



天津科技大学学报

Journal of Tianjin University of Science & Technology

ISSN 1672-6510, CN 12-1355/N

《天津科技大学学报》网络首发论文

题目: 社交推荐中基于知识感知网络的高效图去噪方法
作者: 张贤坤, 孙晗娟, 孙月, 王丽媛, 龙卫平, 宋琛
DOI: 10.13364/j.issn.1672-6510.20250098
收稿日期: 2025-06-14
网络首发日期: 2026-07-09
引用格式: 张贤坤, 孙晗娟, 孙月, 王丽媛, 龙卫平, 宋琛. 社交推荐中基于知识感知网络的高效图去噪方法[J/OL]. 天津科技大学学报.
<https://doi.org/10.13364/j.issn.1672-6510.20250098>



网络首发: 在编辑部工作流程中, 稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定, 且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式(包括网络呈现版式)排版后的稿件, 可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定; 学术研究成果具有创新性、科学性和先进性, 符合编辑部对刊文的录用要求, 不存在学术不端行为及其他侵权行为; 稿件内容应基本符合国家有关书刊编辑、出版的技术标准, 正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性, 录用定稿一经发布, 不得修改论文题目、作者、机构名称和学术内容, 只可基于编辑规范进行少量文字的修改。

出版确认: 纸质期刊编辑部通过与《中国学术期刊(光盘版)》电子杂志社有限公司签约, 在《中国学术期刊(网络版)》出版传播平台上创办与纸质期刊内容一致的网络版, 以单篇或整期出版形式, 在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊(网络版)》是国家新闻出版广电总局批准的网络连续型出版物(ISSN 2096-4188, CN 11-6037/Z), 所以签约期刊的网络版上网络首发论文视为正式出版。



社交推荐中基于知识感知网络的高效图去噪方法

张贤坤¹, 孙晗娟¹, 孙月², 王丽媛¹, 龙卫平¹, 宋琛¹

(1. 天津科技大学人工智能学院, 天津 300457; 2. 深圳市安软慧视科技有限公司, 深圳 518000)

摘要: 社交推荐系统通过整合用户社交关系和用户-项目交互数据实现个性化推荐。在实际的社交网络中普遍存在冗余关系与噪声的连接, 严重降低了社交推荐系统的性能效果。为解决这一问题, 本文提出了一种基于知识感知网络 (knowledge-aware network, KAN) 的社交推荐图去噪方法 (graph denoising method for social recommendation, GDMSR), 命名为 KAN-GDMSR, 融合傅里叶频域建模、边置信度自适应评估与多层正则化控制机制, 有效提升社交图结构的表达质量与推荐鲁棒性。实验结果表明: KAN-GDMSR 在推荐的精度、效率和鲁棒性等方面均取得了显著效果。与基线方法 GDMSR 相比, KAN-GDMSR 在 N@10 和 R@10 这两个指标上分别平均提高了 12.7% 与 11.3%, 同时训练时间缩短了约 23.5%。本研究方法为社交推荐系统中的图去噪建模提供新的思路, 为后续高噪声环境下、复杂度高的推荐系统设计提供理论支撑和依据。

关键词: 社会推荐; 图去噪; 知识感知网络; 动态去噪; 自适应策略; 动态正则化

中图分类号: TP391

文献标志码: A

文章编号: 1672-6510 (0000) 00-0000-00

Efficient Graph Denoising Methods Based on Knowledge-Aware Networks in Social Recommendation Systems

ZHANG Xiankun¹, SUN Hanjuan¹, SUN Yue², WANG Liyuan¹, LONG Weiping¹, SONG Chen¹

(1. College of Artificial Intelligence, Tianjin University of Science & Technology, Tianjin 300457, China;

2. Shenzhen An Ruan Hui Shi Technology Co., Ltd., Shenzhen 518000, China)

Abstract: Social recommender systems are designed to provide customized recommendations by leveraging user social relationships and user-item interaction data. Redundant relationships with noisy connections are prevalent in authentic social networks, which significantly impair the efficacy of social recommendation systems. This paper proposes a solution to the aforementioned problem in the form of an efficient graph denoising method based on the knowledge-aware network (KAN) referred to as the KAN-based graph denoising method for social recommendation (GDMSR), named KAN-GDMSR. This method integrates Fourier frequency domain modeling, adaptive evaluation of edge confidence, and multi-layer regularization control mechanism to effectively improve the representation quality and recommendation robustness of social graph structures. Experimental results show that KAN-GDMSR significantly outperforms the baseline GDMSR in terms of recommendation accuracy, efficiency, and robustness. Specifically, KAN-GDMSR achieves average improvements of 12.7% in N@10 and 11.3% in R@10, while the training time is reduced by approximately 23.5%. The research method provides a novel concept for graph denoising modeling in social recommender systems and offers theoretical support and a foundation for the subsequent design of recommender systems with high complexity in high-noise environments.

Key words: social recommendation; graph denoising; knowledge-aware network; dynamic denoising; adaptive strategy;

收稿日期: 2025-06-14; 修回日期: 2026-03-12

基金项目: 国家自然科学基金项目 (62377036); 天津市科技计划项目 (22KPMRC00210)

作者简介: 张贤坤(1970—), 男, 安徽芜湖人, 教授; 通信作者: 孙月, 算法工程师, qcghagnz85@foxmail.com

dynamic regularization

随着社交网络的快速发展,基于社交关系的个性化推荐系统已广泛应用于互联网服务,各种兴趣/内容推送给用户的应用呈迸发式增长。社交推荐系统通过整合用户间的社交关系和用户-项目交互数据,能够有效地刻画用户的兴趣,实现兴趣或内容的个性化推送。社交推荐系统一方面考虑了用户彼此之间的社交关系链,另一方面也结合用户与系统平台之间的交互日志信息对用户的兴趣进行刻画,社交同质性作为该类系统的理论基础,也是推荐满意度的重要因素,即社交关系越紧密的人其兴趣偏好越相似,同时用户的行为对周围人的行为也会产生潜在影响。

通过社交关系网络的丰富信息,社交推荐系统能够实现更有针对性的个性化推送。与此同时,社交关系网络的复杂性也为推荐系统带来新的挑战:一是要如何刻画用户间的复杂社交联系、排除冗余信息和无效信息的干扰,成为了当前系统推荐性能提升的瓶颈;二是如何从巨大多样化的社交关系中筛选真实的、高质量的关系边^[1-2]。在当前数据体量不断上升的背景下,构建更具有表达力的社交推荐建模机制变得更为重要,尤其是在提升噪声与冗余信息的过滤能力方面^[3]。高阶关系通常是指用户之间的连接,其不仅包括直接交互还包括通过中间节点形成的间接联系。这一结构关系隐含着更深层次的社交影响机制,能够更为准确地揭示潜在的行为模式。非线性关系主要体现的是用户行为之间的复杂依赖性和偏好多样性,这一结构能够有效提升建模的推荐精度。在实际的社交网络中包含大量的冗余信息和无效信息,并不能直接反映用户的真正兴趣和行为习惯等^[4-6]。冗余边的存在一定程度上影响模型对于用户真实偏好的敏锐度,增加了模型的计算负担。

近年来,社交网络去噪研究受到国内外学者的广泛关注^[7]。通过从原始社交图中去除冗余或噪声关系,仅保留信息性社交关系,可以有效提升推荐性能。Zhang 等^[8]提出一种基于动态权重分配的网络图去噪方法,该方法通过分析用户交互历史,动态调整社交关系的权重,从而削弱冗余信息对推荐结果的干扰。将多模态特征与动态建模相结合,能够更有效地抑制噪声干扰。傅里叶变换通过频域分析能够高效分离高频噪声信号,从而显著提升推荐系统的鲁棒性^[9]。如何将傅里叶变换与动态关系建模深度结合,以实现更高效的去噪,是当前研究中的重要难题。因此,本文

主要就以下两个重点问题进行研究:第一,识别与推荐目标紧密相关的有效社交关系,需要通过引入判别式边选择机制过滤可能是负面影响的边,提高模型的鲁棒性和准确性;第二,缓解用户偏好差异带来的社交噪声影响,未被筛选过的“噪声行为”加入建模过程中,很容易让推荐系统误判用户的真实诉求^[10]。这在关系动荡的大规模动态社交网络上影响更加明显,加大模型训练的不确定性和增加模型训练所消耗的时间和资源^[11]。因此,需设计一种噪声边精细化处理算法。在计算成本可控的前提下尽可能提高无效边的判定准确性,提高推荐模型泛化性能。

针对上述问题,本文提出了一种基于知识感知网络(knowledge-aware network, KAN)与图神经网络(graph neural network, GNN)的社交推荐图去噪方法(graph denoising method for social recommendation, GDMSR),命名为 KAN-GDMSR,通过引入更具结构表达能力的去噪机制,增强模型对复杂社交图结构的分析处理能力,从而有效提升推荐系统的鲁棒性与推荐精度。本文主要的创新点:第一,基于傅里叶频域建模的图去噪机制;第二,基于边置信度的动态去噪与图结构优化策略;第三,融合法层正则化的双层 KAN-GDMSR 推荐框架。

1 相关工作

1.1 基于 GNN 的社交推荐模型

基于 GNN 的社交推荐模型在融合用户之间的社交关系与用户-项目之间的交互数据等方面表现出显著优势:一是社会影响的扩散机制,在数据训练过程中考虑了社交网络中的邻居偏好;二是用户偏好学习机制,通过用户与项目之间的历史交互行为对模型进行训练,以此预测用户未来的兴趣倾向。

用户的社交网络可以表示为用户-用户同质图 $G_s = (U, E)$, 其中 U 表示用户集合, E 表示用户之间的社交关系。用户与项目之间的交互构成了用户-项目二部图 $G_r = (U \cup I, P)$, 其中 P 表示用户与项目的交互, I 表示项目合集。为表示用户与项目的嵌入,通常采用 d 维嵌入矩阵 $E_1 \in R^{U \times d}$ 和 $E_2 \in R^{I \times d}$, 这些嵌入可通过用户或项目的 ID 编码、连续特征值或离散特征 ID 学习得到。

通过 GNN 的消息传递机制,社会影响扩散部分

可以有效建模目标用户与其好友之间的影响关系。堆叠 k 层 GNN 价于在图结构上进行 k 跳邻域的信息传播, 因此在第 k 层更新后, 用户 u 的偏好为

$$E_1^{(k)}(u) = GNN(E_1^{(k-1)}(u), \{E_1^{(k-1)}(v) \mid \forall v \in R_u\}) \quad (1)$$

其中: R_u 表示用户 u 的好友集合, GNN 模块可以是常见的模型如图卷积网络 (Graph Convolutional Network, GCN)、图注意力网络 (Graph Attention Network, GAT) 或 GraphSAGE (Graph Sample and Aggregate) 等。

此外, 用户 u 基于其交互历史 P_u (即用户与项目的交互集合) 的偏好表示为

$$E_{1,r}^{(k)}(u) = GNN(E_1^{(k-1)}(u), \{E_2^{(k-1)}(i) \mid \forall i \in P_u\}) \quad (2)$$

通过结合社会影响和交互历史, 用户最终的综合偏好表示为

$$E_1^{(k)}(u) = \text{Combine}(E_{1,s}^{(k)}(u), E_{1,r}^{(k)}(u)) \quad (3)$$

其中: *Combine* 模块可以是均值池化或注意力聚合操作。

尽管 GNN 提升了社交推荐系统的表现能力, 但是在大规模社交网络下, GNN 模型的计算复杂度, 难以满足实际系统的效率需求, 而且大规模社交网络下复杂多样的社会影响难以被单一模型完全捕捉。

1.2 图去噪研究现状

随着社交推荐系统和 GNN 模型的发展, 图去噪已成为提升网络结构学习与个性化推荐性能的重要方向^[13]。当前主流的图去噪方法可分为统计与规则方法、深度学习自适应机制、频域分析、对抗性训练与多模态/动态图结构建模几大类。

早期图去噪的统计和规则方法以边权阈值、互动频率等特征为依据, 通过剔除社交网络中的冗余和异常边以降低低质量连接的影响^[14], 对结构单一或小规模网络具有一定效果, 但在异构和动态环境下, 其对高阶噪声的识别和适应能力有限。随着 GNN 的广泛应用, 基于深度学习的自适应去噪方法通过 GNN 的消息传递与节点嵌入机制, 对社交边权重进行自动调整, 能够动态削弱噪声边对表示学习的干扰, 并提升模型在分布转移与复杂网络环境下的鲁棒性^[15]。然而, 现有方法在高阶结构表达能力、“过平滑”现象以及大规模网络下的计算效率等方面仍面临挑战。

近年来, 频域方法逐步成为图去噪领域的重要研究方向, 其利用傅里叶变换及低通滤波等技术, 在频域内高效分离高频噪声, 有效提升特征平滑性与模型的鲁棒性^[16]。尽管该类方法在异质与多模态关系场景

中表现突出, 但在动态与大规模网络中的效率和与深度建模的协同机制仍有待完善。

对抗性训练与边置信度机制是通过对抗性图卷积、注意力分配增强模型对高比例噪声的鲁棒性, 动态优化社交关系的质量。但是, 这类方法在提升适应性的同时, 往往伴随更高的计算与训练成本, 在超大规模网络下的实用性和计算效率还需提升。

多模态特征融合与动态图优化主要是通过引入知识图谱、多源语义信息及时空动态建模, 增强复杂语义与高阶关联的表达能力, 从而提升图去噪策略的普适性。与此同时高维特征空间、异构融合难度和系统效率瓶颈也成为了该模式亟需解决的问题。

随着知识图谱和知识感知网络在推荐系统网络结构建模中的应用, 已有研究^[17]将知识增强机制引入图去噪任务。通过融合知识图谱中的结构与语义信息, 提升节点和边的表征能力, 该方法能够更准确地识别和过滤噪声关系, 实现更高质量的图结构重建。知识感知机制为节点提供丰富的上下文信息, 促进高阶语义与多模态特征的融合。但是, 在面对大规模且复杂的社交关系网络, 该方法仍然存在知识推理效率低、异构数据融合难和动态环境适应性弱等问题。

在社交推荐场景中, 近年来也出现了专门面向社交图去噪的代表性工作。Li 等^[14]提出的模型从社交图 and 用户-物品交互图两个视角联合建模噪声边, 通过图神经网络对两类图的结构进行同步去噪, 从而提升社交推荐的鲁棒性。Chen 等^[27]利用可学习的边权和门控机制, 对社交图中的边进行自适应弱化或增强, 在多个社交推荐数据集上取得了优于传统 GNN 模型的效果。这两类方法与本文工作同属社交图去噪范畴, 相比之下, 本文进一步引入傅里叶频域建模与双层 KAN 结构, 将频域去噪、置信度驱动的动态图结构调整和层间正则化统一在同一框架中, 更加突出对多阶非线性结构的表达能力和训练效率。

2 KAN-GDMSR 方法

2.1 框架概述

社交推荐系统在个性化推荐中具有广泛应用, 但在实际应用中系统面临噪声干扰、冗余关系和局部信息不足等问题。这些问题使得社交图的结构复杂且质量较低, 从而影响推荐模型的精度和效率^[18-20]。为了解决上述问题, 本文提出了一种基于知识感知网络

(KAN) 的高效图去噪推荐框架。该框架结合了频域去噪、动态边权调整和层间正则化策略, 增强嵌入特征的鲁棒性和模型的泛化能力, 从而有效提升了推荐性能。KAN-GDMSR 整体框架 (图 1) 包括数据预处理与图构建、傅里叶变换去噪、动态去噪与图结构调整以及最终的模型训练与正则化等核心模块。

本文框架在各阶段融合 KAN-GDMSR 的核心设计模块以增强推荐系统的鲁棒性与表达能力, 涵盖了从图构建到模型优化的完整流程, 主要阶段为: 数据预处理与图构建、傅里叶变换去噪、动态去噪与图结构调整、模型训练与正则化。

(1) 数据预处理与图构建。利用用户与项目的交互数据及用户间的社交关系构建两类图结构: 用户-用户社交图与用户-项目交互图。用户-用户社交图用于建模兴趣传播 (节点表示用户, 边代表社交连接); 用户-项目交互图则刻画用户偏好的语义模式 (节点包括用户与项目, 边表示交互行为)。本文引入置信度建模机制动态评估边的可靠性, 用于图结构的优化与冗余边的剔除。

(2) 傅里叶变换去噪。为抑制噪声干扰、增强图嵌入的特征表达能力, 本文在社交图上引入傅里叶变换去噪机制。通过将嵌入特征映射至频域并应用低通滤波器有效去除高频噪声, 从而提升特征平滑性与结构表达能力。该频域增强操作作为 KAN-GDMSR 的核心模块之一, 为后续图结构调整与建模提供了更稳定的特征基础。

(3) 动态去噪与图结构调整。在图构建与去噪的基础上进一步基于边的置信度进行结构动态优化。基于置信度建模计算用户之间的关系强度动态调整

社交图的结构。系统根据置信度水平对边执行削弱或剔除操作, 仅保留高置信度关系边, 从而有效减少冗余连接和结构噪声。该过程提升图结构的可靠性, 为后续兴趣的传播建模奠定坚实基础。通过置信度建模, 系统具备自适应调整图结构的能力, 能够对低置信度的边采用过滤或弱化操作, 保留高置信度关系。

(4) 模型训练与正则化。模型在训练阶段采用了双层 KAN 结构, 第一层 KAN 主要负责建模用户与邻居之间的局部兴趣的传播, 第二层 KAN 主要负责融合用户-项目之间的交互图信息, 提取全局语义关联与长期兴趣模式。与此同时, 通过引入层间正则化机制约束两层特征的差异性, 确保局部与全局嵌入之间的互补性, 防止出现信息冗余和过拟合现象, 实现端到端的推荐性能的提升。




图 1 KAN-GDMSR 整体框架

Fig. 1 Overall framework of KAN-GDMSR

图 2 所示给出了 KAN-GDMSR 框架中图去噪模块的细节流程。该模块以用户-用户社交图和用户-项目交互图为输入, 首先, 对社交图执行傅里叶变换去噪, 对节点特征进行频域平滑; 随后, 通过置信度建模对边进行动态筛选和权重调整, 得到去噪后的社交图结构; 最后, 将更新后的社交图与交互图一同输入双层 KAN 模型进行表示学习和推荐预测。




图 2 KAN-GDMSR 中图去噪模块的细节流程

Fig. 2 Details of the graph denoising module in KAN-GDMSR

2.2 动态去噪机制

在社交推荐系统中用户的社交关系图通常包含

着大量冗余信息和低置信度的边^[21-24], 这些噪声边会干扰用户偏好的建模, 从而降低推荐系统的性能和鲁

棒性。为解决该问题, 本文提出了一种动态去噪机制, 通过置信度建模, 过滤噪声边优化社交图结构。动态去噪机制的核心是对社交关系的置信度进行量化建模。假设用户 u 和邻居节点 v 的置信度为

$$\text{Confidence}(u, v) = f(h_u, h_v) \quad (4)$$

其中, $f(\cdot)$ 为边置信度的计算函数, 在实现中采用一层前馈神经网络对边两端节点的特征进行非线性映射。 h_u 和 h_v 分别为用户 u 和 v 的特征向量, 置信度值 $\text{Confidence}(u, v)$ 表示节点 v 对 u 的影响程度。将用户 u 与邻居节点 v 的特征向量拼接后做线性变换并通过 Sigmoid 函数归一化, 为

$$z_{uv} = \text{Confidence}(u, v) = f(h_u, h_v) = \sigma(w_c [h_u \| h_v] + b_c) \quad (5)$$

其中: $[h_u \| h_v]$ 表示对向量 h_u 和 h_v 的拼接, w_c 和 b_c 为可学习参数, $\sigma(\cdot)$ 为 Sigmoid 函数, 将置信度约束在 $(0, 1)$ 区间。得到的 z_{uv} 即为节点对 (u, v) 的置信度, 用于式(6)中的阈值截断以及式(17)的动态去噪损失建模。

通过设定置信度阈值 τ , 移除低于阈值的边, 从而动态调整社交图结构, 去噪后的社交关系集合为

$$E' = \{(U, V) \in E : \text{Confidence}(u, v) > \tau\} \quad (6)$$

为进一步增强推荐性能, 本文在去噪过程中引入了傅里叶变换。将用户与邻居节点的特征映射至频域通过低通滤波去除高频噪声, 为

$$h_u^{\text{denoise}} = \text{IFFT}(\text{FFT}(h_u) \cdot \text{LowPassFilter}(\omega)) \quad (7)$$

其中: FFT 和 IFFT 分别为傅里叶变换和逆变换, ω 为频率参数。 $\text{LowPassFilter}(\omega)$ 表示在频率域上的低通滤波器。这里将用户节点的嵌入 h_u 看作定义在社交图上的一维图信号: 如果一条社交边连接的两个用户兴趣相近, 则沿这条边的特征变化较小, 可视为低频成分; 而噪声边往往连接兴趣差异较大的用户, 使得特征在边两端出现较大的跳变, 对应于高频成分。

通过 FFT 将 h_u 映射到频域后, $\text{LowPassFilter}(\omega)$ 在低频段的响应接近 1, 用于保留在大多数社交边上变化平滑、反映稳定社交关系与长期兴趣模式的部分; 在由噪声边和异常交互产生的高频段, 滤波器的响应逐渐衰减甚至接近 0, 从而削弱这些局部剧烈波动带来的干扰。经过 IFFT 得到的

h_u^{denoise} 可以看作一次“频域平滑”后的用户表示, 相当于在保留可靠社交关系信息的同时, 对不可信或噪声社交边进行了显式抑制, 为后续双层 KAN 的特征传播提供更加平滑、鲁棒的输入。

2.3 基于 KAN 的特征建模

KAN 是一种灵活的层结构模型, 其通过递归特征传递和信息聚合机制, 捕捉节点之间的高阶关联与深层次语义特征, 为推荐任务提供更强的非线性表达能力^[25]。

在社交推荐任务中, 用户-用户社交图 $G_s = (U, E)$ 和用户-项目交互图 $G_r = (U \cup I, P)$ 是建模的基础, KAN 的特征建模过程包括以下两部分。

(1) 邻居特征聚合。在每一层网络中, 用户节点的特征通过邻居节点的特征聚合更新, 为

$$h_u^{(l+1)} = \sigma\left(\sum_{v \in \mathcal{N}(u)} \alpha_{uv}^{(l)} W^{(l)} h_v^{(l)}\right) \quad (8)$$

其中: $h_u^{(l+1)}$ 表示用户 u 在第 $l+1$ 层的特征; $h_v^{(l)}$ 表示用户 v 在第 l 层的特征; $\mathcal{N}(u)$ 为用户 u 的邻接节点集合; $W^{(l)}$ 为第 l 层的特征映射的可学习权重矩阵; $\alpha_{uv}^{(l)}$ 为节点 v 对目标节点 u 的注意力权重, 表示关系强度; σ 为非线性激活函数。

(2) 傅里叶变换嵌入。为增强特征表达能力, KAN 在每一层中引入傅里叶正余弦嵌入, 将节点特征在多个频率尺度上展开。该操作是在原始嵌入 h_u 的基础上, 构造一组由正余弦函数变换得到的辅助特征, 使模型能够同时感知缓慢变化的低频模式和局部突变的高频模式, 其形式如式(9)所示。

$$h_u^{\text{Fourier}} = [\cos(\omega h_u), \sin(\omega h_u)] \quad (9)$$

其中, ω 为频率参数, 用于调整特征周期性范围^[26]。当 ω 较小时, 嵌入对在社交图上缓慢变化的成分更敏感, 更侧重于刻画稳定兴趣与高置信度社交关系; 当 ω 较大时, 嵌入对邻居之间的快速变化更加敏感, 更容易响应由噪声边产生的局部异常模式。

在训练过程中, 不同频率通道的权重由损失函数自适应地学习: 与推荐任务相关的低频通道会被赋予更大的权重, 而主要对应噪声扰动的高频通道则会被压缩。傅里叶变换嵌入在不改变现有模型结构和参数定义的前提下, 为 KAN 提供了一种“按频率分解并选择”的表示机制, 从特征层面进一步抑制高频噪声。为避免特征冗余, 本文将通过动态正则化强化局部和全局特征的互补性从而进一步提升推荐性能。

2.3.1 第一层网络

第一层网络级局部兴趣传播，主要任务是捕捉用户与其邻居节点（好友）之间的局部关系，建模局部兴趣传播。

邻居特征聚合，为

$$h_u^{(l+1)} = \sigma(\sum_{v \in \mathcal{N}(u)} \alpha_{uv}^{(l)} W^{(l)} h_v^{(l)}) \quad (10)$$

注意力权重计算：通过注意力机制为每个邻居节点 v 计算权重，为

$$\alpha_{uv} = \text{soft max}(\frac{\langle W_q^{(l)} h_u^{(l)}, W_k^{(l)} h_v^{(l)} \rangle}{\sqrt{d}}) \quad (11)$$

其中， $W_q^{(l)}$ 和 $W_k^{(l)}$ 分别为查询和键的映射矩阵， $\langle \cdot, \cdot \rangle$ 表示向量点积操作， d 是特征维度的归一化因子。

傅里叶嵌入：为增强特征的表达能力，假如傅里叶正余弦嵌入，为

$$h_u^{\text{Fourier}} = [\cos(\omega h_u), \sin(\omega h_u)] \quad (12)$$

其中： ω 为频率参数，用于调整特征周期性。

2.3.2 第二层网络

第二层网络专注于用户与项目的全局关联建模，提取用户长期偏好模式。

KAN 的特征传递机制通过递归更新的方式逐层优化节点特征，其数学定义为

$$h_u^{(l+1)} = \sigma(W^{(l)} h_u^{(l)} + \sum_{i \in \mathcal{N}(u)} \beta_{ui}^{(l)} W_i^{(l)} h_i^{(l)}) \quad (13)$$

其中： $h_u^{(l)}$ 表示用户 u 在第 l 层的特征， $\mathcal{N}(u)$ 为用户 u 的邻接节点集合， $W^{(l)}$ 和 $W_i^{(l)}$ 是特征映射矩阵， $\beta_{ui}^{(l)}$ 为是用户 u 和项目 i 的注意力权重。

权重分配集制，为

$$\beta_{ui}^{(l)} = \text{soft max}(\frac{\langle W_q^{(l)} h_u^{(l)}, W_k^{(l)} h_i^{(l)} \rangle}{\sqrt{d}}) \quad (14)$$

该公式类似于第一层的注意力机制，但针对的是用户和项目的关系。

融合全局特征：在全局语义建模中，还可以结合多跳特征的关系^[27]，例如用户通过多个项目节点与其他用户间接关联的语义信息，为

$$h_u^{\text{global}} = \sum_{k=1}^K \gamma_k W_k h_k \quad (15)$$

其中： K 为多跳关系的最大步数， γ_k 表示不同跳数的权重。

2.4 层间正则化

为避免两层网络产生信息冗余，设计了动态正则化策略，强化特征互补性，为

$$L_{\text{reg}} = \lambda \|h_u^{\text{local}} - h_u^{\text{global}}\|_2^2 \quad (16)$$

其中： h_u^{local} 和 h_u^{global} 分别为第一层和第二层的最终特征； λ 为正则化强度参数，用于平衡；两层特征的互补特性。

动态去噪损失用于通过边的置信度建模过滤噪声边，优化社交图的结构质量^[28-29]。动态去噪损失根据社交图中每条边的置信度对图的优化过程施加约束。对于低置信度边，通过损失函数弱化其影响或从图中移除。

$$L_{\text{conf}} = \sum_{(u,v) \in E} \max(0, \varepsilon - \text{Confidence}(u,v)) \quad (17)$$

其中： E 为社交图的边集合； $\text{Confidence}(u,v)$ 为节点 u 和 v 之间的置信度； ε 为置信度阈值，控制边是否保留。

推荐任务损失用于优化用户对目标物品的预测评分，其基于用户对项目的实际评分或交互记录进行预测。利用目标用户对物品的预测得分 $r_{u,i}$ 和实际评分 $r_{u,i}$ 之间的误差进行建模，损失函数可以采用均方误差（MSE）或交叉熵损失等。

$$L_{\text{rec}} = \frac{1}{|D|} \sum_{(u,i) \in D} (r_{u,i} - \hat{r}_{u,i})^2 \quad (18)$$

其中 D 是训练样本集合，包含所有用户 u 与物品 i 的交互记录。

结合推荐任务损失 L_{rec} 、动态去噪损失 L_{conf} 和层间正则化损失 L_{reg} ^[29]，损失函数为

$$L = L_{\text{rec}} + \alpha L_{\text{conf}} + \beta L_{\text{reg}} \quad (19)$$

其中， α 、 β 为损失平衡系数。

3 实验

3.1 实验设置

为了验证本文的 KAN-GDMSR 方法，在 Ciao、Yelp 和 Douban 这 3 个公开的社交推荐数据集上进行实验。这些数据集包含丰富的用户-用户社交关系和用户-项目交互数据，在社交推荐相关研究中得到了广泛应用。各数据集统计信息见表 1。

表 1 实验数据集信息

Tab. 1 Experimental dataset information

数据集	用户数	物品数	交互数	社交关系数	交互密度/%	社交密度/%
Douban	2669	15940	535210	32705	1.26	0.46
Ciao	7355	17867	140628	111679	0.11	0.21
Yelp	32827	54272	598121	964510	0.03	0.09

此外, 近期社交图去噪方向还出现了其他模型^[14,27], 同样聚焦于提升社交图结构质量。由于这两类方法的实现依赖较多工程细节, 与本文采用的数据预处理和评价协议存在差异, 因此暂未将其纳入数值对比。本文主要选择了当前在社交推荐与图去噪研究中被广泛采用的代表性基线模型 (Diffnet++、MHCN、NeuralSparse、ESRF、GDMSR 等) 进行实验验证。

在社交推荐模型方面, 选择 Diffnet++ 和 MHCN 作为基线模型与本文方法进行比对。将 KAN-GDMSR 与基于规则的方法、NeuralSparse 和 ESRF 进行对比。此外, 本文还将 LightGCN (该模型仅使用交互数据而不考虑社交关系数据) 作为基线模型。

在超参数设置方面, 除非特别说明, 所有实验中嵌入维度统一为 $d = 64$, batch size 为 1024, 优化器采用 Adam, 学习率为 10^{-3} 。傅里叶相关参数 (如频率参数 ω)、边置信度阈值 τ 以及损失中的正则化强度和权重系数 λ, α, β 均通过在验证集上于一个预先设定的合理区间内进行网格搜索获得最优取值。我们

在多个数据集上对这些参数在附近做过扰动实验, 发现在推荐的取值范围内, 各项指标的变化幅度较小, 模型性能趋势保持稳定, 说明所提出方法对关键超参数具有一定的鲁棒性。

为全面评估模型性能, 采用召回率 (Recall@K, 记为 $R@K$) 和归一化折损累积增益 (normalized discounted cumulative gain, NDCG@K, 记为 $N@K$) 作为评价指标。其中, $R@K$ 表示在前 K 个推荐结果中命中真实交互项目的比例, 用于衡量模型的检索能力; $N@K$ 在考虑命中情况的同时, 对推荐结果的排序位置进行加权, 强调高排名结果的重要性, 其中 $K=\{1,3\}$ 。对测试集随机抽取 100 个用户未互动过的项目, 与测试集中的正样本一起进行排名。

3.2 整体性能验证

将 KAN-GDMSR 与现有的未去噪的社交推荐模型以及不同程度的去噪方式进行了比较, 结果见表 2。在所有的实验中, KAN-GDMSR 取得了最好的效果, 与目前其他方法相比, 综合性能提高约 2%~6%, 全部数据都是通过多次重复实验得到的结果, 并具有良好的稳定性, 由统计检验可知所有差异均具有显著性 ($p<0.01$)。在 3 个数据集 (Ciao、Yelp 和 Douban) 上, KAN-GDMSR 在 Recall 和 NDCG 等重要指标上都有着明显的改进效果。

表 2 本方法在不同推荐方法上的总体性能

Tab. 2 Overall performance of this method on different recommended methods

数据集	方法	Ciao			Yelp			Douban		
		R@1	R@3	N@3	R@1	R@3	N@3	R@1	R@3	N@3
LightGCN	-	0.2298	0.0785	0.2071	0.5681	0.2774	0.5804	0.4321	0.1696	0.4156
	w/o denoising	0.2742	0.1109	0.2639	0.6031	0.3072	0.5897	0.5165	0.2156	0.4988
	Rule based	0.2860	0.1123	0.2677	0.6230	0.3228	0.5996	0.5358	0.2489	0.5172
	NeuralSparse	0.2869	0.1153	0.2734	0.6383	0.3289	0.6054	0.5470	0.2226	0.5102
	ESRF	0.2864	0.1197	0.2736	0.6184	0.3124	0.5958	0.5374	0.2393	0.5194
Diffnet++	GDMSR	0.3020	0.1244	0.2821	0.6449	0.3291	0.6102	0.5614	0.2540	0.5297
	KAN-GDMSR	0.3196	0.1312	0.2904	0.6592	0.3418	0.6213	0.5829	0.2676	0.5402
	Δ	5.82%	5.47%	2.94%	2.22%	3.88%	1.83%	3.84%	5.35%	1.98%
	w/o denoising	0.2330	0.0884	0.2297	0.6991	0.3252	0.6364	0.6198	0.3167	0.5933
	Rule based	0.2301	0.0916	0.2311	0.6966	0.3234	0.6347	0.6082	0.3372	0.5980
MHCN	NeuralSparse	0.2461	0.1034	0.2540	0.7012	0.3288	0.6352	0.6206	0.3349	0.6011
	ESRF	0.2495	0.1028	0.2568	0.6927	0.3298	0.6344	0.6194	0.3244	0.5995
	GDMSR	0.2618	0.1138	0.2632	0.7036	0.3405	0.6434	0.6396	0.3496	0.6137

KAN-GDMSR	0.2782	0.1195	0.2724	0.7165	0.3487	0.6528	0.6532	0.3593	0.6264
Δ	6.26%	5.01%	3.50%	1.83%	2.41%	1.46%	2.13%	2.77%	2.06%

注: R@K 表示 R@K (召回率), N@K 表示 N@K (归一化折损累积增益); “w/o denoising”表示未使用图去噪模块的基线模型; “Rule based”表示基于规则的去噪方法; Δ 表示 KAN-GDMSR 相对于 GDMSR 的相对提升比例。

需要说明的是, 本文采用的 Ciao、Yelp、Douban 等公开社交推荐数据集本身就包含大量自然形成的噪声边, 如较弱的社交关系、偶发性的交互行为等, 且三者在社交图稀疏度和噪声程度上存在明显差异: Ciao 的社交关系较为稀疏、噪声比例相对更高, Douban 的社交图则相对更为致密, Yelp 介于两者之间。在不额外注入人工噪声的前提下, KAN-GDMSR 在 3 套数据集上均能稳定优于多种代表性基线方法, 说明所提出模型在不同自然噪声水平和图结构条件下具有一定的鲁棒性。

为进一步验证模型在计算效率方面的表现, 在相同实验环境与超参数设置下统计各模型的平均训练时间, 以每轮 (epoch) 的平均耗时为衡量指标。实验结果表明, 与 GDMSR 相比, KAN-GDMSR 在 3 个数据集上的训练时间均有所降低, 平均减少约

20%~25%, 其中在 Yelp 数据集上训练时间降低约 23.5%。效率提升的原因主要体现在两个方面: 一是双层 KAN 结构通过分层建模机制减少了无效特征传播, 提高了收敛效率; 二是频域去噪与动态边筛选机制在训练初期即抑制了高频噪声与冗余连接, 从而减少无效梯度更新, 提升整体训练稳定性。

上述结果表明, 本文方法在提升推荐性能的同时, 并未引入额外的计算负担, 反而在一定程度上优化了模型的训练效率。

3.3 消融实验

为验证本文提出的双层 KAN 模块以及傅里叶动态正则化能否为模型增益, 进行了模块消融实验: 分别禁用 KAN 模块和傅里叶动态正则化, 并且训练不同配置的模型进行测试, 根据模型的运行结果来确定各个模块对于模型性能增益情况, 结果见表 3。

表 3 消融实验结果

Tab. 3 Ablation experiment results

模型配置	Ciao			Yelp			Douban		
	R@1	R@3	N@3	R@1	R@3	N@3	R@1	R@3	N@3
本文模型	0.3196	0.1312	0.2904	0.6592	0.3418	0.6213	0.5829	0.2676	0.5402
Fourier Only	0.286	0.1123	0.2677	0.623	0.3228	0.5996	0.5358	0.2489	0.5172
KAN Only	0.2869	0.1153	0.2734	0.6383	0.3289	0.6054	0.547	0.2226	0.5102
Base Model	0.2742	0.1109	0.2639	0.6031	0.3072	0.5897	0.5165	0.2156	0.4988

3.3.1 双层 KAN 模块消融

双层 KAN 模块消融实验是为了证明这一模块是否对于抓取用户偏好、建模社交信任有贡献。此实验基于 Diffnet++ 进行设计, 在对比实验中分别使用完整模型 (本文模型)、开启傅里叶动态正则化 (Fourier Only) 以及基础模型 (Base Model, 去掉双层 KAN 模块和傅里叶动态正则化的情况下, 基于用户-物品的交互数据以及社交信任网络的数据构建而成的)。由此看出完整模型的各项指标都是显著高于开启傅里叶动态正则化以及基础模型的。

根据实验结果可知, 在各项数据集指标上, 本文模型都比 Fourier Only 和 Base Model 高。其中 R@1 指标有 8%~12% 的提升, N@3 有 5%~8% 的提升, R@3 有 7%~20% 的提升。由此可以得出, 该完整模型利用双层 KAN 模块与傅里叶动态正则化相结合的

方式更好地捕捉了用户偏好的复杂多样性以及用户间的社交信任关系, 加强了模型自身鲁棒性及泛化能力。相比于其他设置而言, 全模型的推荐覆盖度与排序相关性都表现出了较好的效果, 证明了 KAN-GDMSR 方法具有较强的性能优势。

3.3.2 傅里叶动态正则化消融

傅里叶动态正则化消融实验是用来验证本模块对于降噪及提升模型泛化能力这一项单独的功能, 将这个消融实验主要应用于 Diffnet++ 模型。实验的结果将通过对比完整模型、仅启用双层 KAN 模块以及基础模型 (该模型去除傅里叶动态正则化和双层 KAN 模块的情况下, 基于用户-物品交互数据和社交信任网络数据) 的对比得出傅里叶动态正则化的效果。最后实验结果显示, 从实验维度分析可知, 完整模型各项指标都优于只有打开双层 KAN 模块, 也优

于只使用基础模型的结果。

由此得出结论, 傅里叶动态正则化效果显著, 表现在各实验数据集上, 在引入了傅里叶动态正则化的完整模型中, 相较只开启双层 KAN 模块的模型提高了 5%~8%; 相比原始的模型有了 10%~15% 的较大增幅; N@3 指标对比基线、完整模型分别提升 4%~7%、8%~12%; R@3 相比 Baseline 有所上升, 对于完整模型而言, 其相对 R@3 指标实现了 6%~12% 和 15%~20% 的较大增幅。

结果表明, 傅里叶动态正则化利用频域建模与降噪有效减少了高频噪声对于推荐系统的影响, 在提升模型泛化能力、鲁棒性方面也优于仅使用 KAN 模块的模型, 并且在提高推荐覆盖率、排序相关性方面有着更强的表现力, 证明了傅里叶动态正则化的有效性以及在社交推荐领域的广泛应用性。

傅里叶动态正则化对模型的增益主要体现在两个方面: 一是通过在频域中约束特征的高频能量, 抑制由少量噪声边引起的局部尖锐波动, 使节点表示在社交图上更加平滑; 二是在特征层面引入多频通道, 使模型能够区分“稳定行为模式”(低频)和“异常交互或噪声边”(高频), 训练过程中高频通道的权重会被自适应压缩。消融结果中, 当去掉傅里叶正则化时, 模型在噪声较重的数据集上的性能下降更为明显, 也从侧面印证了上述频域建模对于分离高频噪声具有实际贡献。

消融实验的结果表明, 双层 KAN 模块和傅里叶动态正则化分别单独作用于模型上可使模型获得一定幅度的改进, 但其综合起来时两个模块起到了互相补充的作用, 使得模型在模型的预测准确度、排序效果以及覆盖范围等指标都获得了提升。由此可见, 在线社会化的社交平台的信息结构较为复杂, 单一的方法很难适应, 因此将两者联合使用可以极大的提高推荐系统的质量。

3.3.3 正则项与损失权重的消融分析

为了说明层间正则项及其损失权重设置对模型性能的影响, 本文在验证集上对正则化强度 λ 以及损失平衡系数 α, β 进行了调节和观察。

在固定 α, β 的情况下, 将 λ 从较小值逐步增大可以看到: 当 $\lambda = 0$ (即去掉层间正则项) 时, 模型更容易在局部兴趣传播上过拟合, 测试集上的 Recall 与 NDCG 指标略有下降; 当 λ 取中等范围时, 局部与全局特征之间的互补性得到更好平衡, 整体性能达

到较优水平; 当 λ 过大时, 两层表示被过度约束, 模型表达能力反而有所下降。在固定 λ 的情况下, 对 α, β 在中等范围内进行调整时, 模型在各数据集上的性能变化较小, 表现较为稳定: 只有当某一权重极端偏大或偏小时, 才会出现明显退化。上述现象表明, 层间正则项本身确实为模型带来了可观增益, 同时所提出损失函数的超参数在较宽的范围内具有一定鲁棒性, 便于在实际系统中部署与调优。

基于社交推荐任务存在社交图噪声多、连接冗余等实际问题, 提出了用双层知识感知网络 (KAN) 和傅里叶动态正则化结合的方法。在该方法中利用傅里叶变换构造频域特征以增强对高频噪声的提取与抑制作用, 并基于正则化策略动态选择边结构来提高用户偏好的建模能力; 利用双层 KAN 通过分层建模机制能够更精确地表征用户-邻居之间在各层次间的相似程度以及彼此间的关系, 因而提升了推荐的个性化效果。最后从多组大规模数据集上验证了本文方法对于结构复杂或者含噪多的社交图拥有良好的预测能力及较低的计算代价。因此本文所提方法具有较好的鲁棒性、精度以及模型的深层次度, 可为复杂社交环境下个性化推荐提供合理有效的解决方法。

4 结 论

针对社交推荐系统中社交关系的噪声对建模精度的影响, 本文提出了一种融合双层知识感知网络与傅里叶动态正则化的高效图去噪推荐方法。该算法利用频域特性刻画社交网络中的周期性与非线性关联, 通过双层 KAN 结构实现用户的局部兴趣传播和长时偏好的深度建模。实验结果表明, 该方法在推荐精度、排序相关性与覆盖率等核心指标上均优于现有主流的推荐算法, 具备较强的稳定性、可扩展性和工程应用的潜力。本文方法实现了社交结构信息的分层表达, 有效抑制了高频噪声, 提升了模型的鲁棒性与泛化能力。该方法为大规模、动态演化的社交推荐问题提供了新的技术路径和理论支持。

本研究依然存在局限性: 在极大规模网络环境下的计算效率有待进一步提高; 傅里叶正则化机制的性能对参数选择较为敏感等。未来研究可进一步探索模型结构轻量化、自适应频率调控机制以及多模态信息融合等方面, 以提高方法的通用性与实际部署能力。

参考文献:

- [1] Li Jiuqiang, Wang Hongjun. Graph diffusive self-supervised learning for social recommendation[C]//ACM. Proceedings of the 47th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2024: 2442-2446.
- [2] 陈昱瑾,王晶,武志昊,等.基于图卷积网络融合群组关系的社会化推荐方法[J].计算机工程,2023,49(5):112-121.
- [3] 黄立威,江碧涛,吕守业,等.基于深度学习的推荐系统研究综述[J].计算机学报,2018,41(7):1619-1647.
- [4] 朱金侠,孟祥福,邢长征,等.融合社交关系的轻量级图卷积协同过滤推荐方法[J].智能系统学报,2022,17(4):788-797.
- [5] Liu Jingyu, Chen Shi, Shen Li. A comprehensive survey on graph neural network accelerators[J]. Frontiers of Computer Science, 2025, 19(2): 192104.
- [6] 张宜浩,朱小飞,徐传运,等.基于用户评论的深度情感分析和多视图协同融合的混合推荐方法[J].计算机学报,2019,42(6):1316-1333.
- [7] 刘露,房敏,彭涛,等.一种基于图神经网络的知识感知推荐系统: 202210796167.8 [P].
- [8] Zhang Zeyang, Wang Xin, Zhang Ziwei, et al. Dynamic graph neural networks under spatio-temporal distribution shift[J]. Advances in neural information processing systems, 2022, 35: 6074-6089.
- [9] Wahab M F, Gritti F, O'Haver T C. Discrete Fourier transform techniques for noise reduction and digital enhancement of analytical signals[J]. TrAC Trends in Analytical Chemistry, 2021, 143: 116354.
- [10] 匡海丽,常亮,宾辰忠,等.上下文感知旅游推荐系统研究综述[J].智能系统学报,2019,14(4):611-618.
- [11] Qin Dong, Zhou Xiangmin, Chen Lei, et al. Dynamic connection-based social group recommendation[J]. IEEE Transactions on Knowledge and Data Engineering, 2018, 32(3): 453-467.
- [12] Nasari M, Zakiyyah A Y. Exploring the Efficiency of Various GNN Architectures for Node Classification in Social Networks[C]//IEEE. 2024 6th International Conference on Cybernetics and Intelligent System (ICORIS). New York: IEEE, 2024: 1-6.
- [13] 吴静,谢辉,姜火文.图神经网络推荐系统综述[J].计算机科学与探索,2022,16(10):2249-2263.
- [14] Li Anchen, Yang Bo. Dual Graph Denoising Model for Social Recommendation[C]//ACM. Proceedings of the ACM on Web Conference 2025. New York: ACM, 2025: 347-356.
- [15] Rey S, Segarra S, Heckel R, et al. Untrained graph neural networks for denoising[J]. IEEE Transactions on Signal Processing, 2022, 70: 5708-5723.
- [16] Zheng Shuai, Zhu Zhenfeng, Liu Zhizhe, et al. Node-oriented spectral filtering for graph neural networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 46(1): 388-402.
- [17] Lian Qi, Qi Yu, Pan Gang, et al. Learning graph in graph convolutional neural networks for robust seizure prediction[J]. Journal of Neural Engineering, 2020, 17(3): 035004.
- [18] Wang Hao, Xu Yao, Yang Cheng, et al. Knowledge-adaptive contrastive learning for recommendation[C]//ACM. Proceedings of the sixteenth ACM international conference on web search and data mining. New York: ACM, 2023: 535-543.
- [19] Li Hongchan, Zheng Jinming, Jin Baohua, et al. Adaptive knowledge contrastive learning with dynamic attention for recommender systems[J]. IEEE Transactions on Neural Networks and Learning Systems, 2024, 13(18): 3594.
- [20] Li Tianchun, Liu Shikun, Yongbin Feng, et al. Semi-supervised graph neural networks for pileup noise removal[J]. The European Physical Journal C, 2023, 83(1): 99.
- [21] Wang Xiang, Huang Tinglin, Wang Dingxian, et al. Learning intents behind interactions with knowledge graph for recommendation[C]//ACM. Proceedings of the Web Conference 2021. New York: ACM, 2021: 878-887.
- [22] Dai Enyan, Jin Wei, Liu Hui, et al. Towards robust graph neural networks for noisy graphs with sparse labels[C]//ACM. Proceedings of the fifteenth ACM international conference on web search and data mining. New York: ACM, 2022: 181-191.
- [23] 深圳市万佳安人工智能数据技术有限公司. 一种面向大规模社交网络的交友推荐方法和系统: 202010383331.3[P].
- [24] Mu Nan, Zha Daren, He Yuanye, et al. Graph attention networks for neural social recommendation[C]//IEEE. 2019

- IEEE 31st international conference on tools with artificial intelligence (ICTAI). New York: IEEE, 2019: 1320-1327.
- [25] Yang Zhisheng, Li Li. Knowledge graph-based recommendation with knowledge noise reduction and data augmentation[J]. Applied Intelligence, 2024, 54(21): 10333-10359.
- [26] Xu Lanling, Tian Zhen, Li Bingqian, et al. Sequence-level semantic representation fusion for recommender systems[C]//ACM. Proceedings of the 33rd ACM International Conference on Information and Knowledge Management. New York: ACM, 2024: 5015-5022.
- [27] Chen Xinran, He Chaobo, Guan Quanlong. Boost social recommendation via adaptive denoising network[C]//ACM. Companion Proceedings of the ACM Web Conference 2024. New York: ACM, 2024: 577-580.
- [28] Yu Junliang, Yin Hongzhi, Li Jundong, et al. Enhancing social recommendation with adversarial graph convolutional networks[J]. IEEE Transactions on knowledge and data engineering, 2020, 34(8): 3727-3739.
- [29] He Xiangnan, Deng Kuan, Wang Xiang, et al. LightGCN: Simplifying and powering graph convolution network for recommendation[C]//ACM. Proceedings of the 43rd International ACM SIGIR conference on research and development in Information Retrieval. New York: ACM, 2020: 639-648.