

基于自监督图卷积和注意力机制实现 隐式反馈降噪的社交推荐

郭向星¹, 周 魏^{1,2}, 杨正益^{1*}, 文俊浩^{1,2}, 杨佳佳¹, 刘 蔓³

(1. 重庆大学大数据与软件学院, 重庆 400044; 2. 信息物理社会可信服务计算教育部重点实验室(重庆大学), 重庆 400044;
3. 中国移动通信集团重庆有限公司, 重庆 401320)

摘要: 基于图神经网络的社交推荐系统取得了较好的性能, 然而, 基于图神经网络的社交推荐模型存在以下挑战: 基于图神经网络的模型的邻域聚集操作会放大用户的隐式行为中的噪声, 使得用户和物品的向量表示存在偏差; 用户物品图中的边和用户社交关系图中的边的异质性, 导致基于图神经网络在两张图上学习到的用户向量表示存在于不同的语义空间, 直接融合往往得到次优的向量表示. 针对上述问题, 本文提出了基于自监督图卷积和注意力机制实现隐式反馈降噪的社交推荐模型. 该模型从原始的用户物品图中捕捉用户的真实兴趣, 生成降噪的用户物品交互图; 提出一种新颖的用户向量融合方法, 对异质的用户向量表示进行融合. 在两个公开数据集上的实验结果表明, 所提出的模型在不同数据集上的推荐性能均较基线模型有显著提升. 在 lastfm 数据集上, 推荐性能提升了 1.18% 至 3.87%; 在 ciao 数据集上, 推荐性能提升了 3.56% 至 7.31%. 通过消融实验验证了模型各个模块的有效性.

关键词: 注意力机制; 隐式反馈; 图卷积神经网络; 自监督学习; 社交推荐

基金项目: 重庆市技术创新与应用发展重大项目(No.CSTB2022TIAD-STX0006); 国家自然科学基金(No.72074036, No.62072060)

中图分类号: TP311 **文献标识码:** A **文章编号:** 0372-2112(2025)01-0151-12

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.12263/DZXB.20230387

Denosing Implicit Feedback with Self-Supervised Graph Convolution Network and Attention Mechanism for Social Recommendation

GUO Xiang-xing¹, ZHOU Wei^{1,2}, YANG Zheng-yi^{1*}, WEN Jun-hao^{1,2}, YANG Jia-jia¹, LIU Man³

(1. School of Big Data & Software Engineering, Chongqing University, Chongqing 400044, China;
2. Key Laboratory of Dependable Service Computing in Cyber Physical Society (Chongqing University), Ministry of Education, Chongqing
400044, China; 3. China Mobile Group Chongqing Co., Ltd., Chongqing 401320, China)

Abstract: Social recommender systems based on graph neural networks (GNNs) have achieved promising performance. However, challenges exist in GNN-based social recommendation models, such as the neighborhood aggregation operation of GNN-based models amplifying noise in users' implicit behaviors, resulting in suboptimal user and item representations. Additionally, the heterogeneity of edges in the user-item graph and the user social relationship graph leads to user representations learned on two different semantic spaces, where direct fusion also results in suboptimal representations. To address these issues, this paper proposes a social recommendation model based on self-supervised graph convolution and an attention mechanism to achieve implicit feedback noise reduction. The model captures users' true interests from the original user-item graph, generating a denoised user-item interaction graph; a novel method is introduced for fusing user vectors to integrate heterogeneous user vector representations. Experimental results on two public datasets demonstrate that the proposed model significantly improves the recommendation performance over the baseline models. Specifically, on the lastfm dataset, the performance improvement ranges from 1.18% to 3.87%, while on the ciao dataset, the improvement ranges from 3.56% to 7.31%. The effectiveness of each module is verified through ablation experiments.

Key words: attention mechanism; implicit feedback; graph convolution neural networks; self-supervised learning; social recommendation

Foundation Item(s): Science and Technology Innovation Key Research and Development Program of Chongqing (No.CSTB2022TIAD-STX0006); National Natural Science Foundation of China (No.72074036, No.62072060)

1 引言

随着移动互联网技术的快速发展,人们的生活方式发生了巨大改变,大数据时代使得信息爆炸式增长,同时也造成了信息过载^[1]的问题.推荐系统是缓解该问题的有效方法,推荐系统可以从海量的互联网资源中为用户推荐符合用户个人兴趣和需求的项目,如信息、服务、商品等^[2].推荐系统既能满足用户对互联网服务的需求,也能提升企业的利润^[3,4].目前,推荐系统已经广泛应用在很多领域,如短视频平台(Tiktok、哔哩哔哩、快手等),电商平台(淘宝、京东、Amazon等),社交平台(微博、Twitter、Meta、腾讯等).

凭借图神经网络(Graph Neural Network, GNN)强大的表征学习能力,基于图神经网络的推荐系统成为了当前推荐模型的主流.推荐系统中的用户、物品和交互关系可以方便地表示成图上的节点和边.此外,图神经网络可以捕捉到节点的高阶邻居信息,实现更强的协同过滤效果.推荐系统除了能够构建用户物品图,还可以把用户的社交关系构建成社交关系图^[5],在社交关系图上借助图神经网络将社交关系图应用到推荐系统中,增强用户的向量表示,进而提升推荐结果的准确性.社交推荐系统的目标是利用社交网络中每个用户的本地邻居偏好来增强用户建模,同时利用用户对项目的交互以及用户对用户的社交关系来向用户生成提供更加精准的个性化推荐^[6].

然而,将图神经网络应用到社交推荐系统仍然存在一些挑战.(1)依据用户的历史交互行为所建立的用户物品交互图通常包含用户的噪声行为.这是因为用户在实际使用过程中可能会有一些随意或非代表性的点击和浏览,这些噪声行为会在用户物品交互图中被记录下来,进而对捕捉用户真实偏好产生负面影响.(2)使用图神经网络构建用户物品交互图和用户的社交关系图时,所建立的边具有本质上的区别.具体来说,用户物品交互图中的边是隐式关系,它们反映了用户和物品之间的交互行为.而在用户社交关系图中,边则是显式关系,它们反映了用户之间的明确关系.

针对挑战(1),本文提出基于自监督图卷积和注意力机制实现隐式反馈降噪的社交推荐.模型通过注意力机制捕捉用户的真实兴趣,并生成用户物品增强图,通过自监督学习策略进行辅助训练,以减少隐式反馈中噪声数据对用户偏好的影响.针对挑战(2),提出一个新颖的用户向量表示融合模块,该模块通过一个三层的全连接神经网络对来自不同图并且异质的两个向量表示进行融合.

2 相关工作

本节对图神经网络的社交推荐系统、隐式反馈推荐系统和自监督学习推荐系统三个方面进行总结和分析.

(1)基于图神经网络的社交推荐系统

在社交推荐中用户物品之间的交互关系和用户之间的社交关系可以很方便地表示成图数据,凭借图神经网络强大的表示学习能力,近年来很多学者提出了许多基于图神经网络的社交推荐模型^[7].

早期的图神经网络模型仅对社交网络进行编码,如DiffNet(Differential Network model)^[8].DiffNet为了捕捉用户之间的社交影响提出了一种基于神经影响扩散的社交推荐模型.该模型使用神经网络来捕捉用户间的影响关系,通过影响扩散模型来预测用户的可能行为,从而改善推荐的准确性.随后该作者提出DiffNet++^[9]模型,该模型基于深度拓扑学习,同时从用户物品图和用户的社交关系图中捕捉推荐特征,从而改善推荐精度.DGRec(Graph neural network for Recommendation with Diversified embedding generation)^[10]是一种基于图神经网络的推荐系统,从多维度考虑用户和物品之间的关系,并利用多元嵌入技术来提升推荐质量.LightGCN(Lightweight Graph Convolutional Network)^[11]通过实验发现图卷积神经网络中的激活函数、自连接和转移矩阵对推荐系统的贡献较小,并且会增加模型的复杂度和计算量,因此作者提出了轻量级的图卷积神经网络,并将其应用到推荐系统,取得了很好的效果.SocialLGN(Light Graph convolution Network for Social recommendation)^[12]将LightGCN应用到社交推荐系统,并提出了一个新颖的融合模块对来自不同图的用户表示进行融合,取得了较好的推荐效果.

(2)隐式反馈推荐系统

推荐系统中的反馈分为显式反馈和隐式反馈^[13].显式反馈是指用户对物品的评分或者评论等行为,这些行为可以较为准确地反映用户的偏好.而隐式反馈表明用户是否进行了浏览、收藏或者分享等操作,通常用二元变量(0和1)表示.在现实生活中,由于时间和成本的原因,显式反馈数据往往很难收集,而隐式反馈数据更常见且容易获取^[14].然而隐式反馈带有噪声和不确定性,因此在进行建模时需要处理^[15].学者发现隐式反馈中的噪声数据会影响推荐系统学习用户的偏好,为缓解该问题提出了一种自适应降噪训练策略,在训练过程中通过两个自适应损失函数动态地降低较大损失的样本和降低较大损失的样本

的权重. Wei 等人^[16]认为在隐式反馈中可能存在不能反映用户偏好的行为,例如用户意外地浏览了小视频,为此提出一种图优化卷积网络推荐模型,通过图优化层识别置信度高的交互行为并对其进行修剪,在训练过程中根据训练的状态自适应地调整交互图的结构. 于旭等人^[17]将隐式反馈作为显式反馈的补充,提出结合显式反馈和隐式反馈的混合推荐算法,采用因子分解机对显式特征进行建模,采用因式分解对隐式特征进行建模,最后使用多层感知机进行融合.

(3) 自监督学习推荐系统

自监督学习减少了对标注数据的依赖,能够采用自定义的伪标签进行监督训练^[18]. 在推荐系统中引入自监督学习,可以从用户的历史交互行为和用户的社交关系中提取用户的兴趣和行为模式,增强用户和物品的向量表示,提高模型的泛化能力,减少对噪声数据的影响,从而提高推荐模型的性能.

SGL(Self-supervised Graph Learning)^[19]认为基于图神经网络的推荐系统容易受到噪声交互行为的影响,为了提升图神经网络推荐系统的准确性和鲁棒性,引入自监督学习到用户物品交互图,采用三种不同的手段改变原始图的结构以此生成节点的多个视图,使用辅助的自监督任务通过节点的自我辨别增强用户和物品的向量表示;SGL采用多任务学习的方式联合经典的推荐任务和辅助的自监督学习任务.

Zhang 等人^[20]指出现有的基于 GNN 和对比学习的社交推荐模型以对称的方式学习用户和物品的向量表示的策略在不平衡的数据集上无效,或者在用户数目过多或物品数过多的数据集上低效率. 为了缓解这个问题,提出了对比图学习模型 CGL(Contrastive Graph Learning for social recommendation),通过扩散模块对社交信息和兴趣信息进行聚合学习用户和物品的向量表示,通过读出模块计算用户和物品的最终向量表示,最后通过预测模块计算用户对物品的评分.

Liu 等人^[21]指出基于图神经网络的推荐系统采用的随机丢弃的手段可能会降低推荐系统的性能,为缓解这个问题,提出了一个图对比学习模块以自监督学习的方式学习嵌入,减少了信息丢失的随机性. 除此之外,引入了去偏对比损失函数解决 BPR(Bayesian Personalized Ranking)损失函数的次优抽样和样本偏差.

3 隐式反馈降噪的社交推荐模型

现有的自监督学习推荐系统^[19]通过数据增强(如节点丢弃、边缘丢弃和随机游走)生成节点的多个视图,并通过对比学习最大化同一节点不同视图之间的一致性,最小化不同节点视图之间的一致性. 通过设置辅助任务提供额外的监督信号,与主监督任务联合优

化,提高推荐模型的性能.

针对隐式反馈中存在噪声使得难以捕捉用户真实兴趣的问题,本文基于自监督图卷积神经网络和注意力机制,对原始的用户物品图进行降噪处理,建立反映用户真实兴趣的降噪图,通过图卷积神经网络在两个视图上聚合和更新用户及物品的向量表示. 如图 1 所示,模型分为四个模块:基于用户兴趣感知的图增强模块、自监督学习模块、用户表示融合模块和个性化推荐模块.

不同于以往随机变换用户-项目图的方法^[19],本研究采用了一种更加精确的自监督对比学习方法,丢弃不能反映用户兴趣的边(即噪声行为)来实现用户-项目图的增强变换. 该方法能够更有效地捕捉用户与项目之间的关系. 通过有针对性地丢弃这些噪声行为的边,能够削减图中的噪声信息,从而优化模型的训练效果. 相比随机变换方法,这种方法可以更细致地控制信息丢失的程度,从而可能带来更优的性能表现. 采用边缘丢弃(Edge dropout)作为主要的数据增强方法,通过引入注意力机制捕捉并舍弃不能反映用户兴趣的边,以此实现对比学习的图增强.

基于用户兴趣感知的图增强模块的作用是从用户的隐式反馈数据中剔除噪声数据、提取用户的兴趣,并生成能够反映用户真实兴趣的增强图. 自监督学习模块的作用是通过自监督学习策略增强用户和物品向量表示的泛化能力. 用户表示融合模块的作用是通过一个三层全连接神经网络对两种不同来源并且具有异质性的用户向量表示进行融合. 个性化推荐模块的作用是通过最终的用户和物品的向量表示计算用户对物品的评分,并依据评分的高低为用户生成 Top-K 个推荐物品.

3.1 符号说明与问题描述

本节对文章涉及到的符号进行定义和解释. 假设 $U = \{u_1, u_2, u_3, \dots, u_m\}$ 表示所有用户的集合,其中 u_i 表示第 i 个用户, m 代表用户总数;类似地, $V = \{v_1, v_2, v_3, \dots, v_n\}$ 表示所有物品的集合,其中 v_j 表示第 j 个物品, n 代表物品总数. $\mathbf{R} = (r_{uv} | u = 1, 2, 3, \dots, m; v = 1, 2, 3, \dots, n)$, 其中 r_{uv} 表示用户 u 对物品 v 的交互关系(点击、关注、观看等行为),若用户 u 交互了物品 v , $r_{uv} = 1$, 否则 $r_{uv} = 0$. 同样地, $\mathbf{S} = (s_{ij} | i = 1, 2, 3, \dots, m; j = 1, 2, 3, \dots, m)$ 表示用户的社交关系,其中 s_{ij} 表示用户 u_i 对用户 u_j 的社交关系,若用户 u_i 和用户 u_j 建立了社交关系,则 $s_{ij} = 1$, 否则 $s_{ij} = 0$.

遵循主流推荐系统模型,通过嵌入技术(Embedding)将用户和物品映射到向量空间中,以便计算它们之间的相似度. 其中, \mathbf{e}_u 和 \mathbf{e}_v 分别表示用户 u 和物品 v 的向量表示, $\mathbf{e}_u^{(k)}$ 和 $\mathbf{e}_v^{(k)}$ 分别表示用户 u 和物品 v 经过 k 层图神经网络后的向量表示;当 $k=0$ 时, $\mathbf{e}_u^{(0)}$ 和 $\mathbf{e}_v^{(0)}$ 表示用户 u 和物品 v 初始化的向量表示.

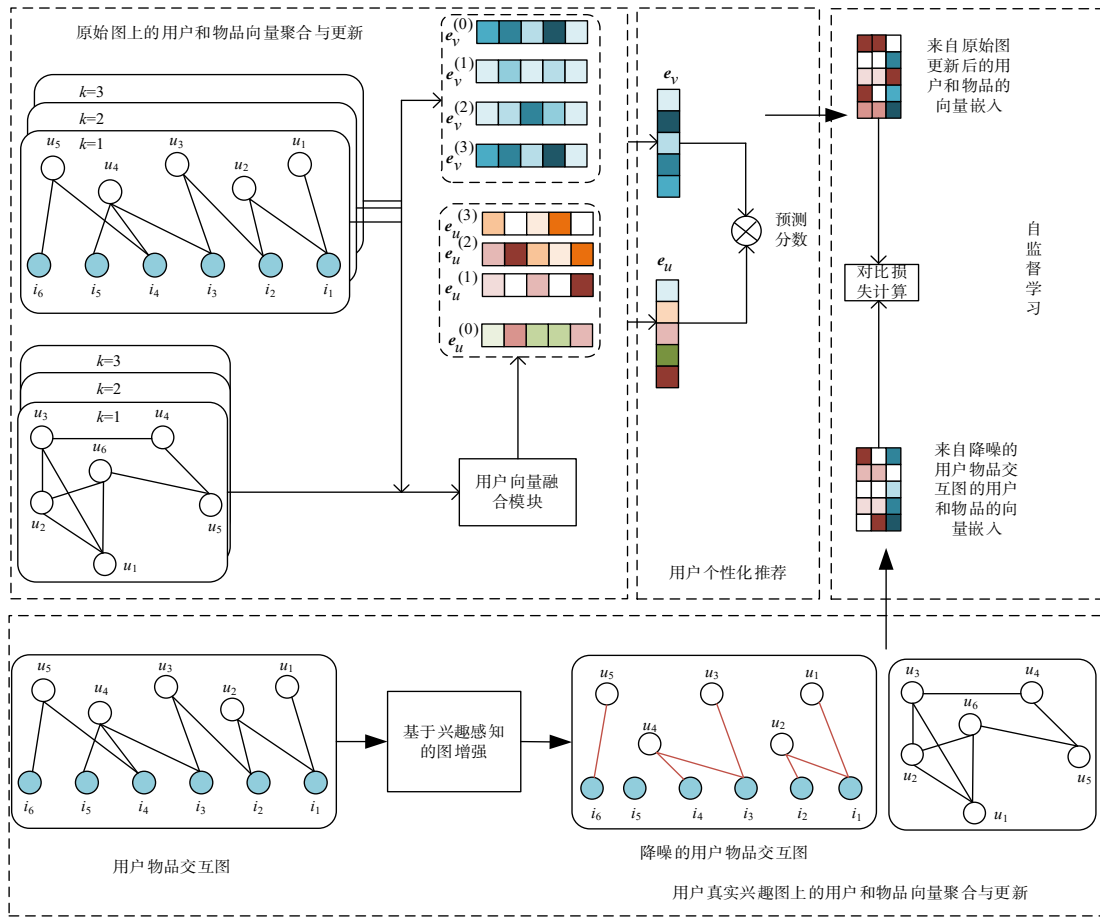


图1 模型总体框架图

给定用户和物品的交互矩阵 R 以及用户的社交关系矩阵 S , 社交推荐的问题定义: 对于目标用户 u 和其历史交互过的物品集合 P_u , 以及用户 u 的社交关系集合 F_u , 社交推荐模型的任务是为目标用户 u 推荐 Top-K 个他/她可能感兴趣的物品集合.

3.2 用户真实兴趣感知图增强模块

如图2所示, 为了从用户的隐式反馈数据中剔除噪声数据、提取用户的兴趣, 以减少用户隐式反馈中噪声行为的影响, 基于真实兴趣感知的图增强模块使用注意力机制捕捉用户的真实兴趣, 生成能够反映用户真实兴趣的增强图. 具体来说, 对于用户 u 和所有物品的集合 V , 通过注意力机制计算 u 和 V 中每个向量 e_v 的重要性权重, 计算公式如式(1)和式(2)所示.

$$x_{uv} = a(e_u, e_v) \quad (1)$$

$$w_{uv} = \frac{\exp(x_{uv})}{\sum_{k=1}^n \exp(x_{uk})} \quad (2)$$

其中, $a(\cdot)$ 为相似度度量函数, 在这里使用内积作为相似度度量函数. 同样地, 对于用户集合 U 中每一个用户

和物品集合 V 中所有的物品均执行上述操作, 得到用户的注意力分数矩阵 W . 其计算公式如式(3)所示. 该注意力分数矩阵的每一行表示用户对用户物品的注意力分数大小.

$$W = \begin{pmatrix} w_{11} & \dots & w_{1n} \\ \vdots & \ddots & \vdots \\ w_{m1} & \dots & w_{mn} \end{pmatrix} \quad (3)$$

之后, 如式(4)和式(5)所示, 兴趣阈值 T 由百分位数 threshold 计算得出, 将小于阈值 T 的注意力分数均设置为 0, 仅保留大于阈值 T 的注意力分数, 即仅保留能够反映用户真实兴趣的注意力.

$$w'_{uv} = \begin{cases} 0, & w_{uv} < T \\ w_{uv}, & w_{uv} \geq T \end{cases} \quad (4)$$

$$W' = \begin{pmatrix} 0 & \dots & 1 \\ \vdots & \ddots & \vdots \\ 1 & \dots & 0 \end{pmatrix} \quad (5)$$

其中, W' 即为用户真实兴趣的注意力矩阵. 如式(6)所示, 将原始的用户物品交互矩阵 R 与 W' 进行对应元素积, 即可在原始的用户物品图的基础上得到基于用户

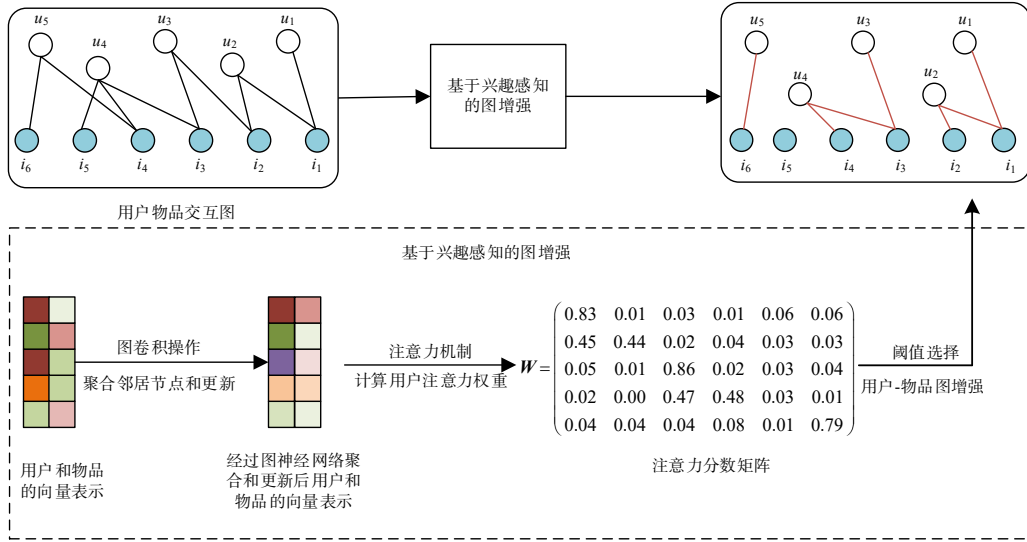


图2 基于用户真实兴趣感知的图增强

兴趣感知的增强用户物品图. 得到的新图是对原始的用户物品图进行增强的图, 为用户保留其真实感兴趣的交互行为.

$$R_{aug} = R \odot W' \quad (6)$$

其中, R 是原始的用户物品图的交互矩阵, R_{aug} 是基于用户真实兴趣的降噪图对应的矩阵, \odot 表示对应元素积.

3.3 用户向量表示融合模块

为了融合来自用户物品图和用户社交关系图两种不同来源的用户向量表示, 本小节提出一个新颖的用户向量表示融合模块. 经该模块融合之后的用户向量表示既保留了来自于两种不同图的向量表示, 还蕴含了两种向量表示之间的协同关系. 具体来说, 令 h_i 和 h_j 分别表示来自用户物品图和用户社交关系图的两个向量表示, 为了能更多地捕捉到有用的信息, 首先将 h_i, h_j 和它们的对应元素积 $h_i \odot h_j$ 拼接在一起, 其计算公式如式(7)所示:

$$X_{ij} = (h_i, h_j, h_i \odot h_j) \quad (7)$$

拼接后的向量 X_{ij} 不仅携带了 h_i 和 h_j 向量表示, 而且还携带了两者之间的协同信息, 将拼接后的向量 X_{ij} 送入到一个三层全连接神经网络中生成最终的用户向量表示, 这个全连接神经网络如式(8)所示:

$$\begin{aligned} X_1 &= \sigma(\xi_1 X_{ij} + \alpha_1) \\ X_2 &= \sigma(\xi_2 X_1 + \alpha_2) \\ X_3 &= \xi_3 X_1 + \alpha_3 \\ X_0 &= \frac{X_3}{\|X_3\|_2} \end{aligned} \quad (8)$$

其中, ξ_1, ξ_2, ξ_3 和 $\alpha_1, \alpha_2, \alpha_3$ 分别为权值矩阵和偏置矩阵. 在这里该模块使用 Mish 函数^[20]作为激活函数 σ , Mish

函数是一种新颖的自正则非单调激活函数, Mish 激活函数使用输入变量与其非线性变化后的激活值相乘, 没有任何参数, 使用起来更加方便, 并且表现效果优于 ReLU 激活函数. 其计算公式如式(9)所示:

$$f(x) = x \tanh(\ln(1 + e^x)) \quad (9)$$

3.4 用户和物品向量聚合更新模块

原始图和增强图上的用户和物品向量更新规则相似. 本节采用轻量图卷积神经网络^[11]作为编码器, 分别在两个图上更新用户和物品向量, 其更新规则如下.

(1) 用户物品图和用户真实兴趣增强图上的用户物品向量更新

如式(10)所示, 假设 $e_u^{(k+1)}$ 和 $e_v^{(k+1)}$ 分别表示用户和物品在第 $k+1$ 层上的向量表示, 通过用户和物品的邻居节点的向量表示来更新所有节点的向量表示:

$$\begin{aligned} e_u^{(k+1)} &= \sum_{v \in N_u} \frac{1}{\sqrt{|N_u|} \sqrt{|N_v|}} e_v^{(k)} \\ e_v^{(k+1)} &= \sum_{u \in N_v} \frac{1}{\sqrt{|N_u|} \sqrt{|N_v|}} e_u^{(k)} \end{aligned} \quad (10)$$

(2) 用户社交关系图上的用户向量更新

如式(11)所示, 同样利用邻居节点的向量表示更新目标节点的向量, 得到其在第 $k+1$ 层的向量表示 $e_{user}^{(k+1)}$:

$$e_{user}^{(k+1)} = \sum_{friend \in N_{user}} \frac{1}{\sqrt{|N_{user}|} \sqrt{|N_{friend}|}} e_{friend}^{(k)} \quad (11)$$

(3) 用户向量表示融合

在得到了来自用户物品图和用户社交关系图的第 $k+1$ 层用户向量表示之后, 通过 3.3 节提出的融合模块, 获得第 $k+1$ 层最终的用户向量表示, 融合规则如式(12)所示:

$$\mathbf{e}_u^{(k+1)} = \text{fusion}(\mathbf{e}_u^{(k+1)}, \mathbf{e}_{\text{user}}^{(k+1)}) \quad (12)$$

(4)最终的用户和物品向量表示

分别在用户物品图和社交关系图上叠加 K 层的图卷积神经网络得到多层用户和物品的向量表示,将这些向量表示通过加权求和的方式计算出最终的用户和物品向量表示,其计算规则如式(13)所示:

$$\mathbf{e}_u = \sum_{k=0}^K \frac{1}{K+1} \mathbf{e}_u^{(k)}, \quad \mathbf{e}_v = \sum_{k=0}^K \frac{1}{K+1} \mathbf{e}_v^{(k)} \quad (13)$$

其中,当 $k=0$ 时, $\mathbf{e}_u^{(0)}, \mathbf{e}_v^{(0)}$ 分别表示初始的用户和物品向量表示.

3.5 个性化推荐模块

如式(14)所示,个性化推荐模块将用户 u 和物品 v 的最终向量表示 \mathbf{e}_u 和 \mathbf{e}_v 进行内积操作,得到的预测分数 \hat{y}_{uv} 即为用户 u 对物品 v 的偏好评分. 依据预测分数的高低生成推荐序列,按照预先设定的 Top- K 为用户生成 Top- K 个推荐物品.

$$\hat{y}_{uv} = \mathbf{e}_v^T \cdot \mathbf{e}_u \quad (14)$$

Denoising-GCN 采用贝叶斯个性化排名 BPR 损失^[22]对模型进行优化. BPR 损失是隐式推荐系统中常用的损失函数,其目标是最大化用户与物品之间的预测概率的差异. 数据集中观测到的用户行为称为正样本,对于每一个正样本,通过随机负采样的方式制作负样本,即未被观测到的负样本. 对于每一个用户、正样本、负样本, BPR 损失函数将推荐系统的任务看作是参数估计,其目标就是最大化正样本接近用户的概率,最小化负样本接近用户的概率,并使用随机梯度下降法优化模型的参数.

对于任意的用户 u , 其正样本为 i 和负样本为 j , 则 BPR 损失函数定义如式(15)所示:

$$L_{\text{main}} = \sum_{(u, i, j) \in O} -\log \sigma(\hat{y}_{ui} - \hat{y}_{uj}) \quad (15)$$

其中, $O = \{(u, i, j) | (u, i) \in O^+, (u, j) \in O^-\}$ 表示训练集, $(u, i) \in O^+$ 表示数据集中观察到的用户交互行为, $(u, j) \in O^-$ 表示通过随机负采样从未观测的用户交互行为中制作的负样本.

此外,原始图上得到的最终用户和物品向量将连同增强图上得到的最终用户和物品的最终向量表示用于 3.6 节的自监督学习模块.

3.6 自监督学习模块

令 3.4 节在原始图上学习的用户的向量表示为 \mathbf{e}'_u , 在用户真实兴趣增强图上学习的用户的向量表示为 \mathbf{e}''_u , 使用余弦相似度来衡量这两个 Embedding 的相似性,如式(16)所示:

$$\text{similarity}(\mathbf{e}'_u, \mathbf{e}''_u) = \frac{\mathbf{e}'_u \cdot \mathbf{e}''_u}{\max(\|\mathbf{e}'_u\| \cdot \|\mathbf{e}''_u\|, \varepsilon)} \quad (16)$$

其中, ε 为一个极小的数,防止分母为 0 而出现错误,在这里设置为 $\varepsilon = 10^{-6}$. 在使用余弦相似度作为衡量 Embed-

ding 的相似度指标之后,对于同一个用户其在原始图上经过聚合和更新操作后的向量表示和其在真实兴趣图上经过聚合和更新后的向量表示 $\{(\mathbf{e}'_u, \mathbf{e}''_u) | u \in U\}$, 将它们映射到“相似”标签;对于不同用户在原始图和真实兴趣图上经过聚合和更新后的向量表示 $\{(\mathbf{e}'_u, \mathbf{e}''_j) | u, j \in U, u \neq j\}$, 将它们映射到“不相似”标签. 所设计的损失函数定义如式(17)所示:

$$\text{loss}_{\text{user}} = \begin{cases} 1 - \text{similarity}(\mathbf{e}'_u, \mathbf{e}''_u), & \text{label} = 1 \\ \max(0, \text{similarity}(\mathbf{e}'_u, \mathbf{e}''_j)), & \text{label} = -1 \end{cases} \quad (17)$$

其中, label 为标签, label = 1 表示两个向量相似, label = -1 表示两个向量不相似. 同理,令来自原始的用户物品图的物品的向量表示为 \mathbf{e}'_v , 来自真实兴趣图的物品的向量表示为 \mathbf{e}''_v , 可以定义物品的向量表示相似损失函数,如式(18)所示:

$$\text{loss}_{\text{item}} = \begin{cases} 1 - \text{similarity}(\mathbf{e}'_v, \mathbf{e}''_v), & \text{label} = 1 \\ \max(0, \text{similarity}(\mathbf{e}'_v, \mathbf{e}''_k)), & \text{label} = -1 \end{cases} \quad (18)$$

最后可以得到自监督学习的损失函数,如式(19)所示:

$$\text{loss}_{\text{ssl}} = \text{loss}_{\text{user}} + \text{loss}_{\text{item}} \quad (19)$$

3.7 模型的训练

Denoising-GCN 分为两个任务,主要的推荐任务和辅助的自监督学习任务. 本文使用多任务训练^[19]的方式对模型进行优化,模型的总损失函数如式(20)所示:

$$L = L_{\text{main}} + \mu \text{loss}_{\text{ssl}} + \lambda \|\Theta\|_2^2 \\ = L_{\text{main}} + \mu(\text{loss}_{\text{user}} + \text{loss}_{\text{item}}) + \lambda \|\Theta\|_2^2 \quad (20)$$

其中, Θ 为模型的参数; μ 和 λ 为超参数,分别控制自监督学习的强度和正则化的强度.

4 实验与分析

为了评估所提出模型的有效性,在两个公开数据集上进行实验. 主要回答了以下问题.

RQ1: 相对于基线方法, Denoising-GCN 在两个数据集上的表现如何?

RQ2: Denoising-GCN 带有三个超参数,不同的超参数会如何影响其性能?

RQ3: 基于用户真实兴趣感知的图增强手段对 Denoising-GCN 性能的贡献如何?

RQ4: 所提出的用户向量表示融合模块对 Denoising-GCN 性能的贡献如何?

4.1 实验环境与数据集

使用 PyTorch 实现了 Denoising-GCN, 并在戴尔 XPS 8950 上执行训练. 戴尔 XPS 8950 配备了 24 核 Intel i9-

12900K 处理器和一块 24 GB 内存的 Nvidia GeForce RTX 3090 GPU.

所使用的两个数据集均为社交推荐的基准数据集. 这两个数据集详细的统计信息如表 1 所示.

表 1 数据集统计表

统计项	lastfm	ciao
用户数	1 892	7 375
物品数	17 632	105 114
交互关系数	92 834	284 086
社交关系数	25 434	57 544
稀疏度(交互关系)	99.72%	99.96%
稀疏度(社交关系)	99.29%	99.89%

Lastfm 数据集^[23]是从社交音乐平台 lastfm (<https://www.last.fm/>)上收集的. 用户可以为艺术家的音乐进行评分,评分行为可以看作是隐式反馈,评分可以看作是偏好. 同时,用户可以根据自己的偏好建立社交关系. ciao^[23]数据集是从英国的消费者评论网站 ciao (<https://www.ciao.co.uk/>)上收集的. 该数据集包含了 730 万个用户和 111.7 万条社交关系. 将每个数据集按 4:1 的比例分为训练集和测试集,并且选择成对学习的方法:将数据集中存在的交互行为视为正样本,随机从数据集中采样一个不存在的即未被用户交互过的样本作为负样本.

4.2 基线方法与实验设置

为了验证所提出的模型的有效性,本文选择以下推荐模型进行对比:

(1)BPR^[22]:BPR 是一种基于 CTR 预估的推荐算法. BPR 采用了概率建模的方法,将推荐任务看作是一个二元分类问题进行建模.

(2)LightGCN^[11]:LightGCN 是一种轻量图卷积神经网络,它舍弃了图卷积神经网络中的激活函数、自连接和转移矩阵,可以更加高效地捕捉用户之间的相似性,从而提升推荐系统的性能.

(3)DiffNet^[8]:DiffNet 是基于图神经网络的社交推荐模型,它考虑用户的历史行为和社交关系,利用图嵌入技术学习用户和物品的向量表示,并通过影响扩散传播用户的兴趣.

(4)SocialLGN^[12]:SocialLGN 引入社交关系到 LightGCN 中,增强用户的向量表示,并采用融合策略融合来自不同图的用户向量表示,取得了很好的准确性.

(5)SGA^[24]:SGA 是一种图神经网络社交图注意力聚合模型. 它利用社交网络获取用户之间的协作信息,并采用自注意力机制来建模用户-物品交互中的重要性差异. SGA 适用于并行训练,从而提高推荐系统的效率,这是神经网络部署的机器学习模型的常见瓶颈.

使用 Adam 优化器^[25],学习率为 0.001 来优化所提

出的模型. 设置用户和物品的 Embedding 大小为 64,训练的批次量大小为 2 048.

使用三个指标来评估模型和基准模型在 Top-K 上的表现,分别是精度(Precision)、召回率(Recall)和标准化折扣累积收益(Normalized Discounted Cumulative Gain, NDCG),这些指标广泛用于 Top-K 推荐任务.

Recall@20:对于每个用户,将预测的前 20 个物品与其实际交互的物品进行比较,计算其交集并将其除以实际交互的物品总数. 计算所有用户的平均值,并将其称为 Recall@20 值.

NDCG@20:与 Recall@20 类似,但是对于每个用户,将交互的物品按照评分的高低排序,然后计算预测的前 20 个物品的 DCG 值和实际交互的物品的 DCG 值. 将这些值归一化并计算其平均值,称之为 NDCG@20 值.

Precision@20:对于每个用户,将预测的前 20 个物品与其实际交互的物品进行比较,计算其交集并将其除以预测的物品总数. 计算所有用户的平均值,并将其称为 Precision@20 值.

4.3 实验结果分析

如表 2 所示,通过观察可以得到以下结论:

(1)所提模型在两个数据集上的所有评价指标均高于其他模型,Denosing-GCN 的推荐效果相对于次优模型 SocialLGN 提升了 1.18%~7.32%.

(2)Denosing-GCN 模型通过基于用户真实兴趣感知的图降噪模块和自监督学习模块减少用户历史交互行为中噪声的影响,学习到较优的用户和物品向量表示,进而提升了推荐结果的准确性.

4.4 参数敏感性分析

本文提出的模型 Denosing-GCN 总共有三个超参数,分别是正则化强度 λ 、自监督学习损失函数的权重 μ 和百分位数 threshold. 本节研究这三个超参数对 Denosing-GCN 性能的影响.

(1)自监督学习强度对模型性能的影响

首先,设置 $\lambda=0.001$ 和 $\text{threshold}=75$,在 λ 和 threshold 保持不变的情况下,从 $\{0.0001, 0.001, 0.01, 0.1\}$ 改变自监督学习损失函数的权重 μ 的值,通过观察模型的性能表现来研究自监督学习的强度 μ 对 Denosing-GCN 性能的影响. 由图 3 可以看出,随着自监督学习权重的增加,Denosing-GCN 的性能先增加再下降. 这是因为自监督学习利用数据中的自身信息学习有用的特征表示,如果自监督学习的权重过小,会导致推荐模型忽略自监督学习的损失,从而导致模型的性能下降;另一方面,如果自监督学习的权重过大,会导致推荐模型过度依赖自监督学习的损失,导致模型忽略了其他特征的学习,从而引起推荐模型性能的下降.

表 2 所提模型与其他模型的性能比较

数据集	lastfm			ciao		
	Recall@20	NDCG@20	Precision@20	Recall@20	NDCG@20	Precision@20
BPR	0.149 9	0.132 1	0.072 0	0.033 9	0.026 0	0.011 1
LightGCN	0.276 9	0.278 8	0.135 8	0.059 1	0.047 8	0.020 2
DiffNet	0.248 8	0.247 4	0.121 5	0.052 7	0.040 3	0.018 2
SGA	0.249 7	0.272 3	0.071 2	—	—	—
SocialLGN	<u>0.279 4</u>	<u>0.288 3</u>	<u>0.136 8</u>	<u>0.061 8</u>	<u>0.048 6</u>	<u>0.020 5</u>
Denoising-GCN	0.289 6	0.291 7	0.142 1	0.064 0	0.050 4	0.022 0
improve/%	3.65	1.18	3.87	3.56	3.70	7.32

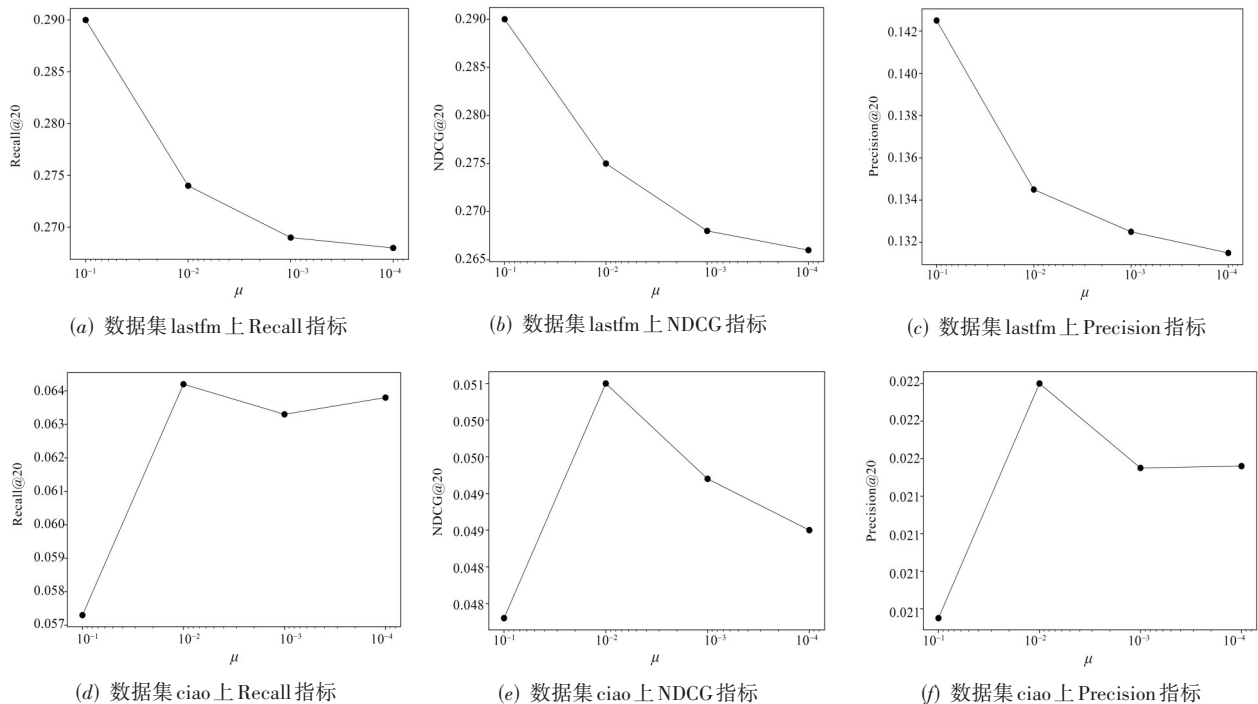


图 3 两个数据集上自监督学习强度对模型性能的影响

(2) 正则化强度对模型性能的影响

设置 $\mu=0.1$ 和 $\text{threshold}=75$, 在 μ 和 threshold 保持不变的情况下, 改变 λ 的值, 通过观察模型的性能表现以研究不同的正则化强度 λ 对 Denoising-GCN 性能的影响. 图 4 为不同的正则化强度对 Denoising-GCN 的影响, 由图 4 可以看出, 随着正则化强度权重的增加, Denoising-GCN 的性能先增加再下降. 这是因为正则化强度 λ 越高, 模型的参数的值越小, 模型的预测结果就越准确, 因此模型的性能也就越好. 但是, 如果正则化强度 λ 太高, 参数的值就会变得太小, 从而导致模型出现过拟合, 这样就会使 Denoising-GCN 性能变差. 正则化强度太大或太小, 都将对模型产生负面影响. 当正则化强度为 $\lambda=0.1$ 时, Denoising-GCN 会受到过度的约束, 因此模型的性能下降. 当正则化强度为 $\lambda=0.000 1$ 时, Denoising-GCN 很容易受到过拟合, 降低了模型的泛化能力, 从而

影响了模型的性能.

(3) 百分位数对模型性能的影响

设置 $\mu=0.000 1$, $\lambda=0.1$, 在 λ 和 μ 保持不变的情况下, 从 $\{85, 75, 50, 25, 15\}$ 改变百分位数 threshold 的值, 通过观察模型的性能变化情况来研究在生成基于用户真实兴趣的用户物品图时百分位数 threshold 对 Denoising-GCN 的影响 (也即注意力阈值 T 对 Denoising-GCN 的影响). 为了方便观察, 对模型和 SocialLGN 在两个数据集上的结果进行了最大最小归一化处理, 由图 5 可以看出, 百分位数 threshold 会影响 Denoising-GCN 的性能, 但总体来说, 即使采用了不同的 threshold , Denoising-GCN 的性能仍比 SocialLGN 要好一些. 这是因为不同的百分位数 threshold 代表不同的注意力阈值 T , 也代表着本节提出的用户真实兴趣的阈值. 百分位数 threshold 越大, 意味着用户的历史交互行为中的大部分并不能反映出用

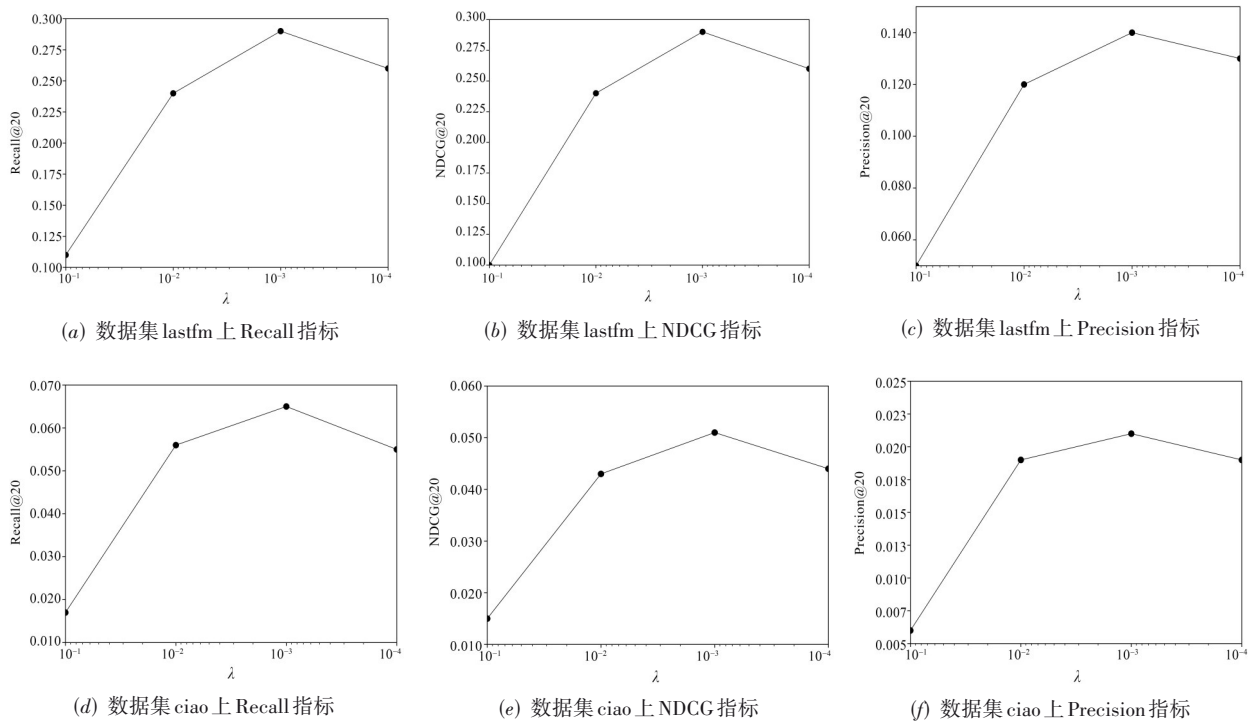


图4 两个数据集上正则化强度对模型性能的影响

用户的真实兴趣,这些交互行为将被舍弃;百分位数 threshold 越小,意味着用户的历史交互行为中的小部分并不能反映用户的真实兴趣. 百分位数的选择应该与数

据集相关,将这部分内容留作以后的工作继续探究.

4.5 消融实验

为了分析模型中模块对整体模型的重要性,设计

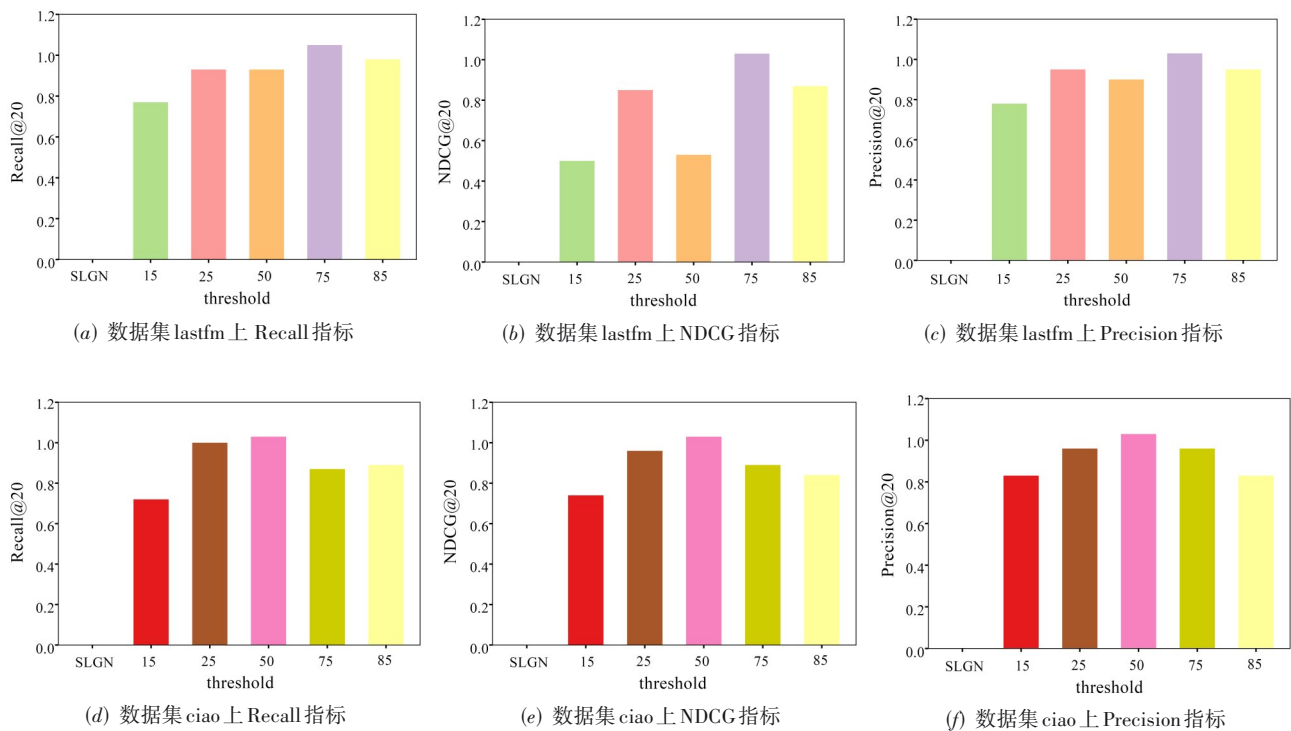


图5 两个数据集上 threshold 对模型性能的影响

以下消融实验.

Denoising-GCN-0:该变体模型去除了自监督学习模块,以验证自监督学习模块的作用.

Denoising-GCN-1:该变体模型改变了自监督学习策略,从另一个角度验证自监督学习模块的作用.

Denoising-GCN-2:该变体模型将所提用户向量融合模块替换为加权和,以验证所提融合模块的作用.

Denoising-GCN-3:该变体模型更改了降噪图的生成模式,以验证基于用户真实兴趣感知的图降噪模块的作用.

表3列出了变体模型和原始模型的性能表现,其中最好的结果加粗表示,第二好的结果用下划线表示.由表3可以看出,Denoising-GCN-0去掉了基于真实兴趣感知的图增强模块和自监督学习模块,其性能表现并不如Denoising-GCN,这说明本文所提基于真实兴趣感知的图增强模块和自监督学习模块确实对Denoising-GCN的性能有积极作用.Denoising-GCN-1的性能与原始的Denoising-GCN的性能接近,这是因为Denoising-GCN-1在自监督学习阶段不再使用原始的用户物品图与增强后的真实兴趣图作为自监督信号,而是采用两个不同的百分位数threshold得到两个不同的注意力阈值,进而得到两个基于不同兴趣强度的增强图.用户和物品在不同兴趣强度的增强图上进行聚合和更新后的向量表示作为自监督信号进行辅助训练.Denoising-GCN-1的性能从另一个角度验证了基于用户真实兴趣感知的图降噪模块和自监督学习模块的作用.将所提出的用户向量表示融合模

块替换为加权和之后,模型Denoising-GCN-2的性能下降,这验证了融合模块对模型的积极作用.Denoising-GCN-3改变了降噪图的生成模式,得到的注意力矩阵 W' 不再与原始的用户物品图进行元素积,直接使用 W' 作为降噪图.可见Denoising-GCN-3的性能并不如原始的模型.这验证了用户真实兴趣感知的图降噪模块的作用.

4.6 扩展实验与分析

本节进一步验证Denoising-GCN和Denoising-GCN-1的性能差异.原始模型使用原始的用户物品图与增强后的真实兴趣图作为自监督信号;而Denoising-GCN-1采用两个不同的注意力阈值得到的基于不同兴趣强度的增强图作为自监督信号.Denoising-GCN-1采用与原始模型相同的训练方式,不同的自监督信号.

在Douban^[26]和Yelp(<https://www.yelp.com/dataset>)两个新的数据集上对Denoising-GCN和Denoising-GCN-1进行了实验.由表4可以看出,Denoising-GCN-1在某些指标上表现优于Denoising-GCN,尤其是在Yelp数据集上,这验证了基于不同兴趣强度的增强图作为自监督信号的有效性.

Denoising-GCN-1在新的数据集上表现更优,这可能是因为两种不同强度的增强图能够更有效地捕捉用户的多样化兴趣,从而提升模型的学习能力.相比之下,Denoising-GCN虽然也利用了增强图,但仅对比增强图与未增强图,可能限制了其自监督学习的效果.未来的研究可以进一步探索不同的图增强策略,以优化自监督信号的生成,提高模型的泛化能力.

表3 Denoising-GCN和变体模型在两个数据集上的表现

数据集	lastfm			ciao		
	Recall@20	NDCG@20	Precision@20	Recall@20	NDCG@20	Precision@20
Denoising-GCN-0	0.267 0	0.265 3	0.130 7	0.062 6	0.048 3	0.021 3
Denoising-GCN-1	<u>0.288 6</u>	<u>0.290 1</u>	<u>0.141 7</u>	0.064 2	0.050 4	<u>0.021 8</u>
Denoising-GCN-2	0.266 3	0.268 1	0.130 6	0.060 5	0.047 5	0.020 8
Denoising-GCN-3	0.270 9	0.272 4	0.132 9	—	—	—
Denoising-GCN	0.289 6	0.291 7	0.142 1	<u>0.064 0</u>	0.050 4	0.022 0
SocialLGN	0.279 4	0.288 3	0.136 8	0.061 8	0.048 6	0.020 5

表4 Denoising-GCN和Denoising-GCN-1模型在两个数据集上的表现

数据集	Douban			Yelp		
	Recall@20	NDCG@20	Precision@20	Recall@20	NDCG@20	Precision@20
Denoising-GCN-1	0.081 4	0.327 6	0.301 1	0.109 1	0.085 0	0.041 2
Denoising-GCN	0.081 5	0.327 8	0.300 9	0.108 4	0.084 7	0.041 1

5 总结

本文旨在解决基于图神经网络社交推荐系统中隐式反馈降噪和来自两种图的用户表示具有异质性的问题,提出了基于自监督图卷积和注意力机制实现隐式反

馈降噪的社交推荐模型.该模型旨在从用户隐式的历史交互行为中捕捉用户的真实兴趣,并使用用户的社交关系增强用户的表示.两个公开的数据集上的大量实验验证了所提模型的有效性.为了促进研究的复现和进一步

发展,我们已将本文中的源代码公开在 GitHub 上: <https://github.com/hsianghsing/Denoising-GCN>. 然而,本文的方法也存在一些不足之处,需要在未来的研究加以改进. 不同数据集可能需要采用不同的自监督学习强度和兴趣百分位数,这两个超参数的搜索过程耗费大量时间,增加了模型训练的复杂度和计算成本. 自监督学习和对比学习需要大量计算资源,尤其是在处理大规模数据集时,训练时间和内存需求较高,可能限制了模型在实际应用中的可行性. 在未来的研究工作中,我们将针对这两个方面对模型进行优化.

参考文献

- [1] 黄璐, 林川杰, 何军, 等. 融合主题模型和协同过滤的多样化移动应用推荐[J]. 软件学报, 2017, 28(3): 708-720.
HUANG L, LIN C J, HE J, et al. Diversified mobile app recommendation combining topic model and collaborative filtering[J]. Journal of Software, 2017, 28(3): 708-720. (in Chinese)
- [2] 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.
HUANG L W, JIANG B T, LV S Y, et al. Survey on deep learning based recommender systems[J]. Chinese Journal of Computers, 2018, 41(7): 1619-1647. (in Chinese)
- [3] GAO C, WANG X, HE X N, et al. Graph neural networks for recommender system[C]//Proceedings of the Fifteenth ACM International Conference on Web Search and Data Mining. New York: ACM, 2022: 1623-1625.
- [4] 张帅, 高旻, 文俊浩, 等. 基于自监督学习的去流行度偏差推荐方法[J]. 电子学报, 2022, 50(10): 2361-2371.
ZHANG S, GAO M, WEN J H, et al. Self-supervised learning for alleviating popularity bias in recommender systems[J]. Acta Electronica Sinica, 2022, 50(10): 2361-2371. (in Chinese)
- [5] 曹阳, 高旻, 余俊良, 等. 基于双图混合随机游走的社会化推荐模型[J]. 电子学报, 2023, 51(2): 286-296.
CAO Y, GAO M, YU J L, et al. Bi-graph mix-random walk based social recommendation model[J]. Acta Electronica Sinica, 2023, 51(2): 286-296. (in Chinese)
- [6] TANG J L, HU X, LIU H. Social recommendation: A review[J]. Social Network Analysis and Mining, 2013, 3(4): 1113-1133.
- [7] SHARMA K, LEE Y C, NAMBI S, et al. A survey of graph neural networks for social recommender systems[J]. ACM Computing Surveys, 2024, 56(10): 1-34.
- [8] WU L, SUN P J, FU Y J, et al. A neural influence diffusion model for social recommendation[C]//Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2019: 235-244.
- [9] WU L, LI J W, SUN P J, et al. DiffNet: A neural influence and interest diffusion network for social recommendation[J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 34(10): 4753-4766.
- [10] YANG L W, WANG S J, TAO Y Z, et al. DGRec: Graph neural network for recommendation with diversified embedding generation[C]//Proceedings of the Sixteenth ACM International Conference on Web Search and Data Mining. New York: ACM, 2023: 661-669.
- [11] HE X N, DENG K, WANG X, et al. LightGCN: Simplifying and powering graph convolution network for recommendation[C]//Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2020: 639-648.
- [12] LIAO J, ZHOU W, LUO F J, et al. SocialLGN: Light graph convolution network for social recommendation[J]. Information Sciences, 2022, 589: 595-607.
- [13] KOREN Y. Factorization meets the neighborhood: A multifaceted collaborative filtering model[C]//Proceedings of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2008: 426-434.
- [14] 陈碧毅, 黄玲, 王昌栋, 等. 融合显式反馈与隐式反馈的协同过滤推荐算法[J]. 软件学报, 2020, 31(3): 794-805.
CHEN B Y, HUANG L, WANG C D, et al. Explicit and implicit feedback based collaborative filtering algorithm[J]. Journal of Software, 2020, 31(3): 794-805. (in Chinese)
- [15] WANG W J, FENG F L, HE X N, et al. Denoising implicit feedback for recommendation[C]//Proceedings of the 14th ACM International Conference on Web Search and Data Mining. New York: ACM, 2021: 373-381.
- [16] WEI Y W, WANG X, NIE L Q, et al. Graph-refined convolutional network for multimedia recommendation with implicit feedback[C]//Proceedings of the 28th ACM International Conference on Multimedia. New York: ACM, 2020: 3541-3549.
- [17] 于旭, 何亚东, 杜军威, 等. 一种结合显式特征和隐式特征的开发者混合推荐算法[J]. 软件学报, 2022, 33(5): 1635-1651.
YU X, HE Y D, DU J W, et al. Developer hybrid recommendation algorithm based on combination of explicit features and implicit features[J]. Journal of Software,

- 2022, 33(5): 1635-1651. (in Chinese)
- [18] JAISWAL A, BABU A R, ZADEH M Z, et al. A survey on contrastive self-supervised learning[J]. Technologies, 2021, 9(1): 2.
- [19] WU J C, WANG X, FENG F L, et al. Self-supervised graph learning for recommendation[C]//Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2021: 726-735.
- [20] ZHANG Y S, HUANG J J, LI M, et al. Contrastive graph learning for social recommendation[J]. Frontiers in Physics, 2022, 10: 830805.
- [21] LIU Z, MA Y P, OUYANG Y X, et al. Contrastive learning for recommender system[EB/OL]. (2021-01-05)[2023-04-04]. <https://arxiv.org/abs/2101.01317v1>.
- [22] RENDLE S, FREUDENTHALER C, GANTNER Z, et al. BPR: Bayesian personalized ranking from implicit feedback[EB/OL]. (2012-05-09)[2023-04-04]. <https://arxiv.org/abs/1205.2618v1>.
- [23] CANTADOR I, BRUSILOVSKY P, KUFLIK T, et al. Second workshop on information heterogeneity and fusion in recommender systems (HetRec2011)[C]//Proceedings of the Fifth ACM Conference on Recommender Systems. New York: ACM, 2011: 387-388.
- [24] LIUFU Y W, SHEN H. Social recommendation via graph attentive aggregation[M]//Parallel and Distributed Computing, Applications and Technologies. Cham: Springer International Publishing, 2022: 369-382.
- [25] KINGMA D P, BA J, HAMMAD M M. Adam: A method for stochastic optimization[EB/OL]. (2017-01-30)[2023-04-04]. <https://arxiv.org/abs/1412.6980v9>.
- [26] ZHU F, CHEN C C, WANG Y, et al. DTCDR: A framework for dual-target cross-domain recommendation[C]//Proceedings of the 28th ACM International Conference on Information and Knowledge Management. New York: ACM, 2019: 1533-1542.

作者简介



郭向星 男,1995年生,重庆大学大数据与软件学院硕士研究生. 主要研究方向为推荐系统、自监督学习.

E-mail: guoxiangxing@cqu.edu.cn



文俊浩 男,1969年生,工学博士,重庆大学大数据与软件学院教授. 主要研究方向为计算智能、推荐系统.

E-mail: jhwen@cqu.edu.cn



周 魏 男,1987年生,工学博士,重庆大学大数据与软件学院副教授、博士生导师. 主要研究方向为推荐系统、信息检索、机器学习.

E-mail: zhouwei@cqu.edu.cn



杨佳佳 女,1999年生,重庆大学大数据与软件学院硕士研究生. 主要研究方向为服务计算、数字孪生、智能制造.

E-mail: yangjiajia@stu.cqu.edu.cn



杨正益 男,1979年生,工学博士,重庆大学大数据与软件学院副教授. 主要研究方向为服务计算、工业物联网、大数据分析.

E-mail: zyyang@cqu.edu.cn



刘 蔓 女,1983年生,中国移动通信集团重庆有限公司工程师. 主要研究方向为通信服务与智能推荐.

E-mail: liuman1@139.com