

融合物品关系的图神经网络推荐算法

廖冬, 于海征

引用本文

廖冬, 于海征. 融合物品关系的图神经网络推荐算法[J]. 计算机科学, 2023, 50(11A): 230100019-9.

LIAO Dong, YU Haizheng. [Graph Neural Network Recommendation Algorithm Based on Item Relations](#) [J]. Computer Science, 2023, 50(11A): 230100019-9.

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)

[一种融合CNN和Swin Transformer的医学显微图像分割模型](#)

Medical Microscopic Image Segmentation Model Based on CNN Structure and Swin Transformer
计算机科学, 2023, 50(11A): 230200119-8. <https://doi.org/10.11896/jsjcx.230200119>

[基于注意力机制和ConvLSTM的船舶交通流量预测算法](#)

Ship Traffic Flow Prediction Algorithm Based on Attention Mechanism and ConvLSTM
计算机科学, 2023, 50(11A): 230800067-7. <https://doi.org/10.11896/jsjcx.230800067>

[基于图卷积网络和注意力机制的诊断预测](#)

Diagnosis Prediction Based on Graph Convolutional Network and Attention Mechanism
计算机科学, 2023, 50(11A): 221100232-6. <https://doi.org/10.11896/jsjcx.221100232>

[基于知识蒸馏和高效通道注意力的异常检测](#)

Novelty Detection Method Based on Knowledge Distillation and Efficient Channel Attention
计算机科学, 2023, 50(11A): 220900034-10. <https://doi.org/10.11896/jsjcx.220900034>

[贝叶斯网络结构学习的CMIHC算法](#)

CMIHC Algorithm for Bayesian Network Structure Learning
计算机科学, 2023, 50(11A): 220800046-7. <https://doi.org/10.11896/jsjcx.220800046>

融合物品关系的图神经网络推荐算法

廖冬 于海征

新疆大学数学与系统科学学院 乌鲁木齐 830017

(1171877184@qq.com)

摘要 典型的社交推荐方法都受限于对用户的行为建模,如用户与用户之间的社交行为、用户与物品之间的交互行为,而忽略了用户感兴趣的多个物品之间存在的潜在相关性,导致信息丢失。在数据稀疏的推荐场景中,用户行为的稀疏性导致系统可用的信息不足,因此需要引入具有丰富内涵的物品关系作为辅助信息。文中致力于融合用户行为和辅助信息共同建模用户的偏好,以提升推荐的准确性。推荐系统中的数据大多可以表示为图结构,例如用户的社交行为、交互行为和物品关系,可以转化为用户-用户图、用户-物品图和物品-物品图。图神经网络在处理大规模图形数据方面颇有成效,建立一个包含物品关系的图神经网络推荐框架面临巨大的挑战:1)物品-物品关系是隐式的;2)用户-用户图、用户-物品图、物品-物品图,是3种不同类型的图;3)用户与用户、用户与物品、物品与物品之间的联系都具有异质性。为了解决上述问题,文中提出了一种新的基于图神经网络的社交推荐方法(PEVGraphRec),引入了一种数学上的方法显式地构建物品间的连接,该模型能够内在地结合3种不同的图,以便更好地学习用户偏好。最后,提出了注意力机制来综合地考虑不同信息的权重。在3个真实数据集上进行实验,实验结果证明了所提方法的有效性。

关键词: 社交推荐;图神经网络;物品-物品图;异质性;注意力机制

中图法分类号 TP183

Graph Neural Network Recommendation Algorithm Based on Item Relations

LIAO Dong and YU Haizheng

College of Mathematics and System Sciences, Xinjiang University, Urumqi 830017, China

Abstract Typical social recommendation methods are limited by modeling user behavior, such as social behavior between users, interaction behavior between users and items. However, the potential correlation between multiple items that users are interested in is ignored, leading to information loss. In recommendation scenarios with sparse data, the sparsity of user behavior leads to insufficient information available in the system, so it is necessary to introduce item relationships with rich connotations as auxiliary information. This paper aims to integrate user behavior and auxiliary information to jointly model user preferences, so as to improve the accuracy of recommendations. Most of the data in the recommendation system can be expressed as a graph structure, such as user's social behavior, user's interactive behavior and item relationship, which can be converted into user-user graph, user-item graph and item-item graph. Graph neural networks (GNN) are effective in processing large-scale graphic data, and building a framework with item relations based-GNN for social recommendations is facing considerable challenges: 1) the item-item relationship is implicit; 2) user-user graph, user-item graph, and item-item graph are three different types of graphs; 3) the relationship between user and user, user and item, item and item is heterogeneous. In order to solve the above problems, this paper proposes a new social recommendation method based on graph neural network, PEVGraphRec, which introduces a mathematical way to explicitly construct connections between items. This model inherently combines three different graphs to better learn user preference. Finally, an attention mechanism is proposed to consider the weight of different information comprehensively. Comprehensive experiments on three real-world datasets verify the effectiveness of the proposed framework.

Keywords Social recommendation, Graph neural network, Item-Item graph, Heterogeneous, Attention mechanism

推荐系统通过预测用户对商品的偏好和兴趣,来为用户的决策提供帮助,以此缓解信息过载问题^[1]。然而,由于收集数据的成本较高,大多数现有的推荐系统都遭遇数据稀疏和冷启动问题^[2]。为了缓解这两个问题,文献[3-5]提出将用户之间的社交信息纳入推荐,作为用户-物品交互的辅助信息。

研究表明,人们的行为很容易受到朋友的影响,并且倾向和有相似喜好的人交朋友^[6-7],这意味着社交关系对用户的决策产生着重要影响^[8]。因此,社会关系的应用大大提升了许多推荐系统^[9-11]的性能。

推荐系统中的大部分信息本质上都具有图结构。图神经

基金项目:国家自然科学基金(61662079,11761070,U1703262);新疆维吾尔自治区自然科学基金面上项目(2021D01C078)

This work was supported by the National Natural Science Foundation of China(61662079,11761070,U1703262) and Natural Science Foundation of Xinjiang, China(2021D01C078).

通信作者:于海征(yuhaizheng@xju.edu.cn)

网络(Graph Neural Networks, GNN)在图^[12-14]表示学习方面具有优势。具体表现为,图神经网络能够自然地整合图领域内的节点信息和拓扑结构,与传统神经网络相比它在特征提取和表示上更加高效^[15],可伸缩性更强,能够处理的数据规模更大^[16]。因此,凭借其在特征提取上表现出的优越性能,使得图神经网络在推荐方面的应用成为了发展的必然趋势^[17]。

学习每个用户和物品的低维潜在表示是构建推荐系统的关键^[18]。社交推荐中的数据通常被建模成两个图,一个是用户-物品交互图,用于表示用户和物品之间的交互关系,另一个是反映用户之间关系的社交图。除了这两种显式的关系,大多数的社交推荐都忽略了一个重要的信息来源,即物品与物品之间潜在的关系。事实上,物品间的关系可以增强物品的表示学习。因为物品与物品之间并不是相互独立的,它们很可能是相似或者有关联的^[19-20]。物品关系能够从侧面反映出用户的隐藏兴趣。例如,购买了电脑的用户很可能购买鼠标,因为它们之间存在一定的关联性(即功能是适配的)。因此,当用户计划购耳机时,有线耳机和无线耳机大概率是捆绑出现的,因为它们的功能相似。许多应用程序试图运用物品之间的关系,来发现新的或之前未知的物品,以及识别用户感兴趣的物品组合。具体地说,亚马逊允许用户在商品之间进行导航,例如“购买了 X 的用户也购买了 Y”以及“浏览 X 的用户也浏览 Y”^[21]。显然,物品之间的关系也可以建模成图数据,表示为物品-物品图,如图 1(c)所示。由于用户的交互行为通常会随时间发生改变,用户与物品之间的关系存在着许多不确定因素,而物品关系是一种相对稳定且易于获取的信息。因此,利用物品之间的关系增强用户的偏好学习是一种可靠的方法。

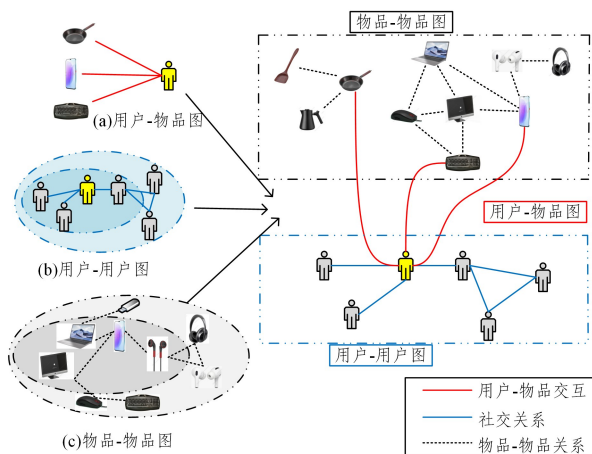


图 1 社交推荐中的图数据

Fig. 1 Graph data in social recommendations

因此,可将 3 个异构图,即用户-物品图、用户-用户图(社交图)、物品-物品图,作为社交推荐系统的数据来源。然而,要建立基于 GNN 的社交推荐,并且同时对上述的 3 个图进行建模面临一些挑战。物品与物品之间的关系是隐式的,不同于用户与用户社交关系、用户与物品交互关系那样实体之间存在明确的链接。因此,第一个挑战是如何建立物品之间的关系,并构建物品-物品图。这 3 个异构图从不同的角度提供了用户兴趣和物品属性,将它们的信息汇总有助于学习更好的用户和物品表示。第二个挑战是如何本质地结合这些图。

此外,由于在线世界中链接信息的低成本,因此可能导致社交网络具有不同强度的连接^[22],如亲密朋友、普通朋友、活动朋友。用户在交流兴趣爱好时,更可能与亲密的朋友分享,而不是普通朋友。因此,平等地考虑社交网络中的友谊^[23],可能无法很好地模拟它们真实的关系,甚至会导致推荐性能下降。同理,物品与物品间的关联强度、用户与物品间的互动强度也是不同的。因此,第三个挑战是如何解决实体间连接强度不一致的问题。

为了解决上述 3 个挑战,受到 Graph^[24]的启发,本文提出了一个新的基于 GNN 的社交推荐模型 PEVGraphRec,它能够敏锐地捕获网络各方面的有效信息,并基于这些内容进行推荐和预测。该模型基于相似性构建物品间的关系,其中相似性度量本文采用的是 Zhang 等提出的 PEV 方法^[25],该方法能够弥补传统相似性在冷启动情况下的不足。接下来,利用图神经网络从用户-用户图和用户-物品图中学习用户的表示,从物品-物品图和用户-物品图中学习物品的表示。最后,将用户表示和物品表示输入多层感知机,得到评分预测。

本文的贡献可以概括如下:

- 1)介绍了一种数学上挖掘物品关系的 PEV 方法,构建物品-物品图。物品关系的融入,使得整个模型更加灵活、可靠。
- 2)提出了一个新的图神经网络 PEVGraphRec,该模型连贯地对多种关系进行建模,增强了用户和物品的表示。
- 3)注意力机制的应用解决了各种关系存在的连接强度不一致问题。
- 4)在 3 个真实世界的数据集上进行了实验,结果表明,所提框架具有较好的鲁棒性,能够更好地对抗系统的冷启动问题。

1 相关工作

1.1 符号说明

令 $U = \{u_1, u_2, \dots, u_n\}$ 与 $V = \{v_1, v_2, \dots, v_m\}$ 分别为用户集合和物品集合, n 和 m 代表系统中的用户总数、物品总数。 $p_i \in \mathbb{R}^d$ 是用户的原始嵌入, $q_j \in \mathbb{R}^d$ 是物品的原始嵌入, d 为用户和物品的嵌入长度。 $U_{i,j}$ 表示同时对物品 v_i 和 v_j 评分的用户集合。

将评分矩阵 $\mathbf{R} \in \mathbb{R}^{n \times m}$ 视为用户-物品图,若用户 u 对物品 i 有评分,那么 $r_{i,j}$ 表示评分,若用户与物品之间没有评分,则将其填充为 0。将邻接矩阵 $\mathbf{T} \in \mathbb{R}^{n \times n}$ 看作用户-用户社交图, $t_{i,j} = 1$ 表示用户 u_i 和 u_j 之间有社交关系,否则没有。

上述两个图很容易建立,因为它们都是显式的关系。而物品与物品之间的关系是隐式的,没有明确的连接,接下来介绍一种数学上的挖掘物品关系的方法。通过用户的点击或评分行为计算两个物品间的相关性是最常见的方法之一^[26]。但是传统方法严重依赖评级数据,导致其面临数据稀疏的挑战。

1.2 PEV 相似性度量方法

Zhang 等^[25]提出的 PEV 相似性度量方法,打破了传统方法在数据稀疏场景下的局限性。该方法从 3 个角度,即邻近度(Proximity)、影响力(Effect)、有用性(Value),充分利用评分信息,全面地度量物品之间的关联。PEV 对相似性的定义如下:

$$S_{ij} = \sum_{u \in U_{i,j}} PEV(r_{u,i}, r_{u,j}) \quad (1)$$

其中, $S_{ij} \in (0, 1)$ 表示物品 i 和 j 之间的相似度, $r_{u,i}$ 和 $r_{u,j}$ 分别表示目标用户 u 对物品 v_i 和 v_j 的评分, $U_{i,j}$ 表示共同评分过物品 v_i 和 v_j 的用户集合。若用 R_1 和 R_2 分别表示目标用户对任意两个物品的评分, 则有:

$$PEV(R_1, R_2) = Proximity(R_1, R_2) \times Effect(R_1, R_2) \times Value(R_1, R_2) \quad (2)$$

具体的计算方法如表 1 所列。其中评分一致是为了判断两评分之间的真实距离。若用户对某两个物品的评分同时大于或小于中间值, 则用户对这两个物品的评分具有一致性 Agreement 并取值为 1, 否则为不一致, Disagreement 取值为 0。中间值为 $R_{med} = \frac{R_{max} - R_{min}}{2}$, 其中 R_{max} 和 R_{min} 分别为评分系统中的最大、最小阈值。 \bar{R} 表示该用户的平均评分。

表 1 关于 PEV 相似性度量方法的计算

Table 1 Calculation of PEV similarity measurement method

度量标准	计算方法
评分一致性	$Agreement(R_1, R_2) = \begin{cases} 1, & R_1, R_2 > R_{med} \text{ 或者 } R_1, R_2 < R_{med} \\ 0, & \text{其他} \end{cases}$
评分距离	$d(R_1, R_2) = \begin{cases} R_1 - R_2 , & Agreement = 1 \\ 2 R_1 - R_2 , & Agreement = 0 \end{cases}$
邻近度	$Proximity(R_1, R_2) = \frac{1}{\{(2(R_{max} - R_{min}) + 1) - d(R_1, R_2)\}^2}$
影响力	$Effect(R_1, R_2) = \begin{cases} (R_1 - R_{med} + 1)(R_2 - R_{med} + 1), & \text{若 } Agreement = 1 \\ \frac{1}{(R_1 - R_{med} + 1)(R_2 - R_{med} + 1)}, & \text{若 } Agreement = 0 \end{cases}$
有用性	$Value(R_1, R_2) = \begin{cases} 1 + \left(\frac{R_1 + R_2}{2} - \bar{R}\right)^2, & \text{若 } R_1, R_2 > \bar{R} \text{ 或 } R_1, R_2 < \bar{R} \\ Value(R_1, R_2) = 1, & \text{其他} \end{cases}$

当且仅当 $S_{ij} \geq \theta$, 物品 v_i 和 v_j 之间存在相似连接, 其中 θ 为一个固定的阈值。建立物品-物品图为 $G = (V_I, E_I)$, 其中 V_I 是物品集合, E_I 是边集合, 用于连接两个相关的物品。

综上所述, 本文所用到的 3 个图已全部构建完成, 即

用户-物品图 R 、用户-用户社交图 T 和物品-物品图 G 。

2 模型框架

2.1 模型概述

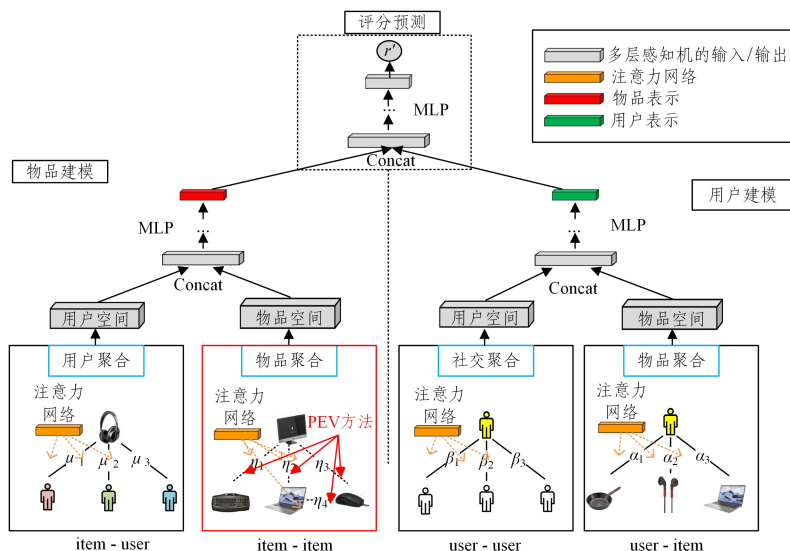
所提模型的框架结构如图 2 所示, 其主要分为 3 个部分: 物品建模、用户建模和评分预测。

第一部分是物品建模, 其主要目的是学习物品表示。物品表示一方面可以从用户-物品图中学习, 另一方面物品-物品图所展现的物品关系有助于增强物品的表示学习。同样地, 对于这两个图分别采取用户聚合与物品聚合的手段。第一个用户聚合是从用户-物品图中选择物品之前交互过的重要用户(用户空间), 从用户的角度学习物品更深层次的属性。第二个物品聚合是把属性相似的物品或者功能捆绑的物品聚集起来, 该过程的关键在于利用 PEV 方法建立物品连接, 然后从物品的角度(物品空间)捕获物品的特征。

第二部分是用户建模, 它的主要目的是学习用户表示。社交图(用户-用户图)和用户-物品图都包含了用户信息, 它们从两个不同的角度展现了用户特征。其挑战在于如何将社交图和用户-物品图本质地结合起来。为了解决这个问题, 本文使用两种类型的聚合分别从两个异构图中学习用户因子。一种是物品聚合, 从用户与物品的历史交互中寻找对用户重要的物品(物品空间), 通过这些物品的信息了解用户兴趣。另一种是社交聚合, 在社交网络中找到重要的朋友(社交空间), 根据朋友的兴趣建模用户的爱好。

因此, 学习用户和物表示就是利用两种聚合器从两个空间(用户空间和物品空间)收集信息。对于用户而言, 用户空间保存用户的社交连接, 而物品空间保存与用户交互过的物品。对于物品而言, 用户空间是与某物品交互过的用户群, 物品空间是与目标物品相似的一系列物品。

第三部分是评分预测, 通过整合用户建模和物品建模组件, 来学习模型参数以预测用户对候选物品的评分。接下来, 将详细介绍每个模型组件。



注: 它包含 3 个主要组成部分: 物品建模、用户建模和评分预测。

图 2 所提模型的整体架构

Fig. 2 Overall architecture of the proposed model

2.2 物品建模

物品建模用于学习物品 v_j 的嵌入表示, 记作 $t_j \in R^d$ 。物品不仅与用户之间存在交互关系, 物品与物品之间还存在着相似关系, 这为学习物品的表示提供了不同的视角。我们使用两种类型的聚合器同时从用户空间和物品空间收集物品信息, 如图 2 的右侧所示。第一种是用户聚合, 它从用户-物品图中学习来自用户空间中的物品的潜在表示, 记作 $t_j^U \in R^d$ 。第二种是物品聚合, 它从物品-物品图中学习来自物品空间中的物品的潜在表示, 记作 $t_j^I \in R^d$ 。结合用户空间和物品空间的表示就形成了最终的物品表示 $t_j \in R^d$ 。接下来, 将介绍用户聚合、物品聚合以及如何结合来自两个空间的物品的潜在因素。

2.2.1 用户聚合: 用户空间中的物品潜在因子

由于用户-物品图不仅包含用户与物品之间的交互, 还包含用户对物品的意见(或评分), 因此本文提供了一种原则的方法, 联合捕获用户-物品图中的交互和意见, 用于学习物品 v_j 在用户空间中的潜在因子 t_j^U 。对于每个物品 v_j , 通过用户-物品图中的交互来收集物品信息。

$$t_j^U = \sigma(W \cdot \text{Aggre}_{\text{users}}(\{f_{ji}, \forall t \in B_{(j)}\}) + b) \quad (3)$$

其中, W 和 b 分别是权重和偏差, σ 是非线性激活函数, $\text{Aggre}_{\text{users}}$ 是用户聚合器, $B_{(j)}$ 表示与 v_j 交互过的用户集合。 f_{ji} 是一个意见感知交互表示。

即使是同一个物品, 在用户与物品的交互过程中, 用户也可能会表达不同的意见。这些来自不同用户的意见有助于建模物品的潜在因子。对于从 u_i 到 v_j 的带有意见(或评分) r 的交互, 引入一个意见感知交互表示 f_{ji} , 它由原始的用户嵌入 p_i 和意见嵌入 e_r 结合得到, 其中意见嵌入 $e_r \in R^d$ 是每个评分 r 所对应的向量表示。 g_v 表示用来融合交互信息和意见信息的函数:

$$f_{ji} = g_v([p_i \oplus e_r]) \quad (4)$$

其中, \oplus 表示两个向量间的拼接操作。此外, 设计了一种注意力网络, 以意见感知 f_{ji} 和目标物品嵌入 q_j 为输入, 通过双层神经网络来区分用户的重要性权重 μ_{ji} :

$$t_j^U = \sigma(\sum_{i \in B_{(j)}} \mu_{ji} f_{ji}) + b \quad (5)$$

$$\mu_{ji}^* = w_2^T \cdot \sigma(w_1 \cdot [f_{ji} \oplus q_j]) + b_1 + b_2 \quad (6)$$

$$\mu_{ji} = \frac{\exp(\mu_{ji}^*)}{\sum_{i \in B_{(j)}} \exp(\mu_{ji}^*)} \quad (7)$$

其中, σ 是非线性激活函数, μ_{ji} 是注意力得分, 用于捕获用户-物品交互中的异质性影响, 从而了解用户空间中的物品潜在因子。最终的注意力权重是通过使用 Softmax 函数对上述注意力得分进行标准化而得。

2.2.2 物品聚合: 物品空间中的物品潜在因子

物品之间并不是相互独立的, 并且很可能是相似的或是相关的, 相似或相关的物品有助于进一步丰富物品表示。因此, 对于每个物品 v_j , 我们需要收集来自物品-物品图中的具有相似关系的物品信息, 以增强物品表示。来自物品空间的物品潜在因子为 t_j^I , 具体的聚合过程如下:

$$t_j^I = \sigma(W \cdot \text{Aggre}_{\text{items}}(\{y_{jk}, \forall k \in I_{(j)}\}) + b) \quad (8)$$

其中, W 和 b 分别是权重和偏差, σ 是非线性激活函数, $\text{Aggre}_{\text{items}}$ 是物品聚合器, $I_{(j)}$ 表示与 v_j 相似的物品集合, y_{jk} 是一个相似性感知表示。

由于同一个目标物品, 在与其他物品建立相似关系时, 所

表现的关联强度可能是不同的。而这些来自不同物品的相似关系可以捕捉到同一物品的特征。因此, 对于 v_j 和 v_k 间带有相似性的连接, 引入了一个相似性感知 y_{jk} , 它由物品嵌入 q_k (q_k 表示与目标物品具有相似连接的物品嵌入) 和相似性嵌入 k_s 结合得到, 其中相似性嵌入向量 $k_s \in R^d$ 是每个相似度 S_{ij} 所对应的向量表示。 g_v 表示用于融合关联信息和相似信息的函数。 y_{jk} 的表达式如下:

$$y_{jk} = g_v([q_k \oplus k_s]) \quad (9)$$

其中, \oplus 表示两个向量间的拼接操作。此外, 设计了一种注意力网络, 以相似性感知 y_{jk} 和目标物品的嵌入表示 q_j 为输入, 通过双层神经网络来区分用户的重要性权重 η_{jk} :

$$t_j^I = \sigma(\sum_{k \in I_{(j)}} \eta_{jk} y_{jk}) + b \quad (10)$$

$$\eta_{jk}^* = w_2^T \cdot \sigma(w_1 \cdot [y_{jk} \oplus q_k]) + b_1 + b_2 \quad (11)$$

$$\eta_{jk} = \frac{\exp(\eta_{jk}^*)}{\sum_{k \in I_{(j)}} \exp(\eta_{jk}^*)} \quad (12)$$

其中, σ 是非线性激活函数, η_{jk} 是注意力得分, 用于捕获物品-物品关联的异质性影响, 从而了解物品空间中的物品潜在因子。最终的注意力权重是通过使用 Softmax 函数对上述注意力得分进行标准化而得。

2.3 物品表示

由于用户-物品图和物品-物品图提供的是不同角度的物品信息, 为了充分地学习物品表示, 需要将用户空间和物品空间的物品潜在因子进行堆叠。利用一个标准的 MLP 将这两个潜在因子结合起来作为最终的物品表示, 在输入 MLP 之前将用户空间中的物品潜在因子 t_j^U 和物品空间中的物品潜在因子 t_j^I 进行拼接。形式上, 将物品 v_j 的物品表示 t_j 定义为:

$$c_1 = [t_j^U \oplus t_j^I] \quad (13)$$

$$c_2 = \sigma(W_2 \cdot c_1 + b_2) \quad (14)$$

...

$$t_j = \sigma(W_l \cdot c_{l-1} + b_l) \quad (15)$$

其中, l 是隐藏层数。

2.4 用户建模

用户建模旨在获取用户表示。与物品建模类似的是, 使用两种聚合器分别获取来自社交空间和物品空间的用户潜在因子。因为用户既与物品之间有着交互关系, 又与好友之间存在联系, 这两种关系为增强用户的表示学习提供了不同的视角。第一种聚合称为社交聚合, 是从社交图中学习社交空间中的用户潜在因子, 记作 $h_i^S \in R^d$ 。第二种聚合称为物品聚合, 是从用户-物品图中学习物品空间中的用户潜在因子, 记作 $h_i^I \in R^d$ 。将两个空间的潜在因子结合生成最终的用户表示, 记作 $h_i \in R^d$ 。

2.5 评分预测

该模型的一个显著优点是, 对于物品和用户的建模是相似而独立的, 这简化了社交推荐的过程。推荐系统中包含各种各样的任务, 如 top- k 推荐和评级预测等, 本文选择评级预测作为推荐任务。因此, 需要将用户和物品的聚合信息送到前馈网络来预测评分。 h_i 是最终的用户表示, t_j 是最终的物品表示, 通过它们的相互作用, 才产生了最终的评分 $r_{i,j}$:

$$g_1 = [h_i \oplus t_j] \quad (16)$$

$$g_2 = \sigma(W_2 \cdot g_1 + b_2) \quad (17)$$

...

$$g_{l-1} = \sigma(W_l \cdot g_{l-1} + b_l) \quad (18)$$

$$r'_{ij} = w^T \cdot g_{l-1} \quad (19)$$

其中, l 是隐藏层数, r'_{ij} 预测的是用户 u_i 给物品 v_j 的评分。

3 实验结果及分析

3.1 实验设置

3.1.1 数据集

本文在真实的数据集 Ciao, Epinions 和 Douban 上测试所提模型的性能。表 2 列出了这 3 个数据集的详细信息。

表 2 数据的统计信息

Table 2 Data information statistics

数据	Ciao	Epinions	Douban
用户	7317	18088	24562
物品	104975	261649	46643
评分	283320	764352	244936
评分密度%	0.0369	0.0161	0.0214
社交连接	111781	355813	513010
社交密度%	0.2087	0.1087	0.0850

1)Ciao。Ciao 包含了用户对电影的评分记录和用户之间的信任关系。评分记录包含用户对物品 1 到 5 的评分、物品 id、物品类别。此外,数据集还具有这些信息的时间戳。

2)Epinions。Epinions 是一个社交网络平台,用户可以对物品进行评分并发布信任声明,该报告发表在 LIBREC 网站上。这个数据集与 Ciao 类似,也包含时间戳信息。

3)Douban。Douban Movie 是一个分享用户对电影评价的网络平台,用户可以对电影发表评论并打分。

3.1.2 评价标准

实验采用了平均绝对误差 MAE 和均方根误差 RMSE 作为结果度量指标。MAE 和 RMSE 被广泛应用于推荐领域,都表示预测值与真实值的偏差。它们的值越小,表示推荐质量越高。值得注意的是,这两个指标的小幅改进,可以显著提升 top- k 的推荐效果^[27]。

3.1.3 基线模型

为了全面评估模型性能,将对比的社交推荐模型分为两类:矩阵分解模型和图神经网络模型。对比的基线模型如下。

1)矩阵分解模型

PMF^[28] 模型对用户-物品评分矩阵进行分解,从而学习用户和物品的潜在因素。

SoRec^[29] 提出了将用户-物品评分矩阵和用户-用户社交关系矩阵共同执行矩阵分解。

SoReg^[30] 通过对社会网络信息添加正则化项来约束矩阵分解。

2)图神经网络模型

DiffNet^[31] 是一种基于图的社交推荐方法。它直接从用户-项目交互图和社交图中获取用户的表示向量,并生成最终的用户表示。

ScAN^[32] 利用共同注意力 (co-attention) 神经网络,通过用户-好友与某物品交互的历史数据来学习用户与好友之间的影响力。当用户与不同的物品进行交互时,分别为用户及其好友分配不同的注意权重,从而得到新的用户潜在偏好特征。该网络中的社交数据也使用 Node2Vec 进行初始化。

GCMC+SN^[33] 是一种先进的图神经网络结构的推荐系统。为了将社交网络信息合并到 GCMC 中,他们利用 Node2Vec^[34] 生成用户嵌入作为用户侧信息,而不是直接使

用原始特征进行社交联系。这是因为原始特征输入向量是高度稀疏和高维的。利用网络嵌入技术可以将原始的输入特征向量压缩为低维稠密的向量,从而使模型易于训练。

SocialLGN^[1] 是一种有效的基于图卷积神经网络的社会推荐模型。该模型利用 GCNs 的优势来捕捉用户偏好受到社交网络中社交扩散过程的影响。

ConsisRec^[35] 通过修改神经网络,解决了社会关系不一致问题。将抽样概率与邻居间的一致性得分联系起来,对一致性邻居进行抽样,并将重要的社会关系聚合。

GraphRec^[24] 在社交图、用户-物品图上联合建模了两种类型的聚合,以全面了解用户和物品嵌入。

3.1.4 参数设置

数据集被随机划分为 3 个部分:训练集 (60%)、验证集 (20%) 和测试集 (20%)。在所有实验中,使用均值为 0、标准差为 0.1 的高斯分布对参数进行初始化。超参数是根据验证性能进行调优,利用网格搜索进行调整的,用户嵌入大小从 {8, 16, 32, 64, 128, 256} 中搜索,物品嵌入大小从 {16, 32, 64, 128, 256, 512} 中搜索。每轮训练的批量大小在 {32, 64, 128, 512} 中搜索,学习率在 {0.0005, 0.001, 0.005, 0.01, 0.05, 0.1} 中搜索。激活函数为 ReLU,训练过程中采用早停策略,如果验证集上的 RMSE 连续 5 次验证都没有提高,则停止训练。

3.2 推荐系统的性能比较

为确保 PEVGraphRec 对推荐结果的全面提升,首先比较了各种方法的推荐性能。表 3 列出了各推荐模型在 Ciao, Epinions 和 Douban 数据集上关于 MAE 和 RMSE 的预测误差。观察实验结果,主要有以下发现:

1)SoRec 和 SoReg 的表现始终优于 PMF。这 3 种方法都是基于矩阵分解的推荐,但是 PMF 的效果最差,是因为该方法仅利用评分信息来做推荐。而 SoRec 和 SoReg 对评分信息和社交网络共同执行矩阵分解。结果表明,社交网络有助于提升推荐性能。

2)DiffNet, ScAN, GCMC+SN 和 SocialLGN 的性能优于 SoRec 和 SoReg。这几种方法都是同时利用评分信息和社交网络进行推荐的,而 DiffNet, ScAN, GCMC+SN 和 SocialLGN 是基于神经网络的推荐模型。这种性能的提升证实了神经网络在处理推荐任务方面拥有强大的功能。

3)ConsisRec 和 GraphRec 的性能甚至超过了 DiffNet, ScAN, GCMC+SN 和 SocialLGN。这 6 种方法都利用神经网络框架来处理评分信息和社交网络,但是 ConsisRec 和 GraphRec 在对邻居采样的过程中解决了社会关系不一致的问题。这就体现了注意力机制在解决异质性关系方面的优势。

4)本文所提的 PEVGraphRec 模型始终优于所有基线模型。相比 ConsisRec 和 GraphRec,本文模型提供了先进的方式来整合评分信息和社交网络。与 GraphRec 相比,PEVGraphRec 显式地构建了物品与物品间的关系,并将其合并到物品建模中,以增强物品的表示。结果表明,物品之间的关系是有用的辅助信息。

综上所述,模型的比较结果显示:1)社交网络信息和物品的邻居信息有助于提升推荐性能;2)相比传统的推荐方法,基于神经网络框架的推荐能获得更好的效果;3)所提模型的性能优于上述先进的基线模型。

3.3 模型分析

本节将研究模型超参数、模型组件对模型性能的影响,以及相似性度量方法缓解冷启动问题的能力对模型产生的影响。

3.3.1 嵌入维度对模型性能的影响

恰当的维度选择是决定模型性能优劣的因素之一,本节分析用户嵌入和物品嵌入的维度变化对本模型性能的影响。

图 3 给出了维度变化给模型性能带来的影响。此处实验仅改变嵌入维度,其他所有参数都设置为默认值。实验显示

模型中用户和物品的最佳嵌入维度分别是 64 和 128。随着嵌入维度的减小,模型性能有所下降。原因是维度越小,就不能包含节点全部的必要信息;然而,当嵌入维度增加到某个值以后,模型的训练时间大大增加。其原因是,随着维度的增加需要调整的参数也不断增多,模型将面临收敛困难的问题。对比 3 个数据集,发现 Epinions 对嵌入维度的大小最为敏感,而 Ciao 依赖于精确的调优,因为改变维度时模型性能的变化幅度较小。该实验表明,恰当的维度才能使得模型发挥出最大的优势。

表 3 不同推荐算法的性能比较

Table 3 Performance comparison of different recommender algorithms

		PMF	SoRec	SoReg	DiffNet	ScAN	Social LGN	GCMC+ SN	Consis Rec	Graph Rec	PEV Graph Rec
Ciao	MAE	0.9520	0.8489	0.8987	0.7698	0.7634	0.7564	0.7697	0.7394	0.7540	0.7328
	RMSE	1.1967	1.0738	1.0947	1.0247	1.0192	1.0185	1.0221	0.9722	1.0093	0.9689
Epinions	MAE	1.0211	0.9086	0.9412	0.8511	0.8549	0.8579	0.8602	0.8046	0.8441	0.8027
	RMSE	1.2739	1.1563	1.1936	1.1025	1.0971	1.0892	1.1004	1.0495	1.0878	1.0413
Douban	MAE	0.9701	0.8542	0.9114	0.7943	0.7816	0.7756	0.7880	0.7886	0.7638	0.7544
	RMSE	1.2241	1.1024	1.1943	1.0288	1.0257	1.0245	1.0361	1.0347	1.0105	0.9902

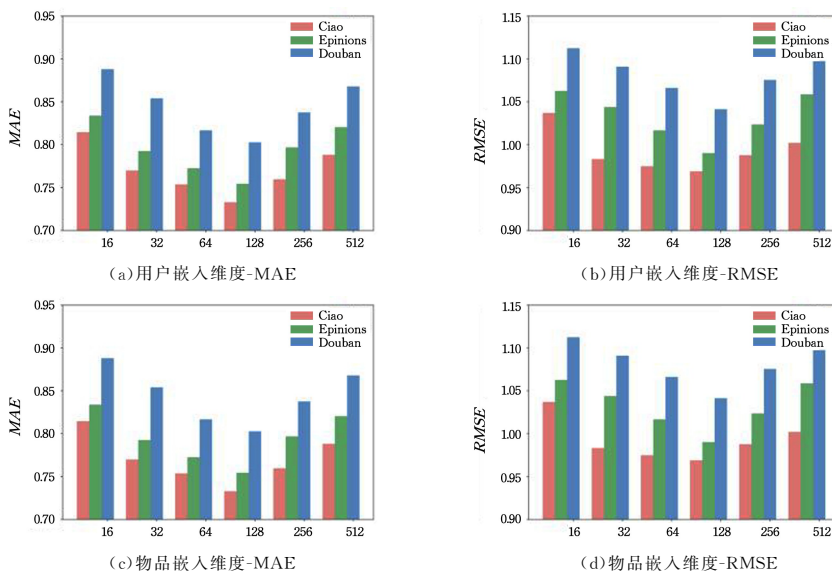


图 3 在 3 个数据集上模型对嵌入维度的敏感性

Fig. 3 Sensitivity of model to embedding dimension size in three datasets

3.3.2 各组件对模型性能的贡献

为了证明所提模型的有效性,本节比较了 PEVGraphRec 及其 4 个组件。如图 2 所示,该模型由 item-user, item-item, user-user 和 user-item 4 个组件构成,各组件的具体功能如下。

1) item-user: 在对物品建模时,禁用了物品与用户的交互信息。该变体仅利用物品空间的物品潜在因子 t_j^i 当作最终的物品表示 t_j ,忽略了用户空间的物品潜在因子 t_j^u 。

2) item-item: 在对物品建模时,移除了 PEVGraphRec 的物品-物品隐式图。该变体仅使用用户空间的物品潜在因子 t_j^u 当作最终的物品表示 t_j ,忽略物品空间的物品潜在因子 t_j^i 。

3) user-user: 该组件表示删除 PEVGraphRec 的社交网络。该变体仅使用物品空间中的用户潜在因子 h_i^i 作为最终的用户表示 h_i ,而忽略了社交网络中的用户潜在因子 h_i^s 。

4) user-item: 在用户建模方面,忽略了用户与物品的历史

交互。该变体仅用社交网络中的用户潜在因子 h_i^s 作为最终的用户表达 h_i ,忽略了物品空间的用户潜在因子 h_i^i 。

图 4 显示了 PEVGraphRec 及其 4 个组件在 Ciao, Epinions 和 Douban 上的性能表现。从结果来看,我们有以下发现:

1) item-user/user-item: 可以看到,各组件的重要程度会因数据集的不同而产生略微变化。然而,在 3 个数据集上表现一致的是,无论是用户建模还是物品建模,没有了用户与物品的交互信息,模型性能显著下降。这验证了本文的假设,即用户-物品的交互有助于用户和物品的表示学习,并提高了推荐的性能。

2) item-item: PEVGraphRec 通过构建物品-物品图来考虑物品间的关系。可以看到的是,PEVGraphRec 比 GraphRec 的效果更好。具体而言,从表 3 的结果来看,所提模型在 Ciao, Epinions 和 Douban 上的 MAE 分别提升了 2.12%, 4.14% 和 0.94%, RMSE 分别提升了 4.04%, 4.65% 和

2.03%。从图4显示的结果来看,尽管 item-item 组件提供的信息量比其他3个组件都要少,但是实验仍然证明了物品-物品关系图能够作为提升模型性能的有效手段。这些结果有力地支持了本文的关键思想,即相似或相关的物品有利于增强物品的表示学习,从而达到提升性能的效果。

3)user-user:该组件重点分析了社交信息的有效性。从结果可以看到,删除社交网络信息使得模型性能大幅下降。这意味着模型在进行预测时,严重依赖于社交网络。这一结果也解释了为何 GraphRec 模型仅考虑用户-物品和用户-用户的连接,也取得了不错的成果。

3.3.3 各组件对模型性能的贡献

为了证明所提模型的有效性,本节比较了 PEVGraphRec 及其4个组件。如图2所示,该模型由 item-user, item-item, user-user 和 user-item 4个组件构成,各组件的具体功能如下。

1)item-user:在对物品建模时,禁用了物品与用户的交互信息。该变体仅利用物品空间的物品潜在因子 t_j^i 当作最终的物品表示 t_j ,忽略了用户空间的物品潜在因子 t_j^u 。

2)item-item:在对物品建模时,移除了 PEVGraphRec 的物品-物品隐式图。该变体仅使用用户空间的物品潜在因子 t_j^u 当作最终的物品表示 t_j ,忽略了物品空间的物品潜在因子 t_j^i 。

3)user-user:该组件表示删除 PEVGraphRec 的社交网络。该变体仅使用物品空间中的用户潜在因子 h_i^i 作为最终的用户表示 h_i ,而忽略了社交网络中的用户潜在因子 h_i^s 。

4)user-item:在用户建模方面,忽略了用户与物品的历史

交互。该变体仅用社交网络中的用户潜在因子 h_i^s 当作最终的用户表达 h_i ,忽略了物品空间的用户潜在因子 h_i^i 。

图4给出了 PEVGraphRec 及其4个组件在 Ciao, Epinions 和 Douban 上的性能表现。从结果来看,我们有以下发现。

1)item-user/user-item:各组件的重要程度会因数据集的不同而产生略微变化。然而,在3个数据集上表现一致的是,无论是用户建模还是物品建模,没有了用户与物品的交互信息,模型性能显著下降。这验证了本文的假设,即用户-物品的交互有助于用户和物品的表示学习,并提高了推荐的性能。

2)item-item: PEVGraphRec 通过构建物品-物品图来考虑物品间的关系。可以看到的是,PEVGraphRec 比 GraphRec 的效果更好。具体而言,从表3的结果来看,所提模型在 Ciao, Epinions 和 Douban 上的 MAE 分别提升了 2.12%, 4.14% 和 0.94%, RMSE 分别提升了 4.04%, 4.65% 和 2.03%。从图4显示的结果来看,尽管 item-item 组件提供的信息量比其他3个组件都要少,但是实验仍然证明了物品-物品关系图能够作为提升模型性能的有效手段。这些结果有力地支持了本文的关键思想,即相似或相关的物品有利于增强物品的表示学习,从而达到提升性能的效果。

3)user-user:该组件重点分析了社交信息的有效性。从结果可以看到,删除社交网络信息使得模型性能大幅下降。这意味着模型在进行预测时,严重依赖于社交网络。这一结果也解释了为何 GraphRec 模型仅考虑用户-物品和用户-用户的连接,也取得了不错的成果。

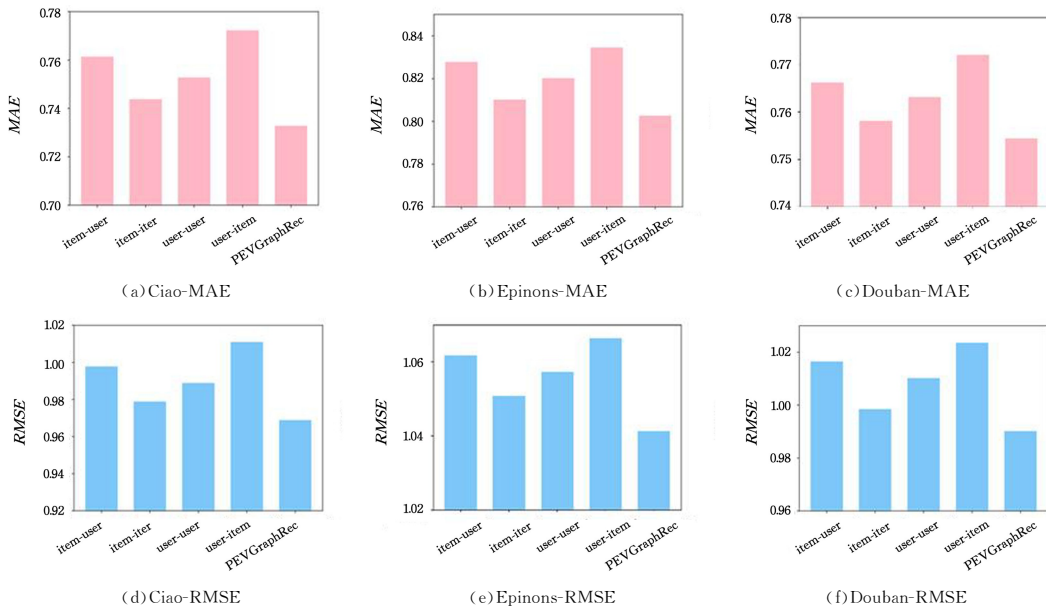


图4 在3个数据集上各组件对模型性能的贡献

Fig. 4 Contributions of each component to model performance in three datasets

3.3.4 模型缓解冷启动的能力

本节研究了不同的相似性度量方法对推荐结果的影响。为了更清晰地展示 PEV 相似性度量方法在整个模型中起到的作用,本文将 PEVGraphRec 与它的两个变体 COR-GraphRec 和 COS-GraphRec 进行比较。下面给出这两种变体的定义。

1)COR-GraphRec:将提出的模型中的相似性度量方法替换成皮尔逊相似性 COR。

2)COS-GraphRec:将提出的模型中的相似性度量方法替换成余弦相似性 COS。

若 x 代表每个用户评价过的物品数量,将 $x < 10$ 的用户当作新用户,新用户在全用户中所占的比例表示为数据的稀疏度。新用户越多,数据就越稀疏。

图5给出了 PEVGraphRec 及其变体在3个数据集上的表现。从图中可以看出,在数据信息丰富的情况下,传统的相关相似性方法具有优势,然而在新用户较多的情况下,PEV

展现出了明显的优势。即当数据非常稀疏时,PEV 相似性度量方法能显著地提高该模型的推荐质量。

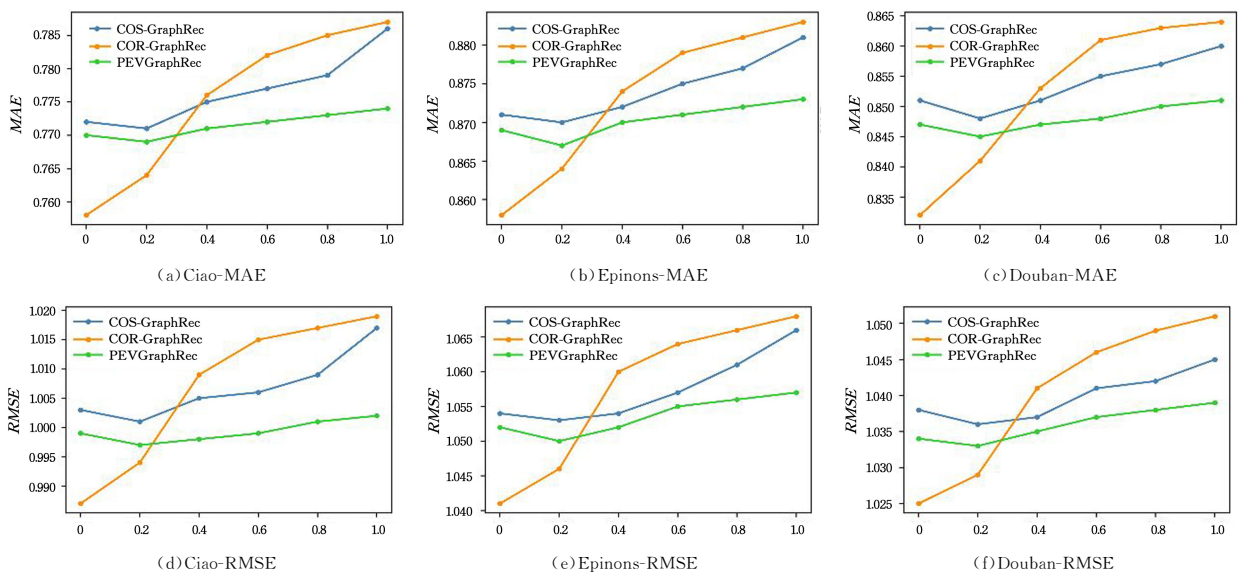


图 5 在训练过程中使用 COR, COS 和 PEV 相似性度量方法的模型的性能

Fig. 5 Performance of model using COR, COS and PEV similarity measurement during training process

结束语 本文提出了一个用于社交推荐的图神经网络框架(PEVGraphRec)。特别地,提出了不同的聚合方式来建模图数据,以学习更好的用户和物品表示。此外,利用一种数学上相似性的方法来建立物品间显式的连接,并将这种物品关系融入到社交推荐模型中,以增强物品的表示学习。因此,本文的社交推荐模型同时对物品与用户的交互关系、用户好友的社交关系和物品与物品之间的相似关系共同建模。在建模过程中利用注意机制来解决连接强度不一致的问题。在 3 个真实数据集上进行实验,结果表明物品关系有助于提高模型的性能,并验证了所提模型的有效性。在本文中,PEVGraphRec 仅考虑了用户的单一行为(评分行为),而实际上用户的行为是丰富的,例如点击、购买、分享行为等;其次,用户的兴趣往往是随时间动态变化的,而本文建模的用户偏好是静态的,忽略了时间因素。因此,未来工作可以尝试将用户不同类型的行为共同用作模型的训练,以进一步增强推荐系统的准确性;另外,可以通过加入长短期记忆网络,来学习用户的动态兴趣。

参考文献

- [1] LIAO J, ZHOU W, LUO F, et al. SocialLGN: Light graph convolution network for social recommendation[J]. Information Sciences, 2022, 589: 595-607.
- [2] LIU Z W, FAN Z W, WANG Y, et al. Augmenting Sequential Recommendation with Pseudo-PriorItems via Reversely Pre-training Transformer[C]// Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2021.
- [3] LI M N, TEI K J, FUKAZAWA Y. An Efficient Adaptive Attention Neural Network for Social Recommendation[J]. IEEE Access, 2020, 8: 63595-63606.
- [4] WU L, LI J, SUN P, 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.
- [5] WU L, SUN P, HONG R, et al. Collaborative neural social recommendation[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2021, 51(1): 464-476.
- [6] CIALDINI R B, GOLDSTEIN N J. Social influence: Compliance and conformity[J]. Annu. Rev. Psychol. 2004, 55(1): 591-621.
- [7] MCPHERSON M, SMITH-LOVIN L, COOK J M. Birds of a Feather: Homophily in Social Networks[J]. Annual Review of Sociology, 2001, 27(1): 415-444.
- [8] RESNICK P, VARIAN H R. Recommender systems[J]. Communications of the ACM, 1997, 40(3): 56-58.
- [9] TANG J, HU X, LIU H. Social recommendation: a review[J]. Social Network Analysis and Mining, 2013, 3(4): 1113-1133.
- [10] JAMALI M, ESTER M. A matrix factorization technique with trust propagation for recommendation in social networks[C]// Proceedings of the fourth ACM conference on Recommender systems. ACM, 2010: 135-142.
- [11] SALAMAT, LUO X, JAFARI A. HeteroGraphRec: A heterogeneous graph-based neural networks for social recommendations[J]. Knowledge-Based Systems, 2021, 217, 106817.
- [12] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks[C]// International Conference on Learning Representations(ICLR). 2017.
- [13] DEFFERRARD M, BRESSON X, VANDERGHEYNST P. Convolutional neural networks on graphs with fast localized spectral filtering[C]// 30th Conference on Neural Information Processing Systems(NIPS 2016). 2016: 3844-3852.
- [14] BRUNA J, ZAREMBA W, SZLAM A, et al. Spectral networks and locally connected networks on graphs[J]. arXiv: 1312.6203, 2013.
- [15] ZHANG Y, QI P, MANNING C D. Graph convolution over pruned dependency trees improves relation extraction[J]. arXiv: 1809.10185, 2018.
- [16] ZHANG Y J, DU Y L, MENG X W. Group recommendation system and its application[J]. Chinese Journal of Computers, 2016, 39(4): 745-764.

- [17] LIU X, MEI H Y, WANG J H. Research on Graph Neural Network Recommendation Method[J]. Computer Engineering and Applications, 2022, 58(10): 41-49.
- [18] WANG J C, YUAN F J, CHEN J, et al. Stackrec: Efficient training of very deep sequential recommender models by iterative stacking. [C]// The 44th International ACM SIGIR Conference on Research and Development in Information Retrieval, Canada, 2021: 357-366.
- [19] LINDEN G, SMITH B, YORK J. Amazon.com recommendations; Item-to-item collaborative filtering [J]. IEEE Internet Computing, 2003, 7(1): 76-80.
- [20] DESHPANDE M, KARYPIS G. Item-based top-n recommendation algorithms[J]. ACM Transactions on Information Systems (TOIS), 2004, 22(1): 143-177.
- [21] FAN W, MA Y, LI Q, et al. A Graph Neural Network Framework for Social Recommendations[J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 34(5): 2033-2047.
- [22] XIANG R, NEVILLE J, ROGATI M. Modeling relationship strength in online social networks[C]// Proceedings of the 19th International Conference on World Wide Web. ACM, 2010: 981-990.
- [23] CHEN M, LI Y H, ZHOU X Z. CoNet: Co-occurrence neural networks for recommendation[J]. Future Generation Computer Systems, 2021, 124(3): 308-314.
- [24] FAN W, MA Y, LI Q, et al. Graph neural networks for social recommendation[C]// Proceedings of the WWW'19. San Francisco, CA, USA, 2019: 417-426.
- [25] ZHANG Z P, GUO X L. PEV: New similarity measure applying to Item-based collaborative filtering algorithm[J]. Journal of Chinese Computer Systems, 2009, 30(4): 716-720.
- [26] 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(WWW'19). 2019: 2091-2102.
- [27] LIU Z W, ZHENG L, ZHANG J W. JSCN: Joint spectral convolutional network for cross domain recommendation[C]// 2019 IEEE International Conference on Big Data (Big Data). IEEE, 2019: 850-859.
- [28] SALAKHUTDINOV R, MNIH A. Probabilistic matrix factorization[C]// Proceedings of the 20th International Conference on Neural Information Processing Systems(NIPS'07). Red Hook, NY, USA, 2007: 1257-1264.
- [29] MA H, YANG H X, LYU R M, et al. Sorec: Social recommendation using probabilistic matrix factorization[C]// Proceedings of the 17th ACM conference on Information and Knowledge Management(CIKM'08). New York, USA, 2008: 931-940.
- [30] MA H, ZHOU D, LIU C, et al. Recommendersystems with social regularization[C]// Proceedings of the fourth ACM international conference on Web Search and Data Mining. ACM, 2011: 287-296.
- [31] 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 (SIGIR 2019). ACM, Paris, France, 2019: 235-244.
- [32] LI M, TEI K, FUKAZAWA Y. An efficient co-attention neural network for social recommendation[C]// Proceedings of the IEEE/WIC/ACM International Conference on Web Intelligence (WI'19). Thessaloniki, Greece, 2019: 34-42.
- [33] BERG R, KIPF T N, WELLING M. Graph convolutional matrix completion[C]// Proceedings of the KDD'18 Deep Learning Day. London, UK, 2018.
- [34] GROVER A, LESKOWEC J. node2vec: Scalable feature learning for networks[C]// Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining(KDD'16). San Francisco, CA, USA, 2016: 855-864.
- [35] YANG L, LIU Z, DOU Y, et al. ConsisRec: Enhancing GNN for social recommendation via consistent neighbor aggregation[C]// The 44th International ACM SIGIR Conference on Research and Development in Information Retrieval(SIGIR'21). ACM, 2021.



LIAO Dong, born in 1996, postgraduate. Her main research interest is personalized intelligent recommendation systems.



YU Haizheng, born in 1976, Ph.D, associate professor, master supervisor, is a member of China Computer Federation. His main research interests include big data and so on.