

## 基于高阶和时序特征的图神经网络社会化推荐算法研究

于健, 赵满坤, 高洁, 王聪源, 李亚蓉, 张文彬

### 引用本文

于健, 赵满坤, 高洁, 王聪源, 李亚蓉, 张文彬 [基于高阶和时序特征的图神经网络社会化推荐算法研究](#) [J]. 计算机科学, 2023, 50(3): 49-64.

YU Jian, ZHAO Mankun, GAO Jie, WANG Congyuan, LI Yarong, ZHANG Wenbin. [Study on Graph Neural Networks Social Recommendation Based on High-order and Temporal Features](#) [J]. Computer Science, 2023, 50(3): 49-64.

---

### 相似文章推荐 (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)

##### [基于图神经网络的多信息优化实体对齐模型](#)

Multi-information Optimized Entity Alignment Model Based on Graph Neural Network

计算机科学, 2023, 50(3): 34-41. <https://doi.org/10.11896/jsjcx.220700242>

##### [基于图注意力的神经协同过滤社会推荐算法](#)

Neural Collaborative Filtering for Social Recommendation Algorithm Based on Graph Attention

计算机科学, 2023, 50(2): 115-122. <https://doi.org/10.11896/jsjcx.211200019>

##### [利用异构图神经网络实现情绪-原因对的有效抽取](#)

Utilizing Heterogeneous Graph Neural Network to Extract Emotion-Cause Pairs Effectively

计算机科学, 2023, 50(1): 205-212. <https://doi.org/10.11896/jsjcx.211100265>

##### [基于影响力剪枝的图神经网络快速计算图精简](#)

Fast Computation Graph Simplification via Influence-based Pruning for Graph Neural Network

计算机科学, 2023, 50(1): 52-58. <https://doi.org/10.11896/jsjcx.220900032>

##### [结合全局信息的深度图解耦协同过滤](#)

Deep Disentangled Collaborative Filtering with Graph Global Information

计算机科学, 2023, 50(1): 41-51. <https://doi.org/10.11896/jsjcx.220900255>

# 基于高阶和时序特征的图神经网络社会化推荐算法研究

于 健<sup>1,4,5</sup> 赵满坤<sup>1,4,5</sup> 高 洁<sup>1,4,5</sup> 王聪源<sup>1,4,5</sup> 李亚蓉<sup>2,4,5</sup> 张文彬<sup>3,4,5</sup>

1 天津大学智能与计算学部 天津 300354

2 天津大学国际工程师学院 天津 300354

3 天津大学信息与网络中心 天津 300354

4 天津市先进网络与应用重点实验室 天津 300354

5 天津市认知计算与应用重点实验室 天津 300354

(yujian@tju.edu.cn)

**摘 要** 跨项目社会推荐是一种将社交关系整合到推荐系统中的方法。社会化推荐中包含用户-项目交互图和社交网络图,用户是连接这两个图的桥梁,其表示学习对提升社会化推荐的性能至关重要。然而,现有方法主要使用用户或项目的静态属性和社交网络中的显式朋友关系来进行表示学习,用户和项目交互的时序信息及隐式朋友关系未得到充分利用。因此,在社会化推荐中,如何有效利用时序信息和社交信息成为重要的研究课题之一。文中通过建模用户的隐式朋友和项目的社交属性,提出了一种新颖的基于高阶和时序特征的图神经网络社会化推荐算法(Graph Neural Networks Social Recommendation Based on High-order and Temporal Features)模型,简称 HTGSR。HTGSR 首先利用门控递归单元对基于项目的用户表征进行建模,以反映用户的近期动态偏好,并定义一个高阶建模单元来提取用户的高阶连通特征,挖掘用户的隐式朋友信息;其次利用注意力机制获取基于社交关系的用户表征;然后提出不同的项目社交网络的构建方式,并利用注意力机制来获取项目表征;最后将用户和项目的潜在表征输入到多层感知机,完成用户对项目的评分预测。在两个数据集上进行详细的实验,并将实验结果与多种类型的推荐算法进行比较,结果表明 HTGSR 模型在两个数据集上的效果均较优。

**关键词:** 社会化推荐;时序特征;图神经网络;高阶特征

**中图法分类号** TP311

## Study on Graph Neural Networks Social Recommendation Based on High-order and Temporal Features

YU Jian<sup>1,4,5</sup>, ZHAO Mankun<sup>1,4,5</sup>, GAO Jie<sup>1,4,5</sup>, WANG Congyuan<sup>1,4,5</sup>, LI Yarong<sup>2,4,5</sup> and ZHANG Wenbin<sup>3,4,5</sup>

1 College of Intelligence and Computing, Tianjin University, Tianjin 300354, China

2 Tianjin International Engineering Institute, Tianjin University, Tianjin 300354, China

3 Information and Network Center, Tianjin University, Tianjin 300354, China

4 Tianjin Key Laboratory of Advanced Networks and Applications, Tianjin 300354, China

5 Tianjin Key Laboratory of Cognitive Computing and Application, Tianjin 300354, China

**Abstract** Cross-item social recommendation is a method of integrating social relationships into the recommendation system. In social recommendation, user is the bridge connecting user-item interaction graph and user-user social graph. So user representation learning is essential to improve the performance of social recommendation. However, existing methods mainly use static attributes of users or items and explicit friend information in social networks for representations learning, and the temporal information of the interaction between users and items and their implicit friend information are not fully utilized. Therefore, in social recommendation, effective use of temporal information and social information has become one of the important research topics. This paper focuses on the temporal information of the interaction between users and items, and gives full play to the advantages of social network, modeling the user's implicit friends and item's social attributes. This paper proposes a novel graph neural networks social recommendation based on high-order and temporal features, referred to as HTGSR. Firstly, the framework uses gated recurrent unit to model item-based user representations to reflect the user's recent preferences, and defines a high-order mo-

到稿日期:2022-07-11 返修日期:2022-12-15

基金项目:国家自然科学基金(61877043,61877044)

This work was supported by the National Natural Science Foundation of China(61877043,61877044).

通信作者:张文彬(zhangwenbin@tju.edu.cn)

deling unit to extract the user’s high-order connected features and obtain the user’s implicit friend information. Secondly, HTGSR uses attention mechanism to obtain social-based user representation. Thirdly, the paper proposes different ways to construct item’s social networks, and uses the attention mechanism to obtain item representations. Finally, the user’s and item’s representations are input to the MLP to complete the user’s rating prediction for the item. The paper conducts specific experiments on two public and real-world datasets, and compares the experimental results with different recommendation algorithms. The results show that the HTGSR has achieved good results on the two datasets.

**Keywords** Social recommendation, Temporal features, Graph neural networks, High-order features

随着 5G 时代的到来和各种电子设备的广泛应用,各种信息正在以爆炸式的速度生成和传播,如存储在网络中的视频、音频和文本数据。用户很难从这些海量数据中过滤出想要的信息,用户的个性化需求无法通过单一服务来满足。Varian 等<sup>[1]</sup>于 1997 年提出了推荐系统的概念。推荐系统的出现弥补了搜索引擎的缺陷,它可以有效地将用户的个人历史行为作为自己的服务因素,从而过滤冗余信息,为用户带来不同程度的个性化体验。

推荐系统涵盖了广泛的领域,如表 1 所列。互联网技术的快速发展有助于获得更丰富的用户交互数据和社会信息,但也导致了信息数据的爆炸性增长。尽管基于矩阵分解和协同过滤的传统推荐算法在一定程度上提高了推荐性能,但它们高度依赖于用户-项目交互矩阵。其主要通过获得用户对项目的评分等显性反馈来生成推荐候选项目,而没有充分利用用户的浏览时间等隐性反馈。面对庞大的用户数量和交互式数据,这种方法已经无法满足用户对个性化推荐体验的高需求。深度学习方法<sup>[2]</sup>的出现弥补了传统推荐算法的不足。此类方法可以学习复杂的非线性关系,将用户和项目的交互信息与用户的社交网络信息相结合,并学习更全面的用户表示和项目表示,以提高推荐的准确性。

表 1 常见的推荐系统的应用

Table 1 Common applications of recommendation systems

| 应用   | 推荐系统实例                |
|------|-----------------------|
| 视频   | 优酷、爱奇艺、腾讯视频、YouTube   |
| 新闻   | 网易新闻、头条、腾讯新闻、MoviLens |
| 音乐   | QQ 音乐、网易云、酷狗、Ringo    |
| 电商平台 | 京东、淘宝、Amazon          |
| 社交平台 | 微信、微博、Twitter         |

当前,真实社会和虚拟社会的不断融合极大地促进了社交信息的快速传播,改变了人们的社交方式。因此,社交网络已经成为互联网发展中不可或缺的重要角色,社会化推荐也成为了当前研究的热点方向之一。虚拟社交网络与用户的真实社交的共同之处在于人与人之间的关系既亲密又疏远。通常,研究人员将其定义为不同强度的社交关系<sup>[3]</sup>。大多数社交关系密切的用户都有类似的生活和工作环境以及朋友圈,如家人和朋友、同学或同事,但这种高度重复的强关系网络并不利于信息的传播。相反,在由兴趣相似的陌生人组成的脆弱关系网络中,信息可以更迅速、更广泛地传播。因此,在研究推荐算法的过程中,关注社交网络中存在差异的社交关系已成为提高推荐性能的关键点之一,如 Twitter<sup>[4]</sup>和 Epings<sup>[5]</sup>中的信任关系。

由于社会化推荐的数据规模庞大、稀疏且冗余,如何防止

过度拟合、数据稀疏和冷启动仍然是社会化推荐面临的挑战。在社会化推荐中,本文主要关注信息利用的 3 个方面,以应对上述挑战。

- (1)如何衡量目标用户与其朋友之间的社交关系?
- (2)在进行社会化推荐时,社交关系的强弱将发挥什么价值?产生什么影响?
- (3)推荐时应该采取什么方法来充分利用用户项目的交互图和社交网络中的有效信息?

将深度神经网络(Deep Neural Network,DNN)应用于评级预测的社会推荐<sup>[6-9]</sup>的方法已被证明能够学习到更完整的用户和项目表示,如 FTMFI<sup>[10]</sup>,ARSE<sup>[11]</sup>,SVD++<sup>[12]</sup>等。Yang 等<sup>[13]</sup>使用随机步行抽样策略来获取社交网络中的邻居,利用注意力机制来量化浏览记录对用户兴趣的影响。基于 DNN 的社会化推荐方法可以准确捕捉用户的静态和动态偏好,使推荐效果更符合用户的兴趣和偏好,增强推荐的可解释性。本文在现有方法的基础上对社会化推荐展开研究,通过结合用户交互行为的时序信息和用户社交网络的隐式朋友信息进行用户表征学习,并利用注意力机制捕获不同项目对用户偏好的影响和不同用户对项目表征的影响。

本文提出了一种高阶时序图神经网络社会化推荐算法模型 HTGSR。该模型引入了门控递归单元来建模用户与项目之间交互的时序信息,并简化了具有叠加作用的现有模块;使用两层注意力网络来捕捉用户的不同显式朋友对自己的影响,以基于社交关系对用户表示进行建模。本文将用户的隐式朋友作为目标用户的高阶连接性特征和时序信息集成到基于项目的用户表征建模过程中。在项目表征建模过程中,使用注意力机制为目标项目的交互用户赋予不同的权重,以捕捉不同用户对目标项目表征的影响。基于现有数据,完成了不同项目的社交网络构建,并将其集成到项目表征建模中。该模型充分发挥了社交网络信息在用户和项目建模中的重要作用。本文的主要贡献如下:

- (1)充分利用目标用户对交互项目的评分时间信息。在分析了用户-项目交互图和数据特征之后,本文使用门控递归单元(Gated Recurrent Unit,GRU)来描述用户的兴趣变化;在建模用户的潜在表示时,将用户与项目之间的交互时间作为辅助信息。此外,本文还分析了时间特征建模方法在实验部分的适用性。
- (2)基于对用户社交网络中信息特征的分析,定义了一个高阶建模单元(High-Order Modeling Unit,HOMU),该单元将用户的隐式好友信息作为目标推荐用户的高阶连通性特征,并将其嵌入到用户表示中,以确保其能够集成到预测模型

中。在建模高阶特征的过程中,本文仍然使用时间序列信息作为辅助信息,并使用门控递归单元为具有较大社会影响力的用户赋予更大的权重,有效地反映了社交网络中不同用户对目标用户表示学习的贡献程度。

(3)在 Ciao 和 Epions 两个公共数据集上进行了充分实验,以论证上述创新点的积极意义。以 MAE 和 RMSE 作为评价标准,在不同类别的推荐模型中选取经典算法作为基线模型进行比较,实验结果表明本文方法在两个评价指标上均优于基线方法。本文还进行了消融实验和分析,以深入探讨各个部分对模型性能的影响。同时,提出了两种不同的项目社交网络构建方法,即数量型项目社交网络(Number Item Social,NIS)和比例项目社交网络(Proportion Item Social,PIS),以便对项目特征层采取不同的建模方法,分析特征层建模对模型性能的影响。

## 1 社会化推荐算法理论基础

### 1.1 社会化推荐和传统推荐

社会化推荐经过多年的沉淀和发展已经取得了丰硕的成果<sup>[14-16]</sup>。与传统推荐不同,社会化推荐不仅利用了用户和项目之间的交互信息,而且还结合了用户之间的社交信息、位置关系等重要的影响因子。另外,两者之间也有一些主要区别,如表 2 所列。

表 2 社会化推荐与传统推荐的主要区别

| Table 2 Main difference between social recommendation and traditional recommendation |                 |                 |
|--------------------------------------------------------------------------------------|-----------------|-----------------|
| 差异点                                                                                  | 传统推荐            | 社会化推荐           |
| 数据特点                                                                                 | 数据的规模、稀疏性及冗余性较小 | 数据的规模、稀疏性及冗余性更强 |
| 信息类型                                                                                 | 评分信息            | 评分信息及社交关系信息     |
| 采用的主要方法                                                                              | 协同过滤算法          | 协同过滤算法及社会网络分析法  |
| 推荐结果                                                                                 | 准确度较低           | 准确度较高           |

随着互联网技术的发展和社交媒体的盛行,大量的互联网用户可以随时参与在线网络活动,因此产生了多种多样的社交关系。社交网络中社交关系的强弱是不同的,如何合理有效地挖掘对用户有价值的社交关系是社会化推荐面临的挑战之一。

### 1.2 传统推荐算法简介

基于内容(Content-Based,CB)的推荐算法<sup>[3]</sup>首先对项目进行内容分析,以获得项目的内容属性索引;其次对用户的历史行为数据进行建模,以获得用户的兴趣;然后计算候选项目与用户偏好的相关度并排序;最后向用户推荐具有高相关性的项目。该算法需要从不同类型的推荐项目中提取不同的特征进行建模,因此在使用此类算法时,用户和项目的特征属性提取尤为重要<sup>[17-19]</sup>。例如,推荐的电影往往是基于电影类型和导演风格等因素提取特征来进行推荐的;商品类别的推荐通常是基于商品类型、价格或大小等因素的建模。基于内容的推荐算法在新闻推荐和论文推荐等文本领域表现非常好,并且通常更具解释性。

协同过滤(Collaborative Filtering,CF)思想的出现促进了推荐系统的发展,并已成为推荐系统中广泛流行的

技术<sup>[20-24]</sup>。协同过滤主要根据用户的行为数据表达用户的兴趣,寻找项目或用户之间的相关性,然后根据相关性选择候选项目集以推荐给目标用户。尽管该算法不依赖于任何领域知识,但它受到用户和项目之间的交互矩阵的限制。交互矩阵的值可以表示用户与项目的交互行为,这类信息可以极大地帮助研究人员捕捉用户的兴趣和偏好。用户和项目之间的交互数据可以分为两类:显式反馈和隐式反馈。评分等体现用户对项目直接行为的信息被称为显式反馈;点击、浏览这类间接反映用户兴趣特征的数据信息被称为隐式反馈。基于协同过滤的算法根据实现策略的不同划分为基于模型的协同过滤算法和基于内存的协同过滤算法<sup>[25-26]</sup>。

### 1.3 社会化推荐算法简介

矩阵分解技术<sup>[27-30]</sup>可以将用户-项目评分矩阵分解为两个或多个低维矩阵的乘积以实现维度规约,并使用低维空间数据研究高维数据的性质,主要包括奇异值分解(Singular Value Decomposition,SVD)、非负矩阵分解 Nonnegative Matrix Factorization,NMF)和概率矩阵分解(Probabilistic Matrix Factorization,PMF)。在社会化推荐中,矩阵分解技术关注用户的社交网络信息对用户潜在特征向量的影响,并将用户的各种社交网络关系信息集成到矩阵的优化分解过程中,以提取更好的潜在特征向量。例如,SoRec<sup>[29]</sup>是一种将基于 PMF 的社交网络结构与用户项目评分矩阵相结合的方法,其将两个不同的数据资源通过共享的用户潜在特征空间连接起来。通过基于概率矩阵分解的因子分析,学习低阶用户的潜在特征空间和项目潜在特征空间,提出社会化建议。

然而,这种方法并没有区分用户之间的信任程度,因此研究人员开始研究用户信任程度的计算。例如,SPTW<sup>[30]</sup>以社交网络中用户的信任关系及用户对兴趣点推荐的反馈为动机,通过矩阵分解技术计算社交网络中用户之间的信任程度,然后使用高概率位置分类算法来生成兴趣点列表作为推荐项。SoRec 和 SPTW 的社会关系不区别方向,Yang 等<sup>[31]</sup>认为,社会关系的方向性可能会对推荐效果产生一定影响,因此提出了 TrustMF 模型。该模型充分利用了矩阵分解技术,并根据信任关系的方向,将用户投影到信任者特征向量和可信特征向量中,分别表示用户“信任他人”和“被他人信任”的行为,该模型能够准确地反映现实世界中的推荐过程。

图神经网络能自然地集成节点信息以及拓扑结构,已经被证实对图数据的表示学习具有十分重要的意义<sup>[32-34]</sup>。基于图神经网络的社会化推荐算法<sup>[35-38]</sup>通常利用用户-项目的交互图和用户-用户社交图中的两部分数据进行有效的推荐,将用户及项目作为用户-项目的交互图和用户-用户社交图的节点,至于节点的状态信息则是用项目-项目之间、用户-用户之间、用户-项目之间和内容信息间的关系来表示。这两个图属于两个异构的网络,用户共存在这两个网络中,是连接这两个图的桥梁。因此用户的表示学习在社会化推荐中是极其重要的。由于社会化推荐数据规模大且稀疏,Yang 等<sup>[35]</sup>将矩阵分解技术和图嵌入技术相结合,提出了 HOP-Rec 模型,在用户项目交互图上利用随机游走策略挖掘高阶关系,使用矩阵分解作为预测模型。但是其中的高阶关系仅被用来丰富



训练数据,没有真正用于预测过程中。而 NGCF<sup>[36]</sup>模型成功把高阶连通性特征集成到预测模型中,并采用共同注意力机制将自我关注和其他关注考虑在内,提升了推荐效果。上述方式利用周围邻居提出静态模型,而没有模拟信息在全局的循环传播过程。因此,Wu 等<sup>[37]</sup>提出了一种具有分层影响传播结构的模型 DiffNet。DiffNet 对社会网络中用户之间的关系进行迭代计算,将用户的偏好影响力进行  $K$  轮传播,最终形成用户之间互相影响的偏好传播。Zhang 等<sup>[38]</sup>认为社交传播性不仅存在于用户之间,也存在于项目之间,因此提出了 DANSER 模型。该模型将用户领域的静态、动态双重社交因素扩展到项目领域,并以此研究推荐过程中的 4 种社交因素,动态地衡量两个领域的 4 种社会互动,提升了社会效应的可解释性。

2 高阶时序图神经网络社会化推荐

近年来,社会化推荐在众多研究者的推动下取得了长足的进步,数据稀疏性和冷启动问题得到有效缓解。尽管现有的社会化推荐方法在性能上有了一定的提升,但大多数方法都是通过描述用户或项目的固有属性(如 ID、类别等)来获取用户或项目的嵌入表示<sup>[39-48]</sup>。对于一些动态属性(容易随时间改变的属性)的建模有所欠缺,无法学习更完整和准确的用户或项目表示。此外,在现实生活中,用户的偏好变化与时间相关,用户可能在不同的阶段对不同的项目特征感兴趣。时序性能够帮助研究者有效探索用户多阶段的兴趣变化,找出用户偏好发生变化的时间点,有助于进一步挖掘用户兴趣变化的原因。随着社交平台的普及,社交网络变得越来越复杂。当用户的显式好友无法与用户分享有用的信息时,就需要考虑用户的隐式好友信息对用户的影响。当前已经提出了许多基于时间信息的推荐模型。例如,Xia 等<sup>[49]</sup>提出了一种双通道超图卷积网络,并将自监督学习的思想融入其中,通过最大化两个通道学习到的会话表示之间的互信息作为辅助任务来改进推荐任务;Chang 等<sup>[50]</sup>考虑到潜在信号行为和快速变化的偏好,利用 GNN 网络通过项目-项目兴趣图来整合隐藏信号行为以及快速变化的偏好。本文结合用户-项目交互的时序信息和用户隐式朋友的高阶特征,提出了一种新的高阶序列图神经网络社会化推荐模型。下文将详细介绍高阶时序图神经网络社会化推荐模型的构建过程。

2.1 符号与定义

在社会化推荐中,有两个实体集合:一个是用户集合  $U = \{u_1, u_2, \dots, u_n\}$ ,另一个是项目集合  $V = \{v_1, v_2, \dots, v_m\}$ 。其中,  $n$  表示用户的个数,  $m$  表示项目的数量。本文将  $R \in R^{n \times m}$  看作是用户-项目评分矩阵。如果  $u_i$  给予了  $v_j$  一个评分,那么  $r_{ij}$  就是评分数值的表示,否则文中将用 0 来填充  $u_i$  对  $v_j$  的评分。评分值  $r_{ij}$  可以被看作是用户  $u_i$  对于  $V_j$  的观点意识,  $F(i)$  代表与用户  $u_i$  相连的邻居的集合,  $C(i)$  是用户  $u_i$  交互过的项目集,  $B(j)$  是与项目  $v_j$  交互过的用户集合。文中使用  $p_i \in R^d$  向量来表示一个用户,用  $q_j \in R^d$  向量来表示一个项目。  $d$  是嵌入向量的维度。本文公式中涉及的符号及定义如表 3 所列。

表 3 符号与定义

| 符号            | 定义及描述                                              |
|---------------|----------------------------------------------------|
| $e_r$         | 对于评分级别 $r$ 的观点嵌入,例如五星评分, $r \in \{1, 2, 3, 4, 5\}$ |
| $d$           | 嵌入向量的长度                                            |
| $h_i^I$       | 用户 $u_i$ 从 $C(i)$ 上获取基于项目的用户潜在表征                   |
| $h_i^S$       | 用户 $u_i$ 从 $F(i)$ 上获取基于社交关系的用户潜在表征                 |
| $h_i$         | 结合 $h_i^I$ 和 $h_i^S$ 形成的用户 $u_i$ 的潜在表征             |
| $X_{ia}$      | 项目 $v_a$ 针对用户 $u_i$ 具有观点意识交互的表示                    |
| $f_{jt}$      | 用户 $u_t$ 针对项目 $v_j$ 具有观点意识交互的表示                    |
| $z_j$         | 项目 $v_j$ 的潜在表征                                     |
| $\alpha_{iu}$ | 某个项目 $v_a$ 对用户 $u_i$ 在社交域上的表征 $h_i^{S-}$ 的注意力权重    |
| $\beta_{uo}$  | 某个用户 $u_o$ 对目标用户在社交域上的表征 $h_i^{S-}$ 的注意力权重         |
| $\mu_{jt}$    | 某个用户 $u_t$ 对目标项目在社交域上的表征 $h_i^{S-} z_j^t$ 的注意力权重   |
| $r'_{ij}$     | 用户 $u_i$ 对项目 $v_j$ 的预测评分值                          |
| $\oplus$      | 两个向量的连接操作                                          |
| $w, b$        | 神经网络中的权重和偏置值                                       |

2.2 模型概述

本文提出了一种基于高阶和时序特征的图神经网络社会化推荐算法模型 HTGSR。该模型分析了数据集的特点,探索并成功地找到了一种对用户-项目交互的时间序列信息进行有效建模的方法;针对现有方法中具有叠加效果的模块进行了简化;将用户的隐式朋友作为目标用户的高阶连通特征,融入用户表征的建模过程中。在基于项目的用户表征建模过程中,HTGSR 利用门控循环单元有效地结合了时间信息。在基于社交关系的用户表征建模过程中,HTGSR 对目标用户的邻居进行建模,使用双层注意力网络来捕捉不同邻居对目标用户表征的影响。在项目表征建模过程中,本文模型融合用户嵌入和评分嵌入的信息共同进行建模,利用注意力机制对目标项目的交互用户赋予不同的权重,以捕捉不同用户对目标项目表征的影响。用户和项目表征将被送入多层感知器以预测用户对未知项目的评分。本文提出的 HTGSR 框架整体模型如图 1 所示,框架由用户表征建模、项目表征建模和评分预测 3 个子模块组成。

- (1)用户表征建模。在社交图网络推荐中,用于建模用户潜在特征的数据存在于两个图中,即社交图和交互图。社交聚合也被称为基于社交关系的用户表征建模,这部分主要是充分利用用户的社交邻里关系来学习用户的潜在表征。项目聚合也被称为基于项目的用户表示建模。该模块可以通过用户-项目图中的交互信息来挖掘用户特征,并考虑时序信息。此外,本文还定义了一个高阶特征建模单元(High-Order Modeling Unit, HOMU)来对用户的“隐式朋友”进行建模。通过融合基于社交关系和基于项目的用户表示,可以获得用户的综合潜在向量表示。
- (2)项目表征建模。该模块用于获取项目的潜在向量表征。用户聚合也被称为基于用户的项目表征建模。为了更好地获得项目表示,该模块的用户聚合包括与目标项目交互的用户嵌入及其评分嵌入,并使用注意力机制分配不同的权重,用于捕捉不同用户对目标项目表征的影响。
- (3)评分预测。该模块将得到的用户表示和项目表示串联起来,然后输入多层感知器来预测用户对未知项目的评分。




图1 HTGSR模型的整体框架

Fig. 1 Overall framework of HTGSR model

本文将从用户表征建模、项目表征建模和评分预测3方面具体阐述模型构建过程,同时给出相关理论基础的详细证明。

### 2.3 用户表征建模过程

用户表征建模的主要作用是获取用户的潜在表征,对于某一个用户  $u_i$ ,表示为  $h_i \in \mathbf{R}^d$ ,  $h_i$  是由用户在项目域上的表征  $h_i^I \in \mathbf{R}^d$  和用户在社交域上的表征  $h_i^S \in \mathbf{R}^d$  组成的。本文利用设计好的聚合函数将这两个不同域的表征进行融合连接,生成最终的用户表征  $h_i$ 。下文将详细介绍基于项目域上的用户潜在表征建模、基于社交关系的用户潜在表征建模,以及如何合并这两个域的表征。

#### 2.3.1 基于项目的用户潜在表征建模

用户-项目交互图中的数据主要反映以下3方面的信息:目标用户交互过的项目、对每个项目的评分,以及发生评分行为的时间。HTGSR模型能够充分利用用户-项目交互图中的这3类信息,并将它们融合在一起,得到基于项目的用户潜在表征,如式(1)所示:

$$h_i^I = \sigma(W \cdot \text{Aggre}_{\text{items}}(\{X_{ia}, \forall a \in C(i)\} + b)) \quad (1)$$

其中,  $C(i)$  表示用户  $u_i$  交互过的项目的集合,向量  $X_{ia}$  表示用户  $u_i$  与项目  $v_a$  之间的意见交互信息,  $\text{Aggre}_{\text{items}}$  是一个项目聚合函数,  $\sigma$  代表一个非线性激活函数,  $W$  和  $b$  是神经网络中的权重和偏置值。下文将详细介绍如何定义观点交互表示  $X_{ia}$  和聚合函数  $\text{Aggre}_{\text{items}}$ 。

当用户和一个项目交互时,可以通过对这个项目的评分来展示自己对该项目的观点。例如,在日常的购物过程中,人们通常会对项目进行星级评分,这些评分可以帮助建模学习用户在项目域上的潜在向量表示,从而更好地捕获用户的偏好。为了能够有效地建模用户对项目的评分,本文引入观点嵌入向量  $e_r \in \mathbf{R}^d$ ,这样可以将用户的评分作为一个稠密的向量表示。对于每一个用户  $u_i$  交互过的项目  $v_a$ ,本文采用向量  $X_{ia}$  作为项目表征  $q_a$  和观点嵌入向量  $e_r$  整合的结果表示,文中通过一个多层感知机来实现,定义为  $g_v$ 。这个多层感知机的输入为  $q_a$  和  $e_r$ ,输出为  $X_{ia}$ 。表达式如式(2)所示:

$$X_{ia} = g_v([q_a \oplus e_r]) \quad (2)$$

对于聚合函数  $\text{Aggre}_{\text{items}}$ ,常用的一种方式是将与用户  $u_i$

相关的  $X_{ia}$  进行线性加和再平均,如式(3)所示:

$$h_i^I = \sigma\left(W \cdot \left\{ \sum_{a \in C(i)} \frac{1}{|C(i)|} X_{ia} \right\} + b\right) \quad (3)$$

此方法认为用户交互过的每一个项目对用户表征的学习贡献是均等的,而且没有考虑用户与项目交互的时序信息对贡献程度的影响。现实中,用户在一天内交互过项目1和项目2,但是对项目1的评分是5,对项目2的评分是1,显然用户不喜欢项目2,由此可知项目2对用户表征的学习贡献很小,项目1则相反。另外,由于用户在与项目交互时是和时间相关的,用户的喜好也会随着时间发生变化,因此时序信息对学习用户的潜在表征具有重要的作用。

为了能够考虑时序信息,本文的聚合函数  $\text{Aggre}_{\text{items}}$  引入了门控递归单元 GRU 模型。GRU 是一个强大且有效的建模序列特征的工具,已经在自然语言处理领域取得了很大成效。门控递归单元 GRU 被公认是长短期记忆网络(Long Short-Term Memory, LSTM)在门控函数数量上的升级版结构体。在功能上二者都能够弥补循环神经网络的长期依赖不足,但在 GRU 模型中只有两个门函数:分别是更新门和重置门。这也是本文选择用 GRU 来建模时序特征的原因之一。GRU 的关键符号及定义如表4所列。

表4 循环递归单元符号及定义

Table 4 Notation and definition of recurrent unit

| 符号              | 定义及描述        |
|-----------------|--------------|
| $Z_t$           | 更新门          |
| $r_t$           | 重置门          |
| $h_t'$          | 当前记忆内容       |
| $h_t$           | 输出隐藏状态       |
| $w_z, w_r, w_h$ | 需要学习的参数      |
| $\sigma(\cdot)$ | sigmoid 激活函数 |
| $\circ$         | 哈达玛积         |
| $\tanh(\cdot)$  | 双曲正切激活函数     |

GRU 模块在每一个时间步的计算式如式(4)所示:

$$\begin{aligned} Z_t &= \sigma(W_z[X_{ia}, h_{t-1}]) \\ r_t &= \sigma(W_r[X_{ia}, h_{t-1}]) \\ h_t' &= \tanh(W_h[X_{ia}, r_t \circ h_{t-1}]) \\ h_t &= Z_t \circ h_{t-1} + (1 - Z_t) \circ h_t' \end{aligned} \quad (4)$$

本文将进一步介绍 GRU 中关键的更新门  $Z_t$  和重置门  $r_t$

的作用。在序列建模的过程中,  $\mathbf{Z}_t$  由于整合了 LSTM 中的遗忘门和输入门, 因此可以决定要将上一步  $h_{t-1}$  中的哪些信息丢弃以及在当前记忆内容  $h_t$  中哪些新信息需要被添加。如果  $\mathbf{Z}_t$  接近于 1, 那么  $1 - \mathbf{Z}_t$  将接近于 0, GRU 将忽略大部分当前记忆内容中的相关信息, 对上一步的信息保持主要的关注度。重置门  $r_t$  的作用是决定选择遗忘多少之前的信息, 具体来说, 是通过乘以  $h_{t-1}$  来确定要遗忘多少先前步骤中以往的信息, 如果  $r_t$  接近 0, GRU 将忽略过去的信息, 只关注当前的输入  $\mathbf{X}_{it}$ 。因为用户交互过的项目不止一个, 所以文中将目标用户相关的所有表征作为 GRU 的输入, 然后可以得到一个用户表征  $h_t$ , 这个表征里包含用户与项目交互的意见信息和时序信息, 如式(5)所示:

$$h_t = \text{GRU}(\{\mathbf{X}_{ia}, \forall a \in C(i)\}) \quad (5)$$

进一步可以得到新的  $h_t^l$ , 如式(6)所示:

$$\begin{aligned} h_t^l &= \sigma(\mathbf{W} \cdot h_t + b) \\ &= \sigma(\mathbf{W} \cdot \{\text{GRU}(\{\mathbf{X}_{ia}, \forall a \in C(i)\})\} + b) \end{aligned} \quad (6)$$

为了能够融合高阶信息, 即目标用户的隐式朋友关系, 本文还提出了一种新颖的方式以得到目标用户涉及的项目表征  $q_a$ , 用新的定义符号  $\text{New}q_a$  表示。高阶信息的建立过程如图 2 所示。




图 2 高阶特征构建模型

Fig. 2 High-order features building model

本文将目标用户交互过的所有项目的嵌入作为 GRU 的输入之一, 但是该项目嵌入代表的是项目的原始特征, 如 ID 和属性等。在图 2 所示的高阶特征建模单元中, 对于目标用户交互过的每个项目的项目嵌入都包含两部分信息, 一部分是项目的原始嵌入阵, 另一部分是交互过该项目的所有用户嵌入融合的结果, 然后将其馈入到多层感知机  $g_u$ 。值得注意的是, 本文在进行高阶特征建模时, 依然利用 GRU 结合用户和项目交互的时序信息。获取嵌入高阶特征的项目表征  $\text{New}q_a$  表达式如式(7)所示:

$$\text{New}q_a = q_a \oplus \text{GRU}(g_u(p_i \oplus e_{ia}), \forall i \in B(a)) \quad (7)$$

获取用户与对项目的观点交互表示  $\mathbf{X}_{ia}$  表达式如式(8)所示:

$$\mathbf{X}_{ia} = \mathbf{g}_v([\text{New}q_a \oplus e_r]) \quad (8)$$

以上内容讲述了如何将时序信息和高阶特征信息这一协同信号聚合在基于项目的用户潜在表征中。

### 2.3.2 基于社交关系的用户潜在表征建模

通过社会相关理论可以证明, 用户的偏好更可能与那些和用户处于同一社交网络中的朋友的偏好相似, 因此在学习用户潜在表征时包含社交信息很有必要。然而, 用户之间联系的强度是不同的, 在学习基于社交关系的用户潜在表征时

应当考虑社交关系的异构优势。因此, 本文采用 DSCF<sup>[46]</sup> 中的注意力机制, 对目标用户不同强度关系的社交朋友赋予不同的权重, 选出贡献值较大朋友来表征目标用户的社交信息。

为了获得用户在社交域上的潜在表征  $h_i^s$ , 本文从社交图中利用目标用户的显式朋友在项目域上的潜在表征, 式(9)所示:

$$h_i^s = \sigma(\mathbf{W} \cdot \text{Aggre}_{\text{friends}}(\{h_o^l, \forall o \in F(i)\}) + b) \quad (9)$$

此方法认为所有的显式朋友对目标用户的表征具有相同的贡献, 未挖掘社交图中联系强弱对贡献值的影响。因此, 本文采用了两层神经网络的注意力机制, 通过注意力值  $\beta_{io}^*$  与目标用户嵌入  $p_i$  和显式朋友  $h_o^l$  相关联, 从而捕获对目标用户产生重要影响的用户, 进而对他们之间的关系强度进行建模, 如式(10)一式(12)所示:

$$h_i^s = \sigma(\mathbf{W} \cdot \{\sum_{o \in F(i)} \beta_{io}^* h_o^l\} + b) \quad (10)$$

$$\beta_{io} = \frac{\exp(\beta_{io}^*)}{\sum_{o \in F(i)} \exp(\beta_{io}^*)} \quad (11)$$

$$\beta_{io}^* = \mathbf{W}_2^T \cdot \sigma(\mathbf{W}_1 \cdot h_o^l \oplus p_i + b_1) + b_2 \quad (12)$$

其中,  $\beta_{io}^*$  用于捕获目标用户与显式朋友之间联系的强度。

### 2.3.3 综合性用户潜在表征学习

综合性用户潜在表征学习是为了学习到更好的用户潜在表征, 本文将基于项目的用户表征  $h_t^l$  与基于社交关系的用户表征  $h_i^s$  相结合, 获得最终的用户潜在表征  $h_i$ , 然后将最终的用户潜在表征输入到多层感知机中。用户潜在表征的最终定义如式(13)所示:

$$\begin{aligned} c_1 &= h_t^l \oplus h_i^s \\ c_1 &= \sigma(\mathbf{W}_2 \cdot c_1 + b_2) \\ &\dots \\ h_i &= \sigma(\mathbf{W}_l \cdot c_{l-1} + b_l) \end{aligned} \quad (13)$$

其中,  $l$  是隐藏层的层号。

### 2.4 项目表征建模过程

项目表征建模部分用于学习项目的潜在表征  $z_j$ 。由于项目只存在于交互图中, 因此本文对每个项目  $v_j$  进行用户聚合, 即基于用户的项目表征建模。鉴于项目的特征并不会像用户偏好一样随着时间的变化而变化, 因此只考虑捕获交互和观点进行学习项目潜在表征。对于每一个项目  $v_j$ , 采用聚合交互过项目  $v_j$  的用户及其评分来学习项目的潜在表征。因为多个用户对同一个项目的评分不一定一致, 这种有区别的分值可以有效反映用户兴趣的多样性。而这些来自不同用户的意见有助于捕捉到同一项目的特点, 进而对项目潜在表征进行建模。对于  $u_i$  与  $v_j$  交互且评分是  $r$  这一交互过程, 本文引入一个  $f_{ji}$  作为意见交互过程的表示, 如式(14)所示:

$$f_{ji} = \mathbf{g}_u([p_i \oplus e_r]) \quad (14)$$

上式中包含原始的用户嵌入  $p_i$  以及观点嵌入  $e_r$ 。首先将二者进行连接, 其次将融合结果输入多层感知机中, 定义为  $g_u$ , 用来聚合带有意见信息的交互信息。然后, 通过聚合交互过项目  $v_j$  的所有用户及其意见表征结果  $f_{ji}$  来学习项目的潜在表征  $z_j$ 。用户聚合函数定义为  $\text{Aggre}_{\text{users}}$ , 在项目-用户交互图中,  $\text{Aggre}_{\text{users}}$  用来聚合交互过某一项目的所有用户的意见表示。所以某一项目的潜表征如式(15)所示:

$$\mathbf{Z}_j = \sigma(\mathbf{W} \cdot \text{Aggre}_{\text{users}}(\{f_{ji}, \forall i \in B(j)\}) + b) \quad (15)$$

对于聚合函数  $\text{Aggre}_{\text{users}}$ , 常用的一种方式是将与项目  $v_j$



相关的  $f_{ji}$  进行线性加和再平均。如式(16)所示:

$$\mathbf{Z}_j = \sigma \left( \mathbf{W} \cdot \left\{ \sum_{\forall i \in B(j)} \frac{1}{|B(j)|} f_{ji} \right\} + \mathbf{b} \right) \quad (16)$$

上述方法认为所有交互过项目  $v_j$  的全部用户的评分对于该项目的表示具有相同的贡献。但是在现实生活中,通常会在无效的评分。例如,用户购买完某一个商品之后,并不会对商品进行评分,在数据处理过程中,这类型的空值会被填充为0。显然,这样的评分对于项目潜在表征的贡献几乎没有,可以看出不同用户的意见交互表示  $f_{ji}$  对于项目的潜在表征学习贡献不同。为了区分每个用户的意见交互权重  $\mu_{ji}$ , 论文依然采用两层神经网络的注意力机制,将  $f_{ji}$  和项目嵌入表示  $q_j$  作为输入,以捕获不同用户的意见交互表示对于项目表征的不同影响,如式(17)一式(19)所示:

$$\mathbf{Z}_j = \sigma(\mathbf{W} \cdot \{ \sum_{\forall i \in B(j)} \mu_{ji} f_{ji} \} + \mathbf{b}) \quad (17)$$

$$\mu_{ji} = \frac{\exp(\mu_{ji}^*)}{\sum_{\forall i \in B(j)} \exp(\mu_{ji}^*)} \quad (18)$$

$$\mu_{ji}^* = \mathbf{w}_2^T \cdot \sigma(\mathbf{W}_1 \cdot [f_{ji} \oplus q_j] + \mathbf{b}_1) + \mathbf{b}_2 \quad (19)$$

其中,  $\mu_{ji}$  用于捕获用户-项目交互对项目潜在表征学习的不同的影响。

本文中的用户表征建模分为基于项目的表征建模和基于社交关系的表征建模。受此启发,本文还考虑为项目构建一个社交网络,完成基于社交关系的项目表示建模。建模的主要思想是:针对两个不同的项目(项目1和项目2),判断与这两个项目交互的用户数量是否达到一定的阈值或在阈值以上,若是,则为目标项目建立数量型项目社交网络。另一种尝试是判断与两个项目有过交互的公众用户比例是否在一定阈值以上,若是,则认为这两个项目具有一定的相似性,可以为这两个项目建立比例型社交网络。这两种方式也可以理解为目标项目的显式朋友关系。具体的建模过程将在不同项目特征建模方法对结果的影响的实验中详细介绍。

#### 2.4.1 构建项目社交关系

数量型项目社交网络(Number Item Social, NIS)构建方式如图3所示。这一构建方式首先将项目集合中的每个项目按照交互用户数量大于或等于阈值  $N$  进行过滤。交互用户数量小于阈值的项目则只进行基于用户的项目表征建模,不进行社交关系的项目表征建模。在过滤后的项目集合中,选择目标项目  $V_i$ , 然后寻找目标项目  $V_i$  与其他项目  $V_m$  的公共交互用户,若公共交互用户的数量大于或等于阈值,则将  $V_m$  视为  $V_i$  的邻居之一。在整个社交网络的构建过程中,每个项目都会被当做一次目标项目且阈值  $N=5$ , 来构建所有项目的社交网络,以此进行基于社交关系的项目表征建模。




图3 NIS项目社交网络的构建方式

Fig. 3 Building way of NIS item social network

比例型项目社交网络(Proportion Item Social, PIS)构建

方式如图4所示。这一方式是先在项目集合  $V$  中选取目标项目,其次寻找目标项目与其他项目  $V_m$  的公共交互用户,获取公共用户数量,如式(22)所示:

$$P(v_i, v_r) = \frac{|N(i) \cap N(t)|}{|N(t)|} \quad (20)$$

其中,  $|N(t)|$  表示目标项目  $v_i$  的交互用户的总数,  $|N(i) \cap N(t)|$  表示项目  $v_i$  与目标项目  $v_r$  的公共交互用户的数量,  $P(v_i, v_r)$  表示项目  $v_i$  与目标项目  $v_r$  的公共交互用户占比。若  $P(v_i, v_r)$  的值大于或等于阈值,则将  $v_i$  加入目标项目  $v_r$  的社交网络中,作为其邻域之一。在项目集  $V$  中,所有的项目都会被当做一次目标项目且阈值  $N=60\%$ , 获取其社交邻域集合。




图4 PIS项目社交网络的构建方式

Fig. 4 Building way of PIS item social network

#### 2.4.2 建模项目表征

对于项目特征建模,本文考虑构建项目的社交网络,将项目建模过程分别进行基于用户的表征建模和基于社交关系的表征建模。文中采用  $z_j^U$  表示基于用户的项目潜在表征建模,如图5所示。项目建模主要分为两个模块,一个是基于用户的项目表征建模,另一个是基于社交网络的项目表征建模。由于基于用户的项目表征建模过程在第3.4节中已有介绍,因此这一小节将重点介绍基于社交网络的项目表征  $z_j^S$  的建模过程。




图5 项目表征建模整体框架

Fig. 5 Overall framework for project representation modelling

为了获得项目在社交网络的潜在表征  $z_j^S$ , 本文从社交图中融合目标项目的邻域基于用户上的潜在表征,如式(21)所示:

$$\mathbf{z}_j^S = \sigma(\mathbf{W} \cdot \text{Aggre}_{\text{friends}}(\{z_o^U, \forall o \in F(j)\}) + \mathbf{b}) \quad (21)$$

其中,  $F(j)$  表示一个集合,该集合是目标项目的邻域集合;  $\text{Aggre}_{\text{friends}}$  定义为目标项目邻域的聚合函数,论文采用两层神经网络的注意力机制,通过注意力值  $a_o$  与目标项目嵌入  $q_j$  和邻域表示  $z_o^U$  相关联,从而捕获对目标项目产生重要影响的



项目,进一步对它们之间的关系强度进行建模。如式(22)一式(24)所示:

$$\mathbf{z}_j^S = \sigma(\mathbf{W} \cdot \{ \sum_{o \in F(j)} \alpha_{io} \mathbf{z}_o^U \} + \mathbf{b}) \quad (22)$$

$$\alpha_{io} = \frac{\exp(\alpha_{io}^*)}{\sum_{o \in F(j)} \exp(\alpha_{io}^*)} \quad (23)$$

$$\alpha_{io}^* = \mathbf{w}_2^T \cdot \sigma(\mathbf{W}_1 \cdot [\mathbf{z}_o^U \oplus \mathbf{q}_j] + \mathbf{b}_1) + \mathbf{b}_2 \quad (24)$$

其中,  $\alpha_{io}$  表示目标项目和其邻域之间的关系强度。

本文将基于用户的项目表征  $\mathbf{Z}_o^U$  和基于社交关系的项目表征  $\mathbf{z}_j^S$  进行结合, 获取到最终的项目潜在表征  $\mathbf{z}_j^I$ , 然后将最终的项目潜在表征输入到多层感知机中, 项目潜在表征定义如式(25)所示:

$$\begin{aligned} \mathbf{c}_1 &= [\mathbf{z}_j^U \oplus \mathbf{z}_j^S] \\ \mathbf{c}_2 &= \sigma(\mathbf{W}_2 \cdot \mathbf{c}_1 + \mathbf{b}_2) \\ &\dots \\ \mathbf{z}_j &= \sigma(\mathbf{W}_l \cdot \mathbf{c}_{l-1} + \mathbf{b}_l) \end{aligned} \quad (25)$$

其中,  $l$  是隐藏层的层号。

## 2.5 评分预测过程

在实际生活中, 由于人们的需求不同, 推荐的主要任务也不相同。本文建议将提出的高阶时序图神经网络社会化推荐模型应用在评级预测的推荐任务上。如图 1 的评分预测所示, 首先将用户潜在表征  $\mathbf{h}_i$  和项目潜在表征  $\mathbf{z}_j$  串联, 然后再馈入多层感知机进行评级预测。详细过程如式(26)所示:

$$\begin{aligned} \mathbf{g}_1 &= [\mathbf{h}_i \oplus \mathbf{z}_j] \\ \mathbf{g}_2 &= \sigma(\mathbf{W}_2 \cdot \mathbf{g}_1 + \mathbf{b}_2) \\ &\dots \\ \mathbf{g}_{l-1} &= \sigma(\mathbf{W}_l \cdot \mathbf{g}_{l-1} + \mathbf{b}_l) \\ r'_{ij} &= \mathbf{W}^T \cdot \mathbf{g}_{l-1} \end{aligned} \quad (26)$$

其中,  $\mathbf{g}_l$  是第  $l$  层潜在表征表示,  $r'_{ij}$  是用户  $u_i$  对项目  $v_j$  的评分预测值。

## 2.6 模型训练

本文采用通过优化损失函数的值以达到训练过程中评估参数的目的。由于本文在这项工作中重点关注的任务是评级预测, 因此选择的损失函数如式(27)所示:

$$Loss = \frac{1}{2|O|} \sum_{i,j \in O} (r'_{ij} - r_{ij})^2 \quad (27)$$

其中,  $O$  代表所有观察到的用户-项目交互记录,  $|O|$  表示观察到的评分的数量,  $r'_{ij}$  和  $r_{ij}$  分别是用户  $u_i$  对项目  $v_j$  评分的预测值和真实值。本文将针对高阶时序图神经网络社会化推荐模型的处理方法进行介绍, 这些处理方法对提高模型训练效率和性能有着非常重要的影响, 决定着模型是否具有应用于工程实践的可能。

### (1) 预处理方法

根据模型建模过程的介绍和理论分析, 本文的模型中有 3 种随机初始化的嵌入, 包括项目嵌  $\mathbf{q}_j$ , 用户嵌入  $\mathbf{p}_i$  和评分嵌入  $\mathbf{e}_r$ , 它们在训练过程中共同学习。随着数据量的大幅增加, 原始数据呈现出稀疏且维度大的特点, 而独热编码已经不能满足对用户及项目的特征进行充分完整表示的需求。为了使表示出的特征信息更加完善, 本文将高维稀疏特征表示成一个低维稠密的向量, 这样可以更加轻松地训练模型。评分

嵌入矩阵取决于系统的等级量表, 如果评分矩阵中的用户对项目的评分存在缺失项, 将用 0 来填充。

### (2) 优化损失函数

第二个处理方法是优化损失函数。本文采用的是 GraphRec<sup>[42]</sup> 中的均方根反向传播 (Root Mean Square propagation, RMSprop)。RMSprop 是自适应梯度算法 AdaGrad 的改进算法, 同时也是自适应学习率调整 Adadelata 的一个特例。Adagrad 的主要特点在于不断累加每次训练中梯度的平方, 具体计算方法如式(28)所示:

$$\theta = \theta - \frac{\eta}{\sqrt{\epsilon + \sum_t g_t^2}} g_t \quad (28)$$

其中,  $g_t$  是模型在  $t$  时刻的梯度, 文中将其设为一个极小的正数, 然后将  $\sum_t g_t^2$  和相加, 以防分母为 0。在训练过程中, 随着梯度的累加, 学习率会越来越小。这种优化器的优点在于可以自动调节参数的学习率, 缺点是学习率下降较快, 很大程度上会造成学习提前结束。Adadelata 是在 Adagrad 的基础上做了轻微的修改, 其特点是比 Adagrad 更加稳定。Adadelata 的计算方法如式(29)、式(30)所示:

$$\theta = \theta - \frac{\eta}{\sqrt{\epsilon + E[g^2]_t}} g_t \quad (29)$$

$$E[g^2]_t = \beta E[g^2]_{t-1} + (1-\beta) g_{t-1}^2 \quad (30)$$

Adadelata 和 Adagrad 的区别在于式(28)中  $\sum_t g_t^2$  被前  $t$  个  $g_t$  的期望  $E[g^2]_t$  代替。这样做的好处是可以使学习率的下降速度变慢。当参数  $\beta = 0.5$  时,  $E[g^2]_t$  就变成梯度平方和的平均数, 然后再进行开根号, 这样就可以获取到梯度均方根 RMS, 如式(31)所示:

$$RMS[g]_t = \sqrt{E[g^2]_t + \epsilon} \quad (31)$$

因此 RMSprop 中更新参数的方法如式(32)所示:

$$\theta = \theta - \frac{\eta}{RMS[g]_t} g_t \quad (32)$$

### (3) 缓解过拟合问题

此外, 过拟合是深度神经网络中长期存在的问题。出现过拟合问题的原因可能是训练数据太少, 当模型在训练集上表现出的性能太优时, 不排除会出现过拟合的现象。因此在模型训练之前, 采取一定的方式缓解过拟合问题是有必要的。缓解过拟合, 常见的处理方法有在损失函数中加入正则项、当验证集效果变差时提前终止和采用 Dropout 策略随机将一部分神经元丢弃。本文经过不同方式的实验后, 发现 Dropout 策略<sup>[39]</sup>实验效果最好, 因此最终采用 Dropout 策略来缓解过拟合问题。

模型训练的过程如算法 1 所示。

### 算法 1 高阶时序图神经网络社会化推荐模型训练过程

输入: 数据集  $O: \{U, V, R, T\}$ , 权重  $w$ , 偏置值  $b$ , 学习率  $\eta$  等

输出: 用户  $u_i$  对项目  $v_j$  的评分  $r'_{ij}$ ,  $u_i \in U, v_j \in V$

1. 利用数据集得到  $H: U_v, U_r, V_u, V_r, S: U_s$
2. 随机初始化网络参数
3. while 训练轮数未达到 do
4. while 一轮训练没有结束 do
5. 随机抽取  $N$  条训练数据  $\{u_{v_i}, u_{r_i}, v_{u_i}, v_{r_i}\} \in H, \{u_{s_i}\} \in S$
6. 用用户建模得到用户表征向量  $\mathbf{h}_i$
7. 利用项目建模得到项目表征向量  $\mathbf{z}_j$

- 8.通过评分模型得到评分预测值  $r'_{ij} = \text{Rating}(h_i, z_j)$
- 9.计算损失函数  $\text{Loss}: L = \frac{1}{2|O|} \sum_{i,j \in o} (r'_{ij} - r_{ij})^2$
- 10.利用 RMSprop 更新网络参数
- 11.end while
- 12.end while

### 3 实验与分析

本节将介绍高阶时序图神经网络社会化推荐模型的实验并进行结果对比分析。首先介绍本文模型实验中使用的数据集,其次介绍实验环境、模型的评价指标以及参数设置。本文对比分析了 HTGSR 框架和其他几种不同类型的算法框架的区别。为了进一步验证模型的两个创新点都是有效的,在 Ciao 数据集和 Epinions 数据集上都进行了消融实验,分析每个模块对模型性能的影响。然后进一步探究不同时间特征建模方式的适用性和不同项目特征建模方式对模型性能的影响。最后将对实验参数嵌入维度对模型性能的影响进行分析阐述。

#### 3.1 实验数据集

本文采用两个具有代表性且公开的数据集 Ciao 数据集和 Epinions 数据集来验证所提模型的有效性。两个数据集的用户数、项目数等详细数据如表 5 所列。这两个数据集均在网站<sup>1)</sup>上可以获取到。这两个公开的数据集按照不同的科研需求分为不同的文件类型。下面将分别详细介绍两个数据集的相关信息。

表 5 数据集的详细信息

Table 5 Detailed information of dataset

| 数据集      | Ciao    | Epinions |
|----------|---------|----------|
| 用户数量     | 7 317   | 18 088   |
| 项目数量     | 104 975 | 261 649  |
| 评分数量     | 283 319 | 764 352  |
| 评分密度/%   | 0.036 8 | 0.016 1  |
| 社交关系数量   | 111 781 | 355 813  |
| 社交关系密度/% | 0.208 7 | 0.108 7  |

(1)Ciao 数据集。该数据集来自一个比较受欢迎的产品评论网站<sup>2)</sup>,在该网站上可以记录用户的账户详细信息和个人偏好,例如允许用户对交互过的商品进行评分,浏览或者书写评论,还可以通过社交媒体分享感兴趣的商品以及允许用户将某个人添加到自己的社交圈等。获取到的数据集中主要包含两个文件:rating.mat 和 trustnetwork.mat,分别表示用户的评分信息和用户的社交信息。rating.mat 中主要包含 6 种属性:userid,productid,categoryid,rating,helpfulness 和 time point,分别表示用户编号、项目编号、项目类别编号、用户对该项目的评分、用户评分的有用性和用户创建评分的时间点。trustnetwork.mat 中主要包含两个用户之间的关系,分为两个属性:用户编号及其好友编号。数据显示用户之间的关系是单向的,例如(1,2)仅代表用户 1 信任用户 2,并不是用户 1 和用户 2 相互信任。此数据集中包含 7 317 个用户,104 975 个项目,283 319 个评分记录,,用户社交连接数量达到 111 781 个。另外,一个用户至少交互过 1 个项目,至多

交互过 1 256 个。而一个项目至少被 1 个,至多被 779 个用户交互过;一个用户至少有 1 个,至多有 804 个邻居。

(2)Epinions 数据集。该数据集来源于一个非常流行的电商平台<sup>3)</sup>,该网站上的项目分类齐全,用户可以选择自己感兴趣的项目进行交互,并对其进行评分或者书写评论等。获取到的数据集由两个.mat 文件组成。rating.mat 中主要包含 6 种属性:用户编号、项目编号、项目类别编号、用户对该项目的评分、用户评分的有用性和用户创建评分的时间点。trust-network.mat 中主要包含两个用户之间的关系,分为两个属性:用户编号及其好友编号。这个数据集包含 18 088 个用户,261 649 个项目,764 352 条评分记录。此外,本数据集还包含用户之间的信任关系,共有 355 813 个用户信任对。

#### 3.2 实验设置

##### 3.2.1 实验环境

本文提出的 HTGSR 模型的实验环境主要是基于实验室服务器,其 CPU 类型为 Intel Xeon Gold 5218,图形处理器是 V100,内存 100 GB。模型使用的深度学习框架是 PyTorch,PyTorch 是一个具备灵活性的深度学习开发平台。采用 Ubuntu18.04 的操作系统,编译环境为 Python3.6。

##### 3.2.2 评价指标

本文采用平均绝对误差和均方根误差这两个常用的指标来评估推荐模型的质量<sup>[41]</sup>。平均绝对误差(Mean Absolute Error,MAE)表示观测值与真实值误差绝对值的平均值,均方根误差(Root Mean Squard Error,RMSE)是对预测值与真实值误差的平方和与预测次数比值开平方。两个指标的计算分别如式(33)和式(34)所示:

$$MAE = \frac{1}{|T|} \sum_{(i,j) \in T} |r'_{ij} - r_{ij}|$$

(33)

$$RMSE = \sqrt{\frac{1}{|T|} \sum_{(i,j) \in T} (r_{ij} - r'_{ij})^2}$$

(34)

其中, $T$ 表示待测评分的集合, $r_{ij}$ 和 $r'_{ij}$ 分别代表 $u_i$ 对 $v_j$ 的真实评分和预测分值。通常 RMSE 的值比 MAE 的值大一些。分析可知,RMSE 值的计算分为 3 步:计算误差平方、累加、开方。如果把真实值和预测值比作两个定点,那么它们差值的平方就代表距离的平方,经过累加之后这个值越来越大,无形之间将两个点的差值逐渐拉大。而 MAE 始终代表真实误差,因此 RMSE 的值一般比 MAE 的值大。在评估模型性能时 MAE 和 RMSE 的值越小越好,即便这两个指标降低的幅度较小,也有可能给推荐的性能带来较大的提升。

##### 3.2.3 参数设置

本文引用 GraphRec<sup>[42]</sup>的划分方式对每个数据集进行了不同比例的划分,如表 6 所列。

表 6 数据集的划分比例

Table 6 Proportion of dataset partition

(单位:%)

| 划分  | 比例 1 | 比例 2 |
|-----|------|------|
| 训练集 | 60   | 80   |
| 测试集 | 20   | 10   |
| 验证集 | 20   | 10   |

<sup>1)</sup> <https://www.cse.msu.edu/tangjili/datasetcode/truststudy.htm>

<sup>2)</sup> <http://www.ciao.co.uk>

<sup>3)</sup> [www.epinions.com](http://www.epinions.com)

本文采用 ReLU 作为激活函数,原因在于,ReLU 可以很好地改善梯度爆炸和梯度消失问题,并且可以帮助研究人员节省神经网络的计算成本。在实验过程中,采用控制变量的方法,找到重要参数最合适的取值。在高阶时序图神经网络社会化推荐算法模型中,有 3 个重要的参数:学习率、批次大小和嵌入维度。这样考虑是因为学习率过大和过小都会导致实验效果无法达到最佳,按照正态分布的思想,学习率过大和过小都会使其远离最优解。文中学习率在 $[0.0005, 0.001, 0.005, 0.01, 0.05, 0.1]$ 之间调整,批次大小则在 $[8, 16, 32, 64, 128, 256]$ 之间调整,嵌入维度在 $[16, 32, 64, 128]$ 之间调整。这样设置的原因在于,如果嵌入维度较小,那么就不能保证能包含丰富的信息;相反,如果嵌入维度较大,就意味着计算过程会增加一定的复杂度,导致模型训练时间延长。在模型进行训练之前,必不可少的步骤是参数初始化。本文选择高斯分布进行参数初始化,基线算法的参数均以原论文值作为初始值,在经过了一定次数的调参实验后,本文模型在学习率为 0.01,批次大小为 64,嵌入维度为 64 时取得最佳效果。

3.2.4 对比模型

将本文提出的模型与 4 种具有代表性的基线模型进行比较。

(1)PMF<sup>[43]</sup>模型主要利用两个更低秩的用户和电影矩阵的乘积对用户偏好矩阵建模,并以高斯分布方法建模用户及项目的表征。但是该模型仅利用了用户项目评级矩阵,欠缺社交信息的利用。

(2)SoRec<sup>[29]</sup>以用户为桥梁连接交互图和社交图中的数据信息,其在 PMF 的基础上进行了改进升级,将矩阵分解技术用于用户和项目的潜在因子特征分析上,学习了低阶用户潜在特征空间和项目潜在特征空间,提出了社会化建议。此模型的优点是综合使用了用户的社交网络信息和评价信息,并对这两个矩阵进行了因子分解。

(3)SocialMF<sup>[44]</sup>模型在矩阵分解中结合了信任传播机制,探讨了一种在社交网络中以模型为基础的推荐方法。该模型使每个用户的特征依赖于它在社交网络中的直接邻居的特征向量,利用这一思想,间接连接到社交网络中的用户的潜在特征将是依赖性的,从而实现传播信任。

(4)TrustMF<sup>[31]</sup>是基于模型的方法。该方法充分利用了矩阵分解技术,根据信任关系的方向性,将用户映射为信任者

特征向量和被信任者特征向量,分别表示用户的“信任他人”和“被他人信任”行为,该模型推荐效果的提升证实了社交关系的方向性可能会对推荐的准确性产生一定的影响。

(5)NeuMF<sup>[36]</sup>模型是一种基于神经网络的协同过滤方法。此方法利用深度神经网络来模拟用户和项目的潜在表征,是目前比较先进的矩阵分解框架,可以很好地表达和推广矩阵分解。

(6)DeepSoR<sup>[45]</sup>是基于深度神经网络的方法。该方法从社会关系中学习每个用户的非线性特征,并将其集成到概率矩阵分解中完成评级预测。

(7)DSCF<sup>[46]</sup>提出了一种深层的社交协同过滤框架,利用深度神经网络原理,从遥远的社会关系中提取有用的信息用于推荐。

(8)GCMC+SN<sup>[47]</sup>在一个图卷积矩阵补全框架(GCMC)的基础上融入了社交信息,且进行了高维稀疏数据的低维稠密化处理,此方法是目前比较先进的基于 GNNs 的社会化推荐模型。

(9)GraphRec<sup>[42]</sup>是一种基于图神经网络的社会化推荐框架。该框架将用户-项目交互图中的信息以及用户对项目的评分信息进行同步捕获,然后聚合目标用户的显式朋友关系信息,是目前图神经网络社会化推荐中比较先进的技术。

本文在 4 种不同的推荐算法中选取典型的模型作为基线模型进行对比,这 4 种推荐算法的分类及信息利用如表 7 所列。

表 7 基线算法的类型划分  
Table 7 Typology of baseline algorithms

| 类型              | 算法                       | 信息利用              |
|-----------------|--------------------------|-------------------|
| 传统的推荐算法         | PMF                      | 用户-项目评分矩阵         |
| 传统的社交推荐算法       | SoRec, SocialMF, TrustMF | 用户-项目评分矩阵、用户信任关系  |
| 基于 DNNs 的社交推荐算法 | NeuMF, DSCF, DeepSoR     | 用户-项目评分矩阵、用户信任关系  |
| 基于 GNNs 的社交推荐算法 | GCMC+SN, GraphRec        | 用户-项目评分矩阵、用户社交网络图 |

3.3 与基线模型对比及结果分析

本文将分别介绍所提模型在两个公开的数据集 Ciao 和 Epinions 上的实验效果,并与上文阐述的各类基线模型进行比较,充分证明本文提出的高阶时序图神经网络社会化推荐模型中创新点的有效性。实验对比结果如表 8 所列。

表 8 HTGSR 与基线模型的对比  
Table 8 Comparison of baseline models with HTGSR

| methods  | Ciao(60%) |       | Ciao(80%) |       | Epinions(60%) |       | Epinions(80%) |       |
|----------|-----------|-------|-----------|-------|---------------|-------|---------------|-------|
|          | MAE       | RMSE  | MAE       | RMSE  | MAE           | RMSE  | MAE           | RMSE  |
| PMF      | 0.952     | 1.197 | 0.902     | 1.124 | 1.021         | 1.274 | 0.995         | 1.213 |
| SoRec    | 0.849     | 1.074 | 0.841     | 1.065 | 0.909         | 1.156 | 0.896         | 1.144 |
| SocialMF | 0.835     | 1.059 | 0.827     | 1.050 | 0.897         | 1.141 | 0.884         | 1.133 |
| TrustMF  | 0.768     | 1.054 | 0.769     | 1.048 | 0.855         | 1.151 | 0.841         | 1.134 |
| NeuMF    | 0.825     | 1.082 | 0.806     | 1.062 | 0.910         | 1.165 | 0.907         | 1.148 |
| DeepSoR  | 0.781     | 1.044 | 0.774     | 1.032 | 0.852         | 1.114 | 0.838         | 1.097 |
| DSCF     | 0.750     | 1.016 | 0.734     | 0.990 | 0.843         | 1.100 | 0.829         | 1.072 |
| GCMC+SN  | 0.770     | 1.022 | 0.753     | 0.993 | 0.860         | 1.100 | 0.859         | 1.071 |
| GraphRec | 0.752     | 1.019 | 0.739     | 0.995 | 0.856         | 1.095 | 0.829         | 1.089 |
| HTGSR    | 0.739     | 0.995 | 0.730     | 0.984 | 0.825         | 1.068 | 0.821         | 1.069 |

本文在平均绝对误差 MAE 和均方根误差 RMSE 这两个指标上,进一步对数据集进行了不同比例的划分,使模型的



实验结果更具有说服力。需要说明的是,本文模型所使用的两个评价指标的值越小,模型的推荐效果越好。经过以上模型性能的比较分析得知:

(1)SoRec,SocialMF,TrustMF 和 PMF 均以矩阵分解技术为主,但是 PMF 的性能不如其他三者。这是因为 PMF 只利用了用户-项目交互中的评级信息,而 SoRec,SocialMF 和 TrustMF 不仅利用了用户对项目评级信息,还利用了用户之间的社交网络信息,说明社交信息有利于提升推荐的性能。

(2)NeuMF 和 PMF 都只利用了评级信息,但是 NeuMF 的性能却优于 PMF,这是因为 PMF 并不是基于神经网络结构的方法,这也验证了神经网络对推荐性能的强大作用。

(3)除了 PMF,其余基线方法都利用了用户的评级信息和社交信息,基于矩阵分解技术的方法明显不如基于神经网络结构的方法,这些提升进一步证明了神经网络模型对推荐性能的贡献非常大。另外,DSCF 大部分指标的值都低于 GraphRec 和 GCMC+SN,其性能更优是因为 DSCF 在使用社交信息时加入了用户遥远关系中的用户朋友信息。这也说明了在社会化推荐中,辅助信息越丰富,推荐效果就越准确。

(4)在基于图神经网络的社会化推荐方法 GraphRec 和 GCMC+SN 中,性能较好的是 GraphRec,因此我们将 GraphRec 作为本文模型主要的对比模型。由表 8 可知,本文提出的 HTGSR 在性能上均优于 GraphRec。这是因为 HTGSR 不仅利用了用户-项目交互的评级信息、时序信息,还构建了目标用户的高阶传播特征。这个结果不仅说明了时序信息对学习用户潜在表征的重要性,也证实了高阶特征对推荐性能提升的积极影响。

3.4 消融实验

本节主要是针对本文提出的两个创新点进行消融实验并对结果进行分析,通过模型的指标值的变化来判断模块的有效性。为了深入分析 HTGSR 模型中时序信息和用户的高阶特征信息发挥的作用,本文提出了相关的变体。

(1)GraphRec:2019 年在国际推荐系统学术会议 WWW 上提出的基线方法,在学习用户的潜在表征时仅使用了用户的意见信息和社交网络中的显式朋友信息,未进行用户-项目交互时序信息的建模,即未计算用户进行评分的时间。

(2)GraphRec+GRU:在 GraphRec 的基础上,通过 GRU 的作用,将用户与项目交互的时序信息融入到学习用户的潜在表征中,但是这个变体中依然含有注意力机制。

(3)GraphRec+GRU-Att:在基于项目的用户表征建模中将注意力机制移除。这个变体是为了说明门控递归单元 GRU 组件对用户建模产生的积极作用。GRU 在融合用户与项目交互的时序信息时和注意力机制有重叠的影响,均会给予不同的项目不同的权重,因此将注意力机制移除来证明 GRU 的作用。

(4)HTGSR:本文提出的模型。在用户建模过程中,合理地利用了用户与项目交互的时序信息,并采用门控递归单元 GRU 对时序信息进行建模;另外将目标用户的隐式朋友关系建模为用户高阶连通特征,用于最终的评级预测。

本文将上述变体分别在两个数据集上进行消融实验,结果如表 9 所列。

表 9 GraphRec,GraphRec+GRU,GraphRec+GRU-Att 与 HTGSR 的实验结果对比

Table 9 Comparison of experimental results of GraphRec, GraphRec+GRU,GraphRec+GRU-Att and HTGSR

| 训练            | 指标   | 方法       |              |                 | HTGSR  |
|---------------|------|----------|--------------|-----------------|--------|
|               |      | GraphRec | GraphRec+GRU | GraphRecGRU-Att |        |
| Ciao(60%)     | MAE  | 0.7524   | 0.7443       | 0.7420          | 0.7394 |
|               | RMSE | 1.0189   | 1.0123       | 0.9972          | 0.9953 |
| Ciao(80%)     | MAE  | 0.7387   | 0.7339       | 0.7318          | 0.7296 |
|               | RMSE | 0.9954   | 0.9930       | 0.9877          | 0.9844 |
| Epinions(60%) | MAE  | 0.8561   | 0.8409       | 0.8366          | 0.8247 |
|               | RMSE | 1.0948   | 1.0995       | 1.0792          | 1.0677 |
| Epinions(80%) | MAE  | 0.8290   | 0.8251       | 0.8237          | 0.8213 |
|               | RMSE | 1.0889   | 1.0727       | 1.0643          | 1.0692 |

3.4.1 时序模块的有效性

为了说明时序信息的有效性,保持其他参数设置不变,本文将 GraphRec+GRU 的性能与 GraphRec 进行对比。为了验证是门控递归单元 GRU 在基于项目的用户表征建模这一部分发挥了有效性而不是注意力机制的影响,本文将 GraphRec+GRU-Att 与 GraphRec+GRU 进行比较。为了让实验数据更加直观,我们将结果以柱状图的方式呈现,如图 6 和图 7 所示。




图 6 时序信息和门控递归单元 GRU 在 Ciao 数据集上的有效性  
Fig. 6 Validity of timing information and gated recurrent units GRU on Ciao dataset




图 7 时序信息和门控递归单元 GRU 在 Epinions 数据集上的有效性  
Fig. 7 Validity of timing information and gated recurrent units GRU on Epinions dataset

由图 6 可知,在 Ciao 数据集上 GraphRec+GRU 的 MAE 和 RMSE 都呈现出下降的趋势。与 GraphRec 相比,GraphRec+GRU 的 MAE 和 RMSE 平均下降了 0.87% 和 0.45%。由图 7(a)可知,在 Epinions 数据集上,GraphRec+GRU 变体的 MAE 值呈现逐个下降的趋势,说明了 GRU 模块对模型的积极作用。由图 7(b)可知,在 Epinions(60%)上,GraphRec+GRU 的 RMSE 值虽然不如 GraphRec,但是在去掉基于项目域的用户表征建模过程中的注意力机制后,GraphRec+GRU-Att 的性能明显优于 GraphRec 模型,因此我们

猜测出现这个结果是 GRU 和注意力机制的叠加作用为负导致的。从图 7 来看,在 Epinions(80%)上 GraphRec+GRU 的 MAE 和 RMSE 的指标都出现了下降的趋势,相较于 GraphRec 分别平均降低了 1.13%,0.53%,证明了在用户建模过程中,时序信息对于学习用户潜在表征的重要性。本文在使用门控递归单元 GRU 的同时移除了用户建模中基于项目建模过程的注意力机制,发现 GraphRec+GRU-Att 的 MAE 值和 RMSE 值均有明显的下降,即性能明显优于 GraphRec+GRU。具体来说,在 Ciao 数据集上,MAE 和 RMSE 分别平均降低了 0.30%和 1.02%。在 Epinions 数据集上,MAE 降低了 0.34%,RMSE 降低了 1.32%,证明了本文的假设是正确的,即时序信息和门控循环单元 GRU 对学习用户潜在表征是有帮助的,同时也说明了时序信息和门控循环单元 GRU 对本文所提框架 HTGSR 的重要意义。

综上所述,用户和项目交互的时序信息有助于更好地捕获用户特征,学习用户的潜在表征。同时,GRU 对本文模型产生了积极的作用。

3.4.2 高阶特征的有效性

本文提出的 HTGSR 在学习用户潜在表征的过程中聚合了目标用户的隐式朋友关系(与用户交互过相同的项目,但是并不存在于社交图中)。在实际的应用中,如果无法从目标用户的显式朋友关系中提取到有效的信息,则需要借助它们的隐式朋友关系。为了说明隐式朋友关系这一高阶特征对模型性能的影响,本文将 HTGSR 与上述提及的 GraphRec, GraphRec+GRU, GraphRec+GRU-Att 进行详细的比较。在实验过程中,将数据集进行了划分,为了方便用统计结果来绘图,本文对同一数据集得出的 MAE 值和 RMSE 值进行求均值,结果如图 8 和图 9 所示。




图 8 高阶特征在 Ciao 数据集上的有效性

Fig. 8 Validity of high-order features on Ciao dataset




图 9 高阶特征在 Epinions 数据集上的有效性

Fig. 9 Validity of high-order features on Epinions dataset

从图 8 和图 9 来看,两个指标整体都呈现下降的趋势。与 GraphRec+GRU-Att 相比,HTGSR 加入了目标用户的隐式朋友这一高阶特征后,MAE 和 RMSE 发生了明显的下降,

即推荐效果有了明显的提升。具体来说,在 Ciao 数据集上,MAE 降低了 0.33%,RMSE 降低了 0.26%;在 Epinions 数据集上,MAE 降低了 0.86%,RMSE 值降低了 0.31%。与 GraphRec 相比,HTGSR 模型的 MAE 值和 RMSE 值在 Ciao 数据集上分别降低了 1.48%和 1.73%,在 Epinions 数据集上 MAE 值和 RMSE 值分别降低了 2.32%和 2.34%。这说明本文模型性能超过所有基线中最优基线的性能,同时也证明了高阶特征对提升推荐的性能有着重要的意义。

3.5 时间特征建模方式的适用性分析

对于时间特征建模方式,Xia 等<sup>[49]</sup>为了提高社会化推荐的解释性提出了一个门控递归单元 GRU 的改进版 T-GRU。T-GRU 主要是为了进一步讨论时间间隔因素对推荐解释性的影响。例如,如果用户与某个项目交互的时间点与预测的时间比较接近,那么就认为用户的偏好基本没有发生变化,相反则认为用户的偏好变化较大。T-GRU 是在 GRU 的基础上加入了时间门  $g_t$ ,其过程如式(37)所示:

$$g_t = \sigma(W_g[x_t, h_{t-1}] + \lambda_{\Delta_t}) \tag{35}$$
$$\Delta_t = T_t - T_{t-1}$$

其中,  $\Delta_t$  表示时间间隔,  $\lambda$  是一个预定义的超参数且大于 0。将不同项目的意见交互表示  $x_{it}$  作为 T-GRU 的输入,其在本文模型 HTGSR 中的详细使用过程如式(38)所示:

$$z_t = \sigma(W_z[x_{it}, h_{t-1}])$$
$$r_t = \sigma(W_r[x_{it}, h_{t-1}])$$
$$h'_t = \text{Tanh}(W_h[x_{it}, g_t \odot r_t \odot h_{t-1}])$$
$$h_t = g_t \odot z_t \odot h_{t-1} + (1 - g_t \odot z_t) \odot h'_t$$
 (36)

T-GRU 考虑了  $g$  的大小对推荐效果的影响,即  $g_t$  比较大时注重当前的偏好信息,  $g_t$  较小时注重用户过去的偏好信息。但从 Ciao 数据集上的实验结果(见表 10)可以看出,采用 T-GRU 和 GRU 后实验结果与 GraphRec 相比的确有一定的提升,因为 T-GRU 考虑到了时间间隔特征对用户偏好的影响,GRU 考虑到了时间顺序对用户偏好的影响。从表 10 可以看出 GRU 和 T-GRU 给 GraphRec 带来的性能提升相近。考虑到内存和时间的消耗以及本文重点关注的是时序特征对用户表征建模的作用,因此本文最终采用 GRU 来对用户和项目之间交互的时序信息进行建模,并取得了不错的效果。

表 10 GraphRec 上分别使用 T-GRU 与 GRU 结果比较

Table 10 Comparison of results on GraphRec using T-GRU and GRU respectively

| 训练        | 指标   | 方法       |                |              |
|-----------|------|----------|----------------|--------------|
|           |      | GraphRec | GraphRec+T-GRU | GraphRec+GRU |
| Ciao(60%) | MAE  | 0.7524   | 0.7448         | 0.7443       |
|           | RMSE | 1.0189   | 1.0165         | 1.0123       |

3.6 项目表征建模方式的影响分析

为了探究如何通过现有的数据构建出项目的社交网络,本文将项目潜在表征建模分成两部分:基于用户的项目表征建模和基于社交关系的项目表征建模。本节将展示两种项目社交网络的构建方式——数量型项目社交网络和比例型社交网络。然后以这两种网络的社交关系分别完成项目表征建模。最后进行大量的实验及结果分析来说明项目表征建模

方式对模型性能的影响。

3.7 实验结果分析

为了分析不同项目特征建模对模型性能的影响,本文提出以下变体:

(1)HTGSR-H:在本文整体模型 HTGSR 的基础上,去掉了基于项目的用户表征建模过程中使用的高阶特征。

(2)HTGSR-H+NIS:在 HTGSR-H 变体的基础上,以 NIS 方式构建目标项目的社交网络并进行基于社交关系的项目表征建模,将其应用于最终的预测过程中。

(3)HTGSR-H+PIS:在 HTGSR-H 变体的基础上,以 PIS 方式构建目标项目的社交网络并进行基于社交关系的项目表征建模,将其应用于最终的预测过程中。

(4)HTGSR:本文提出的整体 HTGSR 框架。

(5)HTGSR+NIS:在本文提出的整体 HTGSR 框架中,将项目建模分为基于用户的项目表征建模和基于社交网络的项目表征建模。

除 HTGSR+NIS 外,其他 4 种变体的对比结果如表 11 所列。

表 11 HTGSR-H,HTGSR-H+NIS,HTGSR-H+PIS 与 HTGSR 的实验结果对比

| 训练                | 指标   | 方法            |             |             |               |
|-------------------|------|---------------|-------------|-------------|---------------|
|                   |      | HTGSR-H       | HTGSR-H+NIS | HTGSR-H+PIS | HTGSR         |
| Ciao(60%)         | MAE  | 0.7443        | 0.7393      | 0.7428      | 0.7394        |
|                   | RMSE | 0.9998        | 0.9992      | 1.0011      | <b>0.9953</b> |
| Ciao(80%)         | MAE  | 0.7378        | 0.7365      | 0.7413      | <b>0.7296</b> |
|                   | RMSE | 0.9930        | 0.9868      | 0.9982      | <b>0.9844</b> |
| Epinions<br>(60%) | MAE  | 0.8366        | 0.8251      | 0.8370      | <b>0.8247</b> |
|                   | RMSE | 1.0856        | 1.0763      | 1.0876      | <b>1.0677</b> |
| Epinions<br>(80%) | MAE  | <b>0.8168</b> | 0.8218      | 0.8373      | 0.8213        |
|                   | RMSE | 1.0781        | 1.0719      | 1.0701      | <b>1.0692</b> |

将基于社交的项目表征用于模型后的影响分析:为了排除高阶特征的影响,本文将 HTGSR-H+NIS,HTGSR-H+PIS 和 HTGSR-H 进行对比,结果如图 10 所示。从图 10 可以看到,在去掉高阶特征后,不同的社交网络的构建方式对模型性能有不同的影响。NIS 社交网络的构建方法增强了项目的表征,HTGSR-H+NIS 模型的 MAE 和 RMSE 均低于 HTGSR-H,即性能处在一个提升的趋势上,而以 PIS 社交网络的构建方法来增强项目的表征,并没有很明显的提升效果。




图 10 不同项目表征建模方式在 Ciao 数据集上的结果

Fig. 10 Results of different item representation modelling approaches on Ciao dataset

从图 11 可以看出,在 Epinions(80%)的 MAE 指标上,

HTGSR-H 的效果最好,但是在其他训练集的指标上效果不佳。而对比 HTGSR-H+NIS 和 HTGSR-H+PIS 的结果可以发现,HTGSR-H+NIS 的整体性能优于 HTGSR-H+PIS,因为 HTGSR-H+NIS 在构建项目的社交网络前对于交互用户较少的项目进行了过滤。在没有固定一个比例的情况下,HTGSR-H+NIS 构建的项目社交网络更加复杂和全面,表达的节点信息更加丰富,因此表现出的效果更好。




图 11 不同项目表征建模方式在 Epinions 数据集上的结果

Fig. 11 Results of different item representation modelling approaches on Epinions dataset

项目社交表征和用户高阶特征对模型性能的影响分析:将变体 HTGSR-H+NIS,HTGSR-H+PIS 与 HTGSR 进行比较,可以得出,本文提出的模型 HTGSR 相比 HTGSR-H 性能提升明显。因为 HTGSR 中不仅包含目标用户的显式朋友关系,且其中的高阶特征建模的主要目的是更深层次地挖掘目标用户的隐式朋友关系,拓宽目标用户的社交网络,从而增强用户的潜在向量表示。相比对用户的社交网络建模,对项目的社交网络建模存在一定的局限性。因为本文在为目标项目构建社交网络时,主要针对的是一些固有属性特征不相似但可能存在一定的关联性的项目,挖掘的是项目的隐式朋友关系,而显式朋友关系建模部分缺失,导致最终 HTGSR-H+NIS 的结果不如 HTGSR。

特征信息量对模型性能的影响分析:为了探究特征信息的多少对模型性能的影响,本文将 HTGSR-H+NIS,HTGSR,HTGSR+NIS 与 HTGSR-H 进行比较,实验结果如表 12 所列。

表 12 特征信息的多少对模型性能的影响

Table 12 Effect of the amount of feature information on model performance

| 方法          | Ciao(60%)     |               | Ciao(80%)     |               |
|-------------|---------------|---------------|---------------|---------------|
|             | MAE           | RMSE          | MAE           | RMSE          |
| HTGSR-H     | 0.7524        | 1.0189        | 0.7387        | 0.9954        |
| HTGSR-H+NIS | <b>0.7393</b> | 0.9992        | 0.7365        | 0.9868        |
| HTGSR       | 0.7394        | <b>0.9953</b> | <b>0.7296</b> | <b>0.9844</b> |
| HTGSR+NIS   | 0.7410        | 1.0088        | 0.7431        | 0.9989        |

从表 12 可以看出,只采用用户高阶特征的 HTGSR 模型和只用项目隐式社交信息的 HTGSR-H+NIS 的性能均优于 HTGSR-H,但是用户高阶特征带来的性能提升较大。原因可能是在构建用户的高阶特征时,本文模型遍历目标用户的交互项目集,将每个项目交互用户信息进行向量表示,使得基于项目的用户潜在表征中包含项目的固有属性特征以及用户的高阶特征。而以 NIS 方式构建项目的隐式社交网络时,本文采用的是项目的原始固有属性特征,因此 HTGSR 的性能提升比 HTGSR-H+NIS 更明显。



在 HTGSR+NIS 中将全部信息用于模型预测中,模型结果反而下降。根据结果推测,在社会化推荐中加入越多的信息并不代表一定能带来性能提升。原因可能是用户和项目的表征学习大多来源于用户-项目二部图,在对用户潜在表征建模过程中很可能已经包含了一些项目的相关性信息,导致两部分产生信息重叠和不一致问题,因此性能下降。此外,也可能是由于模型的结构太过于复杂,当前的数据无法使模型收敛至最佳效果,而引发性能下降。

3.7 嵌入维度分析

嵌入维度是模型在训练过程中一个非常重要的实验

参数,本节主要论述嵌入维度对 HTGSR 模型性能的影响。HTGSR 模型中主要涉及的嵌入向量有  $p, q$  和  $e$ ,实验结果如表 13 所列。从表中可以看出,在不同的嵌入维度大小下,模型的性能是不同的,通常,逐渐增大嵌入维度,评价指标值会先增后减。嵌入维度从 16 增加到 64 时,指标值下降,性能提升;嵌入维度为 128 时,HTGSR 性能会降低。结果表明,嵌入维度越大,表示能力越强,模型性能越好;但嵌入维度太大,则会增加模型的时间复杂度,导致性能下降。因此,本文在模型训练过程中需要找到最优的嵌入维度大小,以便在性能和复杂性之间取得平衡。

表 13 嵌入维度对模型性能的影响  
Table 13 Impact of embedding dimension on model performance

| 维度      | Ciao(60%)     |               | Ciao(80%)     |               | Einions(60%)  |               | Epinions(80%) |               |
|---------|---------------|---------------|---------------|---------------|---------------|---------------|---------------|---------------|
|         | MAE           | RMSE          | MAE           | RMSE          | MAE           | RMSE          | MAE           | RMSE          |
| $d=16$  | 0.7549        | 1.0023        | 0.7553        | 0.9927        | 0.8664        | 1.0931        | 0.8440        | 1.0818        |
| $d=32$  | 0.7486        | 0.9996        | 0.7431        | 0.9882        | 0.8324        | 1.0774        | 0.8315        | 1.0704        |
| $d=64$  | <b>0.7394</b> | <b>0.9953</b> | <b>0.7296</b> | <b>0.9844</b> | <b>0.8247</b> | <b>1.0677</b> | <b>0.8213</b> | <b>1.0692</b> |
| $d=128$ | 0.7460        | 0.9984        | 0.7412        | 0.9925        | 0.8405        | 1.0728        | 0.8347        | 1.0737        |

如图 12 和图 13 所示,HTGSR 模型的嵌入维度  $d=64$  时,在 Ciao 数据集和 Epinions 数据集上的带状图处于最低

点,表明此时 HTGSR 模型的 MAE 指标和 RMSE 指标在两个数据集上取得了最好的性能。




图 12 模型嵌入维度在 Ciao 数据集上的影响  
Fig. 12 Impact of model embedding dimensionality on Ciao dataset




图 13 模型嵌入维度在 Epinions 数据集上的影响  
Fig. 13 Impact of model embedding dimensionality on Epinions dataset

**结束语** 社交媒体的兴起促进了现实社交和虚拟社交方式的结合,人们的社交方式正在逐渐发生变化,各种数据呈指数级增长,呈现出规模化、稀疏化、冗余化和复杂化的特点。基于矩阵分解的社会化推荐算法和基于图神经网络的社会化推荐算法虽然在解决数据稀疏性和冷启动方面取得了一定的成绩,但也面临着一系列巨大的挑战。首先,用户偏好随时间动态变化,如何有效利用用户-项目交互的时序信息进一步捕捉用户兴趣偏好成为社会化推荐面临的挑战之一。其次,用户的社交网络错综复杂,在社交关系中用户之间的交往并不简单,社会关系有强联系和弱联系之分。选取更好的方法来

区分不同强度的社交关系也是社会化推荐的需要克服的困难之一。此外,用户的社交朋友可以分为显式和隐式。目前,大多数方法都是利用用户的显式好友关系来进行用户表征学习。因此,如何挖掘用户的潜在社交关系就显得尤为重要。为了应对上述挑战,本文提出了一种新的基于图神经网络的社会化推荐算法模型 HTGSR,该模型根据交互行为的时序信息和用户隐式好友等高阶信息获取用户潜在表征。HTGSR 首先使用门控递归单元对基于项目的用户表征进行建模,以时间序列信息作为辅助信息描述用户近期动态偏好,定义高阶建模单元提取高阶连通特征,挖掘用户的隐式朋友

信息;其次利用注意力机制获取基于社交关系的用户表征;然后提出不同的项目社交网络构建方法——数量型社交网络(NIS)和比例型社交网络(PIS),获取两种方法基于社交关系的项目表征,分别与基于用户的项目表征进行聚合,得到更完整的项目潜在表征;最后将用户和项目的潜在表征输入到多层感知机中,完成用户对项目的评分预测。

为了从实践层面验证 HTGSR 模型在数据集 Ciao 和 Epinions 上的有效性,本文首先选择了 4 种推荐算法的典型模型作为基线方法与本文方法进行比较,并提出了 4 种变体在两个数据集上分别进行消融实验,验证了本文创新点的有效性;其次进行时序特征建模方法的适用性实验,分析 T-GRU 与 GRU 的比较和选择;然后提出了 5 种相关变体进行不同项目特征建模方法的影响分析实验,探讨项目社交网络对模型性能的影响;最后进行超参数实验,讨论嵌入维度对模型性能的影响。经过大量的实验和分析,结果表明本文提出的高阶时序图神经网络社会化推荐算法模型 HTGSR 取得了较好的效果。

## 参 考 文 献

- [1] RESNICK P, VARIAN H R. Recommender systems[J]. Communications of the ACM, 1997, 40(3): 56-58.
- [2] SHOKEEN J, RANA C. A study on features of social recommender systems[J]. Artificial Intelligence Review, 2020, 53(2): 965-988.
- [3] TANG J, AGGARWAL C, LIU H. Recommendations in signed social networks[C]// Proceedings of the 25th International Conference on World Wide Web, Montreal: ACM, 2016: 31-40.
- [4] KOLLI S, KHAJEHEIAN D. Social network analysis of Pokemon Go in Twitter[C]// Proceedings of the 2nd National and 1st International Digital Games Research Conference: Trends, Technologies, and Applications. Tehran: IEEE, 2018: 17-26.
- [5] WU Q, ZHANG H, GAO X, et al. Dual graph attention networks for deep latent representation of multifaceted social effects in recommender systems[C]// Proceedings of the 28th International Conference on World Wide Web. San Francisco: ACM, 2019: 2091-2102.
- [6] PUSHPENDRA K, SINGH T R. Recommendation system techniques and related issues: a survey[J]. International Journal of Information Technology, 2018, 10(4): 495501.
- [7] YANG X, GUO Y, LIU Y, et al. A survey of collaborative filtering based social recommender systems[J]. Computer Communications, 2014, 41(5): 1-10.
- [8] SUN Z, YANG J, ZHANG J, et al. Recurrent knowledge graph embedding for effective recommendation[C]// Proceedings of the 12th ACM Conference on Recommender Systems. Vancouver: ACM, 2018: 297-305.
- [9] LIU X. An improved clustering-based collaborative filtering recommendation algorithm[J]. Cluster Computing, 2017, 20(2): 1281-1288.
- [10] ZHAO Z L, WANG C D, WAN Y Y, et al. FTMF: recommendation in social network with feature transfer and probabilistic matrix factorization[C]// Proceedings of the International Joint Conference on Neural Networks. Vancouver: IEEE, 2016: 847-854.
- [11] SUN P, WU L, WANG M. Attentive recurrent social recommendation[C]// Proceedings of the 41st International ACM SIGIR Conference on Research and Development in Information Retrieval. Ann Arbor: ACM, 2018: 185-194.
- [12] 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: ACM, 2008: 426434.
- [13] YANG J, WAN J, WANG Y, et al. Social network-based News Recommendation with Knowledge Graph[C]// Proceedings of the IEEE International Conference on Information Technology, Big Data and Artificial Intelligence. Chongqing: IEEE, 2020: 1255-1260.
- [14] JAMALI M, ESTER M. A matrix factorization technique with trust propagation for recommendation in social networks[C]// Proceedings of the 4th ACM Conference on Recommender Systems. Barcelona: ACM, 2010: 135-142.
- [15] GURINI D F, GASPARETTI F, MICARELLI A, et al. Temporal people-to-people recommendation on social networks with sentiment-based matrix factorization[J]. Future Generation Computer Systems, 2018, 78(P1): 430-439.
- [16] MA H, KING I, LYU M R. Learning to recommend with social trust ensemble[C]// Proceedings of the 32nd Annual International ACM SIGIR Conference on Research and Development in Information Retrieval. Boston: ACM, 2009: 203210.
- [17] MENG X W, LI R C, ZHANG Y J, et al. Survey on Mobile Recommender Systems Based on User Trajectory Data[J]. Journal of Software, 2018, 29(10): 3111-3133.
- [18] YUE W, WANG Z, TIAN B, et al. A Hybrid Model-and Memory-Based Collaborative Filtering Algorithm for Baseline Data Prediction of Friedreich's Ataxia Patients[J]. IEEE Transactions on Industrial Informatics, 2020, 17(2): 1428-1437.
- [19] KAO H T, YAN S, HOSSEINMARDI H, et al. User-Based Collaborative Filtering Mobile Health System[J]. ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2020, 4(4): 1-17.
- [20] LIAO G Q, LAN T M, HUANG X M, et al. Survey on Recommendation Systems in Event-based Social Networks[J]. Journal of Software, 2021, 32(2): 424-444.
- [21] SHU J, SHEN X, LIU H, et al. A content-based recommendation algorithm for learning resources[J]. Multimedia Systems, 2017, 24(2): 163-173.
- [22] ALMEIDA M S, BRITTO A. MOEA-RS: A Content-Based Recommendation System Supported by a Multi-objective Evolutionary Algorithm[C]// Proceeding of the 19th International Conference on Artificial Intelligence and Soft Computing. Zakopane: Springer, 2020: 265-276.
- [23] DENG Z H, HUANG L, WANG C D, et al. DeepCF: A Unified Framework of Representation Learning and Matching Function Learning in Recommender System[C]// Proceedings of The 31rd AAAI Conference on Artificial Intelligence. Honolulu: AAAI, 2019: 61-68.
- [24] HAO T, ZHENG Z. The implementation and optimization of matrix decomposition based collaborative filtering task on x86 platform[C]// Proceedings of the 2nd International Symposium

- on Benchmarking, Measuring and Optimization. Denver: Springer, 2019: 110-115.
- [25] XUE F, HE X, WANG X, et al. Deep item-based collaborative filtering for top-n recommendation[J]. ACM Transactions on Information Systems(TOIS), 2019, 37(3): 1-25.
- [26] JIANG S, QIAN X, SHEN J, et al. Author topic model-based collaborative filtering for personalized POI recommendations[J]. IEEE Transactions on Multimedia, 2015, 17(6): 907-918.
- [27] HUANG Z, XU X, ZHU H, et al. An efficient group recommendation model with multiattention-based neural networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(11): 4461-4474.
- [28] SALAKHUTDINOV R, MNH A. Probabilistic Matrix Factorization[C]//Proceedings of the 21st Annual Conference on Neural Information Processing Systems. Vancouver: Curran Associates, 2007: 1257-1264.
- [29] MA H, YANG H, LYU M R, et al. SoRec: social recommendation using probabilistic matrix factorization[C]//Proceedings of the 17th ACM Conference on Information and Knowledge Management. Napa Valley: ACM, 2008: 931-940.
- [30] LOGESH R, SUBRAMANIASWAMY V. A reliable point of interest recommendation based on trust relevancy between users[J]. Wireless Personal Communications, 2017, 97(2): 2751-2780.
- [31] YANG B, LEI Y G, YOU L D, et al. Social Collaborative Filtering by Trust[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(8): 1633-1647.
- [32] FAN S, ZHUN J, HAN X, et al. Metapath-guided heterogeneous graph neural network for intent recommendation[C]//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Anchorage: ACM, 2019: 2478-2486.
- [33] WANG X, HE X, WANG M, et al. Neural graph collaborative filtering[C]//Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. Paris: ACM, 2019: 165-174.
- [34] VAN DEN B R, KIPF T, WELLING M. Graph Convolutional Matrix Completion[J]. arXiv:1706.02263, 2017.
- [35] YANG J H, CHEN C M, WANG C J, et al. HOP-rec: high-order proximity for implicit recommendation[C]//Proceedings of the 12th ACM Conference on Recommender Systems. Vancouver: ACM, 2018: 140-144.
- [36] HE X, LIAO L, ZHANG H, et al. Neural Collaborative Filtering[C]//Proceedings of the 26th International Conference on World Wide Web. Perth: ACM, 2017: 173-182.
- [37] 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. Paris: ACM, 2019: 235-244.
- [38] WU Q, ZHANG H, GAO X, et al. Dual Graph Attention Networks for Deep Latent Representation of Multifaceted Social Effects in Recommender Systems[C]//Proceedings of the World Wide Web Conference. San Francisco: ACM, 2019: 2091-2102.
- [39] SRIVASTAVA N, HINTON G E, KRIZHEVSKY A, et al. Dropout: a simple way to prevent neural networks from overfitting[J]. The Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [40] LI L, TANG S L. Metric Ranking Learning Recommendation Model Based on Content Representation[J]. Acta Electronica Sinica, 2020, 48(08): 1615-1622.
- [41] WANG S, TANG J, WANG Y, et al. Exploring Hierarchical Structures for Recommender Systems[J]. IEEE Transactions on Knowledge and Data Engineering, 2018, 30(6): 1022-1035.
- [42] FAN W, MA Y, LI Q, et al. Graph neural networks for social recommendation[C]//The World Wide Web Conference. 2019: 417-426.
- [43] MNH A, SALAKHUTDINOV R R. Probabilistic matrix factorization[C]//NIPS. 2007: 1257-1264.
- [44] 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. 2010: 135-142.
- [45] FAN W, LI Q, CHENG M. Deep modeling of social relations for recommendation[C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2018: 612-618.
- [46] FAN W, MA Y, YIN D, et al. Deep social collaborative filtering[C]//Proceedings of the 13th ACM Conference on Recommender Systems. 2019: 305-313.
- [47] BERG R, KIPF T N, WELLING M. Graph convolutional matrix completion[J]. arXiv:1706.02263, 2017.
- [48] CHEN X, ZHANG Y, QIN Z. Dynamic explainable recommendation based on neural attentive models[C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2019: 53-60.
- [49] XIA X, YIN H Z, YU J L, et al. Self-Supervised Hypergraph Convolutional Networks for Session-based Recommendation[J]. arXiv:2012.06852, 2020.
- [50] CHANG J X, GAO C, ZHENG Y, et al. Sequential Recommendation with Graph Neural Networks[C]//Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2021: 378-387.



**YU Jian**, born in 1974, senior engineer. His main research interests include data mining, database, and computer network research.



**ZHANG Wenbin**, born in 1983, engineer. His main research interests include data mining and education informatization research.