

# 用于社交推荐的增强影响扩散模型

刘 会<sup>1)</sup> 张璇<sup>1), 2)</sup> 杨 兵<sup>1)</sup> 云 炜<sup>1)</sup> 赵静转<sup>1)</sup>

<sup>1)</sup>(云南大学软件学院 昆明 650504)

<sup>2)</sup>(云南省软件工程重点实验室 昆明 650504)

**摘要** 随着网络上创建连接、协作、共享的全新变革方式的出现,互联网上丰富的社交行为现象引起了研究者和实践者的关注。近年来,随着社交网络平台的普及与推广,基于社交网络的推荐系统也成为了个性化推荐领域的研究热点之一,社交推荐系统可以利用社交网络来缓解传统的推荐算法中数据稀疏性问题。在社交网络中,社交关系影响起着重要作用,而用户信任是社交关系形成的基础,每一个用户会受到其信任的用户影响,这些被信任的用户也会被自己的社交关系所影响,这就表明了联系在一起的用户会相互影响,导致社交联系之间的用户偏好具有相似性。用户的信任关系影响着用户偏好的推断,同时用户受到其信任用户的社交关系影响,而这些社交关系影响在社交网络中递归传播和扩散。因此,基于社交推荐算法研究的关键就在于信任信息的挖掘和利用。在基于社交网络的推荐领域中,比较有代表性的模型为DiffNet,该模型未充分考虑到信任问题,同时,在递归计算长距离的社交关系时,有额外的噪声,影响推荐预测的质量。本文提出了基于DiffNet改进的社交推荐模型—EIDNet。首先,该模型在模拟社交关系影响扩散过程时,通过用户对物品的历史交互记录建立用户间的信任关系,并融合到递归社交动态建模中,以获得不同用户面向不同物品的不同信任关系。其次,在计算社交影响力时,提出增加残差连接的方式,减少长距离社交关系产生的噪声。同时,为了解决同阶领域权重分配问题,提出使用注意力机制,学习用户朋友关系向量,针对不同的用户计算不同的权重,适应地衡量用户朋友间的社交影响力。最终,将三个部分融合在一个统一的框架中,以相互增强,并建立一个更好的扩展模型。最后,结合用户与物品的历史交互行为和社交关系来预测用户未来的行为和偏好。本文的主要贡献包括:(1)将基于用户与物品的历史交互记录的信任融合到递归社交动态建模中,以解决不同用户因信任关系而面向不同物品进行推荐的问题;(2)在递归计算长距离的社交关系时,提出残差连接的方式来减少噪声影响;(3)引入了注意力机制,为社交网络中的用户给予不同的重要性,以解决同阶领域权重分配问题。实验结果表明,EIDNet与DiffNet最好的性能结果相比,在Yelp上的表现提升了10.61%,在Flickr上的表现提升了24.98%,结果证实了本文提出的改进模型可以提升社交推荐模型的推荐性能。

**关键词** 推荐系统;社交网络;DiffNet;残差连接;注意力机制;信任

**中图法分类号** TP18      **DOI号** 10.11897/SP.J.1016.2023.00626

## An Enhanced Influence Diffusion Model for Social Recommendation

LIU Hui<sup>1)</sup> ZHANG Xuan<sup>1), 2)</sup> YANG Bing<sup>1)</sup> YUN Wei<sup>1)</sup> ZHAO Jing-Zhuan<sup>1)</sup>

<sup>1)</sup>(School of Software, Yunnan University, Kunming 650504)

<sup>2)</sup>(Yunnan Key Laboratory of Software Engineering, Kunming 650504)

**Abstract** AbstractWith the emergence of new and transformative ways of creating connection, collaboration, and sharing on the Internet, the phenomenon of rich social behavior on the Internet

收稿日期:2020-04-22;在线发布日期:2021-11-18.本课题得到国家自然科学基金项目(61862063,61502413,61262025)、国家社会科学基金项目(18BJL104)、云南省中青年学术和技术带头人后备人才项目(202205AC160040)、云南省院士专家工作站项目“云南省金芝专家工作站”(202205AF150006)、云南省软件工程重点实验室开放基金项目(2020SE301)、云南大学软件学院“知识驱动智能软件工程科研创新团队”项目资助。刘会,硕士研究生,主要研究方向为推荐系统、知识图谱、机器学习。E-mail: liuhui950828@gmail.com。张璇(通信作者),博士,教授,博士生导师,中国计算机学会会员,主要研究领域为软件工程、人工智能、可信软件、需求工程。E-mail: zhxuan@ynu.edu.cn。杨兵,硕士研究生,主要研究方向为机器学习、数据挖掘、大数据。云炜,硕士研究生,主要研究方向为知识建模、知识图谱、机器学习及其应用。赵静转,硕士研究生,主要研究方向为知识推荐和机器学习。

has attracted the attention of researchers and practitioners. In recent years, with the popularity and promotion of social network platforms, recommendation systems based on social networks have also become one of the research hotspots in the field of personalized recommendation. Social recommendation systems use social networks to alleviate the data sparsity problem in traditional recommendation algorithms. In social networking, social relationships have played an important role, and user trust is the foundation of social relationship. Every user is affected by the users they trust. These trusted users will be affected by their own social relations, which means that users associated with each other have preference similarity among socially connected users. The user's trust relationship affects the user's preference, and the user is affected by the social relationship between its trust users, and these social relationships are increasing and spreading in social networks. Therefore, the focus of social recommendation algorithm research lies in the mining and utilization of trust information in the field of recommendation based on social network, a representative model is DiffiNet, which has not fully considered the problem of trust, and at the same time, there is additional noise when recursive long-distance social relationships, affecting the quality of the recommended forecasts. Therefore, a DIFFNET improved social recommendation model-EIDNet is proposed in this paper. Firstly, when simulating the diffusion process of social relationship influence, the trust relationship between users is established by the historical interaction records of users with items, and integrates it into the recursive social dynamic modeling to obtain different trust relationships for different users for different items. Second, when calculating social influence, a method of increasing residual connections is proposed to reduce the noise generated by long-distance social relationships. At the same time, in order to solve the problem of weight distribution in the same order domain, an attention mechanism is proposed to learn the user friend relationship vector, calculate different weights for different users, and adaptively measure the social influence among users' friends. Ultimately, the three parts are fused into a unified framework to reinforce each other and build a better scaling model. Finally, the user's future behavior and preferences are predicted by combining the user's historical interaction behavior and social relationship with the item. The main contributions of this paper include: (1) Integrate trust based on historical interaction records between users and items into recursive social dynamic modeling to solve the problem of different users recommending different items due to trust relationships; (2) In the recursive calculation of long-distance social relations, a residual connection method is proposed to reduce the influence of noise; (3) Attention mechanism is introduced to match different importance to users in the social network to solve the problem of weight distribution in the same order domain. The experimental results show that, compared with the best performance results of DiffNet, the performance of EIDNet on Yelp is improved by 10.61%, and the performance on Flickr is improved by 24.98%. The results confirm that the improved model proposed in this paper improves the recommendation performance of the social recommendation model.

**Keywords** recommendation system; social network; DiffNet; residual connections; attention mechanism; trust

## 1 引言

随着 21 世纪信息技术和互联网跳跃式的发展，

信息数据量爆炸性增长,出现日益严峻的信息过载问题,鉴于搜索引擎不能够提供个性化服务,推荐系统应运而生,已成为人们在做决策时广泛使用的系统之一<sup>[1]</sup>.许多企业和网站都采用了推荐系统来研

究其用户的偏好,用更加准确、高效的方式为用户提供定向的产品信息和服务信息,以提高用户满意度,并增强用户粘度。目前,推荐系统已经应用于各种不同的领域,众多的组织和学者致力于对推荐系统进行研究和改进<sup>[2]</sup>。但是,传统的推荐系统仍受到用户行为数据的稀疏性问题限制。

随着社交网络平台的普及与推广,基于社交网络的推荐方法被广泛应用。社交网络已经成为人们交友、分享和购物服务等的主要平台<sup>[3]</sup>,比如在线分享网站 Facebook 和新浪微博等。在社交网络中,社交关系影响起着重要作用,而用户信任是社交关系形成的基础,每一个用户会受到其信任的用户影响,这些被信任的用户也会被自己的社交关系所影响,这就表明了联系在一起的用户会相互影响,导致社交联系之间的用户偏好具有相似性。因此,基于社交推荐算法研究的关键就在于信任信息的挖掘和利用。近年来,研究者们尝试将人与人的社交关系引入推荐算法中<sup>[2-4]</sup>,通过加入信任信息,利用用户之间的社交关系来预测用户的未知偏好,结果表明,具有人际影响的社交推荐算法可以较好的缓解数据稀疏性问题,由此可见,社交分析极大地推动了推荐算法的创新。以往的这些社交推荐模型大多只静态地分析社交网络关系中每个用户的本地邻居偏好影响,而忽略了用户偏好会随着社交信息动态扩散而受到影响<sup>[5]</sup>。2019 年,Wu 等人提出了深度影响传播模型—DiffNet<sup>[6]</sup>,用来模拟社交网络中的社交影响扩散过程,每个用户的嵌入会受到其信任连接的用户嵌入的影响。具体来说,社交影响扩散的传播过程开始时扩散迭代  $k=1$ ,之后,每个用户的社交影响开始扩散传播,在第  $k$  层时的潜在嵌入受到其在第  $(k-1)$  层迭代时的社交关联用户影响。尽管 DiffNet 具有出色的性能,但我们认为,该模型仍有改进的空间。一方面,该模型未充分考虑到信任问题,用户的信任关系影响着用户偏好的推断,首先,特定用户与不同物品交互情况下,用户信任程度不同,可能会对用户产生不同的社交影响,该用户因不同用户的信任关系而面向不同物品进行推荐的问题。其次,对于一个用户来说,他/她朋友的影响力可能是不同的,因为不是所有的朋友都能在系统中塑造他/她的偏好。我们可以推断出,在预测用户的社交影响偏好时,用户社交影响不同,导致用户的权重或关注程度不同。因此,该模型无法很好地实现在同阶的邻域上分配不同的权重给不同的邻居;另一方面,在递归计算长距离的社交关系时,会引入额外的噪声,影响推

荐预测的质量。而事实上,在社交网络模型中,我们选择当前用户的前  $k$  层邻居,如果  $k$  选择的过大,太多相似度不高的近邻被纳入当前用户的最近邻集合中,会带来额外的噪声;如果  $k$  选择的过小,最近邻集合规模就会很小,预测的误差会增大<sup>[7]</sup>。通常来说,用户更加喜欢参考他们信任的朋友的偏好来做决定。

为了解决上述 DiffNet 存在的三个问题,我们提出了增强影响扩散模型 EIDNet(Enhanced Influence Diffusion Neural Network),以进一步提高社交推荐系统的性能。首先,该模型在模拟社交关系影响扩散过程时,通过融合基于用户与物品历史交互记录的信任到递归社交动态建模中,以获得不同用户面向不同物品的信任。其次,在计算社交影响力时,我们提出增加残差连接的方式,来减少长距离社交关系产生的噪声。同时,为了解决同阶领域权重分配问题,我们提出使用注意机制,来学习用户朋友关系向量,针对不同的用户计算不同的权重,适应地衡量用户朋友间的社交影响力。最终,将三个部分融合在一个统一的框架中,以相互增强,并建立一个更好的扩展模型。最后,结合用户与物品的历史交互行为和社交关系来预测用户未来的行为和偏好。

本文接下来其他章节的结构组织如下:第 2 节概述社交推荐系统的相关工作;在第 3 节中描述了 EIDNet 的框架结构,详细地阐述了改进方案及公式推导;在第 4 节给出了 EIDNet 算法描述与复杂度分析;第 5 节通过实验验证该模型的有效性,介绍了数据集、评价指标和相关对比实验结果;最后,在第 6 节对全文进行总结,并做出进一步研究规划。

## 2 相关工作

目前,已有许多个性化推荐系统相关的研究工作<sup>[8-11]</sup>。推荐系统根据用户的个性化需求,例如:喜好和习惯等特点和用户的历史购买行为来预测用户对物品的偏好以及用户未来的行为。构建推荐系统的技术通常包括基于内容过滤的推荐方法<sup>[12]</sup>、基于协同过滤的推荐方法<sup>[13]</sup>、基于知识的推荐方法<sup>[14]</sup>和多种方法混合的推荐方法<sup>[15]</sup>,其中,协同过滤推荐算法利用相似的邻居来生成推荐,成为推荐系统中最具有代表性的算法之一,主要分为基于用户的协同推荐算法和基于物品的协同推荐算法。已有的推荐算法取得不错的推荐效果,但仍存在着数据稀疏和冷启动问题。

现在,许多推荐系统和商业网站致力于为用户

提供个性化服务,例如 Amazon<sup>①</sup>, Last. fm<sup>②</sup>, Netflix<sup>③</sup>等,这些社交网络上蕴含了丰富的社交内容。鉴于传统的推荐系统往往忽视了社交信息,许多专家学者致力于对推荐系统进一步创新和优化,结合社交网络与推荐系统来增强推荐性能。基于社交网络的社交推荐系统就是利用用户之间的社交网络,通过建立与其他用户的社交连接,预测用户的偏好,匹配用户可能喜欢的物品<sup>[16]</sup>。目前,已有相关综述研究<sup>[4,10,17]</sup>对社交推荐进行详细阐述。社交推荐系统所使用的方法归纳为基于矩阵分解的社交推荐方法和基于近邻的社交推荐方法<sup>[17]</sup>。社交推荐系统的基础是构建用户之间的社交影响力和社交相关性<sup>[18]</sup>,随着信息在社交网络中扩散,用户会受到社交关系的影响,社交影响是用户向社交网络中的关注者传播其偏好的过程,用户的行为,包括偏好和兴趣等。随着信息在社交影响中的传播和扩散,用户会受到社交信任朋友的影响,用户信任的朋友又会受到其自己的朋友的影响,相互联系的人会相互影响,这就导致了社交邻居之间的相似偏好现象,即用户的偏好很大程度上与其社交朋友类似。受到经典的社交推荐算法的启发,基于社交影响理论的研究 SoRec<sup>[19]</sup>, SocialMF<sup>[20]</sup>以及 TrustSVD<sup>[21]</sup>模型将社交网络信息应用到推荐上,通过引入用户信任信息到推荐系统中,证明了社交推荐可以更好地缓解传统协同过滤算法中存在的数据稀疏与冷启动问题,并取得了较好的推荐结果。其中,Koren 在奇异值分解算法(SVD, singular value decomposition)的基础上引入隐式反馈,提出了 SVD++ 算法<sup>[22]</sup>,将用户的隐式反馈与显式反馈相结合,对用户的潜在兴趣进行建模,能够较好地缓解了冷启动问题。TrustSVD<sup>[21]</sup>在 SVD++ 的基础上,加入用户的社交邻居的信任影响关系,通过考虑评分和信任关系的影响,获得了较好的推荐结果。随后,田尧等人提出了一种基于双信任机制的奇异值分解算法 EITrustSVD<sup>[23]</sup>。在显式信任的 TrustSVD 算法的基础上,同时加入用户之间的隐式信任,可以有效地提高推荐质量。此外,某些研究将不信任信息整合到推荐系统中亦可以提高性能<sup>[24]</sup>。因此,较于当前最流行的协同过滤推荐技术,具有人际关系影响的社交推荐比传统的推荐方法更加合适做推荐<sup>[25]</sup>。近年来,基于图神经网络和图卷积网络的方法已经成功地应用在推荐系统中<sup>[26-29]</sup>。其中,图卷积网络的关键思想是以图的信息传递或扩散方式生成节点嵌入,通过聚合来自邻居的信息来生成当前节点表示。而来自邻居的消息

又是基于来自他们各自邻居的邻居进行迭代卷积操作,依此类推。基于图卷积网络的改进模型具有高效、计算成本更少的特点,因此,许多研究工作采用图卷积网络进行推荐,研究者提出将推荐任务转化为图的链接预测问题,并通过在用户—物品交互二部图上传递消息来学习用户和物品的嵌入,利用图结构和节点属性特征捕捉用户的偏好,可以取得良好的结果<sup>[29]</sup>。GC-MC<sup>[26]</sup>是将图卷积直接应用到用户—物品评级图上的最初尝试之一。但是,图卷积仅利用用户与物品之间连接的一层操作,而忽略了图的高阶结构。随之,Wu 等人提出了利用用户—物品交互矩阵输入 GC-MC 进行二部边缘预测的方法<sup>[27]</sup>,但该模型的两步过程并不灵活。随后,Ying 等人开发了 PinSage<sup>[28]</sup>,该算法基于随机游动和图卷积生成图结构和节点特征信息的节点嵌入。

上述将图卷积应用到推荐系统的模型只考虑了每个用户的本地邻居关系,忽略了社交网络中的社交关系扩散的动态影响过程。最近, SocialGCN<sup>[5]</sup> 和 DiffNet<sup>[6]</sup>解决了这个问题,利用图卷积网络的优势来捕捉用户的偏好如何受到社交网络中社交扩散过程的影响,取得较好的推荐结果。在文献[5]和[6]的工作中,它们都使用了图卷积网络来模拟社交影响过程。图卷积网络对每个卷积中嵌入的邻居节点等进行聚合,对每个邻居节点同等重要。相比之下,图注意力网络(GAT)<sup>[30]</sup>利用了注意力机制,考虑了来自邻居节点的不同权重,聚焦于重要的相邻节点。注意力机制已被证明在各种任务中是有效的,如计算机视觉、图像识别和自然语言处理。近年来,注意力机制也被广泛应用于推荐系统中,以更精确地捕捉不同的用户偏好。例如,注意因子分解机器(AFM)<sup>[31]</sup>在两两特征交互层之后增加了一个基于注意力的池化层,以学习每个特征交互对内容感知推荐的重要性。Zhou 等人提出了深度兴趣网络(DIN)<sup>[32]</sup>,对用户的每个历史交互物品赋予不同的权重,生成自适应的用户表示,从而获得更好的推荐结果。GraphRec<sup>[29]</sup>利用注意力机制建模,以学习每个社交邻居和每个被评价的物品的注意力权重。此外,还出现了一些基于注意力机制延伸的多重组合。Wu 等人提出了双图注意力网络(DANSER)模型<sup>[33]</sup>,用于非线性聚合两个网络中邻居节点的嵌入,用四个不同的 GAT 构建用户静态偏好向量、用

① <http://www.amazon.com>

② <http://www.Last.fm.com>

③ <http://www.netflix.com>

户动态偏好向量、物品静态属性向量和物品动态属性向量,赋予上面四个向量不同的权重,然后输出得到预测的评分。Chen 等人提出 DCN-SR<sup>[34]</sup> 应用一种共注意网络捕捉用户长、短期交互行为之间的动态交互,生成用户长、短期兴趣的依赖表示。总之,基于注意力机制的方法通常更具有可解释性。

我们提出的 EIDNet 仍借鉴了图卷积网络,用来模拟了递归社交扩散影响过程。在社交网络中,每个用户都会受其社交关系的影响,社交信息会从每个用户传播到他/她的社交邻居,再传播到社交邻居的邻居,从而出现信息扩散传播过程,而这种社交传播影响过程又呈现出动态的递归效果,随着时间的推移,用户兴趣不断发生变化,社交邻居的影响也会随之改变,影响每个用户的嵌入。这里的递归社交扩散过程即社交影响在社交网络中递归传播和扩散的过程。同时,我们的工作也受到了注意力建模应用的启发,将注意力机制融合于社交网络中进行推荐。本文中,在计算社交关系时,我们引入了注意力机制的模块,用来学习用户和他们的朋友之间的关系向量,为社交图中的用户给予不同的重要性,以解决同阶领域权重分配问题。一定程度上,在这些基于网络结构的个性化推荐系统的研究中,网络结构越深表达能力越好,且性能越好,然而随着网络深度的增加,会带来梯度消散和梯度爆炸问题。DiffNet<sup>[6]</sup> 就是利用深层社交网络结构进行推荐,通过分析 DiffNet 的实验结果,随着  $k$  的扩散,更新的用户嵌入反而会引入噪声,使得模型的性能下降,影响推荐结果。因此,本文 EIDNet 提出了增加残差连接<sup>[35]</sup> 的优化方法,来缓解深层网络梯度传播面临的问题,通过增加残差连接的方式,从而让梯度多了一条恒等映射通道,来减少深层网络的训练过程中的噪音。残差连接起作用主要原因是残差块学习恒等函数非常容易,网络性能不会受到影响,甚至可以提高效率,因此创建残差连接可以提升网络性能,进而提高推荐系统的性能。

### 3 EIDNet 模型

在本节中,我们首先对 EIDNet 模型架构进行详细描述,然后对社交网络扩散的各层进行解释与公式推导。

#### 3.1 相关定义

在社交平台上,用户通常会建立与其他用户的社交联系,用户与物品进行交互并显示出对物品的

偏好。本节主要描述与用户和物品相关的符号定义,我们用大写黑体字母表示矩阵,小写黑体字母表示向量。在社交推荐系统中,具体的符号定义如表 1 所示。

表 1 符号定义表

定义描述	符号
用户集	$\mathbf{U} ( \mathbf{U}  = M)$
物品集	$\mathbf{I} ( \mathbf{I}  = N)$
用户—用户社交矩阵	$\mathbf{T} \in \mathbb{R}^{M \times M}$
用户—物品评分矩阵	$\mathbf{R} \in \mathbb{R}^{M \times N}$
用户 $u$ 对物品 $i$ 的评分	$r_{ui}$
用户特征矩阵	$\mathbf{X} \in \mathbb{R}^{d1 \times M}$
物品特征矩阵	$\mathbf{Y} \in \mathbb{R}^{d2 \times N}$
用户相关的特征向量	$\mathbf{x}_u$
物品相关的特征向量	$\mathbf{y}_i$
用户嵌入矩阵和向量	$\mathbf{A}, \mathbf{a}_u$
物品嵌入矩阵和向量	$\mathbf{B}, \mathbf{b}_i$
扩散深度	$K$
权重矩阵	$\mathbf{w}$

在社交网络结构中,主要由用户和物品这两种类型的节点组成,其中,用户—用户的边对应用户之间的信任关系,用户—物品之间的边对应的用户对物品的评分数据。用户评分数据关系到  $m$  个用户组成的用户集  $\mathbf{U} = \{u_1, u_2, \dots, u_m\}$ ,  $n$  个物品组成的物品集  $\mathbf{I} = \{i_1, i_2, \dots, i_n\}$  和一个  $M \times N$  阶用户对物品的评分矩阵  $\mathbf{R}$ 。在评分矩阵中,  $r_{ui}$  表示用户  $u$  对物品  $i$  的评分,用来表示用户对于物品的偏好。若用户  $u$  喜欢物品  $i$ ,则  $r_{ui} = 1$ ,否则  $r_{ui} = 0$ 。社交网络可以定义为用户之间的社交联系,构建为用户—用户之间的社交信任网络图:  $\mathbf{G} = [\mathbf{U}, \mathbf{T} \in \mathbb{R}^{M \times M}]$  表示,其中,  $\mathbf{U}$  为所有顶点集,即用户集,  $\mathbf{T}$  为节点间的边集,表示为  $M \times M$  阶的用户社交矩阵,  $M$  表示社交用户的数量。本文中,每个用户  $u$  直接连接的一组社交邻居表示为  $\mathbf{T}_u$ ,如果用户  $u_1$  信任用户  $u_2$ ,则  $t_{u_1 u_2} = 1$ ,否则  $t_{u_1 u_2} = 0$ ;通常来说,  $\mathbf{T}$  是不对称的,如果用户  $u_1$  连接到用户  $u_2$  时,那么  $u_1$  信任  $u_2$ ,  $u_2$  信任  $u_1$ ,即  $t_{u_1 u_2} = 1 \wedge t_{u_2 u_1} = 1$ 。此外,用户和物品具有非常丰富的属性特征,用户和物品各自相关的属性特征定义为  $\mathbf{x}_u$  和  $\mathbf{y}_i$ ,组成用户和物品特征矩阵  $\mathbf{X}$  和  $\mathbf{Y}$ 。那么,社交推荐问题可以定义如下:

**定义 1.** 社交推荐(social recommendation)<sup>[6]</sup>。给出一个评分矩阵  $\mathbf{R}$ ,一个社交矩阵  $\mathbf{T}$ ,以及用户和物品相关的特征矩阵  $\mathbf{X}$  和  $\mathbf{Y}$ ,我们的目标是预测用户对物品的未知偏好:  $\hat{\mathbf{R}} = f(\mathbf{R}, \mathbf{T}, \mathbf{X}, \mathbf{Y})$ 。

基于信任的社交推荐算法主要利用用户的信任

关系进行研究,信任在社交推荐中至关重要,信任在不同研究领域具有不同的理解和定义。本文中,我们对推荐系统领域中的信任进行如下定义:

**定义2. 信任(*trust*)<sup>[8]</sup>.**假设用户<sub>1</sub>基于历史交互行为,认为用户<sub>2</sub>能够做出让自己比较满意的推荐,那么可以认定<sub>1</sub>信任<sub>2</sub>。

在现实生活中,信任来源于主观个体的经验积累,信任程度也是一个主观概念,受到用户过去评分或交互经验的影响。假设两个用户对同一物品进行评价,就认为这两个用户之间进行了一次交互,根据用户之间的交互行为能够推断出信任。如果用户<sub>1</sub>和用户<sub>2</sub>同时信任很多用户,表示<sub>1</sub>和<sub>2</sub>观点类似,用户<sub>1</sub>信任的用户,那么<sub>2</sub>未来很有可能也会信任。在社交网络中,兴趣偏好越相似的用户之间的信任程度越高,Papagelis等人<sup>[36]</sup>利用皮尔逊相关系数来度量用户之间的信任值。在计算用户<sub>m</sub>对<sub>n</sub>的信任度时,本文采用基于用户之间的相似度来衡量用户之间的可信度,用户<sub>m</sub>和<sub>n</sub>之间的相似度公式 $sim(u_m, u_n) =$

$$\frac{\sum_{i_j \in I_{u_m} \cap I_{u_n}} (r_{u_m i_j} - \bar{r}_{u_m})(r_{u_n i_j} - \bar{r}_{u_n})}{\sqrt{\sum_{i_j \in I_{u_m} \cap I_{u_n}} (r_{u_m i_j} - \bar{r}_{u_m})^2} \sqrt{\sum_{i_j \in I_{u_m} \cap I_{u_n}} (r_{u_n i_j} - \bar{r}_{u_n})^2}} \quad (1)$$

其中, $r_{u_m i_j}$ 和 $r_{u_n i_j}$ 分别表示用户<sub>m</sub>和用户<sub>n</sub>对物品*i<sub>j</sub>*的评分, $\bar{r}_{u_m}$ 和 $\bar{r}_{u_n}$ 分别表示用户<sub>m</sub>和用户<sub>n</sub>的总体评分的平均值, $I_{u_m} \cap I_{u_n}$ 为用户<sub>m</sub>和用户<sub>n</sub>的共同评分物品数。

信任会随着物品交互结果的变化而逐渐变化,当用户<sub>m</sub>和用户<sub>n</sub>的共同评分物品数不等于0时,就认为用户之间有信任关系,进而计算信任度。假设预测用户<sub>m</sub>对用户<sub>n</sub>的信任度值,计算出用户<sub>m</sub>与其他用户<sub>n</sub>的相似性,则该系数值为用户之间的信任值。反之,当新用户没有评分信息或两个用户之间没有相交的领域,信任度为0。用户<sub>m</sub>和用户<sub>n</sub>的信任度表达式如下:

$$trust(u_m, u_n) = \begin{cases} sim(u_m, u_n), & \text{if } |I_{u_m} \cap I_{u_n}| \neq 0 \\ 0, & \text{otherwise} \end{cases} \quad (2)$$

在社交网络中,信任是一种复杂的网络关系,具有差异性、模糊性、传递性、非对称性、组合性、动态性等特点。本文主要研究信任的传递性和动态性特点。同时,我们也将用户交互历史行为中的信任信息加入递归社交动态建模中,从而能够更加有效地基

于信任进行社交推荐。

### 3.2 模型架构

本文提出的EIDNet是基于DiffNet构建了改进的增强影响扩散模型,模拟了社交递归传播影响的过程,用户最终偏好受到之前的偏好和社交邻居关系的共同影响,我们的目标是在一个低维嵌入空间中对用户和物品进行编码,使低维嵌入空间中的相似性近似于用户对物品的偏好。为了更好的表示用户和物品的影响,通过平均所有学习到的用户和物品的词向量来获得每个用户(物品)的特征向量。EIDNet的关键思想:嵌入层输出用户和物品的嵌入表示,首先对于每个用户(物品),融合层通过融合用户(物品)的特征和嵌入(free embedding),生成融合的用户(物品)嵌入;然后将融合的用户嵌入送到影响扩散层。影响扩散层采用分层结构进行构建,对社交网络中的递归社交扩散过程进行建模;最后,在影响扩散过程达到平衡之后,根据用户—物品交互历史行为和社交关系来预测用户未来的行为和偏好。EIDNet与DiffNet主要的不同之处是考虑到用户信任问题,(1)考虑到特定用户与不同物品交互时,该用户面向不同用户的信任程度不同的问题,我们加入了用户—物品的历史交互记录(物品特征)到递归社交动态建模中(图1中绿线表示),以解决不同用户因信任关系而面向不同物品进行推荐的问题。(2)在递归计算社交关系时,我们提出了一种增加残差连接的方式(图1中红线表示),来减少长距离关系的噪声。(3)我们引入了注意力机制(Attention),帮助学习用户和他们的朋友用户之间的关系向量,将那些对社交影响很重要的用户提取出来,并塑造他们的人际关系。

图1展示了EIDNet的整体模型架构,将用户—物品对<u, i>作为输入,模型输出用户u喜欢物品i的概率。该模型的基本流程包括:

- (1)嵌入层输出用户u和物品i的嵌入表示。
- (2)对于每个用户和物品,都是通过融合层,融合用户和物品的嵌入及其相关特征,产生融合的用户和物品嵌入表示。
- (3)将融合的用户嵌入表示送入影响扩散层,影响扩散层利用一个层级的结构对社交网络中的扩散过程进行建模。同时,我们将基于用户与物品历史交互记录的信任关系(包括了物品的特征)融合到递归社交动态建模中(图1中绿线表示),并引入了注意力机制(Attention),解决了同阶领域权重分配问题。此外,为了减少长距离关系的噪声,我们还提出

了增加残差连接的方式(图 1 中红线表示),用来提升网络性能。

(4)当影响扩散过程达到平衡后,输出层输出用户对物品的推荐偏好。

### 3.3 EIDNet 层级描述

EIDNet 的整个神经体系结构主要包含四个部分:嵌入层(Embedding Layer),融合层(Fusion Layer),影响扩散层(Influence Diffusion Layers)和预测层(Prediction Layer). 每个部分具体描述如下:

#### 嵌入层

我们从文献[5,6]中获得经验,我们将用户和物品编码到低维嵌入空间,用户和物品的嵌入分别记为  $\mathbf{A} \in \mathbb{R}^{D \times M}$  和  $\mathbf{B} \in \mathbb{R}^{D \times N}$ . 这两个嵌入  $\mathbf{A}$  和  $\mathbf{B}$  表示用户和物品的协同嵌入表示,在低维嵌入空间的相似度近似于用户对物品的偏好. 嵌入层首先将用户  $u$  和物品  $i$  进行 one hot 编码,然后在嵌入层执行索引操作,从用户嵌入矩阵  $\mathbf{A}$  和物品嵌入矩阵  $\mathbf{B}$  中得到用户嵌入向量  $\mathbf{a}_u$  和物品嵌入向量  $\mathbf{b}_i$ .

#### 融合层

融合层的目的是从不同类型的用户或物品输入中获取初始表示. 用户融合嵌入表示由用户嵌入向量  $\mathbf{a}_u$ ,以及用户特性向量  $\mathbf{x}_u$  组成. 同样地,物品融合嵌入表示也是由该物品的嵌入向量  $\mathbf{b}_i$  和该物品的特征向量  $\mathbf{y}_i$  组成. 对于每个用户  $u$  来说,融合层将用户嵌入向量  $\mathbf{a}_u$  和它的相关的特征向量  $\mathbf{x}_u$  输入到单层全连通神经网络,以获取用户融合嵌入  $\mathbf{h}_u^0$ . 该融合过程可公式化为

$$\mathbf{h}_u^0 = \sigma(\mathbf{M}^0 \times (\mathbf{a}_u, \mathbf{x}_u) + b) \quad (3)$$

其中  $\mathbf{M}^0$  是一个变换矩阵,  $b$  是偏差项,  $\sigma(^*)$  是一个

非线性函数. 该融合层也可以将单层的全连接操作替换为其他传统的融合操作,例如拼接操作:  $\mathbf{h}_u^0 = (\mathbf{a}_u, \mathbf{x}_u)$  和加权求和操作:  $\mathbf{h}_u^0 = W^1 \mathbf{a}_u + W^2 \mathbf{x}_u$ . 对于每个物品  $i$  来说,融合层将物品嵌入向量  $\mathbf{b}_i$  和它的特征向量  $\mathbf{y}_i$  经过非线性变换之后得到物品嵌入  $V_i$ :

$$V_i = \sigma(\mathbf{M} \times (\mathbf{b}_i, \mathbf{y}_i) + b) \quad (4)$$

$V_i$  主要由来自物品嵌入矩阵  $\mathbf{B}$  中的物品嵌入向量  $\mathbf{b}_i$  和它的特征向量  $\mathbf{y}_i$  两个部分组成,其中,  $\mathbf{M}$  是一个变换矩阵,  $b$  为偏差项.

#### 影响扩散层

影响扩散层将每个用户从融合层得到的融合嵌入  $\mathbf{h}_u^0$  和用户的历史行为放入社交网络  $\mathbf{T}$  中进行用户偏好扩散动态建模. 为了将影响扩散过程建立在一个多层结构上,我们将特征信息放入社交网络中进行扩散. 每一层  $k$  将用户前一层( $k-1$ )的嵌入和当前用户的特征向量作为输入,与上一层的嵌入进行求和操作得到更新的用户嵌入. 然后,更新的用户嵌入被发送到第( $k+1$ )层,以进行下一个扩散过程. 我们从 DiffNet<sup>[6]</sup> 的实验结果中看出,随着  $k$  的扩散,更新的用户嵌入反而会引入噪声,使得实验的结果下降. 因此,我们将社交扩散过程结束后的结果与上一层的嵌入进行求和操作以得到更新的用户嵌入. 我们将用户  $u$  在第  $k$  层社交影响扩散层的嵌入  $\mathbf{h}_u^k$  放入第( $k+1$ )层社交影响扩散层进行影响扩散操作,以得到用户  $u$  的更新的嵌入  $\mathbf{h}_u^{k+1}$ . 具体而言,首先将所有来自第  $k$  层的信任用户的影响转化为一个固定长度的向量  $\mathbf{h}_{T_u}^{k+1}$ :

$$\mathbf{h}_{T_u}^{k+1} = \mathcal{P}(\mathbf{h}_u^k \mid u' \in \mathbf{T}_u) \quad (5)$$

其中  $\mathcal{P}(^*)$  表示平均池化操作,  $\mathbf{T}_u$  是用户  $u$  连接的用户集,它对当前可信用户的隐藏嵌入执行平均操作.

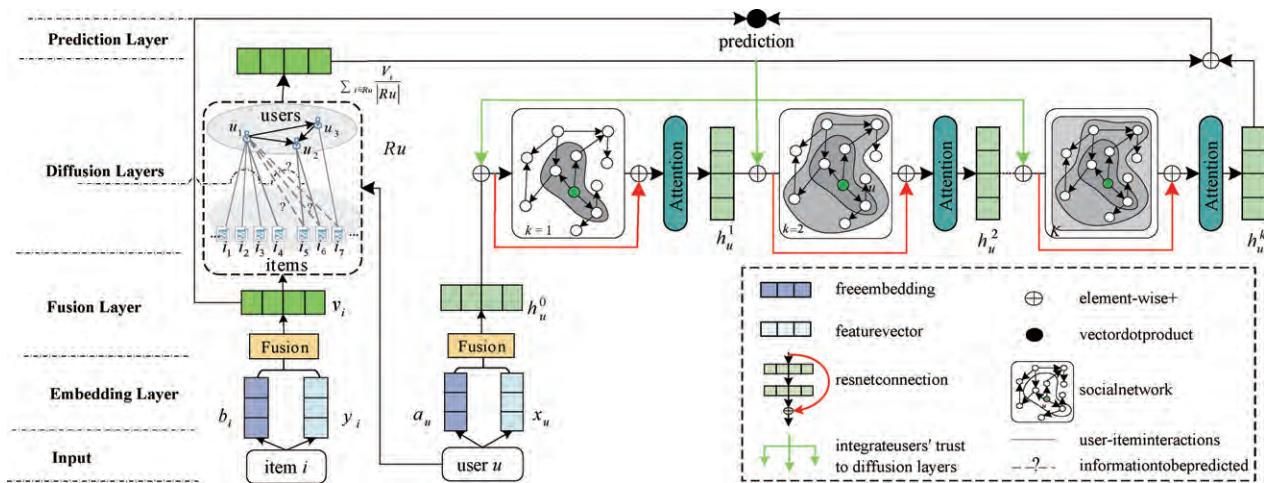


图 1 EIDNet 模型结构

然后,我们将影响扩散嵌入聚集  $\mathbf{h}_{T_u}^{k+1}$ 、潜在嵌入  $\mathbf{h}_u^k$  和历史行为进行结合后的结果与  $\mathbf{h}_u^k$  进行求和操作以得到更新后的嵌入  $\mathbf{h}_u^{k+1}$ 。该过程可以形式化为

$$\mathbf{h}_u^{k+1} = \epsilon^{k+1} \left( \mathbf{M}^k \times \left( \mathbf{h}_{T_u}^{k+1}, \mathbf{h}_u^k + \sum_{i \in \mathbf{R}_u} \frac{V_i}{|\mathbf{R}_u|} \right) + b \right) + \mathbf{h}_u^k \quad (6)$$

其中  $\epsilon^{k+1} (*)$  为非线性变换函数,  $\sum_{i \in \mathbf{R}_u} \frac{V_i}{|\mathbf{R}_u|}$  是用户  $u$  的历史行为,  $\mathbf{R}_u$  是用户  $u$  交互过的物品集合。

$\mathbf{h}_{T_u}^{k+1}$ 、 $\mathbf{h}_u^k$  和  $\sum_{i \in \mathbf{R}_u} \frac{V_i}{|\mathbf{R}_u|}$  的结合方式为:首先将  $\mathbf{h}_u^k$  与  $\sum_{i \in \mathbf{R}_u} \frac{V_i}{|\mathbf{R}_u|}$  进行求和后作为一个整体,再将这个整体与  $\mathbf{h}_{T_u}^{k+1}$  放入用一个非线性神经网络进行组合建模。 $\mathbf{h}_u^k$  的加入是为了增强前一层的嵌入对预测结果的影响程度,

从而减轻更新后的嵌入  $\mathbf{h}_u^{k+1}$  中的噪声。在实际运行中,我们可以预先设定  $k$  的深度,将公式(3)的  $\mathbf{h}_u^0$  作为影响扩散层的开始,逐渐扩散到第  $k$  层。

此外,为了解决同阶邻域上的权重分配问题,我们引入了注意力机制:

$$\mathbf{h}_u^{k+1'} = \mathbf{h}_u^{k+1} \times softmax(\mathbf{W}^T \times tanh(\mathbf{h}_u^{k+1})^T) \quad (7)$$

$softmax$  函数对用户社交关系注意进行归一化处理,其中,  $\mathbf{W}$  是可学习的权重矩阵,  $tanh$  作为非线性激活函数,  $\mathbf{h}_u^{k+1}$  是用户更新后的嵌入。最终它能够判断给予哪些邻居用户更多的权重。我们的模型不仅利用了图结构,而且指定了邻居的不同重要性。在 Attention 的作用下,模型会关注到图中最重要的节点,Attention 更巧妙地利用了图节点之间的相互联系,区分了社交联系的层级,能够增强社交推荐任务中需要的有效信息。

#### 预测层

通过影响扩散层和公式(4)分别得到用户  $u$  在第  $k$  层的嵌入  $\mathbf{h}_u^k$  和物品  $i$  的融合向量  $V_i$ ,我们将用户  $u$  对物品  $i$  的偏好程度建模为

$$\hat{r}_{u,i} = V_i^T (\mathbf{h}_u^k + \sum_{i \in \mathbf{R}_u} \frac{V_i}{|\mathbf{R}_u|}) \quad (8)$$

其中每个用户的最终嵌入表示  $\mathbf{u}_a = \mathbf{h}_u^k + \sum_{i \in \mathbf{R}_u} \frac{V_i}{|\mathbf{R}_u|}$ , 由来自影响扩散层在第  $k$  层的嵌入  $\mathbf{h}_u^k$ , 以及用户的历 史交互行为  $\sum_{i \in \mathbf{R}_u} \frac{V_i}{|\mathbf{R}_u|}$  组成, 即用户的最终预测结果是由相应的用户最终嵌入向量和物品嵌入向量

结合形成的。其中  $\mathbf{R}_u$  是与  $u$  交互的物品集合, 用来捕获用户的偏好。

#### 3.4 模型训练

为了更关注用户的隐式反馈并受到 DiffNet<sup>[6]</sup> 和 BPR<sup>[37]</sup> 的启发, 我们使用了一个基于成对排名的损失函数作为模型的学习目标:

$$\min_{\Theta} \mathcal{L}(\mathbf{R}, \hat{\mathbf{R}}) = \sum_{u=1}^M \sum_{(i,j \in D_u)} \sigma(\hat{r}_{u,i} - \hat{r}_{u,j}) + \mu \Theta_1^2 \quad (9)$$

其中  $\sigma(*)$  是 sigmoid 激活函数。 $\Theta = [\Theta_1, \Theta_2]$ ,  $\Theta_1 = [\mathbf{A}, \mathbf{B}]$ ,  $\Theta_2 = [\mathbf{M}, \mathbf{M}^{k-1}]$ 。 $\mu$  是一个用于控制用户和物品自由嵌入矩阵的复杂性正则化参数。 $D_u = \{(i, j) | i \in \mathbf{R}_u \wedge j \in \mathbf{V} - \mathbf{R}_u\}$  表示用户  $u$  的成对训练集, 其中  $\mathbf{R}_u$  是用户  $u$  的正向反馈数据集。

### 4 算法及复杂度分析

基于上述定义, 我们给出 EIDNet 推荐算法:

**算法 1.** EIDNet 算法.

输入: 用户特征矩阵  $\mathbf{X}$ , 物品特征矩阵  $\mathbf{Y}$ , 社交网络  $\mathbf{T}$ , 扩散深度  $K$ ;

输出: 结果集  $\hat{\mathbf{R}}$ ;

步骤:

- 1 随机初始化模型参数集  $\Theta$ ;
- 2 WHILE 不包含任何  $T$  信息 DO
- 3 FOR EACH  $<u, i>$  IN 训练集 DO /\* 批量读取用户—物品对  $<u, i>$  \*/
- 4  $\mathbf{h}_u^0 = \sigma(\mathbf{M}^0 \times (\mathbf{a}_u, \mathbf{x}_u) + b)$ ; /\* 计算用户在第 0 层的初始融合嵌入  $\mathbf{h}_u^0$  \*/
- 5  $V_i = \sigma(\mathbf{M}^0 \times (\mathbf{b}_i, \mathbf{y}_i) + b)$ ; /\* 计算物品嵌入 \*/
- 6 FOR  $k = 1$  TO  $K$  DO
- 7  $\mathbf{h}_{T_u}^{k+1} = P(\mathbf{h}_u^k | u' \in T_u)$ ; /\* 计算用户  $u$  的信任用户的影响扩散嵌入聚合 \*/
- 8  $\mathbf{h}_u^{k+1} = \epsilon^{k+1} (\mathbf{M}^k \times (\mathbf{h}_{T_u}^{k+1}, \mathbf{h}_u^k + \sum_{i \in \mathbf{R}_u} \frac{V_i}{|\mathbf{R}_u|}) + b)$  +  $\mathbf{h}_u^k$ ; /\* 计算用户  $u$  的更新的嵌入 \*/
- 9  $\mathbf{h}_u^{k+1'} = \mathbf{h}_u^{k+1} \times softmax(\mathbf{W}^T \times tanh(\mathbf{h}_u^{k+1})^T)$ ; /\* 计算同阶邻域权重 \*/
- 10 END FOR
- 11  $\mathbf{u}_a = \mathbf{h}_u^k + \sum_{i \in \mathbf{R}_u} \frac{V_i}{|\mathbf{R}_u|}$ ; /\* 计算用户最终的嵌入表示 \*/
- 12  $\hat{r}_{u,i} = V_i^T (\mathbf{h}_u^k + \sum_{i \in \mathbf{R}_u} \frac{V_i}{|\mathbf{R}_u|})$ ; /\* 计算用户  $u$  对物品  $i$  的评分 \*/
- 13 FOR EACH  $\Theta$  TO  $[\Theta_1, \Theta_2]$  DO

```

14     更新  $\Theta = \Theta - \eta \frac{\partial L}{\partial \hat{r}_{u,i}} \frac{\partial \hat{r}_{u,i}}{\partial \theta}$ ; (10)
15 END FOR
16 END FOR
17 END WHILE
18 RETURN  $\hat{R}$ . /* 通过迭代更新参数  $\Theta = [\Theta_1, \Theta_2]$  ,
计算  $\mathbf{h}_u^0, V_i$ , 得到推荐的结果集  $\hat{R}$  */

```

我们提出的 EIDNet 算法主要思想是, 利用社交网络  $\mathbf{T}$ , 构建分层的社交影响扩散结构, 模拟用户的偏好如何受到递归社交扩散过程的动态影响。我们的目标是预测每个用户对未知物品的偏好, EIDNet 模型学习参数, 根据模型得到预测结果, 即返回推荐结果集  $\hat{R}$ 。EIDNet 算法在输入用户特征矩阵  $\mathbf{X}$ 、物品特征矩阵  $\mathbf{Y}$ 、社交网络  $\mathbf{T}$ , 以及扩散深度  $K$  后, 融合层采用用户和物品嵌入及其特征矩阵进行用户和物品融合表示学习, 每个用户的初始层, 即第 0 层的融合嵌入  $\mathbf{h}_u^0$  (公式 3), 当用户或物品特性不可用时, 对应的融合层将消失。对于每一个用户  $u$ , 我们将在第  $k$  层社交扩散层的嵌入表示为  $\mathbf{h}_u^k$ , 将  $k$  层输出的反馈信息放入第  $k+1$  层进行影响扩散操作, 得到用户  $u$  的更新的嵌入  $\mathbf{h}_u^{k+1}$ 。其中, 我们首先需要将所有来自第  $k$  层的信任用户的影响转化为  $\mathbf{h}_{T_u}^{k+1}$ , 再将  $\mathbf{h}_{T_u}^{k+1}, \mathbf{h}_u^k$  和历史交互记录  $\sum_{i \in R_u} \frac{V_i}{|R_u|}$  进行结合后的结果与  $\mathbf{h}_u^k$  进行求和操作, 得到更新后的嵌入  $\mathbf{h}_u^{k+1}$ 。同时, 我们引入了注意力机制(公式 7), 计算出同阶邻域的权重  $\mathbf{h}_u^{k+1'}$ , 直到推荐系统不包含任何社交网络信息时, 影响扩散层消失会随着  $\mathbf{h}_u^k = \mathbf{h}_u^0$  消失。在这种情况下, 如公式(8)所示, 最终计算出用户的最终预测结果。

在 EIDNet 算法中, 用户和物品嵌入参数  $\Theta = [\Theta_1, \Theta_2]$ , 其中参数  $\Theta_1 = [\mathbf{A}, \mathbf{B}]$ ,  $\Theta_1$  的空间复杂度与经典的嵌入模型相同, 储存了每个用户和每个物品的嵌入, 并随着用户和物品线性增长; 另一个参数  $\Theta_2 = [\mathcal{M}, [\mathcal{M}^k]_{k=0}^{K-1}]$ , 它的空间存储成本是可以忽略的, 因为  $\Theta_2$  参数远小于用户和物品的数量。由 DiffNet<sup>[6]</sup> 可知, DiffNet 的空间复杂度与经典的嵌入模型相同, 同样地, EIDNet 的空间复杂度与经典的嵌入模型相同。并且, 我们所提出的 EIDNet 模型主要的额外时间成本在于分层的影响扩散过程。在社交扩散过程中, 每一层  $k$  将用户从前一层 ( $k-1$ ) 的嵌入作为输入, 在当前的社交扩散过程结束后输出用户更新后的嵌入。然后, 将更新后的用户嵌入发送到 ( $k+1$ ) 层, 用于下一个扩散过程, 由此

可见,  $K$  对算法有着重要影响。给定  $M$  个用户, 每个用户的平均社交近邻设定为  $N$ , 扩散深度为  $K$ , 影响扩散过程的时间复杂度为  $O(MN \times K)$ , 额外的参数更新的时间复杂度也为  $O(MN \times K)$ , 因此, 算法的时间复杂度为  $O(MN \times K)$ 。此外, 我们还比较了 DiffNet 的时间复杂度, Yelp 数据集下, DiffNet 迭代 10 次为 114.18s, EIDNet 迭代 10 次为 123.24s, 因此, EIDNet 的时间复杂度跟 DiffNet 相差不大。由此可见, EIDNet 并没有因为增加用户与物品的历史交互记录和残差连接而受到影响。我们的实验结果表明, 大多数基于图卷积的模型在  $k=2$  时达到最佳推荐性能, 因此每个用户的社交近邻限制在  $N \leq M$  范围内, 此时, 额外的时间复杂性是可以接受的。综上所述, 我们所改进的 EIDNet 在提升性能的同时, 并没有增加时间复杂度和空间复杂度。

## 5 实 验

本节中, 为了验证 EIDNet 是否优于社交推荐任务的最新基线模型, 我们用实验来评估 EIDNet 的性能。

### 5.1 数据集及参数设置

我们在两个真实世界的数据集 Yelp<sup>(1)</sup> 和 Flickr<sup>(2)</sup> 上进行实验。本文中, 依据用户—物品评分数据进行推荐。Yelp 是一个基于位置的在线社交网络。用户可以与他人交朋友, 并通过评分的形式来表达他们的观点态度。由于每个用户给的评分在 [0, 5], 我们对其进行了阈值处理, 大于 3 的评分认为用户喜欢物品。首先, 我们使用 gensim 工具来学习如何将每个词嵌入到 word2vec 模型中。然后, 我们通过对每个用户(物品)的所有学过的词向量求平均, 得到每个用户(物品)的特征向量。

Flickr 是一个在线图像社交共享平台, 具有较强的社交影响力扩散效应。用户关注其他用户, 用户会分享图片, 其他用户会对图片点赞, 并向其社交关注者分享他们对图像的偏好, 表达自己偏好。给定每个图像, 我们在数据集上对该图像进行了真实值分类, 将图像发送到 VGG16 卷积神经网络, 并将 VGG16 最后一个连接层中的 4096 维表示作为图像的特征表示。对于每个用户的特征表示是该用户在训练数据中喜欢的图像特征表示的平均值。在数据

<sup>(1)</sup> <https://www.yelp.com/dataset>

<sup>(2)</sup> <http://flickr.com/>

预处理步骤中,对于这两个数据集,我们过滤掉了拥有少于 2 条评价记录和 2 条社交连接的用户,并删除了那些被评价少于 2 次的物品。我们随机选择 10% 的数据进行测试。剩下的 90% 的数据作为训练集,为了调整参数,从训练数据中选择 10% 作为验证集。预处理后数据的详细统计如表 2 所示。

表 2 两个数据集的统计特征情况

Dataset	Yelp	Flickr
Users	17237	8358
Items	38342	82120
Total Links	143765	187273
Ratings	204448	314809
Link Density	0.048%	0.268%
Rating Density	0.031%	0.046%

考虑到社交活动中,网络中的好友常常会关注相同的用户和物品,我们把用户与物品的交互记录,包括:购买、反馈和评价等,作为推荐模型的重要因素,当用户与物品产生了交互记录则记为 1。在改进的模型 EIDNet 中,我们把交互记录融合到递归社交动态建模中,利用不同用户交互行为中的信任关系,面向不同物品进行推荐。对于我们提出的模型,用较小的随机值初始化嵌入向量。在模型实际训练过程中,我们使用 tensorflow 实现了模型的小批量训练,训练批量大小为 512,并使用 Adam<sup>[38]</sup> 作为模型的优化方法,初始学习率为 0.001。我们还设置了相关参数,包括:扩散深度  $K$ 、嵌入长度  $D$  及 top- $N$ 。具体的实验参数设置如表 3 所示。

表 3 参数设置表

Learning Rate(lr)	0.001
Batch Size(bs)	512
Diffusion Depth( $K$ )	{0,1,2,3,4}
Embedding Size( $D$ )	{16,32,64,128}
Top- $N$ ( $N$ )	{1,2,3,4,5,6,7,8,9,10}

## 5.2 评价指标与对比算法

本文中,为每个用户推荐前  $n$  个物品时,我们使用了两个基于排名的指标:命中率(HR)<sup>[39]</sup> 和归一化折损累积增益(NDCG)<sup>[40]</sup>。其中,HR 衡量的是在前  $n$  个列表中击中目标的百分比。NDCG 是用来衡量排序质量的指标,为优化目标,保证推荐在返回结果总体质量好的情况下,把更高质量结果排在更前面。具体来说,HR 度量用户在测试数据中所喜欢而且已经在前  $n$  个排名列表中成功预测的物品数量;NDCG 会考虑物品的命中位置,如果命中的物品在顶部位置,NDCG 会给出更高的分数。对于这两个

指标,值越大,性能越好。

为了验证 EIDNet 的有效性,我们将 EIDNet 和几个模型进行比较,包括经典的协同过滤模型(BPR<sup>[37]</sup>,FM<sup>[41]</sup>)基于社交的推荐模型(SocialMF<sup>[20]</sup>,TrustSVD<sup>[21]</sup>,ContextMF<sup>[42]</sup>),以及基于图的 GraphRec<sup>[29]</sup>,PinSage<sup>[28]</sup>,NGCF<sup>[43]</sup> 推荐模型。几个模型的概述如下:

- **BPR**<sup>[37]</sup> 是一种基于矩阵分解的成对排序算法,针对每一个用户自己的物品喜好做排序优化。

- **FM**<sup>[41]</sup> 通过先学习每个特征隐向量,然后通过量化的交互(隐向量之间的内积),可以学到不同特征之间的关联关系,以缓解数据稀疏问题。

- **SocialMF**<sup>[20]</sup> 是一种基于概率矩阵分解模型,通过利用每个用户与其好友的信任传播关系信息作为辅助信息,来缓解数据稀疏问题。

- **TrustSVD**<sup>[21]</sup> 是基于信任的矩阵分解模型,该模型引入社交信任关系,不仅考虑用户对物品评分和信任的显性影响,还考虑到评分和信任的隐性影响。

- **ContextMF**<sup>[42]</sup> 提出了一种基于上下文的矩阵因子分解模型,该模型将个人偏好和人际影响结合起来,从社交文本、微博转发行为数据中计算出用户的偏好相似性和社交影响力,衡量用户的信任关系。

- **GC-MC**<sup>[26]</sup> 提出了一种用于矩阵补全任务的图自编码器框架,从链接预测的角度解决推荐系统中的评分预测问题。

- **GraphRec**<sup>[29]</sup> 在用户嵌入过程中,联合考虑了一阶社交邻居和感兴趣的邻居,捕获用户—物品图中的交互和意见。

- **PinSage**<sup>[28]</sup> 是第一个基于 GCN 的工业级推荐系统,有效的结合了随机游走以及图卷积,能够学习节点嵌入。PinSage 和 NGCF<sup>[43]</sup> 都是对高阶图结构进行建模。

- **DiffNet**<sup>[6]</sup> 提出一个具有层级扩散结构的 DiffNet 模型,基于社交网络中迭代的动态扩散过程进行建模。DiffNet 证明了利用高阶社交结构进行推荐具有有效性。DiffNet-nf 表示简化版本的 DiffNet,比如删除了部分用户和物品功能。

此外,为了详细地分析 EIDNet 的推荐性能增强效果,我们还分别设计了三个实验变体:EIDNet\_res 为仅增加残差连接的实验结果,EIDNet\_res\_int 为增加了残差连接和交互关系的实验结果,EIDNet 为增加了注意力机制、残差连接和交互关系所有改进的实验结果,在接下来的实验分析中,我们将 EIDNet\_res,EIDNet\_res\_int,EIDNet 和其他模型进行对比。

### 5.3 实验对比与分析

为了验证第 3 节提出的方法的有效性,我们在两个真实数据集 Yelp 和 Flickr 进行实验,比较所有模型的总体性能。为了保证公平性和有效性,我们对所有参数进行调优,以确保对比算法的最佳

性能,这些对比算法中有多个参数,主要包括  $N$ (top- $N$ )、 $D$ (嵌入长度)和  $K$ (扩散深度),具体参数如表 3 所示。在表 4 和表 5 中,我们设置了扩散深度参数  $K=2$ ,在表 6 中,我们设置了嵌入长度  $D=64, N=10$ 。

表 4 不同嵌入长度  $D$  值下的 HR@10 与 NDCG@10 的性能对比( $N=64, K=2$ )

Models	Yelp						Flickr					
	HR			NDCG			HR			NDCG		
	$D=16$	$D=32$	$D=64$									
BPR	0.2435	0.2616	0.2632	0.1468	0.1573	0.1554	0.0773	0.1554	0.0795	0.0603	0.0628	0.0732
FM	0.2768	0.2835	0.2825	0.1698	0.1720	0.1717	0.1115	0.1212	0.1233	0.0866	0.0954	0.1062
SocialMF	0.2571	0.2709	0.2785	0.1655	0.1695	0.1677	0.1001	0.1056	0.1174	0.0723	0.0964	0.1061
TrustSVD	0.2826	0.2854	0.2939	0.1683	0.1710	0.1749	0.1352	0.1341	0.1404	0.0978	0.1083	0.1203
ContextMF	0.2985	0.3011	0.3043	0.1758	0.1808	0.1818	0.1405	0.1382	0.1433	0.0920	0.1102	0.1131
CNSR	0.2702	0.2817	0.2904	0.1723	0.1745	0.1746	0.1146	0.1198	0.1229	0.0791	0.0978	0.1057
GraphRec	0.2873	0.2910	0.2912	0.1663	0.1677	0.1812	0.1195	0.1211	0.1231	0.0784	0.0930	0.0992
PinSage	0.2944	0.2966	0.3049	0.1753	0.1786	0.1855	0.1192	0.1234	0.1257	0.0844	0.0998	0.1046
NGCF	0.3050	0.3068	0.3042	0.1826	0.1844	0.1828	0.1110	0.1150	0.1189	0.0819	0.0945	0.0998
DiffNet-nf	0.3126	0.3156	0.3195	0.1882	0.1822	0.1928	0.1342	0.1317	0.1408	0.0979	0.1089	0.1192
DiffNet	0.3366	0.3437	0.3477	0.2052	0.2095	0.2121	0.1575	0.1621	0.1641	0.1210	0.1231	0.1273
EIDNet_res_int	0.3431	0.3515	0.3683	0.2096	0.2160	0.2248	0.1613	0.1702	0.1904	0.1332	0.1375	0.1510
<b>EIDNet</b>	<b>0.3544</b>	<b>0.3645</b>	<b>0.3784</b>	<b>0.2126</b>	<b>0.2252</b>	<b>0.2346</b>	<b>0.1721</b>	<b>0.1785</b>	<b>0.1991</b>	<b>0.1394</b>	<b>0.1409</b>	<b>0.1591</b>

表 5 不同大小 top- $N$  值下 HR@ $N$  与 NDCG@ $N$  的性能对比( $D=64, K=2$ )

Models	Yelp						Flickr					
	HR			NDCG			HR			NDCG		
	$N=5$	$N=10$	$N=15$									
BPR	0.1695	0.2632	0.3252	0.1231	0.1554	0.1758	0.0651	0.0795	0.1037	0.0603	0.0628	0.0732
FM	0.1855	0.2825	0.3440	0.1341	0.1717	0.1876	0.0989	0.1233	0.1473	0.0866	0.0954	0.1062
SocialMF	0.1739	0.2785	0.3365	0.1324	0.1677	0.1841	0.0813	0.1174	0.1300	0.0723	0.0964	0.1061
TrustSVD	0.1882	0.2939	0.3688	0.1368	0.1749	0.1981	0.1089	0.1404	0.1738	0.0978	0.1083	0.1203
ContextMF	0.2045	0.3043	0.3832	0.1484	0.1818	0.2081	0.1095	0.1433	0.1768	0.0920	0.1102	0.1131
CNSR	0.1877	0.2904	0.3458	0.1389	0.1746	0.1912	0.0920	0.1229	0.1445	0.0791	0.0978	0.1057
GraphRec	0.1915	0.2912	0.3623	0.1279	0.1812	0.1956	0.0931	0.1231	0.1482	0.0784	0.0930	0.0992
PinSage	0.2105	0.3049	0.3863	0.1539	0.1855	0.2137	0.0934	0.1257	0.1502	0.0844	0.0998	0.1046
NGCF	0.1992	0.3042	0.3753	0.1450	0.1828	0.2041	0.0891	0.1189	0.1399	0.0819	0.0945	0.0998
DiffNet-nf	0.2101	0.3195	0.3982	0.1535	0.1928	0.2164	0.1087	0.1408	0.1709	0.0979	0.1089	0.1192
DiffNet	0.2276	0.3477	0.4232	0.1679	0.2121	0.2331	0.1210	0.1641	0.1952	0.1142	0.1273	0.1384
EIDNet_res_int	0.2537	0.3683	0.4435	0.1855	0.2248	0.2478	0.1476	0.1904	0.2445	0.1193	0.1510	0.2123
<b>EIDNet</b>	<b>0.2759</b>	<b>0.3784</b>	<b>0.4448</b>	<b>0.2296</b>	<b>0.2346</b>	<b>0.2547</b>	<b>0.1603</b>	<b>0.1991</b>	<b>0.2527</b>	<b>0.1250</b>	<b>0.1591</b>	<b>0.2206</b>

首先,我们比较两个数据集上所有模型的总体性能,如下表 4 和表 5 所示,表 4 中对比算法选取参数  $N=10, K=2$ ,根据不同大小的  $D$  得到最优结果,以确保对比算法的最佳效果,表 5 中对比算法选取参数  $D=64, K=2$ ,根据不同大小的  $N$  得到最优值,以确保对比算法的最佳效果。具体来说,表 4 显示了在两个数据集上不同模型在不同大小  $D$  的 HR@10 和 NDCG@ $N$  结果( $N=10, K=2$ ),如表 4 所示,几乎所有模型的性能结果都随着  $D$  从 16 增长到 64 而提高,其中,一些模型在  $D=32$  时达到最佳性能结果(如 BPR, FM),而 DiffNet、EIDNet\_

res\_int 和 EIDNet 都在  $D=64$  取得最佳性能结果,我们所提出的 EIDNet 模型在任何维度  $D$  下的都取得了最优的结果,这说明了对社交网络中递归扩散过程建模的有效性。EIDNet\_res\_int 和 EIDNet 在加入新的改进方法的情况下,能表现出更好的性能,证实了在扩散层中增加残差连接,注入用户—物品的交互记录,引入注意力机制的有效性。另外,EIDNet 较 DiffNet 有明显改进,EIDNet 在 Yelp 上的表现提升了 10.45%,在 Flickr 上的表现提升了 21.32%。在接下来的实验中,为了保证公平性,我们为每个模型设置了性能结果最好的参数  $D=64$ 。同时,我们进一步比

较了不同 top- $N$  推荐大小  $N$  的结果,表 5 显示了在两个数据集上不同模型在不同大小的 top- $N$  值下的 HR@10 和 NDCG@ $N$  结果( $K=2, D=64$ ). 根据实验结果,我们也能够发现,EIDNet 总是表现出最好的性能,这与表 4 的观察结果相似. 根据整体的实验结果,我们提出的 EIDNet 在不同的评价指标和不同的参数下模型表现都能表现出更好的性能. 因此,我们可以从经验上总结出我们所提出的模型的优越性.

为了具体地分析三个改进带来性能提升的幅度,我们还在 Yelp 和 Flickr 上对模型进行了详细分析. 事实上,扩散深度决定了社交图中的社交影响大小,因此,扩散层的数目也非常重要,我们分析了不同  $K$  值下的不同实验结果. 表 6 给出了 DiffNet、EIDNet\_res、EIDNet\_res\_int 和 EIDNet 在两个数据集上不同大小  $K$  的结果,其中,对比算法选取最佳效果下的参数  $D=64, N=10$ . “Improve”一栏显示了与最佳性能结果相比的差异变化,我们设置扩散深度参数  $K=2$  为基准. 如下表 6 所示,当  $K=2$  时,DiffNet、EIDNet\_res、EIDNet\_res\_int 和 EIDNet 都达到最佳性能,每一次改进都带来比 DiffNet 更好的性能结果,而整合所有改进的 EIDNet 总表现出最好的结果. 当  $K$  从 0 增加到 1 时,DiffNet 和 EIDNet\_res 性能结果都迅速提高,当  $K$  继续增加到 3 时,性能下降,这是因为即使增加了残差连接,我们的模型在计算长距离社交关系时也无法完全避免噪声,但在一定程度上可以提高模型的性能. 我们假设,考虑第  $K$  步递归社交扩散过程类似于每个用户的  $K$ -hop 邻居,由于社交扩散随着时间的推移和每个用

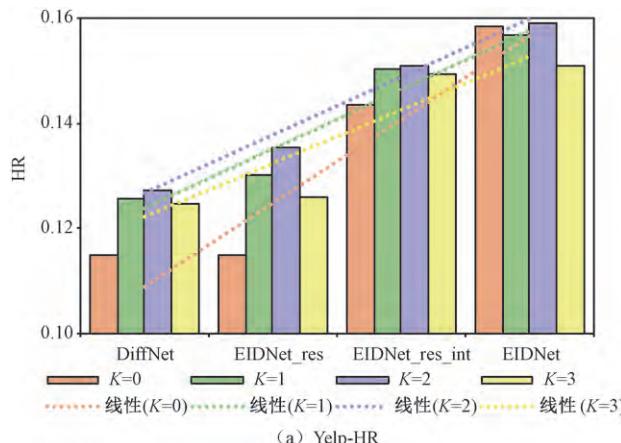
户与  $K$ -hop 邻居之间的距离而减小,即浅层用户关系影响更大,所以,将  $K$  设置为 2 就足以进行社交推荐. 实验结果表明,EIDNet 在 Yelp 和 Flickr 上实验结果均好于 DiffNet 的性能结果. 在仅加入残差连接的情况下 EIDNet\_res, 当  $K=2, D=64, N=10$  时, 较 DiffNet 的最好的性能结果, 在 Yelp 上提升了 4.60%, 在 Flickr 上提升了 6.44%. EIDNet\_res\_int 增加了残差连接和信任关系, 与 DiffNet 的最佳性能结果对比, 当  $K=2, D=64, N=10$  时, 在 Yelp 上提升了 5.99%, 在 Flickr 上提升了 18.62%; EIDNet 是在 EIDNet\_res\_int(加入残差连接和信任关系)的基础上, 引入了注意力机制, 当  $K=2, D=64, N=10$  时, EIDNet 取得了最好的结果, 较 EIDNet\_res\_int 最好的结果, 在 Yelp 上提升了 4.36%, 在 Flickr 上提升了 5.36%. EIDNet 的最好性能结果与 DiffNet 的最好性能结果比较, 在 Yelp 上的表现提升 10.61%, 在 Flickr 上的表现提升了 24.98%. 我们还可以看出, 当  $K=0$  时, EIDNet\_res 的结果跟 DiffNet 保持一致, 这是因为 EIDNet\_res 在计算第 0 层社交关系时, 还没有增加残差连接效果, 这就等同于 DiffNet 模型第 0 层的社交连接. 当  $K=0$  时, 即不考虑用户社交影响时, EIDNet\_res 和 DiffNet 结果都是最差的, 说明了考虑社交扩散影响可以有效提高推荐性能. 而 EIDNet\_res\_int 和 EIDNet 在  $K=0$  时, 比 DiffNet 表现出更好的性能, 这是因为模型加入了用户与物品的交互记录, 当没有用户社交关系时, 基于用户与物品交互记录的信任为用户提供了可供参考的推荐内容, 证明了我们提出的模型的有效性, 进一步提高了社交推荐性能.

表 6 不同扩散深度  $K$  时 HR@10 和 NDCG@10 的性能比较

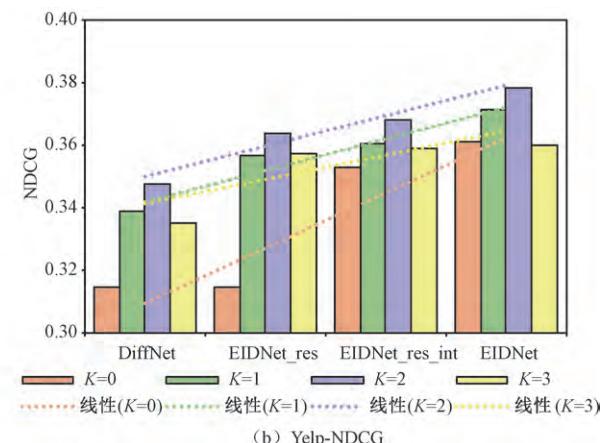
Models	$K$	Yelp				Flickr			
		HR	Improve	NDCG	Improve	HR	Improve	NDCG	Improve
DiffNet	$K=2$	<b>0.3477</b>	—	<b>0.2121</b>	—	<b>0.1641</b>	—	<b>0.1273</b>	—
	$K=0$	0.3145	-9.54%	0.2014	-5.09%	0.1439	-12.27%	0.1148	-10.00%
	$K=1$	0.3390	-2.50%	0.2081	-1.93%	0.1592	-2.96%	0.1257	-1.22%
	$K=3$	0.3348	-3.72%	0.2005	-5.49%	0.1603	-2.34%	0.1246	-2.22%
EIDNet_res	$K=2$	<b>0.3637</b>	—	<b>0.2206</b>	—	<b>0.1736</b>	—	<b>0.1355</b>	—
	$K=0$	0.3145	-13.52%	0.2014	-8.70%	0.1439	-17.10%	0.1148	-15.27%
	$K=1$	0.3568	-1.89%	0.2089	-5.30%	0.1714	-1.26%	0.1303	-3.83%
	$K=3$	0.3575	-1.70%	0.2099	-4.85%	0.1701	-2.01%	0.1258	-7.15%
EIDNet_res_int	$K=2$	<b>0.3683</b>	—	<b>0.2248</b>	—	<b>0.1904</b>	—	<b>0.1510</b>	—
	$K=0$	0.3529	-4.18%	0.2215	-1.46%	0.1870	-1.78%	0.1435	-4.96%
	$K=1$	0.3606	-2.09%	0.2235	-0.57%	0.1897	-0.36%	0.1504	-0.39%
	$K=3$	0.3590	-2.52%	0.2210	-1.69%	0.1890	-0.73%	0.1492	-1.19%
EIDNet	$K=2$	<b>0.3784</b>	—	<b>0.2346</b>	—	<b>0.1991</b>	—	<b>0.1591</b>	—
	$K=0$	0.3610	-4.62%	0.2302	-1.87%	0.1982	-0.45%	0.1583	-0.51%
	$K=1$	0.3715	-1.82%	0.2330	-0.68%	0.1968	-1.15%	0.1567	-1.50%
	$K=3$	0.3602	-4.80%	0.2232	-4.85%	0.1907	-4.21%	0.1508	-5.21%

此外,为了更加直观地看到加入改进模型的提升幅度,我们分别在 Yelp 和 Flickr 数据集下,分析不同模型(DiffNet、EIDNet\_res、EIDNet\_res\_int 和 EIDNet)在不同  $K$  值下的性能结果表现,如下图 2(a)(b) 和图 3(a)(b) 所示,我们选取了对比模型 DiffNet 的最佳性能结果,确定参数  $D=64, N=10$ 。图 2(a)和(b) 分别显示了不同模型在 Yelp 数据集上 HR 和 NDCG 的性能表现,其中,横轴显示了不同模型名称,纵轴表示具有不同模型的每个组的性能水平,其中  $K$  表示扩散层数,分别取 0,1,2,3。图 2 与表 6 分析一致,在不同指标 HR 和 NDCG 下,四个模型都在  $K=2$  时,取得最佳性能。各模型在每一项  $K$  的性能结果都呈现出线性增长趋势,即每一个改进都带来比 DiffNet 更好的性能结果,我们可以观察到,EIDNet 一直保持最好的性能结果。图 3(a)和(b) 分别显示了不同模型在 Flickr 数据集上 HR 和 NDCG 的性能表现,与图 2 观察结果一致,进一步证实了改进模型的有效性。最后,我们研究不同的模型在不同指标 HR 和 NDCG 的性能表现。在 Yelp 数据集下,分析不同模型 HR 和

NDCG 的性能,如下图 4(a)(b) 和图 5(a)(b) 所示。我们可以发现,图 4(a) 和图 4(b) 分别显示了不同模型在 HR 的性能表现,其中,横轴显示了不同模型,纵轴表示具有不同模型的每个组的性能水平,其中  $D$  表示嵌入层数,分别取 16, 32, 64;  $N$  分别取 5, 10, 15。在图 4(a) 和图 5(a) 中,大多数模型的整体性能随着嵌入层数的增加都迅速提高,但某些模型在达到一定性能时,其性能并不会随着嵌入层的增加而提升。其中,BPR 只考虑了用户—物品的评分信息进行推荐,FM 和 TrustSVD 通过利用节点特性和社交网络信息,进而优于 BPR。ContextMF 使用了用户和物品的特性以及社交网络结构,比大多数对比算法表现出更好的性能结果。GraphRec 在用户嵌入过程中联合考虑了一阶社交邻居和兴趣邻居,进一步改进了传统的社交推荐模型。然而,GraphRec 仅对用户嵌入学习的两个图的一阶关系建模,忽略了高阶图的结构。PinSage、NGCF 和 DiffNet 利用了图节点特性,对高阶用户—物品图结构进行建模。这些基于图神经模型的对比算法,显示了利用高阶图结构进行推荐的有效性,而 EIDNet 模型,

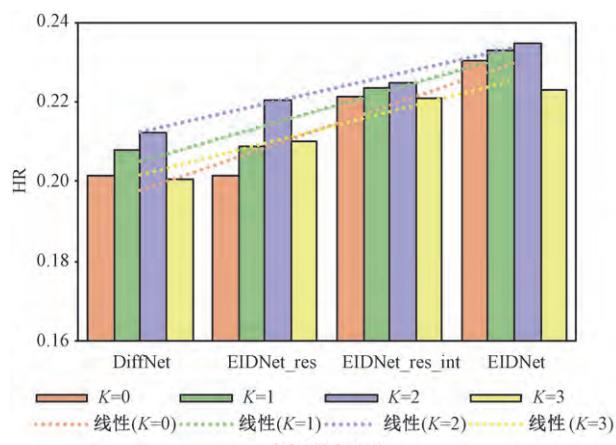


(a) Yelp-HR

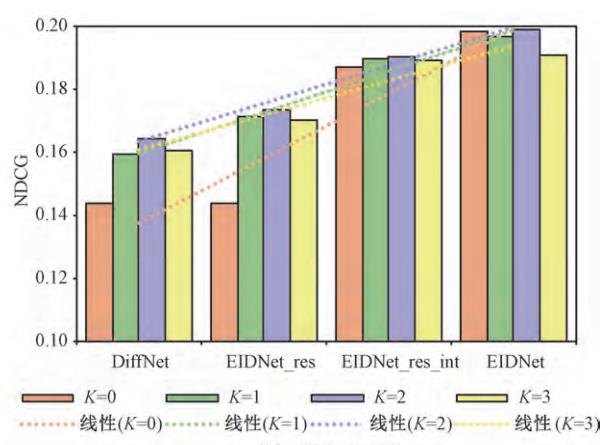


(b) Yelp-NDCG

图 2 不同模型在 Yelp 数据集上的性能表现



(a) Flickr-HR



(b) Flickr-NDCG

图 3 不同模型在 Flickr 数据集上的性能表现

也模拟了高阶社交结构,取得了更好的性能结果,每一个改进都可以提高模型的性能结果,整合三个改进的 EIDNet 能够保持最好的性能结果。此外,在 Yelp 数据集下,分别显示了不同模型在 NDCG 的性能表现,如下图 5(a)和 5(b)所示。我们可以看出,图 5(a)(b)与图 4(a)(b)中的性能表现基本保持一致,EIDNet 在另一个

指标 NDCG 上也表现出同样的性能结果,从整体性能结果来看,我们所提出的 EIDNet 模型的性能在不同参数下都取得较好的性能,与其他对比算法和变体实验相比,我们改进模型的性能结果是最好的。可以得出结论,在不同的评价指标和不同的参数下模型表现都能表现出更好的性能,我们的模型具有较好的泛化能力。

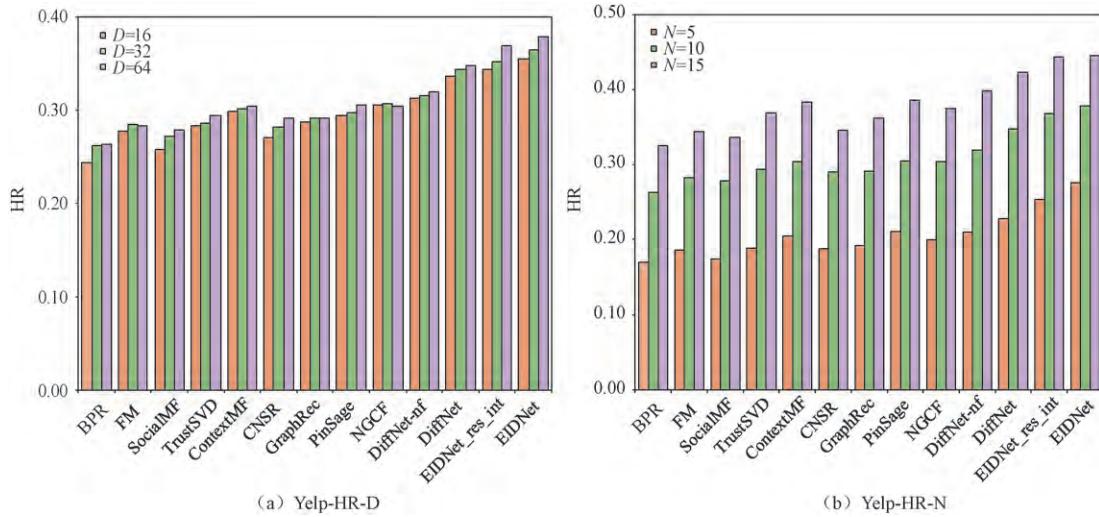


图 4 不同模型在 HR 的性能表现

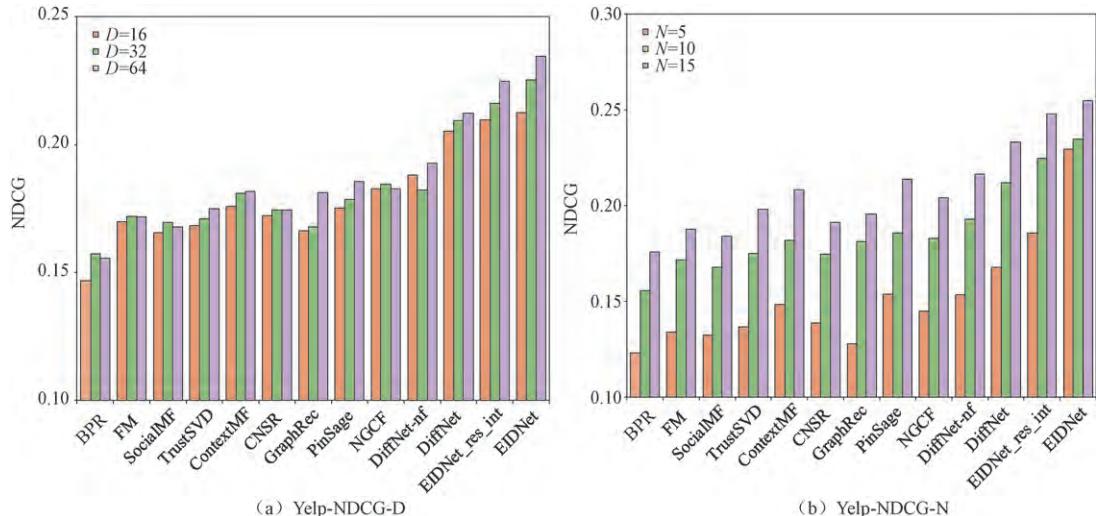


图 5 不同模型在 NDCG 的性能表现

#### 5.4 实验总结

在本文中,我们设置实验参数  $lr = 0.001, bs = 512$ ,可以达到最好的实验结果。根据整体实验结果,得出结论,在不同的排名指标和不同的参数下,与所有对比算法的最佳性能结果相比,我们提出的 EIDNet 优于所有对比算法。同时,较 2019 年 DiffNet 的实验结果,我们观察到 EIDNet 总是表现出更好的性能。为了说明我们所提出 EIDNet 模型的有效性,我们将 EIDNet 的最好性能结果( $K = 2, D = 64, N = 10$ )与 DiffNet 的最好性能比较,在 Yelp 上的表

现提升 10.61%,在 Flickr 上的表现提升了 24.98%。此外, EIDNet\_res 在仅加入残差连接的情况下( $K = 2, D = 64, N = 10$ ),与 DiffNet 最好的性能结果相比,在 Yelp 上的表现提升了 4.60%,在 Flickr 上的表现提升了 6.44%;EIDNet\_res\_int 较 DiffNet 的最佳性能结果对比,在 Yelp 上提升了 5.99%,在 Flickr 上提升了 18.62%;EIDNet 较 EIDNet\_res\_int 最好的结果,在 Yelp 上提升了 4.36%,在 Flickr 上提升了 5.36%。因此,我们通过

实验验证了本文提出的改进模型,确实可以提升 DiffNet 社交推荐模型的推荐性能.

## 6 结论与未来工作

本文提出的 EIDNet 模型考虑了融合社交信息长距离关系产生的噪声,还考虑到特定用户与不同物品交互时,该用户对不同用户的信任程度不同,为基于信任的推荐研究提供了新思路. 本文做出的主要贡献如下:

(1) 提出一个基于社交网络的增强影响扩散模型—EIDNet, 将基于用户与物品的历史交互记录的信任融合到递归社交动态建模中, 体现社交网络中用户的信任关系的作用. 与 DiffNet 所做工作相比, 我们通过以用户—物品交互网络和用户—用户社交网络作为输入, 同时考虑到用户与不同物品交互时面向不同用户的信任程度不同, 将基于用户交互的信任融合到递归社交动态建模中, 基于不同用户的信任关系, 面向不同物品进行推荐, 实验结果证明了增加信任关系的有效性.

(2) 在递归计算社交关系时, 提出增加残差连接的方式, 来减少长距离关系的噪声, 并且不会增加模型的复杂度. 通过实验, EIDNet 在仅加入残差连接的情况下,  $K = 2, D = 64, N = 10$  时, 与 DiffNet 最好的性能相比, 在 Yelp 上的表现提升了 4.60%, 在 Flickr 上的表现提升了 6.44%.

(3) 引入了注意力机制解决了同阶领域权重分配问题, 增强社交推荐任务中需要的有效信息; EIDNet 与 EIDNet\_res\_int(残差连接和用户—物品历史交互记录)性能结果比较, 在 Yelp 上的表现提升了 4.36%, 在 Flickr 上的表现提升了 5.36%.

(4) 在两个真实的数据集上, 实验结果证实了提出的模型可以提升社交推荐模型的推荐性能. EIDNet 与 DiffNet 最好的性能结果相比 ( $K = 2, D = 64, N = 10$ ), 在 Yelp 上的表现提升了 10.61%, 在 Flickr 上的表现提升了 24.98%.

由实验结果可以看出, EIDNet 确实提高了推荐性能. 在未来, 我们提出两个需要进一步研究的问题:(1)在许多在线社交网络中,许多用户也表示不信任信息,探索不信任关系的推荐作用,以及如何将其与我们的模型合并;(2)考虑增加信任关系的同时,融合社交网络中的上下文信息、探索用户的多元

信息,例如:兴趣和习惯等,对推荐的影响;(3)将对 Attention 模块的进一步探索留作以后的工作.

## 参 考 文 献

- [1] Resnick P, Varian H R. Recommender systems. Communications of the ACM, 1997, 40(3): 56-58
- [2] Adomavicius G, Tuzhilin A. Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. IEEE Transactions on Knowledge and Data Engineering, 2005, 17(6): 734-749
- [3] Yu W, Lin G. Social circle-based algorithm for friend recommendation in online social networks. Chinese Journal of Computers, 2014, 37(4): 801-808(in Chinese)  
(王筠,高琳. 基于社交圈的在线社交网络朋友推荐算法. 计算机学报, 2014, 37(4): 801-808)
- [4] Tang J, Hu X, Liu H. Social recommendation: a review. Social Network Analysis and Mining, 2013, 3(4): 1113-1133
- [5] Wu L, Sun P, Hong R, et al. Socialgcn: an efficient graph convolutional network based model for social recommendation. arXiv preprint arXiv:1811.02815, 2018
- [6] Wu L, Sun P, Fu Y, et al. A neural influence diffusion model for social recommendation//Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. Paris, France, 2019: 235-244
- [7] Ma H, Zhou D, Liu C, et al. Recommender systems with social regularization//Proceedings of the 4th ACM International Conference on Web Search and Data Mining. Torino, Italy, 2011: 287-296
- [8] Chen T, Zhu Q, Zhou MX, Wang S. Trust-based recommendation algorithm in social network. Journal of Software, 2017, 28(3): 721-731(in Chinese)  
(陈婷,朱青,周梦溪,王珊. 社交网络环境下基于信任的推荐算法. 软件学报,2017,28(3):721-731)
- [9] Ricci F, Rokach L, Shapira B. Introduction to recommender Systems Handbook//Recommender Systems Handbook. Boston, USA: Springer, 2011: 1-35
- [10] Yang X, Guo Y, Liu Y, et al. A survey of collaborative filtering based social recommender systems. Computer Communications, 2014, 41: 1-10
- [11] Mao Jia-Xin, Liu Yi-Qun, Zhang Min, Ma Shao-Pin. Social influence analysis for micro-blog user based on user behavior. Chinese Journal of Computers, 2014, 37(4): 791-800 (in Chinese)  
(毛佳昕,刘奕群,张敏,马少平. 基于用户行为的微博用户社交影响力分析. 计算机学报, 2014, 37(4): 791-800)
- [12] Balabanović M, Shoham Y. Fab: content-based, collaborative recommendation. Communications of the ACM, 1997, 40(3): 66-72
- [13] Huang Chuang-Guang, Yin Jian, Wang Jing, et al. Collaborative filtering recommendation algorithm for uncertain

- neighbors. Chinese Journal of Computers. 2010, 33(8): 1369-1377(in Chinese)  
(黄创光,印鉴,汪静,等.不确定近邻的协同过滤推荐算法.计算机学报,2010,33(8):1369-1377)
- [14] Burke R. Knowledge-based recommender systems. Encyclopedia of Library and Information Systems, 2000, 69(Supplement 32): 175-186
- [15] Carrer-Neto W, Hernández-Alcaraz M L, Valencia-García R, et al. Social knowledge-based recommender system. Application to the movies domain. Expert Systems with Applications, 2012, 39(12): 10990-11000
- [16] Huang J, Cheng X, Guo J, et al. Social recommendation with interpersonal influence//Proceedings of the 19th European Conference on Artificial Intelligence (ECAI). Lisbon, Portugal, 2010, 10: 601-606
- [17] Al Hasan M, Zaki M J. A survey of link prediction in social networks//Social Network Data Analytics. Boston, USA: Springer, 2011: 243-275
- [18] Anagnostopoulos A, Kumar R, Mahdian M. Influence and correlation in social networks//Proceedings of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Las Vegas, USA, 2008: 7-15
- [19] Ma H, Yang H, Lyu M R, et al. Sorec: social recommendation using probabilistic matrix factorization//Proceedings of the 17th ACM Conference on Information and Knowledge Management. Napa Valley, USA, 2008: 931-940
- [20] Jamali M, Ester M. A matrix factorization technique with trust propagation for recommendation in social networks//Proceedings of the 4th ACM conference on Recommender systems. New York, USA, 2010: 135-142
- [21] Guo G, Zhang J, Yorke-Smith N. Trustsvd: collaborative filtering with both the explicit and implicit influence of user trust and of item ratings//Proceedings of the AAAI Conference on Artificial Intelligence. Austin, USA, 2015, 29(1): 123-129
- [22] Koren Y. Factorization meets the neighborhood: a multifaceted collaborative filtering model//Proceedings of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Las Vegas, USA, 2008: 426-434
- [23] Tian Yao, Qin Yong-Bin, Xu Dao-Yun, Zhang Li. TrustSVD algorithm based on double trust mechanism. Computer Science and Exploration, 2015, 9(11): 1391-1397 (in Chinese)  
(田尧,秦永彬,许道云,张丽.基于双信任机制的TrustSVD算法.计算机科学与探索,2015,9(11):1391-1397)
- [24] Victor P, Verbiest N, Cornelis C, et al. Enhancing the trust-based recommendation process with explicit distrust. ACM Transactions on the Web (TWEB), 2013, 7(2): 1-19
- [25] Sun P, Wu L, Wang M. Attentive recurrent social recommendation//The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval. Ann Arbor, USA, 2018: 185-194
- [26] Berg R, Kipf T N, Welling M. Graph convolutional matrix completion. arXiv preprint arXiv:1706.02263, 2017
- [27] Wu Y, Liu H, Yang Y. Graph convolutional matrix completion for bipartite edge prediction//International Conference on Knowledge Discovery and Information Retrieval (KDIR). Seville, Spain, 2018: 49-58
- [28] Ying R, He R, Chen K, et al. Graph convolutional neural networks for web-scale recommender systems//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. London, UK, 2018: 974-983
- [29] Fan W, Ma Y, Li Q, et al. Graph neural networks for social recommendation//The World Wide Web Conference. San Francisco, USA, 2019: 417-426
- [30] Velić ković P, Cucurull G, Casanova A, et al. Graph attention networks. arXiv preprint arXiv:1710.10903, 2017
- [31] Xiao J, Ye H, He X, et al. Attentional factorization machines: learning the weight of feature interactions via attention networks. arXiv preprint arXiv:1708.04617, 2017
- [32] Zhou G, Zhu X, Song C, et al. Deep interest network for click-through rate prediction//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. London, UK, 2018: 1059-1068
- [33] Wu Q, Zhang H, Gao X, et al. Dual graph attention networks for deep latent representation of multifaceted social effects in recommender systems//The World Wide Web Conference. San Francisco, USA, 2019: 2091-2102
- [34] Chen W, Cai F, Chen H, et al. A dynamic co-attention network for session-based recommendation//Proceedings of the 28th ACM International Conference on Information and Knowledge Management. Beijing, China, 2019: 1461-1470
- [35] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition//Proceedings of the IEEE conference on computer vision and pattern recognition. Seattle, USA, 2016: 770-778
- [36] Papagelis M, Plexousakis D, Kutsuras T. Alleviating the sparsity problem of collaborative filtering using trust inferences//International Conference on Trust Management, Paris, France. Lecture Notes in Computer Science. Berlin, Germany: Springer, 2005: 224-239
- [37] Rendle S, Freudenthaler C, Gantner Z, et al. BPR: bayesian personalized ranking from implicit feedback. arXiv preprint arXiv:1205.2618, 2012
- [38] Kingma D P, Ba J. Adam: a method for stochastic optimization. arXiv preprint arXiv:1412.6980, 2014
- [39] Deshpande M, Karypis G. Item-based top-n recommendation algorithms. ACM Transactions on Information Systems (TOIS), 2004, 22(1): 143-177
- [40] Farseev A, Samborskii I, Filchenkov A, et al. Cross-domain recommendation via clustering on multi-layer graphs//Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval. Shin-

juku, Japan, 2017: 195-204

- [41] Rendle S. Factorization machines//2010 IEEE International Conference on Data Mining. Sydney, Australia, 2010: 995-1000
- [42] Jiang M, Cui P, Wang F, et al. Scalable recommendation with social contextual information. IEEE Transactions on

Knowledge and Data Engineering, 2014, 26(11): 2789-2802

- [43] He X, Liao L, Zhang H, et al. Neural collaborative filtering//Proceedings of the 26th International Conference on World Wide Web. Perth, Australia, 2017: 173-182



**LIU Hui**, M. S. candidate. Her research interests include recommender system, knowledge graph, machine learning.

**ZHANG Xuan**, Ph. D., professor.

Her research interests include software engineering, artificial intelligence, trustworthy software, and requirement engineering.

**YANG Bing**, M. S. candidate. His interests include machine learning, data mining and big data.

**YUN Wei**, M. S. candidate. His research interests include knowledge modeling, knowledge graph, machine learning and its applications.

**ZHAO Jing-Zhuan**, M. S. candidate. Her research interests include knowledge recommendation and machine learning.

## Background

With the emergence and fast-growing of the online social networks, users' interests, opinions or behaviors are influenced by others. Some works have verified that social recommendations with interpersonal influence can better alleviate the problem of data sparsity. Consequently, more and more organizations and scholars are devoted to studying social influence phenomenon in the social networks. However, early social recommendation approaches neglect the dynamic process of social influence diffusion. In this paper, we propose EIDNet, an improved model of DiffNet that models the recursive social diffusion process. Considering the problems of DiffNet and users' trust, it not only integrates user's historical interaction records into recursive social dynamic modeling to obtain the trust degree of different users for different items, but also adds residual connections to reduce noise. Furthermore, we

design a new attention-based module to learn the relationship vector between users and their friends to assign different importance to edges between nodes in the social graph. And finally, experiments show the effectiveness of our proposed model by comparing it with other baselines, which can further improve the recommendation performance of the DiffNet.

This work is supported by the National Natural Science Foundation of China project “Research on data-driven software non-functional requirements knowledge acquisition and service”. In this project, the approach of an enhanced influence diffusion neural network for social recommendation is studied. Additionally, we have extensively studied knowledge graph and recommendation system based on knowledge, and we may explore other useful information into account on future work.