

融合多维交互特征的电商直播异常行为识别模型及风控策略研究

艾健雄, 高梓仪, 吴雨桐

南京林业大学经济管理学院, 江苏 南京

收稿日期: 2026年7月14日; 录用日期: 2026年7月28日; 发布日期: 2026年9月10日

摘要

针对电商直播场景下恶意刷单、虚假互动和恶意套取平台优惠等异常行为影响平台交易秩序与用户体验的问题, 本文构建了一种融合多维交互特征的电商直播异常行为识别模型。区别于传统主要依赖交易金额、消费频次和最近消费时间等静态交易特征的识别方法, 本文结合直播场景的实时互动特征与账号关联特征, 引入弹幕频率、停留时长、设备IP聚集度等变量, 形成面向电商直播场景的改进特征体系。针对风控场景正负样本极度不平衡的问题, 采用SMOTE算法进行过采样平衡处理, 并系统对比了逻辑回归、随机森林与XGBoost模型在分类任务中的性能。实验表明, 结合SMOTE处理的XGBoost模型异常识别效果最优, F1-score达0.976, AUC接近1.0。进一步通过SHAP可解释性分析发现, 弹幕频率和设备IP聚集度对模型预测结果的贡献较高, 说明在电商直播异常行为识别中, 交互特征和网络关联特征相较于单一交易特征具有更强的判别作用。基于上述结果, 本文进一步提出实时流计算监测、账号关系图谱关联分析和分级风控处置策略, 为电商直播平台异常行为识别与风险控制提供参考。

关键词

电商直播, 异常行为识别, 机器学习, XGBoost模型, 风险控制

Research on an E-Commerce Live Streaming Anomaly Detection Model and Risk Control Strategy Incorporating Multi-Dimensional Interaction Features

Jianxiong Ai, Ziyi Gao, Yutong Wu

School of Economics and Management, Nanjing Forestry University, Nanjing Jiangsu

Received: July 14, 2026; accepted: July 28, 2026; published: September 10, 2026

文章引用: 艾健雄, 高梓仪, 吴雨桐. 融合多维交互特征的电商直播异常行为识别模型及风控策略研究[J]. 电子商务评论, 2026, 15(9): 322-331. DOI: 10.12677/ec.2026.1591002

Abstract

To address the issues of abnormal behaviors such as malicious click fraud, fake interactions, and malicious exploitation of platform discounts in e-commerce live streaming scenarios, which disrupt transaction order and user experience, this paper constructs an e-commerce live streaming abnormal behavior recognition model integrating multi-dimensional interaction features. Unlike traditional methods primarily relying on static transaction features like transaction amount, consumption frequency, and recent consumption time, this study combines real-time interaction features of live streaming scenarios with account association features, introducing variables such as danmu frequency, dwell time, and device IP clustering degree to form an improved feature system tailored for e-commerce live streaming. To tackle the extreme imbalance of positive and negative samples in risk control scenarios, the SMOTE algorithm is employed for oversampling and balancing. Systematic comparisons were conducted among logistic regression, random forest, and XGBoost models in classification tasks. Experiments demonstrate that the XGBoost model with SMOTE processing achieves the best abnormal recognition performance, with an F1-score of 0.976 and an AUC close to 1.0. Further SHAP interpretability analysis reveals that danmu frequency and device IP clustering degree contribute significantly to model prediction results, indicating that interaction features and network association features play a stronger discriminative role than single transaction features in e-commerce live streaming abnormal behavior recognition. Based on these findings, this paper further proposes real-time streaming computation monitoring, account relationship graph association analysis, and hierarchical risk control strategies, providing reference for abnormal behavior identification and risk management in e-commerce live streaming platforms.

Keywords

E-Commerce Live Streaming, Abnormal Behavior Recognition, Machine Learning, XGBoost Model, Risk Control

Copyright © 2026 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

随着我国数字经济的蓬勃发展,2024年,网络直播用户规模达8.33亿人¹。电商直播凭借“实时互动”与“沉浸体验”成为推动内需升级的重要力量,其对消费者购物行为与商业生态的深远影响已得到学界的广泛共识[1]。然而,电商直播具有访问并发高、互动频率高、交易转化链路短等特点,也使恶意刷单、虚假互动、恶意套取平台优惠等异常行为更容易在短时间内集中发生。面对日益复杂的在线欺诈手段,单一的异常检测方法难以满足平台治理需求,风险控制正逐渐由事后处置向全链路、系统化治理演进[2]。传统依靠静态交易数据的异常检测在直播场景中暴露出一定局限性,如何在海量动态交互数据中精准识别异常行为,已成为电商平台风险控制中需要重点解决的问题。本研究通过融合时序交互特征与社交网络特征,构建高精度的机器学习分类模型,以期为电商直播平台的动态风险管控提供理论依据与技术支持。

¹https://news.cyol.com/gb/articles/2025-06/26/content_4wvyK7hWZP.html

2. 文献综述

2.1. 用户异常行为与互动特征研究

近年来,随着电商直播模式的快速发展,国内外学者围绕直播场景下的用户行为、购买意愿和互动机制进行了较多研究。已有研究多从消费者心理、主播特征、互动氛围和营销刺激等角度解释用户购买行为。例如,漆亚林、杨婧童[3]基于 S-O-R 理论分析了直播环境下情绪感知对用户购买行为的影响;袁海霞、黄丽雯[4]认为,直播间互动模式能够降低消费者感知不确定性,从而提升购买意愿;魏剑锋等[5]、韩召等[6]和刘江[7]分别从主播特性、代言类型和语言风格等方面验证了直播主体特征对消费者行为的影响。上述研究说明,电商直播中的互动行为不仅是用户参与的重要表现,也是影响消费决策的重要因素。在用户行为量化方面,传统研究较多采用 RFM 模型从最近一次消费、消费频次和消费金额等维度构建用户画像,也有研究将 RFM 模型与聚类、集成学习等方法结合,用于消费模式预测和用户价值识别[8]。然而,现有研究更多关注正常用户的购买转化和价值挖掘,对异常用户在直播间中的高频互动、短时停留、账号协同等行为特征关注不足。尤其是在电商直播高并发、强互动和即时交易的场景下,单纯依赖交易特征难以及时识别虚假互动、恶意刷单和异常套利行为。因此,有必要将直播互动特征和账号关联特征纳入异常行为识别框架。

2.2. 基于机器学习的异常检测算法

异常检测技术已广泛应用于金融反欺诈、网络安全和平台治理等领域。已有研究表明,传统规则引擎虽然具有解释性强、部署简单等优点,但在面对高维、非线性和动态变化的数据环境时,容易出现规则滞后和泛化能力不足的问题。Hilal 等[9]认为,在金融欺诈检测任务中,机器学习方法能够更有效地处理大规模非结构化数据。由于真实风控场景中正常样本与异常样本数量往往严重不平衡,研究者提出了多种样本再平衡方法。Zhao 和 Bai [10]在财务舞弊预测中使用 SMOTE 算法,有效缓解了少数类样本被忽略的问题;Piao 等[11]提出基于加权 AdaBoost-SVM 的再平衡方法,提高了不平衡数据上的分类稳定性。在模型构建方面,集成学习模型因具有较强的非线性拟合能力和泛化能力,被广泛应用于异常检测任务。Ikerman 等[12]比较了随机森林和 XGBoost 在信用卡欺诈检测中的表现,并结合可解释人工智能方法分析模型输出,提升了机器学习模型在风控场景中的透明度。总体来看,SMOTE、XGBoost 和 SHAP 等方法已经在异常检测领域形成了较成熟的技术基础,为本文在直播电商场景中的模型构建提供了方法参考。

2.3. 文献述评与本文研究贡献

综上,现有研究已经在两个方面形成了较为成熟的基础:一是电商直播用户行为研究较充分地揭示了互动、主播特征和消费心理对购买行为的影响;二是机器学习、样本不平衡处理和模型可解释性方法已在金融反欺诈等异常检测领域得到较多应用。但是,现有研究仍存在一定不足:第一,直播电商异常行为识别研究相对较少,已有成果更多关注用户购买意愿和营销效果,对异常互动、虚假交易和账号协同行为的识别关注不足;第二,传统异常检测方法多依赖交易金额、购买频次等静态交易特征,难以充分反映直播场景中的实时互动信号;第三,虽然 SMOTE、XGBoost 和 SHAP 等技术组件本身已较为成熟,但将其组合应用于电商直播异常行为识别场景,并进一步比较交易特征、交互特征和网络关联特征的重要性,仍具有一定研究价值。基于此,本文的主要贡献体现在以下三个方面:第一,面向电商直播场景构建融合交易特征、互动特征和网络关联特征的异常行为识别框架,弥补传统 RFM 指标对直播实时互动信息刻画不足的问题;第二,采用 SMOTE 方法缓解异常样本占比较低导致的类别不平衡问题,并

比较逻辑回归、随机森林和 XGBoost 模型的识别效果；第三，利用 SHAP 方法解释模型输出结果，发现弹幕频率和设备 IP 聚集度等交互与网络特征相较于单一交易特征具有更强的预测贡献，并据此提出更具针对性的实时监测和图谱关联风控策略。

3. 数据处理与异常特征工程

3.1. 数据来源与预处理

3.1.1. 数据集描述

受限于电商平台直播平台核心风控数据的商业机密性，本研究创造性地采用“基准真实标签+特征仿生合成”的方式来构建脱敏化训练集，该数据集以阿里天池公开发布的 ICDM 2022 大规模风控数据库为基础搭建底层图谱结构，再根据风险标记信息生成电商直播领域的专属特征库，总样本量达到 2 万条，其中正常用户占比高达 91%，异常/潜在违规行为样本分别占总样本量的 8.7%约 1885 例，整体分布极不平衡，约为 10:1，精准对应了互联网环境下典型的风险特征与发展态势。

3.1.2. 数据清洗与缺失值处理

在数据预处理阶段，本文剔除了关键特征严重缺失或存在明显逻辑谬误(如停留时长为负数、消费金额极大且无行为轨迹)的无效数据。随后，利用标准化方法对数值型特征进行了无量纲化处理，以消除不同量纲对后续机器学习模型梯度下降带来的负面影响，确保模型的收敛速度与稳定性。

3.2. 基于改进 RFM 模型的特征构建

3.2.1. 传统 RFM 指标的局限性

传统的 RFM 模型主要从最近一次消费时间、消费频次和消费金额三个维度刻画用户价值，在静态电商平台中具有较强的解释力和应用价值。然而，电商直播场景具有实时互动强、交易决策快和账号行为集中等特点，部分异常账号可能通过小额交易、快速退款或集中互动等方式规避单一交易规则。因此，仅依靠 RFM 指标容易忽视直播过程中的动态行为信号，难以全面刻画异常用户的行为特征。

3.2.2. 引入直播互动维度(Interaction)

针对上述痛点，本文在 RFM 基础上引入了直播互动维度。具体包括：

弹幕频率(danmaku_freq)：正常用户弹幕发送通常具有较强的随机性和内容差异性，而异常账号可能由自动化脚本控制，在短时间内呈现弹幕发送频率偏高、发送间隔规律性较强等特征。

停留时长(stay_duration)：真实消费者的观看时长通常与其兴趣、商品吸引力和主播互动效果相关，而部分异常账号可能在完成点赞、评论或优惠领取等指定行为后迅速退出直播间，表现出停留时间较短的特征。

3.2.3. 引入社交网络维度(Network)

异常账号往往并非孤立存在，而是可能呈现多账号共用设备、共用网络环境或集中登录等关联特征。基于此，本文选取设备 IP 聚集度(ip_cluster_deg)作为网络关联维度的核心指标，用于衡量同一 IP 地址、设备环境或终端标识下关联账号的数量规模。当某一网络环境下短时间内出现大量账号集中进入直播间、发送相似互动内容或执行相似交易行为时，该指标能够反映潜在的账号协同行为风险。

3.3. 异常行为画像分析

3.3.1. 正常用户与异常用户的行为分布差异

通过对提取特征的探索性数据分析(EDA)发现，异常用户在消费金额(M)上通常偏低，但在互动频率

与聚集度上极高。这种“低客单价、高频次、高协同”的特征，构成了典型的黑产群体行为画像。

3.3.2. 特征相关性分析

如图 1 所示,本文通过计算各特征间的皮尔逊相关系数(Pearson Correlation Coefficient)绘制了热力图。由图可知,弹幕频率与设备 IP 聚集度之间存在一定的正相关性,这印证了“群控软件批量发弹幕”的业务假设。各特征与风险标签之间均表现出不同程度的相关性,证明了本文改进特征工程的有效性,为后续模型的训练提供了坚实的数据底座。




Figure 1. Improved RFM model multidimensional feature correlation heatmap
图 1. 改进 RFM 模型多维特征相关性热力图

4. 异常识别模型构建与实验分析

4.1. 实验设计

4.1.1. 数据集划分

为客观评估模型的泛化能力,避免过拟合,本文按照 7:3 的比例对构建好的数据集进行了分层抽样划分(Stratified Sampling)。其中,70%的数据作为训练集用于模型学习,剩余 30%作为测试集用于独立评估模型性能。

4.1.2. 评价指标选取

针对异常检测这一典型的二分类任务,且样本极度不平衡,单一的准确率(Accuracy)极易产生误导(即将所有样本预测为正常即可获得 90%以上的准确率)。因此,本文综合选取了精确率(Precision)、召回率(Recall)、F1-score 以及 AUC 值(ROC 曲线下面积)作为核心评价指标。

4.2. 模型训练与优化

4.2.1. 针对极端类别不平衡的 SMOTE 过采样处理

在电商风控的真实数据分布中,正常用户与黑灰产异常账号存在严重的类别不平衡。在模型训练前,本文统计训练集发现,正常样本达 12,680 条,而异常样本仅 1320 条,比例接近 10:1。若直接使用原始数据训练,机器学习模型会陷入“多数类陷阱”,导致对异常行为的召回率极低。为此,本文在送入分类器前,实际调用了 SMOTE (合成少数类过采样技术)算法对训练集进行处理。SMOTE 通过在少数类样本的 K 近邻间进行线性插值,生成了 11,360 条合成异常样本。处理后,训练集正负样本分布达到绝对平衡(12,680:12,680)。后续逻辑回归、随机森林与 XGBoost 基模型的迭代训练与交叉验证,均是在此平衡后的训练集上完成的,这从根本上保障了模型决策边界的合理性。

4.2.2. 基模型选择与对比

本文选取了三种极具代表性的机器学习算法作为基模型展开横向对比测试:线性分类器代表逻辑回归(Logistic Regression)、Bagging 算法代表随机森林(Random Forest)以及 Boosting 算法代表 XGBoost。测试结果如表 1 所示:

Table 1. Comparison of evaluation results of three machine learning models on the test set
表 1. 三种机器学习模型在测试集上的评估结果对比

Model	Accuracy	Precision	Recall	F1-score	AUC
Logistic Regression	0.988667	0.910744	0.975221	0.941880	0.998653
Random Forest	0.995333	0.973545	0.976991	0.975265	0.999763
XGBoost	0.995500	0.975265	0.976991	0.976127	0.999554

从表 1 可以看出,虽然逻辑回归的准确率达到 0.988,但其精确率相对较低(0.910),这表明线性模型在处理复杂的非线性异常特征时,容易将部分正常用户误判为异常用户,即假正例数量相对较高。而基于决策树的集成模型表现出较强的鲁棒性,特别是 XGBoost,其 F1-score 达到 0.976, AUC 值接近 1.0,成为本研究实验中的最优模型。

4.2.3. 基于网格搜索的模型超参数调优

为使 XGBoost 模型在当前直播数据集上达到最优拟合状态,本文引入了网格搜索交叉验证(GridSearchCV)进行超参数调优。对于树模型而言,过于复杂的树结构会导致过拟合,而过于简单的树则会欠拟合。本文重点对以下核心超参数进行了搜索:

n_estimators (基学习器数量): 搜索区间设定为[100, 200, 300, 500]。

max_depth (树的最大深度): 搜索区间设定为[3, 5, 7, 9]。限制树深可有效防止模型对训练集中的少数黑产样本进行过度记忆。

learning_rate (学习率): 搜索区间设定为 [0.01, 0.05, 0.1, 0.2]。

经过 5 折交叉验证(5-fold Cross Validation),模型在各项参数组合中不断迭代验证误差。最终,网格搜索输出的最优参数组合为: n_estimators = 300, max_depth = 5, learning_rate = 0.1。该参数组合在保证模型强悍分类性能的同时,最大限度地控制了运算开销。

4.3. 实验结果分析

4.3.1. 混淆矩阵分析

对比通过图 2 的混淆矩阵对比可知, XGBoost 模型在左下角(假正例,即误将正常用户判定为异常)和

右上角(假负例,即漏报的真实异常用户)的数值均低于传统逻辑回归模型。这说明在电商直播场景中,集成算法能够更好地兼顾异常样本召回率与正常样本识别准确性。




Figure 2. Confusion matrix of three models

图 2. 三种模型的混淆矩阵

4.3.2. ROC 曲线与 PR 曲线对比

分析图 3 直观展示了三种模型在不同阈值下的表现。ROC 曲线越靠近左上角,模型性能越优;在应对不平衡数据时,PR (Precision-Recall)曲线的高低更能反映模型对少数类的识别能力。两条曲线均显示出 XGBoost 与随机森林在特征拟合上的压倒性优势。




Figure 3. Comparison of ROC curve and PR curve of the model

图 3. 模型的 ROC 曲线与 PR 曲线对比

4.3.3. 特征重要性排序(SHAP 值分析)

为了降低机器学习模型的“黑盒”特征,增强模型的可解释性,本文采用 SHAP (SHapley Additive exPlanations)值对 XGBoost 模型进行了深入剖析。由图 4 可知,对模型预测贡献度排名前两位的特征分别是弹幕频率(danmaku_freq)与设备 IP 聚集度(ip_cluster_deg)。这一结果说明,在电商直播场景下,传统交易指标可能被部分异常账号通过小额交易、低价商品或短周期交易行为弱化其识别效果;而由自动化脚本或协同账号产生的高频互动特征与网络关联特征,是识别直播异常行为的重要判别依据。

5. 基于机器学习结果的风险控制策略设计

根据前文 SHAP 特征重要性分析结果(见图 4),弹幕频率与设备 IP 聚集度是影响模型判断结果的重要特征。因此,平台风控策略不应仅依赖交易金额和下单频次等静态指标,而应结合直播互动过程中的




Figure 4. SHAP feature importance analysis of XGBoost model
图 4. 基于 XGBoost 模型的 SHAP 特征重要性分析

实时行为信号和账号关联关系，形成“实时监测 - 风险评分 - 分级处置 - 模型回流”的闭环机制。

5.1. 针对高频弹幕的实时流计算监测机制

针对弹幕频率较高、停留时长较短等异常互动特征，平台可在直播过程中引入实时流计算机制，对用户互动行为进行连续监测。具体而言，可基于 Apache Flink、Spark Streaming 等流计算框架，以用户账号、设备标识或会话 ID 为统计对象，设置短周期滑动窗口，对单位时间内的弹幕数量、重复内容比例、互动间隔和停留时长进行实时聚合。在窗口参数设置上，可采用“短窗口识别突发行为、长窗口判断持续风险”的方式。例如，将 10 秒作为短滑动窗口，滑动步长设置为 2 秒，用于捕捉短时间内的集中刷屏行为；同时设置 60 秒滚动窗口，用于判断用户是否持续保持异常高频互动。阈值设定不宜采用固定经验值，而应结合训练集和验证集的统计分布确定。例如，可将正常用户弹幕频率的 95% 分位数作为初始预警阈值，将 99% 分位数作为高风险阈值；同时结合 XGBoost 输出的异常概率进行综合判断。当某用户在连续两个以上窗口中弹幕频率超过高风险阈值，且模型输出异常概率高于 0.8 时，可判定为高风险互动行为。在处置方式上，应采用分级干预策略，避免对正常用户造成过度影响。对于低风险用户，可进行验证码验证、互动频率限制或提示性提醒；对于中风险用户，可降低其互动内容展示权重，限制重复弹幕发送频率；对于高风险用户，可将其互动内容转入人工复核或暂时限制直播间互动权限。通过这种方式，既能够减少自动化脚本对直播间互动秩序的干扰，也能够降低正常用户被误判的可能性。

5.2. 针对高 IP 聚集度的账号关系图谱关联分析

针对设备 IP 聚集度较高所反映的账号关联风险，平台可构建账号关系图谱，对异常账号群体进行关联识别。图谱中的节点可包括用户账号、设备指纹、IP 地址、手机号、支付账户、收货地址、直播间会话等；边则表示不同节点之间的关联关系，例如同一设备登录多个账号、多个账号共用同一 IP、多个账号使用相同收货地址、多个账号在相近时间进入同一直播间并执行相似互动行为等。通过节点和边的定义，可以将单一账号风险识别扩展为账号群体风险识别。在图谱计算过程中，可进一步引入边权重和时间衰减机制。对于同一设备指纹、同一支付账户等稳定关联关系，可赋予较高权重；对于同一 IP 地址这类可能受网络环境影响的关联关系，则应结合时间、地理位置、登录频率和行为相似度进行综合判断，以避免仅凭 IP 相同就直接判定账号异常。需要注意的是，部分异常账号可能通过代理 IP、动态拨号 IP 或频繁切换网络环境来削弱 IP 聚集度特征的识别效果。因此，图谱关联分析不能只依赖单一 IP 指标，

而应融合设备指纹、浏览器指纹、登录时间间隔、地理位置跳变、弹幕文本相似度、进入直播间时间同步性等多类信号。当多个账号虽然 IP 不完全相同,但在短时间内呈现相似的进入路径、相似的互动内容和高度一致的交易行为时,仍可通过图谱中的多跳关联识别出潜在异常账号群体。在处置层面,平台可根据图谱风险评分进行差异化处理。对于仅存在弱关联的账号,可纳入观察名单并提高后续行为监测频率;对于存在多重强关联且模型风险评分较高的账号,可触发二次验证、优惠领取限制、订单复核或人工审核;对于确认存在组织化异常行为的账号群体,可进行批量限制、风险标签回流和模型增量更新。通过账号关系图谱与机器学习模型的结合,可以提升平台对协同异常行为的识别能力和处置效率。

5.3. 风控策略闭环与模型更新机制

为保证风控策略的持续有效性,平台还应建立模型结果回流机制。实时监测和图谱分析产生的风险标签、人工审核结果、用户申诉结果和最终处置结果,应定期回流至特征库和训练样本库中。一方面,可用于修正模型对正常用户和异常用户的边界判断;另一方面,也可用于更新弹幕频率阈值、IP 聚集度阈值和图谱边权重。通过“模型识别-策略处置-结果反馈-模型更新”的闭环机制,平台能够适应异常行为模式的变化,提升电商直播场景下风险控制的稳定性和可解释性[13]。

6. 结论与展望

本文针对电商直播场景下恶意刷单、虚假互动和异常套利等行为识别问题,在传统交易特征基础上融合弹幕频率、停留时长和设备 IP 聚集度等交互与网络关联特征,构建了基于 SMOTE 过采样和 XGBoost 算法的异常行为识别模型。研究结果表明:第一,传统静态交易指标在直播场景中的解释能力存在一定局限,而弹幕频率和设备 IP 聚集度在 SHAP 归因分析中表现出较高的预测贡献,说明交互特征与网络关联特征是刻画直播异常行为的重要依据。第二,在正负样本比例不均衡的情况下,SMOTE 与 XGBoost 结合能够有效提升异常样本识别能力,模型 F1-score 达到 0.976,能够较好兼顾异常行为召回率与正常用户识别准确性。第三,基于模型解释结果提出的实时流计算监测、账号关系图谱关联分析和分级处置机制,能够为电商直播平台异常行为治理提供具有可操作性的参考。

尽管本研究取得了较好的识别效果,但仍存在一定局限性。受真实平台风控数据获取限制,本文采用脱敏化数据和特征构建方式进行实验,数据规模和特征维度仍有进一步拓展空间。未来研究可进一步引入弹幕文本语义、用户观看路径、直播间商品转化链路和多模态内容特征,并结合在线学习方法持续更新模型参数,以提升异常行为识别模型在真实直播平台中的适应性和稳定性。同时,平台风险控制还需紧密契合我国直播电商政策的优化导向[14],并在多主体协同共治框架下推动网络直播带货法律治理体系的完善[15]。

参考文献

- [1] Purboyo, P., Said, L.R., Firdaus, M.R. and Mayvita, P.A. (2025) A Systematic Literature Review on Live-Streaming Commerce: Trends, Consumer Behavior, and Business Implications. *Access Journal—Access to Science, Business, Innovation in the Digital Economy*, 6, 437-451. [https://doi.org/10.46656/access.2025.6.2\(11\)](https://doi.org/10.46656/access.2025.6.2(11))
- [2] Vanini, P., Rossi, S., Zvizdic, E. and Domenig, T. (2023) Online Payment Fraud: From Anomaly Detection to Risk Management. *Financial Innovation*, 9, Article No. 66. <https://doi.org/10.1186/s40854-023-00470-w>
- [3] 漆亚林, 杨婧童. S-O-R 理论视域下情绪、感知对电商直播用户购买行为的中介效应研究[J]. 新闻界, 2024(8): 55-65.
- [4] 袁海霞, 黄丽雯. 电商直播互动模式对消费者购买意愿的影响研究[J]. 哈尔滨商业大学学报(社会科学版), 2022(6): 19-30.
- [5] 魏剑锋, 李孟娜, 刘保平. 电商直播中主播特性对消费者冲动购买意愿的影响[J]. 中国流通经济, 2022, 36(4): 32-42.

-
- [6] 韩召, 杜刚, 熊爱华, 等. 明星代言还是主播“场外代言”?——两种代言类型对购买意愿的影响机制研究[J]. 外国经济与管理, 2022, 44(3): 53-68.
- [7] 刘江. 电商主播语言风格对消费者冲动性购买意愿的影响——基于心流体验的中介和电子口碑的调节作用[J]. 商业经济研究, 2025(14): 67-70.
- [8] Zhao, Y. (2025) RK-W-Stacking: A Hybrid Model Combining Entropy-Weighted RFM-K-Means Clustering and Weighted Stacking Ensemble for User Consumption Prediction. *Informatica*, **49**, 107-118.
<https://doi.org/10.31449/inf.v49i32.9086>
- [9] Hilal, W., Gadsden, S.A. and Yawney, J. (2022) Financial Fraud: A Review of Anomaly Detection Techniques and Recent Advances. *Expert Systems with Applications*, **193**, Article ID: 116429.
<https://doi.org/10.1016/j.eswa.2021.116429>
- [10] Zhao, Z. and Bai, T. (2022) Financial Fraud Detection and Prediction in Listed Companies Using SMOTE and Machine Learning Algorithms. *Entropy*, **24**, Article 1157. <https://doi.org/10.3390/e24081157>
- [11] Piao, C., Wang, N. and Yuan, C. (2023) Rebalance Weights Adaboost-SVM Model for Imbalanced Data. *Computational Intelligence and Neuroscience*, **2023**, Article ID: 4860536. <https://doi.org/10.1155/2023/4860536>
- [12] Ikermane, M., Mohy-Eddine, M. and Rachidi, Y. (2025) Credit Card Fraud Detection: Comparing Random Forest and Xgboost Models with Explainable AI Interpretations. In: Aboudrar, I., Ilahi Bakhsh, F., Nayyar, A. and Ouachtouk, I., Eds., *Innovative Technologies on Electrical Power Systems for Smart Cities Infrastructure*, Springer, 126-135.
https://doi.org/10.1007/978-3-031-86705-7_12
- [13] 吕鹏, 周旅军, 范晓光. 平台治理场域与社会学参与[J]. 社会学研究, 2022, 37(3): 68-91, 227-228.
- [14] 邱科达, 宋姗姗, 张李义. 我国直播电商政策量化分析与优化建议[J]. 当代经济管理, 2024, 46(4): 24-36.
- [15] 丁国峰. 协同共治视角下网络直播带货法律治理体系的构建[J]. 学术论坛, 2024, 47(2): 18-31.