

电商平台个性化推荐中相似度优化与可学习模型融合研究

郭强, 代梦飞

上海理工大学管理学院, 上海

收稿日期: 2026年3月5日; 录用日期: 2026年3月17日; 发布日期: 2026年4月27日

摘要

随着电子商务的发展, 个性化推荐系统在提升用户满意度、点击率和转化率方面起着重要作用。然而, 传统的协同过滤方法往往面临数据稀疏性和用户评分偏差等问题, 限制了其预测精度和排序效果。本研究旨在通过将相似度度量与残差学习框架相结合, 优化电子商务场景下的个性化推荐性能。本文基于MovieLens 100k数据集, 探索了在不同相似度方法下结合手工特征与可学习模型的推荐方法。首先提取了用户活跃度(Activity)、评分序列相关性(DFA)和声誉(Reputation)三个手工特征, 并在Cosine、Jaccard、Pearson和Spearman四种相似度基础上, 使用了XGBoost等六种可学习模型对预测残差进行建模与校正。实验结果显示: 在不同的相似度方法下, XGBoost模型性能最优, 其中Jaccard相似度下的XGBoost在RMSE、MAE指标上表现最佳, 并且单个手工特征使用的效果有限, 而特征组合能够显著提升推荐性能。此外, 将Jaccard相似度结合XGBoost可学习模型的推荐模型与常用推荐算法进行对比, 发现其在RMSE和MAE上显著优于传统方法, 且NDCG@10指标最高, 验证了手工特征与可学习模型结合在电商推荐中的有效性。本文研究结果为电商平台提供了优化个性化推荐策略的可行方案。

关键词

电子商务, 推荐系统, 手工特征, XGBoost, 相似度度量

Research on the Similarity Optimization and Learnable Model Integration for Personalized Recommendation in E-Commerce Platforms

Qiang Guo, Mengfei Dai

Business School, University of Shanghai for Science and Technology, Shanghai

Received: March 5, 2026; accepted: March 17, 2026; published: April 27, 2026

文章引用: 郭强, 代梦飞. 电商平台个性化推荐中相似度优化与可学习模型融合研究[J]. 电子商务评论, 2026, 15(4): 859-869. DOI: 10.12677/ecl.2026.154464

Abstract

With the rapid development of e-commerce, personalized recommendation systems play a critical role in enhancing user satisfaction, click-through rates, and conversion rates. However, traditional collaborative filtering methods often suffer from data sparsity and user rating bias, which limit prediction accuracy and ranking performance. To address these challenges, this study proposes a hybrid recommendation framework that integrates similarity measures with a residual learning mechanism to optimize personalized recommendation performance in e-commerce scenarios. Based on the MovieLens 100K dataset, we investigate recommendation approaches that combine handcrafted user features with learnable models under different similarity metrics. Specifically, three handcrafted features—user activity, rating sequence correlation measured by detrended fluctuation analysis (DFA), and reputation—are extracted. On the basis of four similarity measures (Cosine, Jaccard, Pearson, and Spearman), six learnable models, including XGBoost, are employed to model and correct the prediction residuals. Experimental results demonstrate that XGBoost consistently achieves superior performance across different similarity measures. In particular, the combination of Jaccard similarity and XGBoost yields the lowest RMSE and MAE values. Moreover, using a single handcrafted feature yields limited improvement, whereas the combination of all features significantly enhances recommendation performance. Furthermore, compared with commonly used recommendation algorithms, the proposed hybrid model significantly outperforms traditional methods in terms of RMSE and MAE, while achieving the highest NDCG@10. These findings validate the effectiveness of integrating handcrafted features with learnable models for e-commerce recommendation and provide empirical support for optimizing personalized recommendation strategies.

Keywords

E-Commerce, Recommendation Systems, Handcrafted Features, XGBoost, Similarity Measures

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

随着数字经济的快速发展, 电子商务平台已成为线上消费的主要渠道。面对海量商品和高度同质化的市场环境, 如何通过个性化推荐提升用户点击率、转化率和复购率, 成为电商企业信息化建设中的核心问题。个性化推荐作为一种重要的信息过滤技术, 广泛应用于电子商务、社交服务以及基于位置的服务等领域, 随着数据量的爆炸式增长, 原有的推荐算法存在执行效率低和数据稀疏性等问题[1]。传统协同过滤方法基于用户或项目间的相似度进行推荐, 但忽略了用户的行为特征和评分习惯。在电子商务中, 该算法通过对用户的评分或行为等进行分析, 找到具有相似偏好的用户群体, 并推荐相似用户喜欢的项目。近年来, 机器学习模型被广泛应用于推荐系统, 以提升推荐准确性和个性化水平。

雷清锋[2]通过行为序列相似度建模融合用户兴趣标签, 并在 DIN 模型中引入时间衰减注意力机制, 有效提升了电商场景下用户兴趣表征能力。庄维嘉[3]提出基于 LightGBM-LR 融合模型与协同过滤交替最小二乘法相结合的混合推荐算法, 通过特征融合提升预测准确性与鲁棒性。叶昊等[4]利用 XGBoost 进行特征重要性分析, 发现用户浏览次数、重复购买频次及点击率是影响复购行为的关键因素, 为电商精准营销提供了数据支持。景秀丽等[5]基于电商促销活动数据构建 XGBoost 预测模型, 在评估用户潜在购买价值与提升长期投资回报率方面取得良好效果。吴鑫等[6]将遗传算法引入 XGBoost 模型超参数优化过程, 提出 GA-XGBoost 预测框架, 在电商购买行为预测任务中取得优于传统机器学习模型的效果。Peng

Nianjiao 等[7]在电商推荐系统设计中结合 Kafka 消息队列与 Lambda 架构, 实现了内容推荐与协同过滤的整合, 并对系统进行了全面的功能与非功能测试, 为电商平台推荐系统的开发提供了可参考的实现方案。Li Zijian [8]指出跨境电商平台存在信息过载与多政策、多商品类型干扰问题, 传统协同过滤算法难以满足实际需求。该研究基于协同过滤算法提出改进方案, 并在实验中验证了推荐效果的提升。Park Soon Hyeok [9]指出, 在协同过滤中相似度度量对推荐性能具有显著影响, 改进的 Jaccard 类相似度在多个公开数据集上整体优于传统方法。Kermany Naime Ranjbar [10]通过将用户评分可信度、人口统计特征与项目本体语义信息融入协同过滤算法, 在多个真实数据集上验证了其在缓解稀疏性和冷启动问题方面的有效性。杜宇键[11]提出了一种优化的 CT-LightGBM 模型, 通过多维音乐特征融合提升音乐推荐与榜单预测准确率, 并在实验中优于多种传统机器学习方法。王芳等[12]构建了融合协同过滤与 XGBoost 的电商用户重复购买预测模型, 通过多维行为特征与 Pearson 相似度计算实现重购行为预测, 并取得较优推荐效果。杨峰等[13]提出的 TDGCN-L 模型通过融合显式反馈与语义特征, 在图卷积框架下实现了推荐准确性与多样性的协同优化, 为多源特征增强的推荐方法提供了有益参考。Ahmed 等[14]提出了基于矩阵分解与多层感知器的信任感知跨域深度神经矩阵分解(TCrossDNMF)模型, 用于在跨域场景下预测活跃用户评分, 并缓解电子商务系统中的用户冷启动问题。Liang 等[15]提出 KerGNNT 模型, 通过图神经网络提取子图特征, 并结合图核与 Transformer 优化相似度计算, 实现结构感知, 从而显著提升推荐系统的准确性。

综上所述, 现有研究主要通过引入机器学习模型、融合多维用户行为特征以及改进相似度计算方法来提升推荐系统性能。其中, 一些混合推荐模型通过结合协同过滤与机器学习, 在一定程度上缓解了稀疏性问题。然而, 现有研究主要集中于通过构建复杂的模型结构提升推荐性能, 而对协同过滤预测结果进行校正的研究仍有限。因此, 本文以 MovieLens 100k 数据集为例, 结合不同相似度计算方法, 在传统协同过滤框架基础上通过引入用户活跃度、评分序列相关性和声誉三个手工特征, 并结合可学习模型对基础预测结果进行校正, 从而实现对传统协同过滤方法的增强。进一步地, 研究不同可学习模型在推荐任务中的性能表现, 将提出的方法与多种经典推荐算法进行对比分析, 以验证该方法在提升推荐精度和排序性能方面的增强效果。本文方法与一些依赖复杂深度模型的推荐方法相比, 结构相对简单且更侧重于对协同过滤预测结果进行残差校正, 因此特别是在评分数据较为稀疏的情况下, 该方法能够在保持模型复杂度较低的同时取得较稳定的推荐效果。

2. 方法

本研究采用公开评分数据集 MovieLens 100k (<http://www.grouplens.org>)进行实验, 该数据结构与电商平台中的“用户-商品-评分”交互形式高度一致, 可模拟电商环境下用户的浏览评价等行为。因此, 实验结果对电商个性化场景推荐具有参考意义。该数据集包含 943 位用户对 1682 部电影的 10 万条评分, 评分范围为 1 到 5, 每个用户都至少对 20 部电影进行了评分。另外, 为模拟电商时间序列行为, 对每位用户按照时间戳进行 80%训练集、20%测试集划分。

本文使用的评价指标包括 RMSE、MAE、Precision 和 NDCG@10。其中, NDCG 是归一化回折损累计增益, 取值范围[0, 1], 值越大表示推荐排序效果越好。其计算公式如下:

$$\text{NDCG}@k = \frac{\text{DCG}@k}{\text{IDCG}@k} \quad (1)$$

$$\text{DCG}@k = \sum_{i=1}^k \frac{rel_i}{\log_2(i+1)} \quad (2)$$

$$\text{IDCG}@k = \sum_{i=1}^{|REL|} \frac{rel_i}{\log_2(i+1)} \quad (3)$$

其中, rel_i 表示第 i 个推荐结果的真实相关性分数。 $|REL|$ 表示按照结果的真实相关性从大到小排序后, 取前 K 个结果组成的集合个数, 在本文中 K 取 10, 用于衡量每个用户前 10 个推荐结果的排序质量。

2.1. 相似度计算

本文选用四种常用相似度来衡量用户之间的兴趣相似度, 包括 Cosine、Jaccard、Pearson 和 Spearman 相似度。不同相似度对稀疏评分数据的敏感度存在差异, 因此在用户行为稀疏或冷启动场景下, 选择合适的相似度度量能够显著影响后续残差学习模型的性能。

(1) Cosine 相似度: 主要用于衡量用户评分向量的方向相似度, 不受评分绝对值大小的影响, 适用于评分稀疏的场景, 其能够有效捕捉用户偏好模式。

$$\text{Cosine}(A, B) = \frac{A \cdot B}{\|A\| \|B\|} \quad (4)$$

其中, 分子为用户 u 与 v 在共同评分项上的评分向量点积, 分母为对应评分向量的欧几里得范数乘积。

(2) Jaccard 相似度: 基于用户评分物品的重叠情况计算, 关注用户共同评分的物品比例, 适用于二值化或高稀疏矩阵场景, 能够突出用户行为重叠信息。

$$\text{Jaccard}(u, v) = \frac{|I_u \cap I_v|}{|I_u \cup I_v|} \quad (5)$$

其中, 分子为用户 u 与 v 共同评分的物品数量, 分母为用 u 与 v 评分物品集合的并集数量。

(3) Pearson 相关系数: 通过中心化处理消除用户评分偏差, 衡量用户评分的线性相关性, 适合关注评分趋势而非绝对评分值的场景。

$$\text{Pearson}(u, v) = \frac{\text{Cov}(u, v)}{\sigma_u \sigma_v} \quad (6)$$

其中, 分子表示用户 u 与 v 在共同评分项上的协方差, 分母表示两者评分标准差的乘积。

(4) Spearman 等级相关: 关注用户评分排序的一致性, 而非评分数值本身, 适合排序推荐任务, 它能够衡量用户对物品偏好的相对排序关系。

$$\text{Spearman}(u, v) = \frac{\text{Cov}(R_u, R_v)}{\sigma_{R_u} \sigma_{R_v}} \quad (7)$$

其中, R_u 和 R_v 表示用户评分的排序向量, 分子为排序值之间的协方差, 分母为排序值标准差的乘积。

2.2. 用户手工特征构建

为了增强残差学习模型对不同用户群体评分行为的刻画能力, 本文构建了三类用户手工特征: 用户活跃度(Activity)、评分序列相关性(DFA)以及用户声誉(Reputation)。这些特征能够提供额外的行为信息, 有助于模型在残差拟合过程中进行更精细化的残差校正。在特征构建过程中, 对所有特征进行了 Min-Max 标准化处理, 以消除不同量纲对模型训练的影响, 并加速模型收敛。

(1) 用户活跃度 k_u : 用于衡量用户评分行为的活跃程度, 定义为用户评分物品的数量。

$$k_u = |O_{ui}| \quad (8)$$

$|O_{ui}|$ 表示用户 u_i 已评分的物品集合。

(2) 用户评分序列相关性 η : 用于衡量用户评分序列的长程相关性。

$$\eta = \text{DFA} \quad (9)$$

$0 < \eta < 0.5$ 表示序列具有负相关性; $\eta = 0.5$ 表示序列是不相关的白噪声; $0.5 < \eta$ 表示序列具有正相关性。

(3) 用户声誉 μ : 通过用户正向评分比例计算声誉值, 用于反映用户在评分行为中的偏好倾向。

$$\mu = \text{Correlation based ranking algorithm}(\mu_i) \quad (10)$$

$\mu \in [0,1]$, 使用基于相关性的排名算法[16]来进行计算。

2.3. 残差学习模型

为了利用手工特征对基础预测残差进行学习与校正, 本文使用以下可学习模型对预测残差 $e = r_{true} - r_{base}$ 进行训练, 并得到最终评分:

$$r_{final} = r_{base} + \hat{e} \quad (11)$$

残差学习框架能够充分融合手工特征信息, 对不同相似度下的预测残差进行针对性校正, 提升评分精度和排序效果。本文使用到的可学习模型包括 LightGBM、CatBoost、MLP、随机森林、Ridge 回归, 以及本文实验中效果最佳的 XGBoost。XGBoost 是基于梯度提升算法的原理的一个改进版本, 中文名为极端梯度提升[17]。通过逐步拟合前一轮的预测残差构建新树, 从而提升预测精度。在本文中, XGBoost 以三类用户手工特征为输入, 预测评分残差 \hat{e} , 再与基础预测 r_{base} 相加得到最终评分 r_{final} 。

3. 实验结果和分析

3.1. 不同相似度下可学习模型比较

本文在四种用户相似度(Cosine、Jaccard、Pearson、Spearman)下, 对六种残差学习模型(LightGBM、XGBoost、CatBoost、MLP、随机森林、Ridge 回归)进行了性能比较。

实验结果如图 1~4 所示。从图中可以观察到: 在 Cosine 和 Jaccard 相似度下, XGBoost 表现最优, 其 RMSE 和 MAE 均最小, 同时 Precision 排名前列, 其次就是 LightGBM, 在各项指标上总体排名第二。相较之下, Pearson 与 Spearman 相似度下的模型整体性能有所下降。其中, 尤其是 MLP 与 Ridge 回归表现明显低于其他模型, 而 XGBoost 仍表现最优。

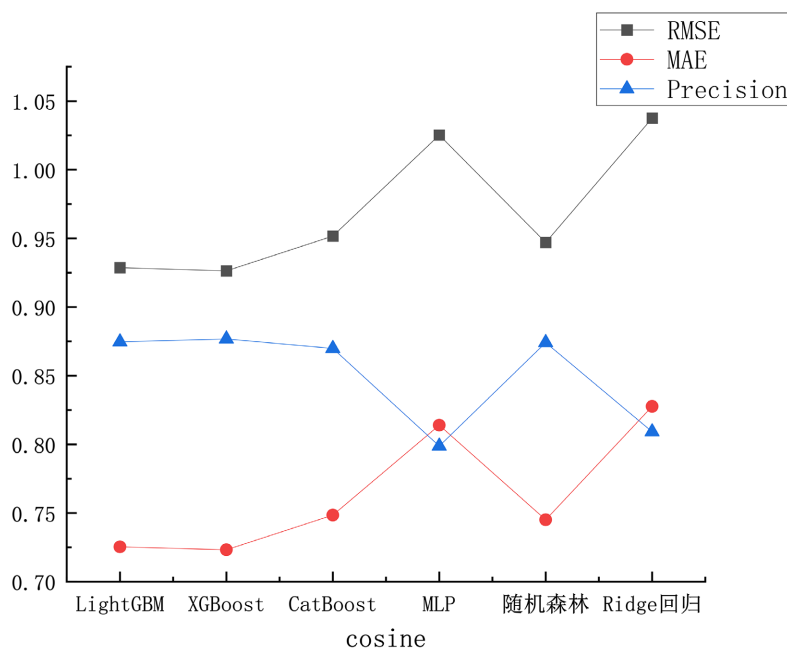


Figure 1. Comparison of learnable models under Cosine similarity
图 1. Cosine 相似度下可学习模型比较

进一步比较 XGBoost 在不同相似度下的表现(图 5)可以发现, Jaccard 相似度下的 XGBoost 为所有相似度度量中最优, RMSE = 0.924847、MAE = 0.719246。相比之下, 其 Precision (0.869910)略低于 Cosine 相似度下的 XGBoost (0.876744), 但仍保持较高水平。该结果表明, Jaccard 相似度能够更有效地捕捉用户评分行为的重叠信息, 从而提高残差学习模型的预测精度。




Figure 2. Comparison of learnable models under Jaccard similarity
图 2. Jaccard 相似度下可学习模型比较




Figure 3. Comparison of learnable models under Pearson similarity
图 3. Pearson 相似度下可学习模型比较

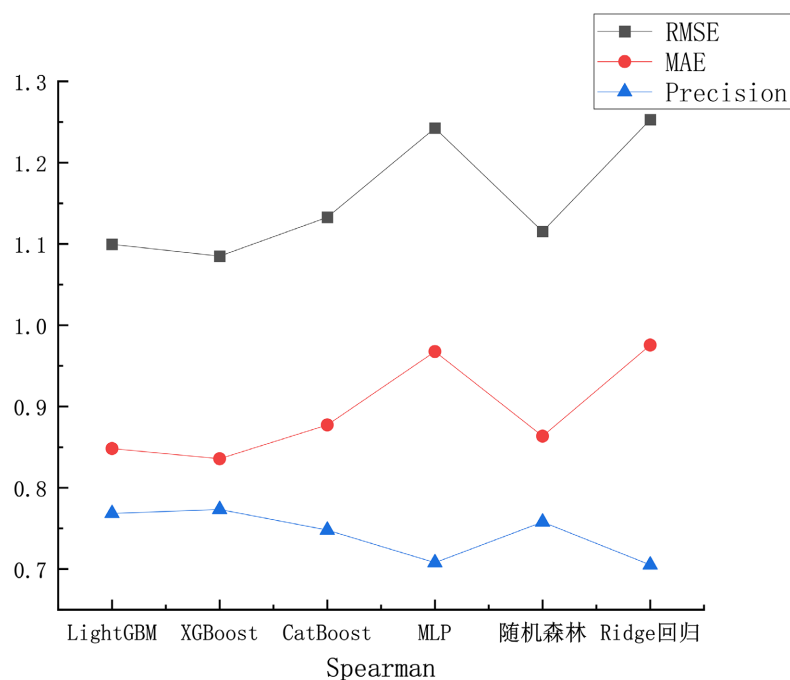


Figure 4. Comparison of learnable models under Spearman similarity
图 4. Spearman 相似度下可学习模型比较




Figure 5. Comparison of XGBoost under different similarity measures
图 5. 不同相似度下 XGBoost 比较

3.2. 与常见推荐系统模型比较

为了进一步验证本文方法的有效性, 将最优模型 Jaccard 相似度下的 XGBoost 与常用推荐系统模型进行了对比, 基线模型包括矩阵分解类(MF、SVD、SVD++、PMF、Biased MF)、神经网络推荐类(NCF、AutoRec、NFM), 以及基于相似度的纯 Jaccard 方法。实验结果如表 1 和图 6 所示。

Table 1. Comparison with commonly used recommendation models
表 1. 与常见推荐系统模型比较

方法	RMSE	MAE	NDCG
MF	1.161412	0.962337	0.783118
SVD	1.161020	0.962110	0.779994
SVD++	1.161734	0.962640	0.785962
NCF	1.161714	0.962645	0.780665
PMF	1.161943	0.962761	0.782608
Jaccard	0.924847	0.719246	0.816750
Biased MF	1.161512	0.962367	0.781388
AutoRec	1.161771	0.962770	0.784247
NFM	1.162133	0.962888	0.780378
纯 Jaccard	1.061695	0.846184	0.816714




Figure 6. Comparison with commonly used recommendation models
图 6. 与常见推荐系统模型比较

从结果可以看出: Jaccard 相似度下的 XGBoost 在 RMSE 和 MAE 指标上显著优于传统矩阵分解和神经网络推荐方法, 同时 NDCG@10 (0.816750) 也处于最高水平, 这说明其不仅在评分预测上更准确, 也能提供更优排序推荐。相比之下, 纯 Jaccard 方法相比传统推荐方法在预测性能上已有一定优势, 但在引入 XGBoost 后预测误差指标进一步降低, 说明残差学习模型对手工特征的利用显著提升了推荐效果。

综合来看, 基于 Jaccard 相似度的 XGBoost 方法在本实验中表现最优, 体现了手工特征与可学习模型的有效结合。从电商应用角度来看, Jaccard 相似度能够更有效刻画用户在商品选择上的重叠行为特征, 有助于识别兴趣相似的潜在消费群体。结合残差学习模型后, 系统能够更准确地校正评分偏差, 从而提升对用户真实购买意愿的预测能力, 为电商平台的精准营销与个性化推荐提供技术支持。

3.3. 消融实验

为进一步验证手工特征对模型性能的影响, 本文在实验中分别单独使用用户活跃度(activity)、评分序列相关性(DFA)及声誉(reputation)三个手工特征。实验结果如图 7 所示。




Figure 7. RMSE and MAE of individual handcrafted features and their combination under four similarity measures
图 7. 四种相似度下单个手工特征及特征组合的 RMSE 与 MAE

从结果可以看出: 在 Cosine、Jaccard 和 Pearson 相似度下, 用户声誉对残差校正的效果最显著, 其中 RMSE 和 MAE 最低, 说明在三个手工特征中用户声誉在预测评分偏差中贡献最大。对 Spearman 相似度, 三类手工特征的性能差异较小。这一结果表明, 在评分稀疏的情况下, 用户声誉特征提供了较稳健

的信息, 而 XGBoost 能够利用特征间的非线性关系, 有效校正残差, 从而提升预测精度。这可能是因为声誉较高的用户评分相对稳定, 在稀疏数据情况下更容易反映用户真实偏好, 因此在残差校正中起到了更明显的作用。在四个相似度下, 仅使用单一手工特征的 RMSE 和 MAE 均高于组合特征的指标结果, 说明单个特征不足以充分捕捉用户行为对预测残差的影响, 而通过特征组合可以有效提升预测精度。

4. 总结

本文提出了一种基于手工特征与可学习模型的电商推荐方法, 通过提取用户活跃度、评分序列相关性及声誉这三类手工特征, 并结合四种用户相似度计算及六种可学习模型进行评分残差预测。实验结果显示, Jaccard 相似度下的 XGBoost 模型在 RMSE、MAE 及 NDCG 指标上均优于其他方法, 并且各相似度下单个特征的使用对预测性能的提升有限, 而手工特征组合的使用能够显著降低 RMSE 与 MAE。这可能是因为 Jaccard 相似度更关注用户评分物品的重叠情况, 在评分稀疏时更容易识别兴趣相似的用户, 同时 XGBoost 能够有效建模手工特征与残差之间的非线性关系, 并通过迭代拟合残差利用特征交互信息, 从而进一步提升误差校正能力。研究结果表明, 合理选择用户相似度度量并结合手工特征的可学习模型, 可显著提升电商推荐系统的预测精度和排序性能。

综上所述, 本文提出的基于 Jaccard 相似度的 XGBoost 残差学习方法, 为电商平台优化个性化推荐策略提供了参考。未来可进一步探索多源特征融合与深度学习模型结合的残差学习方法, 以提升电商推荐系统的智能化水平与商业价值。

基金项目

国家自然科学基金, 在线社交用户行为的耦合时序分析理论及其应用研究。编号: 72171150。

国家自然科学基金, 人机融合社会系统中的用户传播影响力时序超图分析理论与方法研究。编号: 72371150。

参考文献

- [1] 刘超慧, 李玲玲. 基于机器学习的个性化推荐算法及应用[M]. 北京: 人民邮电出版社, 2024: 161.
- [2] 雷清锋. 基于用户行为序列的电子商务混合推荐模型研究[D]: [硕士学位论文]. 武汉: 武汉轻工大学, 2024.
- [3] 庄维嘉. 基于 LightGBM-LR 融合模型的混合推荐算法研究及应用[D]: [硕士学位论文]. 上海: 上海第二工业大学, 2023.
- [4] 叶昊, 袁凯骏, 沈伟, 等. 基于改进 XGBoost 算法的电商平台用户复购行为预测研究[J]. 通信与信息技术, 2025(2): 11-16.
- [5] 景秀丽, 史明曦. 基于 XGBoost 算法的电商用户重复购买行为预测[J]. 辽宁大学学报(自然科学版), 2023, 50(2): 134-145.
- [6] 吴鑫, 李君, 茅智慧, 等. 基于 GA-XGBoost 的电商用户购买行为预测[J]. 浙江万里学院学报, 2022, 35(4): 86-92.
- [7] Peng, N.J., et al. (2023) Design and Implementation of an Intelligent Recommendation System for Product Information on an e-Commerce Platform Based on Machine Learning. *International Conference on Internet of Things and Machine Learning (IoTML 2023)*, Singapore, 15-17 September 2023, 129371K.
- [8] Li, Z.J. (2023) Research on Cross-Border E-Commerce Recommendation System Based on Collaborative Filtering. *Proceedings SPIE 12625, International Conference on Mathematics, Modeling, and Computer Science (MMCS2022)*, Wuhan, 1 June 2023, 1262510. <https://doi.org/10.1117/12.2671183>
- [9] Park, S.H. and Kim, K. (2023) Collaborative Filtering Recommendation System Based on Improved Jaccard Similarity. *Journal of Ambient Intelligence and Humanized Computing*, 14, 11319-11336. <https://doi.org/10.1007/s12652-023-04647-0>
- [10] Kermany, N.R., et al. (2023) Incorporating User Rating Credibility in Recommender Systems. *Future Generation Computer Systems*, 147, 30-43.
- [11] 杜宇键. 基于 CT-LightGBM 模型的音乐推荐算法研究及榜单预测[D]: [硕士学位论文]. 上海: 上海师范大学,

- 2024.
- [12] 王芳, 龚丽兰. 基于协同过滤技术的电商用户重复购买行为预测模型构建[J]. 佳木斯大学学报(自然科学版), 2024, 42(8): 173-176+145.
- [13] 杨峰, 耿秀丽. 利用 TDGCN-L 优化电商推荐: 整合显式反馈以提高用户满意度[J/OL]. 重庆工商大学学报(自然科学版), 1-10. <https://link.cnki.net/urlid/50.1155.N.20251231.0933.002>, 2026-03-04.
- [14] Ahmed, A., Saleem, K., Khalid, O. and Rashid, U. (2021) On Deep Neural Network for Trust Aware Cross Domain Recommendations in e-Commerce. *Expert Systems with Applications*, **174**, Article ID: 114757. <https://doi.org/10.1016/j.eswa.2021.114757>
- [15] Liang, S., Ma, J., Sun, F., Chen, T., Lu, X. and Ren, S. (2025) KerGNNT: An Interpretable Graph Neural Network Recommendation Model. *Knowledge and Information Systems*, **67**, 5187-5213. <https://doi.org/10.1007/s10115-025-02376-8>
- [16] Zhou, Y., Lei, T. and Zhou, T. (2011) A Robust Ranking Algorithm to Spamming. *EPL (Europhysics Letters)*, **94**, Article No. 48002. <https://doi.org/10.1209/0295-5075/94/48002>
- [17] 王方圆. 基于 XGBoost 和 CTI 融合的推荐算法的研究与应用[D]: [硕士学位论文]. 株洲: 湖南工业大学, 2025.