

基于注意力机制的图神经网络社交推荐算法

吴郑霞, 葛云生

(桂林理工大学 计算机科学与工程学院, 广西 桂林 541000)

摘要: 针对现有的社交推荐系统无法处理用户与项目潜在信息以及存在过平滑现象的问题, 提出一种基于注意力机制的图神经网络社交推荐算法(SGNN-AM)。该算法在图神经网络中引入注意力机制和多层感知机, 避免了多次图卷积运算后可能遇到的过平滑问题。首先, 将用户和项目的嵌入信息进行初始化; 其次, 利用注意力机制为用户—项目交互图 and 用户社交图中的用户与项目分配相应权重; 最后, 使用多层感知机聚合学习用户和项目的表示, 将所有计算得到的协同信号进行线性运算后输出最终预测结果。在 LastFM 和 Ciao 两个真实数据集上进行实验, 结果显示, 与基准模型中的最优表现相比, SGNN-AM 的指标 Precision@20 分别提高了 2.84% 和 2.79%, Recall@20 分别提高了 2.36% 和 1.14%, NDCG@20 分别提高了 1.13% 和 2.28%, 证明了该算法的合理性和有效性。

关键词: 社交推荐; 多层感知机; 推荐系统; 注意力机制; 图神经网络

DOI: 10.11907/rjtk.241603

中图分类号: TP391

文献标识码: A

开放科学(资源服务)标识码(OSID):

文章编号: 1672-7800(2025)009-0075-07



Graph Neural Network Social Recommendation Algorithm Based on Attention Mechanism

WU Zhengxia, GE Yunsheng

(College of Computer Science and Engineering, Guilin University of Technology, Guilin 541000, China)

Abstract: To address the issue of existing social recommendation systems being unable to process the potential information between users and items, as well as the problem of over-smoothing, we propose a social recommendation algorithm based on attention mechanism and graph neural networks (SGNN-AM). This algorithm introduces attention mechanisms and multilayer perceptrons into graph neural networks, avoiding the potential over-smoothing problem that may arise after multiple graph convolution operations. First, the embedding information of users and items is initialized; second, the attention mechanism is used to assign corresponding weights to the user-item interaction graph and the user social graph; finally, multilayer perceptrons are employed to aggregate and learn the representations of users and items, outputting the final prediction results after linear operations on all computed collaborative signals. Experiments conducted on two real datasets, LastFM and Ciao, show that compared to the optimal performance of the baseline model, SGNN-AM improves Precision@20 by 2.84% and 2.79%, Recall@20 by 2.36% and 1.14%, and NDCG@20 by 1.13% and 2.28%, demonstrating the rationality and effectiveness of the algorithm.

Key Words: social recommendations; multilayer perceptron; recommendation systems; attention mechanism; graph neural networks

0 引言

现代互联网的快速发展导致信息呈爆炸式增长, 对于信息的传递与交流带来了极大的挑战, 使用户难以快速获得想要的信息。然而, 个性化推荐系统的出现很大程度上改善了信息过载问题^[1]。因此, 推荐系统相关研究受到了越来越多学者关注, 目前推荐系统已被广泛应用于广告、

电子商务和网络媒体等在线服务中^[2]。推荐系统是根据用户的兴趣、历史交互数据等信息判断用户当前可能感兴趣或需要的项目^[3]。但是, 随着用户和项目数量逐渐增加, 用户与项目不断产生交互, 可能会面临冷启动问题。比如, 当有新用户或新项目加入时, 由于缺乏足够的交互数据, 推荐系统很难推荐满意的内容给尚未产生交互信息的新用户或新项目。协同过滤是一种有效缓解冷启动的方法。其根据大量的用户交互信息捕获用户偏好, 并向用

收稿日期: 2024-07-15

扫描二维码阅读全文:



作者简介: 吴郑霞(1999-), 女, 桂林理工大学计算机科学与工程学院硕士研究生, 研究方向为推荐系统; 葛云生(1964-), 男, 硕士, 桂林理工大学计算机科学与工程学院副教授、硕士生导师, 研究方向为计算机应用。本文通讯作者: 葛云生。

户推送可能感兴趣的项目^[4]。然而,当交互数据不足时会导致数据稀疏性问题,从而影响算法的有效性。此外,在实际生活中,人们很容易受到朋友的影响,会更倾向于和具有相似偏好的人交朋友,由此产生的社交关系可以体现相关用户的潜在偏好信息。研究发现,在社交网络中,已有社交关联用户之间的偏好相似性明显高于没有社交关联的用户^[5]。因此,将社交信息数据应用于推荐系统中,能很大程度上缓解数据稀疏性和冷启动问题^[6]。

在推荐系统中,用户—项目交互数据被建模成用户—项目交互图,而社交关系数据被定义为社交图。一般来说,将社交信息应用于推荐系统中有两种方法:一是统一学习所有节点的嵌入信息,将两个图合并表示为异构图;二是学习两个图中每个用户的嵌入表示,再将两个学习的嵌入表示合并为最终表示,如图1所示。




Fig. 1 Representation and fusion of users and items

图1 用户和项目的表示与融合

针对现有基于图神经网络的社交推荐系统无法充分挖掘用户与项目的潜在关联信息以及容易过平滑的问题,本文提出一种基于注意力机制的图神经网络社交推荐算法 SGNN-AM (Graph Neural Network Social Recommendation Algorithm Based on Attention Mechanism)。为了应对上述挑战,SGNN-AM 使用图神经网络技术将用户数据集到推荐系统中。具体而言,本文主要贡献如下:

(1) 根据注意力机制的特点分配用户和项目权重,以得到最优权重,并且使用归一化操作避免图卷积层数增加时带来的过平滑问题。

(2) 使用多层感知机学习用户和项目的表示,捕获用户与物品的非线性关系,挖掘用户与项目之间潜在的协作信号。

(3) 在两个基于购物和音乐的真实数据集上与其他5个基准算法进行比较,研究结果证明了 SGNN-AM 算法的有效性与合理性。

1 相关工作

1.1 传统推荐系统

对于现代生活而言,电影、餐饮、电子产品、音乐和购物等已成为人们生活的一部分。推荐系统是一种信息过

滤器,其利用机器学习算法和技术,通过学习用户或项目的历史行为,预测用户的兴趣偏好。一般而言,推荐系统分为非个性化推荐与个性化推荐。非个性化推荐不考虑用户的历史行为和偏好,通常是直接推送项目的榜单数据,比较适用于冷启动用户。然而,非个性推荐内容单一,不会考虑用户特点。而个性化推荐能在不同场景下满足用户需求,为用户量身打造的个性化推荐效果越好,客户的满意度则会越高。个性化推荐根据不同的应用场景可分以下3类:基于特征的推荐、基于协同过滤的推荐和基于混合方式的推荐。

基于特征的推荐主要使用用户提供的数据,根据项目的特定属性来查找用户喜欢项目的其它相似项目。为了解决特征推荐中的项目属性分布问题,Dai 等^[7]提出基于高斯混合模型的内容推荐,通过使用相似度计算方式,以提高推荐的准确性。为了提高从海量文库中查找目标文献的准确率,Zhang 等^[8]提出一种基于深度内容的协同过滤方法 DeepCCF。该方法通过结合基于内容的过滤和基于神经网络的协同过滤,深入挖掘用户与论文主题的高阶交互特征,进一步提高了推荐的准确率。基于协同过滤的推荐主要是通过分析用户的行为信息与偏好,并对其进行挖掘,从而决定哪些项目应当推荐给具有相似品味的其他用户来生成预测;Yang 等^[9]考虑到图结构中缺乏潜在偏好链接,提出一种基于协同过滤的增强型图学习模型 (Enhanced Graph Learning Network, EGLN)。通过使用增强的图学习模块和节点嵌入模块迭代地相互学习,并使用局部—全局优化函数来获取增强图学习过程中的全局属性,提升了模型性能;Lin 等^[10]考虑到在图协同过滤里通常采用对比学习来构造对比对,而忽略了用户或项目的相邻关系,提出邻域强化对比学习模型 (Neighborhood-enriched Contrastive Learning, NCL)。通过充分挖掘语义空间中潜在的邻居关系,显著提升了模型性能。基于混合方式的推荐是通过结合协同过滤和项目推荐的方式,融合多种辅助信息(如用户社交网络、商品评论、知识图谱等),从而提供更精准与多样化的推荐。Wang 等^[11]考虑到现有混合推荐方法将每个用户公平对待,而忽略了纯协同过滤方法计算和集成辅助信息成本高的问题,提出一种基于条件生成对抗网络的协同过滤模型 AugCF,依据用户的喜好生成新交互数据的特征,实现端到端的训练模型,保证了交互数据的准确性;Wang 等^[12]考虑到现有推荐系统无法充分利用知识图谱中的全局结构信息,提出一种新的混合推荐模型 CurvRec,采用混合曲率流形交互学习方式,有效捕获了知识图谱中的复杂几何结构。

1.2 基于图神经网络的协同过滤推荐系统

图神经网络方法通过图上节点信息的传递来捕获节点间的关联关系,不仅可以得到图的表示向量,而且可以预测整个图、节点或边^[13]。在推荐系统中,用户与项目之间的交互能被表示为二分图,因此图神经网络不仅可用来

学习用户和项目之间的表示,而且可用于节点分类、链接预测和社区检测等学习节点表示任务中^[14-17]。Wang等^[18]考虑到传统推荐系统无法捕获用户和项目交互时产生的有效潜在信息,提出一种神经图协同过滤框架(Neural Graph Collaborative Filtering, NGCF),通过多层图卷积集成方式捕捉用户与项目之间的协同信息;He等^[19]考虑到NGCF的冗余性,提出一种协同过滤模型LightGCN,通过邻域平均方式更新节点嵌入向量,降低了模型复杂性;Wu等^[20]针对高度节点对表征学习的影响以及表征易受噪音干扰的问题,提出一种图自监督学习方法(Self-supervised Graph Learning, SGL)。通过数据增强的方式生成多视图,借鉴对比学习的思路辅助主任务学习,提高了图表征学习的准确性和鲁棒性;Lin等^[10]考虑到数据稀疏性的问题,提出一种新的对比学习算法(Neighborhood-enriched Contrastive Learning, NCL),利用节点之间的关系设计对比学习任

务,挖掘语义空间中潜在的邻域关系;Xia等^[21]针对低通拉普拉斯平滑算子的过平滑和噪声效应问题,提出一种简单的协同过滤模型SimRec,通过保持全局协作信号和重新校准表示,实现自适应的信息传递。

2 SGNN-AM算法

2.1 算法框架

SGNN-AM算法总体框架如图2所示。SGNN-AM算法分为3层:①数据嵌入层。根据用户和项目信息初始化用户与项目的嵌入;②信息传播层。在社交图和用户—项目交互图中使用注意力机制分配权重,并传播用户和项目的嵌入;③输出预测层。聚合来自不同传播层的细化嵌入,利用多层感知机预测连接两个节点任何边的值,输出用户和项目的最终表示。




Fig. 2 Overall architecture of the SGNN-AM model

图2 SGNN-AM算法总架构

2.2 数据嵌入层

给定 $U = \{u_1, u_2, u_3, \dots, u_n\}$ 和 $I = \{i_1, i_2, i_3, \dots, i_m\}$, 分别表示用户集合与项目集合的初始状态,其中 n, m 表示嵌入的维度大小。因此,构建嵌入矩阵公式如下:

$$\mathbf{E} = \begin{bmatrix} e_{u_1}, \dots, e_{u_n} & e_{i_1}, \dots, e_{i_m} \\ \text{users embeddings} & \text{items embeddings} \end{bmatrix} \quad (1)$$

其中, $\mathbf{E}$ 表示用户嵌入和项目嵌入的集合, $e_{u_1}, \dots, e_{u_n}$ 表示用户 $u_1, u_2, u_3, \dots, u_n$ 嵌入, $e_{i_1}, \dots, e_{i_m}$ 表示项目 $i_1, i_2, i_3, \dots, i_m$ 嵌入。

本文算法将在用户社交图和用户与项目交互图上实现嵌入过程,相较于矩阵分解等传统方法,将协同信号注入到嵌入过程中,并在交互层采用直接输出分数的方式得到预测值,推荐结果会更加准确。

2.3 信息传播层

为了捕获协同信号,将图神经网络的消息传递机制应用于数据嵌入层,从而得到生成的用户和项目嵌入。之后,对用户—项目交互图与社交图上用户和项目的潜在向量展开图卷积运算。具体而言,定义 k 为传播层的级数,从 $k-1$ 层获取第 k 个信息传播层的嵌入,并输出更新后的嵌入。其中,当 $k=1$ 时,其代表的是第0个信息传播层,也即初始的数据嵌入层。

用户嵌入的更新过程如下:用户 u 同时使用用户—项目交互图和社交图来更新从 $k-1$ 层得到的用户嵌入信息,表示为 $\mathbf{e}_u^{(k-1)}$ 。同理,项目 i 在用户—项目交互图上更新从 $k-1$ 层收到的项目嵌入信息,表示为 $\mathbf{e}_i^{(k-1)}$ 。因此,用户 u 分别为用户—项目交互图和社交图生成两个嵌入,表示为 $\mathbf{q}_u^{(k)}$ 和 $\mathbf{p}_u^{(k)}$ 。

$$\mathbf{q}_u^{(k)} = \sum_{i \in \mathcal{N}_u^I} \frac{1}{\sqrt{|\mathcal{N}_u^I|} \sqrt{|\mathcal{N}_v^I|}} \mathbf{e}_i^{(k-1)} \quad (2)$$

$$\mathbf{p}_u^{(k)} = \sum_{i \in \mathcal{N}_u^S} \frac{1}{\sqrt{|\mathcal{N}_u^S|} \sqrt{|\mathcal{N}_v^S|}} \mathbf{e}_i^{(k-1)} \quad (3)$$

其中, $\mathcal{N}_u^I, \mathcal{N}_v^I$ 表示用户 u 和项目 i 在用户—项目交互图中的邻域集合, $\mathcal{N}_u^S, \mathcal{N}_v^S$ 表示用户 u 和项目 i 在社交图中的邻域集合。式(2)和式(3)本质上是社交图与用户—项目交互图中用户相邻节点的信息合并后,再更新用户 u 的嵌入。

然后将 $\mathbf{q}_u^{(k)}$ 和 $\mathbf{p}_u^{(k)}$ 结合以生成更新后的用户嵌入 $\mathbf{e}_u^{(k)}$,如式(4)所示。其中, $f(\cdot)$ 表示图融合操作。在该算法中,使用图融合操作生成 $\tilde{\mathbf{e}}_u^{(k)}$ 。

$$\mathbf{e}_u^{(k)} = f(\mathbf{q}_u^{(k)}, \mathbf{p}_u^{(k)}) \quad (4)$$

$$\tilde{\mathbf{e}}_u^{(k)} = \text{softmax}\left(\mathbf{W}_3 \left(\sigma(\mathbf{W}_1 \mathbf{p}_u^{(k)}) + \sigma(\mathbf{W}_2 \mathbf{q}_u^{(k)}) \right)\right) \quad (5)$$

其中, $\sigma(\cdot)$ 表示 $\tanh$ 激活函数, $\mathbf{W}_1, \mathbf{W}_2 \in \mathbb{R}^{d \times d}$, $\mathbf{W}_3 \in \mathbb{R}^{d \times 2d}$ 表示可训练权重矩阵, $\tilde{\mathbf{e}}_u^{(k)}$ 表示用户 u 在第 k 层的注意力分数。利用Softmax函数对 k 层的注意力分数进行归一化操作,其目的是为了防止 k 增加时, $\mathbf{e}_u^{(k)}$ 的值过度增长。

$$\mathbf{e}_u^{(k)} = \frac{\exp(\tilde{\mathbf{e}}_u^{(k)})}{\sum_{k=1}^K \exp(\tilde{\mathbf{e}}_u^{(k)})} \quad (6)$$

项目嵌入更新过程如下:在用户—项目交互图中,项目 i 从 $k-1$ 层得到项目嵌入 $\mathbf{e}_i^{(k)}$,传播过程如下:

$$\mathbf{e}_i^{(k)} = \sum_{u \in \mathcal{N}_i^I} \frac{1}{\sqrt{|\mathcal{N}_v^I|} \sqrt{|\mathcal{N}_u^I|}} \mathbf{e}_u^{(k-1)} \quad (7)$$

2.4 预测输出层

为了获得用户的多个表示,使用 k 层传播迭代生成的用户向量表示,即 $\{\mathbf{e}_u^0, \mathbf{e}_u^1, \dots, \mathbf{e}_u^k\}$ 。不同层的用户向量表示体现了不同用户的兴趣偏好,从而生成最终的用户向量表示。同理,对项目采用相同操作,将多层迭代生成的项目特征表示拼接起来,即 $\{\mathbf{e}_i^0, \mathbf{e}_i^1, \dots, \mathbf{e}_i^k\}$ 。

为了解决协同过滤算法中可能遇到的模型泛化能力不足的问题,提出一种多层感知机用于学习用户和项目的表示,以提高模型的非线性建模能力和灵活性,具体公式如下:

$$\begin{aligned} \mathbf{x}_u &= a(W^{(k)} \mathbf{e}_u^{(k-1)} + b^{(k)}) \\ \mathbf{x}_i &= a(W^{(k)} \mathbf{e}_i^{(k-1)} + b^{(k)}) \end{aligned} \quad (8)$$

其中, $\mathbf{x}_u, \mathbf{x}_i$ 分别表示用户 u 和项目 i 的特征向量, k 表示隐藏层数量, W, b 表示多层感知机的参数, $a(\cdot)$ 表示ReLU激活函数。

最后,为了计算用户 u 对目标项目 i 的喜爱程度分数 $\hat{y}_{ui}$,使用内积计算方式输出最终得分:

$$\hat{y}_{ui} = \mathbf{x}_u \odot \mathbf{x}_i \quad (9)$$

2.5 算法优化

为了训练算法参数,使用BPR(Bayesian Personalized Ranking)算法所采用的损失函数^[22]。在推荐系统中,该损失函数应用广泛。BPR算法的核心思想是将用户—项目对进行排序,使排序后的序列更能体现用户的喜好。目标函数定义如下:

$$\text{Loss} = \sum_{(u,i) \in \mathcal{N}_u^I \cup (u,j) \notin \mathcal{N}_u^I} -\ln \sigma(\hat{y}_{ui} - \hat{y}_{uj}) + \lambda \|\theta\|_2^2 \quad (10)$$

其中, θ 表示从数据嵌入层输出的 N 个用户和 M 个项目的嵌入; $\hat{y}_{uj}$ 表示用户 u 对目标项目 j 的喜爱程度分数; λ 表示 L_2 正则化函数。

同时,采用Adam算法更新模型参数,其对预测模型起到一定作用^[23]。相较于传统的随机梯度下降算法,Adam算法可以针对不同参数动态调整参数的学习率,为快速探寻局部最优解提供了捷径。

3 实验与结果分析

本节将对SGNN-AM算法进行实验分析。首先,阐述所用的数据集、对比模型、参数配置、评价指标与实验设置;其次,与其他算法进行不同基准算法的性能对比和冷启动实验;最后,设计消融实验、层数影响和正则化系数实验,分析模型的可行性。

3.1 数据集

为了评估SGNN-AM的有效性,分别在LastFM(<https://grouplens.org/datasets/hetrec-2011/>)和Ciao(<https://www.cse.msu.edu/~tangjili/datasetcode/truststudy.htm>)两个稀疏性、大小不同的真实公开数据集上进行实验。LastFM是一个来源于知名音乐平台LastFM网站的音乐数据集,包含1 892个用户以及用户与音乐相关项目之间的17 632次互动。例如,推荐用户好友喜欢的音乐,或者找到有相似音乐口味的用户,并推荐其相互关注。Ciao是一个来源于名为Ciao网站的在线购物数据集,涵盖7 375个用户的大量商品评分信息,并涉及用户之间的105 114条社交关系。例如,如果两个用户的兴趣偏好相似,则可以把其中

一个用户喜欢的商品推荐给另一个用户。简单来说,就是找到喜好相似的用户,然后互相分享其喜欢的商品。表1显示了所使用数据集的统计数据。

Table 1 Experimental datasets

表1 实验数据集

数据集	LastFM	Ciao
用户数	1 892	7 375
项目数	17 632	105 114
评分数	92 834	284 086
评分稠密度	0.278%	0.037%
社交关系数	25 434	57 544
社交关系稠密度	0.711%	0.106%

3.2 基准模型

将本文模型分别与以下不同的推荐模型进行比较:

(1)BPR-MF。将用户与项目表示成固定维度的嵌入信息,使用BPR损失函数优化后的矩阵分解个性化排序算法^[22]。

(2)DiffNet。一种基于图的社交推荐模型。DiffNet将社交推荐问题重塑为一个异构图,可以同时处理社交网络和兴趣网络的输入^[24]。

(3)NGCF。在多层图卷积网络中,通过显式建模用户与项目之间的高阶连通性来获取嵌入信息,从而有效利用了用户和物品之间的结构信息^[18]。

(4)LightGCN。该方法对NGCF模型进行了改进,删除了非线性激活函数和特征变换两个内容,一定程度上提升了算法的推荐性能^[19]。

(5)DISGCN。主要将社会同质性中的用户兴趣和社会影响力视为影响社交推荐用户行为的两个关键因素^[25]。

3.3 参数设置

实验配置如下:实验环境为Python3.8,操作系统为Windows11,深度学习实施框架为Pytorch,GPU为GeForce RTX 3060。实验中所有模型的嵌入大小固定为64。对于每个数据集,采用随机抽样方法从历史交互数据中选取80%的数据作为训练集,以确保在超参数调优过程中实现公正性,并有效预防过拟合现象,余下20%的数据则根据1:1的比例随机分配给验证集和测试集,以确保模型评估的准确性和可靠性。对于每个观察到的用户-项目交互,会将其看作一个正实例,运用负采样策略将其与用户没有消费过的一个负项目进行配对。模型的默认学习周期数设置为1 000个epoch,当验证集评测指标在20轮内没有任何变化时,训练会提前终止。

冷启动问题是推荐系统领域面临的关键挑战之一,是指因新用户缺乏行为数据或新物品缺少用户反馈,系统难以对用户进行精准推荐。因此,针对冷启动问题,本文设计了评估模型推荐性能的实验。为了保证实验的准确性,除与其它推荐模型中的嵌入维度、批处理和学习率参数保持一致外,其它默认参数均与NGCF^[19]原文献或者源代码相同。

3.4 评价指标

为了有效评估Top-K推荐和用户或项目偏好的先后次序,实验选择精确率(Precision)、召回率(Recall)和归一化折损累计增益(Normalized Discounted Cumulative Gain, NDCG)3个性能评价指标进行评判。精确率和召回率计算公式如式(11)、式(12)所示。

$$Precision = \frac{TP}{TP + FP} \quad (11)$$

$$Recall = \frac{TP}{TP + FN} \quad (12)$$

其中,TP、FP和FN分别为真阳性、假阳性以及假阴性推荐项目数量。真阳性和假阳性项目是由交互推荐产生的结果,而假阴性项目是由非交互推荐产生的结果。

$$NDCG@N = \frac{r(1) + \sum_{i=2}^k \frac{r(i)}{\log_2^i}}{\sum_{i=1}^{|REL|} \frac{r(i)}{\log_2^{(i+1)}}} \quad (13)$$

其中, $r(1)$ 被定义为相关性得分。当 $r(i) = 1$ 时,表明推荐项目与用户之间存在交互行为;当 $r(i) = 0$ 时,表明推荐项目与用户没有发生交互关系。 $|REL|$ 是指根据相关分数降序排序后,得到前N个推荐项目的总和。

3个性能评价指标数值越小,表示推荐效果越差。因为用户和项目之间的交互稀疏性不同,所以会对每个用户重新任意选取一个未评分的项目,将其视作负样本。之后,将收集到的负样本和在训练阶段中与用户交互的项目进行整合。为了实现公正的评价,将对全部项目进行排序。针对特定模型和两个数据集上的每个实验都会重复5次,最终输出运算结果进行对比。

3.5 实验结果分析

将提出的SGNN-AM算法与其他5种基准算法进行比较,实验结果分别如表2、表3所示。实验结果表明,与BPR-MF模型相比,基于图神经网络的NGCF在性能对比实验和冷启动实验中的推荐效果更佳,表明了图神经网络在推荐系统中的重要性。LightGCN因删除了非线性激活和线性转化操作,推荐性能明显优于NGCF和DiffNet。DISGCN模型相比LightGCN表现更优,这得益于其在LightGCN框架上增加了社交信息,并考虑了高阶图结构对用户嵌入的影响。在LastFM和Ciao原始数据集上,与DISGCN相比,SGNN-AM的Precision@20分别提高了2.84%和2.79%,Recall@20分别提高了2.36%和1.14%,NDCG@20分别提高了1.13%和2.28%。在LastFM和Ciao冷启动数据集上,与DISGCN相比,SGNN-AM的Precision@20分别提高了3.88%和3.16%,Recall@20分别提高了12.04%和1.44%,NDCG@20分别提高了23.29%和2.34%。由实验结果可知,SGNN-AM的推荐结果优于其他基准模型,并且对于改善推荐系统的冷启动问题也具有一定效果。

3.6 消融实验

为验证本文算法的有效性,对算法中的注意力机制和

Table 2 Performance comparison of different benchmark algorithms**表 2 不同基准算法性能比较**

算法	LastFM			Ciao		
	Precision@	Recall@	NDCG@	Precision@	Recall@	NDCG@
	20	20	20	20	20	20
BPR-MF	0.101 1	0.207 0	0.195 8	0.013 8	0.040 7	0.030 2
DiffNet	0.121 3	0.248 6	0.238 7	0.017 9	0.053 3	0.041 2
NGCF	0.128 9	0.269 6	0.257 5	0.018 3	0.053 8	0.041 6
LightGCN	0.136 3	0.275 2	0.278 8	0.020 9	0.058 7	0.046 4
DISGCN	0.137 2	0.280 1	0.284 2	0.021 5	0.060 5	0.048 2
SGNN-AM	0.141 1	0.286 7	0.287 9	0.022 1	0.062 3	0.049 3
Improve%	2.842 5	2.356 3	1.301 9	2.790 6	1.136 3	2.282 1

Table 3 Comparison of cold start experiment results**表 3 冷启动实验结果比较**

算法	LastFM			Ciao		
	Precision@	Recall@	NDCG@	Precision@	Recall@	NDCG@
	20	20	20	20	20	20
BPR-MF	0.017 3	0.244 8	0.010 43	0.006	0.037 1	0.021 4
DiffNet	0.026 9	0.239 8	0.128 7	0.007 6	0.052 3	0.030 7
NGCF	0.028 9	0.221 3	0.138 9	0.008 3	0.054 1	0.032 8
LightGCN	0.030 5	0.238 8	0.154 8	0.009 4	0.058 3	0.037 9
DISGCN	0.033 6	0.256 5	0.162 3	0.009 5	0.062 7	0.038 5
SGNN-AM	0.034 9	0.287 4	0.200 1	0.009 8	0.063 6	0.039 4
Improve%	3.869	12.046 7	23.290 2	3.157 8	1.435 4	2.337 6


多层感知机模块进行消融评估。其中,变体模型S1是去除注意力机制模块、S2是去除多层感知机模块、S3是同时去除注意力机制模块和多层感知机模块。在 LastFM 和 Ciao 数据集上的实验结果分别如图 3(a)、(b)所示。当去除注意力机制模块时,S1 的推荐性能有所下降;当去除多层感知机模块时,S2 的推荐准确度欠佳;当两个模块都去除后,S3 的效果最差。通过与其他变体算法比较,可看出 SGNN-AM 的推荐效果最佳,表明 SGNN-AM 挖掘了用户与项目之间的潜在特征信息,证明了所有组件的重要性。

3.7 层数影响


为了更好地评估传播层数对模型性能的影响,将正则化系数设定为 $1e^{-4}$,传播层数设置为 $\{1, 2, 3, 4, 5\}$,实验结果见表 4。当传播层数为 1 时,推荐效果最差,这是因为只考虑了一阶邻居。当传播层数为 3 时,推荐效果最佳,这归因于协作信号分别由二阶和三阶邻居传播连接。然而,当传播层数超过 5 时,推荐性能略有下降。因其只利用了最高阶的邻域而忽略了低阶邻域,使得过平滑问题更加明显。

3.8 正则化系数的影响

为了研究正则化系数 λ 对算法的影响,设置 λ 的取值范围为 $0.1 \sim 0.000\ 001$,传播层数为 3 层,分别在两个数据集上进行实验。在 LastFM 和 Ciao 数据集上的实验结果分别如图 4(a)、(b)所示。从图 4 可以看出,当 λ 的值从 0.1 下降到 0.001 时,算法的推荐性能改善明显,说明模型不容易出现过拟合问题;当 λ 的值为 0.000 1 时,算法的推荐性能达到最佳;当 λ 的值从 0.000 1 下降到 0.000 001 时,算法的推荐性能逐渐下降。实验结果表明,SGNN-AM 对 λ 的取值



(a) LastFM



(b) Ciao

Fig. 3 Ablation experiment results**图 3 消融实验结果****Table 4 Performance comparison of models with different layers****表 4 不同层数的模型性能比较**

层数	LastFM			Ciao		
	Precision@	Recall@	NDCG@	Precision@	Recall@	NDCG@
	20	20	20	20	20	20
1	0.178	0.189	0.223	0.023 4	0.026 7	0.028 3
2	0.185	0.193	0.242	0.036 9	0.040 9	0.042 3
3	0.223	0.231	0.263	0.038 6	0.041 9	0.044 8
4	0.208	0.212	0.257	0.023 4	0.026 7	0.028 3
5	0.196	0.21	0.253	0.036 9	0.040 9	0.042 3

并不敏感,过度正则化会对推荐效果带来负面影响。

4 结语

为改善现有基于图神经网络的社交推荐系统存在的不足,本文提出一种基于注意力机制的图神经网络社交推荐算法 SGNN-AM。SGNN-AM 在用户和项目嵌入信息传播过程中引入注意力机制和多层感知机,避免了多次图卷积后会遇到的过平滑问题,从而挖掘用户和项目之间的潜在关系,提高了推荐的准确度。在两个真实数据集上与其他 5 个模型进行比较,实验结果证明 SGNN-AM 均优于其




Fig. 4 Regularization coefficient experiment results

图4 正则化系数实验结果

他基线算法。在冷启动实验中,SGNN-AM的各项指标均有一定提升,证明了该模型的有效性。

随着时间的推移,用户的兴趣偏好呈现动态变化的趋势,静态推荐系统难以满足用户多变的需求。为了更精确地评估用户不断变化的兴趣,在未来的研究中,将考虑在用户与项目嵌入过程中引入时间上下文,从而进一步提高SGNN-AM推荐的时效性和准确度。

参考文献:

- [1] BORCHERS A, HERLOCKER J, KONSTAN J, et al. Ganging up on information overload[J]. Computer, 1998, 31(4): 106-108.
- [2] MA D, WANG Y, MA J, et al. SGNN: a social graph neural network based interactive recommendation scheme for e-commerce[J]. Tsinghua Science and Technology, 2023, 28(4): 786-798.
- [3] WU S, SUN F, ZHANG W, et al. Graph neural networks in recommender systems: a survey[J]. ACM Computing Surveys, 2022, 55(5): 1-37.
- [4] MAO Q, XIE W C, QIAO Y T, et al. Survey on solving cold start problem in recommendation systems[J]. Journal of Frontiers of Computer Science and Technology, 2024, 18(5): 1197-1210.
毛騫, 谢维成, 乔逸天, 等. 推荐系统冷启动问题解决方法研究综述[J]. 计算机科学与探索, 2024, 18(5): 1197-1210.
- [5] LI X, SUN L, LING M, et al. A survey of graph neural network based recommendation in social networks[J]. Neurocomputing, 2023, 549: 126441.
- [6] FAN W, MA Y, LI Q, et al. Graph neural networks for social recommendation[C]//The World Wide Web Conference, 2019: 417-426.
- [7] DAT N V, TOAN P V, THANH T M. Solving distribution problems in content-based recommendation system with Gaussian mixture model[J]. Applied Intelligence, 2022, 52(2): 1602-1614.
- [8] ZHANG J, GU F, JI Y, et al. Personalized scientific and technological literature resources recommendation based on deep learning[J]. Journal of Intelligent & Fuzzy Systems, 2021, 41(2): 2981-2996.
- [9] YANG Y, WU L, HONG R, et al. Enhanced graph learning for collaborative filtering via mutual information maximization[C]// Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval, 2021: 71-80.
- [10] LIN Z, TIAN C, HOU Y, et al. Improving graph collaborative filtering with neighborhood-enriched contrastive learning[C]//Proceedings of the ACM Web Conference 2022, 2022: 2320-2329.
- [11] WANG Q, YIN H, WANG H, et al. Enhancing collaborative filtering with generative augmentation[C]//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 2019: 548-556.
- [12] WANG J, SHI Y, YU H, et al. Mixed-curvature manifolds interaction learning for knowledge graph-aware recommendation[C]//Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval, 2023: 372-382.
- [13] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks[DB/OL]. <https://arxiv.org/abs/1609.02907>.
- [14] KOREN Y, BELL R, VOLINSKY C. Matrix factorization techniques for recommender systems[J]. Computer, 2009, 42(8): 30-37.
- [15] TANG J, AGGARWAL C, LIU H. Node classification in signed social networks[C]//Proceedings of the 2016 SIAM International Conference on Data Mining, 2016: 54-62.
- [16] WANG F, LI T, WANG X, et al. Community discovery using nonnegative matrix factorization[J]. Data Mining and Knowledge Discovery, 2011, 22: 493-521.
- [17] CHENG Z T, ZHONG T, ZHANG S M, et al. Survey of recommender systems based on graph learning[J]. Computer Science, 2022, 49(9): 1-13.
程章桃, 钟婷, 张晟铭, 等. 基于图学习的推荐系统研究综述[J]. 计算机科学, 2022, 49(9): 1-13.
- [18] WANG X, HE X, WANG M, et al. Neural graph collaborative filtering[C]//Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval, 2019: 165-174.
- [19] HE X, 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, 2020: 639-648.
- [20] WU J, WANG X, FENG F, et al. Self-supervised graph learning for recommendation[C]//Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval, 2021: 726-735.
- [21] XIA L, HUANG C, SHI J, et al. Graph-less collaborative filtering[C]// Proceedings of the ACM Web Conference 2023, 2023: 17-27.
- [22] RENDLE S, FREUDENTHALER C, GANTNER Z, et al. BPR: bayesian personalized ranking from implicit feedback[DB/OL]. <https://arxiv.org/pdf/1205.2618>.
- [23] KINGMA D P, BA J. Adam: a method for stochastic optimization[DB/OL]. <https://arxiv.org/abs/1412.6980>.
- [24] WU L, SUN P, FU Y, 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, 2019: 235-244.
- [25] LI N, GAO C, JIN D, 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.

(责任编辑:黄健)