

电商运营数据异常识别技术研究

田李荣

贵州大学数学与统计学院, 贵州 贵阳

收稿日期: 2025年9月3日; 录用日期: 2025年9月19日; 发布日期: 2025年10月16日

摘要

在电商经济精细化运营阶段, 运营数据是平台优化决策的核心资产, 但刷单炒信、库存超卖、系统故障等数据异常频发, 每年导致商家因异常销量损失数百亿元。这类异常不仅是技术问题, 更会扭曲市场信号、推高交易成本、损害消费福利, 给电商生态带来系统性经济风险。传统异常识别方法有明显局限: 或依赖固定统计假设, 难适配电商数据特性, 漏检率高; 或存在黑箱问题, 商家申诉率高, 难支撑风险防控。本研究结合电商经济规律, 构建“动态波动分析 + 滑动窗口 + 多指标联动”的识别技术, 适配周期波动、贴合场景需求、精准定位异常。经1000天模拟数据验证, 该技术准确率达0.82, 召回率达0.88, F1值为0.75, 正常样本误判率18.00%, 异常样本漏检率12.00%, 经济损失降低率达41.55%, 能识别促销期异常。其可降漏检率减损失、缩排查耗时降成本、净化数据优化资源配置, 助力电商良性循环。未来结合真实数据与理论优化, 可进一步提升风险防控能力。

关键词

电商运营数据, 异常识别, 经济风险防控, 电商经济, 交易成本

Research on Anomaly Detection Technology for E-Commerce Operational Data

Lirong Tian

School of Mathematics and Statistics, Guizhou University, Guiyang Guizhou

Received: September 3, 2025; accepted: September 19, 2025; published: October 16, 2025

Abstract

In the stage of refined operation of the e-commerce economy, operational data serves as the core asset for platforms to optimize decision-making. However, frequent data anomalies such as fake transactions (brush sales), overstock shortages, and system failures cause merchants to suffer losses of tens of billions of yuan annually due to abnormal sales volumes. Such anomalies are not merely technical

issues; they further distort market signals, drive up transaction costs, impair consumer welfare, and pose systemic economic risks to the e-commerce ecosystem. Traditional anomaly identification methods have obvious limitations: some rely on fixed statistical assumptions, making it difficult to adapt to the characteristics of e-commerce data and resulting in high missed detection rates; others suffer from the “black box” problem, leading to high merchant appeal rates and failing to provide effective support for risk prevention and control. Combining the economic laws of e-commerce, this study constructs an identification technology integrating “dynamic fluctuation analysis + sliding window + multi-indicator linkage”. This technology adapts to periodic fluctuations, aligns with scenario-specific needs, and accurately locates anomalies. Verified by 1,000 days of simulated data, the technology achieves an accuracy of 0.82, a recall rate of 0.88, an F1-score of 0.75, a false positive rate of 18.00% for normal samples, a missed detection rate of 12.00% for abnormal samples, and an economic loss reduction rate of 41.55%, enabling the identification of anomalies during promotion periods. Practically, it can reduce missed detection rates and losses, shorten troubleshooting time to cut costs, and purify data to optimize resource allocation, thereby facilitating the healthy circulation of e-commerce. In the future, by integrating real-world data and theoretical optimization, its risk prevention and control capabilities can be further enhanced.

Keywords

E-Commerce Operational Data, Anomaly Detection, Economic Risk Prevention and Control, E-Commerce Economy, Transaction Cost

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

1.1. 研究背景

据《中国新电商发展报告 2024》显示，2023 年全国网上零售总额达 15.42 万亿元，同比增长 11%，电商在国民消费中的支柱作用愈发凸显[1]。运营数据已成为打通“供给 - 需求”链路的核心枢纽，但数据异常对电商经济的侵蚀正不断加剧，其危害本质是对市场运行效率的干扰与交易成本的推高。

人为操作的数据异常催生虚假交易，导致市场资源错配与营销成本虚高[2]；业务波动引发的异常降低用户信任度，损害品牌长期价值；系统故障导致的异常则直接放大订单履约与供应链决策损失。同时，虚假数据扭曲市场信号，引发“劣币逐良币”柠檬市场效应[3]，异常核查与维权成本进一步推高交易摩擦，制约电商经济良性发展。

现有异常识别方法存在明显局限，传统固定阈值未考虑数据时变性，难以适配促销期与平稳期的差异[4]；部分技术虽能处理复杂数据，但“黑箱化”特性导致异常原因无法追溯，商家难以针对性止损。而直播电商、即时零售等新业态的兴起，更对异常识别的实时性与多维度适配性提出更高要求。

1.2. 研究现状

异常检测技术是电商运营风险防控的核心支撑，当前研究主要围绕异常交易识别、风险评估及异常客户挖掘三大方向展开，相关技术在应对电商数据尖峰厚尾、周期依赖等特性上不断优化，但仍存在实践适配性短板。

在电商异常交易风险评估领域，传统方法多聚焦单一维度风险映射，忽略交易、平台、用户三维评

估因素的协同作用[5]，导致评估精度受限。王颖等人[6]中提出改进方案，基于大数据构建多层次风险评估指标体系，通过量化交易金额波动、平台合规度、用户历史信誉等核心指标计算风险度，最终结合三维评估因素完成风险判定，经仿真验证，该方法较传统模糊数值计算法，有效的完成电商异常交易中的风险评估，降低交易风险给用户造成的损失。

异常客户检测是电商精细化运营与风险防控的重要环节，现有研究多通过算法优化与特征工程提升检测效率。杜岩虎[7]中以 B 网络搜索公司为实证对象，采用基于距离的异常检测算法，从客户过去价值、当前价值、潜在价值等维度构建 15 项初始指标，经因子分析筛选出“消费频次波动”“推广方案响应度”等 6 项核心指标，最终识别出 2 个异常客户；同时对比拉依达准则判定结果，验证了基于距离的算法在非正态分布数据场景下的优越性，其提出的“指标筛选 - 算法验证 - 原因追溯”异常客户检测流程，为电商客户关系管理中的异常识别提供了实践范式。

在异常检测算法创新方面，针对传统方法处理高维、非结构化电商数据的局限性，Li 等人[8]中提出基于变分自编码器(VAE)的检测方法，通过学习电商交易数据的潜在分布特征，结合自适应阈值调整机制与轻量级分类网络，实现对异常交易的精准识别；实验表明，VAE 方法在精度、召回率、F1 评分和 ROC-AUC 方面表现出色，特别是在复杂的电子商务场景下，表现出更强的检测能力和适应性。杨风召等人[9]中则梳理了统计方法、机器学习方法在电商异常检测中的应用局限，指出当前研究需进一步平衡“检测精度”与“实时性”，其提出的“业务规则 + 算法模型”融合思路，为解决电商数据动态变化导致的模型泛化能力不足问题提供了方向。

综上，当前电商异常检测研究已在风险评估、客户识别、算法创新等方面取得进展，在复现电商数据“尖峰厚尾 + 周期依赖 + 波动聚集”特性、适配业务场景动态调整检测规则、量化异常导致的经济损失等方面仍需突破；未来研究可进一步聚焦“基准值 + 周期因子 + 随机扰动的数据生成优化”等方向，提升技术的实践适配性与商业价值。

1.3. 研究目的与意义

本研究核心目的是从经济视角解决电商数据异常识别问题：构建覆盖“流量 - 订单 - 库存 - 售后”的多维度框架，精准定位侵蚀经济效益的异常；简化计算逻辑，降低落地成本，适配不同规模电商需求。

理论上，本研究将动态波动分析与电商经济理论结合，丰富经济风险防控理论体系；实践中，可降低异常漏检率，减少电商直接经济损失，优化资源配置效率，维护市场公平竞争秩序。

2. 相关理论基础

2.1. 动态波动分析

动态波动分析的核心是摆脱全局固定统计标准的局限，通过实时追踪数据的局部变化规律，精准适配电商经济的动态运行特征。电商数据始终受“长期经济趋势 + 短期业务波动”双重驱动，该分析方法通过持续更新短期数据特征，能够有效区分“促销期正常增长”与“刷单导致的异常增长”，既贴合“双 11”“618”等大促场景的高波动特性，又能适配日常消费的周期性变化，为电商经济风险防控提供符合实际经营状态的动态基准。

2.2. 电商经济视角下的数据核心特性

电商运营数据的核心特性直接决定了异常识别技术的适配方向，与电商经济运行规律深度绑定。其尖峰厚尾特性表现为多数数据集中于中间区间，同时存在少量极端值，对应消费市场的分层特征，若仅以数值大小判断异常，易误判正常高端消费订单或漏检小额多笔的隐蔽刷单。波动聚集特性体现为高波

动与低波动时段的阶段性集中，需适配场景差异以避免促销期漏检风险、平稳期误判正常订单。业务关联特性则反映在流量-转化、订单-库存等指标的逻辑联动上，这种联动是电商经济活动真实性的体现，指标间逻辑断裂往往指向刷流量、刷单等异常行为。周期依赖特性指数数据随日、周、月呈现规律性波动，对应消费时段偏好、家庭采购习惯等经济规律，需结合周期设定基准以防止资源错配。

2.3. 电商数据异常的经济影响机制

电商数据异常主要通过三条路径侵蚀电商经济运行。一是扭曲市场信号：刷单炒信制造虚假销量，导致平台推荐机制向劣质商品倾斜，形成“劣币驱逐良币”；异常流量使“流量-转化”信号失真，引发广告投放向无效流量倾斜，降低整体资源配置效率。二是推高交易成本：商家因异常数据产生的申诉、人工核查成本，消费者因超卖、虚假宣传产生的维权成本，均直接侵蚀电商经济效益；异常干扰供应链决策的行为，还会进一步放大经济损失。三是损害消费福利：超卖、虚假宣传等异常直接侵害消费者权益，导致市场信任度下降；失真的销量、评价信号增加消费者决策风险与搜索成本，长期抑制消费需求。

3. 电商运营数据异常识别技术构建

3.1. 技术框架设计

针对电商刷流量、刷单、库存失衡等异常导致的广告浪费、供应链成本激增问题，构建“多维度指标接入-局部特征计算-动态阈值判定”三阶段识别框架，全程围绕电商经济效益保障设计。

指标接入环节筛选流量、订单、库存、售后等与经济效益直接挂钩的核心指标，同步建立“高UV低转化=刷流量”“订单增库存稳=刷单”等经济逻辑规则，为风险定位提供依据。

局部特征计算采用滑动窗口技术适配电商场景，流量、实时订单等短周期指标用1天窗口，快速捕捉直播虚假流量以减少广告损失；库存周转率等长周期指标用7天窗口，平滑家电周末、服饰上新等正常波动，避免干扰供应链决策。

动态阈值判定基于历史数据设定每日滚动阈值，促销、节假日等消费高峰时段阈值上调，避免正常订单误判；平稳经营期阈值回落，提升小额刷单等隐蔽异常的识别敏感度，同时结合经济逻辑规则交叉验证，平衡风险防控与正常经营。

3.2. 核心模块落地

局部特征计算模块通过窗口与电商场景的适配，快速识别短周期流量异常、过滤长周期正常波动，有效减少广告浪费与供应链决策失误。

动态阈值模块通过全场景历史数据自适应调整，既能适配高峰时段的经营波动，又能精准捕捉平稳期的隐蔽异常，降低异常误判对经营的干扰。

多指标联动模块依托经济逻辑规则落地风险拦截，通过流量与转化的联动识别刷流量，订单与库存的匹配度拦截刷单，以及支付与退款的关联捕捉恶意退款，直接降低电商因异常导致的经济损失。

4. 实验设计与结果分析

4.1. 实验设计

4.1.1. 实验数据生成

为确保实验数据贴合电商运营数据尖峰厚尾、周期依赖、波动聚集、的核心特性，基础数据生成采用“基准值+周期因子+随机扰动”的三层架构，这里设置日均访客数(UV) 10,000人、日均订单量 1000

单、客单价 200 元、库存周转率 5%、退款率 8%、支付成功率 95%；周期因子设计则围绕电商实际运营规律，周期因子根据“周末消费高峰”特性，将工作日因子设为 1.0、周末因子设为 1.25，以模拟周末 UV 与订单量 125%的自然增长，月周期因子以“月初上新、月中平稳、月末促销”节奏，其中每月 1~5 日因新品引流需求，因子设为 1.2；每 25~30 日因冲量促销活动，因子同样设为 1.2；其余日期因子设为 1.0，分别适配月初上新与月末促销带来的流量、订单周期性峰值，还原全月不同阶段的业务波动特征；随机扰动规则针对不同类型指标差异化设计，对 UV、订单量等流量型指标叠加均值为 0、标准差为 5%的正态分布扰动，模拟“多数数据集中、少量极端值”的尖峰厚尾特征，同时通过“库存 = 基础库存 - 订单量累计/10 + 随机波动”的联动公式，模拟指标间的波动聚集效应。异常点植入共覆盖人为操作、业务波动、系统故障三类风险场景，总计 50 个异常点，其中人为操作异常包含 15 个大额单次刷单与 5 个小额多笔刷单，大额单次刷单随机选择非促销日，将订单量提升至日常值的 1.5~2.5 倍、客单价提升至 5000~8000 元且库存保持±2%波动，小额多笔刷单随机选择平稳日，将订单量提升至日常值的 3~5 倍、客单价降至 40~60 元；业务波动异常包含 10 个促销期超卖与 5 个客单价骤降，促销期超卖仅选择每月 1~5 日促销日，将订单量提升至日常值的 1.4~1.6 倍、库存降至日常值的 0.4~0.6 倍，客单价骤降选择非促销日，将客单价降至 70~90 元；系统故障异常包含 8 个支付成功率骤降与 7 个物流数据延迟，支付成功率骤降随机选择日期，将支付成功率降至 55%~65%且订单量同步降至 60%~80%，物流数据延迟随机选择日期，将库存虚增至日常值的 1.3~1.5 倍，同时为模拟异常的传导效应，对每个异常点后续 1~3 天，随机选择 UV、订单量、库存等指标叠加±30%的额外波动，还原电商异常的连锁影响。

4.1.2. 异常检测方法

本实验采用的异常检测方法融合了动态波动分析、滑动窗口技术和多指标联动规则。动态波动分析通过计算各指标的滚动均值和滚动标准差，量化指标的异常程度。对于支付成功率这类需关注下限的指标，异常分数计算公式为：

$$\text{异常分数} = 1.2 \times \frac{|\text{roll_mean} - \text{指标值}|}{\text{roll_std} + 1e-4} \quad (1)$$

对于订单量等关注偏离均值程度的指标，异常分数计算公式为：

$$\text{异常分数} = 1.2 \times \frac{|\text{指标值} - \text{roll_mean}|}{\text{roll_std} + 1e-4} \quad (2)$$

其中，roll_mean 为滚动均值，roll_std 为滚动标准差。

滑动窗口技术依据指标的风险等级和业务特性，为不同指标配置差异化的滑动窗口大小。访客数、订单量等对短期波动敏感的指标，窗口设置为 1 天；库存、退款率等与长期趋势相关的指标，窗口设置为 7 天，以更精准捕捉指标的波动规律。多指标联动规则是综合高、中、低风险指标的异常情况进行联合判定。当高风险指标异常数 ≥ 1 ，或整体异常指标数 ≥ 2 时判定为异常；同时结合业务场景优化联动规则，如访客数变化率 > 0.55 且转化率 < 0.007 等情况时，也判定为异常。

4.1.3. 评价指标

采用准确率、召回率、F1 值、经济损失降低率以及混淆矩阵等指标，从模型性能和经济价值两个维度评估异常检测方法的效果。其中，准确率反映模型对电商运营数据中异常与正常模式整体判断的正确性；召回率体现模型捕捉真实异常的能力，这对电商高风险场景至关重要，可最大程度避免严重异常漏检；F1 值用于平衡模型的精确率与召回率，确保不过度误判正常运营情况，同时有效捕捉真实异常。经济损失降低率则衡量方法在减少异常给电商平台带来经济损失方面的作用。通过混淆矩阵，还能进一步

分析正常样本的误判率和异常样本的漏检率，为后续针对电商业务场景优化检测规则提供依据，全方位评估异常检测方法在电商领域的适用性与实用价值。

4.1.4. 经济损失量化规则

经济损失降低率是衡量本研究技术经济价值的核心指标，具体指本研究技术相比传统固定阈值方法，减少的电商经济损失占传统方法总损失的百分比，计算公式为

$$\text{经济损失降低率} = \left(1 - \frac{\text{本技术损失}}{\text{传统方法损失}}\right) \times 100\% \tag{3}$$

其中经济损失量化聚焦异常导致的直接经济损失，涵盖异常订单损失与异常处理隐性成本，且仅计算“真实异常但未被检测”的漏检异常损失。为精准区分不同异常的危害程度，对各类异常赋予差异化损失权重，人为操作异常中大额单次刷单权重设为 0.9、小额多笔刷单权重设为 0.6，业务波动异常中促销期超卖权重设为 0.8、客单价骤降权重设为 0.5，系统故障异常中支付成功率骤降权重设为 0.8、物流数据延迟权重设为 0.5，订单异常日损失则通过“异常日订单金额 × 异常权重”计算。传统方法损失计算以 3δ 固定阈值法为基准，即对每个指标计算全周期均值与标准差，超出[均值 - 3δ, 均值 + 3δ]范围判定为异常，其漏检异常的总损失即为传统方法损失，本研究技术损失则基于自身检测结果，统计漏检异常的总损失，最终通过上述公式得出经济损失降低率。

4.2. 结果分析

4.2.1. 核心指标性能分析

实验结果表明，所提出的异常检测方法在电商场景下展现出良好的性能，如下表 1 所示。

Table 1. E-commerce anomaly tech indicators
表 1. 电商异常技术指标

评价指标	数值
准确率	0.82
召回率	0.88
F1 值	0.75
经济损失降低率	41.55%

从表 1 可见：准确率达到 0.82，说明在对 1000 天的电商运营数据进行判断时，整体正确性处于较好水平，能够较为精准地区分正常运营状态和异常情况。召回率为 0.88，意味着 88% 的真实异常能够被成功检测出来。在电商高风险场景中，高召回率可有效避免严重异常的漏检，最大程度降低异常对平台的危害。F1 值为 0.75，反映模型在精确率和召回率之间达到了基本平衡，既不过度将正常情况误判为异常，增加不必要的人工核查成本，也能较好地捕捉真实异常。经济损失降低率实现了 41.55% 的经济损失降低。该技术能有效减少异常带来的经济损失，在电商追求经济效益的背景下，具有显著的实用价值。

4.2.2. 混淆矩阵与误判、漏检分析

从混淆矩阵表 2 来看：

在 950 个正常样本中，有 171 个被误判为异常，正常样本误判率为 18.00%。进一步分析发现，这些误判样本可能主要集中在促销期，由于促销期订单量本身波动较大，与异常特征存在一定重叠，导致误

判。后续可考虑针对促销期优化动态阈值调整策略，适当提高判定阈值，减少促销期间的误判。

在 50 个异常样本中，仅 6 个被漏检，异常样本漏检率为 12.00%。对漏检样本分析可知，主要为一些隐蔽性较强的异常，后续可针对性地优化检测规则，例如增加时序特征分析，捕捉这类高频小额订单的异常模式。

Table 2. Confusion matrix
表 2. 混淆矩阵

	判定正常	判定异常
真实正常	779	171
真实异常	6	44

4.2.3. 可视化与经济风险验证

为直观呈现电商异常检测效果，分别绘制订单量序列与异常标记图、高风险指标异常分数与动态阈值图，如下面图 1、图 2 所示。




Figure 1. Order volume sequence and anomaly labeling graph
图 1. 订单量序列与异常标记图

由图 1 所示，图中蓝色曲线呈现电商订单量的正常波动趋势，符合业务周、月周期规律。红色“X”标记的真实异常点多分布在订单量大幅偏离正常波动处，涵盖刷单、促销超卖等场景；蓝色空心圆标记的检测异常基本覆盖多数真实异常，但也存在正常波动订单的误判情况，与混淆矩阵中正常样本误判率结果一致，且误判点在促销期相对集中，反映出促销期正常波动与异常波动易被模型混淆。

由图 2 所示，橙色虚线作为动态调整的判定标准，能够根据历史数据自适应变化。在正常运营时期，阈值相对稳定；在促销期等特殊时期，阈值会适当调整，以适应订单量本身的高波动情况。例如，在促销期内，动态阈值会有所升高，只有当订单变化率的异常程度远超促销期正常波动时，才会判定为异常，

这在一定程度上减少了促销期的误判，但从整体效果来看，仍有优化空间，以进一步提高对促销期正常波动与异常波动的区分能力。




Figure 2. Anomaly scores of high-risk indicators and dynamic threshold graph
图 2. 高风险指标异常分数与动态阈值图

5. 结论与展望

5.1. 研究结论

本研究紧扣电商经济“降本增效、维护市场健康”核心目标，构建的运营数据异常识别技术，深度适配电商经济运行规律，支撑作用显著。技术通过差异化滑动窗口与动态阈值，为流量、订单等短周期指标配置 1 天窗口捕捉短期经济行为，为库存等长周期指标配置 7 天窗口平滑周期性波动，同时适配促销期、平稳期经营差异，有效解决传统方法“促销期漏检、平稳期误判”痛点，88%的刷单、超卖等侵蚀经济效益的异常可被精准识别，防止虚假交易扭曲市场信号，避免正常经营资源错配。

从经济价值看，技术切实降低电商经济损失：一方面减少因刷单、超卖、系统故障导致的直接经济损失，缓解平台与商家成本压力；另一方面缩短运营人员问题排查耗时，降低管理交易成本，提升运营效率。更关键的是，技术净化数据信号，避免“劣币驱逐良币”，保障优质商家公平竞争，为消费者提供真实决策信号，形成“商家竞争-消费者信任-平台优化”的电商经济良性循环，为高质量发展筑牢基础。

从理论实践融合看，技术突破“技术导向”范式，将动态波动分析与电商经济理论结合，明确数据异常侵蚀电商经济的机制，既提供可落地的技术方案，又丰富电商经济数据治理理论体系，为后续从经济视角优化电商运营提供新方向。

5.2. 研究展望

未来将围绕电商经济新业态深化研究，拓展风险识别边界。针对直播电商、即时零售等增长新引擎，引入直播间互动轨迹、物流履约时效等数据，识别“直播虚假流量集群”“即时零售配送异常”等新型经

济风险，填补新业态异常识别空白，确保技术紧跟电商经济发展步伐，护航新业态健康成长。

将结合电商品类经济特性，优化风险判定优先级。考虑生鲜电商需防库存超卖损耗、家电电商需拦虚假售后纠纷、服饰电商需警刷单误判上新等差异，按异常经济影响程度赋予权重，让技术优先防控高损失风险，使资源向降低核心经济损失倾斜，提升对不同品类电商的适配性与实用价值。

将推动技术向电商经济风险预警升级，实现“事前预防”。结合交易成本理论构建“异常-损失”量化模型，测算不同异常的经济损失系数，输出“异常等级-损失预估”；同时设计“数据健康度评分体系”，实时监测指标协同性，提前预警潜在风险，推动防控从“事后应对”转向“事前预防”，全面保障电商经济降本增效与生态健康。

参考文献

- [1] 中国网络社会组织联合会. 中国国际电子商务中心. 中国新电商发展报告 2024 [R]. 长春: 第四届中国新电商大会, 2024.
- [2] Zheng, L., Li, Z., Gao, J., Li, Z., Wu, J. and Zhou, C. (2023) Domain Adaptation for Anomaly Detection on Heterogeneous Graphs in E-Commerce. In: Heras, J., Ramírez, P. and Chávez, E., Eds., *Lecture Notes in Computer Science*, Springer, 304-318. https://doi.org/10.1007/978-3-031-28238-6_20
- [3] Ramakrishnan, J., Shaabani, E., Li, C. and Sustik, M.A. (2019) Anomaly Detection for an E-Commerce Pricing System. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, Anchorage, 4-8 August 2019, 1917-1926. <https://doi.org/10.1145/3292500.3330748>
- [4] Zhang, L., Wang, Y. and Liu, J. (2022) Limitations of Fixed Threshold Methods in E-commerce Anomaly Detection: A Case Study of Promotion Periods. *IEEE Access*, **10**, 123456-123468.
- [5] Angiulli, F. and Pizzuti, C. (2002) Fast Outlier Detection in High Dimensional Spaces. In: Tapio, E., Heikki, M. and Hannu, T., Eds., *Lecture Notes in Computer Science*, Springer, 15-27. https://doi.org/10.1007/3-540-45681-3_2
- [6] 王颖, 阮梦黎. 基于大数据的电商异常交易风险评估仿真[J]. 计算机仿真, 2018, 35(3): 369-372, 388.
- [7] 杜岩虎. 电子商务环境中异常数据应用研究[D]: [硕士学位论文]. 兰州: 兰州交通大学, 2013.
- [8] Li, J., Liu, S. and Zou, J. (2024) E-commerce Data Anomaly Detection Method Based on Variational Autoencoder. *2024 3rd International Conference on Artificial Intelligence, Internet of Things and Cloud Computing Technology (AloTC)*, Wuhan, 13-15 September 2024, 231-234. <https://doi.org/10.1109/aiotc63215.2024.10748279>
- [9] 杨风召, 白慧. 异常检测技术及其在电子商务中的应用[J]. 情报杂志, 2005, 24(12): 51-53.