

融入多影响力与偏好的图对比学习社交推荐算法

胡海波, 杨丹, 聂铁铮, 寇月

引用本文

胡海波, 杨丹, 聂铁铮, 寇月. 融入多影响力与偏好的图对比学习社交推荐算法[J]. 计算机科学, 2024, 51(7): 146-155.

HU Haibo, YANG Dan, NIE Tiezheng, KOU Yue. Graph Contrastive Learning Incorporating Multi-influence and Preference for Social Recommendation [J]. Computer Science, 2024, 51(7): 146-155.

相似文献推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[针对系统调用的基于语义特征的多方面信息融合的主机异常检测框架](#)

Host Anomaly Detection Framework Based on Multifaceted Information Fusion of Semantic Features for System Calls

计算机科学, 2024, 51(7): 380-388. <https://doi.org/10.11896/jsjcx.230400023>

[基于深度确定性策略梯度与注意力Critic的多智能体协同清障算法](#)

Multi-agent Cooperative Algorithm for Obstacle Clearance Based on Deep Deterministic Policy Gradient and Attention Critic

计算机科学, 2024, 51(7): 319-326. <https://doi.org/10.11896/jsjcx.230600129>

[融合多图卷积与层级池化的文本分类模型](#)

Text Classification Method Based on Multi Graph Convolution and Hierarchical Pooling

计算机科学, 2024, 51(7): 303-309. <https://doi.org/10.11896/jsjcx.230400164>

[基于联合学习的语言粒度融合的重叠事件抽取方法](#)

Overlap Event Extraction Method with Language Granularity Fusion Based on Joint Learning

计算机科学, 2024, 51(7): 287-295. <https://doi.org/10.11896/jsjcx.230700118>

[基于外部先验和自先验注意力的图像描述生成方法](#)

Image Captioning Generation Method Based on External Prior and Self-prior Attention

计算机科学, 2024, 51(7): 214-220. <https://doi.org/10.11896/jsjcx.230600167>

融入多影响力与偏好的图对比学习社交推荐算法

胡海波¹ 杨丹¹ 聂铁铮² 寇月²

1 辽宁科技大学计算机与软件工程学院 辽宁鞍山 114051

2 东北大学计算机科学与工程学院 沈阳 110169

(ashuhb@163.com)

摘要 目前,基于图神经网络的社交推荐方法主要对社交信息和交互信息的显式关系和隐式关系进行联合建模,以缓解冷启动问题。尽管这些方法较好地聚合了社交关系和交互关系,但忽略了高阶隐式关系并非对每个用户都有相同的影响,并且监督学习的方法容易受到流行度偏差的影响。此外,这些方法主要聚焦用户和项目之间的协作关系,没有充分利用项目之间的相似关系。因此,文中提出了一种融入多影响力与偏好的图对比学习社交推荐算法(SocGCL)。一方面,引入节点间(用户和项目)融合机制和图间融合机制,并考虑了项目之间的相似关系。节点间融合机制区分图内不同节点对目标节点的不同影响;图间融合机制聚合多种图的节点嵌入表示。另一方面,通过添加随机噪声进行跨层图对比学习,有效缓解了社交推荐的冷启动问题和流行度偏差。在两个真实数据集上进行实验,结果表明,SocGCL 优于其他基线方法,有效提高了社交推荐的性能。

关键词: 社交推荐;注意力机制;图对比学习;图神经网络

中图分类号 TP391

Graph Contrastive Learning Incorporating Multi-influence and Preference for Social Recommendation

HU Haibo¹, YANG Dan¹, NIE Tiezheng² and KOU Yue²

1 School of Computer Science and Software Engineering, University of Science and Technology Liaoning, Anshan, Liaoning 114051, China

2 School of Computer Science and Engineering, Northeastern University, Shenyang 110169, China

Abstract At present, social recommendation methods based on graph neural network mainly alleviate the cold start problem by jointly modeling the explicit and implicit relationships of social information and interactive information. Although these methods aggregate social relations and user-item interaction relations well, they ignore that the higher-order implicit relations do not have the same impacts on each user. And these supervised methods are susceptible to popularity bias. In addition, these methods mainly focus on the collaborative function between users and items, but do not make full use of the similarity relations between items. Therefore, this paper proposes a social recommendation algorithm (SocGCL) that incorporates multiple influences and preferences into graph contrastive learning. On the one hand, a fusion mechanism for nodes (users and items) and a fusion mechanism for graphs are introduced, taking into account the similarity relations between items. The fusion mechanism for nodes distinguishes the different impacts of different nodes in the graph on the target node, while the fusion mechanism for graphs aggregates the node embedding representations of multiple graphs. On the other hand, by adding random noise for cross-layer graph contrastive learning, the cold start problem and popularity bias of social recommendation can be effectively alleviated. Experimental results on two real-world datasets show that SocGCL outperforms the baselines and effectively improves the performance of social recommendation.

Keywords Social Recommendation, Attention Mechanism, Graph Contrastive Learning, Graph Neural Networks

1 引言

社交推荐^[1-2]结合用户对项目的交互信息和用户之间的社交信息学习用户偏好。然而,现有的大多数社交推荐模型

只使用一阶社交邻居缓解协同过滤中的数据稀疏性问题^[3],虽然推荐性能有所提升,但仍存在如下问题。首先,用户不仅受到其直接邻居的影响,还受到以自身为中心的高阶邻居的影响。如图 1(a)所示,虽然用户 u_1 和用户 u_4 不存在朋友关系,

到稿日期:2023-04-21 返修日期:2023-08-29

基金项目:国家自然科学基金(62072084,62072086);辽宁省教育厅科学研究项目(LJKMZ20220646)

This work was supported by the National Natural Science Foundation of China(62072084,62072086) and General Scientific Research Project of Liaoning Provincial Department of Education(LJKMZ20220646).

通信作者:杨丹(asyangdan@163.com)

但用户 u_1 的项目偏好会受到用户 u_4 的影响。这是因为 u_1 是 u_4 的二阶邻居,且存在两条二阶邻居路径,即 $u_1 \rightarrow u_2 \rightarrow u_4$ 和 $u_1 \rightarrow u_3 \rightarrow u_4$ 。其次,相似用户(有共同偏好的用户)之间存在相似偏好,用户偏好不仅与交互的项目相关,还受到相似用户项目偏好的影响。如图 1(b)所示,虽然用户 u_1 没有直接对项目 v_3 的兴趣偏好,但其相似用户 u_3 存在对项目 v_3 的兴趣偏好,用户 u_1 的嵌入表示会受到项目 v_3 的影响。因此,社交推荐利用高阶隐式关系可以更好地建模用户偏好,完成更加个性化、精准的推荐。




图 1 社交推荐示例图

Fig. 1 Illustration of social recommendation

近几年,图神经网络(GNN)中的图卷积网络(GCN)^[4-5]在社交推荐上取得了一定进展。GCN通过对节点进行迭代卷积来捕捉高阶的邻居信息,以更好地建模用户偏好^[6]。同时,为了缓解冷启动和数据稀疏问题,研究者逐渐将图对比学习引入社交推荐。然而,目前基于图对比学习的社交推荐算法仍存在下述问题:首先,没有考虑项目相似关系。现有的大多数社交推荐只引入用户社交网络,忽略了项目之间的相似关系。通过分析用户的交互记录计算物品之间的相似度,可以使推荐结果更加个性化。引入项目的相似网络,不仅可以增强社交推荐的项目嵌入表示,还可以提高推荐系统的解释性。其次,大多数已有的社交推荐方法主要对交互网络图和社交网络图进行联合建模,以学习用户的潜在偏好。然而,不同的用户在平衡两个图时可能存在不同的偏好。例如,一些用户的项目偏好可能受到其社交邻居的影响,而另一些用户则会坚持自己的偏好。因此,动态学习两个图的权重变得至关重要。最后,在冷启动和训练集数量较少时,推荐算法的性能和鲁棒性会受到影响,利用图对比学习可有效解决这一问题。然而,已有的基于图对比学习的社交推荐方法大多数都使用视图增强,通过结构扰动增加原始视图的多样性和复杂性,进而提高推荐性能。但现有研究^[7]已经表明视图增强对推荐性能提升只能起到微小的作用,还会导致模型复杂度增加。因此,使用一个既简单高效又低复杂度的图对比学习方法至关重要。

针对上述问题,本文提出了一个融入多影响力与偏好的图对比学习社交推荐算法 SocGCL,利用高阶隐式关系更好地建模用户偏好。同时,SocGCL 构建了 3 种图,即用户项目交互网络图、用户社交网络图和项目相似网络图。用户社交网络图和用户项目交互网络图从不同的角度提供用户的信息,项目相似网络图和用户项目交互网络图中包含有助于建模项目的信息。此外,SocGCL 引入注意力机制动态聚合不同节点和不同图的嵌入表示。最后,SocGCL 使用一种新的图对比学习方法,通过添加随机噪声进行数据增强,将最后一层嵌入表示与均匀的嵌入表示(对所有层嵌入表示取平均)

进行对比,以减轻流行度偏差对性能的影响,提高算法的泛化能力和鲁棒性。综上所述,本文的主要贡献如下:

1)提出了一个融入多影响力与偏好的图对比学习社交推荐算法,为 3 种图设计了一种基于图卷积神经网络的影响力和偏好扩散机制,利用节点的高阶隐式关系,并使用注意力机制进行节点间融合和图间融合。

2)使用跨层图对比学习方法,平滑地调整节点嵌入表示的一致性,既缓解了冷启动和数据稀疏问题,又弥补了视图增强方法高复杂度的问题。

3)在 Ciao 和 LastFM 数据集上进行大量实验以验证 SocGCL 的有效性和可行性。将 SocGCL 与多种基线方法进行比较,实验结果表明 SocGCL 可以有效缓解冷启动问题。

2 相关工作

本章简要回顾了基于矩阵分解的社交推荐方法、基于图神经网络的社交推荐方法和基于对比学习的社交推荐方法的相关工作。

2.1 基于矩阵分解的社交推荐方法

早期的社交推荐方法大部分都基于矩阵分解技术^[8]。文献[9]在贝叶斯个性化排名的基础上引入社交信息,并认为用户与其社交邻居的项目偏好相似。文献[10]在文献[11]的基础上引入社交信息,将社交邻居的隐式反馈视为用户的辅助隐式反馈。文献[12]将信任传播机制引入模型中,用户嵌入表示与其社交网络中的邻居嵌入表示相关,即两个存在社交关系的用户之间有相似的嵌入表示。文献[13]使用社交信息设计了两个正则项来限制矩阵分解的目标函数,分别为基于平均的正则化和基于个体的正则化。

2.2 基于图神经网络的社交推荐方法

将社交推荐的用户交互网络 and 用户社交网络表示成图,使用图神经网络对图中数据进行迭代聚合,获得图中不同节点的嵌入表示,完成推荐任务。文献[14]率先将图神经网络应用到社交推荐,对用户交互网络图和用户社交网络图中的邻居节点进行迭代聚合,并利用注意力机制为邻居分配不同权重,学习用户嵌入表示。但文献[14]只引入用户之间的社交信息,而忽略了项目之间的相关性。针对该问题,文献[15]在文献[14]的基础上引入项目的相似网络,丰富项目信息。文献[16]使用注意力机制对 3 种社交关系(结构关系、语义关系、情感关系)进行建模,以获取更准确的用户嵌入表示。文献[17]基于 SVD++^[12]的社交推荐模型,对用户交互网络图上的相邻节点进行平均池化;对于用户社交网络图,利用图神经网络迭代聚合用户的高阶邻居节点信息。文献[18]是对文献[17]的扩展,考虑到不同节点对目标节点的影响不同,其使用图注意力机制模拟用户偏好和社交用户之间不同的影响,提高推荐性能。文献[17-18]都采用了分层传播机制模拟社交关系的动态扩散过程。文献[19]提出了双图注意力网络学习双重社交效应的深度隐式表示,一个对用户特定的注意力权重建模,另一个对动态的、上下文感知的注意力权重建模。

2.3 基于对比学习的社交推荐方法

现有基于对比学习的社交推荐方法通过均匀丢弃节点和

边生成新的视图,然后对不同的视图进行对比学习。文献[20]利用社交信息增强用户视图,并构建两个编码器生成来自其他用户的自监督信号,迭代改进每个编码器。文献[21]提出了具有社会意识的双重对比学习,分别考虑用户项目协作关系和项目之间的互信息,并通过适当的负采样消除流行误差。文献[22]构造多种超边,并利用超图结构中的层次结构进行对比学习,其目的是在不同的超图中反映用户的局部和全局高阶连接模式。文献[23]提出了一种解耦对比学习方法,通过最大化嵌入表示之间的互信息,将知识从社会领域转移到协作领域。

3 预备知识和问题描述

3.1 预备知识

设用户集合 $U = \{u_1, u_2, u_3, \dots, u_n\}$ 和项目集合 $V = \{v_1, v_2, v_3, \dots, v_m\}$, n 和 m 分别表示用户和项目的数量。表 1 列出了具体的符号定义。

表 1 符号定义
Table 1 Symbol definition

符号	描述
r_{ij}	用户 u_i 对项目 v_j 的真实评分
G_R	用户项目交互网络图
G_u	用户社交网络图
G_v	项目相似网络图
d	用户和项目的特征嵌入维度
e_{ij}	用户 u_i 对项目 v_j 的评分嵌入表示
p_i	用户 u_i 的嵌入表示
q_j	项目 v_j 的嵌入表示

定义 1 (用户社交网络图) 用户社交网络图定义为

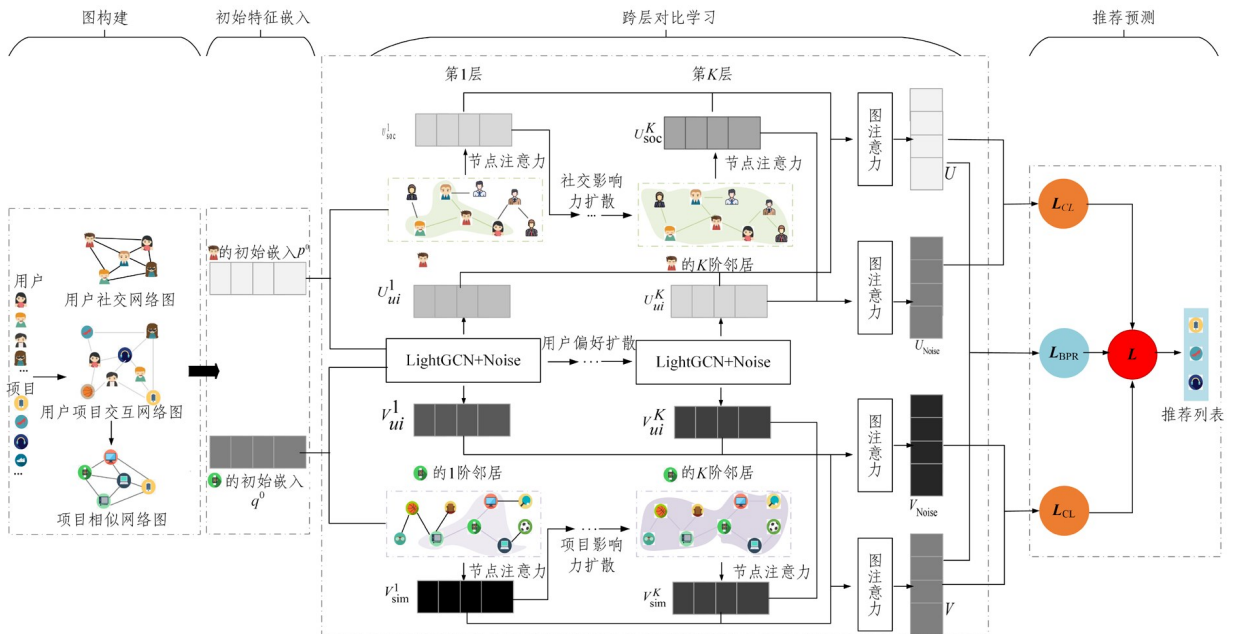


图 2 SocGCL 框架图

Fig. 2 Framework of SocGCL

4.1 图构建

构建用户项目交互网络图 G_R 、用户社交网络图 G_u 和项目相似网络图 G_v 。根据原始数据可以直接构建用户项目

$G_u = \{U, Soc\}$, 其中 $Soc \in R^{M \times M}$ 为用户社交网络图的邻接矩阵, 定义为 $Soc = \{soc_{ij} | i \in U, j \in U\}$ 。

定义 2 (项目相似网络图) 项目相似网络图定义为 $G_v = \{V, Sim\}$, 其中 $Sim \in R^{N \times N}$ 为项目相似网络图的邻接矩阵, 定义为 $Sim = \{sim_{ij} | i \in V, j \in V\}$ 。

定义 3 (用户项目交互网络图) 用户项目交互网络图定义为 $G_R = \{U, V, R\}$, $R \in R^{M \times N}$ 表示存储用户项目交互的评分矩阵, 定义为 $R = \{r_{ij} | i \in U, j \in V\}$ 。

3.2 问题定义

给定用户项目交互网络 (包含交互分数) 和社交网络, 完成 Top-N 推荐任务。SocGCL 的目标是预测用户对未交互项目的交互概率分数, 并据此为每个用户 u_i 推荐最喜欢的前 N 个项目 (未与用户 u_i 交互的项目)。

4 推荐算法

SocGCL 的总体架构如图 2 所示, 主要包括以下 4 个部分: 1) 图构建, 通过对数据进行预处理, 构建用户项目交互网络图、用户社交网络图, 并利用 Jaccard 相似性系数构建项目相似网络图; 2) 初始特征嵌入, 通过用户 ID 和项目 ID 进行初始化, 得到用户和项目的初始嵌入表示和对应的融合嵌入表示; 3) 跨层图对比学习, 使用用户和项目的融合嵌入表示, 对社交网络图和相似网络图中节点的影响扩散过程进行动态建模, 并对交互网络图的节点潜在偏好进行建模, 最终得到各个图中对应的节点嵌入表示, 用于跨层图对比学习; 4) 推荐预测, 对各个图中节点嵌入进行结合, 获得用户和项目的最终嵌入, 预测相应的交互概率分数, 并根据预测结果生成推荐列表。

交互网络图 and 用户社交网络图。项目相似网络图利用 G_R 中的交互信息, 对两个相似项目进行关联, 这种相似性体现在用户交互行为相似, 而不是项目自身属性相似。

例如,两个项目的评价用户大部分都一样,则这两个项目之间的相似度较大。同时考虑到各个项目的交互数量不同,本文使用 Jaccard 相似函数计算各个项目之间的相似性,具体计算式如下:

$$S(i, j) = \frac{G_R(i) \cap G_R(j)}{G_R(i) \cup G_R(j)} \quad (1)$$

其中, $S(i, j)$ 表示项目 v_i 和项目 v_j 之间的相似度, $G_R(i)$ 表示与项目 v_i 有交互的所有用户集合。当 $S(i, j) > 0.5$ 时,表示项目 v_i 和项目 v_j 存在相似关系,并根据项目之间的相似关系构建项目相似网络图。

4.2 初始特征嵌入

使用神经网络的嵌入层初始化得到用户嵌入表示 $p_i^{(0)}$ 、项目嵌入表示 $q_j^{(0)}$ 和评分嵌入表示 e_{ij} ,所有嵌入表示都用固定长度向量 (R^d) 进行编码,设置 $P \in R^{M \times d}$ 和 $Q \in R^{N \times d}$ 表示所用用户和项目的嵌入矩阵。其中, d 是一个超参数,表示特征嵌入维度。上标表示第 k 层的输出, N 和 M 分别表示用户和项目的数量。

对于任意用户 u_i ,通过将用户初始嵌入表示 $p_i^{(0)}$ 和评分嵌入表示 e_{ij} 融合来捕捉用户的初始偏好,得到用户融合嵌入表示 $U^{(0)}$,具体计算式如下:

$$U^{(0)} = MLP([p_i^{(0)} \oplus e_{ij}]) \quad (2)$$

其中, MLP 是一个多层感知机, \oplus 表示对两个向量进行拼接操作。

同理,对于任意项目 v_j , $V^{(0)}$ 是将项目初始嵌入表示 $q_j^{(0)}$ 和评分嵌入表示 e_{ij} 融合的嵌入表示,具体计算式如下:

$$V^{(0)} = MLP([q_j^{(0)} \oplus e_{ij}]) \quad (3)$$

4.3 跨层图对比学习

本节首先介绍了节点的影响扩散和偏好扩散过程,并对扩散结果进行了图对比学习。

4.3.1 影响力和偏好扩散

将用户融合嵌入表示 $U^{(k)}$ 和项目嵌入融合表示 $V^{(k)}$ 作为输入,通过节点扩散模块逐层递归地对用户偏好、项目影响力和社交影响力进行动态建模。每一层都使用前一层的节点嵌入表示作为输入,并在当前层输出更新后的节点嵌入表示。例如,在第 k 层,将用户 u_i 的用户嵌入表示 $U^{(k)}$ 和项目 v_j 的项目嵌入表示 $V^{(k)}$ 作为输入,输出迭代更新的嵌入表示 $U^{(k+1)}$ 和 $V^{(k+1)}$ 。其中, $k \in [0, K]$, K 是一个超参数。

1) 社交影响力扩散。对于用户社交网络图的任意用户 u_i ,传入其第 k 层的嵌入表示,通过迭代聚合邻居信息获得第 $k+1$ 层的聚合嵌入表示,社交扩散过程如下:

$$U_{Soc}^{(k+1)}(i) = \sum_{j \in Soc_i} \eta_{ij}^{(k+1)} \cdot U_{Soc}^{(k)}(j) \quad (4)$$

其中, Soc_i 是社交网络图中用户 u_i 的一阶邻居集合, $U_{Soc}^{(k)}(j)$ 表示用户 u_i 的第 k 层嵌入表示, $U_{Soc}^{(k+1)}(j)$ 表示用户 u_i 的第 $k+1$ 层嵌入表示, $\eta_{ij}^{(k+1)}$ 表示邻居节点 u_j 在用户 u_i 聚合过程中所占的权重。在计算 $\eta_{ij}^{(k+1)}$ 的过程中,最初的方法是将所有的邻居节点设置为相同权重,即 $1/|Soc_i|$ 。然而,该方法忽略了用户偏好的不一致问题,即不同的邻居节点可能有不同的项目偏好。注意力权重 $\eta_{ij}^{(k+1)}$ 的具体计算式如下:

$$\eta_{ij}^{(k+1)} = MLP_{Soc}([U_{Soc}^{(k)}(i), U_{Soc}^{(k)}(j)]) \quad (5)$$

$$\eta_{ij}^{(k+1)} = \frac{\exp(\eta_{ij}^{(k+1)})}{\sum_{a \in Soc_i} \exp(\eta_{ia}^{(k+1)})} \quad (6)$$

其中, MLP_{Soc} 是一个多层感知机,学习第 k 层中用户 u_j 所占的注意力权重。式(6)表示对注意力权重进行归一化, \exp 是一个指数函数,用于保证每个注意力权重都为正数。

2) 项目影响力扩散。对于项目相似网络图的任意项目 v_j , $V_{Sim}^{(k)}(j)$ 表示其在第 k 层的嵌入表示,使用聚合函数获得第 $k+1$ 层的嵌入表示,具体计算式如下:

$$V_{Sim}^{(k+1)}(j) = \sum_{i \in Sim_j} \varphi_{ji}^{(k+1)} \cdot V_{Sim}^{(k)}(i) \quad (7)$$

其中, Sim_j 表示项目相似网络图中项目 v_j 的一阶邻居集合, $V_{Sim}^{(k)}(i)$ 表示项目 v_i 的第 k 层嵌入表示, $U_{Soc}^{(k+1)}(j)$ 表示项目 v_j 的第 $k+1$ 层嵌入表示, $\varphi_{ji}^{(k+1)}$ 是项目 v_i 在聚合过程中的注意力权重。与 $\eta_{ij}^{(k+1)}$ 的计算方法相似,使用注意力机制学习注意力权重 $\varphi_{ji}^{(k+1)}$,具体计算式如下:

$$\varphi_{ji}^{(k+1)} = MLP_{sim}([V_{Sim}^{(k)}(i), V_{Sim}^{(k)}(j)]) \quad (8)$$

$$\varphi_{ji}^{(k+1)} = \frac{\exp(\varphi_{ji}^{(k+1)})}{\sum_{a \in Sim_j} \exp(\varphi_{ja}^{(k+1)})} \quad (9)$$

其中, MLP_{sim} 是一个多层感知机,学习第 k 层中项目 v_i 的注意力权重。式(9)表示对注意力权重进行归一化,可以提高算法的鲁棒性。

3) 用户偏好扩散。在用户项目交互网络图中,本文将 LightGCN^[24] 作为编码器,基于嵌入层的融合嵌入表示学习节点的潜在偏好。LightGCN 通过去除线性变换和非线性激活函数简化了传统的 GCN,提高了运行效率。

对于用户项目交互网络图中的任意用户 u_i ,使用第 k 层的嵌入表示进行聚合、更新,获得第 $k+1$ 层的嵌入表示,扩散过程如下:

$$U_{ui}^{(k+1)}(i) = \sum_{a \in N_i} \frac{U_{ui}^{(k)}(a)}{\sqrt{|N_a|} \sqrt{|N_i|}} \quad (10)$$

其中, N_i 是用户 u_i 的一阶邻居集合, $U_{ui}^{(k)}(a)$ 是用户 u_a 的第 k 层嵌入表示, $U_{ui}^{(k+1)}(i)$ 是更新后的第 $k+1$ 层嵌入表示。 $\frac{1}{\sqrt{|N_a|} \sqrt{|N_i|}}$ 是一个对称归一化项,可以避免嵌入规模随着 GCN 层数的增加而变大。

对于用户项目交互网络图中的任意项目 v_i ,使用第 k 层的邻居节点嵌入表示进行聚合,获得更新后的嵌入表示 $V_{ui}^{(k+1)}(i)$,扩散过程如下:

$$V_{ui}^{(k+1)}(i) = \sum_{b \in N_i} \frac{V_{ui}^{(k)}(b)}{\sqrt{|N_b|} \sqrt{|N_i|}} \quad (11)$$

式(10)和式(11)的本质是聚合邻居节点更新用户 u_i 的嵌入,且只聚合邻居节点,而不聚合目标节点(即自连接)。

4.3.2 对比学习

通过添加随机噪声进行数据增强代替视图增强,优化对比学习损失函数,以获得更均匀的嵌入表示,提高推荐性能。由于用户项目交互信息在推荐算法中具有决定性作用,而用户社交信息和项目相似信息都只是辅助信息,因此本文只在交互网络图中添加随机噪声,具体计算式如下:

$$U_{\text{Noise}}^{(k+1)}(i) = U_{ui}^{(k+1)}(i) + \Delta_i' \quad (12)$$

$$V_{\text{Noise}}^{(k+1)}(i) = V_{ui}^{(k+1)}(i) + \Delta_i' \quad (13)$$

其中, $V_{\text{Noise}}^{(k+1)}(i)$ 和 $U_{\text{Noise}}^{(k+1)}(i)$ 是添加噪声的节点嵌入表示; Δ_i' 是添加的随机噪声向量, 且 $\|\Delta\|_2 = \kappa$, κ 是一个超参数。由于该限制, 数据增强过程中保留了原始嵌入表示的大部分信息, 同时也带来了一些差异。添加的随机噪声只在训练集中使用。

之前的研究表明, 若只使用最后一层的嵌入表示, 随着层数的增加, 基于 GCN 的方法会出现过度平滑的问题^[24]。本文使用跨层图对比(即用最后一层嵌入表示和均匀分布的嵌入表示进行对比)代替最后一层之间的图对比, 该方式在时间复杂度和空间复杂度上都有较大提升。InfoNCE 损失函数 L_{cl} 的具体计算式如下:

$$L_{cl} = \sum_{i \in N_u} -\log \frac{\exp(z_i'^T z_j^{i*} / \tau)}{\sum_{j \in N_u} \exp(\exp(z_i'^T z_j^{i*} / \tau))} \quad (14)$$

其中, N_u 表示与用户 u 存在交互关系的项目集合, τ 是一个超参数, z_i' 表示节点最后一层的嵌入表示, z_j^{i*} 表示所有层节点嵌入表示融合得到的最终嵌入表示。

4.3.3 矩阵运算

使用矩阵运算将用户项目交互图、用户社交图、项目相似图中的节点嵌入表示从第 k 层更新到第 $k+1$ 层。设置用户项目评分矩阵 $R \in R^{M \times N}$, 如果用户 u 与项目 i 存在交互关系, 则 R_{ui} 为对应评分, 否则对应评分为 0。设置评分矩阵 R 的邻接矩阵为 A 。

$$A = \begin{pmatrix} 0 & R \\ R^T & 0 \end{pmatrix} \quad (15)$$

同理, 设置 $Soc \in R^{M \times M}$ 为社交网络图的邻接矩阵, 设置 $Sim \in R^{N \times N}$ 为项目相似网络图的邻接矩阵。

基于上述符号, 第 $k+1$ 层的节点嵌入表示计算式如下:

$$U^{(k+1)} = W_{GU} [\sigma(W_1 \widetilde{Soc} U^{(k)}), (W_2 \widetilde{R} V^{(k)})] \quad (16)$$

$$V^{(k+1)} = W_{GI} [\sigma(W_3 \widetilde{Sim} V^{(k)}), (W_4 \widetilde{R} U^{(k)})] \quad (17)$$

其中, \widetilde{R} 是一个对称归一化矩阵, $\widetilde{R} = D^{-0.5} A D^{-0.5}$, D 是一个对角矩阵。同理, 可以计算 \widetilde{Soc} 和 \widetilde{Sim} 。 W_{GU} 表示社交网络图和交互网络图的用户注意力权重矩阵, W_{GI} 表示相似网络图和交互网络图的项目注意力权重矩阵。在交互网络图中, 获得节点嵌入表示后添加均匀噪声以获得均匀的嵌入表示。最后, 得到用于推荐预测的均匀嵌入矩阵。

$$U = \frac{U^{(1)} + U^{(2)} + \dots + U^{(K)}}{K} \quad (18)$$

$$V = \frac{V^{(1)} + V^{(2)} + \dots + V^{(K)}}{K} \quad (19)$$

最后, 通过将均匀嵌入表示和最后一层嵌入表示进行跨层图对比学习(见式(14)), 来完成推荐任务。

4.4 推荐预测

对每一层的嵌入表示进行组合, 形成均匀分布的节点嵌入表示, 计算过程中不包含节点的初始嵌入表示, 具体计算式如下:

$$U_{\text{Soc}} = \sum_{k=1}^K \alpha_k U_{\text{Soc}}^{(k)} \quad (20)$$

$$V_{\text{Sim}} = \sum_{k=1}^K \alpha_k V_{\text{Sim}}^{(k)} \quad (21)$$

$$U_{ui} = \sum_{k=1}^K \alpha_k U_{ui}^{(k)} \quad (22)$$

$$V_{ui} = \sum_{k=1}^K \alpha_k V_{ui}^{(k)} \quad (23)$$

其中, α_k 表示第 k 层嵌入表示在最终嵌入表示中的权重。 α_k 既可以是手动调整的超参数, 又可以是自动优化的模型参数。实验结果显示, 当 $\alpha_k = 1/k$ 时性能较好。

由于不同节点各不相同, 一些节点容易受到邻居节点的影响, 还有一些节点的偏好比较稳定, 因此各图的权重应该随着节点的不同而个性化更新。本文使用注意力机制学习各个图中节点嵌入表示所占权重, 并得到最终的节点嵌入表示, 具体计算式如下:

$$U = \text{Att}(U_{\text{Soc}}, U_{ui}) \quad (24)$$

$$V = \text{Att}(V_{\text{Sim}}, V_{ui}) \quad (25)$$

其中, U 和 V 表示最终的用户和项目嵌入表示。

对用户和项目的嵌入表示进行内积, 得到用户对未交互项目的预测分数, 具体计算式如下:

$$\hat{r} = U \cdot V \quad (26)$$

其中, \hat{r} 是用于生成推荐列表的预测分数。

4.5 模型训练

SocGCL 包含两个任务: 推荐任务和基于数据增强的跨层图对比学习任务。将贝叶斯个性化排名(BPR)损失函数作为推荐任务的损失函数, 其计算式具体如下:

$$L_{\text{BPR}} = \sum_{(u,i) \in N_u \cup (u,j) \in N_u} -\ln \sigma(\hat{r}_{ui} - \hat{r}_{uj}) + \lambda \|\theta\|^2 \quad (27)$$

其中, N_u 是与用户 u 存在交互关系的项目集合, λ 是控制正则化的超参数, σ 是一个激活函数, θ 是输出的用户嵌入表示和项目嵌入表示。

结合 BPR 损失函数和 InfoNCE 损失函数, 共同优化 SocGCL, 其具体计算式如下:

$$L = L_{\text{BPR}} + \lambda L_{cl} \quad (28)$$

其中, λ 是一个超参数, 表示对比学习的损失函数的权重。

此外, 本文使用 Adam 优化器来优化损失函数, 并利用 Xavier 初始化用户、项目、评分的初始嵌入表示。本文实验部分将对参数设置进行详细描述。

5 算法及复杂度分析

5.1 SocGCL 算法

SocGCL 算法的主要思想是: 利用社交信息和交互信息模拟节点的多影响力与偏好的扩散过程, 预测用户对未交互项目的交互概率分数, 并根据预测分数返回个性化的推荐列表。SocGCL 算法的伪代码如算法 1 所示。

算法 1 SocGCL 算法

输入: 用户集合 U , 项目集合 V , 用户项目交互网络, 社交网络, 层数 K
输出: 推荐列表

1. 根据用户项目交互网络构建项目相似网络, 并将 3 种网络转换为图 (G_u, G_v, G_R) ;

2. 初始化节点和评分嵌入表示 $(p_i^{(0)}, q_j^{(0)}, e_{ij})$, 根据初始嵌入初始化用户和项目的 0 阶嵌入表示 $(V^{(0)}, U^{(0)})$;
3. for $k=1$ to K ; // 执行 K 次;
4. 根据式(4)和式(7)计算用户和项目的交互扩散嵌入表示 $(U_{\text{Soc}}^{(k)}, V_{\text{Sim}}^{(k)})$;
5. 根据式(10)和式(11)计算交互网络图中节点偏好扩散嵌入表示 $(U_{\text{UI}}^{(k)}, V_{\text{UI}}^{(k)})$;
6. 根据式(12)和式(13)对数据增强的用户和项目嵌入表示 $(V_{\text{Noise}}^{(k)}, U_{\text{Noise}}^{(k)})$ 进行迭代更新;
7. end for; // 结束 for 循环
8. 根据式(20)~式(25)计算均匀分布的节点嵌入表示 (U, V) ;
9. 将步骤 6 和步骤 8 的节点嵌入表示代入式(14), 进行跨层图对比学习;
10. 将步骤 8 中的节点嵌入表示代入式(26), 预测用户与未交互项目的交互概率分数;
11. 利用梯度下降更新参数;
12. 直至算法收敛, 返回推荐列表。

5.2 算法复杂度分析

1) 空间复杂度。SocGCL 中的可训练参数主要由两部分组成: (1) 用户和项目的嵌入 $\theta_1 = [U, V]$; (2) 节点注意力和图注意力的权重矩阵运算 $\theta_2 = [\mathbf{W}_{GU}, \mathbf{W}_{GI}, \mathbf{W}_1, \mathbf{W}_2, \mathbf{W}_3, \mathbf{W}_4]$ 。对于(1), 因为大多数基于嵌入的模型都需要存储每个用户和项目的嵌入表示, 这一部分可训练参数的数量与其他模型数量相同且与节点数量成正比。对于(2), 这 6 个权重矩阵在所有节点之间共享, \mathbf{W}_{GU} 和 \mathbf{W}_{GI} 是 $2d \times d$ 维矩阵, 其他 4 个都是 $d \times d$ 维矩阵。综上所述, SocGCL 的空间复杂度近似等于 $(N+M+6d)d$ 。由于节点数量远大于嵌入维度, 因此 $6d^2$ 可以忽略不计, SocGCL 的空间复杂度与经典的嵌入模型相同。

2) 时间复杂度: 与传统的矩阵分解模型相比, SocGCL 的时间复杂度主要体现在跨层图对比学习模块。假设存在 M 个用户和 N 个项目, 用户在社交网络图和交互网络图中平均连接的项目数量分别为 l_{soc}^u 和 l_{ui}^u , 项目在相似网络图和交互网络图中平均连接的用户数量分别为 l_{sim}^i 和 l_{ui}^i 。在第 k 层中, 不仅要计算节点注意力权重, 还要更新节点嵌入表示。因此, 第 k 层的时间复杂度为 $O(M(l_{\text{soc}}^u + l_{ui}^u)d + M(l_{\text{sim}}^i + l_{ui}^i)d)$ 。在最后一层会对多个图的节点嵌入表示进行融合, 该过程的时间复杂度为 $O((M+N)d^2)$ 。跨层图对比学习模块一共有 K 层, 因此 SocGCL 的整体时间复杂度为 $O(K(M(l_{\text{soc}}^u + l_{ui}^u)d + M(l_{\text{sim}}^i + l_{ui}^i)d) + (M+N)d^2)$ 。时间复杂度与节点数量和层数 K 呈线性关系, 因此总时间复杂度在合理范围内。

6 实验

本章详细介绍了实验所需的数据集、评价指标和相关参数, 并进行了大量实验以评估 SocGCL 性能。实验结果可以回答如下问题: 1) SocGCL 是否优于其他社交推荐的基线方法; 2) SocGCL 在冷启动条件下是否能获得较好的性能; 3) SocGCL 的各个模块是否有效, 如对比学习、注意力机制等。

6.1 实验设置

6.1.1 数据集

实验使用两个不同大小、不同稀疏度的真实数据集 Ciao 和 LastFM。Ciao 和 LastFM 数据集的详细信息如表 2 所列。

表 2 数据集的统计信息

Table 2 Statistics of datasets

数据集	Ciao	LastFM
用户	2379	1892
项目	16862	17632
交互关系	35990	92834
社交关系	57544	25434
用户平均交互数量	15.12	49.06
用户平均社交数量	24.18	13.44

6.1.2 评价指标

本文使用归一化折损累积增益 (NDCG)、准确率 (Precision) 和召回率 (Recall) 作为评价指标。Recall 是评估 SocGCL 正确识别所有正样本的能力, 即正确预测的正样本数量占有所有正样本的比率。Precision 指 SocGCL 预测的正样本中, 真正为正样本的比率。NDCG 是评估排序结果的指标, 具体计算式如下:

$$\text{NDCG}@N = \frac{r(1) + \sum_{i=2}^k \frac{r(i)}{\log_2^i}}{\sum_{i=2}^{\lfloor \text{REL} \rfloor} \frac{r(i)}{\log_2^i}} \quad (29)$$

其中, $r(i) = 1$ 表示推荐的项目与目标用户存在交互关系, $r(i) = 0$ 则表示不存在交互关系。 $\lfloor \text{REL} \rfloor$ 表示按 $r(i)$ 排序的前 N 个推荐项目的总数量。

上述 3 个评价指标的取值范围都为 $[0, 1]$ 。评价指标的值越大, 表示 SocGCL 的推荐性能越好。为了方便比较, 本文中所有评价指标的数值均为百分数。

6.1.3 基线方法

基线方法包括基于矩阵分解的社交推荐方法 (SBPR)、基于图神经网络的社交推荐方法 (DiffNet, DiffNet+, SocialLGN, MHCN) 和基于 SSL 的社交推荐方法 (SEPT, S^2 -MH-CN), 详细信息如下。

SBPR^[10]: 基于矩阵分解的社交推荐方法, 其在 BPR 基础上引入了社交信息。

DiffNet^[17]: 基于图的社交推荐方法, 通过用户项目交互网络图和用户社交网络图获取用户的嵌入表示, 生成最终的用户嵌入表示。

DiffNet++^[18]: 基于 GCN 的社交推荐方法, 该方法在 DiffNet 的基础上对用户空间和项目空间的动态扩散过程进行建模。

SocialLGN^[25]: 在 LightGCN 的基础上, 引入社交信息, 设计一种融合方式, 用于在传播过程中聚合用户表示。

MHCN^[22]: 基于超图卷积网络的社交推荐方法, 该方法对具有超边的用户之间的相关性进行建模。

SEPT^[21]: 利用社交网络图增强与用户相关的不同视图, 并设计两个可以增强视图的编码器。

S^2 -MHCN^[22]:在 MHCN 的基础上建立一个自监督的辅助任务,在不同的超图中反映用户的局部和全局高阶关系。

6.1.4 参数设置

为了进行公平的比较,本文参照基线方法的参数设置,并根据实验结果进行微调,确保得到最佳性能。对于 SocGCL,本文使用 Adam 优化方法,学习率默认为 0.001; L_2 正则化系数为 0.0001,批量大小设置为 2408;嵌入维度设置为 64,温度设置为 0.15,层数 K 设置为 3,对比学习权重设置为 $\lambda=0.15$ 。

表 3 SocGCL 与其他基线方法在原始数据集上的性能比较

Table 3 Performance comparison of SocGCL and benchmark methods on original dataset

方法	index	SBPR	DiffNet	SocialLGN	MHCN	SEPT	S^2 -MHCN	DiffNet++	SocGCL
LastFM	Precision@10	16.49	17.27	19.72	19.62	19.89	19.95	18.48	20.00
	Recall@10	16.70	17.79	20.26	19.94	20.48	20.37	18.73	20.51
	NDCG@10	20.21	22.19	25.66	23.83	24.50	24.39	22.31	26.30
	Precision@20	10.10	12.15	13.68	12.85	13.91	13.29	12.74	14.02
	Recall@20	20.70	24.88	27.94	26.12	27.30	27.10	26.52	28.55
	NDCG@20	19.78	24.74	28.83	26.24	27.69	27.07	26.62	29.08
Ciao	Precision@10	1.79	2.38	2.76	2.19	2.68	2.55	2.48	2.94
	Recall@10	2.59	3.41	4.30	2.86	3.60	3.47	3.53	4.42
	NDCG@10	2.66	3.59	4.41	3.19	4.08	3.73	3.66	4.55
	Precision@20	1.41	1.82	2.05	1.73	2.06	1.97	1.88	2.20
	Recall@20	4.12	5.27	6.18	4.52	5.65	5.52	5.67	6.30
	NDCG@20	3.07	4.03	4.86	3.61	4.56	4.64	4.34	5.03

表 4 SocGCL 与其他基线方法在冷启动数据集上的性能比较

Table 4 Performance comparison of SocGCL and benchmark methods on cold-start dataset

方法	index	SBPR	DiffNet	SocialLGN	MHCN	SEPT	S^2 -MHCN	DiffNet++	SocGCL
LastFM	Precision@10	2.82	4.17	4.58	3.18	3.18	3.63	4.57	4.61
	Recall@10	11.51	17.13	19.74	17.38	18.75	20.26	18.61	22.68
	NDCG@10	7.09	11.07	14.19	13.34	13.87	13.34	14.03	17.89
	Precision@20	2.09	2.71	3.33	2.95	3.02	3.18	2.88	3.48
	Recall@20	24.67	24.07	26.63	25.68	25.56	28.14	25.49	30.26
	NDCG@20	11.09	13.09	16.43	16.33	14.70	17.37	15.66	20.38
Ciao	Precision@10	0.70	1.04	1.34	1.20	1.15	1.27	1.09	1.39
	Recall@10	2.34	3.39	4.41	3.73	3.74	3.92	3.50	4.72
	NDCG@10	1.65	2.48	3.28	2.66	2.68	2.88	2.54	3.39
	Precision@20	0.60	0.81	0.97	0.88	0.87	0.92	0.85	1.02
	Recall@20	3.84	5.39	6.30	5.45	5.50	5.98	5.44	6.58
	NDCG@20	2.19	3.16	3.94	3.45	3.31	3.79	3.26	4.01

实验结果表明,基于矩阵分解的推荐方法在原始测试集和冷启动测试集上的表现都差强人意。而基于图神经网络和基于 SSL 的社交推荐方法在推荐性能上各有千秋,相差不大。在所有方法中,SocGCL 在原始测试集和冷启动测试集中都取得了最佳性能,而 SocialLGN 在所有基线模型中获得了最佳性能。由于 SocialLGN 没有引入项目相似网络图,通过对比表 3 中 SocGCL 和 SocialLGN 的推荐性能,可以验证项目相似关系可以帮助系统缓解冷启动问题。与 SocialLGN 相比,SocGCL 在冷启动的 LastFM 数据集上性能取得了较大提升,在 NDCG@10 和 NDCG@20 上分别提升了 26% 和 24%。这也验证了 SocGCL 可以在一定程度上缓解冷启动问题。此外,实验结果表明,社交关系密度越高,提升的效果越好。LastFM 和 Ciao 数据集的社交关系密度分别为 0.71% 和 0.11%。

6.3 消融实验和有效性分析

本节研究 SocGCL 中不同模块的有效性和重要的参数

6.2 实验结果分析

本文在 Ciao 和 LastFM 数据集上进行大量实验,并将 SocGCL 与其他基线方法进行比较。表 3 和表 4 列出了对 Top-10 和 Top-20 推荐中 3 个评价指标的数值。表 3 是对测试集中所有用户进行测试,表 4 只对冷启动用户进行评估。由于冷启动问题是对只与少数项目交互的用户进行推荐,因此本文将测试集中交互次数少于 20 的用户视为冷启动用户,并生成一个冷启动数据集。

影响,并进行了消融实验和参数敏感性分析。

6.3.1 消融实验

本小节通过消融实验研究 SocGCL 中的关键模块对推荐性能的影响以及各个模块的有效性。删除 SocGCL 中部分模块获得以下几种变体方法:1) SocGCL-Item(称为方法 A),即去除项目之间的相似关系;2) SocGCL-NodeAtt(称为方法 B),即去除节点间的融合机制;3) SocGCL-GraphAtt(称为方法 C),即去除图间的融合机制;4) SocGCL-CL(称为方法 D),即去除跨层图对比学习模块。

上述 4 种方法在 Ciao 和 LastFM 数据集上的实验结果如图 3 所示,横坐标表示 SocGCL 和其变体方法,纵坐标表示评价指标的值。从图 3 可以观察到,在 Ciao 和 LastFM 数据集上,SocGCL 优于其他变体方法,取得了最佳性能。移除对比学习的变体方法 D 和移除图间融合机制的变体方法 C 在 Ciao 和 LastFM 上性能下降幅度较大,这验

证了图间融合机制和跨层图对比学习在提升模型性能方面起到重要作用。虽然方法 A 和方法 B 的下降幅度较小,

但不可否认项目相似关系和节点间融合机制对提升性能的积极作用。




图 3 两个数据集上不同方法的训练结果

Fig. 3 Training results of different methods on two datasets

6.3.2 嵌入维度的影响

本小节将研究特征嵌入维度对 SocGCL 的影响,保持其他参数不变,通过调整嵌入维度大小,观察 SocGCL 性能的变化。图 4 给出了 SocGCL 在 Ciao 和 LastFM 数据集上不同嵌入维度的实验结果,横坐标为评价指标,纵坐标为评价指标的值。随着特征嵌入维度的增加,SocGCL 的性能在 Ciao 和 LastFM 数据集上也随之提升。当嵌入维度

由 16 提升到 64 时,SocGCL 的性能明显提升,并接近最优性能。当嵌入维度大于 64 时,SocGCL 的性能逐渐趋于稳定,没有明显提升。实验结果表明,增加嵌入维度可以提高推荐性能。然而,当嵌入维度过高时,不仅会增加 SocGCL 的复杂度,还会降低 SocGCL 的运行效率。因此,选择 64 作为特征嵌入维度,这样既保证了模型性能,又缩短了训练时间。

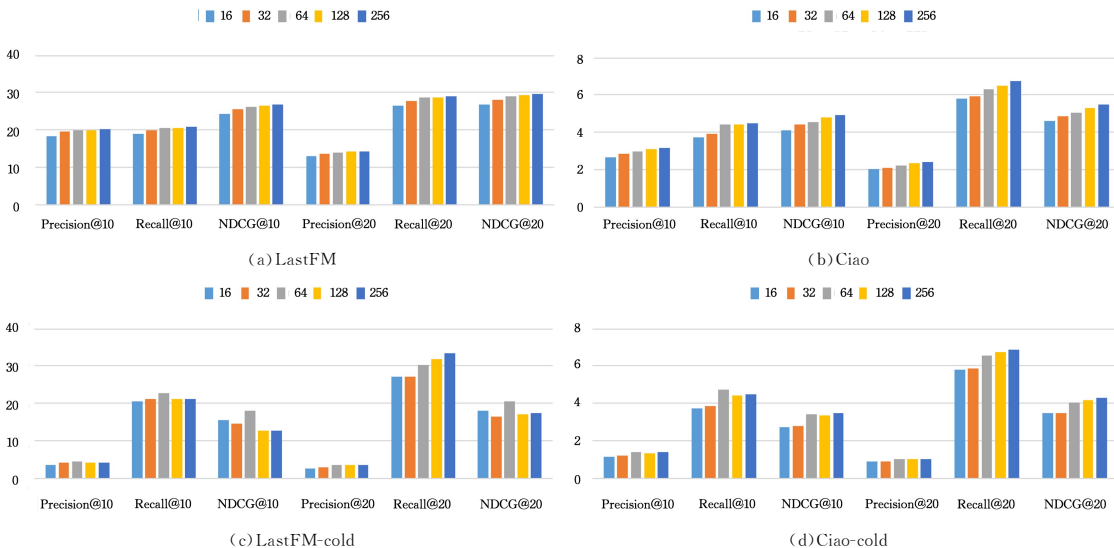



图 4 嵌入维度对 SocGCL 的影响

Fig. 4 Effect of embedding dimension on SocGCL

6.3.3 层数的影响

本小节将研究层数 K 对 SocGCL 的影响,保持其他参数不变,通过调整 K 值,观察 SocGCL 性能的变化。图 5 给出了 SocGCL 在 Ciao 和 LastFM 数据集上不同 K 值的实验结果,横坐标表示层数 K ,纵坐标为评价指标的值。从图 5 可以观察到,在 Ciao 数据集中,当 K 值由 1 增加到 3 时,SocGCL

的性能快速提升,并达到最大值。当 K 值大于 3 时,SocGCL 的性能逐渐下降。在 LastFM 数据集上也观察到相似的趋势,SocGCL 的性能在达到最优值后会降低。综上所述,过大的 K 值会导致过度平滑^[25],模型性能也随之下降。同时,由于社交影响随着用户和 K 阶邻居之间距离的增大而减小,因此将 K 值设置为 3,既可以聚合足够的信息,又可以少一些噪声。

图5 层数 K 对 SocGCL 的影响Fig. 5 Effect of layer number K on SocGCL

6.3.4 温度的影响

本小节将研究温度参数对 SocGCL 的影响,保持其他参数不变,通过调整温度参数大小,观察 SocGCL 性能的变化。表 5 列出了 SocGCL 在 Ciao 和 LastFM 数据集上不同温度的实验结果,评价指标数值越大,代表 SocGCL 性能越好。从表 5 可以观察到,在 Ciao 和 LastFM 数据集中,温度参数为 0.15 时 SocGCL 达到最佳性能,当温度参数过大(0.2)或过小(0.1)时,SocGCL 的性能都会下降。因此,将温度参数设置为 0.15,以确保 SocGCL 达到最佳性能。

表 5 温度参数对性能的影响

Table 5 Effect of temperature parameter on performance

datasets	index	温度		
		0.10	0.15	0.20
LastFM	Precision@10	19.21	20.00	19.51
	Recall@10	19.65	20.51	19.94
	NDCG@10	25.44	26.30	25.57
	Precision@20	13.46	14.02	13.81
	Recall@20	27.42	28.55	28.11
	NDCG@20	28.13	29.08	28.46
Ciao	Precision@10	2.92	2.94	3.05
	Recall@10	4.09	4.42	4.36
	NDCG@10	4.54	4.55	4.80
	Precision@20	2.23	2.20	2.29
	Recall@20	6.33	6.30	6.47
	NDCG@20	5.09	5.03	5.28

6.3.5 对比学习权重的影响

本小节将研究对比学习权重 λ 对 SocGCL 的影响,保持其他参数不变,通过调整 λ 值,观察 SocGCL 性能变化。表 6 列出了 SocGCL 在 Ciao 和 LastFM 数据集上不同 λ 值的实验结果。从表 6 可以观察到,在 Ciao 和 LastFM 数据集中,随着 λ 值的增加,SocGCL 性能逐渐提高,并在 $\lambda=0.15$ 时达到最佳性能。

表 6 温度参数对性能的影响

Table 6 Effect of temperature parameter on performance

datasets	index	$\lambda=0.10$	$\lambda=0.15$	$\lambda=0.20$
LastFM	Precision@10	19.52	20.00	19.55
	Recall@10	19.91	20.51	20.00
	NDCG@10	25.76	26.30	25.90
	Precision@20	13.74	14.02	13.55
	Recall@20	27.92	28.55	27.62
	NDCG@20	28.56	29.08	28.45
Ciao	Precision@10	2.95	2.94	2.70
	Recall@10	4.16	4.42	3.86
	NDCG@10	4.61	4.55	4.25
	Precision@20	2.25	2.29	2.04
	Recall@20	6.34	6.30	5.82
	NDCG@20	5.13	5.03	4.71

结束语 本文提出了一种融入多影响力与偏好的图对比学习社交推荐算法 SocGCL,使用注意力机制学习不同节点和不同图的影响因子,以解决其他社交方法存在的数据稀疏和流行度偏差问题。此外,通过添加随机噪声实现数据增强,并引入跨层图对比学习方法解决冷启动问题。通过分析 SocGCL 的时间复杂度和空间复杂度,结果表明 SocGCL 在训练过程中内存使用率和时间成本都处在合理范围。与现有方法相比,SocGCL 在 Ciao 和 LastFM 数据集上都取得了更好的性能,实验结果验证了 SocGCL 中各个模块的有效性。未来工作中考虑将社交信息和交互信息结合以构建用户-项目-用户三元关系,并使用超图神经网络对三元关系进行建模,学习用户的潜在偏好。

参考文献

- [1] PENG H L,ZHANG X J,JIN K Z. Social Recommendations Method Based on Differential Privacy[J]. Computer Science, 2017,44(S1):395-398.
- [2] QIAN F L,LI Q L. Social Recommendation Combining Global and Dual Local Information[J]. Computer Science,2016,43(2):

- 57-59.
- [3] GUO G,ZHANG J,YORKE-SMITH N. A Novel Recommendation Model Regularized with User Trust and Item Ratings[J]. IEEE Transactions on Knowledge and Data Engineering,2016,28(7):1607-1620.
- [4] GUO Z,WANG H. A Deep Graph Neural Network-Based Mechanism for Social Recommendations[J]. IEEE Transactions on Industrial Informatics,2020,17(4):2776-2783.
- [5] JIN B,CHENG K,ZHANG L,et al. Partial Relationship Aware Influence Diffusion via a Multi-channel Encoding Scheme for Social Recommendation[C]//The 29th ACM International Conference on Information and Knowledge Management(CIKM'20). ACM,2020:585-594.
- [6] LIU S H,WANG B,DENG X J,et al. Self-Attentive Graph Convolution Network with Latent Group Mining and Collaborative Filtering for Personalized Recommendation [C] // IEEE Transactions on Network Science and Engineering (TNSE). 2021.
- [7] YU J,YIN H,XIA X,et al. Are graph augmentations necessary? simple graph contrastive learning for recommendation[C]//Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2022:1294-1303.
- [8] KOREN Y,BELL R,VOLINSKY C. Matrix factorization techniques for recommender systems[J]. IEEE, Computer Journal, Computer,2009,42(8):30-37.
- [9] TONG Z,MCAULEY J,KING I. Leveraging Social Connections to Improve Personalized Ranking for Collaborative Filtering [C]//The 23rd ACM International Conference. ACM,2014.
- [10] JAMALI M,ESTER M. A matrix factorization technique with trust propagation for recommendation in social networks[C]//ACM Conference on Recommender Systems. ACM,2010.
- [11] 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. Las Vegas,Nevada,USA,2008.
- [12] YANG B,LEI Y,LIU J,et al. Social Collaborative Filtering by Trust[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2016:39(8):1633-1647.
- [13] HAO M,ZHOU D,CHAO L,et al. Recommender systems with social regularization[C]//Proceedings of the Forth International Conference on Web Search and Web Data Mining (WSDM 2011). Hong Kong,China,DBLP,2011.
- [14] FAN W Q,MA Y,LI Q,et al. Graph neural networks for social recommendation[C]//The World Wide Web Conference(WWW 2019). San Francisco,CA,USA,2019:417-426.
- [15] SHA X,SUN Z,ZHANG J. Disentangling Multi-Facet Social Relations for Recommendation[J]. IEEE Transactions on Computational Social Systems,2021,9(3):867-878.
- [16] FAN W,MA Y,LI Q,et al. A Graph Neural Network Framework for Social Recommendations[J]. IEEE Transactions on Knowledge and Data Engineering,2020,34(5):2033-2047.
- [17] 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.
- [18] WU L,LI J,SUN P,et al. DiffNet++:A Neural Influence and Interest Diffusion Network for Social Recommendation [J]. IEEE Trans. Knowl. Data Eng,2020,34(10):4753-4766.
- [19] WU Q,ZHANG H,GAO X,et al. Dual Graph Attention Networks for Deep Latent Representation of Multifaceted Social Effects in Recommender Systems[C]//The World Wide Web Conference. 2019:2091-2102.
- [20] YU J L, YIN H Z,GAO M,et al. Socially-aware self-supervised tri-training for recommendation [C] // Proceedings of ACM SIGKDD Conference on Knowledge Discovery & Data Mining (KDD),2021:2084-2092.
- [21] DU J,YE Z S,YAO L N,et al. Socially-aware Dual Contrastive Learning for Cold-Start Recommendation[C]//Proceedings of International ACM SIGIR Conference on Research and Development in Information Retrieval (SIGIR). 2022:1927-1932.
- [22] YU J L, YIN H Z,LI J D,et al. Self-supervised multi-channel hypergraph convolutional network for social recommendation [C] // Proceedings of the ACM Web Conference (WWW). 2021:413-424.
- [23] WU J H,FAN W Q,CHEN J F,et al. Disentangled Contrastive Learning for Social Recommendation[C]//Proceedings of ACM International Conference on Information & Knowledge Management (CIKM). 2022:4570-4574.
- [24] 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. 2020:649-648.
- [25] LIAO J,ZHOU W,LUO F,et al. SocialLGN:Light graph convolution network for social recommendation [J]. Information Sciences,2022,589(C):595-607.



HU Haibo, born in 2000, postgraduate, is a student member of CCF (No. O8310G). His main research interests include recommendation system and data integration.



YANG Dan, born in 1978, Ph.D, professor, is a senior member of CCF (No. 20240S). Her main research interests include recommendation system, data integration, and medical big data.