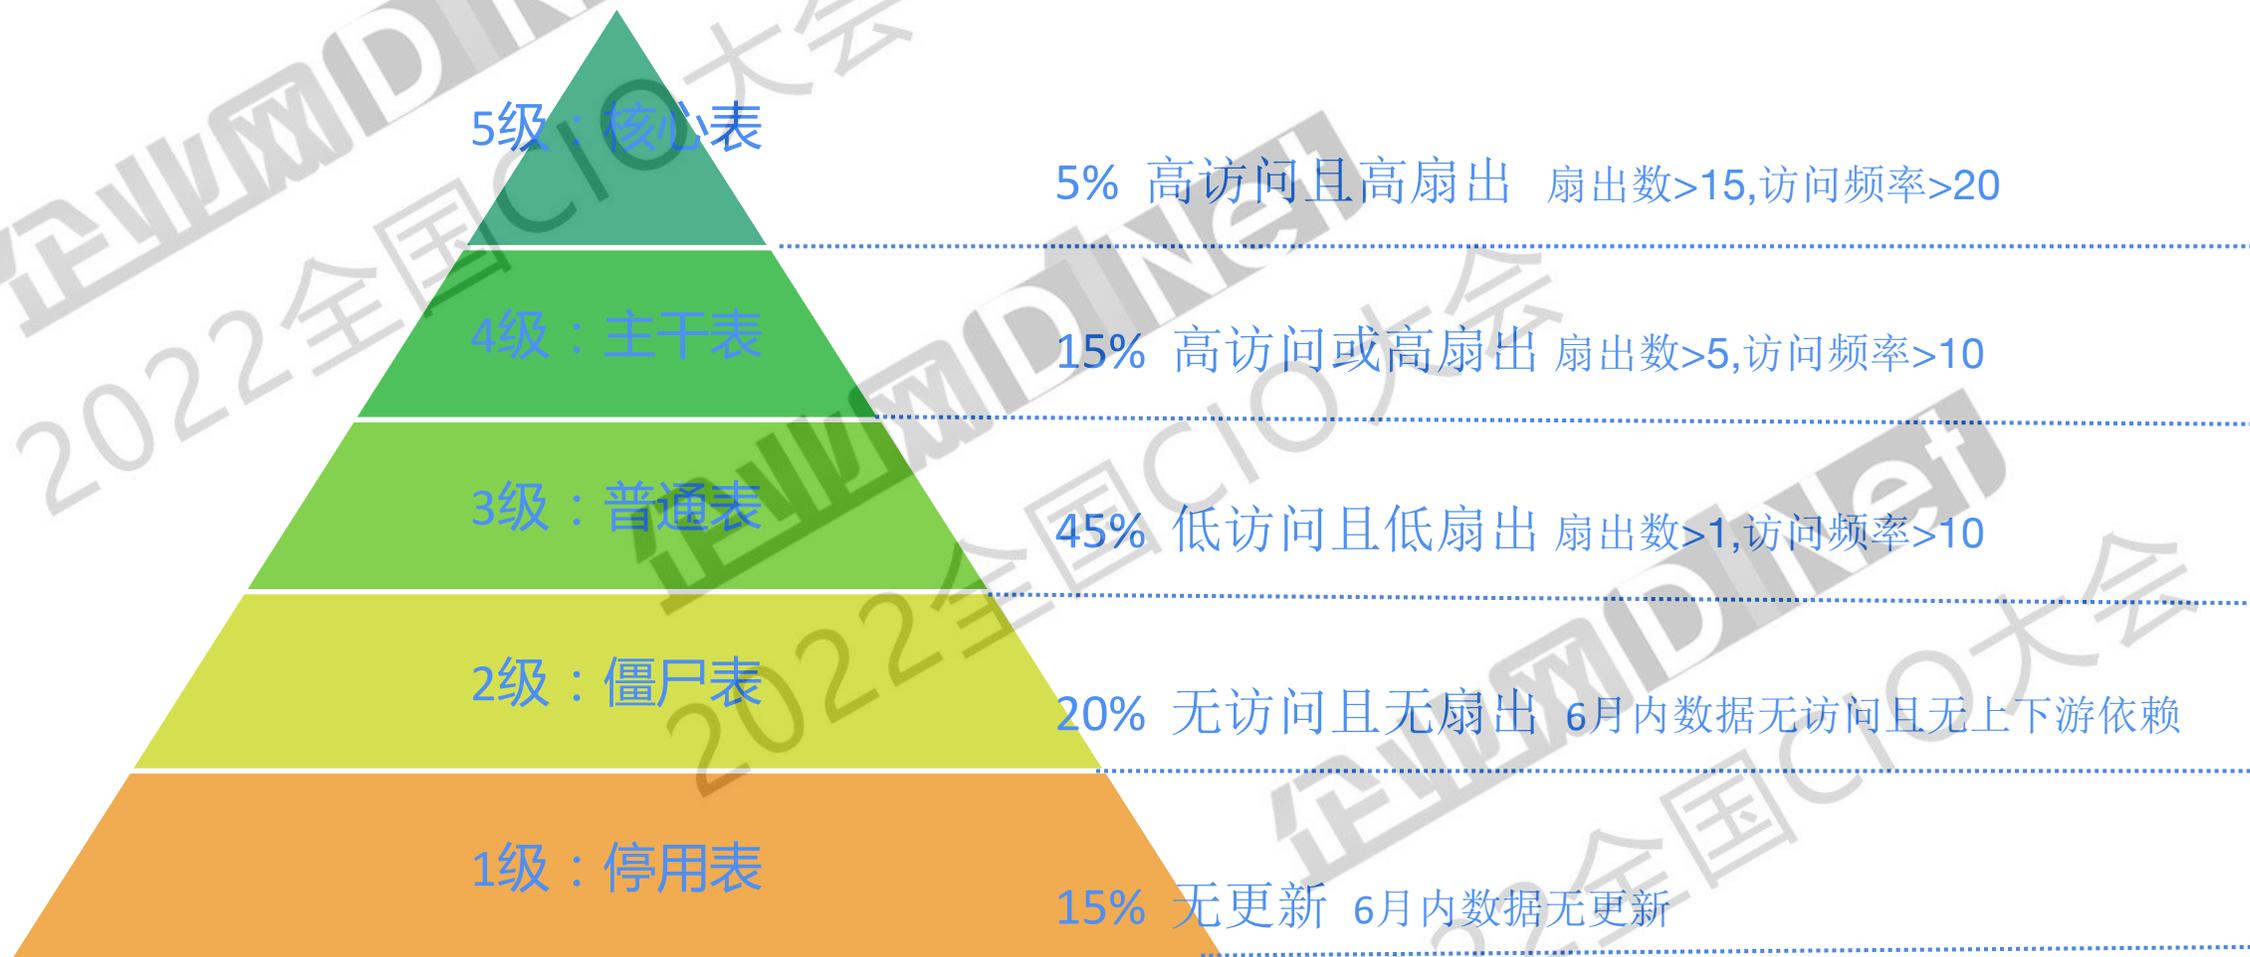
维表层/事实表层

- 主外键一致
- 维度值增加/减少监控

出口层/应用层/报表层

- 逻辑主键
- 多表之间的平衡关联
- 特定业务逻辑监控

腾讯内部实践：如何进行资产评级？



腾讯内部实践：如何进行成本优化？



中心	任务健康度评分 ↓ ①
1 中小商户产品研发中心	94.56
2 境外产品中心	94.49
3 金融与应用产品开发中心	93.25
4 运营支持研发中心	92.52
5 行业应用支持中心	91.07
6 行业应用研发中心	90.91
7 业务连续性架构中心	90.81
8 基础产品中心	90.73
9 支付安全中心	90
1 数据中心	89.52



任务优化

累计优化任务2,940个



存储优化

累计节省存储8PB+



计算优化

累计节省546计算单元，节省成本百万级元/年



成本优化

每年节省千万级元

03

WeData 数据治理平台能力

腾讯内部大数据能力的对外商业化输出-WeData



WeData数据治理-时效性：统一元数据

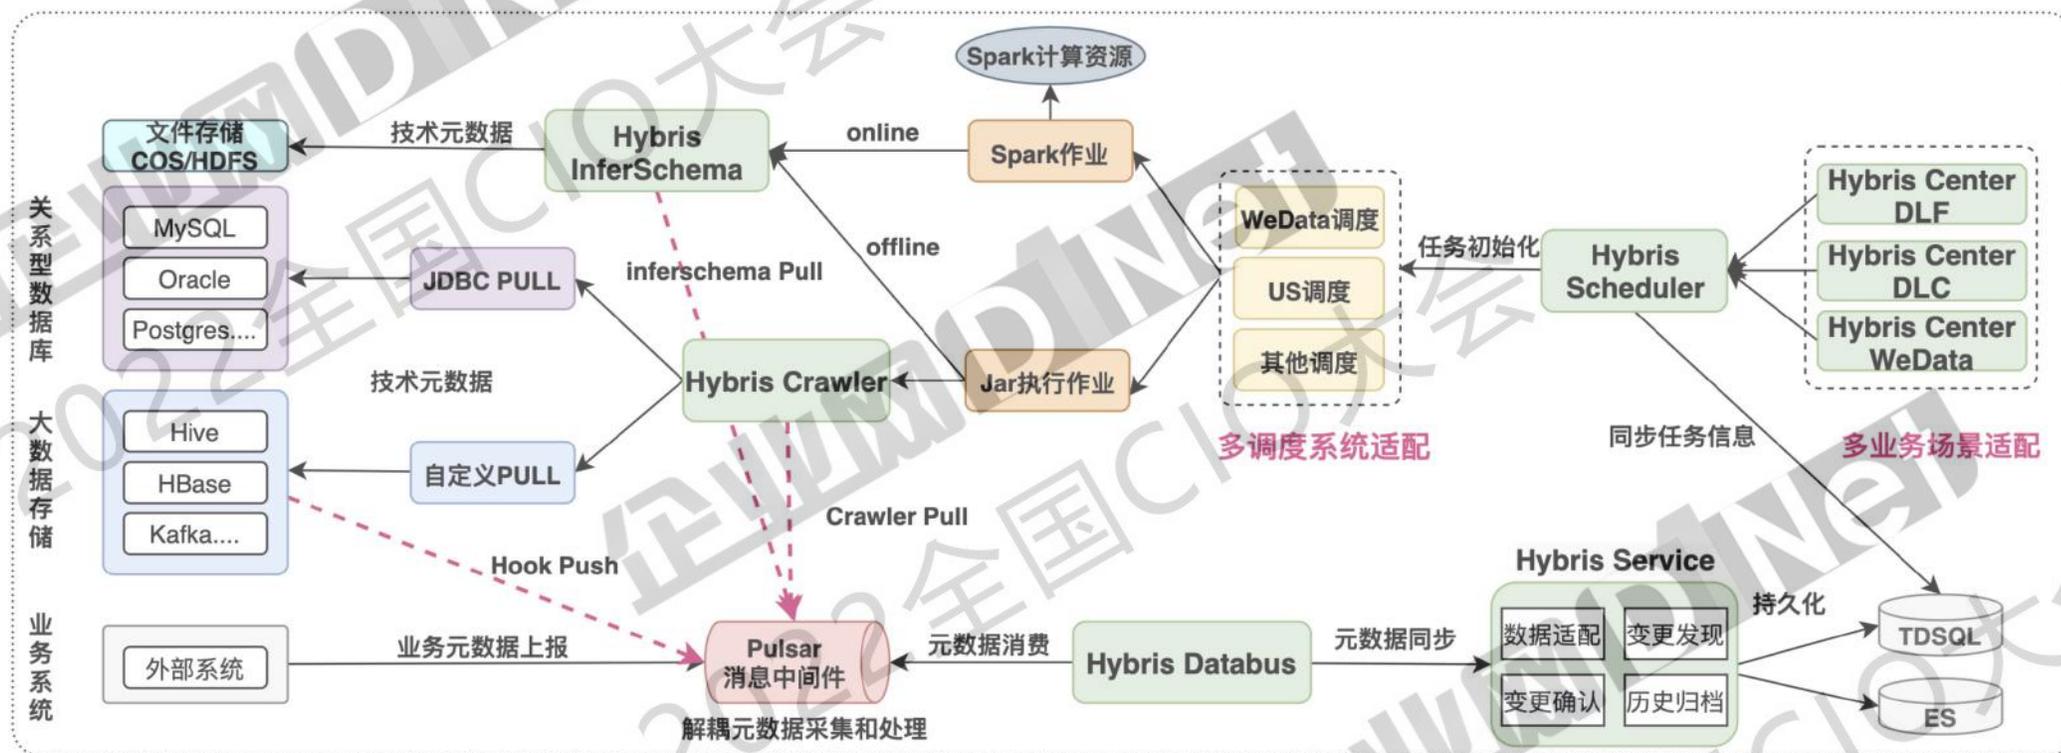
时效

质量

可用

安全

成本



1 多源支持

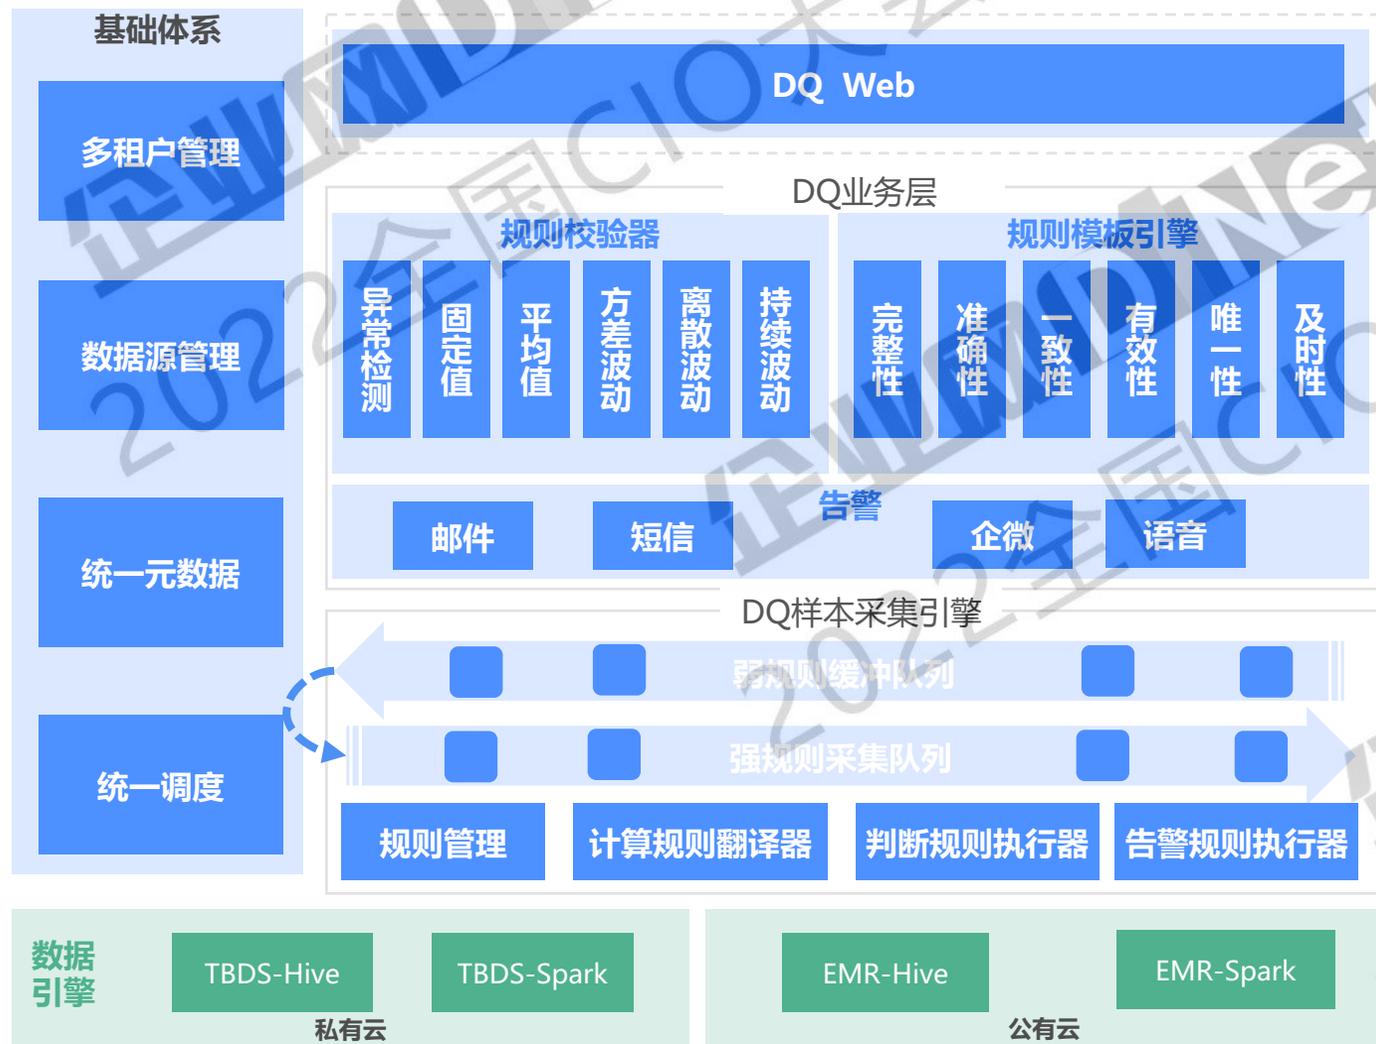
- 关系型数据库
- 大数据存储
- 业务系统

2 多种采集方式

- 实时Hook汇聚
- 离线周期采集补偿
- 业务元数据主动上报

3 多场景适配

- OLTP在线数据目录
- OLAP数据湖分析



1 可视化配置

- 数据监控
- 规则模板
- 运维管理

2 丰富模板

- 53种官方模板
- 自定义规则模板
- 字段级
- 表级

3 全维度规则

- 测试运行
- 事中检测
- 事后检测

4 质量报告

- 综合质量分
- 维度质量分
- 表质量分明细

时效

质量

可用

安全

成本

1. 规则模版定义

质量规则模版

增加数据质量规则集

2. 基于元数据配置数据质量监控

质量监控配置

离线周期检测

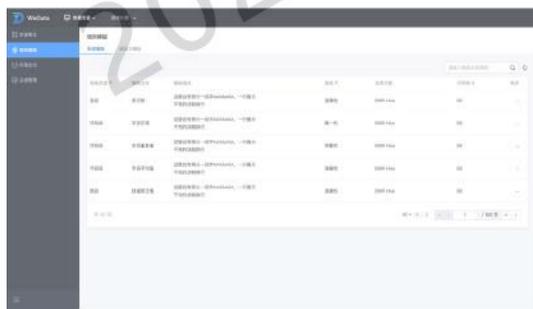
ETL流程监控

3. 质量问题跟踪处理

质量任务运维

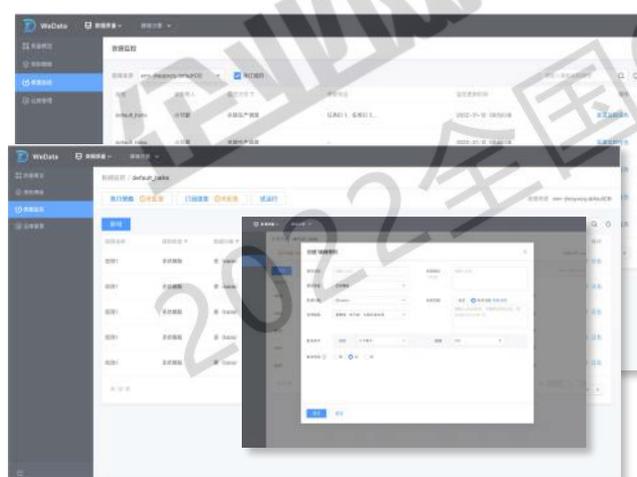
4. 定期数据质量分析

质量概览：质量核心指标日常关注
质量报告：数据质量考核评价



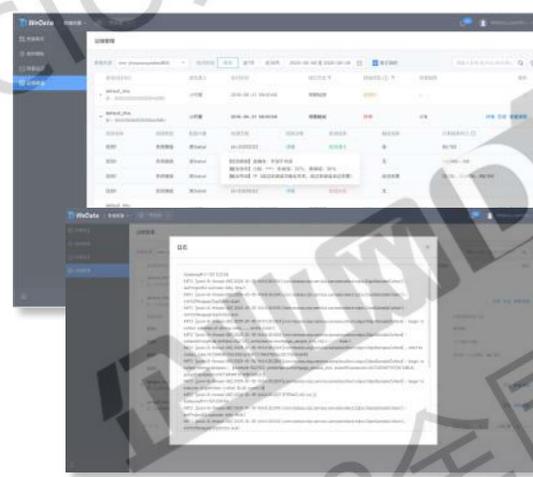
「规则模版」

- 支持系统内置规则模版 40+，包含固定值比较，和波动率对比较



「数据监控」

- 可针对表、字段的进行规则配置
- 同时支持关联到调度实现事中监控阻断、以及离线周期检测固定值比较，和波动率对比较



「运维管理」

- 任务执行情况的运维管理，可查看检测结果，日志问题追踪
- 支持进行问题分级，并提供不同程度的告警触达（短信、微信等）



「质量概览」

- 不同周期下 数据检测、规则运行、质量维度问题情况分布等核心指标的统计
- 查看周期内告警和任务阻塞趋势，并快速定位到“搞频”

WeData数据治理-可用性：数据运营

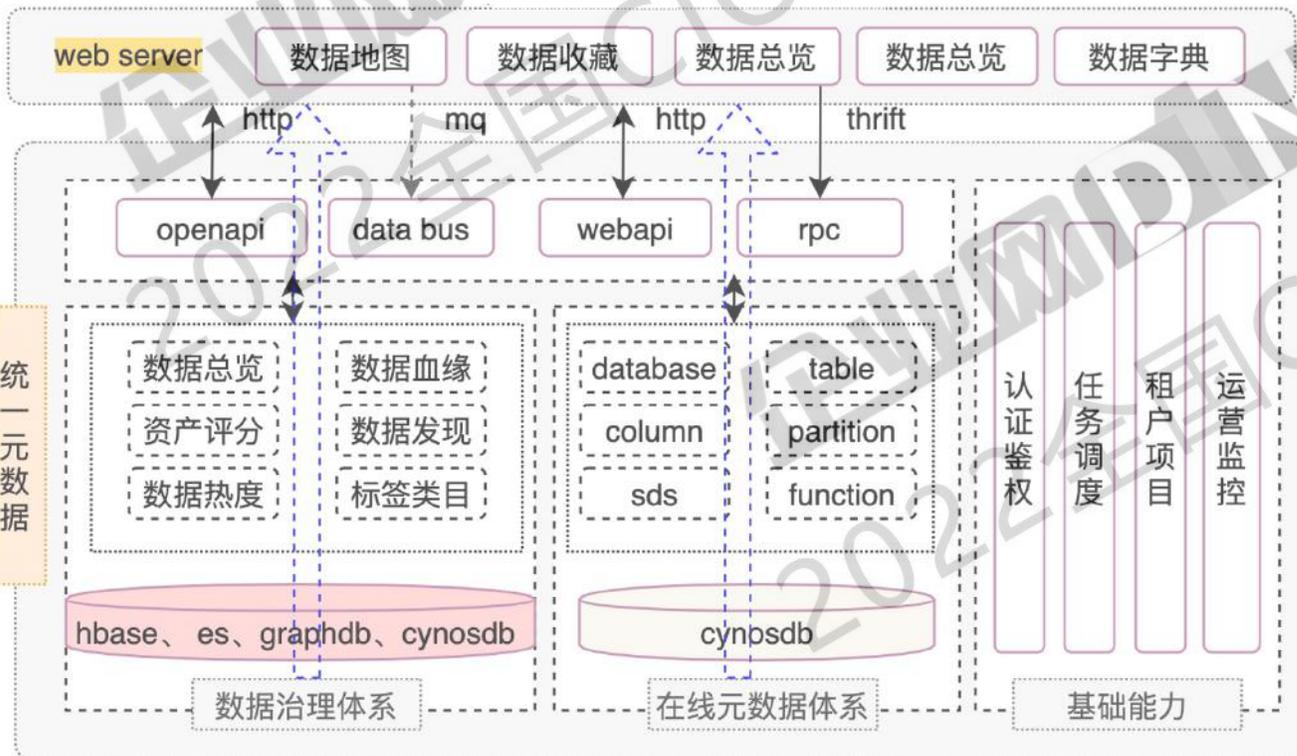
时效

质量

可用

安全

成本



数据发现

数据类目&标签

元数据详情

全局检索

数据探查&数据预览

数据血缘&影响分析

WeData
数据运营

时效

质量

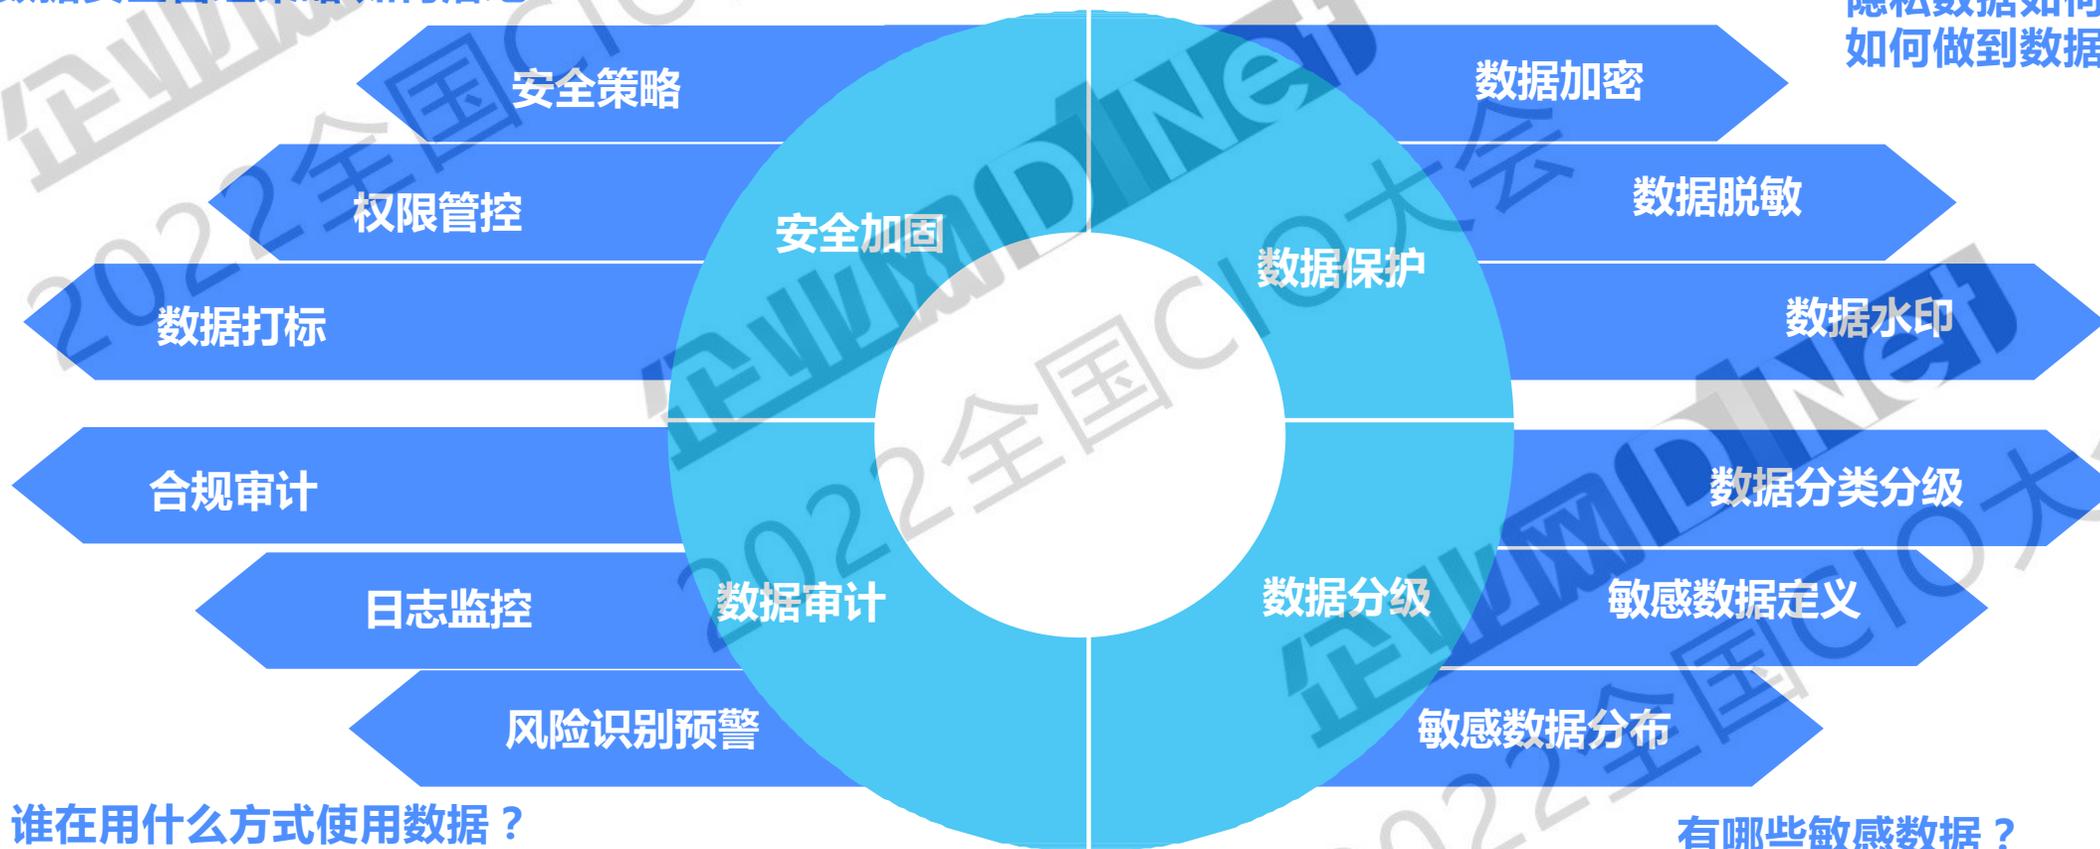
可用

安全

成本

如何管理敏感数据的权限？
数据安全策略如何落地？

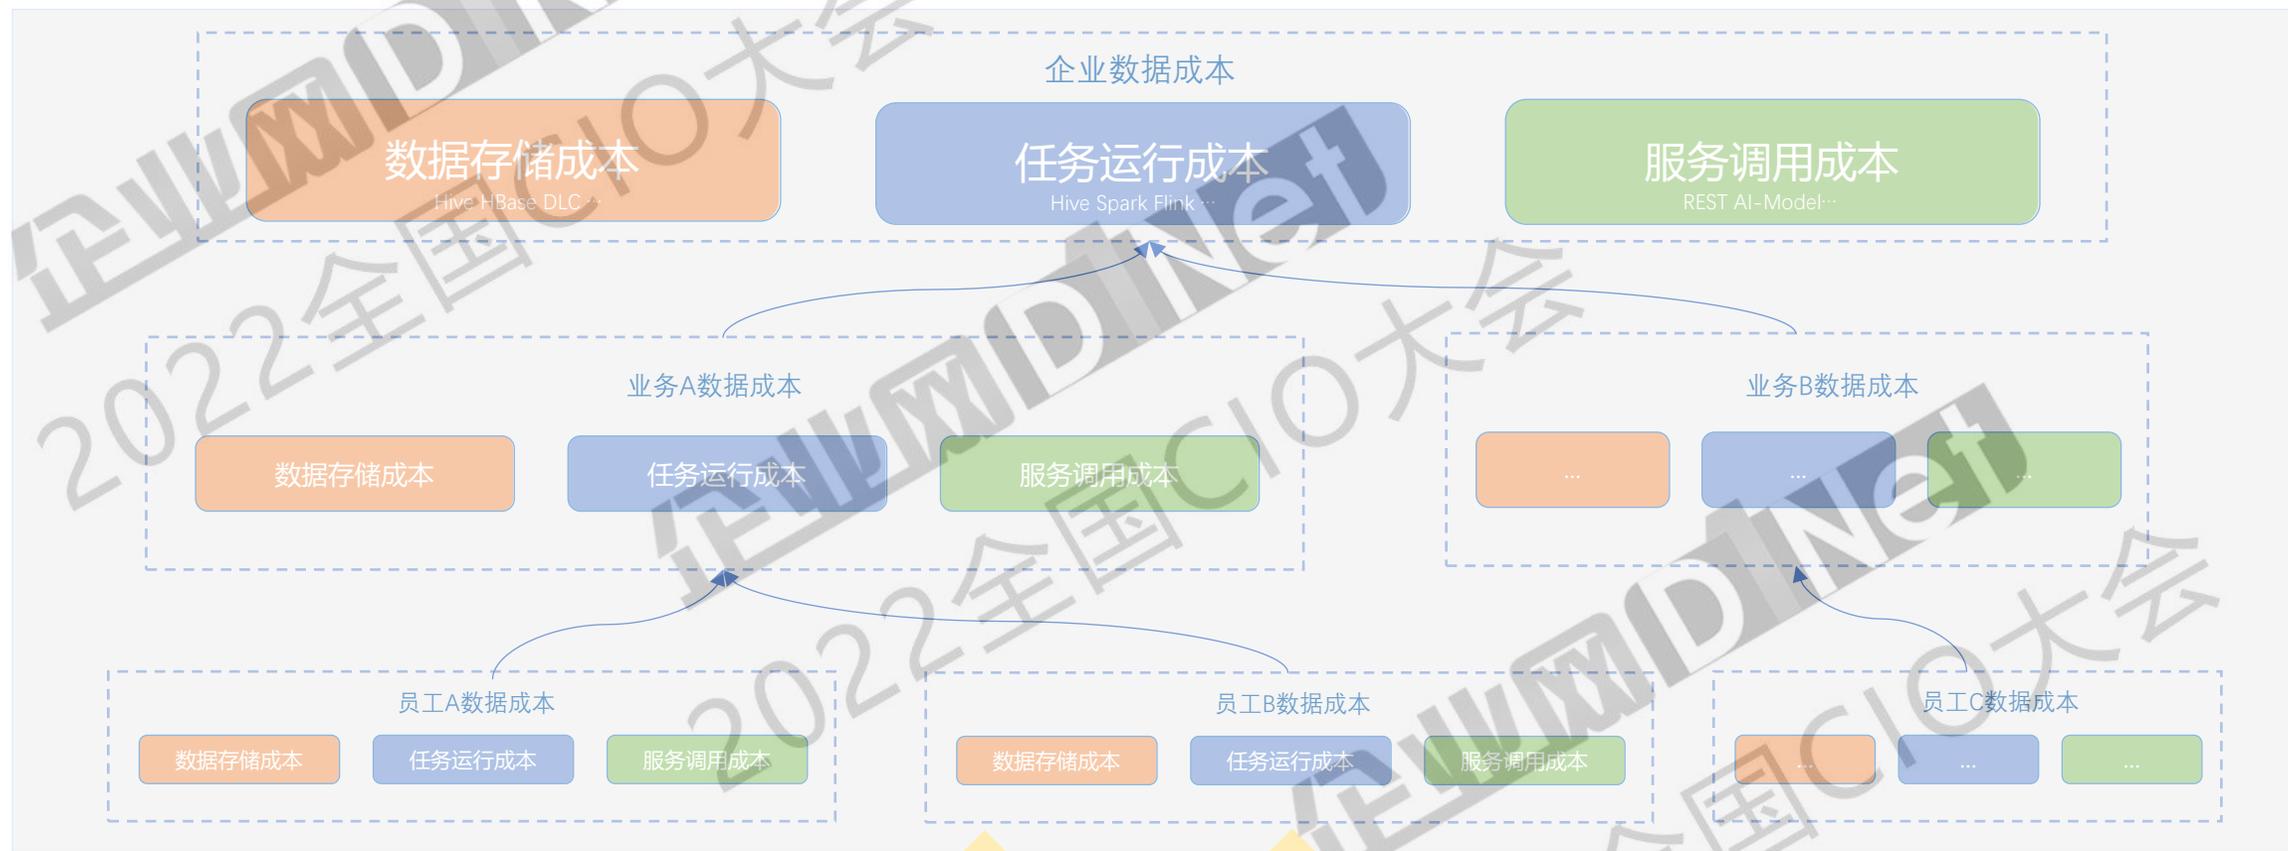
隐私数据如何保护？
如何做到数据可用不可见？



谁在用什么方式使用数据？
如何识别出有风险的数据操作？
如何判断数据操作是否合规？

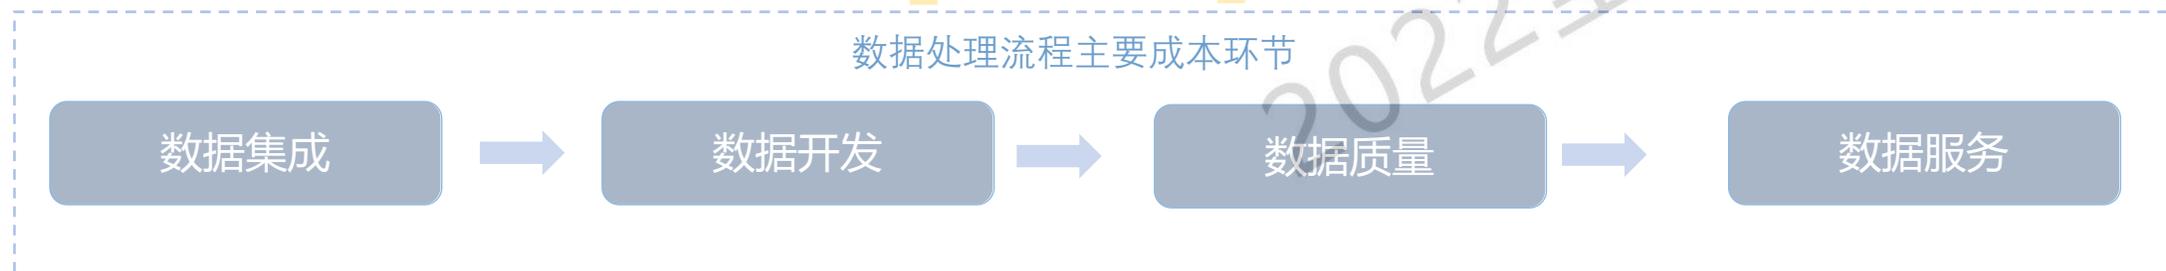
有哪些敏感数据？
敏感数据分布在哪？

WeData数据治理-成本：成本中心



成本打点

成本归属



04

行业案例

企业网DINet

2022全国CIO大会

企业网DINet

2022全国CIO大会

企业网DINet

2022全国CIO大会

成功案例：某商业银行客户数据能力中心建设

统一开发18000+个数据任务 统一落标1000个标准项

- 统一对接MySQL/Oracle/DB2/文件等多种数据源
- 统一开发Hive/Spark/Shell/Python等多种任务
- 基于事件与时间的统一任务调度及运维
- 数据标准平台建标5000个标准项
- 通过数据开发建模平台事前落标1000个

统一管控19000张数据表

- 数据资产平台展示完整字段级数据血缘
- 统一数据权限的申请、授权、审批等管控
- 精确到人到表的行列权限与动态脱敏控制

客户痛点

- 数据的开发、调度工作分散情况严重
- 数据质量低、数据落标困难
- 大数据组件运维复杂，缺乏集中统一的有效运维中心

业务数据

核心账务，对公信贷，个人贷款，在线贷款，代发代扣，外汇资金，人民币资金，理财，基金，网银，信用卡，柜面，支付清算等

方案架构



- 2021金融业新技术应用创新突出贡献奖
- 2021年度农村中小金融机构科技创新优秀案例

应用场景



零售和网金业务的指标标签 营销集市
反欺诈 智能决策 数据探索

成功案例：某工程机械制造商实时监控与故障预测项目

50万台工程设备实时监控

6.5小时工程设备故障预警

1000+个传感器维度实时分析

87.6%故障预测率

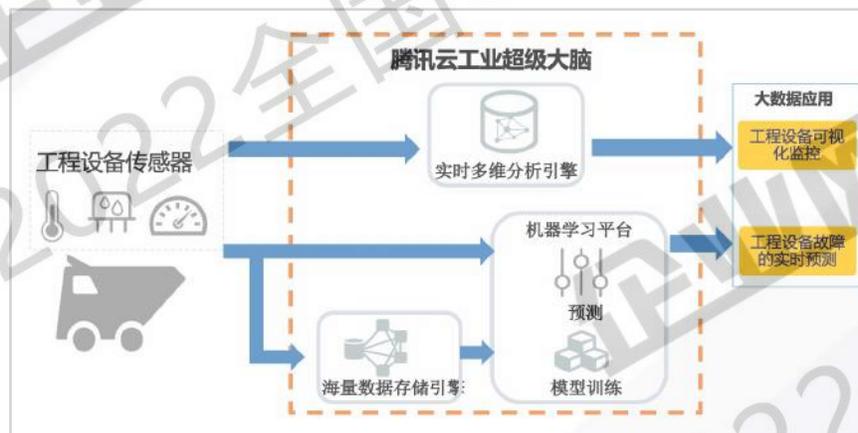
客户痛点

- 物联网设备产生海量数据需要采集
- 实时采集与计算复杂度高
- 基于时序数据进行设备分析

业务数据

工程设备传感器数据、物联网数据

方案架构



应用场景



工程设备实时可视化监控 预测性维护

感谢聆听

企业网DINet
2022全国CIO大会

企业网DINet
2022全国CIO大会

企业网DINet
2022全国CIO大会

企业网DINet
2022全国CIO大会

企业网DINet
2022全国CIO大会