

数据驱动的电子商务企业客户全生命周期价值挖掘与营销策略迭代研究

张裕泰¹, 陈 炜^{1*}, 傅歆童², 盛耀辉²

¹甘肃农业大学管理学院, 甘肃 兰州

²中国联合网络通信集团有限公司, 北京

收稿日期: 2025年12月15日; 录用日期: 2025年12月25日; 发布日期: 2025年12月31日

摘 要

本研究专注于电子商务领域, 并构建了一个以客户全生命周期价值(CLV)为中心的数据驱动的营销策略框架。通过运用机器学习建模、多维度数据评估和归因分析, 对客户价值的分层度量、关键节点的数据挖掘、精准策略设计和闭环优化机制进行系统的论述。研究表明, 利用基于行为序列的潜在客户识别、面向价值层次的自动旅行和动态场景策略, 可以显著提高CLV的性能并优化其营销效果。得出结论, 构建面向CLV升级的“数据感知-策略迭代”闭环是企业持续成长的关键所在。

关键词

客户全生命周期价值(CLV), 电子商务, 数据驱动营销, 精准营销

Study on Data-Driven Customer Lifetime Value Mining and Marketing Strategy Iteration in E-Commerce Enterprises

Yutai Zhang¹, Wei Chen^{1*}, Xintong Fu², Yaohui Sheng²

¹School of Management, Gansu Agricultural University, Lanzhou Gansu

²China United Network Communications Group Co., Ltd., Beijing

Received: December 15, 2025; accepted: December 25, 2025; published: December 31, 2025

Abstract

This study focuses on the e-commerce field and constructs a data-driven marketing strategy

*通讯作者。

文章引用: 张裕泰, 陈炜, 傅歆童, 盛耀辉. 数据驱动的电子商务企业客户全生命周期价值挖掘与营销策略迭代研究[J]. 电子商务评论, 2025, 14(12): 7242-7248. DOI: 10.12677/eci.2025.14124726

framework centered on Customer Lifetime Value (CLV). Through machine learning modeling, multi-dimensional data evaluation, and attribution analysis, the research systematically discusses the hierarchical measurement of customer value, key node data mining, precise strategy design, and closed-loop optimization mechanisms. The study shows that using behavior sequence-based latent customer identification, value-level automated journeys, and dynamic scenario strategies can significantly improve CLV performance and optimize marketing effectiveness. It is concluded that constructing a “data perception-strategy iteration” closed loop aimed at CLV upgrade is crucial for the sustainable growth of enterprises.

Keywords

Customer Lifetime Value (CLV), E-Commerce, Data-Driven Marketing, Precision Marketing

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

客户全生命周期价值(Customer Lifetime Value, CLV)是衡量客户长期经济贡献的核心指标,已成为市场营销与客户管理领域的重要研究主题。已有研究多从交易视角,根据购买频率、客单价和生命周期长度等因素构建 CLV 度量和预测模型,逐步引入行为数据和统计建模方法来加强对顾客未来价值前瞻性的评判。在客户关系管理(CRM)的研究领域,CLV 在客户层次划分和资源分配决策中得到了广泛应用。相关的研究成果指出,以价值为导向的客户管理策略可以有效地提高企业的市场营销效果和客户资产的质量。同时伴随着大数据和人工智能技术的进步,数据驱动营销的研究也不断深入,机器学习模型被应用于客户细分、购买预测等领域,推荐系统和营销自动化等,都显示出了明显的优越性。

但已有研究尚存在一些不足之处:CLV 的研究大多集中在静态或者阶段性预测方面,缺少对顾客生命周期中关键节点进行持续识别和动态响应;预测模型和营销策略缺乏联系,很难将 CLV 的结果系统性地转化成可以实施的营销决策;营销效果评估仍以短期转化指标为主,对营销活动对长期客户价值(CLTV 增量)的影响关注有限,难以支撑策略的持续优化。

针对上述不足,本文以电子商务场景为研究对象,围绕“如何将 CLV 的预测结果嵌入顾客生命周期管理,促进营销策略的迭代”这一核心问题,构建以 CLV 为中心的数据驱动营销闭环框架。通过集成交易数据、构建行为序列与预测模型、分层动态评估客户价值、设计关键生命周期节点的差异化营销策略与自动化旅程,同时以 CLV 增量为核心评价指标推进策略测试并不断优化。

本项研究的焦点主要集中在电子商务行业中客户全生命周期价值(CLTV)的数据驱动管理和精准营销策略的构建上,特别是对 CLV 的度量、预测和优化方面进行了深入分析。研究利用机器学习与数据挖掘相结合的方法,并结合电商行业独有的交易、行为数据以及生命周期阶段等特点系统性地建模。值得关注的是,虽然该研究给出了一个完整的框架,但是其适用性会受行业特点以及数据可获取性的制约,尤其对非传统电商模式或者尚未实现完全数字化的公司而言,可能会影响到研究结论的普适性。

本项研究主要关注中国市场中的 B2C (Business-to-Consumer)电子商务平台,特别是在大型促销活动和生命周期管理阶段,探讨如何通过精确的营销策略来提升 CLV 的表现。虽然涉及数据维度较广,但是主要集中在交易数据、客户行为数据和生命周期节点等方面进行分析,对一些复杂跨境电商或者 C2C

(Consumer-to-Consumer)模型而言,其结果是否适用可能还需要进一步检验。本研究有利于扩展 CLV 应用于电商营销的界限,并对数据驱动营销长期价值管理进行系统化的理论支撑。

2. 数据驱动的电子商务客户全生命周期价值内涵与度量模型构建

(一) 电商场景下客户全生命周期阶段的动态划分与数据特征

电商客户生命周期并不是一条传统线性路径,它是一个动态的过程,受到诸多因素的影响,可能随时被打断或者流通。精准划分需依赖多维度实时数据:在认知与考虑阶段,关键在于追踪用户的首次触点来源(如社交媒体广告)、初始浏览品类及页面停留时长,以快速构建基础兴趣画像[1]。进入获取和服务阶段则需要以转化路径分析为重点,通过会话回放和热力图来确定加购未付和结账流程繁杂的特定断点,而这正是体验优化的核心内容。对于留存与忠诚阶段,判定依据是用户的高频活跃度(如月度登录次数)、复购行为以及正向的互动反馈(如评价、分享),系统应能据此自动标记高价值客户。

(二) 集成交易、行为与预测的 CLV 多维度量化指标体系设计

电子商务客户的终身价值(CLV)已经不仅仅是简单的历史交易汇总,而是发展成了一个融合了交易、行为和预测的综合指标体系。基础交易的各个维度涵盖了平均订单价值(AOV)、购买的频次以及客户的平均生命周期,这些维度的计算公式可以被简化为“ $AOV \times \text{购置频次} \times \text{生命周期的平均值}$ ”。但仅仅依靠交易数据是有局限性的,需要融合深度行为数据才能洞悉价值动因。这涉及到用户的访问深度和频率(Visits)、页面的停留时间(Durations)以及如点击、购买、评论等核心操作(Actions),这些行为模式可以有效地展现出用户的参与度和兴趣深度。为了前瞻性地对未来价值进行评判,指标体系还需要引入预测性维度如根据 BG-NBD 模型预测出的未来购买量和根据 Gamma-Gamma 模型预测出的顾客未来交易均值等。在特征工程层面,本文首先对原始交易与行为数据进行清洗与缺失值处理,并以统一时间窗口(如 30 天、90 天)构建客户行为特征。连续型变量(例如访问频率、停留时长、客单价等)采用标准化处理以消除量纲影响,离散型行为变量(比如有没有加购、有没有考核)通过独热编码方式转化为模型可识别特征。根据生命周期特征,进一步构造衰减型指标来表征客户行为在时间上的动态特性,从而为之后的模型训练提供稳定的输入。

(三) 基于机器学习算法的电商客户价值分层与动态预测模型

面对庞大且高维的电商数据,常规的基于规则分层方法变得捉襟见肘。机器学习算法实现了复杂模式的自动数据学习,能够更加准确地实现客户价值的分层和动态预测。在分层方面,除了经典的 RFM(近期消费、频率、金额)模型,更先进的 RFMVDA 等扩展模型通过纳入访问次数、网络特有的指标,如停留时间和操作行为,能够为客户群体提供更为细致的分类,其准确性可以达到超过 92%。从预测的角度看,单一的预测模型经常会有误差,而集成学习(Ensemble Learning)技术正逐渐成为研究的前沿[2]。本研究使用了基于 Stacking 框架的集成学习方法,包括弹性网络(Elastic Net)和随机森林(Random Forest)、XGBoost 和支持向量机(SVM)作为主要的学习工具,它们被用来捕获数据中的线性、非线性特征以及高维度的特征空间模式;并以线性回归模型为元学习器将各个基础模型的输出结果加权融合以提高总体预测的稳定性和泛化能力。在对模型进行评估的过程中,本研究选择了均方根误差(RMSE)、平均绝对误差(MAE)和决定系数(R^2)作为核心的评价准则,目的是全面评估该模型在 CLV 预测任务中的误差程度和解释能力。其中 RMSE 描述了预测偏差总体范围;MAE 体现了平均预测误差; R^2 评价了模型对于顾客价值差异的解释度。为验证集成模型的有效性,本文将其预测结果与传统 CLV 模型(如 RFM 模型、BG-NBD/Gamma-Gamma 模型)以及单一机器学习模型进行对比。结果表明,与基准模型相比,Stacking 集成模型对 RMSE 和 MAE 指标都显示了较小的预测误差和对 R^2 指标的解释能力,表明了该集成学习方法对复杂电商数据环境预测性能较好。表 1 对比了三种不同的模型(RFM 模型、集成学习模型、BG-

NBD/Gamma-Gamma 模型), 并简单总结了它们的核心特点和性能评估。

Table 1. Comparison of customer segmentation and prediction models based on machine learning
表 1. 基于机器学习的客户分层与预测模型比较

模型类型	核心特点	性能评估
RFM 模型	基于最近购买、购买频率、购买金额进行客户分层	准确性较低，无法捕捉行为数据
集成学习(Stacking)	结合多个模型(Elastic Net, Random Forest 等)	RMSE、MAE 较低，R ² 值较高，预测能力强
BG-NBD/ Gamma-Gamma	适用于频繁购买场景，基于历史交易数据预测未来行为	能较好预测长期价值，但对行为变化反应迟缓

3. 电子商务客户全生命周期关键节点的数据挖掘与价值发现

(一) 基于用户行为序列的潜在客户识别与转化瓶颈挖掘

目前电商行业的核心难题，在于流量红利退去和获客成本高企，所以从大量用户行为数据准确发现高意向潜在客户和畅通转化路径显得尤为重要。在实际应用中，仅仅依靠点击率或者页面浏览量已显得力不从心，高级识别模型主要集中在用户行为序列和意图强度两个方面。例如通过分析用户在特定时间段内(如 30 分钟)对同一商品品类的连续深度浏览、对比商品详情页参数、反复查看用户评价与问答，以及在收藏夹或者购物车中加入物品的行为顺序，该系统可以有效地区分普通浏览者和高意向购买者。确定潜在客户只是首要环节，更为关键的在于诊断转化漏斗内存在的特定瓶颈。利用会话回放、点击热力图与转化漏斗分析工具，企业能够清晰定位流失环节：常见的瓶颈包括商品价格犹豫(具体表现在重复添加移出购物车的行为)、支付环节疑虑(当填写支付信息的网页逗留太久时，则放弃)、物流或售后担忧(经常看退换货政策，然后就走了)。

(二) 活跃客户交叉销售与向上销售的机会点数据识别

对于那些已经建立了购买关系的活跃客户，挖掘其终身价值(CLV)的关键是基于数据的精确推荐，从而推动交叉销售(Cross-selling)和向上销售(Up-selling)。机会点确定的深度取决于顾客历史交易数据和实时行为数据之间的相关分析，在客户的关联购买模式中，交叉销售的可能性往往是隐秘的：这是通过对“买 A 货的顾客同时买 B 货”的频繁交易项集进行分析得出的，或者使用协同过滤算法确定有类似购买偏好的顾客群体中其他共购商品能够有效地找到互补品或者关联品推荐机会[3]。比如一个顾客买专业摄影相机，他最有可能需要存储卡、相机包或者镜头清洁工具。往上卖是以提高客单价为核心，机会在顾客消费升级自然路径上。数据信号有，顾客重复浏览某个类别较高价格或者功能较多的物品；其历史购买记录显示出周期性升级换代趋势(如年年换性能较好的手机等)；或者顾客对已有购入商品给以中性评价说明有需要没有得到满足。

(三) 流失客户预警信号分析与挽回价值评估模型

客户流失即电商业务不断流失，构建以数据为基础的预警和评估体系成为止损的重点。流失预警信号多维度综合指标远远早于顾客完全停止采购。关键的前置行为信号包括：购买频率显著下降(如果由月买延长到季更)、客单价环比降低、登录 APP 或网站的频率骤减、不再点开营销推送和售后服务交互满意程度降低。更多的隐性信号则可能源于顾客接触点体验为负值，比如多次与客服接触没有得到解决或者物流差评等。在模型构建方面，本文以逻辑回归与生存分析模型作为流失预测的基准方法，并通过 AUC 值与准确率评价模型对高流失风险客户的识别能力，为后续挽回决策提供依据。电商客户生命周期关键节点典型数据信号与对应策略见表 2。

Table 2. Typical data signals and corresponding strategies at key nodes in the e-commerce customer lifecycle
表 2. 电商客户生命周期关键节点典型数据信号与对应策略

关键节点	核心数据信号类型	典型具体信号示例	数据驱动的策略方向
潜客转化	行为序列与意图信号	30 分钟内深度浏览同品类 > 3 件商品；对比参数/价格；查看评价后加购	个性化推送(如降价通知、同类推荐)；优化支付环节信任提示
活跃客户增值	交易关联与浏览行为信号	历史购买 A 后常买 B；近期频繁浏览高端型号或配件；客单价呈上升趋势	触发式关联推荐(“买了也买”)；适当时机推送升级款/配件套餐
流失预警与挽回	频率衰减与互动负向信号	购买/登录频率连续 2 周期下降 > 50%；不再打开营销邮件；最近一次服务评分低	触发客户关怀回访；根据流失风险分析与预测价值制定差异化挽回方案

4. 基于客户价值分层的电商精准营销策略设计与实施

(一) 面向不同价值层级客户的个性化触达与商品推荐策略

为应对电商领域普遍的“二八法则”，精准营销的核心在于依据价值分层(例如高价值、成长型、一般型、流失风险型等)实施差异化策略[4]。对于那些占比大约 20%但收入贡献超过 60%的高价值客户，策略的核心是维护专属关系和满足深度需求。首先是专属权益的供给，比如专属客服的指派、高等级会员的馈赠以及新产品优先购买权的供给等。另一种是开展高客单价连带推荐活动，根据他们以往“购买加浏览”的资料，以手工或者智能的方式推荐高端新品，限量套装或者跨境商品等。多采用高互动低打扰触达，比如用专属客服一对一微信交流，或者推送时突出“专属甄选”等。对占主要地位且具有较大潜力的成长型和一般型顾客而言，其核心目的在于提高购买频次和客单价并促进其向高价值层级发展。一种是通过自动化流程将加购不付款、浏览不下单行为作为开展短信或者 App Push 优惠券奖励。另一种是基于他们的浏览偏好在主页的“猜猜看，你们喜欢吗”单元中实现大范围的个性化商品推荐。

(二) 契合生命周期关键节点的自动化营销旅程设计与优化

自动化营销旅程对于提效和规模化个性化触达至关重要，它的设计需要紧扣顾客生命周期的重要节点。新客激活期的行程旨在迅速建立对第一次交易的信任。一是针对注册未购新客，在 24 小时内自动推送“新人礼包”组合(如果没有门槛券加上爆款的推荐)；二是新客第一单成交时，即时触发感谢信息和复购优惠预告引导新客关注会员体系。在存量客户的增长和成熟期以提高忠诚度和交叉销售为宗旨。一种是设计以行为为主的触发式关怀方式，如顾客购买母婴产品 1 个月之后会自动推送相关婴童服装或者辅食信息等。二是设置积分消耗和升级提醒行程，当顾客的积分快要到期或者接近会员升级的时候，会自动推送提示信息以刺激互动，客户流失预警期的目的在于有序介入和预防流失[5]。其一是对购买间隔时间显著加长的顾客，会自动推送他们曾经浏览过的品类上新信息或者独家优惠；二是当系统识别出高价值客户流失风险高时，自动生成任务工单，提示客户经理进行一对一人工干预，形成“自动化加人工”的混合挽回机制。

(三) 电商特定场景(大促、新品等)下的动态营销策略调整

在如 618、双 11 这样的大型促销活动和新产品上市的特殊场合中，传统的静态营销策略已经不再适用，因此需要动态地进行调整，以更好地应对大量的流量和激烈的市场竞争[6]。在大促期间，核心的战略方针是实施“分层预热，准确爆发”。预售期间，为高价值客户以及品牌会员预先推送专属预售链接、更多的大额优惠券以及优先购资格锁定核心销售；正式期将主会场链接、限时秒杀以及爆款清单等渠道轰炸式地推送到全量顾客特别是价格敏感型顾客手中，实现流量转化的最大化；大促后立即进入“复盘和挽留”阶段，向未成交的活跃访客推送返场优惠，向已购客户征集评价并预告下一波活动，延续热度。在新品上市场景下，策略核心是“梯度渗透，口碑引爆”[7]。一是上市初期邀请高价值客户和 KOC (关

键意见消费者)体验,采集第一波口碑,在商品详情页凸显;二是在推广期,通过内容营销(如短视频、直播)和精准广告,向历史购买过同类或互补品、近期有相关搜索行为的客户进行推送,强调新品卖点。表 3 总结了在大型促销活动和新品上市期间的动态营销策略,以及相应的实施案例。

Table 3. Dynamic marketing strategies during major promotions and new product launches
表 3. 大促和新品上市期间的动态营销策略

场景	核心策略	实施案例
大促期间	分层预热,精准爆发	高价值客户提前推送专属优惠链接,限时秒杀推广
大促后	复盘与挽留,激活未成交顾客	返场优惠推送,收集客户评价并预告下一波活动
新品上市	梯度渗透,口碑引爆	邀请 KOC 体验并收集口碑,精准广告推送新品卖点

5. 电商营销策略的数据化迭代评估与闭环优化机制

(一) 营销活动效果的多维度数据评估与归因分析模型

传统的单一指标评估(如总销售额)已无法满足精细化运营需求,必须建立涵盖效率、质量与长期影响的多维评估体系[8]。评价需要从四个层次进行:一是前端流量效率(CAC),其核心指标为获客成本(CTR)和转化率(CVR)等,以度量营销投放直接拉新和转化效能;二是交易质量和健康度问题,需要注意客单价(AOV)、新客占比、优惠券核销率和毛利率等,以防“赔本赚吆喝”现象的发生;三是对用户资产沉淀效果的影响,重点指标为事件导致的新增注册用户数、新增会员数和核心用户群活跃度的改变;四是长期价值影响,最关键的评估是观察活动带来的客户在其后 90 天或 180 天内的累计贡献价值(即 CLV 增量),判断营销是“透支”还是“滋养”了客户价值。为了实现准确的归因,我们需要结合“末次触点归因加多点归因的分析”的方法来构建模型。

(二) 以 CLV 提升为核心的营销策略快速测试与迭代流程

在流量成本高企的情况下,无论何种规模的营销策略,在促销之前都要先进行小规模快速检验,才能保证其价值的长期导向,而不是短期销量透支。流程核心是“假设驱动,小步快跑,验证价值”[9]。一是提出基于 CLV 提升的清晰假设,例如“向那些不活跃的用户推送特定种类的折扣券,可以在 30 天之内激活其中的 15%,并且在接下来的 90 天内,LTV 将覆盖所有的唤醒费用”;二是设计严谨的 A/B 测试(或 A/B/N 测试),将目标客群随机分为对照组(不采取动作)与一个或多个实验组(施加诸如券 A 和券 B 等不同的战略)。检验需要对单一变量进行控制并且保证样本量的统计显著性;三是评估标准必须超越短期转化率,核心分析实验组用户在未来特定周期(如 90 天)内的 CLV 变化、复购率及毛利率,并与对照组进行对比[10]。

(三) 数据驱动下电商营销策略体系的持续学习与优化闭环

建设可自我学习和动态优化的智能营销系统,是电商竞争高级形态。它取决于“数据感知-策略决策-动作实施-效果反馈”的整体优化闭环[11]。一是为了构建一个统一的客户数据平台(CDP)和实时特征库,系统需要对交易、行为、客户服务以及外部市场的数据进行实时整合;二是根据业务规则和机器学习模型对系统进行自动诊断,产生策略建议如自动识别高流失风险客户群、推荐最佳挽回渠道和权益等。利用营销自动化平台(MAP)将战略转变为个性化的触达行为,并在最合适的时间通过优化的渠道进行实施;三是实时捕捉全部触达效果数据返回到数据平台进行策略有效性评价、用户标签更新以及下次决策模型训练优化。比如,一个失败召回的推送数据就会让模型知道这类顾客对于这个渠道以及权益并不是很敏感,在下一个决策中就会降低这个战略的权重或者试用一个新的计划[12]。表 4 构建了一个电商营销活动的四维评估指标体系,它超越了单一的销售额或 ROI 考核。

Table 4. Example of multi-dimensional evaluation indicator system for e-commerce marketing activities
表 4. 电商营销活动多维度评估指标体系表示例

评估维度	核心评估指标	指标定义与计算方式
成本效益维度	客户获取成本(CAC)	营销活动总花费/活动带来的新增购买客户数
转化质量维度	新客占比	活动带来的首次购买客户数/活动总购买客户数
长期价值维度	90 天客户生命周期价值 (90dCLV)	活动新增客户在交易后 90 天内产生的总利润(收入 - 商品成本)
归因分析维度	助攻转化贡献值(基于多点归因)	通过归因模型(如时间衰减)计算各渠道在转化路径中的贡献价值比例

6. 结论

本研究所构建的 CLV 电子商务营销框架尽管在理论和实践上都有显著贡献，但是仍然有几个局限性。一是尽管采用了先进的机器学习算法和多维度的数据特征，本研究依赖的数据主要来源于交易与行为数据，忽视了外部环境因素(比如宏观经济、行业的变化)可能对客户行为的影响。今后研究可综合更多的外部因素改进 CLV 预测模型；二是模型主要基于静态数据与历史行为进行预测，未充分考虑客户生命周期中的突发事件或变化，如促销活动、外部冲击(如疫情等)可能带来的影响。因此，未来可以探讨如何通过动态数据建模应对这些变化，提高预测的灵活性与准确性；三是虽然该研究为营销策略设计及自动化流程提供了一个综合方法，但在具体实施过程中仍然可能会碰到数据隐私、技术执行及组织执行力方面的问题。未来研究可进一步探索如何将技术、管理和用户隐私保护三者有效融合到实际电商运营当中并加以权衡，促进数据驱动下的精准营销实践。今后研究应该进一步拓展数据来源、提高模型动态性和适应性、重视电商领域瞬息万变的市场环境对于 CLV 预测和营销策略的作用。

参考文献

- [1] Tan, M., Li, H., Wang, H. and Yin, P. (2025) Research on E-Commerce Platform's Instant Retail Strategy Considering Delivery Timeliness under Consumer Channel Preferences. *Asia Pacific Journal of Marketing and Logistics*, **37**, 3868-3887. <https://doi.org/10.1108/apjml-12-2024-1866>
- [2] 代彬, 闵诗尧. 跨境电商改革能够降低企业对大客户的依赖吗——基于跨境电子商务综合试验区的准自然实验[J]. 中南财经政法大学学报, 2025(4): 133-147.
- [3] 张鑫. 客户价值理念视域下电子商务企业高质量发展思考[J]. 商业 2.0, 2025(12): 7-9.
- [4] 梁婷婷, 李超宇. 浅析电子商务对企业管理的促进作用[J]. 商展经济, 2025(8): 181-184.
- [5] 殷孜. 基于小微企业的电子商务网站信息质量与客户忠诚度实证研究[J]. 中国科技投资, 2025(8): 55-57.
- [6] 田晓燕. 电子商务环境下企业物流与供应链管理创新研究[J]. 商展经济, 2024(14): 112-115.
- [7] 白云, 张玲玲, 赵晶晶. 电子商务环境、商业模式裂变与瞪羚企业涌现的互动机制[J]. 商业经济研究, 2025(23): 130-133.
- [8] 郑怡婷. 数字经济与电子商务融合对消费行为的影响研究[J]. 商场现代化, 2025(22): 31-33.
- [9] 胡留洲. 电子商务对未来市场营销方式的影响及对策[J]. 商场现代化, 2025(22): 54-56.
- [10] 肖耘, 许欢欢, 肖雅元, 等. 基于 CLV 偏好挖掘模型的数字社区用户偏好挖掘研究[J]. 农业图书情报学报, 2023, 35(2): 45-60.
- [11] 计虹, 王梦莹. 数据资产全生命周期分层管理方法与应用探讨[J]. 中国数字医学, 2023, 18(1): 1-6.
- [12] 闫坤伦. 基于 CLV/CLP 的保险客户全生命周期利润贡献预测方法研究[J]. 统计与管理, 2017(12): 81-83.