

# 基于偏好感知的去噪图卷积网络社交推荐

杨兴耀<sup>1</sup>, 马帅<sup>1</sup>, 张祖莲<sup>2</sup>, 于炯<sup>1</sup>, 陈嘉颖<sup>1</sup>, 王东晓<sup>1</sup>

(1. 新疆大学软件学院, 新疆 乌鲁木齐 830091; 2. 新疆维吾尔自治区气象局新疆兴农网信息中心, 新疆 乌鲁木齐 830002)

**摘要:** 协同过滤推荐通常面临用户-项目交互数据稀疏的挑战, 社交推荐引入用户社交关系来缓解数据稀疏性问题。多数基于图神经网络(GNN)的社交推荐系统在消息传递过程中无法根据用户偏好聚合高阶邻居信息, 造成嵌入表示过平滑和噪声问题。针对上述问题, 提出一种基于偏好感知的去噪图卷积网络的社交推荐模型 PD-GCN。使用无监督学习将具有相似偏好的用户分配到用户-项目交互子图和社交子图, 在子图上进行更高阶的图卷积运算, 缓解了现有模型的过平滑问题。从全局和局部的角度出发, 通过考虑相同偏好用户节点的特征相似度和邻域节点偏好分布多样性识别并去除噪声节点, 增强模型对用户-项目交互和社交关系噪声的鲁棒性。在 LastFM、Ciao、Yelp 3 个公共数据集上的实验结果表明, PD-GCN 模型在召回率和归一化折损累计增益两个指标上相较于其他主流模型表现出更优的性能, 验证了 PD-GCN 模型的有效性。

**关键词:** 社交推荐; 图卷积网络; 过平滑; 用户偏好; 推荐系统

中图分类号: TP18

文献标志码: A

DOI: 10.19678/j.issn.1000-3428.0068748

## Social Recommendation Based on Preference-Aware Denoising Graph Convolutional Networks

YANG Xingyao<sup>1</sup>, MA Shuai<sup>1</sup>, ZHANG Zulian<sup>2</sup>, YU Jiong<sup>1</sup>, CHEN Jiaying<sup>1</sup>, WANG Dongxiao<sup>1</sup>

(1. School of Software, Xinjiang University, Urumqi 830091, Xinjiang, China;

2. Xinjiang Xingnong Network Information Center, Meteorological Bureau of Xinjiang Uygur Autonomous Region, Urumqi 830002, Xinjiang, China)

**【Abstract】** The issue of sparsity in user-item interaction data is commonly encountered in the generation of collaborative filtering recommendations. To address this issue, social recommendations introduce users' social relationships. However, several social recommendation systems based on Graph Neural Network (GNN) cannot aggregate high-order neighbor information according to user preferences during the message-passing process, which leads to embedding oversmoothing and noise. To solve these problems, this study proposes a social recommendation model based on preference-aware denoising Graph Convolution Network (GCN), known as PD-GCN. This model employs unsupervised learning to allocate users with similar preferences to social and user-item interaction subgraphs. Higher-order graph convolution operations are performed within these subgraphs to mitigate the oversmoothing problems observed in existing models. Considering global and local perspectives, the model identifies and removes noisy nodes by weighing the feature similarity among nodes with the same preferences and diversity of neighborhood node preference distributions, thereby enhancing the robustness of the model against noise in user-item interaction and social relationships. Experimental results on three public datasets (LastFM, Ciao, and Yelp) show that the proposed model performs better than other mainstream models in terms of Recall and Normalized Discounted Cumulative Gain (NDCG), verifying the effectiveness of the PD-GCN model.

**【Key words】** social recommendation; Graph Convolution Network (GCN); oversmoothing; user preference; recommendation system

## 0 引言

移动互联网的繁荣发展极大地促进了信息的交流和传播, 网络信息量呈指数级增长。然而, 当面对海量信息时, 用户很难获得与他们相关的对他们有

帮助的信息, 这种现象被称为信息过载。为缓解信息过载问题, 研究者们对推荐系统进行了大量研究, 其中, 协同过滤<sup>[1-2]</sup>是一种流行且有效的推荐方法, 通过大量的用户交互数据捕获相似用户的偏好来建模目标用户的偏好, 并向用户推荐可能感兴趣的项

收稿日期: 2023-11-01 修回日期: 2023-12-23

基金项目: 国家自然科学基金(62262064, 61862060); 新疆维吾尔自治区自然科学基金面上项目(2023D01C17, 2023D01A123, 2022D01C692); 新疆维吾尔自治区自然科学基金资源共享平台建设项目(PT2323); 新疆维吾尔自治区气象局引导项目(YD202212)。

通信作者 E-mail: yangxy@xju.edu.cn

目。然而,当交互数据不足时,数据稀疏问题会严重制约模型的性能。受到社会同质性<sup>[3]</sup>和社会影响力<sup>[4]</sup>的启发,在推荐中利用社交关系可以取得良好的效果。社会同质性是指用户倾向于将自己与其他具有相似偏好的用户联系起来。社会影响力是指具有直接或间接关系的用户倾向于相互影响,使自己与有社交关系的用户更加相似。因此,社交推荐可以通过社交邻居来捕获稀疏交互用户的偏好,从而有效地缓解数据稀疏性问题<sup>[5]</sup>。

由于用户与项目之间的交互和用户社交关系可以建模为图结构,随着深度学习技术的迅速发展,将图神经网络(GNN)<sup>[6-8]</sup>应用于推荐领域的方法越来越多。在图卷积网络(GCN)中,节点的嵌入受到其邻接节点的影响,通过多层卷积操作,节点能够获取高阶邻居的协作信号。NGCF<sup>[9]</sup>使用多层图卷积来学习节点之间的交互信息,在每一层用户和项目的嵌入向量会根据其在图中的邻居节点的嵌入向量进行更新,这使得模型可以捕捉用户和项目之间的复杂关系。DiffNetLG<sup>[10]</sup>中的用户偏好同时受到可观察的显性和未观察到的隐性社会的影响,并利用 GNN 学习异质图上的用户表示。

尽管上述基于 GNN 的方法在社交推荐领域表现出了良好的性能,但仍存在许多问题。NGCF 和 DiffNetLG 模型中的 GCN 框架经过多次迭代的卷积操作会导致原始图中局部特征丧失,产生过平滑问题。IMP-GCN<sup>[11]</sup>虽然通过兴趣感知机制缓解了过平滑问题,但是同时也加大了噪声数据对推荐性能的不利影响。社交推荐模型的噪声问题主要来自社会噪声和交互噪声。一方面,在现实中用户的社交关系是嘈杂的,但社交关系在推荐系统中会被不加区分使用;另一方面,在用户与项目交互过程中产生的交互数据也可能存在噪声,例如流行项目偏差、诱导性广告、浏览与购买差异等问题<sup>[12]</sup>。

为解决上述问题,本文提出基于偏好感知的去噪图卷积网络的社交推荐模型 PD-GCN。该模型首先使用无监督学习,根据用户偏好将用户-项目交互图和社交图同步划分为多个子图,缓解了用户和项目嵌入在多层图卷积后出现的过平滑问题,为减轻子图中噪声节点的负面影响,设计一种结合全局和局部信息的降噪策略,根据用户特征、交互子图和社交子图信息,使用相同偏好节点特征相似度测量器和局部节点偏好分布多样性测量器准确地寻找并去除噪声节点;然后在子图中执行图卷积操作,使得模型能更好地进行用户特征的聚合和表示;最后,在 3 个公共数据集上进行实验,以评估 PD-GCN 模型

的推荐性能。

## 1 相关工作

### 1.1 社交推荐

为了应对大数据时代的数据稀疏性问题,社交关系日益成为提高推荐系统性能的一个重要因素。传统的社交推荐模型通常基于用户之间的社交影响和社交关联来建模,其核心思想是互相关联的用户通常具有相似的行为偏好,而这些具有相似行为偏好的用户倾向于建立联系。传统的社交推荐算法通常采用矩阵分解框架将社交信息纳入推荐过程<sup>[13]</sup>。SoRec<sup>[14]</sup>通过共享潜在用户特征矩阵,执行评级矩阵和关系矩阵的协作分解,从而整合了用户和用户评级之间的信任关系。SBPR<sup>[15]</sup>是一种成对的贝叶斯个性化排名(BPR)模型,它定义了一种称为“社会反馈”的新类别来表示社交网络中的信息。SocialMF<sup>[16]</sup>将信任传播机制融入矩阵分解框架,使得社交网络中每个用户及其邻居的特征向量更加接近。TrustSVD<sup>[17]</sup>同时考虑评分项目和结合受信任用户的显式和隐式影响,对未知项目进行评分预测。为了更好地捕捉间接社交关系,联合推荐模型 InSRMF<sup>[18]</sup>被提出,该模型结合了间接社交关系检测和矩阵分解,以提取有价值的间接关系,显著提高了推荐性能。此外,为了减轻仅使用显式数据的局限性,TSSR<sup>[19]</sup>结合评级矩阵和社交关系来提取隐式数据。虽然现有的社交推荐模型利用用户社交网络的信息获得用户特征向量,在一定程度上缓解了协同过滤方法面临的数据稀疏性问题,但是没有考虑高阶社交关系以及用户和项目的高阶非线性特征,无法为社交关系以及用户和项目之间的复杂交互提供更细粒度的建模。

### 1.2 GNN

GNN 是一种用于处理图结构数据的深度学习模型,在生物信息、交通网络等领域有广泛的应用<sup>[20]</sup>。GCN 通过聚合和传播邻居节点的特征信息,能够为图中的每个节点提供更丰富的表征。由于用户与项目之间的交互以及用户社交关系可以被视为图结构,因此 GNN 在推荐领域具有天然的优势<sup>[21]</sup>。在此背景下,涌现出了许多基于 GNN 的社交推荐模型。GraphRec<sup>[22]</sup>是使用 GNN 的社交推荐系统模型,它结合两个图中用户的一阶邻居信息,以学习用户的表示。在 DiffNet<sup>[23]</sup>模型的基础上,DiffNet++<sup>[24]</sup>额外利用交互图中的高阶信息来优化用户和项目的表示,并使用注意力机制来区分不同邻居的重要性。DISGCN<sup>[25]</sup>利用基于 GCN 的嵌入传播机制,从社会

同质性和社会影响两个方面捕捉社交图中的高阶信息,并通过对比学习确定社会影响力。SocialLGN<sup>[26]</sup>扩展了 LightGCN<sup>[7]</sup>模型,在交互图和社交图上应用图卷积操作,以提高模型处理社交推荐问题的有效性。DeRec<sup>[27]</sup>通过一个解纠缠的对比学习框架来建模用户在社交领域和项目领域的异质行为模式,分别从两个领域中学习用户表示,从而获得更精确的用户和项目表示。RobustSR<sup>[28]</sup>利用一个具有社会正则化和多视角对比学习机制的用户表示学习框架学习社交关系重要性权重,并强制用户表示具有区别性。这些方法利用社交邻居的高阶关系丰富了用户特征表示,在一定程度上能够缓解协同过滤中的数据稀疏问题,但它们没有明确考虑用户-项目交

互图和社交图中的噪声影响。本文建立基于全局和局部信息的降噪模块,增强了模型对噪声节点的鲁棒性。由于在 GCN 中不加选择地聚合邻居的协作信号,当卷积层数增加时节点嵌入变得更加相似,会出现过平滑问题,因此 PD-GCN 引入无监督子图生成模块避免从高阶邻域传播负面信息到嵌入学习过程中,有效地缓解了 GCN 中的过平滑问题。

## 2 PD-GCN 模型

PD-GCN 模型主要包括子图生成、节点降噪、偏好传播、训练与预测 4 个部分,模型整体架构如图 1 所示(彩色效果见《计算机工程》官网 HTML 版,下同)。




图 1 PD-GCN 架构

Fig. 1 PD-GCN architecture

### 2.1 问题定义

设  $U = \{u_1, u_2, \dots, u_m\}$ 、 $I = \{i_1, i_2, \dots, i_n\}$  分别为推荐系统中用户和项目的集合,其中,  $m$  为用户数量,  $n$  为项目数量。用户、项目及其关系通常由用户-项目交互图和社交图表示。定义用户-项目交互图  $G_I = \{(u, y_{ui}, i) \mid u \in U, i \in I\}$ , 其中, 边  $y_{ui} = 1$  表示用户  $u$  与项目  $i$  之间存在交互, 否则  $y_{ui} = 0$ 。定义社交图  $G_S = \{(u_i, s_{ij}, u_j) \mid u_i, u_j \in U\}$ , 其中, 边  $s_{ij} = 1$  表示用户  $u_i$  和  $u_j$  之间存在社交连接, 否则  $s_{ij} = 0$ 。基于上述输入, 社交推荐任务被描述如下: 给定用户-项目交互图  $G_I$  和社交图  $G_S$ , 预测用户  $u$  与所有项目  $i$  之间的交互概率, 按降序对其进行排序, 并选择前  $N$  个项目来为用户  $u$  生成推荐列表。

### 2.2 子图生成

本节将介绍交互子图和社交子图生成模块, 该

模块用于对给定的交互图  $G_I$  和社交图  $G_S$  分别构造子图  $G_{I,s}$  和  $G_{S,s}$ , 其中  $s \in \{1, 2, \dots, N_s\}$ 。将偏好相同的用户分类到同一子图, 保证子图中的用户对彼此的协作信号是积极的。使用一个 3 层的多层感知机对用户进行无监督分类学习:

$$\mathbf{O}_1 = \sigma(\mathbf{W}_1(\mathbf{e}_u^{(0)} + \mathbf{e}_u^{(1)}) + \mathbf{b}_1)$$

$$\mathbf{O}_2 = \sigma(\mathbf{W}_2\mathbf{O}_1 + \mathbf{b}_2)$$

$$\mathbf{L}_p = \mathbf{W}_3\mathbf{O}_2 + \mathbf{b}_3 \quad (1)$$

式中:  $\mathbf{e}_u^{(0)}$  为用户的初始 ID 嵌入;  $\mathbf{e}_u^{(1)}$  为用户通过聚合交互图和社交图的邻居得到的第 1 层嵌入;  $\mathbf{W}_1 \in \mathbb{R}^{d \times d}$ 、 $\mathbf{W}_2 \in \mathbb{R}^{d \times d}$  和  $\mathbf{W}_3 \in \mathbb{R}^{d \times N_s}$  分别是第 1 层、第 2 层和第 3 层感知机的可训练权重;  $\mathbf{b}_1 \in \mathbb{R}^{1 \times d}$ 、 $\mathbf{b}_2 \in \mathbb{R}^{1 \times d}$  和  $\mathbf{b}_3 \in \mathbb{R}^{1 \times N_s}$  分别是第 1 层、第 2 层和第 3 层感知机的偏置向量;  $\sigma$  为 LeakyReLU 激活函数;  $\mathbf{O}_1$ 、 $\mathbf{O}_2$  和  $\mathbf{L}_p$  分别是第 1 层、第 2 层和第

3 层感知机的输出向量,  $L_P$  中最大值的位置表示用户所属的子图。

子图生成的目的是根据用户分组结果和原始交互图和用户社交图的拉普拉斯矩阵, 分别构造表示邻接关系的用户-项目子图和社交子图矩阵。每个用户仅在一个子图中, 在交互子图中包含这个偏好组中的用户及其交互的项目, 在社交图中包含与其有社交关系的用户。

### 2.3 节点降噪

为解决子图中存在的噪声问题, 设计一种结合全局和局部信息的降噪策略, 分为局部噪声测量器  $D_{\text{local}}$  和全局噪声测量器  $D_{\text{global}}$ 。

在通过无监督训练获得偏好分类向量  $L_P$  之后, 将每一行的最大值所在的列索引存储在  $Y$  数组中:

$$Y[i] = \underset{j}{\operatorname{argmax}}(L_P[i][j]) \quad (2)$$

对于社交子图中的每个用户节点  $u$ , 计算其局部节点偏好分布的多样性:

$$P_s(u) = \frac{|\{Y[v]=s \mid v \in \hat{N}(u)\}|}{|\hat{N}(u)|} \quad (3)$$

$$D_{\text{local}}(u) = -\sum_{s=1}^{N_s} P_s(u) \log_a(P_s(u)) \quad (4)$$

式中:  $\hat{N}(u)$  表示用户  $u$  及其在社交图  $G_S$  中邻居的集合;  $P_s(u)$  表示  $\hat{N}(u)$  在社交子图  $G_{S,s}$  中的比例。

更大的  $D_{\text{local}}$  表明用户的邻居属于更多社交子图, 该用户更有可能是偏好间的噪声节点。

经过偏好感知分类的用户具有相似的特征, 然而由于经过无监督学习获得的偏好感知分类可能是不准确的, 因此使用一阶用户特征来计算相似度, 定义偏好为  $s$  的用户代表特征为该偏好分组中用户特征的平均值:

$$U_s = \{u \mid Y[u] = s\} \quad (5)$$

$$e_s = \operatorname{Avg}(e_u \mid u \in U_s) \quad (6)$$

式中:  $U_s$  表示属于偏好  $s$  类的用户集合;  $e_s$  表示  $s$  类的平均特征。

为了识别标记错误的噪声节点, 对于每个用户节点  $u$ , 计算其与所在分组的特征相似度:

$$S(u) = \frac{\exp(e_u \cdot e_{s_u})}{\max_{s \in \{1, 2, \dots, N_s\}} \exp(e_u \cdot e_s)} \quad (7)$$

式中:  $e_{s_u}$  为用户  $u$  所在偏好的平均特征。

与正确标记的节点相比, 标记错误的节点具有更小的  $S(u)$ :

$$D_{\text{global}}(u) = 1 - S(u) \quad (8)$$

式中:  $D_{\text{global}}$  是从全局角度衡量噪声节点的概率。

考虑到全局和局部两种衡量标准,  $D(u)$  最终定义如下:

$$D(u) = D_{\text{local}}(u) + \alpha \cdot D_{\text{global}}(u) \quad (9)$$

式中:  $\alpha$  是一个超参数, 控制  $D_{\text{global}}$  的权重。

PD-GCN 以  $D(u)$  的概率剔除这些噪声节点以及在交互子图中与之相连的项目节点, 从而提高对噪声节点的鲁棒性。

### 2.4 偏好传递

考虑到交互图中的用户和项目之间的直接邻居以及社交图中用户之间的直接邻居为用户提供最直接的偏好和最重要的信息。因此, 在进行一阶传播时, 使用原始图中的邻居节点。子图和原图的聚合和消息传递的原理是相同的, 因此仅描述在子图中的 GCN 模块。

对于用户  $u$ , 使用交互子图  $G_{1,s}$  和社交子图  $G_{S,s}$  更新从第  $k$  层输出的用户嵌入  $e_u^{(k)}$ 。为此, 分别在用户-项目交互图和社交图中为用户  $u$  生成两个嵌入, 表示为  $q_u^{(k)}$  和  $p_u^{(k)}$ :

$$q_u^{(k)} = \sum_{i \in N_u^{G_{1,s}}} \frac{1}{\sqrt{|N_u^{G_{1,s}}|} \sqrt{|N_i^{G_{1,s}}|}} e_i^{(k-1)} \quad (10)$$

$$p_u^{(k)} = \sum_{v \in N_u^{G_{S,s}}} \frac{1}{\sqrt{|N_u^{G_{S,s}}|} \sqrt{|N_v^{G_{S,s}}|}} e_v^{(k-1)} \quad (11)$$

式中:  $N_u^{G_{1,s}}$  表示交互子图中的用户  $u$  的邻居集合;  $N_u^{G_{S,s}}$  表示用户  $u$  在社交子图中的邻居集合。

式(10)和式(11)通过聚合两个图中的用户相邻节点的嵌入来更新用户  $u$  的嵌入。

融合  $q_u^{(k)}$  和  $p_u^{(k)}$  以生成更新的嵌入  $e_u^{(k)}$ :

$$\tilde{e}_u^{(k)} = W_6(\sigma(W_4 q_u^{(k)}) \parallel \sigma(W_5 p_u^{(k)})) \quad (12)$$

$$e_u^{(k)} = \frac{\tilde{e}_u^{(k)}}{\|\tilde{e}_u^{(k)}\|_2} \quad (13)$$

式中:  $\sigma$  是  $\tanh$  激活函数;  $W_4, W_5 \in \mathbb{R}^{d \times d}$ ,  $W_6 \in \mathbb{R}^{d \times 2d}$ , 均为可训练矩阵。

式(13)是归一化操作, 用来抑制随着  $k$  的增加而增加的  $e_u^{(k)}$ 。

对于从  $k$  层输出的项目  $i$  的嵌入  $e_{i,s}^{(k)}$ , 它在用户-项目交互图中进行如下传播:

$$e_{i,s}^{(k)} = \sum_{u \in N_i^{G_{1,s}}} \frac{1}{\sqrt{|N_i^{G_{1,s}}|} \sqrt{|N_u^{G_{1,s}}|}} e_u^{(k-1)} \quad (14)$$

在  $k$  层图卷积后的项目  $i$  的最终嵌入表示是在不同子图中学习到的嵌入特征之和:

$$e_i^{(k)} = \sum_{s \in G_{1,s}} e_{i,s}^{(k)} \quad (15)$$

式中:  $G_{1,s}$  是项目  $i$  所属的交互子图集。

这样保证了在子图中节点的嵌入只聚合子图节

点的高阶信息,使得模型可以进行多层的图卷积以建模用户和项目的高阶信息,缓解了过平滑问题。

## 2.5 训练与预测

将在子图中的各层节点嵌入结合,形成最终的嵌入,用于预测和损失函数优化,结合公式如下:

$$\mathbf{e}_u = \sum_{k=0}^K \alpha_k \mathbf{e}_u^{(k)} \quad (16)$$

$$\mathbf{e}_i = \sum_{k=0}^K \alpha_k \mathbf{e}_i^{(k)} \quad (17)$$

式中:  $\alpha_k$  统一设为  $1/(k+1)$ 。

在预测阶段,利用学习到的用户和项目的最终嵌入的内积计算用户对项目的偏好:

$$\hat{r}_{ui} = \mathbf{e}_u^T \mathbf{e}_i \quad (18)$$

模型采用与经典 GCN 推荐算法相同的损失函数,即 BPR 损失。这种损失函数是一种成对损失,其目标是在训练过程中最大化正样本和负样本的得分之差,通过贝叶斯最大化后验概率进行优化,BPR 损失目标函数可表示如下:

$$L = \sum_{(u,i^+,i^-) \in O} -\ln \varphi(\hat{r}_{ui^+} - \hat{r}_{ui^-}) + \lambda \|\Theta\|_2^2 \quad (19)$$

式中:  $O = \{(u,i^+,i^-) | (u,i^+) \in R^+, (u,i^-) \in R^-\}$  代表训练集,  $R^+$  为训练数据集中用户  $u$  和  $i^+$  之间的观测交互,  $R^-$  为采样的未观测交互的集合;  $\lambda$  和  $\Theta$  分别表示正则化权值和模型所有参数,使用  $L_2$  正则化防止过拟合,使用小批量优化器 Adam 优化预测模型和更新模型参数。

## 3 实验

### 3.1 数据集

为了验证 PD-GCN 模型的有效性,在 LastFM<sup>[26]</sup>,Ciao<sup>[26]</sup>和 Yelp<sup>[28]</sup> 3 个公开数据集上进行实验,统计数据如表 1 所示,其中,交互稀疏度为交互数与用户数和项目数的乘积的比值。对于每个数据集,按照 7:2:1 的比例将数据集分成训练集、验证集和测试集,彼此间独立无交叉数据。

表 1 数据集统计信息

Table 1 Dataset statistical information

| 数据集    | 用户数/个  | 项目数/个   | 交互数/个   | 交互稀疏度/% | 社交关系/个  |
|--------|--------|---------|---------|---------|---------|
| LastFM | 1 892  | 17 632  | 92 834  | 0.278   | 25 434  |
| Ciao   | 7 375  | 105 114 | 284 086 | 0.037   | 57 544  |
| Yelp   | 19 539 | 21 266  | 450 884 | 0.109   | 864 157 |

### 3.2 基线模型

为了验证 PD-GCN 模型的有效性,将其与以下 7 种新近的基于 GCN 的社交推荐基线模型进行比较,在原模型中的超参数设置除特别提及以外,与其原文中获得最佳性能时保持一致:

1) SBPR<sup>[15]</sup>: 基于矩阵分解的推荐模型,利用用户社交关系的协同过滤算法提高个性化排名的准确性。

2) DiffNet<sup>[23]</sup>: 基于图的社交推荐模型,它直接从用户-项目交互图和社交图中提取用户特征向量之和,从而生成最终的用户表示。

3) DiffNet++<sup>[24]</sup>: 在 DiffNet 的基础上采用图注意力网络分别对社交图和交互图进行邻居聚合,生成用户和项目表示。

4) LightGCN<sup>[7]</sup>: 一个简化的 GCN,只有邻居之间的线性传播和聚合,用于计算用户和项目的特征嵌入。

5) IMP-GCN<sup>[11]</sup>: 根据兴趣感知将节点划分为不同的子图,并在这些子图中传播协作信号。

6) SocialLGN<sup>[26]</sup>: 设计一种基于轻量化 GCN 的表示传播机制,将其用于用户-项目交互图和社交图,使其更适用于社交推荐。

7) DISGCN<sup>[25]</sup>: 一种将社会同质性感知的用户兴趣和社会影响力作为影响社交推荐用户行为的两个基本因素的建模方法。

### 3.3 实验设置和评价指标

实验在 Xeon® Platinum 8358P 处理器以及 NVIDIA GeForce RTX 3090 显卡 (24 GB) 的服务器平台上进行训练, CUDA 版本为 11.3, Python 版本为 3.8.3, PyTorch 版本为 1.11.0。模型设置节点嵌入向量维度为 128,  $L_2$  正则化系数  $\lambda = 10^{-5}$ , 学习率  $\mu = 0.001$ , 批处理大小为 2 048, 图卷积层数  $K$  默认设定为 4, 子图数量  $N_s$  设置为 4,  $\alpha$  设定为 1。

实验使用 2 个广泛使用的指标来评估所提出的 PD-GCN 和上述 7 种基准模型的 Top- $N$  排名推荐性能: 召回率 (Recall@ $N$ ) 和归一化折损累计增益 (NDCG@ $N$ )。Recall 重点在于正例, NDCG 则进一步考虑排名信息,  $N \in \{10, 20\}$ 。

### 3.4 实验结果和分析

PD-GCN 模型与对比模型的实验结果如表 2 所示, 其中, Improve 表示 PD-GCN 的指标值相比于次优模型指标值的提升率, 最优指标值用加粗字体

标示,次优指标值用下划线标示,下同。根据实验结果可知:基于矩阵分解的 SBPR 模型的性能表现均低于 GNN 模型,体现了 GNN 能够学习复杂的社交关系和高阶特征;LightGCN 模型表现普遍优于 DiffNet、DiffNet++ 模型,这是因为 LightGCN 删除了 GCN 中对推荐性能有负面影响的两个操作,即线性变换和非线性激活;SocialLGN 和 DISGCN 模型表现优于 LightGCN,它们在 LightGCN 的基础上引入社交信息,并考虑高阶图结构对用户嵌入的影响;IMP-GCN 在所有数据集和所有指标上均明显优于 LightGCN,证明了在执行图卷积操作时

区分用户兴趣的重要性;与次优模型相比,PD-GCN 在 LastFM 数据集的 Recall@N 和 NDCG@N 指标上分别平均提高 2.88%和 3.27%,在 Ciao 数据集上分别平均提升 3.16%和 4.59%,在 Yelp 数据集上分别平均提升 3.47%和 3.12%。该结果表明:引入社交关系对用户进行偏好分类,并对交互子图和社交子图进行降噪处理,可使模型堆叠更多的卷积层,最大程度地利用多跳邻居之间的积极协作信号,排除负面协作信号的消极影响。

综上所述,PD-GCN 在 3 个公开数据集上取得了更好性能。

表 2 不同模型在 3 个数据集上的实验结果

Table 2 Experimental results of different models on three datasets

| 数据集    | 指标        | SBPR    | DiffNet | DiffNet++ | LightGCN | IMP-GCN        | SocialLGN      | DISGCN         | PD-GCN         | Improve/% |
|--------|-----------|---------|---------|-----------|----------|----------------|----------------|----------------|----------------|-----------|
| LastFM | Recall@10 | 0.144 2 | 0.177 9 | 0.187 5   | 0.195 1  | 0.202 1        | 0.202 6        | <u>0.203 3</u> | <b>0.208 9</b> | 2.75      |
|        | Recall@20 | 0.207 0 | 0.248 8 | 0.265 1   | 0.276 9  | 0.278 8        | 0.279 4        | <u>0.280 1</u> | <b>0.288 7</b> | 3.01      |
|        | NDCG@10   | 0.174 9 | 0.221 9 | 0.223 3   | 0.234 0  | 0.254 3        | <u>0.256 6</u> | 0.254 4        | <b>0.266 2</b> | 3.74      |
|        | NDCG@20   | 0.197 8 | 0.247 4 | 0.266 5   | 0.278 8  | 0.288 6        | 0.288 3        | 0.284 2        | <b>0.296 7</b> | 2.81      |
| Ciao   | Recall@10 | 0.025 9 | 0.034 1 | 0.035 7   | 0.041 0  | 0.043 3        | 0.043 0        | <u>0.044 1</u> | <b>0.045 5</b> | 3.17      |
|        | Recall@20 | 0.041 2 | 0.052 7 | 0.056 5   | 0.059 1  | 0.060 9        | 0.061 8        | <u>0.063 3</u> | <b>0.065 3</b> | 3.16      |
|        | NDCG@10   | 0.026 6 | 0.035 9 | 0.037 1   | 0.043 7  | <u>0.045 2</u> | 0.044 1        | 0.043 1        | <b>0.047 2</b> | 4.42      |
|        | NDCG@20   | 0.030 7 | 0.040 3 | 0.044 2   | 0.047 8  | <u>0.050 3</u> | 0.048 6        | 0.049 1        | <b>0.052 7</b> | 4.77      |
| Yelp   | Recall@10 | 0.044 6 | 0.051 1 | 0.062 1   | 0.061 5  | <u>0.063 3</u> | 0.063 2        | 0.061 1        | <b>0.065 6</b> | 3.63      |
|        | Recall@20 | 0.053 3 | 0.084 9 | 0.087 8   | 0.064 7  | 0.067 2        | 0.089 1        | <u>0.090 4</u> | <b>0.093 4</b> | 3.31      |
|        | NDCG@10   | 0.043 1 | 0.039 7 | 0.048 3   | 0.041 6  | 0.049 9        | <u>0.051 1</u> | 0.050 2        | <b>0.052 5</b> | 2.74      |
|        | NDCG@20   | 0.046 7 | 0.051 3 | 0.061 4   | 0.052 6  | 0.057 0        | 0.062 2        | <u>0.062 6</u> | <b>0.064 8</b> | 3.51      |

### 3.5 超参数影响分析

本节对 PD-GCN 的 3 个重要超参数进行研究,包括子图数  $N_s$ 、降噪模块中局部和全局影响比例  $\alpha$  和传播层数  $K$ 。

#### 3.5.1 子图数的影响

为了探究子图数量对模型性能的影响,实验将子图的数量设置为 $\{2, 3, 4, 5\}$ ,在 LastFM、Ciao、Yelp 数据集上的结果分别如表 3、表 4 和表 5 所示。

表 3 LastFM 数据集上 PD-GCN 在不同子图数下的性能

Table 3 Performance of PD-GCN with different number of subgraphs on LastFM dataset

| 子图数/个 | Recall@10      | Recall@20      | NDCG@10        | NDCG@20        |
|-------|----------------|----------------|----------------|----------------|
| 2     | 0.202 1        | 0.281 4        | 0.258 6        | 0.289 1        |
| 3     | <b>0.209 2</b> | <b>0.289 1</b> | <b>0.266 6</b> | <b>0.297 0</b> |
| 4     | 0.208 9        | 0.288 7        | 0.266 2        | 0.296 7        |
| 5     | 0.207 7        | 0.287 4        | 0.264 5        | 0.291 1        |

表 4 Ciao 数据集上 PD-GCN 在不同子图数下的性能

Table 4 Performance of PD-GCN with different number of subgraphs on Ciao dataset

| 子图数/个 | Recall@10      | Recall@20      | NDCG@10        | NDCG@20        |
|-------|----------------|----------------|----------------|----------------|
| 2     | 0.043 9        | 0.062 4        | 0.045 0        | 0.050 8        |
| 3     | 0.044 1        | 0.063 3        | 0.045 9        | 0.051 2        |
| 4     | <b>0.045 5</b> | <b>0.065 3</b> | <b>0.047 2</b> | <b>0.052 7</b> |
| 5     | 0.043 2        | 0.064 1        | 0.046 5        | 0.049 1        |

表 5 Yelp 数据集上 PD-GCN 在不同子图数下的性能

Table 5 Performance of PD-GCN with different number of subgraphs on Yelp dataset

| 子图数/个 | Recall@10      | Recall@20      | NDCG@10        | NDCG@20        |
|-------|----------------|----------------|----------------|----------------|
| 2     | 0.063 3        | 0.089 0        | 0.051 4        | 0.061 5        |
| 3     | <b>0.065 6</b> | <b>0.093 4</b> | <b>0.052 5</b> | <b>0.064 8</b> |
| 4     | 0.064 1        | 0.091 1        | 0.050 4        | 0.062 2        |
| 5     | 0.061 2        | 0.087 8        | 0.045 5        | 0.059 3        |

根据结果可知,在 LastFM 数据集上取得最佳性能时  $N_s = 3$ ,在 Ciao 数据集上取得最佳性能时  $N_s = 4$ ,在 Yelp 数据集上取得最佳性能时  $N_s = 3$ 。可以得出结论:模型性能与数据集的节点数量以及数据稀疏度密切相关,选择适当数量的子图本质上是在挖掘更多积极的协作信号和减少消极的协作信号之间的权衡。一方面,当子图数量过少时,模型将以粗略的级别来区分用户偏好,这可能导致具有不同偏好的用户被划分到同一个子图,会使得用户节点与更多节点有连接关系,虽然这会增加积极协作信号的数量,但也会引入更多的消极协作信号;另一方面,当子图数量过多时,会将偏好划分得过于细致,这可能会导致具有相似偏好的用户被划分到不同的子图中,虽然这有助于减少消极协作信号的影响,但是模型可能会失去一些积极协作信号。因此,选择适当数量的子图可以帮助平衡这两种情况,在充分利用积极协作信号的同时减少消极协作信号的干扰,从而提高模型性能。

### 3.5.2 降噪模块中局部和全局影响比例的影响

为了研究降噪模块中局部和全局影响比例  $\alpha$  对模型性能的影响,实验将其大小设置为  $\{1/3, 1/2, 1, 2, 3\}$ ,实验结果如图 2 和图 3 所示。




图 2  $\alpha$  对 PD-GCN 的 Recall 性能影响

Fig. 2 Impact of  $\alpha$  on Recall performance of PD-GCN




图 3  $\alpha$  对 PD-GCN 的 NDCG 性能影响

Fig. 3 Impact of  $\alpha$  on NDCG performance of PD-GCN

根据实验数据可知,  $D_{\text{global}}$  和  $D_{\text{local}}$  对噪声去除均有效果。当  $\alpha = 1$  时,模型在 LastFM、Ciao 和 Yelp 数据集上均达到最佳性能,  $\alpha$  过大或过小均会导致性能下降,说明了本文提出的节点降噪模块对数据集的稀疏度变化不敏感,PD-GCN 模型具有良好的泛化能力。

### 3.5.3 传播层数的影响

为了研究传播层数  $K$  对模型性能的影响,实验将图的卷积层数设置为  $\{2, 3, 4, 5, 6\}$ ,并加入 IMP-GCN 和 SocialLGN 模型进行对比。由于 3 个数据集的实验结果显示了完全相同的趋势,因此仅展示在 Ciao 数据上获得的结果,如图 4 所示。

首先,当传播层数  $K > 4$  时,PD-GCN 和 IMP-GCN 的性能均优于 SocialLGN,说明了采用无监督学习对用户节点分类有助于确保传输步骤中的多跳协作信号是积极的,缓解了模型在进行高阶图卷积时出现过平滑问题。相反地,当模型在已经有 3 层之后继续添加更多的传播层时, SocialLGN 产生过平滑问题。其次,PD-GCN 在大多数情况下表现优于 IMP-GCN,说明了社交图信息的引入和基于全局和局部的节点降噪任务有助于缓解数据稀疏和噪声问题,弥补了 IMP-GCN 的不足。

### 3.6 噪声鲁棒性分析

为了验证 PD-GCN 中节点降噪模块的鲁棒性,随机生成不同百分比的假边(即噪声比为 0.10、0.20、0.30)来创建一个损坏的用户-项目交互图和社交图作为噪声干扰。在不同噪声比下不同模型的相对性能表现如图 5 所示。由于  $D_{\text{global}}$  和  $D_{\text{local}}$  根据用户偏好感知准确地寻找并去除噪声节点,因此与 IMP-GCN 和 SocialLGN 相比,PD-GCN 在解决数据噪声问题方面显示了较好的性能。然而,在噪声比为 0.30 的 Yelp 数据集上,PD-GCN 模型性能下降较为显著,这是由于 Yelp 数据集社交关系较为稠密,增加高比例噪声边对  $D_{\text{global}}$  的降噪性能产生了影响。

### 3.7 消融实验

为验证 PD-GCN 模型中各个模块的有效性和必要性,设计 3 个变体模型,实验结果如图 6 所示。

3 个变体模型具体如下:

1) PD-GCN-SG: 移除偏好感知的子图生成模块,将用户-项目二部图和社交图直接进行图卷积处理,研究子图生成模块对模型性能的影响。

2) PD-GCN-GL: 移除基于全局和局部的噪声剔除模块,在生成子图后直接进行图卷积处理,研究节点降噪模块对模型性能的影响。

3) PD-GCN-S: 移除社交图输入,只将用户-项目




图 4 K 对 PD-GCN 的性能影响

Fig. 4 Impact of K on the performance of PD-GCN




图 5 数据噪声对模型鲁棒性的影响

Fig. 5 Impact of data noise on model robustness




图 6 针对不同模块的消融实验

Fig. 6 Ablation experiments for different modules

交互图直接嵌入模型,观察模型性能变化。

PD-GCN-SG 的实验数据表明,在有无监督子图生成模块的情况下,模型无法将具有相同偏好的用户及其交互项划分为一个子图从而过滤掉具有不同偏好的用户带来的负面信息,模型在经过多层图卷积后进入过平滑状态。PD-GCN-GL 的实验数据表明,若取消对交互子图和社交子图的噪声剔除处理,将无法根据局部和全局信息降低噪声节点对模型性能的影响。PD-GCN-S 的实验数据表明,在 PD-GCN 中,引入社交图是有必要的,可以有效缓解推荐系统中的数据稀疏性问题,提升推荐性能。

综上,PD-GCN 的综合性能优于其所有变体模型的性能,说明了这 3 个模块在 PD-GCN 模型中是有效的。

#### 4 结束语

本文提出的 PD-GCN 模型通过无监督学习模块并根据用户偏好将交互图和社交图同步划分为多个子图,使用结合全局和局部信息的降噪策略缓解子图中噪声节点对模型性能的影响,在子图中执行图卷积操作捕获交互子图和社交子图中的高阶协作信号,减轻节点特征过平滑的问题,有效建模用户和项目之间的复杂交互以及社交关系。在 3 个公开的数据集上的对比实验结果表明,PD-GCN 模型性能整体优于现有的主流推荐模型。在未来的工作中,考虑融合文本、图像、音频等多模态数据,以更全面地理解用户的偏好和项目的特征,并以此对用户群体进行分类,进一步提高推荐性能。

#### 参考文献

- [1] PRABAKARAN R, PRADEEPKANDHASAMY J, ARUN M. A survey on recommendation systems using collaborative filtering techniques[C]//Proceedings of the 5th International Conference on Smart Systems and Inventive Technology (ICSSIT). Washington D. C., USA: IEEE Press, 2023: 1445-1450.
- [2] 潘润超,虞启山,熊泓霏,等. 基于深度图神经网络的协同推荐算法[J]. 计算机应用, 2023, 43(9): 2741-2746.  
PAN R C, YU Q S, XIONG H F, et al. Collaborative recommendation algorithm based on deep graph neural network[J]. Journal of Computer Applications, 2023, 43(9): 2741-2746. (in Chinese)
- [3] MCPHERSON M, SMITH-LOVIN L, COOK J M. Birds of a feather: homophily in social networks[J]. Annual Review of Sociology, 2001, 27: 415-444.
- [4] CIALDINI R B, GOLDSTEIN N J. Social influence: compliance and conformity[J]. Annual Review of Psychology, 2004, 55: 591-621.
- [5] 徐上上,孙福振,王绍卿,等. 基于图神经网络的异构信任推荐算法[J]. 计算机工程, 2022, 48(9): 89-95, 104.  
XU S S, SUN F Z, WANG S Q, et al. Heterogeneous trust recommendation algorithm based on graph neural networks[J]. Computer Engineering, 2022, 48(9): 89-95, 104. (in Chinese)
- [6] YANG X Y, XU F, YU J, et al. Graph neural network-guided contrastive learning for sequential recommendation[J]. Sensors, 2023, 23(12): 5572.
- [7] HE X N, DENG K, WANG X, et al. LightGCN: simplifying and powering graph convolution network for recommendation[EB/OL]. [2023-10-17]. <http://arxiv.org/abs/2002.02126>.
- [8] 许凤,杨兴耀,于炯,等. 小波卷积增强的对比学习推荐算法[J]. 计算机工程, 2023, 49(5): 105-111, 121.  
XU F, YANG X Y, YU J, et al. Wavelet convolution enhanced contrastive learning recommendation algorithm[J]. Computer Engineering, 2023, 49(5): 105-111, 121. (in Chinese)
- [9] WANG X, HE X N, WANG M, et al. Neural graph collaborative filtering[C]//Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, USA: ACM Press, 2019: 165-174.
- [10] SONG C H, WANG B, JIANG Q X, et al. Social recommendation with implicit social influence[C]//Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, USA: ACM Press, 2021: 1788-1792.
- [11] LIU F, CHENG Z Y, ZHU L, et al. Interest-aware message-passing GCN for recommendation[C]//Proceedings of the Web Conference 2021. New York, USA: ACM Press, 2021: 1296-1305.
- [12] FAN Z W, XU K, DONG Z, et al. Graph collaborative signals denoising and augmentation for recommendation[C]//Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, USA: ACM Press, 2023: 2037-2041.
- [13] 宋玉龙,马文明,刘彤彤. 融合用户信任度的概率矩阵分解群组推荐算法[J]. 计算机工程, 2022, 48(1): 105-111.  
SONG Y L, MA W M, LIU T T. Group recommendation algorithm incorporating user trust with probability matrix factorization[J]. Computer Engineering, 2022, 48(1): 105-111. (in Chinese)
- [14] MA H, YANG H X, LÜ M R, et al. SoRec: social recommendation using probabilistic matrix factorization[C]//Proceedings of the 17th ACM Conference on Information and Knowledge Management. New York, USA: ACM Press, 2008: 931-940.
- [15] ZHAO T, MCAULEY J, KING I. Leveraging social connections to improve personalized ranking for collaborative filtering[C]//Proceedings of the 23rd ACM International Conference on Conference on Information and Knowledge Management. New York, USA: ACM Press, 2014: 261-270.
- [16] JAMALI M, ESTER M. A matrix factorization technique with trust propagation for recommendation in social networks[C]//Proceedings of the 4th ACM Conference on Recommender Systems. New York, USA: ACM Press, 2010: 135-142.
- [17] GUO G, ZHANG J, YORKE-SMITH N. TrustSVD: collaborative filtering with both the explicit and implicit influence of user trust and of item ratings[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto, USA: AAAI Press, 2015: 123-129.
- [18] LIU H F, JING L P, YU J, et al. Social recommendation with learning personal and social latent factors[J]. IEEE Transactions on Knowledge and Data Engineering, 2021, 33(7): 2956-2970.
- [19] SHOKEEN J, RANA C. A trust and semantic based approach for social recommendation[J]. Journal of Ambient Intelligence and Humanized Computing, 2021, 12(11): 10289-10303.
- [20] GUPTA A, MATTA P, PANT B. Graph neural network: current state of art, challenges and applications[J]. Materials Today: Proceedings, 2021, 46: 10927-10932.
- [21] GAO C, ZHENG Y, LI N, et al. A survey of graph neural networks for recommender systems: challenges, methods, and directions[J]. ACM Transactions on Recommender Systems, 2023, 1(1): 1-51.
- [22] FAN W Q, MA Y, LI Q, et al. Graph neural networks for social recommendation[EB/OL]. [2023-10-17]. <http://arxiv.org/abs/1902.07243>.
- [23] 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, USA: ACM Press, 2019: 235-244.

- [24] 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.
- [25] LIN, GAO C, JIN D P, et al. Disentangled modeling of social homophily and influence for social recommendation[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(6): 5738-5751.
- [26] LIAO J, ZHOU W, LUO F J, et al. SocialLGN: light graph convolution network for social recommendation [J]. Information Sciences, 2022, 589: 595-607.
- [27] WU J, FAN W, CHEN J, et al. Disentangled contrastive learning for social recommendation[C]//Proceedings of the 31st ACM International Conference on Information & Knowledge Management. New York, USA: ACM Press, 2022: 4570-4574.
- [28] WU B, KANG Y, GUAN B, et al. We are not so similar: alleviating user representation collapse in social recommendation [C] // Proceedings of the 2023 ACM International Conference on Multimedia Retrieval. New York, USA: ACM Press, 2023: 378-387.

编辑 陆燕菲