

时态信息增强的多样化推荐算法*

袁冠^{1,2}, 曾翔宇¹, 张桂銜¹, 张艳梅¹, 张宇航¹, 杨佩锦¹

¹(中国矿业大学 计算机科学与技术学院/人工智能学院, 江苏 徐州 221116)

²(矿山数字化教育部工程研究中心 (中国矿业大学), 江苏 徐州 221116)

通信作者: 袁冠, E-mail: yuanguan@cumt.edu.cn



摘要: 近年来, 基于图神经网络 (graph neural network, GNN) 的推荐系统能够很好地利用交互数据的交互结构来学习用户和项目表示。然而, 现有的基于图神经网络的推荐模型在聚合过程中往往忽略了交互的时态信息, 从而难以建模用户兴趣变化特征, 导致推荐模型对数据产生过度拟合, 造成推荐结果缺乏多样性, 难以满足用户更加多样化的需求。针对上述问题, 提出了一种时态信息增强的多样化推荐模型。首先, 利用注意力机制来捕获历史用户-物品交互中的时态信息和交互结构信息并融合。同时, 为降低特征冗余并提高表示辨识度, 设计了特征分离模块, 将平滑的全局特征与突出且具有判别力的关键信号进行解耦。然后, 通过邻居选择来突出节点间的差异并进行图卷积, 利用层注意力机制来缓解过平滑问题。最后, 通过重加权损失增强对长尾类别项目的学习以增强多样性。通过在两个数据集上的大量实验验证, 结果表明所提方法可以在实现最佳多样性的同时, 保持较高的准确性。

关键词: 图神经网络; 推荐系统; 多样性; 时态信息; 深度学习; 表示学习

中图分类号: TP18

中文引用格式: 袁冠, 曾翔宇, 张桂銜, 张艳梅, 张宇航, 杨佩锦. 时态信息增强的多样化推荐算法. 软件学报. <http://www.jos.org.cn/1000-9825/7577.htm>

英文引用格式: Yuan G, Zeng XY, Zhang GX, Zhang YM, Zhang YH, Yang PJ. Temporal-information-enhanced Diversified Recommendation Algorithm. Ruan Jian Xue Bao/Journal of Software (in Chinese). <http://www.jos.org.cn/1000-9825/7577.htm>

Temporal-information-enhanced Diversified Recommendation Algorithm

YUAN Guan^{1,2}, ZENG Xiang-Yu¹, ZHANG Gui-Xian¹, ZHANG Yan-Mei¹, ZHANG Yu-Hang¹, YANG Pei-Jin¹

¹(School of Computer Science and Technology/School of Artificial Intelligence, China University of Mining and Technology, Xuzhou 221116, China)

²(Mine Digitization Engineering Research Center of the Ministry of Education (China University of Mining and Technology), Xuzhou 221116, China)

Abstract: In recent years, recommender systems based on graph neural network (GNN) have made good use of the interaction structure of interaction data to learn user and item representations. However, existing recommendation models based on GNN often ignore the temporal information of interactions during aggregation, which makes it difficult to model the change characteristics of users' interests. As a result, this causes overfitting of the recommendation model to data, and a lack of diversity in the recommendation results, thereby making it difficult to satisfy the more diversified needs of users. To this end, a temporal information-enhanced diversified recommendation model is proposed. First, an attention mechanism is employed to capture and fuse temporal information and interaction information from historical user-item interactions. Meanwhile, a feature disentanglement module is designed to disentangle smoothed global features from salient, highly discriminative key signals to reduce feature redundancy and improve representational clarity. Subsequently, neighbour selection is adopted to highlight inter-node differences and conduct graph convolution, with a layer attention mechanism employed to alleviate over smoothing. Finally, the learning of items in the long-tail category is enhanced by reweighting loss to improve the diversity.

* 基金项目: 中央高校基本科研业务费专项资金 (2024-10949); 江苏省研究生科研与实践创新计划 (KYCX24_2781); 徐州市重点研发计划 (KC23296); 徐州市科技基金 (KC22047); 中国矿业大学研究生创新计划 (2024WLKXJ183)

收稿时间: 2025-07-22; 修改时间: 2025-10-10; 采用时间: 2025-11-27; jos 在线出版时间: 2026-02-04

Key words: graph neural network (GNN); recommender system; diversity; temporal information; deep learning; representation learning

当前,互联网、物联网各类智能终端的应用层出不穷,带来了数据的爆炸式增长,用户难以迅速获得与自己兴趣或需求相契合的信息.为了解决信息过载问题,推荐系统应运而生并逐渐发展壮大^[1],成为当代在大量数据中减轻信息过载的重要方案.当前,推荐系统已经深入生活各个方面,如新闻推送^[2]、每日歌单^[3]以及购物推荐^[4-6]等.推荐系统通过从历史数据中获得用户潜在的偏好,基于此提供关于项目的个性化建议.

准确性通常是推荐系统衡量用户与待推荐物品交互可能性的首要指标,这些算法根据用户的历史互动来预测最有可能吸引每个用户的项目.然而,一个好的推荐系统应该从多个角度进行评估,例如公平性^[7]、可解释性^[8]、轻量化^[9]、多样性^[10]、安全性^[11]等.过于追求准确性会导致推荐结果同质化严重,会带来信息茧房、推荐结果单一等问题^[12],即用户反复暴露与他们的偏好相一致的内容,限制了他们对不同项目进行交互的可能.为了解决这些问题,推荐系统的多样化得到越来越多的关注.多样化的推荐系统通过捕捉用户的不同兴趣,增强待推荐项目的差异性,满足用户多元化的需要.然而,多样性和准确性对于推荐系统来说是两个相互冲突的指标,过于优化多样性也会导致准确性的降低,因此,也产生了准确性和多样性难以平衡的困境^[13].综上所述,多样性推荐系统的目的是希望在尽可能保证准确性的前提下,提高推荐系统的多样性^[14].

近年来,图神经网络在处理非欧氏数据方面取得突出效果,吸引了越来越多的推荐系统研究者的注意.在推荐系统中,基于图神经网络 GNN (graph neural network) 的模型将用户的历史交互表示为用户-项目二部图,其中用户和项目是两个不同的集合,边表示用户对项目的某种形式的交互(如评分、购买、浏览等).图神经网络可以轻松获取节点之间的高阶连通性,通过这种形式可以帮助模型不仅理解用户对单个项目的偏好,还能理解用户通过多个项目表现出来的潜在偏好和行为模式.然而,当前基于 GNN 的多样化推荐模型^[10,15]在聚合过程中普遍忽视了用户行为的时态信息,导致了模型无法有效捕捉用户兴趣的动态变化.

用户兴趣的动态变化是推荐系统面临的一个关键挑战.随着时间的推移,用户的兴趣和偏好可能会发生显著变化,而现有的推荐模型往往无法捕捉这种时态顺序上的细微差别.忽视时态信息将导致推荐结果失去时效性,无法反映用户最新的兴趣点和用户兴趣的差异.这种局限性不仅影响了推荐结果的多样性,也削弱了推荐系统对新兴趋势的响应能力,从而降低用户满意度.实际上,如何在用户的交互序列中实现兼顾准确性与多样性的推荐,目前正在成为该领域的一个重要前沿方向^[16].

鉴于此,引入时态信息对于构建一个能够适应用户兴趣变化的多样化推荐系统至关重要.通过融合时态信息,我们可以更好地提高推荐系统对用户需求变化的敏感度.本文通过一个示例(图1)来说明时态信息在图神经网络推荐系统中的重要性.




图1 时态信息对多样性推荐系统的意义

图1基于用户与项目交互记录构建了两个二部图:一个仅基于交互结构信息进行聚合的用户-项目二部图,另一个则基于时态信息和交互结构信息进行聚合的用户-项目二部图.在仅考虑交互结构信息的聚合过程中,用户 Amy 和用户 Judy 的聚合邻居嵌入是完全相同的,因为他们的交互项目列表完全相同.因此,在推荐物品时, Amy 和 Judy 得到的推荐列表是相同的.然而,当本文将时态信息纳入聚合过程时,尽管 Amy 和 Judy 的交互项目列表

依然相同,但他们因个人情况导致交互发生的时间点不同,我们可以利用用户与物品交互的时态信息使得他们的聚合邻居嵌入产生差异.这种差异对于捕捉用户的动态兴趣变化至关重要,可以更加准确地反映用户的偏好与兴趣.因此,有必要为推荐算法引入时态信息以提高推荐结果的多样性.

为了解决这个问题,本文提出了一种基于时态信息增强的多样化推荐 (temporal information enhanced diversified recommendation, TIEDRec) 算法. TIEDRec 不仅依赖交互结构来聚合邻居的信息,还将时态信息集成到邻居嵌入学习中,进而得到更高质量的用户-项目特征,提升推荐系统的多样性.首先,从时态信息和交互结构信息两个维度出发,利用注意力机制^[17]来捕捉历史交互数据中的时态特征和交互结构特征.并在聚合阶段引入特征分离模块,将平滑的全局特征与突出且具有判别力的关键信号进行解耦,以降低特征冗余并增强表示辨识度.然后,对节点的聚合邻域集合进行多样化选择,突显节点间的差异,寻找更多样化的邻居进行聚合,并使用层注意力机制让中心节点直接获取高阶邻居的信息.在保证推荐模型的多样性的同时,缓解直接堆叠层数导致的过平滑问题.最后,通过重加权损失增强对长尾类别项目的学习,从而增强多样性.综上所述,本文的主要工作包括如下几个方面.

(1) 提出一种融合时态信息与特征解耦的多样化推荐 (TIEDRec) 模型.该模型利用多头注意力机制捕捉用户与项目交互中的时序动态,并设计特征解耦模块将学习到的表示分离为平滑的全局特征与突出的局部信号.此设计不仅解决了现有 GNN 模型忽视时态信息的局限,还通过增强表示辨识度,为后续多样化推荐奠定了坚实基础.

(2) 设计一套协同提升多样性与准确性的聚合及优化策略.在聚合阶段,提出一种贪心邻居选择算法,以主动构建信息更丰富的多样化邻居集.在损失函数层面,对经典的 BPR 损失进行可调节的重加权,显著提升模型对长尾项目的关注度.这一系列设计共同作用,有效缓解了推荐系统中“准确性-多样性”对立的困境.

(3) 在真实数据集上进行了充分的实验,实验结果表明 TIEDRec 相较同类方法有效提高了多样性和准确性.

1 多样性推荐相关工作

1.1 基于深度学习的推荐算法

近年来,神经网络在推荐系统领域引发了广泛关注和深入研究^[17],成为学术界的一大热点.其核心目标在于运用先进的深度学习技术,提升推荐算法的性能,以提供更精准、个性化的推荐服务.神经网络通过非线性特征建模^[18],能够捕捉更为复杂的用户与项目关系,从而生成更为丰富和准确的推荐结果.现有的工作多通过映射用户(项目)的现有特征来生成其深层嵌入表示.例如,Xue 等人^[19]提出的神经网络结构,将融合了显式评分和非偏好隐式反馈的用户项目矩阵作为输入,利用深层网络学习架构构建用户和项目的公共低维空间,并通过设计基于二元交叉熵的损失函数来优化性能.Xiao 等人^[20]利用注意力机制从用户的浏览和搜索记录中提取多个兴趣点,以丰富用户特征表示,为用户提供更加精准的推荐.类似地,在基于会话的推荐中,注意力网络也被用来有效捕捉短期交互中物品之间的复杂关系^[21].石美惠等人^[22]利用全局特征与局部特征融合的方法实现下一个兴趣点推荐.然而,许多传统的深度学习推荐模型忽略了用户兴趣的时态变化,导致模型无法及时捕捉用户兴趣的动态变化.近年来,时态信息的引入逐渐成为深度学习推荐系统中的一个研究热点.通过考虑用户行为数据中的时间戳,时态推荐系统能够更好地捕捉用户兴趣随时间的变化,避免了传统模型对历史交互的静态处理,从而提高了推荐的准确性和多样性.时序推荐系统通过融入时态信息,将用户历史交互转化为带有时间序列特征的图结构.这样,系统不仅能够基于用户历史行为进行推荐,还能有效捕捉兴趣变化的动态性.基于时态信息的深度学习推荐算法能够精确建模用户的短期和长期兴趣,优化推荐系统的整体表现,确保推荐结果更符合用户当前的需求和兴趣演变.例如,Kang 等人^[23]提出了基于自注意力机制的时序推荐模型 SASRec,该模型通过建模用户行为的时间顺序,准确预测用户兴趣变化.Sun 等人^[24]引入了 BERT4Rec 模型,将 BERT 应用于推荐系统,利用双向自注意力机制捕捉用户兴趣的长短期变化,从而提升推荐的准确性和多样性.

用户和项目的历史交互数据可以很轻松地转化为图数据,这使得针对图数据设计的图神经网络广泛应用在推荐系统之中并取得了杰出效果.通过将用户的历史交互表示为用户-项目二部图,可以轻松获取它们的高阶连通性,进而深入理解用户的偏好和行为模式.比较典型的模型,NGCF^[25]利用图卷积的信息传播特性,从用户-项目二部图

中学习高阶连通性进行推荐; LightGCN^[26]通过简化 NGCF 中的计算开销,提高了性能和训练速度,实现了更为高效的推荐; LR-GCCF^[27]关注到图神经网络在非线性激活的训练困难和层数加深的过平滑问题,通过去除非线性激活和残差链接提高了训练效果.在此基础上, Chen 等人^[27]提出了一种残差网络结构,缓解了图卷积聚合操作中的过度平滑问题进而提高效率.赵容梅等人^[28]提出了一种基于对比学习的图推荐方法,将融合局部偏好和全局偏好的用户表示输入胶囊网络中.李驰等人^[29]提出了一种基于解耦图卷积网络的协同过滤推荐模型 DeGCF,通过优化图卷积操作和损失函数,进一步提升了模型的准确率.尽管这些模型在某些程度上提高了推荐算法的效率,但是也加剧了推荐物品的同质化,缺少多样化的项目推荐.

1.2 多样化推荐算法

随着数据量的增加,推荐系统在准确性方面的提升逐渐难以满足用户的期望.在用户体验日益重要的时代,人们对推荐结果的多样性需求越来越强烈.多样化推荐旨在为用户提供涵盖不同项目子集的建议,以协助用户发现那些他们可能尚未探索的兴趣领域^[30]. Ziegler 等人^[31]率先提出了多样化推荐的概念,他们在推荐系统的检索阶段使用了一种贪心算法来选择项目,旨在平衡推荐列表中项目的多样性和用户的个人喜好.多样化推荐模型旨在通过为用户提供具有不同项目子集的推荐,探索系统未感知的用户兴趣领域.尽管多样化推荐具有重要意义,但在实际应用中,推荐系统往往面临准确性与多样性难以兼顾的挑战^[15].

随着研究的深入,学者们逐渐开始把注意力转移到推荐系统准确性与多样性的平衡问题上. Hou 等人^[32]详细分析了推荐系统准确性与多样性不平衡带来的问题,并提出有效解决方案. Sha 等人^[33]不仅考虑了推荐项目的相关性和多样性,而且明确将用户感兴趣的覆盖范围纳入考虑范围.随着神经网络的兴起, DGCN^[7,10]成为首个基于 GNN 的多样化推荐方法.该模型对项目的类别频率进行取倒数操作,提高了非流行类别采样的概率,降低了流行类别的优先级,使得节点选择不同的邻居进行聚合,并利用类别增强的负采样和对抗学习来在嵌入空间中多样化项目,从而提升推荐的多样性. Gao 等人^[34]考虑用户满意度的情况,通过反事实思想来帮助模型规划离线强化学习策略,有效地优化了长期用户满意度.为平衡推荐结果的多样性和准确性. Yang 等人^[35]提出 DGRec 模型,在嵌入生成过程中,通过对聚合邻居的选择算法进行改进,并融合注意力机制,实现了准确性与多样性的均衡提升.胡春华等人^[36]则利用自注意力机制挖掘用户实时兴趣,并结合对比学习的方法对商品进行差异化分类,提升了推荐结果的多样性.

综上,尽管当前基于 GNN 的多样化推荐系统在交互结构聚合上取得了较好的效果,但这类研究没有考虑时态信息对于节点特征生成的重要影响.基于上述分析,本文利用注意力机制在聚合过程中融入时态信息,成功地将时态信息与交互结构信息相结合,不仅增强了推荐系统的多样性,同时也提高了推荐结果的准确性.

2 时态信息增强的多样化推荐模型 TIEDRec

TIEDRec 的整体框架如图 2 所示,其核心设计如下:首先,模型利用多头注意力机制融合用户与项目的时态交互序列,并引入特征解耦将融合后的表示分离为平滑与突出两种特征,以增强表示的辨识度.接着,在图卷积聚合前,通过贪心算法筛选多样化的邻居节点以丰富信息,并结合层注意力机制缓解多层聚合带来的过平滑问题.最后,设计一种重加权 BPR 损失函数,通过提升长尾项目在训练中的权重,直接引导模型生成更多样化的推荐结果.

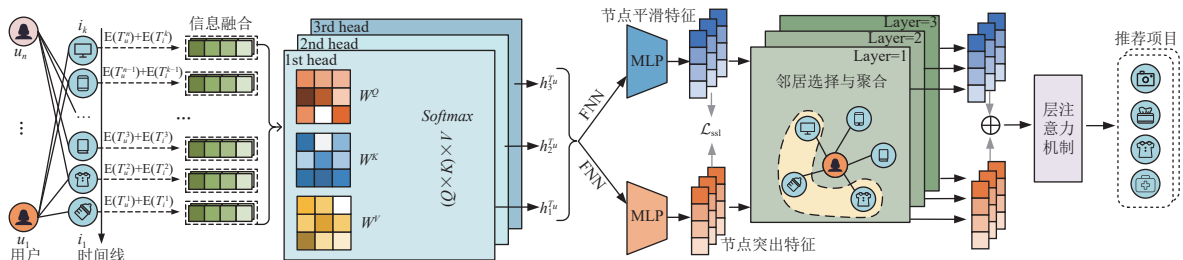


图 2 TIEDRec 模型的整体框架图

2.1 时态信息与交互结构信息的融合.

首先从每个用户-项目对 (u, i) 中构建两个时态序列: (1) 与用户 u 产生交互的项目的时态序列 $T_u = \{i_1, i_2, i_3, \dots, i_S\}$, (2) 与项目 i 产生交互的用户的时态序列 $T_i = \{u_1, u_2, u_3, \dots, u_S\}$, 其中 S 为设定序列的长度. 接下来, 基于这两个时态序列, 生成对应的时态序列嵌入, 即 $X_u = \{e_u^1, e_u^2, e_u^3, \dots, e_u^S\}$ 和 $X_i = \{e_i^1, e_i^2, e_i^3, \dots, e_i^S\}$.

为了增强嵌入的表达能力, 我们将节点的位置嵌入 $P_u = \{e_{ip}^1, e_{ip}^2, e_{ip}^3, \dots, e_{ip}^S\}$ 和 $P_i = \{e_{up}^1, e_{up}^2, e_{up}^3, \dots, e_{up}^S\}$ 与其对应的时态序列嵌入相加, 从而得到节点初始的输入嵌入. 将用户 u 的时态序列嵌入 X_u 与位置嵌入 P_u 相加, 可以得到用户 u 的初始输入嵌入为: $Z_u = \{e_u^1 + e_{ip}^1, e_u^2 + e_{ip}^2, e_u^3 + e_{ip}^3, \dots, e_u^S + e_{ip}^S\}$. 同样, 将项目 i 的时态序列嵌入 X_i 与位置嵌入 P_i 相加, 得到物品的初始输入嵌入为: $Z_i = \{e_i^1 + e_{up}^1, e_i^2 + e_{up}^2, e_i^3 + e_{up}^3, \dots, e_i^S + e_{up}^S\}$.

为了理解和预测用户的行为模式, 我们需要从每个用户-项目对 (u, i) 的单跳邻居中学习有价值的信息. 这些邻居不仅包括用户过去交互过的物品, 也可能包括与当前项目相似的其他项目. 本文采用缩放点积注意力 (scaled dot-product attention) 机制作为时间序列建模的关键部分. 这种机制的优势在于其能够自适应地为不同的邻居分配不同的权重, 从而更加关注那些与当前用户-项目对最相关的邻居. 缩放点积注意力机制通过计算用户-项目对其邻居之间的点积, 自适应地为不同的邻居分配不同的权重, 然后应用一个缩放因子来防止梯度消失或爆炸问题. 这种缩放操作不仅提高了模型的稳定性, 还能够自适应地为不同的邻居分配不同的权重, 从而更加关注那些与当前用户-项目对最相关的邻居, 更好地捕捉用户行为的时序动态. 缩放点积注意力机制的实现过程如公式 (1)-(3):

$$h^u = \text{Softmax}\left(\frac{(Z_u W_Q)(Z_u W_K)^T}{\sqrt{D}}\right)(Z_u W_V) \quad (1)$$

$$h^i = \text{Softmax}\left(\frac{(Z_i W_Q)(Z_i W_K)^T}{\sqrt{D}}\right)(Z_i W_V) \quad (2)$$

$$h^T = \text{Concat}[h^u, h^i] \quad (3)$$

其中, Z_u 和 Z_i 是用户 u 和项目 i 的初始输入矩阵, $h^u \in \mathbb{R}^{S \times D}$ 和 $h^i \in \mathbb{R}^{S \times D}$ 分别代表着用户和项目的单跳邻居的输出嵌入矩阵, $W_Q \in \mathbb{R}^{S \times D}$ 、 $W_K \in \mathbb{R}^{S \times D}$ 和 $W_V \in \mathbb{R}^{S \times D}$ 是每一个用户-项目对的共享权重转换矩阵, 以确保模型的一致性和泛化能力.

2.2 平滑特征与突出特征的并行抽取

为了进一步增强模型的表达能力, 我们采用多头注意力机制^[37], 从不同角度捕捉潜在时态信息. 各个注意力头本意是用于捕捉数据不同维度的信息, 通过这种方式对用户多种类型的兴趣进行感知. 然而, 由于这些注意力机制通常共享相同的输入和目标, 会出现“整体趋势”与“显著信号”在同一机制中相互干扰的情况: 一些注意力头可能对平滑而持续的特征格外敏感, 另一些头则偏向于放大瞬时或局部的强烈信号. 这种差异往往在模型训练过程中被掩盖, 难以形成有针对性的解读.

为了解决这一问题, 我们尝试对多头注意力的输出进行解耦: 一部分子网络专注于提炼平滑、稳定的特征, 从而为输入提供一个均衡的理解; 而另一部分子网络则专门用来“高亮”或凸显那些在某些条件下尤为重要的突出特征, 从而更好地捕捉局部的强烈信号. 通过这种分工设计, 模型能够在不引入额外时序信息或额外标签的前提下, 将多头注意力的输出划分成两类互补的表示——既能保留整体趋势, 又能灵敏感知显著的高权重点. 这种解耦设计能够有效提升模型在处理复杂场景时的灵活性, 尤其在捕捉不同类型的兴趣 (如长期兴趣与短期兴趣) 方面表现得更加精准. 同时, 这一设计也提升了模型的可解释性, 使得不同注意力头的功能更加明确, 便于分析和理解模型的决策过程. 解耦后的结构不再简单地依赖单一的注意力机制, 而是通过分工设计让每个注意力头聚焦于特定的信息, 从而提升了模型的整体表达能力和可解释性^[38].

这种解耦设计的思路来源于提升多头注意力机制内部差异性的相关研究^[37]. 相关工作表明, 通过分配不同的任务给不同的注意力头, 可以有效提高模型的表达能力和多样性, 使其在更复杂的任务中表现得更加出色^[38]. 我们的方法正是基于这一理念, 进一步将多头注意力机制进行解耦, 使其更好地适应不同类型的信息处理需求, 进而提升整体性能.

通过两个多层感知机 (multilayer perceptron, MLP) 进行解耦, 获得节点的平滑特征和突出特征的表示, 如公式 (4)、(5) 所示:

$$h^S = MLP_1(h_1^T \dots \|h_n^T \dots \|h_k^T) \quad (4)$$

$$h^H = MLP_2(h_1^T \dots \|h_n^T \dots \|h_k^T) \quad (5)$$

其中, $h_n^T \in R^{S \times D'/k}$ 代表第 n 个来自缩放注意力函数的输出嵌入矩阵. h^S 代表节点的平滑特征, h^H 代表节点的突出特征.

为了整合邻居嵌入信息, TIEDRec 采用了均值池化操作, 将 h^S 和 h^H 进行聚合. 综合上述操作, 可以得到平滑特征和突出特征下的聚合邻居嵌入表示 e_S 和 e_H , 计算方式如下所示:

$$e_S = \frac{1}{S} \sum_{n=1}^S h_n^S \quad (6)$$

$$e_H = \frac{1}{S} \sum_{n=1}^S h_n^H \quad (7)$$

2.3 特征聚合和传播

在第 2.1 节中的节点时态信息和交互结构信息融合模块中, 可以获取初始的用户和项目表示 e_u 和 e_i . 同时, 为了尽可能使节点的嵌入更具多样性, 本文对聚合邻居集合 S_u 或者 S_i 进行多样化的选择, 保证节点聚合信息的差异性.

以用户节点 u 为例, 本文采用贪心算法来生成用户 u 的聚合邻居集合. 初始时, 将 S_u 设为空集 \emptyset . 然后, 通过 k 次贪心算法进行邻居选择操作, 最终得到用户 u 的多样化邻域聚合子集. 计算过程如公式 (8) 所示:

$$S_u \leftarrow S_u \cup \{\arg \max_{i \in N_u \setminus S_u} [f(S_u \cup i) - f(S_u)]\} \quad (8)$$

其中, N_u 是用户节点 u 的全部邻居集合, S_u 是用户节点 u 经过选择之后的邻居集合. 用户 u 的邻居节点选择函数如公式 (9) 所示:

$$f(S_u) = \sum_{i \in N_u \setminus S_u} \max_{i' \in S_u} \left[\exp \left(-\frac{|e_i - e_{i'}|^2}{\sigma^2} \right) \right] \quad (9)$$

选择完节点的邻居集之后, 采用 LightGCN^[26] 技术对邻居的嵌入进行聚合, 一方面捕捉图神经网络的拓扑结构, 另一方面聚合节点近邻之间的共性特征. 计算过程如公式 (10) 和 (11) 所示:

$$e_S^{(l+1)} = \sum_{i \in S_u} \frac{1}{\sqrt{|S_u| |S_i|}} e_S^{(l)} \quad (10)$$

$$e_H^{(l+1)} = \sum_{i \in S_v} \frac{1}{\sqrt{|S_i| |S_u|}} e_H^{(l)} \quad (11)$$

其中, $e_S^{(l)}$ 和 $e_H^{(l)}$ 是节点第 l 层的平滑、突出嵌入表示, $\frac{1}{\sqrt{|S_u| |S_i|}}$ 是归一化项, S_u 是通过公式 (8) 的贪心算法操作得到的用户邻居集合.

为了实现 $e_S^{(l)}$ 和 $e_H^{(l)}$ 的充分解耦, 我们需要增强二者的独立性, 从数理统计的角度来分析, 如果两个变量是独立的, 则它们的联合期望值就等于各自期望值的乘积:

$$\mathbb{E}[\phi^{(k)}(e_S^{(l)}) \psi^{(k)}(e_H^{(l)})] = \mathbb{E}[\phi^{(k)}(e_S^{(l)})] \mathbb{E}[\psi^{(k)}(e_H^{(l)})] \quad (12)$$

其中, $\phi^{(k)}(\cdot)$ 和 $\psi^{(k)}(\cdot)$ 是非线性变换操作, 目的是消除嵌入的分布偏差, 让相关性计算更加准确. 本文用 Pearson 相关系数来衡量 $\phi^{(k)}(e_S^{(l)})$ 与 $\psi^{(k)}(e_H^{(l)})$ 之间的线性关系, 二者独立性计算过程如下所示:

$$\mathcal{L}_{\text{Ind}} = \sum_{k=1}^K \frac{\text{Cov}(\phi^{(k)}(e_S^{(l)}), \psi^{(k)}(e_H^{(l)}))}{\sqrt{\text{Var}(\phi^{(k)}(e_S^{(l)})) \cdot \text{Var}(\psi^{(k)}(e_H^{(l)}))}} \quad (13)$$

其中, $\text{Cov}(\cdot)$ 和 $\text{Var}(\cdot)$ 分别表示协方差和变量的方差. 独立性损失 \mathcal{L}_{Ind} 越小, 说明共性表示与私有表示之间的相关性越小, 也就越独立. 本文希望通过独立性损失的约束, 获得能够完整且干净地表达不同行为偏好特征的解耦表示.

为了解决多层聚合导致的过平滑问题, 引入了层注意力机制. 通过这种形式, 使得中心节点能够直接接触到高

阶的协同过滤信息, 从而在提升多样性的同时, 有效缓解过平滑问题. 经过 L 层聚合后, 用户和项目的嵌入表示为 e_* , 具体计算过程如公式 (14) 所示:

$$e_* = \sum_{l=0}^L a^{(l)} e_*^{(l)}, e_*^{(l)} = (e_s^{(l)} + e_H^{(l)})/2 \quad (14)$$

其中, $e_*^{(l)}$ 是用户 u 或者项目 i 在第 l 层的嵌入表示. $a^{(l)}$ 是第 l 层对应的权重, 计算如公式 (15) 所示:

$$a^{(l)} = \frac{\exp((W_{Att}, e_*^{(l)}))}{\sum_{l'=0}^L \exp((W_{Att}, e_*^{(l')}))} \quad (15)$$

其中, W_{Att} 是注意力计算的参数.

2.4 损失函数

在现实世界的推荐系统中, 用户交互数据往往呈现出幂律分布的特性, 即少数流行项目吸引了大多数的注意力和交互, 而大量的长尾项目则被忽视. 这种分布特性可能导致推荐系统过度倾向于推荐那些已经非常流行的项目, 从而忽略了那些可能对特定用户群体具有吸引力的长尾项目.

为了解决这一问题, 我们根据项目类别在损失函数中进行重新加权操作. 这种策略的核心思想是平衡推荐系统的覆盖度和多样性^[39].

在通过层注意力机制获得用户和项目的最终嵌入 e_u 和 e_i 之后, 对于每一个正对 (u, i) , 借助随机采样的方式得到负样本 j 来计算贝叶斯个性化排名 (BPR)^[40], 具体损失函数如公式 (16) 所示:

$$\mathcal{L}_{\text{bpr}} = \sum_{(u,i,j) \in \mathcal{E}} w_{C_{(i)}} (\ln \sigma(f_u(i) - f_u(j))) + \lambda \|\Theta\|_2^2 \quad (16)$$

其中, $f_u(i)$ 表示用户 u 对项目 i 的评分, σ 是激活函数, $w_{C_{(i)}}$ 是每个样本类别的权重.

在 TIEDRec 中, 我们根据项目类别在损失函数中进行重新加权操作. $w_{C_{(i)}}$ 的计算过程如公式 (17) 所示:

$$w_{C_{(i)}} = \frac{1 - \beta}{1 - \beta^{|C_{(i)}}|} \quad (17)$$

其中, β 是超参数. 综上所述, 总体损失函数可以表示为:

$$\mathcal{L} = \mathcal{L}_{\text{ind}} + \mathcal{L}_{\text{bpr}} \quad (18)$$

具体来说, 如果项目属于流行类别, 可以通过降低其权重来对其进行抑制. 通过这种方式减少模型对这些已经高度曝光项目的依赖, 鼓励模型探索那些较少被注意的项目. 相反, 如果项目属于长尾类别, 则可以通过增加其权重的方式形成长尾项目激励, 这样做有助于提升这些项目曝光的可能性, 从而增加用户发现新兴趣和新选项的机会.

3 相关实验

3.1 实验准备

3.1.1 数据集

为综合评估 TIEDRec 的有效性, 本文在两个真实数据集上进行实验验证. 两个数据集的数据统计如表 1 所示.

表 1 数据集数据统计

数据集	用户数	物品数	交互数	类别数
Taobao	82 560	135 450	4 184 923	135 450
Beauty	8 159	5 862	98 566	41
ML-1M	6 039	2 768	1 212 633	10

Taobao^[4]: 该数据集包含用户在淘宝平台上的购物交互行为, 由 Alimama 提供. 为了确保数据集的质量, 我们对数据集进行了过滤, 只保留至少有 10 个交互记录的用户/项目数据.

Beauty^[10]: 该数据集包含来自 Amazon 的产品评论信息和元数据. 为了确保数据集的质量, 我们只保留至少有 5 个交互记录的用户/项目.

ML-1M^[33]: 该数据集包含了在线电影推荐服务平台的评分记录。

对于这两个数据集, 本文统一采取如下策略进行数据划分: 60% 的数据作为训练集, 用于模型的学习; 20% 的数据作为验证集, 专门用于超参数的调整以及实施提前停止策略来防止过拟合. 剩余的 20% 的数据则作为测试集使用, 对测试集的评估结果将作为模型性能的最终衡量标准.

3.1.2 对比方法

- (1) Popularity: 一种非个性化推荐方法, 只向用户推荐热门项目.
- (2) MF-BPR^[40]: 使用贝叶斯个性化排序损失优化的矩阵分解方法, 借助用户的隐式反馈数据来进行物品推荐.
- (3) GCN^[41]: 利用图卷积神经网络直接在图数据上传递标签信息, 进行表示学习.
- (4) SASRec^[23]: 通过自注意力网络处理用户的历史行为序列, 能够为每个时间步的交互分配不同的权重, 从而捕捉用户的短期和长期兴趣.
- (5) LightGCN^[26]: 轻量级的图卷积网络, 移除特征转移矩阵和非线性激活函数.
- (6) LR-GCCF^[27]: 在轻量化图卷积网络的同时, 通过残差连接来缓解图神经网络的过平滑问题.
- (7) DGCN^[10]: 根据逆类别频率选择节点邻居进行不同的聚合, 同时利用类别增强的负采样与对抗学习, 以实现嵌入空间中不同项目表示的多样化.
- (8) DGRec^[35]: 对聚合邻居选择算法进行了改进, 通过融合注意力机制, 对模型进行更好的消息聚合改进, 使得模型的推荐结果在多样性和准确性上都取得了较大的改善.
- (9) SAPID^[16]: 基于时间流行的负抽样机制消除了模型中的受欢迎程度偏差, 根据其估计的接触机会, 决定推荐哪些项目.

3.1.3 评价指标介绍

为了实验的公平, 我们参照之前的工作^[10,35]设置评价指标. 具体包括: 使用召回率 ($\text{Recall}@N, R@N$) 和命中率 ($\text{Hit Ratio}@N, H@N$) 来衡量模型的准确性; 使用覆盖率 ($\text{Coverage}@N, C@N$) 用于衡量模型的多样性, 它计算推荐项目的覆盖类别数量. 同时, 为了能够清晰地比较模型的综合性能, 本文还设置了一个均衡指标 ($\text{Balance}@N, B@N$), 计算如公式 (19) 所示:

$$B@N = R@N \times w_1 + H@N \times w_2 + C@N \times w_3 \quad (19)$$

其中, N 是推荐的物品数, 我们分别取 N 为 100 和 300 两种情况. w_1, w_2, w_3 分别表示不同维度的权重, 用户可以根据推荐模型的目标来调整权重的设置. 为了体现 $R@N, H@N, C@N$ 之间的平衡性 (既考虑准确性又考虑多样性), 本文简化了设置过程, 将 w_1, w_2, w_3 的值分别设置为 0.25、0.25、0.005.

3.1.4 参数设置

为了实验的公平起见, 所有方法的节点嵌入维度都固定为 64, batchsize 设置为 1024, 层数设置为 3, 并为每个正用户-项目对随机采样 4 个负项以进行公平比较. 为了追求模型的最佳性能, 所有模型的学习率都通过网络搜索在 0.01–0.1 中进行调整. 早期停止 (early stop) 可以缓解过拟合问题, 如果验证集的性能在 20 个 epoch 中没有提高, 我们会停止训练.

所有模型都使用 Xavier^[42] 方法初始化模型参数, 使用 Adam 方法来优化模型参数. 本文所提出的 TIEDRec 将时间序列长度 S 设置为 50, 邻居数量 k 设置为 100, 超参数 β 设置为 0.99, 具体的参数实验分析在第 3.2 节中展开. 本文所有实验都使用 PyTorch 框架部署实验, 计算设备为一张 NVIDIA 4090 显卡.

表 2 展示了 TIEDRec 和所有对比方法的推荐效果. 表 3 则展示了 TIEDRec 和所有对比方法的综合推荐效果. 其中, 加粗数据表示在所有方法中实验指标最优, 下划线数据表示在所有方法中实验指标次优. 分析所有模型的推荐效果之后, 可以得到以下结论.

(1) 从表 2 的数据可以看出本文提出的方法 (TIEDRec) 在两个数据集中均取得了较好的推荐效果. 在 Beauty 数据集中, TIEDRec 相较对比模型在召回率 ($R@100$)、命中率 ($H@100$) 以及覆盖率 ($C@100$) 上分别提升了 4.91%–6.26%、8.01%–11.08% 以及 2.83%–8.98%. 在 Taobao 数据集中, 性能提升更为显著, 其召回率、命中率及覆盖率相较对比模型分别增长了 14.91%–38.26%、8.67%–22.40% 和 0.88%–3.37%.

表2 实验数据集推荐性能比较

数据集	指标	Popularity	MF-BPR	DGCN	GCN	LightGCN	LR-GCCF	SASRec	DGRec	SAPID	TIEDRec
Beauty	R@100	0.1042	0.2356	0.2431	0.2432	0.2359	0.2686	0.1724	0.2443	0.2412	<u>0.2563</u>
	R@300	0.2103	0.3873	0.3795	0.3906	0.4212	0.4330	0.2896	0.3923	0.3940	<u>0.4305</u>
	H@100	0.1924	0.3495	0.3499	0.3512	0.3775	0.3838	0.2572	0.3508	0.3411	<u>0.3789</u>
	H@300	0.3075	0.4913	0.4746	0.5268	0.5269	<u>0.5442</u>	0.4022	0.4969	0.4862	0.5463
	C@100	15.4292	15.2804	17.6954	15.9389	14.4278	14.5280	<u>18.7617</u>	18.4635	18.7541	19.2839
	C@300	<u>27.7224</u>	25.5146	26.8184	25.4133	23.7911	23.4788	27.0070	27.4194	27.5946	27.7880
Taobao	R@100	0.0175	0.0442	0.0379	0.0437	0.0522	0.0563	0.0521	0.0456	0.0419	<u>0.0524</u>
	R@300	0.0311	0.0393	0.0799	0.0889	0.1049	0.1116	0.1032	0.0917	0.0852	<u>0.1050</u>
	H@100	0.1421	0.3024	0.2612	0.2744	0.3177	0.3331	0.3027	0.2942	0.2825	<u>0.3197</u>
	H@300	0.2457	0.4774	0.4269	0.4509	0.4982	0.5180	0.4902	0.4702	0.4513	<u>0.5000</u>
	C@100	38.3741	34.2103	38.2475	37.3876	32.8161	31.5546	36.2865	<u>39.1889</u>	38.6932	39.5346
	C@300	76.5669	72.4639	85.0989	79.8813	69.9346	82.1892	81.8550	<u>89.7528</u>	89.9562	91.1170
ML-1M	R@100	0.0311	0.0422	0.0238	0.0113	<u>0.0411</u>	0.0122	0.0238	0.0113	0.0310	0.0566
	R@300	0.0692	0.1033	0.1096	0.0256	0.0692	0.0333	<u>0.1096</u>	0.0256	0.1066	0.1698
	H@100	0.3738	0.3359	0.2081	0.0700	0.4238	0.0859	0.2081	0.0700	<u>0.5256</u>	0.6155
	H@300	0.6285	0.5484	0.6978	0.1030	0.6285	0.1184	0.6988	0.1030	<u>0.7199</u>	0.8546
	C@100	11.9796	9.0737	12.6087	10.0881	10.2796	11.0737	<u>11.3087</u>	10.0881	11.2714	11.3980
	C@300	14.1710	14.7689	15.8780	14.3174	13.1710	13.9744	13.3780	13.3174	<u>14.1689</u>	14.7831

表3 TIEDRec 与基线方法在 Beauty、Taobao 和 ML-1M 数据集上的均衡性能比较

方法	Beauty		Taobao		ML-1M	
	B@100	B@300	B@100	B@300	B@100	B@300
Popularity	0.1513	0.2681	0.2318	0.4520	0.1611	0.2453
MF-BPR	0.2227	0.3472	0.2577	0.4915	0.1399	0.2368
GCN	0.2367	0.3476	0.2660	0.5522	0.1210	0.2812
SASRec	0.2283	0.3564	0.2665	0.5344	0.0708	0.1037
LightGCN	0.2255	0.3560	0.2566	0.5029	0.1676	0.2403
LR-GCCF	0.2357	0.3617	0.2551	0.5683	0.0799	0.1078
DGCN	0.2012	0.3080	0.2701	0.5576	0.1145	0.2690
DGRec	0.2411	<u>0.3594</u>	<u>0.2809</u>	<u>0.5892</u>	0.0708	0.0987
SAPID	0.2393	0.3580	0.2746	0.5839	<u>0.2005</u>	<u>0.2850</u>
TIEDRec	0.2552	0.3831	0.2907	0.6068	0.2250	0.3300

(2) 基于流行度 (Popularity) 的方法和矩阵分解方法 (MF-BPR) 忽略了用户和物品之间复杂的交互模式, 相比之下, 基于图神经网络的方法在两个数据集上展现了更高的准确性. Popularity 方法基于物品的流行度来进行推荐, 即推荐那些被大多数用户喜欢的项目. 这种方法的局限性在于它无法考虑用户之间的个体差异和偏好多样性. 忽略了用户的个性化需求, 导致推荐结果过于泛化, 无法满足所有用户的需求. MF-BPR 将用户和物品映射到一个共同的隐空间来捕捉它们之间的潜在关系. 然而, 这种方法主要依赖于用户-物品的交互矩阵, 当数据稀疏或用户物品交互较少时, 其效果会大打折扣. 图神经网络通过学习用户和物品之间的复杂关系, 能够捕捉用户感兴趣的细微变化, 这种能力在用户具有高度个性化需求时尤为重要.

(3) 对比 GCN 而言, LightGCN 在准确性上取得了更佳的效果. 这说明 GCN 模型的特征转移矩阵和非线性激活函数在一定程度上损害了模型的准确性. LightGCN 和 LR-GCCF 过度追求准确性, 使得其多样性效果在所有算法中是最低的. 然而, LR-GCCF 通过残差连接缓解了过平滑问题, 这使得其在 C@300 指标上超过了 LightGCN. 综上, LightGCN 和 LR-GCCF 并不能达到准确性与多样性的平衡. 可以看到, 这些方法的多样性都与单纯的推荐热门项目相似, 说明这些方法都过度依赖于历史交互的结构信息, 使得推荐的多样性并不理想.

(4) TIEDRec 模型在邻域聚合过程中充分利用了时态信息与交互结构信息来对用户兴趣进行刻画, 准确地建模了用户兴趣的演变过程, 捕捉了不同用户的兴趣区别和差异, 从而能够提供更符合用户兴趣的个性化推荐结果.

TIEDRec 通过在损失函数中引入对长尾项目的额外关注,鼓励模型在推荐时不仅考虑热门项目,也重视那些交互较少但可能与用户兴趣高度相关的长尾项目。

根据表 3 的结果,我们可以看到 TIEDRec 在多样性指标和平衡指标上均取得了最佳效果. TIEDRec 的卓越表现证明了其在准确性保持较高水平的同时,还能够显著提高推荐结果的多样性,这对于避免信息茧房效应和满足不同用户的多元化需求至关重要. 同时,通过推荐长尾项目, TIEDRec 还能够帮助挖掘和推广更多的优质内容,从而促进整个推荐生态系统的健康发展.

3.2 参数实验

为了分析模型 TIEDRec 在不同超参数下的推荐结果,本节在两个数据集上进行了超参数分析的实验验证. 重点验证了图神经网络聚合层数 L 、时间序列 S 、样本损失权重 β 以及邻居数量 k 对推荐结果性能的影响. 实验结果及分析如下.

- 图神经网络聚合层数 L . 图神经网络通过堆叠多层结构来捕获用户和项目之间的复杂关系,每一层都在前一层的基础上进一步提炼和抽象信息. 然而,层数 L 的增加可能会引发过平滑现象,节点的嵌入表示趋于收敛到相似的向量,导致不同节点之间缺乏必要的区分度.

针对层数 L 的参数实验结果如图 3 所示,随着图神经网络聚合层数 L 的增加, $R@300$ 先显著上升(从 1 到 2 层),然后下降,再上升. 这表明,随着模型复杂度的增加,模型在捕捉用户核心兴趣的能力上可能会受到影响,导致推荐结果的准确性降低. 这可能是因为随着层数的增加,模型会学习过于复杂的模式,从而忽略了用户的基本偏好.

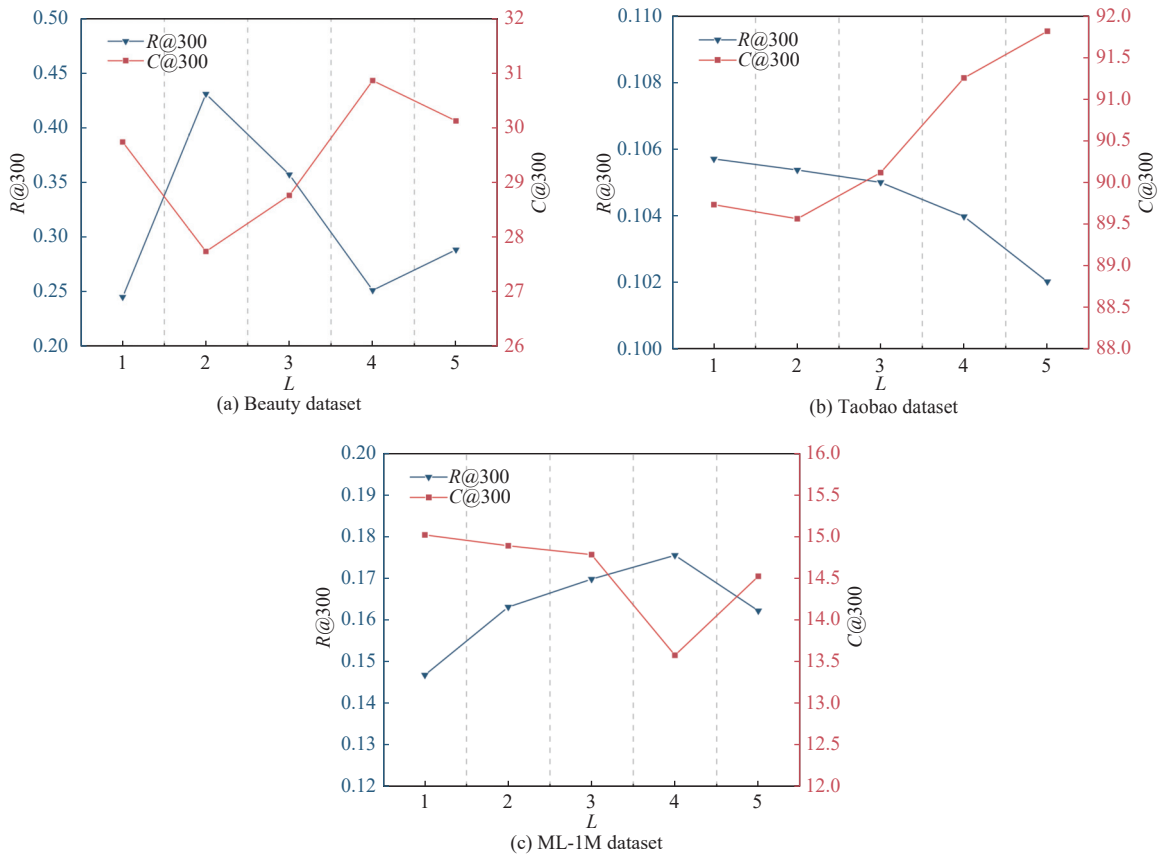


图 3 聚合层数 L 实验

与此同时, $C@300$ 却逐渐增加. 这说明随着层数的增加, 模型能够推荐更多种类的项目, 从而提高了推荐结果的多样性. 然而, 这种多样性的增加可能是以牺牲准确性为代价的, 主要原因在于, 随着层数的增加, 多种类别的项目在嵌入空间中与用户偏好的项目较为接近, 导致模型难以区分而推荐给用户. 这种情况下尽管为用户推荐多类项目, 但并不完全是用户感兴趣的, 因此会降低推荐准确率.

为了解决过平滑问题并平衡准确性与多样性, 需要在 GNN 层数的选择上做出权衡. 实验结果表明, 当选择层数为 3 时, TIEDRec 模型能够达到最佳性能. 在推荐系统中, 图神经网络聚合层数的选择对性能至关重要. 过平滑问题可能导致节点特征表示趋于一致, 降低推荐准确性. 然而, 当层数设置为 3 层时, TIEDRec 模型能够有效地平衡局部和全局信息的融合, 同时避免过平滑问题, 实现推荐准确性和多样性的优化. 设计 3 层结构允许模型在保持节点特征区分度的同时, 捕捉用户和物品之间更丰富的关系, 从而提高推荐的相关性和多样性. 此外, 这种层数设置还有助于提高模型的泛化能力, 确保在新的数据上也能保持较好的推荐效果, 同时在计算效率和实际推荐效果之间实现良好的折中.

- 时间序列 S . 在 TIEDRec 中, 时间序列 S 用于控制时间序列的长度. S 的大小直接决定了 TIEDRec 对用户短期和长期兴趣的捕捉能力. 通过引入时间序列, 我们能够动态跟踪用户兴趣的变化, 融合用户的交互信息, 挖掘其中的隐含信息. 这不仅提高了推荐的多样性, 也在追求高多样性的同时保持了推荐的准确性. S 参数的取值越大, 代表模型捕捉用户长期兴趣的能力越强, 适用于用户兴趣较为稳定的应用场景中, 例如电影推荐或电子商务推荐. S 参数的取值越小, 代表模型能够更好地捕捉用户的短期兴趣, 模型可以对用户兴趣的变化快速做出反应, 适用于用户兴趣变化较快的应用场景, 例如新闻推荐或社交媒体推荐.

从图 4 中我们可以看到选择短时间序列能够提高覆盖率, 但有可能牺牲召回率, 想要提高召回率一定会伴随着覆盖率的降低, 这表明短时间序列的学习能够提高推荐结果的多样性, 但会降低准确率, 长时间序列的学习能够捕捉用户的长期稳定兴趣, 虽然会使准确率升高, 但由于长期兴趣的固化, 会导致覆盖率降低. 通过对时间序列 S 的调整, 在选择 $\text{MaxLen}=50$ 时, 可以平衡准确率和覆盖率, 这既能够打破信息茧房效应还能维持推荐的准确率.

- 样本损失权重 β . 为提高长尾类别项目的关注度 (它们在传统推荐系统中往往难以获得充足曝光), 模型在损失函数中实施了重加权策略. 长尾类别的重要性不容忽视, 它们包含了大量的潜在兴趣点, 能够为用户提供更广泛的选择, 满足不同用户的个性化需求. 通过提高 β 值, TIEDRec 模型能够更多地关注这些长尾类别的项目, 从而增加推荐结果的多样性. 准确性与多样性是推荐系统中两个关键的性能指标. β 参数的调整直接影响了这两个指标之间的权衡. 随着 β 值的升高, 模型会更加倾向于推荐长尾类别的项目, 这可能会导致准确率的下降, 因为这些项目的预测难度通常较大. 然而, 这种牺牲是值得的, 因为它能够显著提高推荐结果的多样性, 使用户能够接触到更多不同的项目. 这种多样性的增加对于避免信息茧房效应、提高用户满意度至关重要.



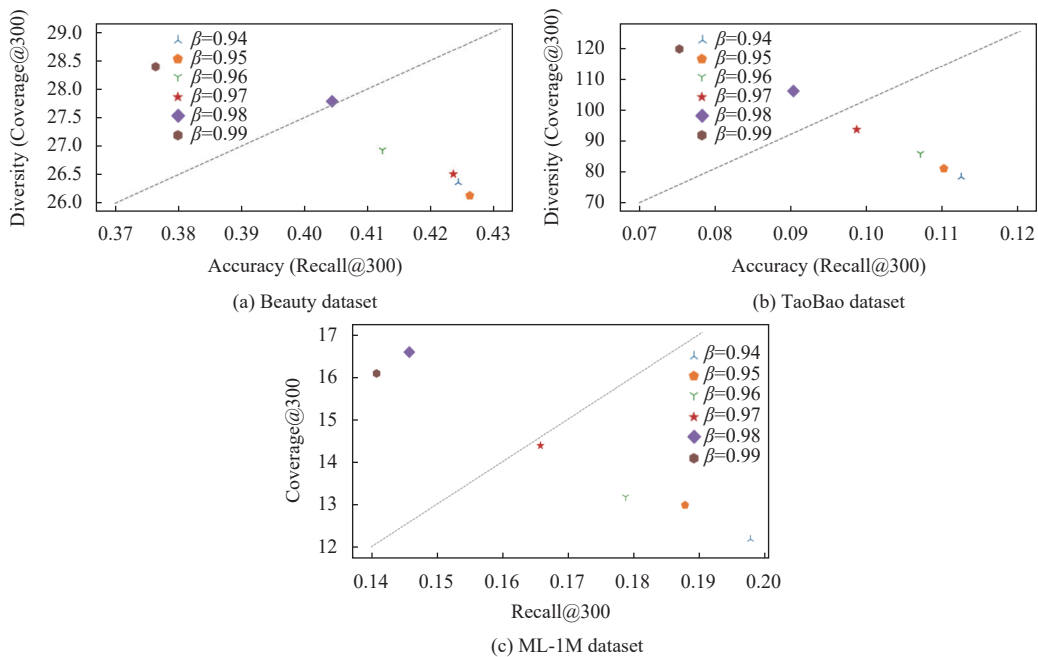


图 4 时间序列 S 实验

图4 时间序列 S 实验 (续)

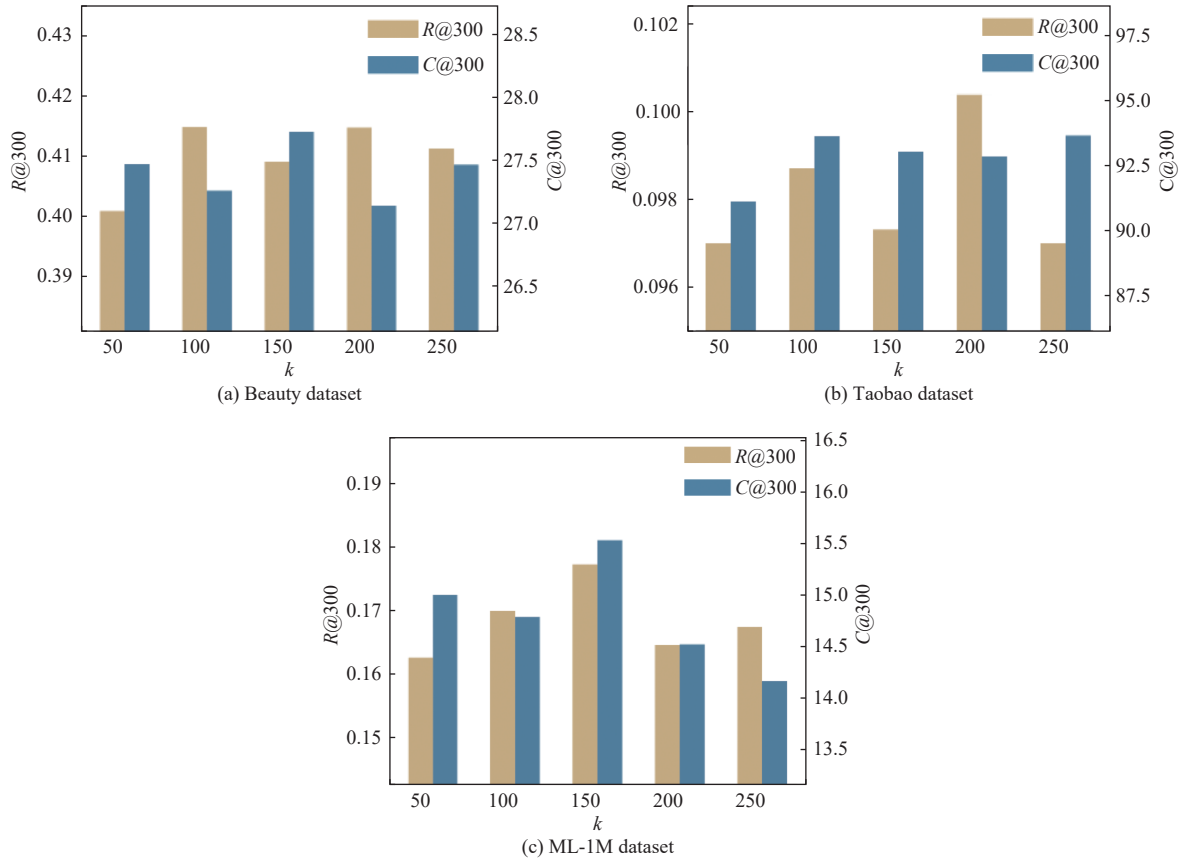
准确性-多样性权衡图(如图5所示)直观地展示了 β 参数对推荐系统性能的影响.随着 β 值的升高,我们可以看到准确率逐渐下降,而推荐结果的多样性则不断增加.这表明,通过专注于长尾类别物品的推荐,可以有效地提高推荐结果的多样性,同时这种多样性的增加并不会对准确性造成不可接受的损害.实验结果进一步证实了 β 参数在平衡推荐结果多样性和准确性方面的重要性.通过细致地调节 β 值,我们可以在不同的应用场景下实现最佳的权衡.这种灵活性使得TIEDRec能够适应不同的用户需求和业务目标.

图5 超参数 β 实验

• 邻居数量 k . 在基于图神经网络的推荐系统中,节点的邻居子集对于捕捉用户和物品之间的复杂关系至关重要.邻居选择函数的作用是从一个节点的所有邻居中筛选出一个更具差异性的子集,以提高模型的表达能力和泛化能力.这种选择过程不仅有助于减少信息冗余,还能够增强模型对不同特征的学习能力.

在TIEDRec中, k 参数定义了邻居选择函数在每个节点上考虑的邻居数量.通过调整 k 的值,我们可以控制邻

居子集的大小, 进而影响推荐系统的准确性和多样性. 从图 6 中可以看出, 随着 k 的增加, $R@300$ 有时增加有时减少. 这表明 k 值的增加可能会使模型在某些情况下更好地捕捉用户的兴趣, 而在其他情况下则可能导致推荐结果的泛化能力下降. 同时, $C@300$ 总体上随着 k 的增加而逐渐增加. 这说明较大的邻居子集有助于提高推荐结果的多样性. 然而, 这种增加的多样性并不总是伴随着准确性的提升, 在某些情况下, 较大的邻居子集可能会引入过多的噪声, 从而降低模型的准确性. 综合考虑图 6 所示的实验结果, 我们可以发现, 当 k 设置为 100 时, 推荐系统能够在两个数据集上的准确性和多样性之间实现较好的均衡. 这个 k 值的选择使得模型既能够捕捉用户的核心兴趣, 又能够提供足够的多样性, 以满足用户的多元化需求. 通过细致地调整 k 参数, 我们可以根据不同的应用场景和用户需求来优化推荐系统的性能.

图 6 聚合邻居数量 k 实验

3.3 消融实验

在本节中, 我们通过在两个数据集上进行消融实验. 实验结果如表 4 所示, 可以观察得出如下结论.

(1) 完整的 TIEDRec 较好地平衡了推荐结果的多样性和准确性. 所提模块的组合能够利用时态信息在保持准确性的同时增加多样性, 为解决准确性和多样性的平衡困境提出了一个切实可行的办法.

(2) “w/o TI”表示通过去除聚合模块中融入时态信息 (temporal information) 的部分. 移除时态信息后, 模型的准确性显著下降, 这可能是由于模型不再能够捕捉用户兴趣随时间的细微变化, 从而倾向于推荐更流行的项目. 时态信息在聚合过程中的加入, 使得模型能够考虑用户行为的时间序列特征, 这有助于更准确地预测用户当前及未来的偏好. 通过这种方式, 模型不仅能够提供准确的推荐, 还能够一定程度上保持推荐的多样性, 因为时序特征的引入增加了模型对不同时间点用户行为的敏感性. 实验结果表明, 在聚合过程中加入时态信息, 可以在较小多样

性代价下显著增加准确性. 具体来说, 时态信息的引入使得模型能够更好地理解用户兴趣的演变, 从而更好地捕捉用户之间的区别.

(3) “w/o LA”表示移除层注意力 (layer attention) 机制后的模型. 覆盖率随着召回率和命中率的减少而增加. 这表明层注意力机制可以捕捉每个节点的差异, 通过为不同的节点分配不同的注意力权重, 可以更好地平衡全局和局部信息, 从而提供更准确的推荐, 平衡模型的多样性和准确性. 这种平衡对于满足用户的个性化需求和避免推荐结果的同质化至关重要.

表 4 在 Beauty 和 Taobao 和 ML-1M 数据集上的消融实验

数据集	指标	w/o TI	w/o LA	w/o LR	w/o FS	TIEDRec
Beauty	<i>R@100</i>	0.0478	0.2143	0.2146	0.2061	0.2563
	<i>R@300</i>	0.0657	0.3656	0.3479	0.4154	0.4305
	<i>H@100</i>	0.2897	0.3354	0.3089	0.3511	0.3789
	<i>H@300</i>	0.4234	0.4498	0.4365	0.5123	0.5463
	<i>C@100</i>	37.1420	20.2256	20.5498	23.1285	19.2839
	<i>C@300</i>	83.1223	27.7556	28.3346	36.2157	27.7280
Taobao	<i>R@100</i>	0.0349	0.0410	0.0047	0.0435	0.0524
	<i>R@300</i>	0.0822	0.0712	0.0103	0.0797	0.1050
	<i>H@100</i>	0.2584	0.2309	0.0091	0.2382	0.3197
	<i>H@300</i>	0.4239	0.3790	0.0241	0.4733	0.5000
	<i>C@100</i>	48.3831	51.5433	64.2356	54.0125	39.5346
	<i>C@300</i>	115.2291	124.4634	153.1566	93.2221	90.1170
ML-1M	<i>R@100</i>	0.0138	0.0141	0.4230	0.4968	0.0566
	<i>R@300</i>	0.1044	0.0340	0.0721	0.1453	0.1698
	<i>H@100</i>	0.5545	0.0854	0.4673	0.5213	0.6155
	<i>H@300</i>	0.6987	0.1530	0.6551	0.7617	0.8546
	<i>C@100</i>	16.3416	10.6742	15.5523	12.1769	11.3980
	<i>C@300</i>	19.5162	14.3084	22.1771	16.3293	14.7831

(4) “w/o FS”表示移除特征分离 (feature separation) 模块后的模型. 与完整模型相比, 该版本的召回率和命中率出现明显下降, 而覆盖率仅有轻微提升. 这说明特征分离模块通过解耦平滑的全局模式与具有判别力的局部信号, 显著提高了表示的辨识度. 当该模块被移除, 节点表征中关键信息与噪声无法有效区分, 导致模型难以同时捕捉全局趋势与局部差异, 从而削弱了推荐准确性. 虽然覆盖率略有增加, 但这种多样性提升属于“无目标扩散”, 并未精准对应用户兴趣. 因此, 特征分离模块对于在多样性与准确性之间取得高质量平衡具有关键作用.

(5) “w/o LR”表示移除损失重加权 (loss reweight) 模块后的模型. 召回率和命中率下降较快, 而覆盖率却急剧增加, 这表明损失重加权模块对于捕捉用户对特定项目的兴趣至关重要. 通过为长尾类别的样本分配更高的权重, 模型能够更加关注这些样本, 从而提高对这些项目的推荐准确性. 这种权重调整有助于模型更好地学习用户对长尾项目的偏好, 即使这些偏好在数据中的表现不够显著. 与此同时, 覆盖率的增加反映了模型在缺少损失重加权时倾向于推荐更多种类的项目, 但这种多样性的增加可能是以牺牲准确性为代价的. 没有适当的权重调整, 模型可能无法区分用户对不同项目的真实感兴趣程度, 导致推荐结果的相关性下降. 损失重加权模块与层注意力机制的协同作用是 TIEDRec 模型的一个关键优势. 损失重加权不仅平衡了长尾类别的训练, 而且为层注意力机制提供了指导, 帮助模型更有效地分配注意力权重. 这种协同作用使模型能够在保持准确性的同时, 提供丰富的推荐多样性.

3.4 复杂度分析

记用户数 $|U|$ 、物品数 $|I|$ 、结点总数 $|V| = |U| + |I|$ 、边数 $|E|$; 嵌入维度 d 、GNN 层数 L 、注意力头数 H (单头维度 d/H)、时间序列长度 S 、每个正样本的负采样数 M 、batch 大小 B . 与正文结构对应: 公式 (1)–(3) 为时态-结构融合的多头注意; 公式 (4)–(7) 为特征解耦的两路 MLP; 公式 (8)–(11) 为多样化邻居选择与 LightGCN 传播; 公式 (14) 和 (15) 为层注意力融合; 公式 (16)–(18) 为重加权 BPR 损失. 复杂度分析实验如表 5 所示, 其中, 加粗数据

表示在所有方法中实验指标最优, 下划线数据表示在所有方法中实验指标次优.

• 时间复杂度方面, 单个 (u, i) 上下文中对长度为 S 的序列做多头注意力的代价为 $O(Sd^2 + S^2d)$ (Q 、 K 、 V 投影与注意力矩阵构建), 用户侧与物品侧各一条序列, 总计 $2 \times O(Sd^2 + S^2d)$; 两路 MLP 的逐位置前馈为 $O(Sd^2)$. 贪心式邻居多样化选择采用“已选集合”相关的边际增益打分, 单结点代价近似为 $O(k \cdot |\mathcal{N}(x)| \cdot d)$. 在所选邻域诱导的稀疏子图上进行 LightGCN 传播, 可写为 $O(LB_nkd)$. 损失计算与正则 (含重加权 BPR 与独立性约束) 为 $O(B(M+1)d)$, 相对上述主项可忽略. 于是单个 batch 的训练时间复杂度可合并为:

$$T_{\text{train}}^{\text{batch}} = O(B(Sd^2 + S^2d)) + O(LB_nkd) + O(B(M+1)d) \quad (20)$$

表 5 在 Beauty、Taobao 和 ML-1M 数据集上的复杂度分析实验

Method	Beauty			Taobao			ML-1M		
	训练时间 (s)	推理时间 (s)	GPU (MiB)	训练时间 (s)	推理时间 (s)	GPU (MiB)	训练时间 (s)	推理时间 (s)	GPU (MiB)
SASRec	18.62	14.55	2496	20.92	19.88	8741	19.48	14.05	3547
LR-GCCF	0.022	0.022	2510	0.232	0.003	2496	0.016	0.007	1000
DGRec	<u>0.60</u>	<u>0.13</u>	1602	12.92	1.20	<u>6264</u>	16.41	<u>2.30</u>	<u>1688</u>
TIEDRec	0.61	0.14	<u>1604</u>	<u>11.90</u>	<u>0.99</u>	<u>6264</u>	<u>15.46</u>	2.49	2276

• 空间复杂度方面, 参数量主要由结点嵌入 $O(|\mathcal{V}|d)$ 、注意力/MLP 的映射参数 $O(d^2)$ 与层注意力参数 $O(d)$ 构成; 中间激活以注意力缓存为主 $O(BS^2 + BSd)$, 批内多层结点表示缓存为 $O(B_nLd)$, 诱导子图的稀疏邻接为 $O(|\mathcal{E}'|) \approx O(|\mathcal{V}|k)$. 故训练期总体空间复杂度可写为:

$$S_{\text{train}} = O(|\mathcal{V}|d + d^2 + |\mathcal{E}'| + BS^2 + B_nLd) \quad (21)$$

3.5 案例分析

在本文实验中, 我们使用 T-SNE 可视化工具投影所提模型学到的潜在表示. 为验证特征解耦的有效性, 我们选择 ML-1M 数据集, 并以解耦前后用户嵌入和物品嵌入的分布进行可视化, 如图 7 所示. 图 7 中, 我们使用不同颜色分别标记了全局特征和局部特征. 可以看出, 经过解耦模块后, 嵌入表示变得更加分离, 不同簇之间的区分也更加明显. 实验结果表明, 解耦模块在提升特征独立性和判别力方面起到了至关重要的作用.




图 7 使用 T-SNE 可视化解耦前后嵌入分布

4 结论

本文提出了融合时态信息和交互结构信息的多样化推荐方法, 首先利用注意力机制实现节点的时态信息和交互结构信息的融合, 然后设计了邻居选择函数, 在邻居选择后进行图卷积, 并通过层注意力机制和损失重加权进一步增强推荐结果的多样化. 本文方法在维持高准确性的同时, 有效增强了推荐内容的多样性, 满足用户对个性化和广泛选择的需求, 有效缓解了信息茧房效应, 使用户能够接触到更广阔的信息和观点. 通过在两个真实世界的大型数据集上进行广泛实验, 本文方法证明了其在特征嵌入的多样性上超越了当前最先进的推荐技术. 实验结果不仅凸显了本文方法的有效性, 更重要的是, 清晰地证实了时态信息对于捕捉用户动态兴趣的必要性和重要性.

尽管本研究提出的 TIEDRec 方法在多样性和准确性方面表现出了显著优势,但仍存在一些局限性. TIEDRec 中采用的时态信息增强策略依赖于历史交互数据的时间序列,对于那些用户行为数据稀疏或缺乏时间标记的场景,可能会影响模型的表现.此外,尽管特征解耦和多样化邻居选择能够缓解过平滑问题,但在非常深的图结构中,模型仍可能面临信息丢失或特征过度平滑的风险,特别是在大规模图数据上,模型的计算复杂度和训练时间仍然是需要优化的关键问题.未来工作可以从以下几个方向展开:首先,可以在更多实际应用场景中进行跨领域验证,探讨 TIEDRec 如何在新闻推荐、视频推荐等具有强烈时效性的数据中实现更好的多样性和准确性的平衡.其次,针对时态信息处理的局限性,未来可以引入更复杂的时间建模方法,如自回归模型或时序图神经网络,以增强模型在变化剧烈场景下的适应能力.另外,考虑到模型计算和训练时间的瓶颈,可以引入图稀疏化、邻域采样等加速技术,进一步提高 TIEDRec 的计算效率,尤其是在大规模数据集上.最后,未来还可以尝试结合用户长期与短期兴趣的多维度建模,从而提升对用户行为演化的捕捉能力,进一步优化多样性和个性化推荐效果.

References

- [1] Wang SJ, Hu L, Wang Y, He XN, Sheng QZ, Orgun MA, Cao LB, Ricci F, Yu PS. Graph learning based recommender systems: A review. In: Proc. of the 30th Int'l Joint Conf. on Artificial Intelligence. IJCAI, 2021. 4644–4652. [doi: 10.24963/ijcai.2021/630]
- [2] Zhang ZZ, Wang B. Prompt learning for news recommendation. In: Proc. of the 46th Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. Taipei: ACM, 2023. 227–237. [doi: 10.1145/3539618.3591752]
- [3] Chen YA, Xie X, Lin SD, Chiu A. WSDM cup 2018: Music recommendation and churn prediction. In: Proc. of the 11th ACM Int'l Conf. on Web Search and Data Mining. Marina Del Rey: ACM, 2018. 8–9. [doi: 10.1145/3159652.3160605]
- [4] Chen C, Ma W, Zhang M, Wang Z, He X, Wang C, Liu Y, Ma S. Graph heterogeneous multi-relational recommendation. In: Proc. of the 35th AAAI Conf. on Artificial Intelligence. AAAI, 2021. 3958–3966. [doi: 10.1145/3336191.3371827]
- [5] Qian ZS, Zhao C, Yu QY, Li DM. Information fusion recommendation approach combining attention CNN and GNN. Ruan Jian Xue Bao/Journal of Software, 2023, 34(5): 2317–2336 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6405.htm> [doi: 10.13328/j.cnki.jos.006405]
- [6] Yan MS, Cheng ZY, Sun J, Wang FS, Sun FM. Two-stage learning for multi-behavior recommendation. Ruan Jian Xue Bao/Journal of Software, 2024, 35(5): 2446–2465 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6897.htm> [doi: 10.13328/j.cnki.jos.006897]
- [7] Morik M, Singh A, Hong J, Joachims T. Controlling fairness and bias in dynamic learning-to-rank. In: Proc. of the 43rd Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. ACM, 2020. 429–438. [doi: 10.1145/3397271.3401100]
- [8] Zhang GX, Yuan G, Cheng DB, Liu L, Li JY, Zhang SC. Mitigating propensity bias of large language models for recommender systems. ACM Trans. on Information Systems, 2025, 43(6): 150. [doi: 10.1145/3736404]
- [9] Qian ZS, Ye ZL, Yao CS, Zhang D, Huang H, Qin LY. Lightweight GCN recommendation combining adaptive period and interest factor. Ruan Jian Xue Bao/Journal of Software, 2024, 35(6): 2974–2998 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6915.htm> [doi: 10.13328/j.cnki.jos.006915]
- [10] Zheng Y, Gao C, Chen L, Jin DP, Li Y. DGCN: Diversified recommendation with graph convolutional networks. In: Proc. of the 30th Web Conf. Ljubljana: ACM, 2021. 401–412. [doi: 10.1145/3442381.3449835]
- [11] Wang K, Wang Y, Liu JY, Deng JZ. Graph convolutional collaborative filtering recommendation algorithm based on rényi differential privacy. Ruan Jian Xue Bao/Journal of Software, 2025, 36(3): 1202–1217 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/7165.htm> [doi: 10.13328/j.cnki.jos.007165]
- [12] Ge YQ, Zhao SY, Zhou HL, Pei CH, Sun F, Ou WW, Zhang YF. Understanding echo chambers in e-commerce recommender systems. In: Proc. of the 43rd Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. ACM, 2020. 2261–2270. [doi: 10.1145/3397271.3401431]
- [13] Shi XY, Liu QL, Xie H, Wu D, Peng B, Shang MS, Lian DF. Relieving popularity bias in interactive recommendation: A diversity-novelty-aware reinforcement learning approach. ACM Trans. on Information Systems, 2024, 42(2): 52. [doi: 10.1145/3618107]
- [14] Dang YZ, Zhang JH, Liu YT, Yang EN, Liang YL, Guo GB, Zhao JZ, Wang XW. Augmenting sequential recommendation with balanced relevance and diversity. In: Proc. of the 39th AAAI Conf. on Artificial Intelligence. Philadelphia: AAAI, 2025. 11563–11571. [doi: 10.1609/aaai.v39i11.33258]
- [15] Liu YL, Zhang Y. Diversity-promoting recommendation with dual-objective optimization and dual consideration. IEEE Trans. on Knowledge and Data Engineering, 2025, 37(5): 2391–2404. [doi: 10.1109/TKDE.2025.3543285]

- [16] Kim J, Kang U. Sequentially diversified and accurate recommendations in chronological order for a series of users. In: Proc. of the 18th ACM Int'l Conf. on Web Search and Data Mining. Hannover: ACM, 2025. 811–819. [doi: [10.1145/3701551.3703564](https://doi.org/10.1145/3701551.3703564)]
- [17] Zhang S, Yao LN, Sun AX, Tay Y. Deep learning based recommender system: A survey and new perspectives. *ACM Computing Surveys*, 2020, 52(1): 5. [doi: [10.1145/3285029](https://doi.org/10.1145/3285029)]
- [18] Zou LX, Xia L, Gu YL, Zhao XY, Liu WD, Huang JX, Yin DW. Neural interactive collaborative filtering. In: Proc. of the 43rd Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. ACM, 2020. 749–758. [doi: [10.1145/3397271.3401181](https://doi.org/10.1145/3397271.3401181)]
- [19] Xue HJ, Dai XY, Zhang JB, Huang SJ, Chen JJ. Deep matrix factorization models for recommender systems. In: Proc. of the 26th Int'l Joint Conf. on Artificial Intelligence. Melbourne: IJCAI, 2017. 3203–3209. [doi: [10.24963/ijcai.2017/447](https://doi.org/10.24963/ijcai.2017/447)]
- [20] Xiao ZB, Yang LW, Jiang W, Wei Y, Hu Y, Wang H. Deep multi-interest network for click-through rate prediction. In: Proc. of the 29th ACM Int'l Conf. on Information & Knowledge Management. ACM, 2020. 2265–2268. [doi: [10.1145/3340531.3412092](https://doi.org/10.1145/3340531.3412092)]
- [21] Huang X, Kou Y, Shen DR, Nie TZ, Li D. Exploiting item relationships with dual-channel attention networks for session-based recommendation. In: Proc. of the 20th Int'l Conf. on Web Information Systems and Applications. Chengdu: Springer, 2023. 198–205. [doi: [10.1007/978-981-99-6222-8_17](https://doi.org/10.1007/978-981-99-6222-8_17)]
- [22] Shi MH, Shen DR, Kou Y, Nie TZ, Yu G. Next point-of-interest recommendation approach with global and local feature fusion. *Ruan Jian Xue Bao/Journal of Software*, 2023, 34(2): 786–801 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6712.htm> [doi: [10.13328/j.cnki.jos.006712](https://doi.org/10.13328/j.cnki.jos.006712)]
- [23] Kang WC, McAuley J. Self-attentive sequential recommendation. In: Proc. of the 2018 IEEE Int'l Conf. on Data Mining. Singapore: IEEE, 2018. 197–206. [doi: [10.1109/ICDM.2018.00035](https://doi.org/10.1109/ICDM.2018.00035)]
- [24] Sun F, Liu J, Wu J, Pei CH, Lin X, Ou WW, Jiang P. BERT4Rec: Sequential recommendation with bidirectional encoder representations from Transformer. In: Proc. of the 28th ACM Int'l Conf. on Information and Knowledge Management. Beijing: ACM, 2019. 1441–1450. [doi: [10.1145/3357384.3357895](https://doi.org/10.1145/3357384.3357895)]
- [25] Wang X, He XN, Wang M, Feng FL, Chua TS. Neural graph collaborative filtering. In: Proc. of the 42nd Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. Paris: ACM, 2019. 165–174. [doi: [10.1145/3331184.3331267](https://doi.org/10.1145/3331184.3331267)]
- [26] He XN, Deng K, Wang X, Li Y, Zhang YD, Wang M. LightGCN: Simplifying and powering graph convolution network for recommendation. In: Proc. of the 43rd Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. ACM, 2020. 639–648. [doi: [10.1145/3397271.3401063](https://doi.org/10.1145/3397271.3401063)]
- [27] Chen L, Wu L, Hong RC, Zhang K, Wang M. Revisiting graph based collaborative filtering: A linear residual graph convolutional network approach. In: Proc. of the 34th AAAI Conf. on Artificial Intelligence. New York: AAAI, 2020. 27–34. [doi: [10.1609/aaai.v34i01.5330](https://doi.org/10.1609/aaai.v34i01.5330)]
- [28] Zhao RM, Sun SY, Yan FL, Peng J, Ju SG. Multi-interest aware sequential recommender system based on contrastive learning. *Journal of Computer Research and Development*, 2024, 61(7): 1730–1740. [doi: [10.7544/issn1000-1239.202330622](https://doi.org/10.7544/issn1000-1239.202330622)]
- [29] Li C, You XY, Zhang M. Decoupled graph convolution network for collaborative filtering. *Journal of Chinese Information Processing*, 2023, 37(11): 131–141. [doi: [10.3969/j.issn.1003-0077.2023.11.014](https://doi.org/10.3969/j.issn.1003-0077.2023.11.014)]
- [30] Yin Q, Fang H, Sun Z, Ong YS. Understanding diversity in session-based recommendation. *ACM Trans. on Information Systems*, 2024, 42(1): 24. [doi: [10.1145/3600226](https://doi.org/10.1145/3600226)]
- [31] Ziegler CN, McNee SM, Konstan JA, Lausen G. Improving recommendation lists through topic diversification. In: Proc. of the 14th Int'l Conf. on World Wide Web. Chiba: ACM, 2005. 22–32. [doi: [10.1145/1060745.1060754](https://doi.org/10.1145/1060745.1060754)]
- [32] Hou L, Liu KC, Liu JG, Zhang RT. Solving the stability-accuracy-diversity dilemma of recommender systems. *Physica A: Statistical Mechanics and its Applications*, 2017, 468: 415–424. [doi: [10.1016/j.physa.2016.10.083](https://doi.org/10.1016/j.physa.2016.10.083)]
- [33] Sha CF, Wu XW, Niu JY. A framework for recommending relevant and diverse items. In: Proc. of the 25th Int'l Joint Conf. on Artificial Intelligence. New York: ACM, 2016. 3868–3874.
- [34] Gao CM, Wang SQ, Li SJ, Chen JW, He XN, Lei WQ, Li B, Zhang Y, Jiang P. CIRS: Bursting filter bubbles by counterfactual interactive recommender system. *ACM Trans. on Information Systems*, 2024, 42(1): 14. [doi: [10.1145/3594871](https://doi.org/10.1145/3594871)]
- [35] Yang LW, Wang SJ, Tao YZ, Sun JK, Liu XL, Yu PS, Wang TQ. DGRec: Graph neural network for recommendation with diversified embedding generation. In: Proc. of the 16th ACM Int'l Conf. on Web Search and Data Mining. Singapore: ACM, 2023. 661–669. [doi: [10.1145/3539597.3570472](https://doi.org/10.1145/3539597.3570472)]
- [36] Hu CH, Chen C, Chen TR, Miao H, Chen W. Diversified real-time user interest recommendation based on self-attention mechanism. *Systems Engineering-theory & Practice*, 2023, 43(9): 2579–2594. (in Chinese with English abstract). [doi: [10.12011/SETP2021-1802](https://doi.org/10.12011/SETP2021-1802)]
- [37] Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez AN, Kaiser Ł, Polosukhin I. Attention is all you need. In: Proc. of the 31st Int'l Conf. on Neural Information Processing Systems. Long Beach: ACM, 2017. 6000–6010.

- [38] Li J, Tu ZP, Yang BS, Lyu MR, Zhang T. Multi-head attention with disagreement regularization. In: Proc. of the 2018 Conf. on Empirical Methods in Natural Language Processing. Brussels: ACL, 2018. 2897–2903. [doi: 10.18653/v1/D18-1317]
- [39] Liang YL, Qian TY, Li Q, Yin HZ. Enhancing domain-level and user-level adaptivity in diversified recommendation. In: Proc. of the 44th Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. ACM, 2021. 747–756. [doi: 10.1145/3404835.3462957]
- [40] Rendle S, Freudenthaler C, Gantner Z, Schmidt-Thieme L. BPR: Bayesian personalized ranking from implicit feedback. In: Proc. of the 25th Conf. on Uncertainty in Artificial Intelligence. Montreal: ACM, 2009. 452–461.
- [41] Kipf TN, Welling M. Semi-supervised classification with graph convolutional networks. In: Proc. of the 5th Int'l Conf. on Learning Representations. Toulon: OpenReview.net, 2017
- [42] Glorot X, Bengio Y. Understanding the difficulty of training deep feedforward neural networks. In: Proc. of the 13th Int'l Conf. on Artificial Intelligence and Statistics. Sardinia: PMLR, 2010. 249–256.

附中文参考文献

- [5] 钱忠胜, 赵畅, 俞情媛, 李端明. 结合注意力 CNN 与 GNN 的信息融合推荐方法. 软件学报, 2023, 34(5): 2317–2336. <http://www.jos.org.cn/1000-9825/6405.htm> [doi: 10.13328/j.cnki.jos.006405]
- [6] 严明时, 程志勇, 孙静, 王法胜, 孙福明. 基于两阶段学习的多行为推荐. 软件学报, 2024, 35(5): 2446–2465. <http://www.jos.org.cn/1000-9825/6897.htm> [doi: 10.13328/j.cnki.jos.006897]
- [9] 钱忠胜, 叶祖隼, 姚昌森, 张丁, 黄恒, 秦朗悦. 融合自适应周期与兴趣量因子的轻量级 GCN 推荐. 软件学报, 2024, 35(6): 2974–2998. <http://www.jos.org.cn/1000-9825/6915.htm> [doi: 10.13328/j.cnki.jos.006915]
- [11] 王锬, 王永, 刘金源, 邓江洲. 基于 Rényi 差分隐私的图卷积协同过滤推荐算法. 软件学报, 2025, 36(3): 1202–1217. <http://www.jos.org.cn/1000-9825/7165.htm> [doi: 10.13328/j.cnki.jos.007165]
- [22] 石美惠, 申德荣, 寇月, 聂铁铮, 于戈. 融合全局和局部特征的下一个兴趣点推荐方法. 软件学报, 2023, 34(2): 786–801. <http://www.jos.org.cn/1000-9825/6712.htm> [doi: 10.13328/j.cnki.jos.006712]
- [28] 赵容梅, 孙思雨, 鄢凡力, 彭舰, 璐生根. 基于对比学习的多兴趣感知序列推荐系统. 计算机研究与发展, 2024, 61(7): 1730–1740. [doi: 10.7544/issn1000-1239.202330622]
- [29] 李驰, 游小钰, 张溢. 基于解耦图卷积网络的协同过滤推荐模型. 中文信息学报, 2023, 37(11): 131–141. [doi: 10.3969/j.issn.1003-0077.2023.11.014]
- [36] 胡春华, 陈聪, 陈泰任, 等. 基于自注意力机制的用户实时兴趣多样性推荐. 系统工程理论与实践, 2023, 43(9): 2579–2594. [doi: 10.12011/SETP2021-1802]

作者简介

袁冠, 博士, 教授, 博士生导师, CCF 高级会员, 主要研究领域为人工智能, 大数据技术, 机器学习, 计算智能.

曾翔宇, 博士生, 主要领域为推荐系统.

张桂衔, 博士生, CCF 学生会员, 主要研究领域为推荐系统.

张艳梅, 博士, 副教授, CCF 专业会员, 主要研究领域为软件分析与测试, 软件缺陷预测.

张宇航, 硕士生, 主要研究领域为图像增强.

杨佩锦, 博士生, 主要研究领域为推荐系统.