

DQMIS

第二届数据质量管理国际峰会

The 2nd Data Quality Management International summit



华矩科技

大数据时代的数据治理挑战及 应对策略

主讲人：华矩科技董事长CEO 谭海华

2018年9月

目录

CONTENTS

01

数据治理在当下大数据内外环境下的发展

02

企业数据治理建设面对挑战

03

如何提升企业数据质量

04

案例分析

01

数据治理在当下大数据内外环境下的发展



大数据的冰山与金山

DQMIS

企业拥有的巨量数据
都是一个沉睡的金矿



数据的价值则如冰山，
您所知道的只是显露的一角



企业大数据价值变现的阶梯发展





大环境对数据治理提出了更高的要求

DQMIS

目前数据应用项目非常多，但真正取得预期效果的项目少之又少，而且开发过程困难重重，其中的一个重要原因就是数据质量问题导致许多预期需求无法实现。如果没有数据治理，再多的业务和技术投入都是徒劳的，因为很经典的一句话：Garbage in Garbage out。数据治理是保证数据质量的必需手段，从全球范围来看，加强数据治理提升数据质量已成为企业提升管理能力的重要任务。

全球的大数据发展都对数据治理提出了更高的要求



中国

《银行业金融机构数据治理指引（征求意见稿）》



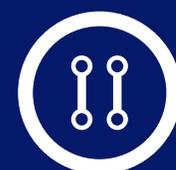
欧盟

《通用数据保护条例》
(GDPR)



美国

《2018年加州消费者隐私法案》(CCPA)



联邦

2018年7月18日联邦贸易委员会(FTC)发布了在众议院能源和贸易小组委员会的作证文本。根据证词，消费者隐私和数据安全将继续成为FTC的执法优先事项。



数据治理成企业当前大数据发展的核心策略

DQMIS



“

数据治理正迅速发展成一种企业核心策略！

”

如今，企业对于全面数据治理的需求从未如此强烈。监管机构希望企业能更加清晰地了解数据，对它进行有效的管控；企业管理层希望理清数据资产，降低数据应用的复杂性，对企业进行更高效的管理；企业每名员工都认识到数据的重要性，更多地采用数据驱动的方式来开展工作。

02

企业数据治理建设面对挑战



“传统的数据治理的主要问题是关注于数据本身，而没有首先关注业务价值，数据只有创造业务价值对于企业而言才有意义。”



一个系统？ 优化的数据？

一个平台？ 改善的报告？

数据集成？ 实时数据展现？

数据仓库？ 精准用户画像？

一套标准？

“传统的数据治理的主要问题是关注于数据本身，而没有首先关注业务价值，数据只有创造业务价值对于企业而言才有意义。”



数据治理目标（示例）



搭建数据质量管理机制，快速诊断并优化数据质量，确保数据应用的高效运行。

梳理数据资源，为数据资源整合和元数据管理提供可靠依据。

整合数据资源，搭建可扩展、高性能、高可用的ODS/EDW数据仓库系统，实现数据资源集成共享。

基于高质量的数据和整合的ODS数据，实现主数据管理，实现客户单一视图和客户分群，搭建客户标签体系，推动精确营销业务。

建立数据资产化管理和数据治理保障机制，加强数据管控，健全数据管理体系。

构建数据服务和应用体系，不断优化数据管理体系，实现真正的数据驱动业务。



数据与真相的关系

DQMIS



- 对的数据不代表真相
- 错的数据一定不能反映真相
- 大数据时代，**正确的，高质量的数据能让你无限接近真相**



数据质量的相关指标（一）

指标类型	说明	衡量标准	备注
完整性 (Completeness)	不存在或缺失字段的数据的百分比。即实体的每个属性都有明确的值，不存在“空”或“未知”的属性。	字段的空值率	= 空值记录总数/总记录数
相关性 (Reliability)	满足外键参照完整性数据的百分比。对于数据库中的某些实体，它们的存在可能要依赖于其它的实体。	外键无对应主键的记录比率	= 外键无对应主键的记录总数/总记录数
唯一性 (Uniqueness)	满足主键唯一性约束数据的百分比。即一个表中的一组属性的值是唯一的。	1 - 主键的重复率	= 1 - 主键重复的记录总数/总记录数
有效性 (Validity)	满足域和数据有效范围定义的数据的百分比，即实体属性的值要在用户定义的有效范围之内。	1 - 异常值比率	= 1 - 超出值域的异常值记录总数/总记录数
及时性 (Timeliness)	是否满足业务应用对数据的时间要求。	满足时间要求的比率	= 满足时间要求的数据总数/总数据数
非重复记录 (Non-duplicate records)	是否存在多个记录表现同一个实体的现象。	样本数据非重复记录比率	= 1 - 样本数据重复记录总数/样本数据总记录数



数据质量的相关指标（二）

指标类型	说明	衡量标准	备注
真实性 (Facility)	真实数据的百分比。真实性是指数据库中实体必须与对应的现实世界中的对象是一致的。	样本数据真实数据比率	$= 1 - \text{样本数据中失真记录总数} / \text{样本数据总记录数}$
精确性 (Accuracy)	指数据精度是否符合业务需要。	样本数据满足业务对精度需求的比率	$= \text{样本数据中满足业务精度需求的记录总数} / \text{样本数据总记录数}$
一致性 (Consistency)	与其它系统（或者系统内部）一致的数据的百分比。	样本数据不同存储的匹配率	$= 1 - \text{样本数据中不同存储不同意义记录总数} / \text{样本数据总记录数}$
可理解性 (Understandable)	含义明确和易于理解的数据的百分比。即数据本身的含义是否简单、明确。	样本数据易于理解的记录比率	$= 1 - \text{样本数据中费解的记录总数} / \text{样本数据总记录数}$
可用性 (Availability)	数据是否可获得，满足业务使用。	样本数据可获得记录的比率	$= \text{样本数据可获得记录总数} / \text{样本数据记录总数}$



何为反映真相的优质数据

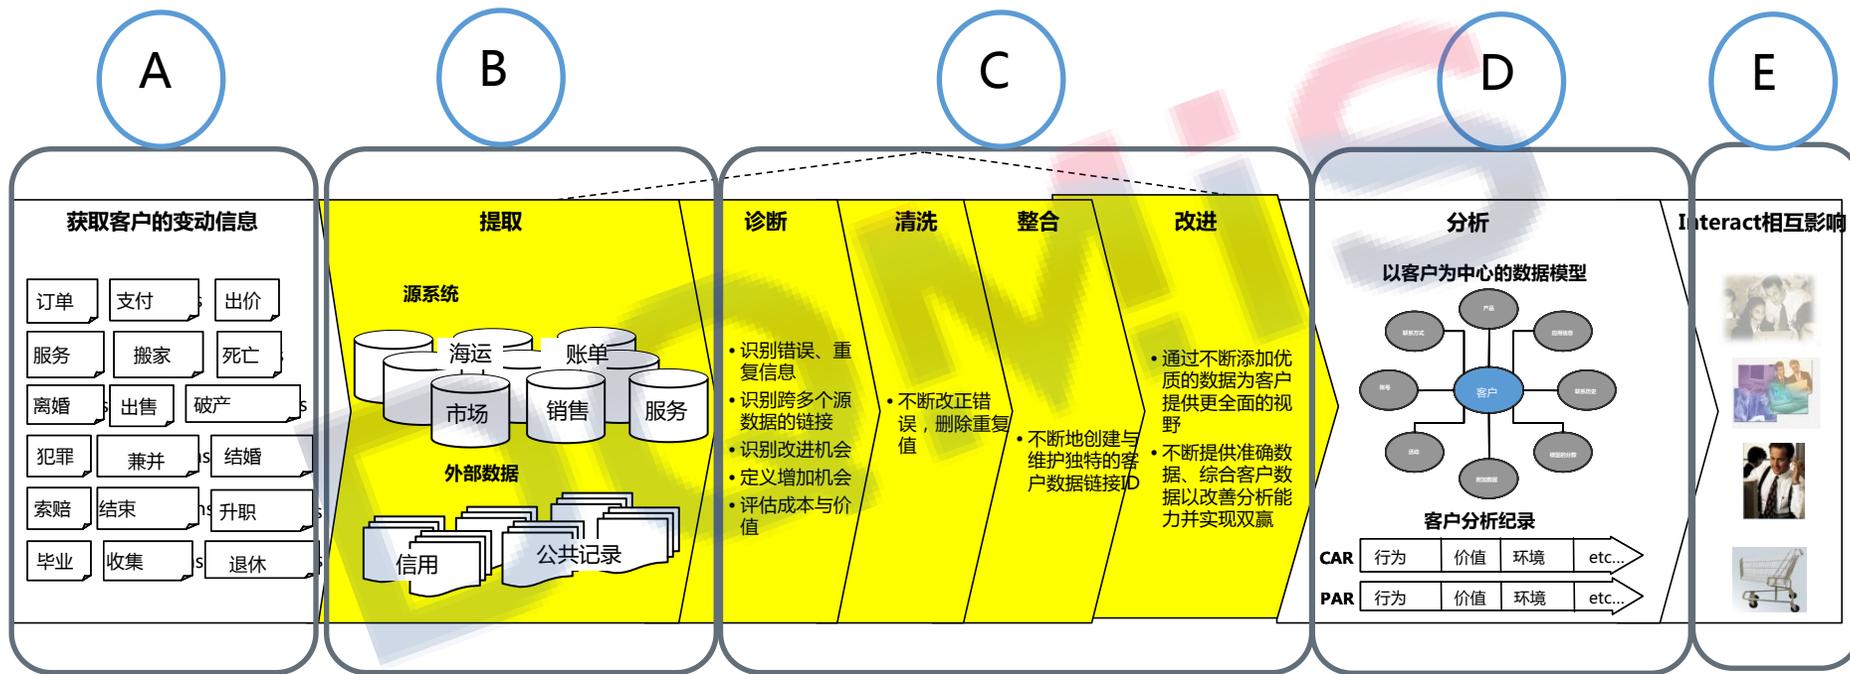
DQMIS





典型的数据治理建设路径

客户数据管理过程



- 各家客户数据纬度有限, 无法靠自家数据形成丰满的360度客户画像

- 历史及异构数据原因, 直接导致元数据管、主数据管理困难。
- 数据质量差
- ETL不堪重负

- 无法发现核心处理规则
- IT与业务人员无法有效互动
- 工作量巨大无法胜任
- 无法形成精准的统一视图
- “半吊子”工程

- 没有高质量数据输出, 无法调试建立更优模型
- 分析报告误差率高, 但无法判断是数据质量问题还是模型问题

- 应用
- 反馈

03

如何提升企业数据质量



数据治理的核心：全面了解您的数据

DQMIS



易受控制的风险
易处理的业务规则
清晰的期望值
业务用户参与程度高

不易受控制的风险
难以知晓的业务规则
低于预期的期望值
业务用户参与程度低



了解数据

DQMIS



数据本质



业务信息

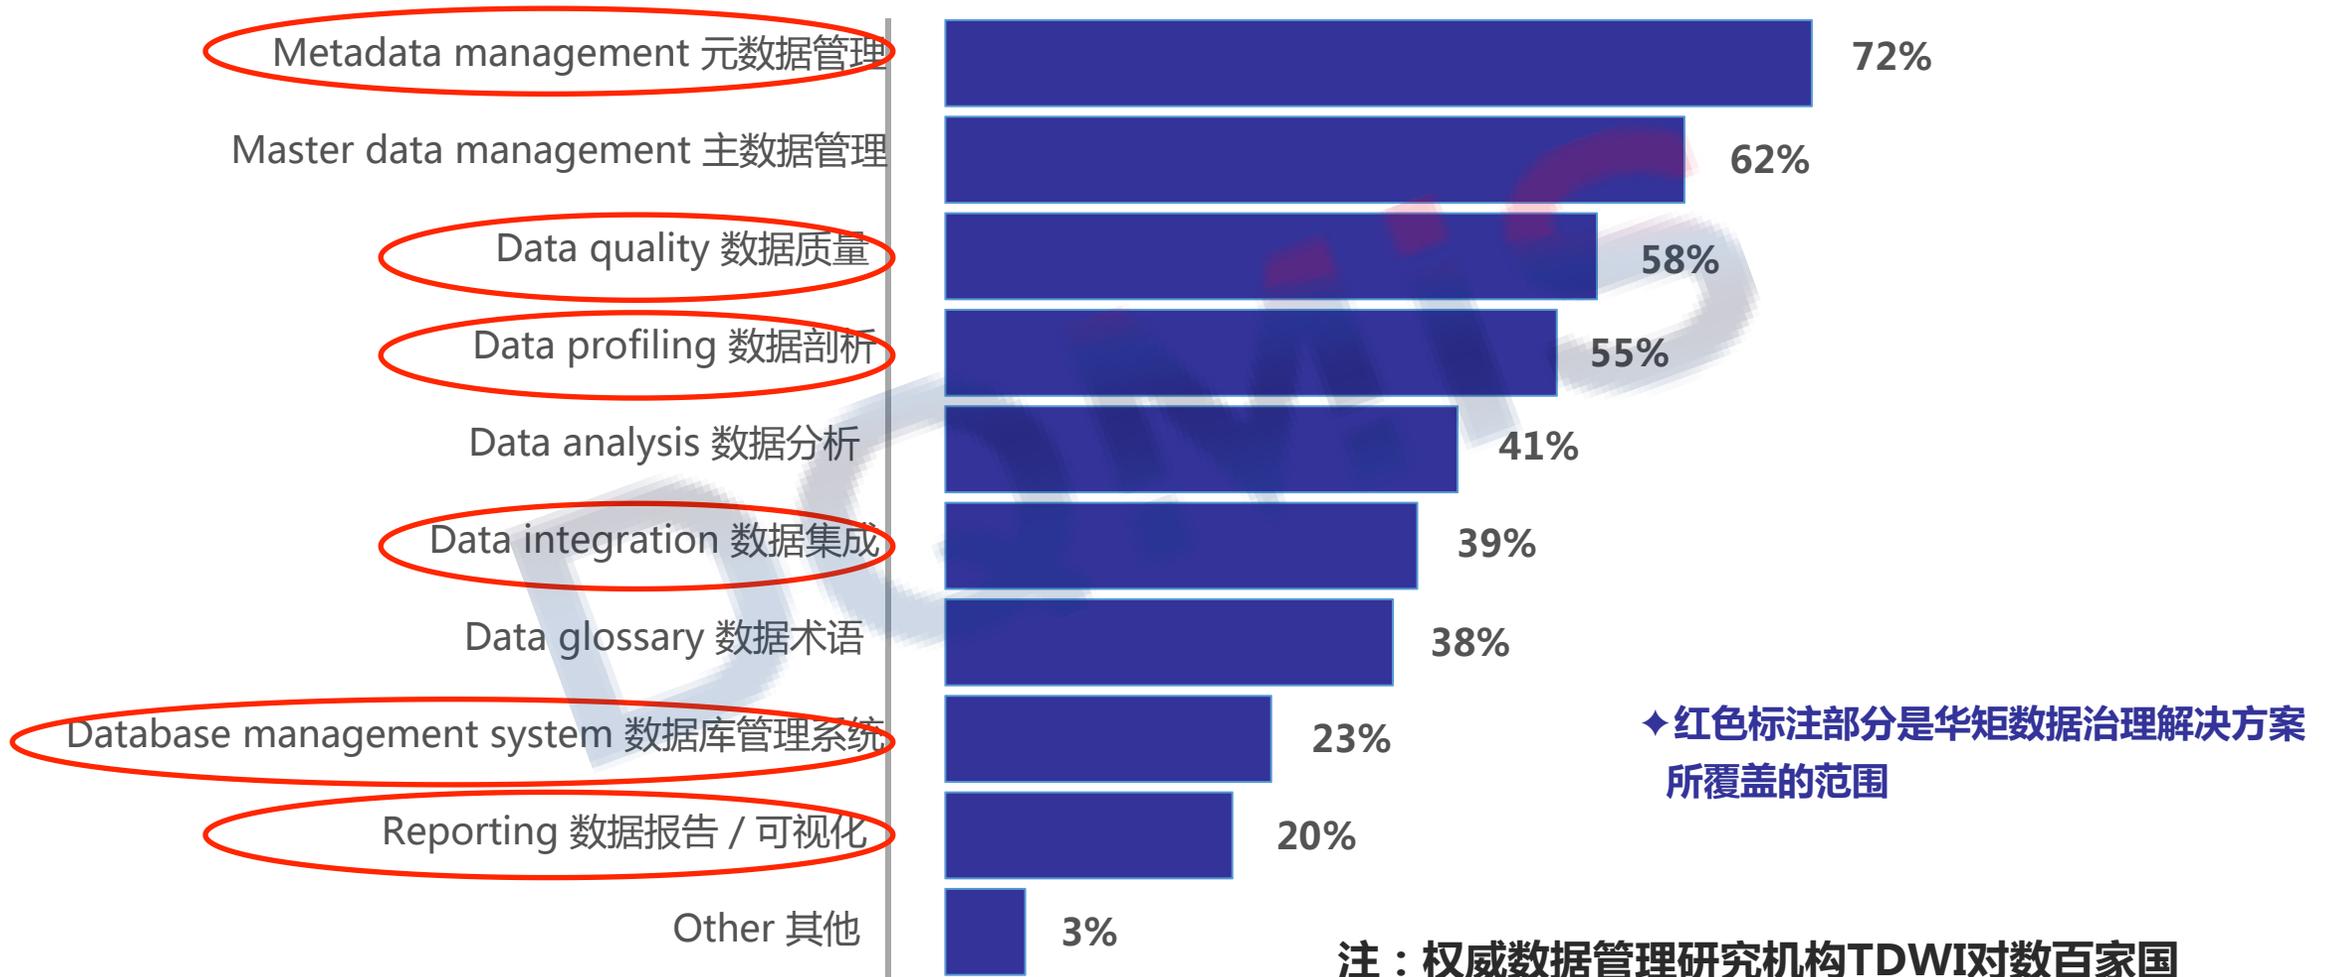


设计信息





数据治理几个关键技术的重要性




◆ 红色标注部分是华矩数据治理解决方案所覆盖的范围

注：权威数据管理研究机构TDWI对数百家国际企业的调研结果。



数据治理路径



调查

数据提取和调查

- 数据库连接
- 域
- 频率
- 模式
- 依赖性
- 外键关系
- 辨识数据值

丰富标准化

数据集成&标准化

- 价值诠释
- 属性赋值
- 数据解析
- 名字/地址
- 标准化
- 地址验证
- 附加数据

联系

关系匹配和数据整合

- 商业匹配
- 第三方数据匹配
- 最好的数据代

集成

实时数据集成

- 控制DB升级
- CRM, ETL, ERP
- RT验证和匹配
- 网页服务



数据治理平台交付的数据治理技术服务

DQMIS





数据治理平台功能概述（示例）

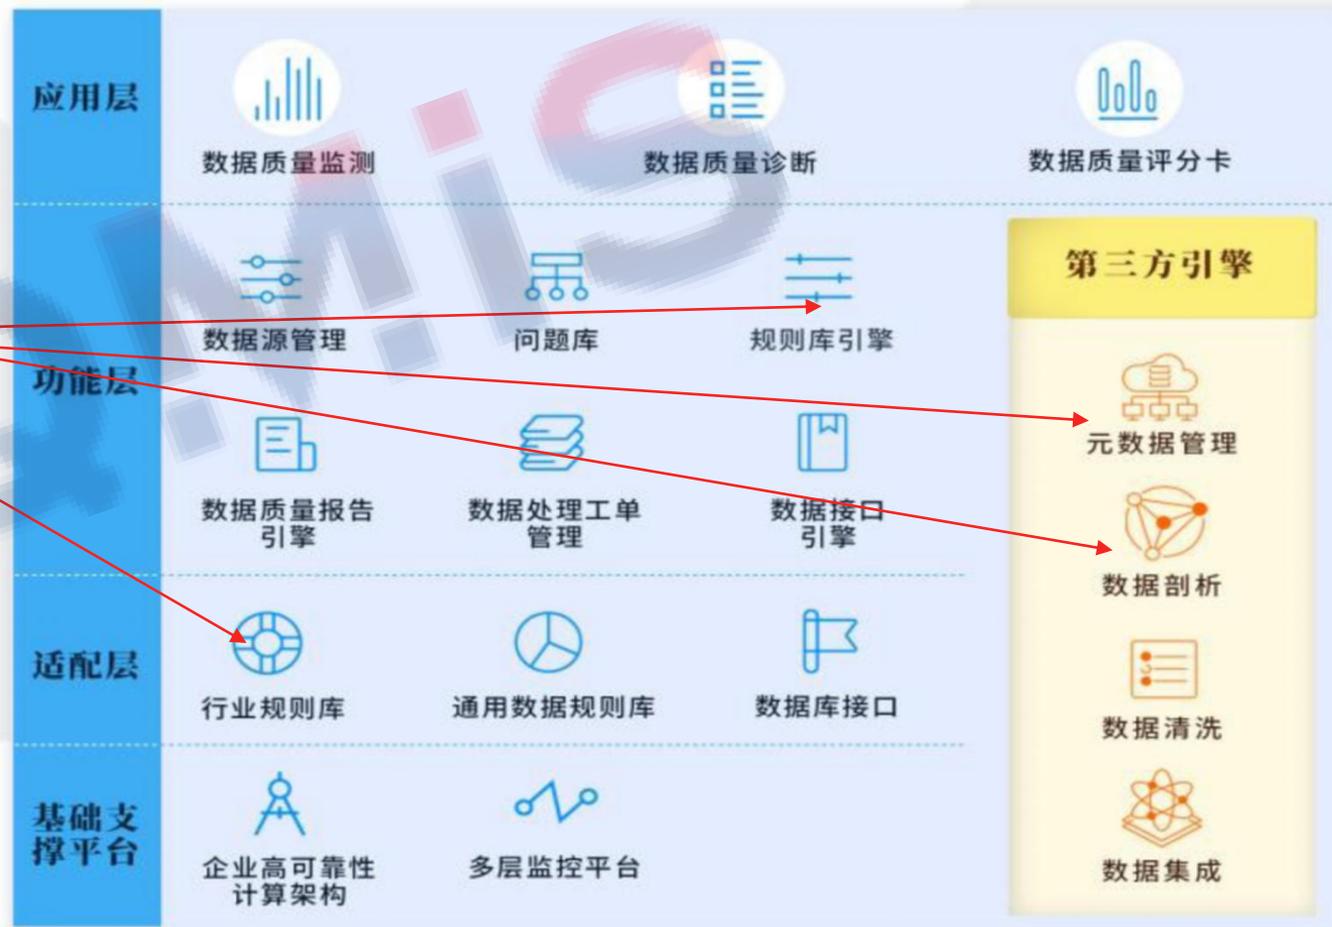
DQMIS

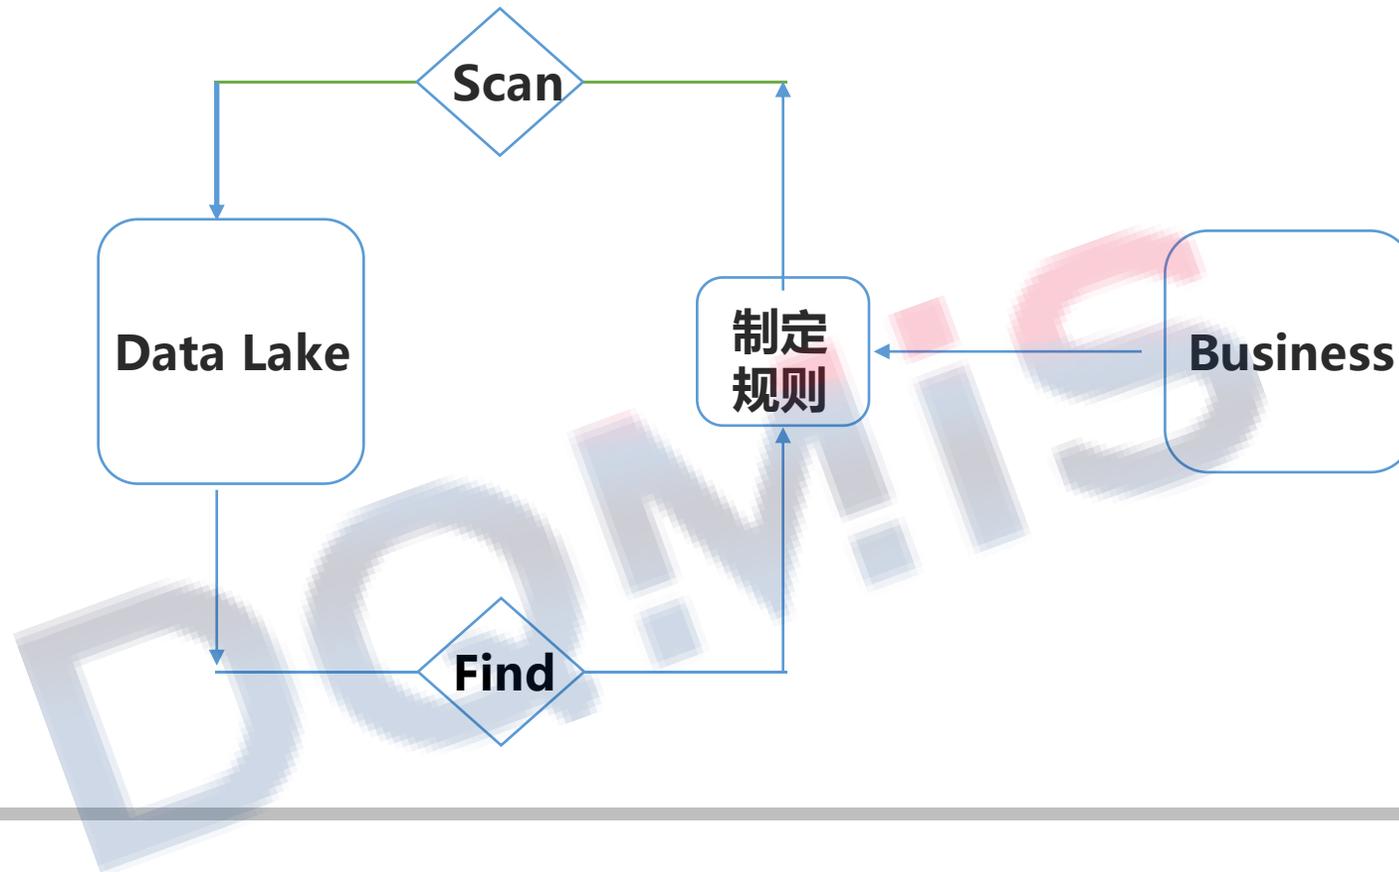
华矩数据治理平台





华矩数据治理平台



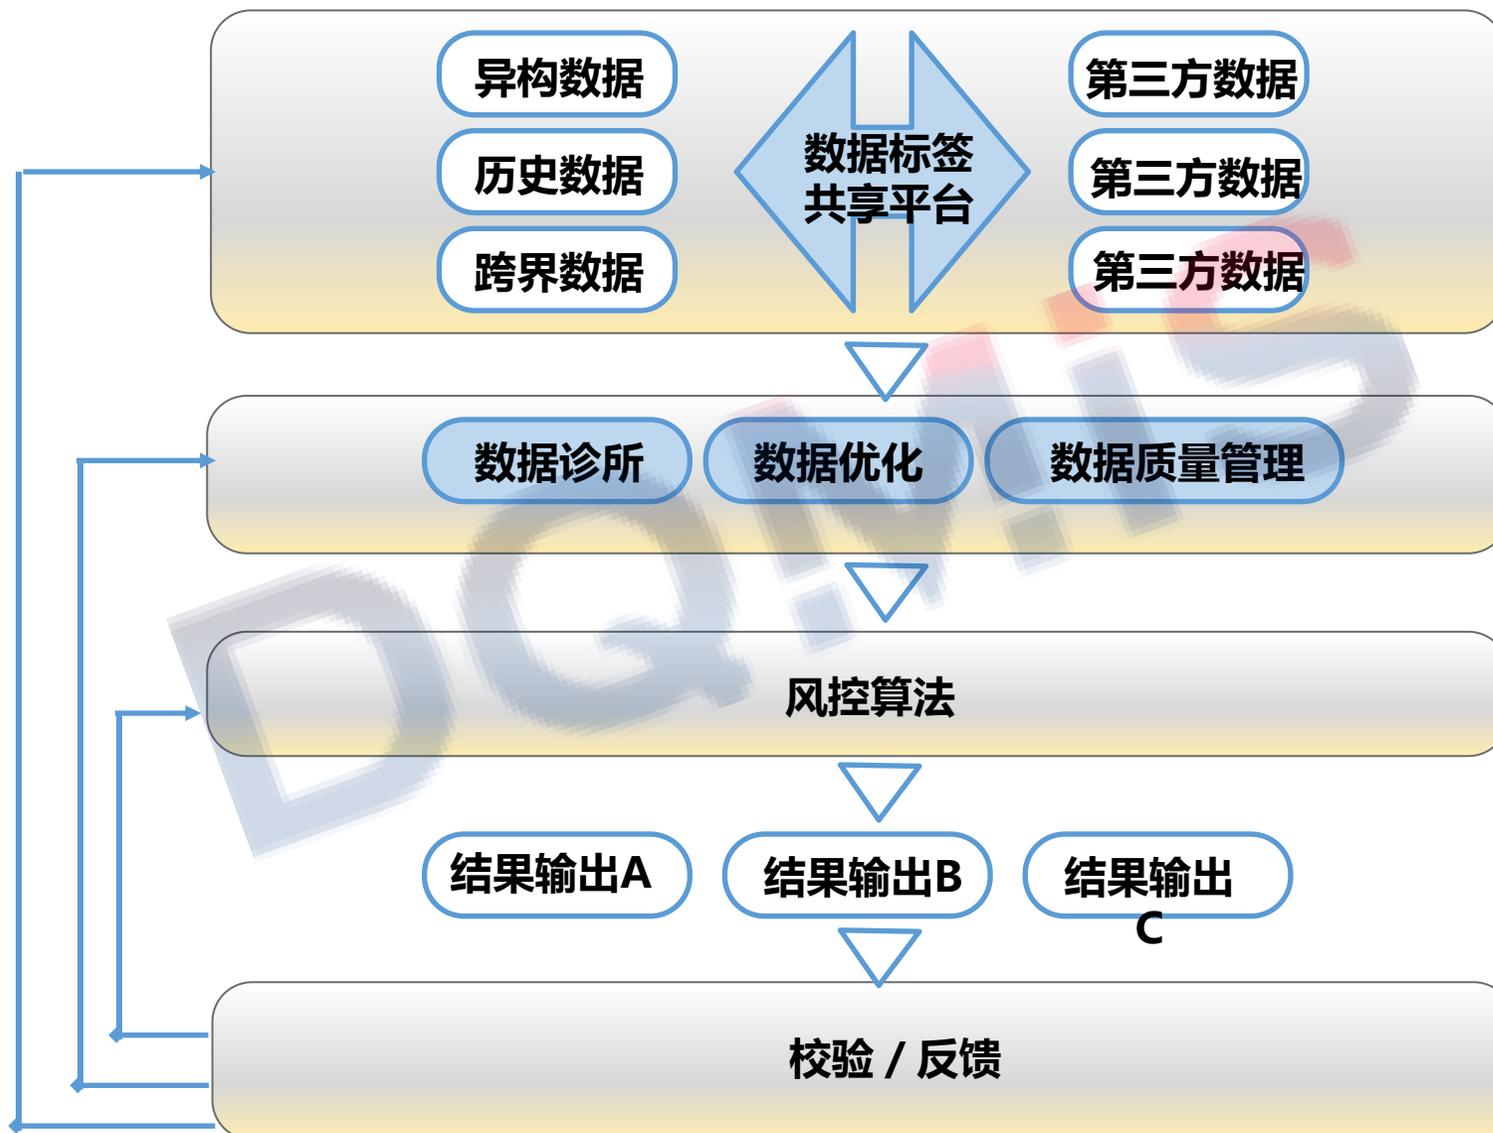


“传统的数据治理的主要问题是关注于数据本身，而没有首先关注业务价值，数据只有创造业务价值对于企业而言才有意义。”



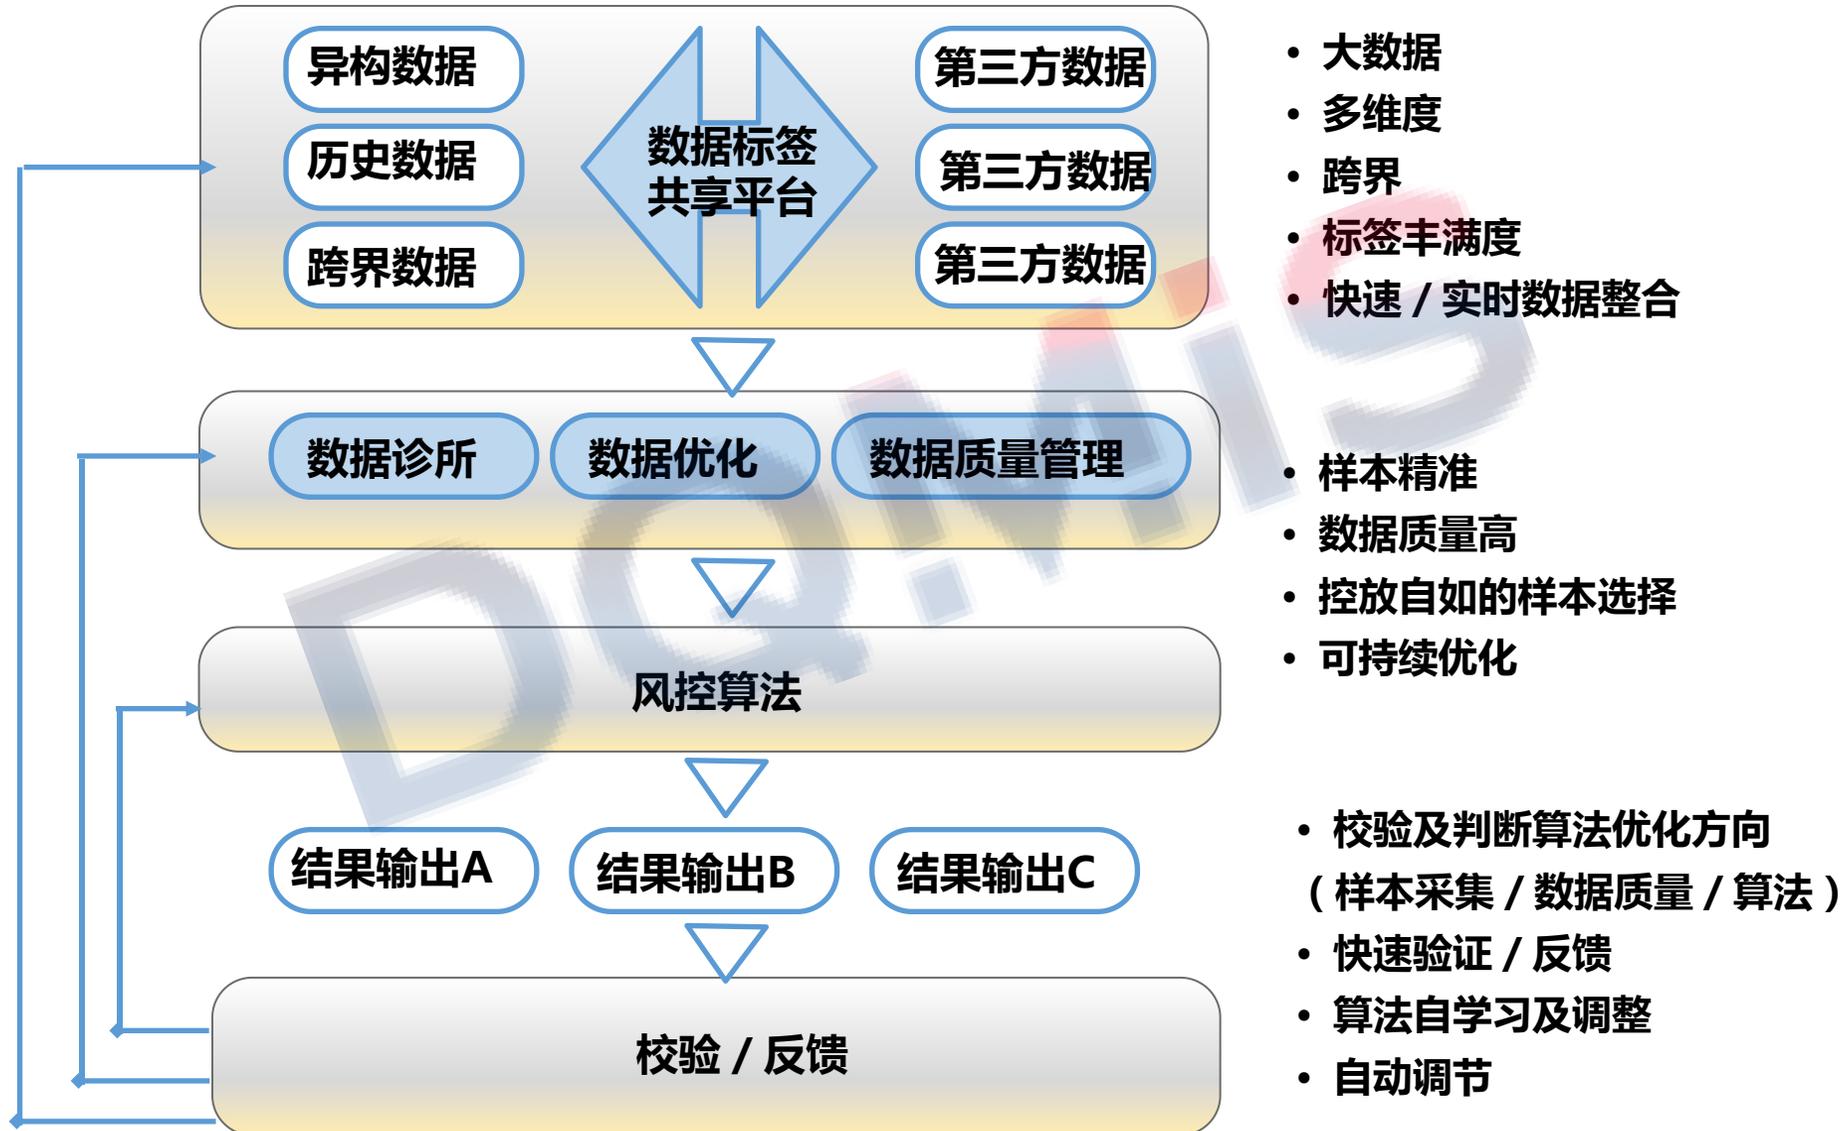
数据治理与业务应用关系 - (示例) 智慧金融风控模型

DQMIS



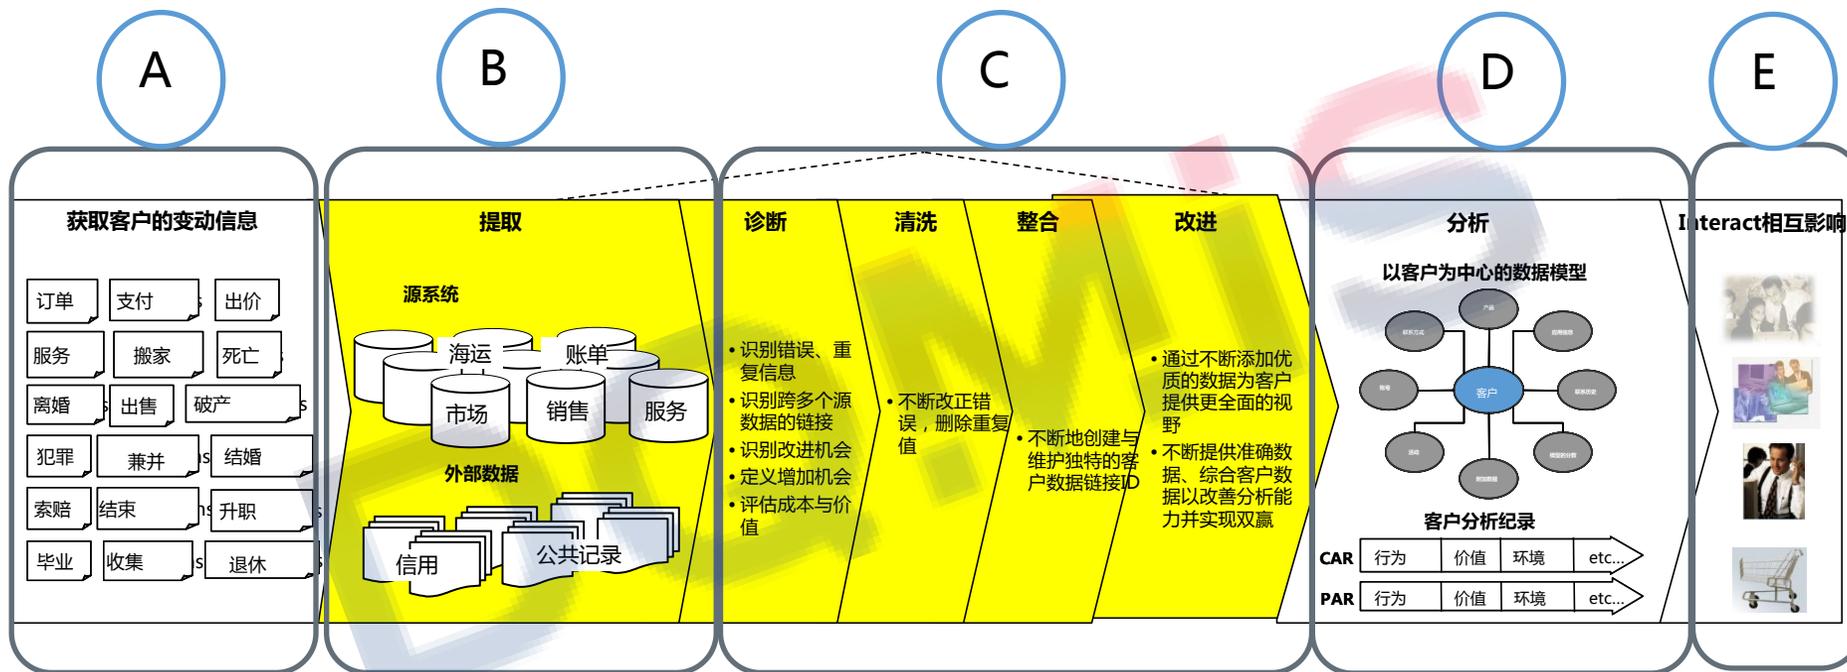


数据治理与业务应用关系 - (示例) 智慧金融风控模型





客户数据管理过程



- 客户360度画像设计

- 数据源选择
- 元数据管理
- 主数据管理
- ODS/data mark 建设
- ETL

- 数据剖析
- 建立业务规则
- 数据质量诊断
- 建立客户统一视图
- 自动化处理的调试和部署

- 建模
- 数据分析
- 结果输出

- 应用
- 反馈

DQMIS

第二届数据质量管理国际峰会

The 2nd Data Quality Management International summit



Thank You!