

电商场景下融合语义信息与对比学习的协同过滤推荐方法

程 实, 朱子涵, 张圣琪, 成 耀*

南通大学人工智能与计算机学院, 江苏 南通

收稿日期: 2026年3月11日; 录用日期: 2026年3月25日; 发布日期: 2026年5月28日

摘 要

针对电商场景中用户-物品交互数据稀疏、协同过滤模型难以刻画物品语义内涵的问题, 本文提出一种融合大语言模型语义增强与对比对齐机制的推荐模型LLMRec。该模型以LightGCN为基础框架, 引入预训练语言模型生成的物品语义嵌入, 并设计Top-p Gate融合机制对语义特征进行自适应激活, 同时构建对比学习约束协同嵌入与语义嵌入之间的一致性。实验结果表明, 在Amazon Books数据集上, LLMRec在Recall@20与NDCG@50指标上取得较优结果, 其中对比对齐模块更倾向于改善更深排序范围内的整体排序结构(NDCG@50), 而语义增强模块更偏向于提升Top-K精排阶段的相关性表现。上述结果体现了两模块在不同排序深度上的互补作用, 并表明该框架在电商推荐场景中具有一定的应用潜力。

关键词

推荐系统, 协同过滤, 大语言模型, 语义增强, 对比学习

A Collaborative Recommendation Filtering Method Integrating Semantic Information and Contrastive Learning in E-Commerce Scenarios

Shi Cheng, Zihan Zhu, Shengqi Zhang, Yao Cheng*

School of Artificial Intelligence and Computer Science, Nantong University, Nantong Jiangsu

Received: March 11, 2026; accepted: March 25, 2026; published: May 28, 2026

Abstract

In e-commerce scenarios, user-item interaction data are usually sparse, making it difficult for

*通讯作者。

文章引用: 程实, 朱子涵, 张圣琪, 成耀. 电商场景下融合语义信息与对比学习的协同过滤推荐方法[J]. 电子商务评论, 2026, 15(5): 703-711. DOI: 10.12677/ecl.2026.155568

conventional collaborative filtering models to effectively capture the semantic characteristics of items. To address this issue, this paper proposes a recommendation model named LLMRec, which integrates large language model-based semantic enhancement with a contrastive alignment mechanism. Built upon the LightGCN framework, LLMRec incorporates semantic embeddings generated by a pretrained language model to enrich item representations. A Top-p Gate fusion mechanism is further designed to adaptively activate semantic features, while a contrastive learning objective is introduced to enforce representation consistency between collaborative embeddings and semantic embeddings. Experimental results on the Amazon Books dataset demonstrate that LLMRec achieves superior performance in terms of Recall@20 and NDCG@50. Specifically, the contrastive alignment module tends to improve the overall ranking structure in deeper ranking ranges (NDCG@50), whereas the semantic enhancement module mainly contributes to the relevance performance in the Top-K refinement stage. These results indicate the complementary effects of the two modules at different ranking depths and suggest that the proposed framework has promising potential for e-commerce recommendation scenarios.

Keywords

Recommender Systems, Collaborative Filtering, Large Language Models, Semantic Enhancement, Contrastive Learning

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

随着电商与内容平台的发展,个性化推荐成为提升体验与转化的关键技术。协同过滤[1]凭借弱依赖领域特征、易迁移被广泛应用,但在用户行为长尾、交互矩阵稀疏场景下难以学习稳定表征[2]。图神经网络可捕获高阶协同信息,成为主流基线[3]。其中,LightGCN通过简化图卷积结构、去除非线性与权重变换,在保持效果的同时降低复杂度,成为常用的图协同过滤基线[4]。然而,仅靠交互结构的图协同过滤存在语义表达不足的问题,在稀疏场景与依赖文本的物品相似性判断中性能受限。

预训练语言模型与大语言模型[5]在文本理解与语义表征上进展显著,为推荐系统引入可解释的语义信息提供了新途径[6]。现有研究常将语义嵌入与协同过滤表示融合[7],以缓解交互稀疏下的表达不足,提升Top-K精排效果。然而,文本信息往往包含营销噪声[8]、模板化描述等无关信息,直接融合易导致模型过度依赖语义,破坏协同结构并造成性能波动退化[9]。其次,自监督与对比学习[10]通过正负样本构造被广泛用于提升表示一致性与泛化能力。现有工作多聚焦于对协同嵌入本身进行对比约束[11],而在语义嵌入与协同嵌入间建立稳定一致性约束、实现跨空间对齐互补方面,仍有较大研究空间[12]。

近年来,国内学者在推荐系统、图协同过滤及语义信息融合领域研究成果丰硕:协同过滤与图神经网络推荐方向,相关研究通过改进图传播和节点表示学习提升了模型在稀疏数据下的鲁棒性[13];语义信息融合方向,已有研究引入文本、多模态特征及知识图谱增强物品表示,缓解冷启动与长尾问题[14]。对比学习在推荐系统中的应用也逐步拓展,通过多视图表示与一致性约束提升了表示空间的判别性和泛化能力[15]。这些研究为本文从“语义增强+表示对齐”角度构建推荐模型提供了重要参考基础。

2. 方法

2.1. 数据来源与预处理

本文选用 Amazon-Books 数据集,构建含 5473 用户、44,550 物品、50,000 交互的实验子集,按

46,600:3400 划分为训练/测试集。基于交互数据构建用户 - 物品二部图 $G = (U, V, E)$ ，以学习协同过滤结构表示。物品文本经清洗、规范化后，由预训练模型 MiniLM 离线编码为语义嵌入 \mathbf{e}_v^{LLM} ，保障语义增强且无训练额外推理开销。

2.2. LLMRec 模型框架

本文旨在学习评分函数 $f(u, v)$ 实现 Top-K 推荐。传统协同过滤在稀疏与细粒度语义场景下难以刻画物品差异，直接融合文本语义易引入噪声、与协同信号冲突。为此提出 LLMRec 框架：以 LightGCN 学习协同表示，用 MiniLM 语义嵌入补充内容信息；通过 Top-p Gate 抑制噪声，并引入语义 - 协同对齐约束与对比学习，在稳定协同结构的同时提升推荐效果。

2.3. 表示学习与融合机制

2.3.1. LightGCN 协同过滤模块

在用户物品图 G 中，LightGCN 通过逐层邻居传播更新节点嵌入。节点 v 的 $k+1$ 层的嵌入计算如下：

$$\mathbf{e}_v^{(k+1)} = \sum_{u \in N(v)} \frac{1}{\sqrt{|N(v)| \cdot |N(u)|}} \mathbf{e}_u^{(k)} \quad (1)$$

其中， $N(v)$ 为节点 v 的交互邻居集，经 K 层传播后，LightGCN 对各层表示取平均得到最终协同嵌入：

$$\mathbf{e}_v^{CF} = \frac{1}{K+1} \sum_{k=0}^K \mathbf{e}_v^{(k)} \quad (2)$$

由此得到用户与物品的协同表示，分别记为 \mathbf{e}_u^{CF} 与 \mathbf{e}_v^{CF} 。

2.3.2. LLM 语义嵌入与 Top-p Gate 融合机制

MiniLM 离线编码物品文本得 \mathbf{e}_v^{LLM} ，引入 Top-p Gate 筛除噪声维度，经 m_p 处理后与 \mathbf{e}_v^{CF} 加权融合获物品融合表示：

$$\tilde{\mathbf{e}}_v = (1-\alpha)\mathbf{e}_v^{CF} + \alpha(m_p \odot \mathbf{e}_v^{LLM}) \quad (3)$$

其中， α 为融合权重， \odot 表示逐元素乘法。

2.3.3. 对比对齐模块

融合表示引入对齐对比约束，统一同物品 \mathbf{e}_v^{CF} ，与语义嵌入表征、区分物品，构造正负样本对设计对比损失，定义为：

$$L_{cl} = -\sum_v \log \frac{\exp(\text{sim}(\mathbf{e}_v^{CF}, \mathbf{e}_v^{LLM})/\tau)}{\sum_j \exp(\text{sim}(\mathbf{e}_v^{CF}, \mathbf{e}_j^{LLM})/\tau)} \quad (4)$$

其中， τ 为温度系数， $\text{sim}(\cdot, \cdot)$ 表示相似度函数。为进一步约束两种表征在数值空间上的一致性，本文引入对齐损失：

$$L_{align} = \sum_v \|\mathbf{e}_v^{CF} - \tilde{\mathbf{e}}_v\|_2^2 \quad (5)$$

2.4. 预测函数与优化目标

本文仅对物品侧引入语义增强，用户侧仍采用协同过滤嵌入表示，以保持协同结构的稳定性。

用户 u 对物品 v 的预测得分为：

$$s_{uv} = \mathbf{e}_u^{CF} \cdot \tilde{\mathbf{e}}_v \quad (6)$$

推荐损失采用 BPR 形式:

$$L_{rec} = - \sum_{(u,v,j)} \log \sigma(s_{uv} - s_{uj}) \quad (7)$$

模型的最终优化目标为:

$$L = L_{rec} + \lambda_{align} L_{align} + \lambda_{cl} L_{cl} \quad (8)$$

其中, λ_{align} 与 λ_{cl} 分别调控对齐与对比损失权重。为防训练初期表征不稳, 分阶段训练: 先以推荐损失协同表示, warmup 后引入对比学习联合优化, 提升稳定性与排序性能。

3. 参数敏感性分析

本章对 LLMRec 关键模块进行参数敏感性分析, 基于 Amazon-Books 数据集, 以 Recall@20、NDCG@20、NDCG@50 为指标, 分析参数影响并给出最优取值。

3.1. 表示一致性约束的影响: 对齐权重 λ_{align} 与对比权重 λ_{cl}

图 1 展示了对齐损失权重 λ_{align} 对性能的影响。 λ_{align} 从 0.5 增至 0.8 时, 指标整体上升; 超过 0.8 后性能趋于稳定。说明适度对齐约束可缓解语义 - 协同嵌入偏移, 提升推荐效果。后续实验取 $\lambda_{align} = 0.80$ 。

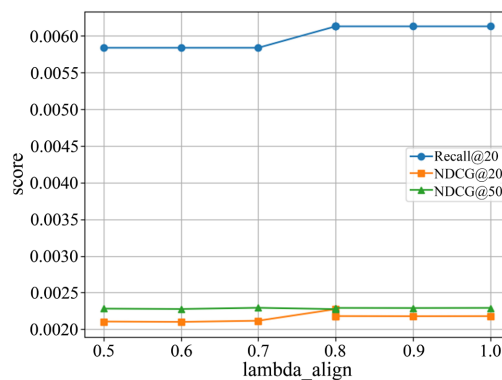


Figure 1. Impact of different alignment loss weights λ_{align} on recommendation performance
图 1. 不同对齐损失权重 λ_{align} 对推荐性能的影响

图 2 显示: λ_{cl} 在 0.10~0.20 时性能最优, >0.25 则下降。适度对比约束提升特征一致性, 过强则影响精排。主实验取 $\lambda_{cl} = 0.20$ 。




Figure 2. Impact of different contrastive loss weights λ_{cl} on recommendation performance
图 2. 不同对比损失权重 λ_{cl} 对推荐性能的影响

3.2. 语义注入强度的影响：融合权重 α 的影响

图 3 显示： α 在 0.20~0.25 时性能最佳， ≥ 0.30 明显下降。语义适合辅助协同，适度提升效果，过度则削弱协同信号。后续取 $\alpha = 0.20$ 。




Figure 3. Impact of different semantic fusion weights α on recommendation performance
图 3. 不同语义融合权重 α 对推荐性能的影响

3.3. Top-p Gate 门控阈值的鲁棒性：fuse_top_p 与 cl_top_p




Figure 4. Impact of different semantic gate parameters fuse_top_p on recommendation performance
图 4. 不同语义门控参数 fuse_top_p 对推荐性能的影响




Figure 5. Robustness analysis of the semantic gate parameter cl_top_p
图 5. 语义门控参数 cl_top_p 的鲁棒性分析

如图 4 和图 5 所示, 对融合阶段阈值 $fuse_top_p$ 与对比阶段阈值 cl_top_p 的分析表明, 两组曲线在较宽参数范围内波动较小, 模型性能整体保持稳定。由此可见, Top-p Gate 具有良好的鲁棒性, 能够自动过滤低贡献语义维度, 并与一致性约束共同提升模型对语义噪声与参数变化的容忍度。

本文主实验采用 $fuse_top_p=0.15$ 、 $cl_top_p=0.15$ 作为默认设置, 无需精细调参即可获得稳定性能。

综合参数敏感性分析, 可得出以下结论: 1) 一致性约束对性能提升至关重要, λ_{align} 取 0.8、 λ_{cl} 取 0.2 时效果最优; 2) 语义融合权重呈单峰趋势, 语义信息宜作为辅助信号, 过高会破坏协同结构稳定性; 3) Top-p Gate 鲁棒性良好, 大幅降低调参成本。后续主实验将采用上述参数, 以保证对比公平性与结果可复现性。

4. 主实验与模型对比

本章在 Amazon-Books 数据集上对比 Baseline、语义增强模型与 LLMRec, 分析语义增强与对比对齐在不同排序深度的作用。采用全物品排序, 以 Recall@20、NDCG@20、NDCG@50 为指标, 统一使用最优超参数保证实验公平可靠。

Table 1. Main experimental results on the Amazon-Books dataset

表 1. Amazon-Books 数据集上的主实验结果

模型	Recall@20	NDCG@20	NDCG@50
Baseline	0.005834	0.002095	0.002211
LLM	0.006126 (+5.00%)	0.002272 (+8.45%)	0.002272 (+2.76%)
LLM + CL	0.006126 (+5.00%)	0.002180 (+4.06%)	0.002293 (+3.71%)

注: 所有实验结果均在相同数据划分与训练设置下独立运行 5 次并取平均值。

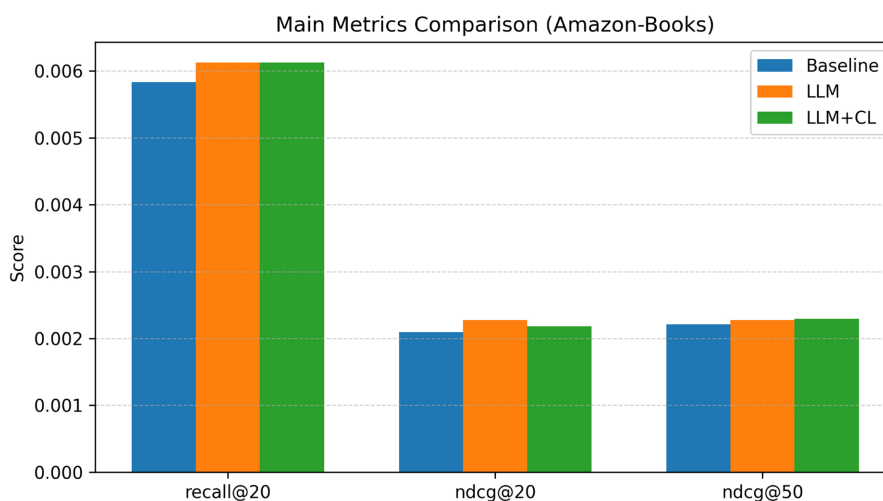


Figure 6. Comparison of main experimental results on Amazon-Books dataset

图 6. Amazon-Books 数据集上的主实验结果对比

表 1 与图 6 显示: Amazon-Books 上, LLM 与 LLM+CL 的 Recall@20 较 Baseline 提升 5.00%, 语义有效增强召回; NDCG@20 中 LLM 提升最优(+8.45%), 语义对浅层精排提升更直接。

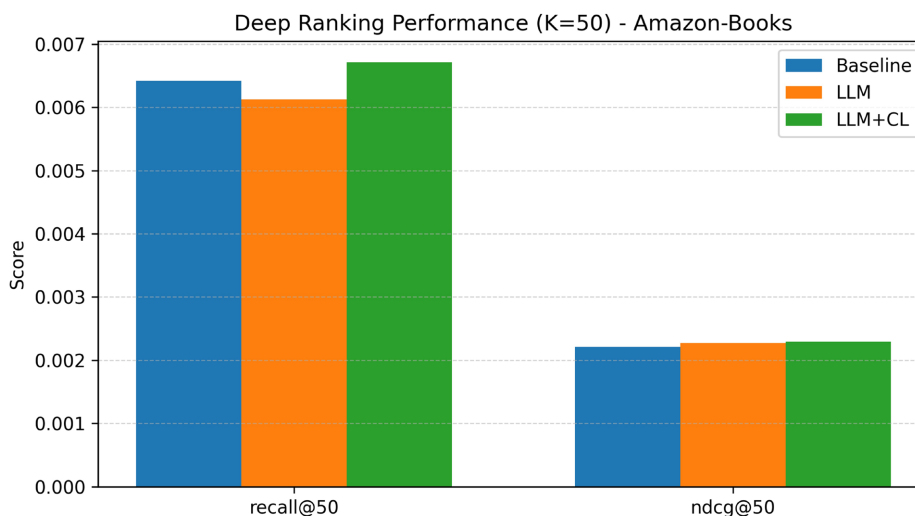


Figure 7. Comparison of deep ranking performance on Amazon-Books dataset
图 7. Amazon-Books 数据集上的深层排序性能对比

图 7 显示：NDCG@50 上 LLM + CL 最优(+3.71%)，表明对比对齐可优化全局排序，提升深层 Top-K 稳定性。语义增强与对比对齐互补：前者更利于浅层精排，后者擅长全局结构优化。

LLM + CL 在 NDCG@20 略低于 LLM，主要原因：NDCG@20 更依赖语义细粒度区分；对比学习与 BPR 优化目标存在差异；数据稀疏下浅层监督有限，对齐收益更体现在全局排序。

综上，Amazon-Books 稀疏数据上，语义增强可补充内容信息，提升浅层精排；对比对齐能优化表示一致性，改善深层排序，二者互补。后续可从权重、负样本、融合策略等方向进一步优化，实现浅层与深层排序协同提升。

4.1. Top-p Gate 的维度级可视化分析

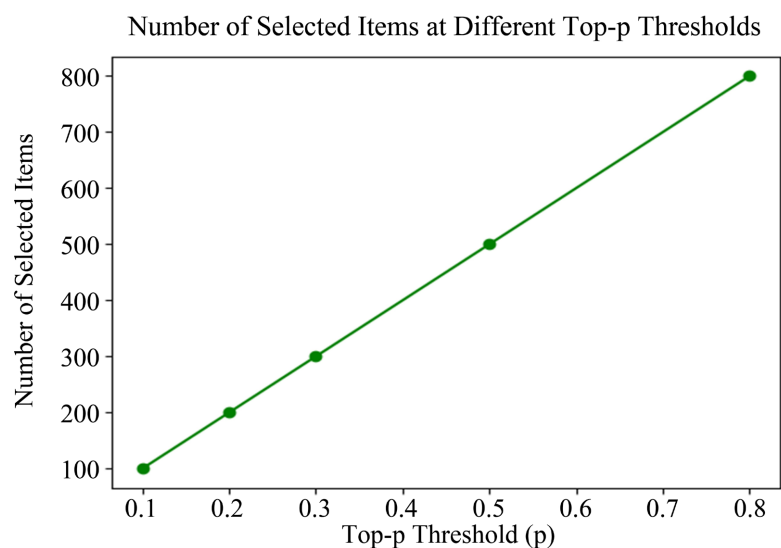


Figure 8. Relationship between Top-p threshold and number of activated semantic dimensions
图 8. Top-p 与激活维度数量的关系

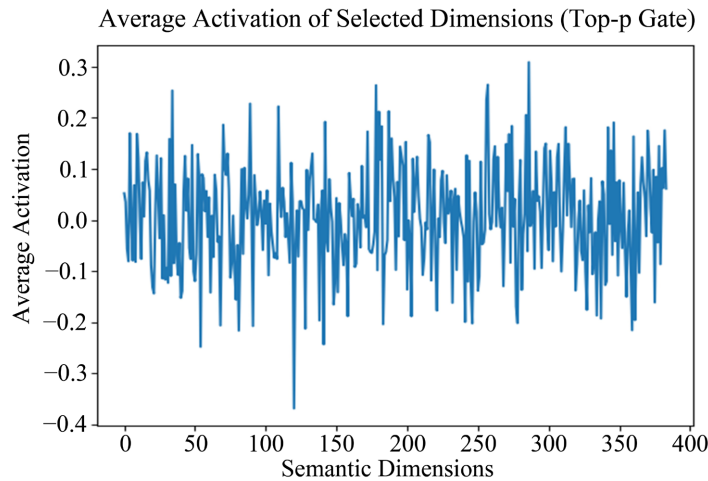


Figure 9. Activation strength distribution across semantic dimensions
图 9. 语义维度激活强度分布

本文对 Top-p Gate 语义融合机制进行可视化分析。图 8 显示，随阈值 p 增大，激活维度单调增长，说明该机制可有效控制语义注入强度。图 9 表明，有效语义维度具有稀疏性，Top-p Gate 通过保留高贡献维度、抑制噪声，使语义更紧凑地融入协同表示。

该门控实现了维度级自适应筛选，让模型聚焦高判别性语义，在稳定协同结构的同时引入有效信息，从而提升精排性能。

4.2. 显著性检验

Table 2. Results of multiple independent runs and significance test
表 2. 多次独立运行结果及显著性检测

模型	Recall@20	NDCG@20	NDCG@50
Baseline	0.005834 ± 0.00011	0.002095 ± 0.00007	0.002211 ± 0.00008
LLM	0.006126 ± 0.00010*	0.002272 ± 0.00006*	0.002272 ± 0.00007*
LLM + CL	0.006126 ± 0.00009*	0.002180 ± 0.00006	0.002293 ± 0.00007*

注：* $p < 0.05$ 。

为验证性能可靠性，本文在不同随机种子下独立运行 5 次实验，保持参数一致，并进行显著性检验。

表 2 表明：LLM 较 Baseline 在浅层指标显著提升，验证语义增强有效；LLM + CL 在 Recall@20、NDCG@50 显著提升，说明对比对齐可优化整体与深层排序。

LLM + CL 在 NDCG@20 未超 LLM，但标准差更小、稳定性更强，与前文结论一致。

多次实验证明，本文方法鲁棒性与统计可靠性良好，在稀疏推荐场景中有效。

5. 总结

本文针对电商推荐中协同模型语义匮乏、语义增强易干扰协同结构的问题，提出融合预训练语言模型与对比对齐机制的推荐方法 LLMRec。以 LightGCN 为骨架，用 MiniLM 提取物品语义嵌入，通过 Top-p Gate 降噪；并引入语义 - 协同一致性约束与对比学习，提升跨空间表示对齐与判别性。

实验表明，语义增强利于浅层 Top-K 指标，对比对齐显著提升深层排序效果，二者在不同排序深度

互补。本文为稳定协同结构下的语义增强提供了可行思路，并在电商稀疏数据上验证了有效性。

未来可从以下方向开展研究：

- 1) 融合商品图片、属性、用户评论等多模态语义信息，提升长尾商品与细粒度语义的表达能力。
- 2) 优化语义注入：细化门控策略，实现语义强度自适应调节，平衡浅层精排与深层排序。
- 3) 面向真实电商场景：在大规模数据与在线环境验证，结合线上指标优化，并解决推理成本、冷启动、分布漂移等部署问题。

参考文献

- [1] Lee, S., Ahn, J. and Kim, N. (2024) Embedding Enhancement Method for LightGCN in Recommendation Information Systems. *Electronics*, **13**, Article 2282. <https://doi.org/10.3390/electronics13122282>
- [2] Koochi, H., Kobti, Z., Farzi, T. and Mahmodi, E. (2024) UDIS: Enhancing Collaborative Filtering with Fusion of Dimensionality Reduction and Semantic Similarity. *Electronics*, **13**, Article 4073. <https://doi.org/10.3390/electronics13204073>
- [3] Cao, Z., Cheng, M., Zhang, X. and Zhang, D. (2025) Hierarchical Heterogeneous Graph Convolution Network and Improved LightGCN for Service Recommendation. *The Journal of Supercomputing*, **81**, Article No. 1552. <https://doi.org/10.1007/s11227-025-08045-5>
- [4] 成耀, 张铎, 周宇, 何金凤, 程实. 基于模糊聚类的电商企业不平衡财务数据风险预测方法[J]. 电子商务评论, 2025, 14(1): 640-647.
- [5] Dou, W., Shen, D., Zhou, X., Kou, Y., Nie, T., Cui, H., et al. (2026) Weakly-Supervised Entity Matching via Llm-Guided Data Augmentation and Knowledge Transfer. *Knowledge-Based Systems*, **335**, Article 115238. <https://doi.org/10.1016/j.knosys.2025.115238>
- [6] Yang, S., Jing, M., Wang, S., Wang, J., Xing, W., Hu, Y., et al. (2025) Exploring LLM-Based Generative Recommender Systems: Corpora, Customization, and Evaluation Insights. *Innovation in Aging*, **9**, igaf122.2248. <https://doi.org/10.1093/geroni/igaf122.2248>
- [7] Zhao, H., Xiang, Z., Wu, L. and Guo, Y. (2026) Beyond Popularity Bias in E-Commerce: Aligning Collaborative Knowledge with Large Language Models via Causal Intervention for Robust Recommendations. *Decision Support Systems*, **202**, Article 114599. <https://doi.org/10.1016/j.dss.2025.114599>
- [8] Li, Y., Yang, Q., Yu, L., Tian, S. and Fan, X. (2026) Robust Graph Contrastive Learning for Recommender Systems: Addressing Data Sparsity and Noise. *Information Systems*, **136**, Article 102625. <https://doi.org/10.1016/j.is.2025.102625>
- [9] Kang, G., Chen, Z., Wang, Y., Liu, J., Xiao, Y. and Shi, M. (2025) Feature-Enhanced Web API Recommendation via Large Language Model and Heterogeneous Graph. *Service Oriented Computing and Applications*, **2025**, 1-15. <https://doi.org/10.1007/s11761-025-00482-7>
- [10] Li, Y., Li, C., Jia, C., Zu, B. and Wang, H. (2025) Contrastive Learning of Adaptive Social Information Fusion for Recommender Systems. *Neurocomputing*, **648**, Article 130654. <https://doi.org/10.1016/j.neucom.2025.130654>
- [11] Forouzandeh, S., Krivitsky, P.N. and Chandra, R. (2025) Multiview Graph Dual-Attention Deep Learning and Contrastive Learning for Multi-Criteria Recommender Systems. *Expert Systems with Applications*, **291**, Article 128378. <https://doi.org/10.1016/j.eswa.2025.128378>
- [12] Li, D., Lu, J., Wang, Z., Wang, J., Wang, X., Shi, F., et al. (2025) Recommender System Based on Noise Enhancement and Multi-View Graph Contrastive Learning. *Applied Soft Computing*, **177**, Article 113220. <https://doi.org/10.1016/j.asoc.2025.113220>
- [13] 吴莽睿, 罗丽, 赵才荣. 基于循环一致性约束的 LLM 增强型语言模型训练框架[J/OL]. 计算机科学: 1-10. <https://link.cnki.net/urlid/50.1075.TP.20250717.1432.008>, 2026-02-08.
- [14] 韩滕跃. 基于多模态信息的推荐算法研究[D]: [博士学位论文]. 北京: 北京邮电大学, 2023.
- [15] 张洪磊, 李滢东, 邬俊, 等. 基于隐私保护的联邦推荐算法综述[J]. 自动化学报, 2022, 48(9): 2142-2163.