

# 融合长短期兴趣的属性增强临时群组推荐算法

王智玄<sup>1</sup>, 庞继芳<sup>1,2\*</sup>, 王智强<sup>1,2</sup>, 宋鹏<sup>3</sup>, 李茹<sup>1,2</sup>

(1.山西大学计算机与信息技术学院, 山西 太原 030006; 2.山西大学计算智能与中文信息处理教育部重点实验室, 山西 太原 030006; 3.山西大学经济与管理学院, 山西 太原 030006)

**摘要:**群组推荐旨在为群体用户提供推荐服务,其最终目的是满足群组成员间不同的偏好需求。现有群组推荐算法大多是面向固定群组的,忽视了大量具有偶然性和特殊性的临时群组。为了进一步拓展群组推荐算法的应用场景,有效应对临时群组历史交互信息短缺的问题,提出一种融合长短期兴趣的属性增强临时群组推荐算法。首先,在用户—项目整体历史交互和用户短期交互序列中分别注入项目的属性信息,综合运用超图网络、图神经网络和门控循环单元学习用户的长短期兴趣。进而,利用注意力机制将组内成员的长期兴趣聚合为群组的长期兴趣;同时,设计成员短期兴趣与群组长期兴趣之间的相似性度量策略计算成员权重,并通过加权融合的方式获得群组的短期兴趣。在此基础上,采用长短期兴趣对比学习最大化两类群组兴趣之间的一致性,通过对比损失和推荐损失对模型进行联合优化,以获得高质量的群组综合表征,实现临时群组的精准推荐。最后,通过2个真实数据集上的对比分析和消融实验验证所提模型的可行性和有效性,实验结果表明项目属性信息和用户短期兴趣可有效增强临时群组表征质量,显著提升模型的推荐效果。

**关键词:**项目属性信息;长短期兴趣;超图网络;对比学习;群组推荐

**中图分类号:**TP391 **文献标志码:**A

**引用格式:**王智玄,庞继芳,王智强,等.融合长短期兴趣的属性增强临时群组推荐算法[J].山东大学学报(理学版),2026,61(3):54-65.

## Attribute enhanced temporary group recommendation algorithm fusing long-and short-term interests

WANG Zhixuan<sup>1</sup>, PANG Jifang<sup>1,2\*</sup>, WANG Zhiqiang<sup>1,2</sup>, SONG Peng<sup>3</sup>, LI Ru<sup>1,2</sup>

(1. School of Computer and Information Technology, Shanxi University, Taiyuan 030006, Shanxi, China; 2. Key Laboratory of Computational Intelligence and Chinese Information Processing of Ministry of Education, Shanxi University, Taiyuan 030006, Shanxi, China; 3. School of Economics and Management, Shanxi University, Taiyuan 030006, Shanxi, China)

**Abstract:** Group recommendation aims to provide recommendation services for group users, with the ultimate goal of meeting the different preference needs of group members. Most existing group recommendation algorithms are designed for fixed groups, ignoring a large number of temporary groups with randomness and specificity. In order to further expand the application scenarios of group recommendation algorithms and effectively address the shortage of historical interaction information in temporary groups, attribute enhanced temporary group recommendation algorithm fusing long-and short-term interests (ALSTG) is proposed. Firstly, item attributes information are injected into the overall historical interactions between users and items and the users' short-term interaction sequences, respectively. Then, users' long-and short-term interests are learned by comprehensively using hypergraph networks, graph neural networks, and gated recurrent units. Furthermore, the long-term interests of members are aggregated into the long-term interests of group through attention mechanism. At the same time, a similarity measurement strategy between the short-term interests of members and the long-term interests of the group is designed to calculate the weights of members, and the short-term interests of the group are obtained through weighted fusion. On this basis, a long-and short-term interest contrastive learning approach is adopted to maximize the consistency between the two types of group interests. The model is jointly optimized through comparative loss and recommendation loss to obtain high-quality group comprehensive representation, thereby achieving accurate

收稿日期:2024-09-18; 网络出版时间:2025-04-09

基金项目:国家自然科学基金资助项目(62472270, 62006148, 72171137, 62272285); 山西省基础研究计划资助项目(202403021221021)

第一作者:王智玄(1998—),男,硕士研究生,研究方向为推荐系统. E-mail:1078850276@qq.com

\*通信作者:庞继芳(1980—),女,副教授,硕士生导师,博士,研究方向为推荐系统与智能决策. E-mail:purplejif@sxu.edu.cn

recommendation for temporary groups. Finally, the feasibility and effectiveness of the proposed model were verified through comparative analysis and ablation experiments on two real datasets. The experimental results show that item attribute information and user short-term interests can effectively enhance the quality of temporary group representation and significantly improve the recommendation performance of the model.

**Key words:** item attribute information; long-and short-term interests; hypergraph networks; contrastive learning; group recommendation

## 0 引言

随着社交平台的快速发展,群体活动日益频繁,迫切需要令大多数成员满意的推荐服务。作为个性化推荐<sup>[1-3]</sup>的拓展和延伸,群组推荐通常是通过聚合不同成员的兴趣来推断群体的偏好。日常生活中普遍存在两类群组:固定群组和临时群组<sup>[4]</sup>。固定群组的成员长期稳定,群组与项目之间存在历史交互记录,而临时群组则由成员临时组建,群组与项目之间几乎没有交互。目前,有关群组推荐的研究主要是面向固定群组的,利用群组—项目的历史交互建模群组偏好<sup>[5-7]</sup>,忽略了临时群组的现实需求。事实上,越来越多的临时群组出现在各种社交活动中,如合作伙伴一起聚餐、班级同学结伴出游、公司员工共同观影等。现有的面向固定群组的推荐方法无法直接用于临时群组的推荐,如何准确捕获临时群组的偏好,进一步拓展群组推荐算法的应用场景成为推荐系统领域亟待解决的一个重要问题。

由于临时群组具有短期性、动态性等特点,缺少群组与项目之间的交互信息,为建模群组偏好带来了挑战。目前,针对临时群组推荐算法的研究大多根据组内成员的历史交互记录学习成员偏好,并通过聚合成员表征得到群组表征<sup>[8-10]</sup>。现有研究存在以下局限性:1) 偏好聚合过程中使用的信息量过少,一定程度上限制了群组表征的质量。2) 忽略了时序信息对群组偏好的影响,无法有效捕捉群组的动态兴趣。

为了提升临时群组推荐效果,可借鉴个性化推荐算法中的成功经验。1) 将项目属性信息融入节点表征学习过程中。项目属性信息中包含丰富的项目侧上下文,如餐厅的环境、服务态度以及菜品的味道等,有助于增强用户和项目的表征质量<sup>[11-13]</sup>。2) 将用户的短期交互序列融入用户偏好建模过程中。通过建模用户短期兴趣,捕捉用户在当前时段内的兴趣变化,从而更好地理解用户需求<sup>[14-15]</sup>。

综上所述,本文提出一种融合长短期兴趣的属性增强临时群组推荐算法(attribute enhanced temporary group recommendation algorithm fusing long-and short-term interests, ALSTG)。将项目属性信息分别融入群组长短期兴趣建模过程中,利用超图网络和注意力机制学习群组的长期静态兴趣,同时,通过图神经网络、门控循环单元和相似性度量策略学习群组的短期动态兴趣。进而,利用对比学习最大化两类群组兴趣之间的一致性,优化群组的长短期兴趣表征。最后,通过自适应融合形成临时群组的综合表征。

本文主要贡献如下:

1) 提出了项目属性信息增强的节点表征策略,将项目属性信息分别与用户历史交互记录和短期交互序列相结合,构建了用户—项目—属性超图网络和项目—属性二部图,更加全面、精准地捕捉项目特征和用户的长短期兴趣。

2) 构建了群组长短期兴趣学习模型,通过注意力机制将成员长期兴趣聚合成群组长期兴趣,进而,根据成员短期兴趣与群组长期兴趣之间的相似度确定成员权重,并通过加权融合得到群组的短期兴趣。

3) 设计了群组长短期兴趣对比学习框架,通过最大化两类群组兴趣之间的一致性,达到优化群组长短期兴趣表征的目的,有效提升临时群组的表征质量。

## 1 相关工作

### 1.1 基于深度学习的推荐算法研究现状

近年来,基于深度学习的推荐技术已成为推荐系统领域的热点研究方向之一。循环神经网络(recurrent neural network, RNN)常常被用来建模序列数据。Song等<sup>[16]</sup>综合考虑用户的兴趣转移及其潜在影响因素,使用变分自动编码器和RNN来捕捉用户的意图。Zhao等<sup>[17]</sup>利用RNN编码用户和项目之间的路径来学习

用户偏好。Yu等<sup>[18]</sup>通过构建调用视图和文本视图来建模用户偏好,并结合双向长短期记忆网络(bidirectional long short-term memory, Bi-LSTM)和多层感知机来学习用户表征。

图神经网络具有强大的表征学习能力,在推荐系统中广泛应用。Wang等<sup>[19]</sup>综合运用图神经网络与注意力机制建模用户和项目之间的协同信息。Zeng等<sup>[20]</sup>将图神经网络与门控机制相结合来挖掘相邻会话间的上下文联系,从而捕捉用户偏好。由于基于图神经网络的方法随着卷积层数的增加会出现过拟合的问题,其常用于捕捉图结构中的局部关系。相比之下,超图网络可以有效建模节点之间的高阶关联关系和全局协同关系,已被广泛用于推荐算法中。Xia等<sup>[21]</sup>分别利用图神经网络和超图网络学习用户的局部和全局表征,并通过二者的融合得到用户综合表征。Wu等<sup>[22]</sup>将用户加入群组的动机分为社交意图和个人兴趣意图,综合使用图和超图网络来建模这2种意图,以提升推荐性能。

为了提高节点表征质量、缓解数据稀疏性,对比学习也常被用于推荐算法中,并表现出良好的效果。Gu等<sup>[23]</sup>基于用户的多行为信息构建多个视图,并利用多视图对比学习提升用户表征质量。Yang等<sup>[24]</sup>通过建立知识图谱与用户—项目交互图之间的跨视图对比学习来增强模型性能。

### 1.2 融合长短期兴趣的推荐算法研究现状

现有考虑长短期兴趣的相关研究主要集中在个性化推荐场景下,通过挖掘并融合用户的长短期兴趣,得到用户的综合表征,增强推荐效果。Zhao等<sup>[25]</sup>设计了时间门和距离门增强的长短期记忆网络来捕捉用户的长短期兴趣,以更准确地把握用户需求。Yan等<sup>[26]</sup>分别使用门控循环单元和卷积神经网络来建模用户的短期兴趣和长期兴趣,以提升用户表征质量。Wu等<sup>[27]</sup>在构建用户—项目交互图的基础上,结合图神经网络来学习用户的长短期兴趣表征,从而完成推荐。Fu等<sup>[15]</sup>将图神经网络和超图网络分别用于建模用户的短期兴趣和长期兴趣,并通过自适应融合得到用户综合表征,以提升推荐性能。综上可知,在用户偏好建模过程中同时考虑长短期兴趣,既能获取用户的长期稳定偏好,又能捕捉用户在短时间内的偏好变化,有助于得到更加精准、全面的用户表征,有效增强模型性能。

### 1.3 群组推荐算法研究现状

现有的固定群组推荐研究大多致力于提升节点的表征质量。Yang等<sup>[6]</sup>利用图神经网络和分解注意力机制聚合用户、群组和项目之间的信息,进而学习节点表征。Wu等<sup>[7]</sup>设计了群组—群组关联图、群组—成员关联图和群组—项目关联图3种视图,综合运用图和超图卷积捕捉群组偏好。Jia等<sup>[28]</sup>提出一个双通道超图卷积网络模型,分别从成员层面和群组层面学习群组表征。

在临时群组推荐研究方面,Sankar等<sup>[8]</sup>利用注意力机制学习群组成员之间的上下文偏好权重,从而优化群组及其成员的表征。Guo等<sup>[9]</sup>分别从用户—项目历史交互和用户—用户社交关系两方面学习用户表征。He等<sup>[10]</sup>构建了用户—项目视图和群组—成员视图,通过多视图融合学习群组的表征。Meng等<sup>[4]</sup>设计了一个混合图神经网络模型,从成员的社交关系和交互记录两个角度学习成员的表征。

然而,现有的临时群组推荐算法仅考虑了群组的长期稳定兴趣,忽视了群组的短期动态兴趣,无法全面建模群组偏好特征。此外,现有的群组推荐算法大多是根据历史交互记录学习群组偏好,未充分利用项目侧的辅助信息,导致节点表征所含的信息量不足,限制了模型的推荐效果。

## 2 融合长短期兴趣的属性增强临时群组推荐算法 ALSTG

### 2.1 符号及问题描述

设用户集合为  $U = \{u_1, u_2, \dots, u_m\}$ , 项目集合为  $I = \{i_1, i_2, \dots, i_n\}$ , 属性集合为  $A = \{a_1, a_2, \dots, a_r\}$ , 临时群组集合为  $G = \{g_1, g_2, \dots, g_k\}$ , 其中  $m, n, r, k$  分别是用户数、项目数、属性数和群组数。用户  $u \in U$  对项目  $i \in I$  的交互矩阵为  $\mathbf{Y} \in \mathbf{R}^{m \times n}$ , 项目—属性关联矩阵为  $\mathbf{Z} \in \mathbf{R}^{n \times r}$ , 用户  $u_p$  的短期交互序列为  $S_p = \{i_1, i_2, \dots, i_j\}$ , 其中  $j$  是用户  $u_p$  短期交互过的项目数。

ALSTG 模型的目标是针对给定临时群组  $g$ , 从项目集合  $I$  中找到最有可能与群组  $g$  发生交互的前  $K$  个项目, 形成群组可能感兴趣的项目列表。

### 2.2 模型总体框架

ALSTG 由用户表征学习模块、群组长短期兴趣学习模块、对比学习模块以及预测模块4部分组成。

1) 项目属性信息增强的用户表征学习模块。将用户—项目交互矩阵与项目—属性关联矩阵相结合构建用户—项目—属性超图网络,利用超图卷积学习用户的长期兴趣表征和项目的综合表征。同时,将用户短期交互序列与项目—属性关联矩阵相结合构建项目—属性序列图,利用门控循环单元(gated recurrent unit, GRU)形成用户的短期兴趣表征。2) 群组长短期兴趣学习模块。通过注意力机制聚合组内成员的长期兴趣得到群组的长期兴趣,并利用相似性度量策略确定组内成员短期兴趣的权重,通过加权融合得到群组的短期兴趣,将两类兴趣进行自适应融合形成群组的综合表征。3) 长短期兴趣对比学习模块。设计两个对比损失函数分别优化群组的长短期兴趣表征,以增强表征质量。4) 预测模块。通过群组综合表征与项目综合表征的内积运算得到预测得分,生成推荐列表。ALSTG模型的整体框架如图1所示。

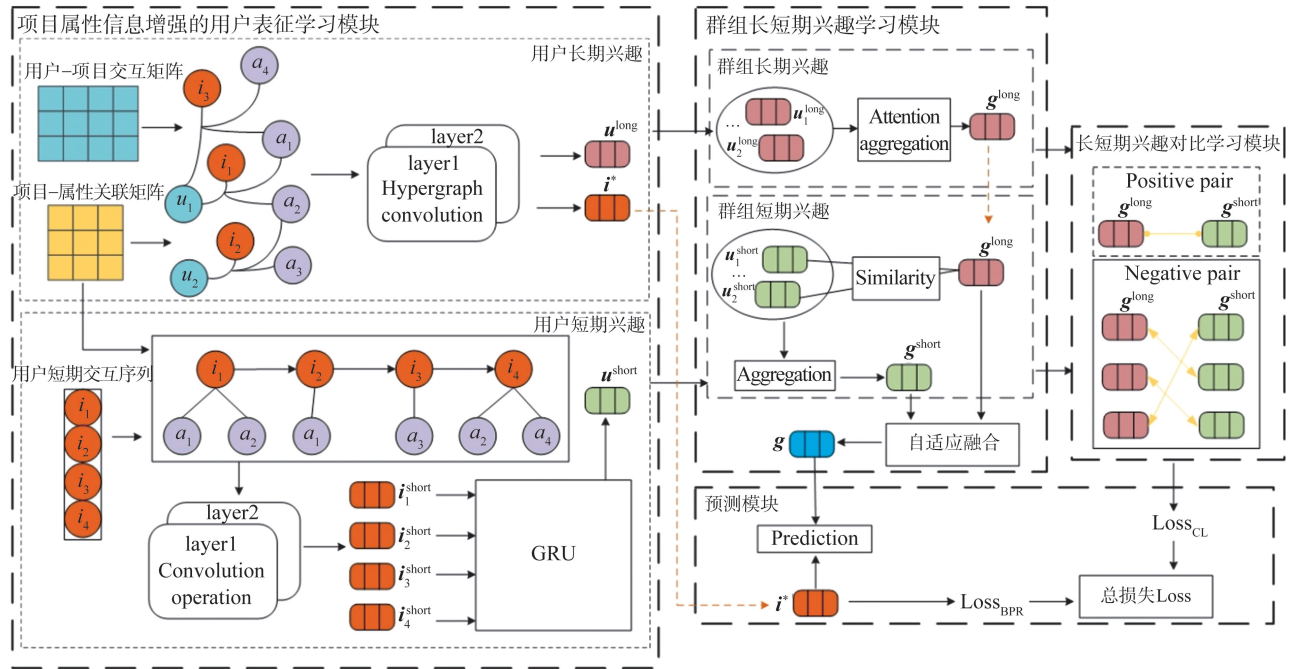


图1 ALSTG模型的整体框架  
Fig.1 Overall framework of the ALSTG model

### 2.3 项目属性信息增强的用户表征

主要介绍项目属性信息增强的用户偏好建模方法和项目特征获取过程,为后续的群组表征学习奠定基础。

#### 2.3.1 用户长期兴趣表征

用户的长期兴趣通过挖掘用户完整的历史交互记录来获取,反映了用户长时间内的稳定偏好。然而,用户—项目历史交互记录包含的信息有限,将项目属性信息融入用户长期兴趣建模过程中,有助于获得富信息的用户表征。

基于用户—项目交互矩阵和项目—属性关联矩阵挖掘用户—项目—属性三元组之间的关系,构建用户长期兴趣超图网络  $G_h = (V_h, E_h, H_h)$ , 超边包含用户、用户交互过的项目以及项目对应的属性3类节点,其中  $V_h = U \cup I \cup A$  表示超图的节点集,  $E_h$  表示超边集, 邻接矩阵  $H_h$  表示节点和超边之间的隶属关系。将用户初始嵌入矩阵  $U \in \mathbf{R}^{m \times d}$ 、项目初始嵌入矩阵  $I \in \mathbf{R}^{n \times d}$  和属性初始嵌入矩阵  $A \in \mathbf{R}^{r \times d}$  堆叠成用户

项目初始嵌入矩阵  $E_{ui}^{(0)} = \begin{pmatrix} U \\ I \\ A \end{pmatrix}$ , 并将其与邻接矩阵  $H_h$  一起输入超图网络,通过超图卷积<sup>[29]</sup>得到更新后的用户项目嵌入矩阵  $\bar{E}_{ui}$ ,

$$\bar{E}_{ui} = D_h^{-1} H_h B_h^{-1} (H_h)^T E_{ui}^{(0)} W_h = \begin{pmatrix} \bar{U} \\ \bar{I} \\ \bar{A} \end{pmatrix}, \quad (1)$$

其中:  $\mathbf{D}_h^{-1}$  表示节点的度矩阵;  $\mathbf{B}_h^{-1}$  表示超边的度矩阵;  $\mathbf{W}_h$  表示可训练的参数矩阵。由用户项目嵌入矩阵  $\bar{\mathbf{E}}_{ui}$  可得用户  $u_p$  的长期兴趣表征  $\mathbf{u}_p^{\text{long}}$  和项目  $i_q$  的综合表征  $\mathbf{i}_q^*$ 。

### 2.3.2 用户短期兴趣表征

用户的短期兴趣通常通过挖掘用户的短期交互序列来获取,短期交互序列是根据时序信息从用户完整的历史交互记录中选取一定比例的最近交互记录得到的。

基于用户的短期交互序列  $S_p$  和项目—属性关联矩阵  $\mathbf{Z}$ , 可构建项目—属性序列图  $G_a = (V_a, E_a)$ , 来挖掘用户近期交互过的项目之间的时序关系, 其中  $V_a$  表示节点集,  $E_a$  表示边集。  $\mathbf{A}_a \in \mathbf{R}^{(j+r) \times (j+r)}$  表示  $G_a$  的邻接矩阵, 其中  $k$  是项目数,  $r$  是项目对应的属性数。将用户短期交互序列中项目的初始嵌入矩阵  $\mathbf{I}^{\text{short}} \in \mathbf{R}^{j \times d}$  和属性初始嵌入矩阵  $\mathbf{A} \in \mathbf{R}^{r \times d}$  堆叠成项目属性初始嵌入矩阵  $\mathbf{E}_{ia}^{(0)} = \begin{pmatrix} \mathbf{I}^{\text{short}} \\ \mathbf{A} \end{pmatrix}$ , 并将其与邻接矩阵  $\mathbf{A}_a$  一起输入图卷积神经网络。参考谱图卷积<sup>[30-31]</sup>, 将第  $l+1$  层的图卷积定义为

$$\mathbf{E}_{ia}^{(l+1)} = \mathbf{D}^{-\frac{1}{2}} \mathbf{A}_a \mathbf{D}^{-\frac{1}{2}} \mathbf{E}_{ia}^{(l)}, \quad (2)$$

其中,  $\mathbf{E}_{ia}^{(l)}$  表示第  $l$  层的节点嵌入矩阵,  $\mathbf{D}^{-\frac{1}{2}}$  表示节点的度矩阵。

通过对每一层获得的嵌入矩阵求平均, 可以得到更新后的项目属性嵌入矩阵  $\bar{\mathbf{E}}_{ia}$ ,

$$\bar{\mathbf{E}}_{ia} = \frac{1}{L+1} \sum_{l=0}^L \mathbf{E}_{ia}^{(l)} = \begin{pmatrix} \bar{\mathbf{I}} \\ \bar{\mathbf{A}} \end{pmatrix}, \quad (3)$$

其中,  $L$  为卷积层数,  $\mathbf{E}_{ia}^{(l)}$  表示第  $l$  层的节点嵌入矩阵。

将更新后的项目表征矩阵  $\bar{\mathbf{I}} = (\bar{\mathbf{i}}_1, \bar{\mathbf{i}}_2, \dots, \bar{\mathbf{i}}_j)$ , 输入到 GRU 中, 生成用户的短期兴趣表征  $\mathbf{u}_p^{\text{short}}$ ,

$$\mathbf{u}_p^{\text{short}} = \text{GRU}((\bar{\mathbf{i}}_1, \bar{\mathbf{i}}_2, \dots, \bar{\mathbf{i}}_j)). \quad (4)$$

## 2.4 群组长短期兴趣学习

### 2.4.1 群组长期兴趣表征

群组的长期兴趣表征  $\mathbf{g}_t^{\text{long}}$  可通过聚合组内成员的长期兴趣得到, 能够反映组内成员长期稳定的共同偏好。考虑到组内成员在群组中的影响力不同, 利用注意力机制计算组内成员的权重  $\alpha_p^{\text{long}}$ ,

$$\alpha_p^{\text{long}} = \frac{\exp(\mathbf{W}_\alpha \mathbf{u}_p^{\text{long}})}{\sum_{u_{p'} \in g_t} \exp(\mathbf{W}_\alpha \mathbf{u}_{p'}^{\text{long}})}, \quad (5)$$

$$\mathbf{g}_t^{\text{long}} = \sum_{u_p \in g_t} \alpha_p^{\text{long}} \mathbf{u}_p^{\text{long}}, \quad (6)$$

其中,  $\mathbf{u}_p^{\text{long}}$  为用户  $u_p$  的长期兴趣表征,  $\mathbf{u}_{p'}^{\text{long}}$  为组内其他用户的长期兴趣表征,  $\mathbf{W}_\alpha$  为可训练的参数矩阵。

### 2.4.2 群组短期兴趣表征

通过聚合组内成员的短期兴趣可得到群组的短期兴趣, 能够反映群组近期的偏好倾向。首先, 计算成员短期兴趣表征与群组长期兴趣表征之间的相似度  $s_p$  并确定组内成员的权重  $w_p$ ,

$$s_p = \text{Sim}(\mathbf{u}_p^{\text{short}}, \mathbf{g}_t^{\text{long}}) = \frac{\mathbf{u}_p^{\text{short}} \cdot \mathbf{g}_t^{\text{long}}}{\|\mathbf{u}_p^{\text{short}}\| \cdot \|\mathbf{g}_t^{\text{long}}\|}, \quad (7)$$

$$w_p = \frac{\exp(s_p)}{\exp\left(\sum_{p' \in g_t} s_{p'}\right)}, \quad (8)$$

其中,  $\mathbf{g}_t^{\text{long}}$  表示群组  $g_t$  的长期兴趣表征,  $\mathbf{u}_p^{\text{short}}$  表示组内成员  $u_p$  的短期兴趣表征,  $\text{Sim}(\cdot)$  为余弦相似度函数。

利用权重  $w_p$  对组内成员的短期兴趣表征进行加权融合, 可得到群组的短期兴趣表征  $\mathbf{g}_t^{\text{short}}$ ,

$$\mathbf{g}_t^{\text{short}} = \sum_{u_p \in g_t} w_p \cdot \mathbf{u}_p^{\text{short}}. \quad (9)$$

### 2.4.3 融合长短期兴趣的群组综合表征

将群组的长期兴趣表征  $\mathbf{g}_t^{\text{long}}$  与短期兴趣表征  $\mathbf{g}_t^{\text{short}}$  自适应融合, 形成群组的综合表征  $\mathbf{g}_t$ ,

$$\mathbf{g}_t = \alpha_t^{\text{long}} \cdot \mathbf{g}_t^{\text{long}} + \beta_t^{\text{short}} \cdot \mathbf{g}_t^{\text{short}}, \quad (10)$$

其中,  $\alpha_i^{\text{long}} = \sigma(\mathbf{g}_i^{\text{long}} \cdot \mathbf{W}_i^{\text{long}})$ ,  $\beta_i^{\text{short}} = \sigma(\mathbf{g}_i^{\text{short}} \cdot \mathbf{W}_i^{\text{short}})$ ,  $\mathbf{W}_i^{\text{long}}$ 、 $\mathbf{W}_i^{\text{short}}$  为可训练参数矩阵,  $\sigma$  为激活函数,  $\alpha_i^{\text{long}}$ 、 $\beta_i^{\text{short}}$  表示可学习权重。

## 2.5 长短期兴趣对比学习

为了更好地建群组长短期兴趣和短期兴趣之间的关联关系,本文设计了长短期兴趣对比学习,用于优化群组的长短期兴趣表征,其目标是最大化同一群组长短期兴趣表征之间的一致性。

具体来说,在优化群组长短期兴趣时,选取目标群组作为正样本( $\mathbf{g}_i^{\text{long}}$ ,  $\mathbf{g}_i^{\text{short}}$ ),其余群组为负样本( $\mathbf{g}_{i'}^{\text{long}}$ ,  $\mathbf{g}_{i'}^{\text{short}}$ ),确保群组的长期兴趣表征  $\mathbf{g}_i^{\text{long}}$  与其短期兴趣表征  $\mathbf{g}_i^{\text{short}}$  比跟其他群组的  $\mathbf{g}_{i'}^{\text{short}}$  更相似。参考 InfoNCF 对比损失函数<sup>[32]</sup>,定义优化长期兴趣的损失函数如下:

$$\text{Loss}_{\text{CL}}^{\text{long}} = - \sum_{\mathbf{g}_i \in G} \log \frac{\exp(\text{Sim}(\mathbf{g}_i^{\text{long}}, \mathbf{g}_i^{\text{short}})/\tau)}{\sum_{\mathbf{g}_{i'} \in G} \exp(\text{Sim}(\mathbf{g}_i^{\text{long}}, \mathbf{g}_{i'}^{\text{short}})/\tau)}, \quad (11)$$

其中  $\tau$  是温度参数。

类似地,定义优化群组短期兴趣的损失函数如下:

$$\text{Loss}_{\text{CL}}^{\text{short}} = - \sum_{\mathbf{g}_i \in G} \log \frac{\exp(\text{Sim}(\mathbf{g}_i^{\text{short}}, \mathbf{g}_i^{\text{long}})/\tau)}{\sum_{\mathbf{g}_{i'} \in G} \exp(\text{Sim}(\mathbf{g}_i^{\text{short}}, \mathbf{g}_{i'}^{\text{long}})/\tau)}, \quad (12)$$

结合以上 2 种损失函数,得到群组长短期兴趣对比学习损失函数,

$$\text{Loss}_{\text{CL}} = \text{Loss}_{\text{CL}}^{\text{long}} + \text{Loss}_{\text{CL}}^{\text{short}}. \quad (13)$$

## 2.6 模型预测与优化

通过对群组与项目表征进行内积运算,得出项目的预测得分  $\hat{y}_{iq}$ ,

$$\hat{y}_{iq} = (\mathbf{g}_i)^T \mathbf{i}_q^*, \quad (14)$$

其中,  $\mathbf{g}_i$  表示群组的综合表征,  $\mathbf{i}_q^*$  表示候选项目的综合表征。

模型采用多任务学习联合优化推荐损失与对比学习损失<sup>[33-34]</sup>,推荐损失采用贝叶斯个性化排名(Bayesian personalized ranking, BPR)方法,

$$\text{Loss}_{\text{BPR}} = \sum_{(i, q, q') \in O} -\ln \sigma(\hat{y}_{iq} - \hat{y}_{iq'}), \quad (15)$$

其中:  $\sigma$  为激活函数;  $O$  表示群组  $g_i$  采样的群组—项目训练集,即群组  $g_i$  与项目  $i_q$  发生了交互,但还未与项目  $i_{q'}$  发生交互。

最后,将对比学习损失  $\text{Loss}_{\text{CL}}$  与推荐损失  $\text{Loss}_{\text{BPR}}$  相结合,得到联合优化的总损失  $\text{Loss}$ ,

$$\text{Loss} = \text{Loss}_{\text{BPR}} + \lambda_1 \text{Loss}_{\text{CL}} + \lambda_2 \|\Theta\|_2^2, \quad (16)$$

其中,  $\lambda_1$  是控制对比学习损失的超参数,  $\lambda_2$  是正则化系数,  $\Theta$  表示模型的可训练参数。

## 3 实验结果与分析

本章将在 MovieLens 和 Tmall 2 个数据集上进行实验并对实验结果进行分析。实验主要验证 3 个研究问题。RQ1:本文模型是否优于其他对比模型? RQ2:本文模型的关键组成部分对模型的性能有什么影响? RQ3:本文模型的超参数对性能有何影响?

### 3.1 实验数据集

MovieLens-1M 数据集(<https://grouplens.org/datasets/movielens/>)是由 GroupLens 研究小组收集并创建的一个电影数据集,由用户的观影记录和电影的属性组成,每条观影记录均包含用户的观影时间。Tmall 数据集(<https://tianchi.aliyun.com/dataset/53>)来自 IJCAI-16 大赛,由用户的购物记录和商品的属性信息组成,用户的购物记录中附有用户购物的时间信息。数据集的信息如表 1 所示。

表 1 实验数据集

Table 1 Experimental datasets

数据集	用户个数	项目个数	用户项目交互数	项目属性	数据集稀疏性/%
MovieLens-1M	6 040	3 416	1 000 209	电影题材	95.21
Tmall	96 392	907 209	4 458 309	商品类别、商品卖家	99.90

参考现有融合长短期兴趣的推荐算法<sup>[15,25,27]</sup>,本文基于用户完整的历史交互记录来挖掘用户的长期兴趣,同时,从完整的历史交互记录中选取最近的 20%作为短期交互序列,并从中挖掘用户的短期兴趣。

### 3.2 评价指标

本文采用 2 个指标来评估 Top- $K$  群组推荐性能,分别是命中率(hit ratio, HR)和归一化折损累计增益(normalized discounted cumulative gain, NDCG)。HR 和 NDCG 越高证明推荐系统性能越好。

1) HR:推荐的项目中实际被接受的项目所占的比例。具体计算公式如下:

$$HR@K = \frac{\#hit@K}{|D_{test}|}, \quad (17)$$

其中, #hit@ $K$  表示测试集中项目的命中次数,  $|D_{test}|$  表示测试用例的总数。

2) NDCG:评估推荐系统中排名列表的准确性。具体计算公式如下:

$$NDCG@K = \frac{DCG@K}{\max DCG@K}, \quad (18)$$

其中,  $DCG@K = \sum_{i=1}^K \frac{2^{rel_i} - 1}{\log_2(i+1)}$ ,  $rel_i$  是项目  $i$  的相关性得分。

### 3.3 参数设置

本文模型 ALSTG 的嵌入维度为 32,训练批量大小为 512,学习率为 0.001,图卷积层数为 2,恒温参数  $\tau$  为 1.0,将 Adam 作为优化器优化模型,使用 Xavier 作为网格参数初始化方法,推荐列表长度  $K$  设置为 5 和 10。

### 3.4 对比模型

对比模型可根据其所使用的主要技术分为 5 类:非个性化群组推荐模型、基于神经网络的群组推荐模型、基于注意力机制的群组推荐模型、基于图神经网络的群组推荐模型和基于超图网络的群组推荐模型。下面列举每类对比模型中的典型推荐模型并进行说明。

非个性化群组推荐模型:POP<sup>[35]</sup>

基于神经网络的群组推荐模型:NCF<sup>[36]</sup>

基于注意力机制的群组推荐模型:AGREE<sup>[37]</sup>

基于图神经网络的群组推荐模型:HetGRec<sup>[38]</sup>、XCL-GR<sup>[39]</sup>

基于超图网络的群组推荐模型:HCR<sup>[28]</sup>、ConRec<sup>[7]</sup>

1) POP<sup>[35]</sup>:该模型是一种经典的非个性化推荐方法,根据项目的受欢迎程度向用户和群组推荐项目。

2) NCF<sup>[36]</sup>:该模型将群组视为虚拟用户,使用神经协同过滤的方法对虚拟用户进行预测。

3) AGREE<sup>[37]</sup>:该模型利用注意力机制聚合群组内的用户表征形成群组表征。

4) HCR<sup>[28]</sup>:该模型通过一个双通道超图卷积网络来捕获群组的成员级和群组级的偏好,并将两类偏好融合得到群组的最终偏好。

5) ConRec<sup>[7]</sup>:该模型分别从成员级、项目级和群组级视图中捕获群组的偏好,通过自适应融合三个视图下的群组偏好得到群组最终偏好。

6) HetGRec<sup>[38]</sup>:该模型通过一个双层次的图注意力网络来学习群组和用户的表征,并利用自监督学习缓解数据稀疏问题。

7) XCL-GR<sup>[39]</sup>:该模型构建了群组—项目、用户—项目和群组—成员 3 个视图,并通过多视图对比学习和注意力机制得到群组的综合表征,以提高群组表征质量。

### 3.5 对比实验结果及分析(RQ1)

本文 ALSTG 模型和对比模型在 2 个数据集上的实验结果如表 2 所示。

由表 2 可知,在所有的推荐模型中,性能表现最差的为 POP 模型,因为该模型是根据项目的受欢迎程度进行推荐,忽略了组内成员的个人偏好。NCF 模型的性能要强于 POP 模型,主要是因为该模型通过用户—项目的交互记录建模用户偏好,并采用预定义策略将成员表征聚合为群组表征。然而,预定义聚合策略忽略了成员权重在偏好聚合过程中的影响,导致推荐效果受限。相比于 NCF 模型,AGREE、HCR 和 HetGRec 采用注意力机制聚合成员表征,具有一定的性能优势。由于 ConRec 模型在获取群组表征时考虑了群组和项

目表征之间的联系,具有较好的推荐效果。XCL-GR 模型通过多视图对比学习对群组表征进行增强,有效提升模型性能。本文所提的 ALSTG 模型,在两个公开数据集上都表现出最好的性能。这是因为:1) 在学习用户和项目的表征时加入了项目的属性信息,丰富了表征的信息量,使建模效果得到提升;2) 结合长短期兴趣建模群组偏好,有助于增强群组的表征质量,提升模型的推荐性能。

表 2 不同  $K$  值下各模型在数据集上的实验结果

Table 2 Experimental results of each model on datasets under different  $K$  values

数据集	模型	HR@ 5	HR@ 10	NDCG@ 5	NDCG@ 10
MovieLens-1M	POP	0.173 0	0.265 8	0.049 1	0.101 3
	NCF	0.302 9	0.373 0	0.086 3	0.153 1
	AGREE	0.322 6	0.412 7	0.156 9	0.208 7
	HCR	0.391 2	0.461 0	0.201 6	0.267 0
	ConsRec	0.403 5	0.483 9	0.216 8	0.302 1
	HetGRec	0.400 1	0.477 0	0.212 7	0.280 2
	XCL-GR	0.392 8	0.471 2	0.214 8	0.281 3
	ALSTG	0.416 8	0.503 7	0.222 7	0.311 0
Tmall	POP	0.102 5	0.172 6	0.067 1	0.083 2
	NCF	0.122 5	0.192 8	0.075 2	0.095 1
	AGREE	0.136 8	0.210 2	0.087 4	0.102 8
	HCR	0.160 3	0.226 0	0.105 1	0.122 0
	ConsRec	0.173 4	0.259 7	0.113 4	0.133 5
	HetGRec	0.169 0	0.246 9	0.109 2	0.127 3
	XCL-GR	0.170 2	0.261 3	0.105 7	0.136 4
	ALSTG	0.180 2	0.268 5	0.120 3	0.138 0

### 3.6 消融实验及结果分析 (RQ2)

为了验证项目属性信息、群组短期兴趣和对比学习方法对模型性能的影响,设计了 3 个变体模型,如表 3 所示。

表 3 ALSTG 及其变体模型介绍

Table 3 Introduction of ALSTG and its variant models

模型	项目属性信息	长期兴趣	短期兴趣	对比学习
ALSTG-A		✓	✓	✓
ALSTG-S	✓	✓		
ALSTG-C	✓	✓	✓	
ALSTG	✓	✓	✓	✓

消融实验的 3 个变体模型介绍如下。

- 1) ALSTG-A:该模型忽略了项目属性信息,只考虑群组的长短期兴趣和对比学习模块。
- 2) ALSTG-S:该模型忽略了群组短期兴趣,只考虑项目的属性信息和群组的长期兴趣。
- 3) ALSTG-C:该模型去掉了对比学习模块,只考虑项目的属性信息和群组的长短期兴趣。

#### 3.6.1 项目属性信息的有效性

ALSTG 模型相较于 ALSTG-A 模型性能有所提升,说明在学习用户和项目表征的过程中加入项目属性信息,可以丰富节点表征的信息量,从而提升模型性能。实验结果如图 2 所示。

#### 3.6.2 群组短期兴趣的有效性

ALSTG 模型相较于 ALSTG-S 模型性能有所提升,说明考虑群组短期动态兴趣,有助于更加全面、细致地建模群组表征,进而改善推荐效果。实验结果如图 3 所示。

为了直观展示群组短期兴趣的有效性,从 MovieLens-1M 数据集中选取了 5 个群组作为样本,分别使用 ALSTG 模型和 ALSTG-S 模型为这 5 个群组生成 Top-10 项目推荐列表。通过比较推荐列表与群组真实交互过的项目,得到 ALSTG 模型和 ALSTG-S 模型的命中率,如表 4 所示,其中带下划线的项目表示群组实际交互过的项目。




图2 MovieLens-1M 和 Tmall 数据集项目属性有效性评估

Fig.2 Evaluation of item attribute effectiveness on MovieLens-1M and Tmall datasets




图3 MovieLens-1M 和 Tmall 数据集短期兴趣有效性评估

Fig.3 Evaluation of short-term interest effectiveness on MovieLens-1M and Tmall datasets

表4 MovieLens-1M 数据集中5个样本群组对应的推荐列表

Table 4 The recommendation list corresponding to five sample groups on MovieLens-1M dataset

群组	模型	推荐列表	命中率
群组 1	ALSTG	[ <u>16</u> , 78, 29, <u>296</u> , <u>1193</u> , 1097, 745, <u>2762</u> , 1022, 648]	0.5
	ALSTG-S	[2628, 1103, <u>16</u> , 236, <u>745</u> , <u>296</u> , 1188, 3256, <u>296</u> , 2490]	0.4
群组 2	ALSTG	[ <u>104</u> , 2735, 1210, 1431, <u>3268</u> , <u>2997</u> , 260, 2858, <u>1261</u> , 1266]	0.4
	ALSTG-S	[ <u>104</u> , 3385, 726, <u>3268</u> , 2036, 85, <u>2997</u> , <u>1261</u> , 693, 1266]	0.4
群组 3	ALSTG	[ <u>349</u> , <u>562</u> , 2329, 1810, <u>2541</u> , <u>3411</u> , <u>1027</u> , 282, <u>36</u> , 2699]	0.6
	ALSTG-S	[2211, <u>349</u> , <u>2329</u> , 625, 749, <u>3411</u> , 282, 1036, 1742, 2569]	0.3
群组 4	ALSTG	[318, 608, <u>1356</u> , 1358, 1210, 3321, <u>1500</u> , 2959, 912, <u>778</u> ]	0.5
	ALSTG-S	[318, 236, <u>1500</u> , <u>1356</u> , 721, 694, 912, <u>778</u> , 1210, 2436]	0.4
群组 5	ALSTG	[2628, <u>1682</u> , <u>1756</u> , 1320, <u>2054</u> , 1252, 653, 1831, <u>587</u> , <u>586</u> ]	0.5
	ALSTG-S	[653, <u>2054</u> , <u>2067</u> , <u>1756</u> , <u>586</u> , 2135, 1265, <u>587</u> , 1339, 1320]	0.4

在表4所示的5个样本群组推荐列表中,ALSTG模型在4个样本群组上的命中率均高于ALSTG-S模型,在1个样本群组上的命中率与之持平,说明考虑群组的短期兴趣可有效提升模型的推荐性能。

### 3.6.3 对比学习的有效性

ALSTG模型相较于ALSTG-C模型性能有所提升,说明利用对比学习可以有效增强群组的长、短期兴趣表征,达到优化群组表征质量的目的。实验结果如图4所示。




图4 MovieLens-1M 和 Tmall 数据集对比学习有效性评估

Fig.4 Evaluation of contrastive learning effectiveness on MovieLens-1M and Tmall datasets

### 3.7 参数分析(RQ3)

#### 3.7.1 嵌入维度

嵌入维度的大小对推荐效果有一定的影响,维度过低使模型的表达能力不足,维度过高容易导致过拟合。为了说明嵌入维度对 ALSTG 模型性能的影响,分别设嵌入维度为[8,16,32,64,128],进行实验对比,实验结果如图5所示。




图5 不同嵌入维度下的实验结果  
Fig.5 Experimental results under different embedding dimensions

由图5可知,当嵌入维度从8到32时,HR和NDCG均逐渐提高;但是随着维度继续增加,HR和NDCG开始逐渐下降。因此,选择32作为ALSTG模型的嵌入维度。

#### 3.7.2 卷积层数

卷积层数会直接影响图卷积神经网络的性能,随着卷积层数的增加,卷积网络面临过平滑的问题。为了说明卷积层数对ALSTG模型性能的影响,卷积层数分别设为[1,2,3,4]进行实验,实验结果如图6所示。




图6 不同卷积层数下的实验结果  
Fig.6 Experimental results under different convolution layers

由图6可知,当卷积层数为2时,HR和NDCG达到最大值,因此,选择2作为ALSTG模型的卷积层数。

## 4 结论

本文提出的ALSTG模型通过将项目属性信息融入表征学习过程中来丰富节点表征的信息量,进而从长短期兴趣2个角度对群组进行建模,能够更好地理解并学习群组的复杂偏好,有效弥补现有研究在捕捉群组动态兴趣变化方面的不足。在此基础上,结合长短期兴趣对比学习,实现群组表征的进一步优化。在两个公共数据集上的实验表明,ALSTG模型可以显著提升群组推荐的性能。然而,本文所提方法也存在一定的局限性,如未考虑社交关系对成员偏好建模及群组偏好聚合的影响。在未来,将尝试利用大语言模型捕捉用户、群组和项目之间潜藏的语义关系,并结合多模态融合技术进一步丰富和增强群组及项目的表征,获得更具解释性的推荐结果,提升群组用户的满意度。

#### 参考文献:

[1] SHYAM A, KUMAR V, KAGITA V R, et al. UniRecSys: a unified framework for personalized, group, package, and package-

- to-group recommendations[J]. *Knowledge-Based Systems*, 2024, 289:111552.
- [2] FU Shengxi, REN Qianqian, LYU Xingfeng, et al. Multi-behavior recommendation with SVD graph neural networks[J]. *Expert Systems with Applications*, 2024, 249:123575.
- [3] HU Zheng, CAI Shi-Min, WANG Jun, et al. Collaborative recommendation model based on multi-modal multi-view attention network: movie and literature cases[J]. *Applied Soft Computing*, 2023, 144:110518.
- [4] MENG Lingqiang, LIU Zhizhong, CHU Dianhui, et al. POI recommendation for occasional groups based on hybrid graph neural networks[J]. *Expert Systems with Applications*, 2024, 237:121583.
- [5] GUO Lei, YIN Hongzhi, CHEN Tong, et al. Hierarchical hyperedge embedding-based representation learning for group recommendation[J]. *ACM Transactions on Information Systems*, 2021, 40(1):1-27.
- [6] YANG Mingdai, LIU Zhiwei, YANG Liangwei, et al. Ranking-based group identification via factorized attention on social tripartite graph[C]// *Proceedings of the 16th ACM International Conference on Web Search and Data Mining*. Singapore: ACM, 2023:769-777.
- [7] WU Xixi, XIONG Yun, ZHANG Yao, et al. Consrec: learning consensus behind interactions for group recommendation[C]// *Proceedings of the ACM Web Conference 2023*. Texas: ACM, 2023:240-250.
- [8] SANKAR A, WU Y H, WU Y H, et al. Groupim: a mutualinformation maximization framework for neural group recommendation[C]// *Proceedings of the 43rd International ACM SIGIR conference on research and development in Information Retrieval*. Xi'an: ACM, 2020:1279-1288.
- [9] GUO Lei, YIN Hongzhi, WANG Qinyong, et al. Group recommendation with latent voting mechanism[C]// *Proceedings of the 36th International Conference on Data Engineerin*. Dallas: IEEE, 2020:121-132.
- [10] HE Z X, CHOW C Y, ZHANG J D. GAME: learning graphical and attentive multi-view embeddings for occasional group recommendation[C]// *Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval*. Xi'an: ACM, 2020:649-658.
- [11] ZHENG Xiaolin, TAN Yanchao, WANG Yan, et al. Finding high-quality item attributes for recommendation[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2022, 35(8):7980-7993.
- [12] HUANG Ling, CHEN Biyi, YE Haiyi, et al. DIAG: a deep interaction-attribute-generation model for user-generated item recommendation[J]. *Knowledge-Based Systems*, 2022, 243:108463.
- [13] XU Li, ZENG Jun, PENG Weile, et al. Modeling and predicting user preferences with multiple item attributes for sequential recommendations[J]. *Knowledge-Based Systems*, 2023, 260:110174.
- [14] SANJAY K, PERVIN N. Integration of short and long-term interests: a preference aware session-based recommender[J]. *Neurocomputing*, 2024, 583:127558.
- [15] FU Jiarun, GAO Rong, YU Yonghong, et al. Contrastive graph learning long and short-term interests for POI recommendation[J]. *Expert Systems with Applications*, 2024, 238:121931.
- [16] SONG Jing, SHEN Hong, OU Zijing, et al. ISLF: interest shift and latent factors combination model for session-based recommendation[C]// *Proceedings of the 28th International Joint Conference on Artificial Intelligence*. Macao: AAAI, 2019: 5765-5771.
- [17] ZHAO Na, LONG Zhen, WANG Jian, et al. AGRE: a knowledge graph recommendation algorithm based on multiple paths embeddings RNN encoder[J]. *Knowledge-Based Systems*, 2023, 259:110078.
- [18] YU Dongjin, YU Ting, WANG Dongjing, et al. Long tail service recommendation based on cross-view and contrastive learning[J]. *Expert Systems with Applications*, 2024, 238:121957.
- [19] WANG Yu, ZHAO Yuying, ZHANG Yi, et al. Collaboration-aware graph convolutional network for recommender systems [C]// *Proceedings of the ACM Web Conference 2023*. Texas: ACM, 2023:91-101.
- [20] ZENG Biqing, CHI Junlong, HONG Peilin, et al. Context-aware graph embedding with gate and attention for session-based recommendation[J]. *Neurocomputing*, 2024, 574:127221.
- [21] XIA Lianghao, HUANG Chao, XU Yong, et al. Hypergraph contrastive collaborative filtering[C]// *Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval*. Madrid: ACM, 2022:70-79.
- [22] WU Xixi, XIONG Yun, ZHANG Yao, et al. Dual intents graph modeling for user-centric group discovery[C]// *Proceedings of the 32nd ACM International Conference on Information and Knowledge Management*. Birmingham: ACM, 2023:2716-2725.
- [23] GU Shuyun, WANG Xiao, SHI Chuan, et al. Self-supervised graph neural networks for multi-behavior recommendation[C]// *Proceedings of the 30th International Joint Conference on Artificial Intelligence*. Montreal: Morgan Kaufmann, 2022:2052-

2058.

- [24] YANG Yuhao, HUANG Chao, XIA Lianghao, et al. Knowledge graph contrastive learning for recommendation [C] // Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. Madrid: ACM, 2022:1434-1443.
- [25] ZHAO Pengpeng, LUO Anjing, LIU Yanchi, et al. Where to go next: a spatio-temporal gated network for next POI recommendation [J]. IEEE Transactions on Knowledge and Data Engineering, 2020, 34(5):2512-2524.
- [26] YAN Cairong, WANG Yiwei, ZHANG Yanting, et al. Modeling long and short-term user behaviors for sequential recommendation with deep neural networks [C] // 2021 International Joint Conference on Neural Networks. Rome: IEEE, 2021:1-8.
- [27] WU Shu, TANG Yuyuan, ZHU Yanqiao, et al. Session-based recommendation with graph neural networks [C] // Proceedings of the AAAI Conference on Artificial Intelligence. Vancouver: AAAI, 2019, 33(1):346-353.
- [28] JIA Renqi, ZHOU Xiaofei, DONG Linhua, et al. Hypergraph convolutional network for group recommendation [C] // 2021 IEEE International Conference on Data Mining. Auckland: IEEE, 2021:260-269.
- [29] FENG Yifan, YOU Haoxuan, ZHANG Zizhao, et al. Hypergraph neural networks [C] // Proceedings of the AAAI Conference on Artificial Intelligence. Vancouver: AAAI, 2019:3558-3565.
- [30] WU F, SOUZA A H, ZHANG T Y, et al. Simplifying graph convolutional networks [C] // International Conference on Machine Learning. California: ACM, 2019:6861-6871.
- [31] HE Xiangnan, DENG Kuan, WANG Xiang, et al. Lightgcn: simplifying and powering graph convolution network for recommendation [C] // Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. Xi'an: ACM, 2020:639-648.
- [32] GUTMANN M, HYVARINEN A. Noise-contrastive estimation: a new estimation principle for unnormalized statistical models [C] // Proceedings of the 13th International Conference on Artificial Intelligence and Statistics. Sardinia: JMLR, 2010:297-304.
- [33] HE Wei, SUN Guohao, LU Jinhu, et al. Candidate-aware graph contrastive learning for recommendation [C] // Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval. Taipei: ACM, 2023:1670-1679.
- [34] YU Junliang, YIN Hongzhi, XIA Xin, et al. Are graph augmentations necessary? Simple graph contrastive learning for recommendation [C] // Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. Madrid: ACM, 2022:1294-1303.
- [35] CREMONESI P, KOREN Y, TURRIN R. Performance of recommender algorithms on top-n recommendation tasks [C] // Proceedings of the 4th ACM Conference on Recommender Systems. Barcelona: ACM, 2010:39-46.
- [36] HE Xiangnan, LIAO Lizi, ZHANG Hanwang, et al. Neural collaborative filtering [C] // Proceedings of the 26th International Conference on World Wide Web. Perth: ACM, 2017:173-182.
- [37] CAO Da, HE Xiangnan, MIAO Lianhai, et al. Attentive group recommendation [C] // The 41st International ACM SIGIR Conference on Research and Development in Information Retrieval. Ann Arbor: ACM, 2018:645-654.
- [38] ZHANG Song, ZHENG Nan, WANG Danli. HetGRec: heterogeneous graph attention network for group recommendation [J]. IEEE Intelligent Systems, 2022, 38(1):9-18.
- [39] HONG T, IBRAHIM N F. Group recommendation fueled by noise-based graph contrastive learning [J]. Journal of King Saud University-Computer and Information Sciences, 2024, 36(5):102063.

(编辑:李艺)