

## 基于图神经网络的多行为推荐综述

杨佩锦<sup>1),2)</sup> 袁冠<sup>1),2)</sup> 张桂銜<sup>1),2)</sup> 乔少杰<sup>3)</sup> 王森章<sup>4)</sup> 李博涵<sup>5)</sup>

<sup>1)</sup>(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)

<sup>2)</sup>(中国矿业大学矿山数字化工程中心 江苏 徐州 221116)

<sup>3)</sup>(成都信息工程大学软件工程学院 成都 610225)

<sup>4)</sup>(中南大学计算机科学与工程学院 长沙 410083)

<sup>5)</sup>(南京航空航天大学人工智能学院 南京 210016)

**摘要** 推荐系统是解决信息过载的重要技术之一,能够满足用户的个性化需求。传统的单行为推荐主要依赖用户的目标行为数据,然而这类数据的规模和其他行为数据相差悬殊,如果仅基于目标行为数据进行推荐,难以全面刻画用户兴趣,制约推荐效果。为应对这一局限,推荐系统逐渐开始重视用户和物品的多种类型交互,开拓了多行为推荐,利用用户的多样化行为,全面理解用户兴趣和行为模式,为用户提供准确和丰富的个性化推荐。近年来,图神经网络的发展为多行为推荐的实现提供了有力支持,在用户-项目的多关系建模和表示学习上表现出色。本文对基于图神经网络的多行为推荐研究进行了系统综述:首先,从用户兴趣、多行为关联和知识辅助三种建模角度,梳理并分析了基于图神经网络的多行为推荐方法;其次,介绍并讨论了在社交推荐、序列推荐和会话推荐中,图神经网络与多行为推荐的结合与应用;然后,本文探讨了如何对多行为推荐进行优化,并介绍了现有的基于图神经网络实现的方法;最后,对多行为推荐未来的研究进行展望。

**关键词** 图神经网络;多行为推荐;推荐场景;模型优化;表示学习

中图法分类号 TP18

DOI号 10.11897/SP.J.1016.2026.01093

## A Survey of Multi-Behavior Recommendation Based on Graph Neural Networks

YANG Pei-Jin<sup>1),2)</sup> YUAN Guan<sup>1),2)</sup> ZHANG Gui-Xian<sup>1),2)</sup> QIAO Shao-Jie<sup>3)</sup>  
WANG Sen-Zhang<sup>4)</sup> LI Bo-Han<sup>5)</sup>

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

<sup>2)</sup>(Engineering Research Center of Mine Digitalization, China University of Mining and Technology, Xuzhou, Jiangsu 221116)

<sup>3)</sup>(School of Software Engineering, Chengdu University of Information Technology, Chengdu 610225)

<sup>4)</sup>(School of Computer Science and Engineering, Central South University, Changsha 410083)

<sup>5)</sup>(School of Artificial Intelligence, Nanjing University of Aeronautics and Astronautics, Nanjing 210016)

**Abstract** Recommender systems represent a pivotal technology for addressing information overload, enabling the fulfillment of users' personalized needs. Traditional single-behavior recommendation primarily relies on users' target behavior data. However, the scale of such data significantly diverges from that of other behavior data. Consequently, recommendations based solely on target behavior data struggle to comprehensively delineate user interests, thereby constraining

收稿日期:2025-06-12;在线发布日期:2026-02-04。本课题得到国家自然科学基金(No. 62172443)、徐州市重点研发计划项目(No. KC23296)、中国矿业大学研究生创新计划项目(No. 2024WLKXJ183)、中央高校基本科研业务费专项资金(No. 2024-10949)、江苏省研究生科研与实践创新计划(No. KYCX24\_2781)资助。杨佩锦,博士研究生,中国计算机学会(CCF)学生会员,主要研究领域为图神经网络、推荐系统。E-mail:peijin@cumt.edu.cn。袁冠(通信作者),博士,教授,中国计算机学会(CCF)高级会员,主要研究领域为智能信息数据处理、大规模图数据计算。E-mail:yuanguan@cumt.edu.cn。张桂銜,博士研究生,中国计算机学会(CCF)学生会员,主要研究领域为可信人工智能、图表示学习。乔少杰,博士,教授,中国计算机学会(CCF)杰出会员,主要研究领域为大数据技术与应用、领域大数据分析。王森章,博士,教授,中国计算机学会(CCF)高级会员,主要研究领域为时空大数据挖掘、图数据挖掘。李博涵,博士,副教授,中国计算机学会(CCF)杰出会员,主要研究领域为推荐系统、知识图谱。

recommendation efficacy. To mitigate this limitation, recommender systems have progressively emphasized multifaceted interactions between users and items, pioneering multi-behavior recommendation. This approach leverages users' diverse behaviors to holistically comprehend user interests and behavioral patterns, thereby delivering accurate and enriched personalized recommendations. In recent years, the advancement of graph neural networks has provided robust support for the implementation of multi-behavior recommendation, demonstrating excellence in multi-relational modeling and representation learning for user-item interactions. This paper presents a systematic review of multi-behavior recommendation research based on graph neural networks. First, we organize and analyze multi-behavior recommendation methods grounded in graph neural networks from three modeling perspectives—user interests, multi-behavior associations, and knowledge-assisted enhancement. Subsequently, we introduce and discuss the integration and applications of graph neural networks with multi-behavior recommendation in social recommendation, sequential recommendation, and session-based recommendation. Furthermore, we explore optimization strategies for multi-behavior recommendation and introduce existing methods implemented via graph neural networks. Ultimately, we offer an outlook on future research directions in multi-behavior recommendation.

**Keywords** graph neural network; multi-behavior recommendation; recommended scenario; model optimization; representation learning

## 1 引 言

推荐系统通过信息过滤,为用户提供个性化服务,提升用户体验并促进平台收益。推荐系统能为不同行业提供个性化支持,例如电子商务网站、短视频平台、旅游平台和新闻平台<sup>[1-2]</sup>。用户依赖推荐系统缓解信息过载问题,并从海量的项目中筛选他们感兴趣和可能需要的信息。准确地从历史交互记录中建模用户偏好,是构建高效推荐系统的核心。

经过几十年的发展,推荐系统的主流建模范式经历了从基于邻域的方法到基于表示学习的方法的演变<sup>[3]</sup>。传统的近邻方法直接推荐与用户历史项目相似的项目<sup>[4]</sup>,因其简单和高效在早期应用中效果显著。但其缺点在于无法捕捉复杂的用户-项目(User-Item, U-I)关系,且缺乏系统优化过程,限制了模型表达能力。随着机器学习的发展,基于表示学习的方法开始出现,尝试将用户和项目特征编码为共享空间中的连续向量,如基于矩阵分解的方法<sup>[5]</sup>和基于因子分解机(Factorization Machine, FM)的方法<sup>[6]</sup>。这种方法能够有效提升嵌入表示的质量,并引入了明确的优化目标(如最小化重构误差),通过梯度下降等优化算法来系统地调整模型参数,引起了研究者的极大兴趣。此后,各种深度学习

技术也被引入推荐领域,用于学习用户和项目的表示,如采用多层感知机的 NCF(Neural Collaborate Filtering)<sup>[7]</sup>和 DeepFM<sup>[8]</sup>等。结合深度学习的推荐模型能够有效捕捉非线性和复杂的用户-项目关系,并能够整合丰富的数据源,目前成为推荐系统在学术研究和工业应用中的主要方法。

在基于深度学习的推荐模型中,基于图表示学习的方法为建模推荐系统中丰富的异构数据提供了一个统一的视角<sup>[9]</sup>。从图的角度考虑推荐系统中的各方面信息,通过将用户和项目分别表示为节点,将他们间的交互表示为边,能够有效展现出用户和项目之间的关系网络。此外,当整合结构化的外部信息(用户之间的社交关系和项目之间的关联关系)时,将推荐任务通过图来建模的优势尤为明显。基于图表示学习的推荐方法早期利用图嵌入技术来建模节点间关系。近年来,受图神经网络(Graph Neural Network, GNN)<sup>[10]</sup>的卓越的节点表示学习能力、结构信息挖掘能力和灵活的传播机制的启发,出现了大量基于 GNN 的推荐模型。GNN 可以自然地显式编码关键的拓扑结构,以改进用户和项目的表示,并通过信息传播机制编码用户之间以及项目之间的相似性。例如,当用户 A 与用户 B 具有相似的购买行为时, GNN 可以推测用户 A 可能对用户 B 购买的商品产生兴趣,进而改善推荐的准确性和多样性。

在学术界和工业界中,大多数推荐工作致力于研究单一的、关于用户目标行为的推荐,即单行为推荐<sup>[11]</sup>。原因在于,目标行为数据通常与用户偏好和平台利益直接相关,能以明确的方式为平台提供反馈,也便于收集和利用。然而单行为推荐没有考虑用户在做出决策之前的行为路径,忽略了用户兴趣演化的过程和决策的潜在驱动因素。这就导致训练的推荐模型无法全面捕捉用户的多样化兴趣和行为,也难以理解用户完整的决策过程,从而制约了推荐的准确性和多样化。为了提升推荐性能,满足用户多层次需要,研究者根据用户和项目交互行为的多样性,开拓了多行为推荐的研究<sup>[12]</sup>。如图 1 所示,用户通过浏览、加购物车和收藏等行为与商品产生交互,最后购买自己需要或最感兴趣的物品。图中四种边代表四类行为,购买为目标行为,其他为辅助行为。从技术演变的路径来看,多行为推荐的发展从早期的基于矩阵分解的方法过渡到如今基于 GNN 的方法。在基于矩阵分解的方法中,集体矩阵分解(Collective Matrix Factorization, CMF)<sup>[13]</sup>最早利用多种反馈类型之间的共享信息来实现用户和项目多关系学习。SVD++<sup>[14]</sup>和多反馈个性化排序(Multiple Feedback Personalized Ranking, MFPR)<sup>[15]</sup>等方法也通过辅助反馈数据来补充用户向量的表示。然而,这些方法为每种交互的反馈类型生成独立的潜在因子,导致它们难以区分不同反馈的偏好强度,影响多反馈精度。为了解决这一问题,一些研究在 BPR(Bayesian Personalized Ranking)负采样器中把多种反馈类型融合,通过为不同的用户反馈类型分配不同的偏好等级来指导项目采样,如多通道贝叶斯个性化排序(Multi-Channel Bayesian Personalized Ranking)<sup>[16]</sup>等。尽管如此,基于矩阵分解的方法仍然面临挑战,主要体现在难以捕捉反馈之间的复杂依赖性,且无法有效挖掘用户与项目之间的高阶关系。




图 1 多行为交互示意图

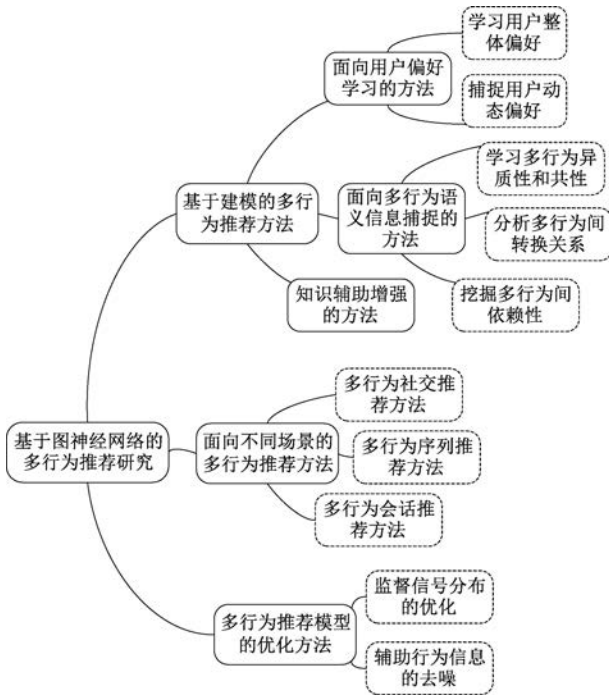
作为新兴的研究方向,多行为推荐与 GNN 的结合取得了巨大成功。从用户-项目交互图的角度

来看,GNN 提供了强大的系统性工具来探索用户-项目高阶关系,这对多行为推荐的嵌入传播和聚合提供了技术支持。

目前,尽管已有综述从多个维度对 GNN 驱动的推荐系统进行系统性梳理<sup>[3,17-18]</sup>,也有研究对多行为推荐中的部分方法做出了初步总结分析<sup>[19-20]</sup>,但仍缺乏以 GNN 为核心视角,对多行为推荐建模范式进行系统性解构与归纳的工作。Gao 等人<sup>[3]</sup>围绕基于 GNN 的推荐系统展开全面综述,涵盖了推荐系统在不同阶段、应用场景与目标导向下的研究进展,但是针对多行为推荐领域未能做出更系统化的深入探讨。Li 等人<sup>[17]</sup>和 Sharma 等人<sup>[18]</sup>分别从社交推荐的任务场景和 GNN 模型结构出发,对 GNN 在社交推荐中的应用进行了综述,但二者在多行为社交推荐方面均缺乏必要的介绍或阐述。Chen 等人<sup>[19]</sup>主要聚焦多行为序列推荐,并探讨了 GNN 在该任务上的应用路径,但未能涉及多行为推荐与其他关键场景的适配机制。He 等人<sup>[20]</sup>对推荐系统中的用户行为建模方法进行了综合探讨,但其技术分析框架未能深入揭示多行为推荐的独特优势与理论边界。随着多行为推荐研究的迅速发展,考虑到 GNN 在当前多行为推荐工作中应用的广泛性和有效性,本综述通过对国内外知名期刊和会议上的著作进行调研,对基于 GNN 的多行为推荐方法进行了全面和系统的概述,讨论其基本思想和最新进展,旨在为各学科的研究人员提供有价值的资源。对比现有综述,本文无论从推荐场景还是应用角度,具有更强的全面性和综合性。本文的主要贡献如下:

(1)系统综述。本文提供了基于 GNN 的多行为推荐方法在多种场景中最新进展的系统综述,涵盖通用场景、社交推荐、序列推荐和会话推荐。本文描述了每个场景中的代表工作和模型,并进行必要的比较和讨论。另外,本文还从模型优化的角度对代表性方法进行分类和总结,包括对监督信号分布的优化和对辅助行为信息的去噪。

(2)总体框架。本文整合相关论文的研究成果,结合推荐系统分类学理论,对算法特征与场景特性进行系统梳理和深入讨论,提出基于图神经网络的多行为推荐通用框架。该框架包含三个核心模块:基于建模的多行为推荐方法、面向不同场景的多行为推荐方法以及多行为推荐模型优化方法,如图 2 所示。



(3)未来工作。本文还指出了未来四个具有潜在价值的研究方向,旨在为未来的研究提供启示。对这四个方向的深入研究能够为实际的多行为推荐系统提供更加有效的解决方案,有利于多行为推荐领域的持续发展和进步。

## 2 背景

### 2.1 问题定义

在推荐系统中,通常存在一种需要优化的用户目标行为。目标行为关系到推荐的成功率,并且和用户偏好最为相关。传统的推荐算法一般针对这种单一类型的行为进行设计,忽略了浏览和点击等交互。这些行为数据在服务器中普遍存在,多行为推荐研究的重点即是利用这些多种类型的交互行为来改进针对目标行为的推荐。为便于多行为推荐的描述,本文给出相关符号定义,如表 1 所示。

用户集合和项目集合可以分别定义为  $U$  和  $I$ ,  $|U|$  和  $|I|$  表示用户和项目的数量。用户和项目以及它们之间的关系可以通过一个异构图  $G=(V, E)$  来表示,用户和项目表示为图中的节点,二者的关系表示为节点之间的边。其中,  $V=U \cup I$  为节点集合,  $E$  为边集合。多行为推荐场景可能包含  $K$  种不同的行为。为反映用户与项目之间的交互情况,本文定义一个三维交互张量  $Y \in \mathbb{R}^{|U| \times |I| \times K}$ , 其中的每

个元素值均为 1 或 0,如果  $u$  通过行为  $k$  和  $i$  产生交互,则  $y_{ui}^k=1$ ; 否则  $y_{ui}^k=0$ 。此处 0 或 1 也可以进一步量化个体交互的强度,本文为了简化,将值表示为 0 或 1。根据上述内容,多行为推荐问题可被描述为:

输入:基于  $K$  种行为的多行为交互张量  $Y \in \mathbb{R}^{|U| \times |I| \times K}$ ;

输出:一个预测用户  $u$  在目标行为下与项目  $i$  产生交互概率的模型。

表 1 符号定义

符号	表示含义
$U/I$	用户/项目集合
$ U / I $	用户/项目数量
$G$	用户-项目交互二部图
$V/E$	二部图 $G$ 中点/边集合
$Y$	关于图的交互张量
$y_i^k$	张量 $Y$ 中的独立元素
$H^{(l)}$	第 $l$ 层的特征矩阵
$A$	邻接矩阵
$D$	度矩阵
$W^{(l)}$	第 $l$ 层的权重矩阵
$\alpha_{ij}$	$j$ 对于节点 $i$ 的注意力系数
$h/h'$	输入/输出的节点特征
$\sigma(\cdot)$	非线性激活函数

### 2.2 图神经网络

社交网络<sup>[21]</sup>和交通网络<sup>[22]</sup>等复杂关系数据普遍适合采用图结构进行建模。近年来,随着这些非欧几里得数据和图结构的广泛结合,图结构的学习研究得到了持续发展和深入探索。在此基础上,图神经网络也迅速成为研究热点。GNN 的兴起建立在图论中的消息传递框架之上,其设计借鉴了卷积神经网络(Convolution Neural Network, CNN)<sup>[23]</sup>的局部连接与参数共享思想,并通过学习图结构数据的低维表示实现端到端的特征提取。GNN 能够在图结构上捕获节点邻域特征,通过消息传递实现特征提取和表示学习。本节将从图结构和网络架构两方面对 GNN 展开进一步探讨。

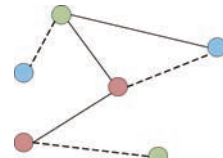
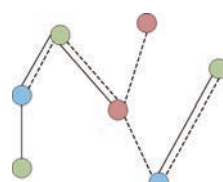
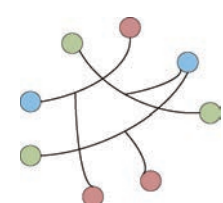
#### 2.2.1 建模多行为推荐的常用图结构

多行为推荐中常用的图结构主要包括异构图、多重图和超图三种,它们的结构示意图如表 2 所示。异构图中不同的节点和边代表它们的种类和含义的不同。多行为建模中,用户与项目可表示为两类节点,各类行为可建模为异质边。该方式既能体现行为多样性,又可揭示不同行为下的  $U-I$  关联模式,为推荐提供细致且结构化的表示基础。多重图的节点间可存在多种边,能够有效刻画用户与项目之间

的复合关系,并提供更细粒度的结构支撑。超图中多个节点可通过一条超边。不同类型的超边可表示不同行为,体现多个用户与项目之间的高阶交互。

该建模方式有助于捕捉多行为数据中隐含的复杂语义结构,为行为间关联建模与联合表示学习提供更丰富的结构信息支撑。

表 2 不同图结构对比

名称	结构	GNN 模型	多行为推荐建模
异构图		HetGNN <sup>[24]</sup> 关键步骤: (1)通过随机游走采样异构邻居节点; (2)将节点多样化内容转换为内容嵌入; (3)聚合内容嵌入并生成节点的最终表示	(1)用户和项目建模为节点,不同行为建模为不同边; (2)优势:可建模全部行为类型; 劣势:无法全面体现 U-I 交互
多重图		MHGNN <sup>[25]</sup> 关键步骤: (1)将多重图分解为多个子图; (2)学习多关系权重,聚合子图邻接矩阵; (3)通过多层图卷积捕获异构元路径信息; (4)融合各层输出,生成节点嵌入	(1)节点间允许多条边存在,表示用户与项目之间的多交互关系; (2)优势:更全面展示交互信息、细粒度更高; 劣势:建模复杂
超图		HGNN <sup>[26]</sup> 关键步骤: (1)基于超图生成拉普拉斯矩阵; (2)将节点特征转换到频域并进行卷积操作; (3)通过超边进行特征传播和邻域聚合	(1)不同超边代表不同行为,连接用户节点及交互的项目节点; (2)优势:能够直接建模高阶关系; 劣势:超参数较多,调优困难

假如给定用户集合  $U$ , 项目集合  $I$  和用户行为集合  $\mathcal{R}$ , 三种图结构建模用户与项目的多行为交互的形式化表达如下:

(1)异构图。给定多行为异构图  $G_{het} = (U, I, \epsilon_h)$ 。  $\epsilon_h = \bigcup_{r \in \mathcal{R}} e_h^r$  为节点间不同种类边的集合, 每条边代表特定的行为。对于产生交互的用户  $u \in U$  和项目  $i \in I$ , 节点间结构可以表示为  $(u, e_h^r, i)$ ,  $e_h^r$  表示用户  $u$  和项目  $i$  的交互行为。

(2)多重图。给定多行为多重图  $G_m = (U, I, \epsilon_m)$ , 其中,  $\epsilon_m = \bigcup_{r \in \mathcal{R}} e_m^r$  为边集合, 每条边代表特定的行为。对于产生交互的用户  $u \in U$  和项目  $i \in I$ , 节点间结构可以表示为  $(u, e_m, i)$ 。多重图中节点间可能存在多条不同类型的边,  $e_m \in \epsilon_m$  表示节点  $u$  和  $i$  间边集合, 用于表示全部交互。

(3)超图。给定多行为超图  $G_h$ , 由于图中  $k$  条超边对应用户的  $k$  种行为类型, 因此该超图可以表示为  $G_h = \{G_h^1, G_h^2, \dots, G_h^k\}$ 。对于子图  $G_h^r = (u, e^r, \mathcal{J})$ ,  $\mathcal{J} \in I$  为用户  $u$  通过行为  $r \in \mathcal{R}$  交互的项目节点集合。子图中的项目节点按照  $u \in U$  的访问顺序通过超边  $e^r$  进行连接。

表 2 展示了多行为推荐常用的三种图结构, 列举了它们适用的代表性 GNN 模型及关键步骤, 并简要阐述了它们在建模中的优劣势。

## 2.2.2 常见的网络模型

GNN 通过迭代地收集邻域信息来捕捉图节点和边之间的高阶相关性, 核心操作是沿着结构化连接传播嵌入, 包括聚合邻域嵌入并将其与目标(节点或边)嵌入融合, 从而逐层更新图的嵌入表示。在这里, 本文对 5 种在多行为推荐中常用的 GNN 模型进行简要介绍。

(1)GCN(Graph Convolutional Network)<sup>[27]</sup>。图卷积网络是经典的谱域 GNN 模型, 通过卷积操作在图结构上进行信息传播和表示学习, 实现了图的半监督分类任务。GCN 能够捕捉图中复杂的结构和关系, 实现对图的全面和深层次的理解, 还具备较强的可扩展性和泛化能力, 能够适应不同规模和结构的图数据。GCN 的消息传播机制如公式 1 所示:

$$\mathbf{H}^{(l+1)} = \sigma(\tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}} \mathbf{H}^{(l)} \mathbf{W}^{(l)}), \quad (1)$$

其中,  $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}_N$  为无向图  $G$  中加入了自连接后的邻接矩阵,  $\mathbf{I}_N \in \mathbb{R}^{N \times N}$  为单位矩阵,  $\tilde{\mathbf{D}}$  为添加自连接后图  $G$  的度矩阵,  $\sigma(\cdot)$  为非线性激活函数,  $\mathbf{H}^{(l+1)}$  和  $\mathbf{H}^{(l)}$  分别为第  $l+1$  层和第  $l$  层的嵌入矩阵,  $\mathbf{W}^{(l)}$  为第  $l$  层的权重矩阵。

(2)GAT(Graph Attention Network)<sup>[28]</sup>。图注意力网络引入注意力机制执行图结构数据的节点分类。对于每个节点, GAT 通过前馈神经网络计算

其与邻居节点之间的注意力权重,并对邻域特征进行加权聚合,生成节点的最终表示。整体计算过程如公式(2)所示:

$$h'_i = \sigma \left( \sum_{j \in \mathcal{N}_i} \alpha_{ij} \mathbf{W}^{(l)} h_j \right), \quad (2)$$

其中,  $\alpha_{ij}$  为节点  $j$  对于节点  $i$  的注意力系数,  $h_j$  为输入的节点  $j$  的特征表示,  $h'_i$  为输出的节点  $i$  的特征表示,  $\mathcal{N}_i$  为节点  $i$  的邻居节点集合,  $\sigma(\cdot)$  为非线性激活函数,  $\mathbf{W}^{(l)}$  为第  $l$  层的权重矩阵。

(3) HetGNN (Heterogeneous Graph Neural Network)<sup>[24]</sup>。异构图神经网络核心是其独特的邻域采样策略,它使用随机游走来选择与每个节点强相关的异构邻居。在训练过程中, HetGNN 采用图上下文损失和批量梯度下降方法优化模型参数,使节点嵌入能够有效捕捉图的异构性和节点的丰富性。

(4) HGNN (Hypergraph Neural Network)<sup>[26]</sup>。超图神经网络的核心创新在于设计超边卷积操作,以进行高效的超图特征学习。HGNN 能够在超图结构上灵活捕捉多模态和异构数据中的复杂关联,实现高效的特征传播与聚合,为超图中复杂关联数据的表示学习提供了通用的解决方案。HGNN 中设计的超边卷积方法如公式 3 所示:

$$\mathbf{H}^{(l+1)} = \mathbf{D}_v^{-\frac{1}{2}} \mathbf{E} \mathbf{D}_e^{-1} \mathbf{E}^T \mathbf{D}_v^{-\frac{1}{2}} \mathbf{W}^{(l)}, \quad (3)$$

其中,矩阵  $\mathbf{E} \in \mathbb{R}^{|\mathcal{V}| \times |\mathcal{E}|}$  中的  $\mathbf{E}_{mn}$  表示超边  $m$  中是否包含节点  $n$ , 矩阵  $\mathbf{D}_v \in \mathbb{R}^{|\mathcal{V}| \times |\mathcal{V}|}$  中的对角元素表示包含该节点的超边数量, 矩阵  $\mathbf{D}_e \in \mathbb{R}^{|\mathcal{E}| \times |\mathcal{E}|}$  中对角元素表示该超边包含的节点数量。

(5) MHGCN (Multiplex Heterogeneous Graph Convolutional Network)<sup>[25]</sup>。多重异构图卷积网络包括两个关键部分:多重关系聚合和多重图卷积。在多重关系聚合阶段, MHGCN 区分不同类型边的重要性来聚合多关系;在多重图卷积阶段, MHGCN 通过不同的图卷积层捕获不同长度的异构元路径信息。然后将各层图卷积的输出进行融合,得到包含不同长度元路径信息的节点嵌入。

综上, GCN 与 GAT 设计的初衷主要面向全局特征提取。GCN 区分语义异质能力有限,但泛化能力强,可针对不同的拓扑结构进行针对性设计。GAT 支持语义差异化建模,在处理序列数据时具有优势。但由于注意力机制的计算成本随邻域节点增加呈二次增长,在处理大规模图时存在效率瓶颈; HetGNN 与 MHGCN 聚焦异构图的精细化建模,但 HetGNN 随机游走参数与 MHGCN 的元路径均依赖人工设定,导致二者在动态场景中受限; HG-

NN 利用超边捕获群体关联,突破了传统图论中二元边的拓扑约束,但超图拉普拉斯矩阵的构建需先验定义超边关系,限制了 HGNN 在处理实时增量数据时的灵活性。从多行为推荐角度来看, GCN 在处理更能体现多行为特性的结构上可作为首选。GAT 适合建模多行为强度差异,如果引入时序信息,在处理转化过程明确的数据时优势明显。HetGNN 擅长处理多类型行为的复杂数据, HGNN 可有效建模捕捉群体行为等非双边交互, MHGCN 适用于行为粒度多样、关系结构复杂的推荐场景。在实际应用中,需根据行为数据类型、图结构复杂度以及计算资源等条件权衡选择具体的神经网络模型。

### 2.3 GNN 在多行为推荐上的适用性

由于 GNN 在结构化信息利用、高阶连通性捕捉、多种信息源整合、监督信号利用等方面的优势,近年来与多行为推荐的结合取得了重要进展。

(1) 结构化信息利用。在多行为推荐领域, GNN 不仅能完成对用户和项目特征的学习,也能根据图结构的设计区分多种行为的重要性。通过为不同的边赋予不同权重, GNN 在优化目标行为的预测的同时,也能够充分考虑辅助行为的贡献,对交互数据达到最大化利用。另外,如果将用户个人信息和项目属性信息纳入建模, GNN 就能够获取用户和项目的结合其他特征的高质量表示,这对于多行为推荐在其他推荐场景中的应用是十分关键的。

(2) 高阶连通性捕捉。在多行为推荐中,交互模式相似的用户可能具有相似的行为习惯,因此,他们的节点嵌入也会呈现相似性,这与协同过滤的思想具有一致性<sup>[29]</sup>。一般方法主要依赖用户和项目间通过各种行为建立的直接关联,而忽略了通过其他用户或项目建立的间接关联,因此只学习到了一阶特征而未考虑高阶连通性的影响,无法完全捕捉协同过滤效应。利用 GNN 进行多行为推荐,能够通过图结构有效地捕捉用户间高阶行为关系和用户与项目的复杂依赖关系。无论是行为的多样性还是项目属性的丰富性, GNN 都能通过图上的多跳邻居关系进行信息传播和聚合,将这些高阶特征融入节点嵌入中。通过 GNN 实现多行为协同过滤,能够更全面地利用多类型交互信息并表达用户的多维偏好,提高推荐系统的准确性。

(3) 监督信号利用。目标行为预测通常是多行为推荐模型进行预测和优化的关键部分,然而目标行为数据在系统收集到的用户多行为数据中通常是

稀疏的,这主要源于目标行为在海量的用户行为数据中出现的次数过于悬殊<sup>[30]</sup>。早期的多行为推荐系统主要依赖于有限的目标行为数据来进行训练和优化,这种稀疏性导致它们在预测用户购买意图时的精度较低、难以收敛。GNN 通过在图上编码半监督信号,可以有效捕捉用户的多种行为模式。此外,GNN 还可以通过设计辅助任务来利用自监督信号,这些辅助任务包括节点的属性预测、边的存在性预测等,通过在图上进行辅助任务的自监督学习,模型能够学习到更丰富的多行为模式和用户的表示,增强整体的推荐效果。

(4)多种信息源整合。GNN 展现出了卓越的多源信息整合能力,在提高精度和个性化方面起到了重要作用。通过合理建模用户的历史行为数据、社交关系信息以及项目内容等多种信息,能够帮助 GNN 有效地捕捉用户和项目的复杂关系。在此基础上,GNN 利用信息传播聚合机制,逐层融合来自不同数据源的信息,从而生成能够全面反映用户偏好的嵌入表示。这种综合表示不仅能刻画用户偏好,同时也考虑了社交信息和商品属性等外在因素的影响,使多行为推荐系统能够在多种信息源的协同作用下实现更全面的预测。此外,GNN 结构的可扩展性也使其在处理大规模多行为图数据时具备更强的建模能力和表达灵活性,为复杂推荐场景中的个性化建模提供了有力支持。

### 3 基于建模的多行为推荐方法

本文通过对基于建模的多行为推荐方法进行综

合分析,构建了一个分类体系。该体系包括三类方法:面向用户偏好学习的方法、面向多行为语义信息捕捉的方法以及知识辅助增强的方法。首先,多行为推荐的优势在于能够将辅助行为信息作为用户偏好学习的重要信号。用户偏好学习包括用户整体偏好学习的方法与捕捉用户动态偏好的方法。此外,行为数据隐含的丰富语义,可以为目标行为预测提供有力的支持。因此,面向行为语义信息捕捉的方法可分为三方面:学习行为间异质性和共性的方法、分析多行为间转换关系的方法、挖掘多行为间依赖性的方法。最后,项目的附加属性对用户行为有影响,综合运用相关的多层次信息有助于提升多行为推荐系统的适用性,因此通过知识辅助增强也是实现多行为推荐的重要手段。

#### 3.1 面向用户偏好学习的多行为推荐方法

面向用户偏好学习包括两个方面:用户整体偏好学习和用户动态偏好捕捉。学习用户整体偏好方法通过对用户不同类型的行为进行综合建模,为用户进行画像,以期得到一种全局、一致的偏好表示。捕捉用户动态偏好方法侧重于追踪和建模用户偏好的演变过程,旨在精准捕捉用户在不同时间节点和情境下的兴趣变化。本节总结和分析了面向用户偏好学习的多行为推荐方法,可采用异构图或多重图建模,并引入知识图谱或建模序列,如表 3 所示。

##### 3.1.1 用户整体偏好学习

Gan 等人<sup>[31]</sup>聚焦用户偏好提出的多行为推荐框架,通过计算用户和项目初始嵌入的内积获得预测的基本分数。另外,框架通过 GCN 捕捉用户在不同行为上的偏好差异,利用 MLP 从中提取深层次

表 3 面向用户偏好学习的方法

策略	模型	发表	年份	结构	GNN 类型
整体偏好学习	FPD <sup>[31]</sup>	ESWA	2023	异构图	GCN
	AMR <sup>[32]</sup>	DASF AA	2022		GAT
	NAH <sup>[33]</sup>	World Wide Web	2023		GAT
	IICL <sup>[34]</sup>	DASF AA	2023		GCN
	V-GMR <sup>[35]</sup>	Applied Intelligence	2023	异构图+KG	GCN
	TSL-MBR <sup>[36]</sup>	软件学报	2024		GCN
	CLMRS <sup>[37]</sup>	ICDM	2024		GCN
	MBKIGN <sup>[38]</sup>	Multimedia Systems	2023		GAT
	MORO <sup>[39]</sup>	APWeb-WAIM	2022		GCN
	MBRec <sup>[40]</sup>	TNNLS	2022		多重图
动态偏好捕捉	RCL <sup>[41]</sup>	RecSys	2023	异构图	GCN
	MB-TGAT <sup>[42]</sup>	PKDD	2023	异构图+交互序列	时序 GAT
	CKML <sup>[43]</sup>	TOIS	2023	异构图+KG	GAT

特征,计算出交互分数。最后两类结果叠加,总和视为用户和项目的整体交互概率。Wei 等人<sup>[32]</sup>提出

的注意力多行为推荐模型,通过计算节点间的交互权重,有效捕捉用户的多行为语境下的局部偏好信

息。该模型在建模过程中显式区分并综合考虑了不同邻居对用户偏好的影响,有效提升了推荐性能。然而,随着用户规模和行为类型的增加,模型承担的计算复杂度将大幅上升,限制了模型在大规模场景下的应用效率。Jiang 等人<sup>[33]</sup>基于 GAT 设计的多行为推荐方法,根据偏好强度为不同的项目嵌入和行为表示赋予个性化的权重,用于学习用户嵌入并进行高阶传播,在大规模场景下同样面临高昂的计算成本。该方法虽然能依赖辅助行为缓解冷启动问题,但是在极端场景下,仍易受节点特征向量随机初始化的影响。Li 等人<sup>[34]</sup>提出的 IICL(Intra-and Inter-behavior Contrastive Learning)框架将多行为推荐任务建模为一个统一的对比学习过程。GNN 的偶数层输出被模型视为结构邻居嵌入,行为语义相似的用户被模型视为语义邻居嵌入。将这两种邻居共同作为正样本,能够在行为内与行为间两个层面强化对用户偏好的一致性建模与表达能力。然而,该模型在结构邻居的选择上未能考虑其不同网络深度下的差异,易导致过平滑现象。此外,模型假设不同行为间存在强关联性,但缺乏辅助行为是否能正向影响目标行为预测的理论依据,易被辅助行为数据中的噪声影响。Yang 等人<sup>[35]</sup>提出一种变分图卷积神经网络 V-GMR(Variational Graph-based Convolutional Neural Network for Multi-behavior Recommendation),结合变分自编码器与 GCN,协同整合辅助行为与目标行为,引导变分推断过程生成语义丰富的用户嵌入。该方法在捕捉用户兴趣的同时,实现了多行为融合建模,获取更全面的用户表示。V-GMR 通过 VAE 的隐变量建模将超参数数量降至单一正则化系数,保持性能的同时降低了调参成本,更适用于大规模工业场景。严明时等人<sup>[36]</sup>提出了一种面向多行为推荐任务的两阶段学习框架 TSL-MBR(Two-Stage Learning for Multi-behavior Recommendation),分别建模用户的全局与局部偏好后再进行融合。一方面,模型基于 GCN 编码多行为数据,学习反映用户长期兴趣的整体偏好。另一方面,利用各类行为数据提取用户在特定行为语境下的局部偏好,构建多粒度的表示空间。两阶段学习方法提高了模型在处理行为异质性和偏好多样性方面的适应能力。但两种偏好的融合流程是固定的,应按实际情况区分不同偏好对预测的影响。例如,当用户交互历史中存在时效性特征时,应赋予局部偏好更高优先级,反之则应将全局偏好作为主导因素。

Yu 等人<sup>[37]</sup>提出基于对比学习的语义知识增强

多行为推荐框架,旨在提升多行为语义信息的表达能力及用户个性化特征的建模能力。一方面,该框架采用行为监督 GCN,提取多行为语义驱动的用户偏好表示。另一方面,引入知识图谱(Knowledge Graph, KG),通过实体关系路径增强项目的语义特征。模型融合两种渠道生成的嵌入向量构造综合的用户偏好表示,实现推荐预测。该框架在建模上实现了多行为依赖与外部语义增强的统一,提升了在推荐场景下的泛化性与鲁棒性。然而,该方法在正负样本对的构造过程中采用随机采样,会忽略关键行为关联或者引入语义不一致的负样本,影响训练的有效性。因此,构建具备行为语义约束的样本筛选机制,是提升框架性能的关键方向。Pan 等人<sup>[38]</sup>通过捕捉用户意图,建模多行为推荐中的用户特征,提出多行为知识图谱意图网络。该框架结合多行为语义和依赖性捕捉行为协同效应,并通过 KG 中的丰富信息学习行为意图表示,建模用户的全面偏好。Xia 等人<sup>[39]</sup>在多行为推荐模型中设计了一种增强注意力的图聚合方法,自动区分在消息传递过程中来自不同图层级的行为感知表示的重要性,捕捉多行为模式的高阶协同信号,刻画用户偏好。Jiang 等人<sup>[40]</sup>设计多行为图对比网络,构建两类表示作为对比视图,改进用户偏好学习:一是通过 GCN 在多个行为图上学习到的用户嵌入经聚合形成的表示;二是在统一的 U-I 交互图上获得的表示。经过对比学习处理后,该框架能够有效强化两类表示之间的一致性。然而,该对比增强模块依赖随机采样,可能会引入无关负样本,削弱对比信号的训练强度。而部分语义接近的正样本在缺乏先验筛选机制的情况下易被错误划为负样本,也会误导优化方向。此外,多行为聚合表示与全局表示之间可能存在语义重叠,若过度强化表示一致性易导致过平滑现象,掩盖不同行为承载的差异性特征,降低对行为语义多样性的刻画能力。

### 3.1.2 捕捉用户动态偏好

Wei 等人<sup>[41]</sup>提出基于关系的对比学习推荐方法,结合多行为图编码器与动态跨关系记忆网络,捕捉用户的长短期偏好。模型将长短期偏好作为对比视图,异质性建模用户动态偏好的。但这种方法会忽略用户在不同时间内的特有倾向,易导致关键兴趣被稀释。Xu 等人<sup>[42]</sup>设计多行为引导的时序图注意力网络,具备挖掘用户短期偏好演化过程的能力。模型根据时序信息构建用户的短期交互序列,并设计自注意力机制建模项目间潜在依赖关系,捕捉用户兴

趣演化模式。Meng 等人<sup>[43]</sup>提出多兴趣学习框架 CKML (Coarse-to-fine Knowledge-enhanced Multi-interest Learning), 以粗细粒度的兴趣融合为核心, 捕捉用户偏好的动态变化。粗粒度兴趣提取采用 GNN 框架初始化不同行为下的兴趣表示。细粒度行为关联模块引入动态路由机制, 划分多类型交互, 并学习其在多兴趣空间下的匹配关系。最终, 通过自注意力对行为间的共享兴趣信息统一建模, 实现多行为联合预测。然而, 由于模型在粗粒度兴趣提取阶段涉及 KG 的使用, 应注意避免 KG 中的误导信息并及时更新, 保证模型捕捉动态偏好的能力。

### 3.1.3 讨论

综上所述, 用户动态偏好捕捉方法能够灵活捕捉用户兴趣的演化轨迹, 在一定程度上缓解静态表征的约束, 面对促销活动、社会热点等可能对用户偏好产生即时扰动的情况具备优势。但现有方法的长短期兴趣划分策略, 可能忽视用户行为周期性的细粒度差异, 在电商平台由于季节周期出现用户需求波动等现象时易出现语义断层, 导致长期或短期兴趣在参与最终预测时的融合不足。可发展多尺度时序解耦架构, 通过自适应时序分割策略构建基于更精细时间片(日/周/月级)的用户行为架构, 并根据周期波动设计门控网络, 为不同的时间周期动态分配权重。同时, 在融合兴趣过程中需注意表示空间

的分配, 避免某种兴趣主导预测, 造成不公平问题。另外, 长期兴趣依赖跨时间的行为累积, 但低活跃用户的长期行为数据稀疏, 模型可能过度依赖少数高频行为, 导致长尾用户兴趣出现建模偏差。

### 3.2 面向多行为语义信息捕捉的多行为推荐方法

学习行为间的异质性和共性特征通过区分不同行为的贡献和理解行为间的共性, 挖掘跨行为模式的潜在协同信号。在此基础上, 一些级联多行为推荐模型挖掘行为的依赖性, 尝试识别用户在特定行为模式下偏好的潜在变化和行为转换规律, 推测用户兴趣并预测行为走向。然而级联方式无法反映用户实际的复杂行为模式, 因此近年来的研究开始更加注重挖掘行为之间的真实依赖关系, 从行为模式推断角度出发, 实现个性化推荐。

从区分行为间的异质性和共性, 到深入分析行为之间的转换关系, 再到挖掘行为间的依赖性, 这一系列研究策略的递进展示了多行为推荐系统从基础到深度的逐步发展。通过这些方法, 推荐系统能够更加全面地理解用户的行为模式, 捕捉潜在的语义关系, 提升推荐效果。本节总结和分析了面向多行为语义捕捉的多行为推荐方法, 异构图、多重图和超图均可满足这类方法的建模需求, 也可进一步引入元路径或设计特殊拓扑结构, 以最大化挖掘行为特征, 如表 4 所示。

表 4 面向行为语义信息捕捉的方法

策略	模型	发表	年份	结构	GNN 类型
多行为间差异与 共性学习	S-MBRec <sup>[44]</sup>	IJCAI	2022	异构图	GCN
	CML <sup>[45]</sup>	ICDM	2022		GCN
	MMCLR <sup>[46]</sup>	DASFAA	2022	异构图+交互序列	GNN
	HMG-CR <sup>[47]</sup>	ICDM	2021		超元图
多行为转换 关系挖掘	MB-CGCN <sup>[48]</sup>	WWW	2023	异构图	GCN
	CGCCN <sup>[49]</sup>	DASFAA	2024		GCN
	CRGCN <sup>[50]</sup>	TOIS	2023		GCN
	Disen-CGCN <sup>[51]</sup>	TORS	2024		GCN
	COPT <sup>[52]</sup>	SIGKDD	2025		GCN
多行为间 依赖性捕捉	HPMR <sup>[53]</sup>	SIGKDD	2023	多重图	GCN
	MB-GMN <sup>[54]</sup>	SIGIR	2021		GAT
	DA-GCN <sup>[55]</sup>	TOIS	2024	有向无环图	DA-GCN <sup>[55]</sup>
	DCMGNN <sup>[56]</sup>	TKDE	2025		DCMGNN <sup>[56]</sup>
	VCGAE <sup>[57]</sup>	ICDM	2023	多重图	GCN
MB-DCAC <sup>[58]</sup>	电子学报	2023	GCN		

#### 3.2.1 学习行为间异质性和共性的方法

Gu 等人<sup>[44]</sup>从监督学习与自监督学习两个视角出发, 兼顾多行为之间的异质性与共性, 提出了融合 GCN 的自监督多行为协同过滤框架。其中, 监督学习任务旨在刻画行为间差异, 使用自适应权重聚合多行为嵌入。自监督学习任务在目标行为与各辅助

行为间进行对比学习, 突出行为共享特征的同时降低计算成本。然而, 在高度稀疏的交互数据下, 基于图结构计算的节点相似度缺乏足够的可靠性, 因此模型的选择性对比学习缓解数据稀疏的效果有限, 易使被误标为正样本的实例在表示空间中靠近, 加剧负迁移效应, 降低模型对表征的判别能力。Wei

等人<sup>[45]</sup>在自监督学习下探索多样化的行为模式,提出了一种对比元学习方法 CML(Contrastive Meta Learning)用于多行为推荐。CML 的目标是通过构建对比损失,促使用户特定行为的表示达成一致。为了捕捉个性化的多行为模式,CML 设计了对比元网络捕捉多行为异质性。但由于采用传统的对比学习范式,CML 在面对丰富语义和大规模数据时,可能将部分正样本混淆为负样本,导致推荐效果下降。Wu 等人<sup>[46]</sup>提出的推荐框架从粗粒度与细粒度两个视角,挖掘行为间的共性与差异。模型通过多行为序列视角与图结构视角之间的对比学习,从粗粒度层次捕捉多行为共性特征,同时保留用户个性化信息。在此基础上,在不同行为间构建细粒度对比任务,挖掘多行为间语义差异,提升预测精度。该方法与 CKML 在粗细粒度划分的目标上存在本质差异:CKML 着重挖掘用户兴趣结构,而本文方法侧重对多行为信息及依赖关系进行有效融合与建模。然而,该框架未对两个对比学习任务的协同机制进行系统性验证,缺乏对梯度方向一致性的分析,在目标函数存在潜在冲突时可能导致训练过程不稳定,削弱整体性能。Yang 等人<sup>[47]</sup>基于超元路径构造超元图,设计多行为对比推荐框架,反映用户和项目之间交互的不同行为模式。模型以目标行为为起点,逐步引入辅助行为,生成多个关于不同行为的超元图,按照行为顺序在超元图间进行对比学习,能够获得每类行为的渐进性和综合性表示。但超元图的构造过程对人工的依赖较大,而用户行为模式存在多样性和动态性的特点,难以被基于固定规则的超元路径覆盖,在泛化性方面存在不足。且相邻的超元图差距较小时,会导致对比学习区分特征的有效性降低。

### 3.2.2 分析多行为间转换关系的方法

用户和项目交互的过程可以视为行为链,例如用户在浏览某种商品后将其加入购物车并购买,那么“浏览-加购-购买”即为一条行为链。行为链中,靠后的行为通常反映更强的偏好。一些方法预设行为链,通过“级联”的方式反映行为间的一定转换关系,构建多行为推荐模型。

Cheng 等人<sup>[48]</sup>根据预设的行为顺序,将多个 GCN 模块串联,通过将前一行为学习到的嵌入作为后一行为嵌入学习的输入,显式建模行为间的转换关系,提升多行为融合有效性。Liu 等人<sup>[49]</sup>进一步提出 GCN 级联结构,利用行为链的依赖关系输出各类行为的嵌入特征。该模型采用多任务学习,使

每个 GCN 单元的输出均服务于对应行为的预测,强化辅助行为的监督信号,并逐步逼近用户的真实偏好。同时,各 GCN 块的输出嵌入会作为下一模块的部分输入,实现对行为依赖路径中流动信息的传递与学习。

Yan 等人<sup>[50]</sup>引入残差连接机制,提出数据驱动的级联残差图卷积神经网络。该方法在多层级联结构中保留早期行为的特征信息,缓解深层结构中信息衰减的问题,增强模型建模行为演化路径的能力,提升用户真实偏好的预测精度。

行为间传输信息时,级联多行为推荐模型通常使用共享的特征变换函数。而用户在不同行为下的偏好模式可能存在显著差异,使用共享的特征变换可能无法捕捉差异化偏好。因此,Cheng 等人<sup>[51]</sup>提出集成元网络的多行为级联模型 Disen-CGCN(Disentangled Cascaded Graph Convolutional Network)。该模型提取用户和物品在各种行为中的个性化信息生成转换矩阵,将一个行为中的嵌入信息转换为下一个行为的初始嵌入,实现跨行为的个性化特征迁移。

组合优化视角下,多行为推荐的核心挑战在于平衡解空间约束强度与行为模式多样性。Zhai 等人<sup>[52]</sup>提出一种基于组合优化视角的多行为推荐框架,通过将交互序列解构为前置行为、过程行为与后续行为三阶段约束机制,显著缩减解空间规模。该方法突破了传统级联范式的固定路径限制,避免穷举的同时保留了用户行为多样性,实现计算效率与模型表达力的协同优化。但模型依赖严格的行为阶段划分,预设的链式结构难以适配独立于主行为路径的辅助行为(如随机收藏)。强制将其纳入约束框架可能导致表示失真。另外,阶段性约束也难以灵活捕捉用户行为的跳跃性(如浏览后直接购买)或循环性(如多次浏览后购买)等模式。上述局限源于组合优化约束与真实行为复杂性的根本矛盾,需在后续研究中探索动态约束机制提升模型普适性。

### 3.2.3 挖掘多行为间依赖性的方法

Meng 等人<sup>[53]</sup>设计增强多行为推荐的分层投影框架,针对负迁移和不够完善的预测任务,通过基于投影的迁移网络精炼上游和下游行为之间的相关性,提升推荐效果。但是,某些行为可能隐含着对下游行为的间接影响(如频繁浏览但未加购的用户可能具有更高的购买潜力),因此强制某种行为与下游行为的表示正交,会过度约束表示空间,导致部分有用信息被丢弃。

Xia 等人<sup>[54]</sup>提出的多行为推荐框架以元学习范式为核心,通过统一的优化视角实现信息跨行为迁移。该方法自适应调节行为权重,并从高阶图连接中挖掘多行为协同机制,使模型能在多任务环境下自适应学习多行为关系。基于此,模型统一调控行为建模与预测输出,实现在表征学习与监督优化两个阶段对行为依赖的协同挖掘。Zhu 等人<sup>[55]</sup>针对多行为级联假设与用户多样化行为路径之间的不匹配,设计了有向无环图卷积神经网络。该方法将行为依赖体现为无环的有向图结构,既能精准建模行为间的单向转换关系,又有效避免了闭环导致的信息冗余。框架内的注意力聚合模块通过遍历所有潜在前驱行为节点,动态提取与目标行为相关的多种路径信息,以支持模型在多行为转换方式下的灵活推断和推荐。Li 等人<sup>[56]</sup>基于多重图框架建模行为模式,提出一种双通道 GNN 模型用于多行为推荐任务。通过引入隐式关系链效应学习和关系链感知对比学习,改进对不同行为与目标行为间相关性的捕捉,统一不同行为的表示,并探索潜在的行为序列,更加合理地利用辅助行为信息增强目标行为预测。Liu 等人<sup>[57]</sup>提出变分集体图自编码器 VCGAE (Variational Collective Graph AutoEncoder),核心思路在于通过联合多行为信息完成节点潜在变量的推断,并借助行为转换网络生成目标行为的转换嵌入,构建融合多路径依赖的节点特征向量。通过线性叠加不同行为向目标行为的转换嵌入,能够刻画行为间依赖关系。然而,由于实际的行为转移往往呈现复杂的非线性和多路径交互模式,单纯的线性组合策略难以充分捕捉动态依赖,在处理高度个性化的行为序列时可能导致模型能力受限。

针对用户多行为的引入可能会导致表示空间的异质性增加的问题,范伟等人<sup>[58]</sup>提出基于异构图的双通道交叉自适应对比学习推荐模型。通过多行为聚合与图卷积操作的交叉执行,调整表征空间结构,

设计更精确的聚合与消息传递范式,增强表征空间分布的均匀性。模型假设两个通道能够独立地捕获不同的行为模式,但在实际应用场景中,这种独立性假设可能导致捕获到的信息冗余。同时,主通道侧重于挖掘行为依赖和协同作用,而辅助通道则在单行为下捕获协同关系。两者的信息融合如果仅通过简单的拼接或加权平均,难以表达它们之间的复杂交互和互补关系,导致部分信息的丢失或者特征的可解释性降低。

### 3.2.4 讨论

综上所述,学习行为间异质性和共性的方法能够实现灵活、准确的多行为协同作用,加强预测结果的合理化。但此类方法对行为语义的高度依赖可能导致较高的标注成本,且在冷启动场景下易引发建模偏差。行为转换关系分析方法通过显式构建行为链,反映用户决策路径的内在逻辑,在线上教育平台等行为转化流程明确的场景中可有效判断用户意图,进行准确推荐。但缺点是较为固化,泛化性差,面对社交平台等多行为可能并发的场景时,表达能力容易受限。挖掘多行为间依赖性方法的优势在于学习并捕捉复杂交互模式及潜在信息,通过分析用户行为习惯进行推荐。但同时也面临计算复杂度与实时性需求的矛盾,易导致模型性能陷入局部最优,或出现推荐延迟现象,难以适应广告投放等实时性要求较高的场景。

### 3.3 知识辅助增强的多行为推荐

多行为推荐系统中额外的知识,如:商品价格、颜色等,可能在引导用户决策过程中发挥关键作用。在图结构中,这些知识可以被显式表示,并通过 GNN 进行学习和传播。这类方法通过属性分离或引入知识图谱等手段,有效增强推荐系统的表现,提升其个性化和精准度。本节总结和分析了知识辅助增强的多行为推荐方法,异构图和 KG 能有效满足这类方法的建模需求,如表 5 所示。

表 5 知识辅助增强的方法

策略	模型	发表	年份	结构	GNN 类型
知识辅助增强	Disen-CGCN <sup>[51]</sup>	TORS	2024	异构图	GCN
	KMCLR <sup>[59]</sup>	ICDM	2023		GCN
	KAMCL <sup>[60]</sup>	DASFAA	2024	异构图+KG	GAT
	KMBFD <sup>[61]</sup>	ICIS	2022		GCN
	KDMBR <sup>[62]</sup>	CIKM	2024		GCN
	KIPI <sup>[63]</sup>	INS	2025		GCN

#### 3.3.1 知识辅助增强的多行为推荐方法

Disen-CGCN<sup>[51]</sup>使用分离表示技术进行细粒度

偏好建模,通过分离项目属性并融合元网络进行特征转换,模拟用户细粒度的多行为偏好转移。然而

在现实场景中,这些属性往往存在隐含关联,属性分离操作会破坏语义完整性,造成信息冗余或丢失。同时,分离出的属性缺乏显式的语义对齐,模型难以验证每种属性是否能够对应用户偏好,可能降低模型的可解释性。

Xuan 等人<sup>[59]</sup>提出知识增强的多行为对比推荐框架,通过三重模块实现异构信息融合。首先,多行为学习模块利用辅助行为监督信号增强用户表征,并建模多行为共性。其次,知识增强模块借助 KG 的语义关系,通过双视图编码方式增强项目嵌入。最后,设计对比学习任务,对齐用户和项目表征用于推荐。模型通过对比学习进一步缓解了数据稀疏问题,但正负样本构造依赖随机采样,可能忽略行为间固有语义关联或引入无关负样本,会限制模型对用户细粒度偏好的判别能力。

Liang 等人<sup>[60]</sup>通过 KG 显式建模用户意图进行推荐。该方法根据项目不同属性,将 KG 解耦为多个子图。GNN 在子图上进行消息传递后,通过注意力机制进行融合嵌入,即可获取用户意图表示。在此基础上,多行为交互模块整合用户在不同行为下的偏好表征,进一步学习用户在不同项目上的意图-行为模式,增强目标行为的推荐效果。但该方法分割 KG 会造成跨属性语义关联的割裂(如用户对品牌和材质的综合考量),导致意图生成模块难以捕捉跨属性的综合特征,生成次优的意图表示。

Liu 等人<sup>[61]</sup>设计的多行为推荐框架从知识层面提取项目信息,构建了包含辅助信息和多行为协同信息的异构交互图,用于同时编码基于知识的特征和基于协同过滤的特征,增强用户和项目之间的显式关联。而 Li 等人<sup>[62]</sup>基于知识增强设计的多行为动态建模推荐框架,采用门控机制区分多行为权重,并引入 KG 建模项目属性,通过图重构和知识感知对比学习任务来丰富项目和用户的语义信息,经过 GCN 学习后得到多层次嵌入,有效提升推荐效果。

Park 等人<sup>[63]</sup>设计的基于行为模式识别的知识约束兴趣感知框架,引入本体视图知识图谱以提升语义建模效果。该框架不仅关注实体信息,还通过本体视图 KG 捕捉与实体相关的广义概念(如商品所属类别)及其层次化从属关系,例如“吹风机-个人护理电器-家用电器”之间的嵌套结构。通过挖掘丰富语义关联,模型能够更细致地刻画用户在不同层次概念下的行为依赖关系,从而增强成对行为依赖建模之间的细粒度相关性,提升推荐的可靠程度。

### 3.3.2 讨 论

知识辅助增强方法将外部知识语义嵌入消息传播,利用 KG 与 U-I 图之间的协同建模,能有效缓解数据稀疏问题。该方法可以通过结构融合将 KG 中的实体与关系引入 U-I 图,构建统一的结构以实现消息传播与聚合。或者通过 GNN 和 TransR、TATEC 等方式,对 U-I 图和 KG 分别编码,并在表示层以注意力机制或对比学习等方式实现特征注入与语义交叉,实现表征融合的效果。在此过程中,KG 的语义信息起到关键作用,不仅能增强项目表示,提升模型对用户属性偏好差异与行为间依赖的理解能力,还通过高阶语义关联揭示用户潜在兴趣的演化逻辑,从而提升偏好建模的鲁棒性与可解释性。然而,不同类型的知识对多行为推荐的贡献也不同:属性知识直接关联项目细粒度特征,有助于精准刻画用户画像;而类别知识则揭示实体间更复杂的语义结构,有助于建模更宏观层面的行为依赖。尽管知识辅助增强潜力很大,却高度依赖外部知识库的覆盖率与准确性,KG 中实体的不完整性(如小众品牌覆盖不全)或错误标注(如将促销标签视为核心特征)均会引入噪声,影响模型性能。此外,KG 的语义信息与 U-I 图中的交互信号在粒度与结构特性上存在差异,融合过程中面临选择性建模与信息校准的挑战。在实际场景中,外部知识动态变化,而静态 KG 难以同步更新,动态性和时效性的不足也会限制推荐效果。未来研究需进一步提升知识辅助增强的全面性、准确性和动态性,以便更有效地利用外部知识,实现更高质量的推荐。

## 4 面向不同场景的多行为推荐方法

### 4.1 多行为社交推荐

社交推荐通过社交邻居或好友关系捕获目标用户的偏好并作为推荐依据<sup>[64]</sup>,如图 3 所示。为了简化模型设计,大多数社交推荐技术出于对平台利益的考虑,仅将目标行为纳入分析。然而用户的多种行为和社交范围会互相影响,忽略多行为下的异质性社会影响扩散会导致推荐结果的损失。因此多行为社交推荐应运而生,通过利用多行为之间的差异化传播信息,刻画全面的社交扩散过程,提高推荐性能。多行为社交推荐方法在建模过程中一般考虑三类关联:用户社交关联(U-U 关联),用户-项目关联(U-I 关联)和项目间关联(I-I 关联),如表 6 所示。本节总结和分析的方法均采用异构图进行建模,将

上述三种关联分别构建为独立的图或者整合为统一的图用于后续学习。

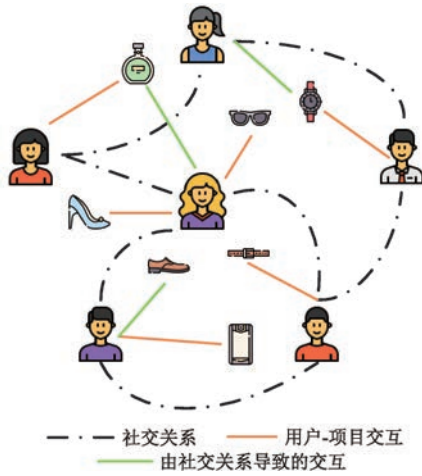


图 3 多行为社交推荐示意图

#### 4.1.1 多行为社交推荐方法

Guo 等人<sup>[65]</sup>提出多关系图融合的信任感知多行为推荐方法,通过特征传播和级联特征向量融合用户信任关系图、多行为异构交互图和项目知识图,充分利用 GCN 捕获用户的信任关系。但是将三种异构图的特征向量映射到同一语义空间时,由于不同结构的语义差异,会导致效果不佳。因此,设计适应性更强的异构图融合方法是模型的优化方向。

Xu 等人<sup>[66]</sup>提出基于分层 GNN 的多行为社交推荐框架,通过关系感知的 GNN 模块对多类型 U-I 关系建模,捕捉多行为协同信号。再重建 U-I 的全局连接关系,实现多行为信息与社交感知的融合建模。然而,模型通过最大化用户之间的互信息建模全局社交依赖,会弱化局部社交关系对用户决策的作用。相比全局社交关系,用户行为可能更易受

表 6 多行为社交推荐方法

策略	模型	发表	年份	结构	GNN 类型
多行为社交推荐	T-MRGF <sup>[65]</sup>	Information Fusion	2021	U-U 图、U-I 图、I-I 知识图	GCN
	KCGN <sup>[66]</sup>	AAAI	2021	U-U 图、U-I 图、I-I 图	GCN
	SR-HGNN <sup>[67]</sup>	ICDM	2020	U-U 图+U-I 图	GCN
	SHGCN <sup>[68]</sup>	TWEB	2023		GCN
	MB-Soc <sup>[69]</sup>	PRCV	2023	U-U 图、U-I 图	GAT

自身社交圈影响。聚合全局社交信号可能无法有效区分强弱社交关系,导致对社交影响的表示不够精确,影响推荐效果。

Huang 等人<sup>[67]</sup>耦合 GNN 和互信息估计框架来联合建模 U-U、I-I 和 U-I 关系,并提出知识耦合的 GNN 用于多行为社交推荐任务。考虑到 U-I 多行为交互模式存在动态特征,该方法采用结合时序编码的消息传递机制。框架将时间信息融入多行为 U-I 图的学习过程中,增强三种关系的协同作用,满足了多行为社交推荐模型的准确性要求。

相比前述依赖多行为数据提升社交推荐性能的方法,Zhang 等人<sup>[68]</sup>提出的社交增强异构图卷积神经网络模型从社交关系角度出发,旨在增强多行为推荐效果。该模型采用 GCN,联合捕捉用户在 U-I 与 U-U 图中的高阶依赖关系,通过聚合池化方式整合社交与行为信号,从整体上提升推荐能力。模型引入动态自适应损失方法,根据各类行为在训练过程中的损失表现,动态调整其在整体优化目标中的权重,使模型聚焦对推荐效果贡献更显著的行为。该方法在综合社交关系与多行为模式信息的基础上,实现了对用户偏好建模过程的精细调控,增强了多源信号融合的适应性和鲁棒性。

一般的社交推荐系统并不进行基于多行为的偏好分析,也并未区分不同交互下的信任传播过程。因此,多行为社交推荐面临的挑战在于如何平衡信任信息和行为偏好的传播。Wu 等人<sup>[69]</sup>提出的多行为社交推荐方法在学习节点嵌入和过程中,通过 GAT 计算信任权重,并将其融入解耦的行为子图中的用户嵌入更新中。这种方法实现了行为偏好和信任信息在社交网络的均衡传播,更准确地根据社交关系和多行为信息预测用户对项目的潜在兴趣。

#### 4.1.2 讨论

综上所述,多行为社交推荐方法优势在于将用户社交关系与多行为交互信息的融合,可使社交影响力与个体行为偏好在预测过程中被协同利用。在冷启动场景下,系统可通过新用户社交连接,将好友偏好特征作为推荐依据考虑,这在社区型内容平台中展现出显著的应用价值。然而,用户可能在社交圈驱动下与某些项目产生新的交互,自身交互特性也可能为用户催生新的社交关系。但现有方法往往只关注两类信息在预测层面的协同作用,而忽略了在现实层面的潜在影响,面临社交-多行为关联的深度不足问题。另外,现有研究对用户社交影响敏感度的异质性缺乏量化标准,在热点话题推荐等信息

传播敏感型场景中,难以动态识别社交影响力和行为影响力对个体偏好的主导差异,造成推荐结果的同质化。可见,多行为信息与社交信息的深度关联还需被进一步挖掘,并应采取自适应的方法灵活平衡二者对预测结果的影响。

## 4.2 多行为序列推荐

序列推荐主要关注用户行为的时间顺序和连续性,通过利用历史行为序列来学习时间步骤感知的序列模式,能够捕捉用户兴趣的演变,提供更加精准和具有时效性的推荐。为了利用用户反馈的异质性和序列性,多行为序列推荐通常同时建模用户的多种行为及其序列信息,推荐更符合用户当下偏好的

项目,如图 4 所示。本节总结和分析了多行为序列推荐方法,采用异构图或超图建模高阶关系,体现用户交互的序列形式,如表 7 所示。




图 4 多行为序列推荐示意图

表 7 多行为序列推荐方法

策略	模型	发表	年份	结构	GNN 类型
多行为序列推荐	TGT <sup>[70]</sup>	TKDE	2022	异构图	时序 GNN
	BLSI <sup>[71]</sup>	INS	2024		HetGNN
	SRMA <sup>[72]</sup>	Neurocomputing	2023		GCN/GAT
	GraphMLP-Mixer <sup>[73]</sup>	计算机研究与发展	2024	超图	GNN+MLP
	BAMBOO <sup>[74]</sup>	TKDE	2024		HetGNN
	HEML <sup>[75]</sup>	ESWA	2024		HGNN
	MISSL <sup>[76]</sup>	ICDE	2024		HGNN

### 4.2.1 多行为序列推荐方法

Xia 等人<sup>[70]</sup>设计融合 Transformer 与时序 GNN 的多行为序列推荐模型,探索不同行为之间的演化,挖掘用户的动态长短期交互模式,实现跨行为与跨时间尺度的统一建模。Jiang 等人<sup>[71]</sup>提出行为增强的长短期兴趣模型,融合自注意力机制与 Het-GNN,从多行为的局部依赖与全局结构联合建模用户兴趣。模型通过门控机制整合多尺度特征,实现了多行为序列中的动态偏好表达。Gao 等人<sup>[72]</sup>联合建模 U-I 交互图与用户-项目-属性图,联合动态行为与属性语义增强序列推荐效果。模型设计能够处理时序与属性信息的 GAT,挖掘交互权重随时间变化的规律以及不同属性对用户偏好的影响。然而,该方法在属性注意力设计上仍有局限,若未充分考虑属性间的潜在关联结构,可能导致特征表达不完整,影响用户兴趣捕捉的全面性。卢晓凯等人<sup>[73]</sup>结合 MLP-Mixer 架构和 GNN,提出 GraphMLP-Mixer 模型用于多行为序列推荐。模型的兴趣挖掘模块通过交替的通道和令牌混合,实现了兴趣内部和兴趣间的信息融合。然而,这种方式会导致信息在不同层级之间的传播出现难度。首先,通道混合聚焦某种特定兴趣,通过特征维度上的混合操作捕捉用户行为和偏好的关联。但该阶段缺乏对不同兴趣的显式建模,导致信息从通道混合阶段传递到令

牌混合阶段时,无法准确反映兴趣之间的全局联系。当复杂用户行为序列中涉及大量兴趣时,某些与全局推荐目标紧密相关的关键项目关系会被弱化,影响模型最终生成的用户偏好表示的全面性和准确性。同时,令牌混合阶段依赖于通道混合阶段的输出,若通道混合未能充分提取兴趣的关键特征,令牌混合的信息交换会受到干扰,影响模型对用户整体兴趣的建模。

Zheng 等人<sup>[74]</sup>针对在线招聘平台中双向需求,提出一种同时面向求职者与招聘者的推荐方法。该方法将历史行为以统一多行为序列结构进行组织,借助 Transformer 和 GNN 提取求职者序列和招聘者特征,实现对双主体行为的协同学习,能够有效建模适配招聘场景的多行为,达到互惠的推荐目的。但缺点是依赖精准的构图过程,若对主动发起行为与被动响应行为的区分不明确,易引入结构噪声,影响模型对交互方向和行为语义的辨识能力。

Li 等人<sup>[75]</sup>提出超图增强的多行为推荐框架,旨在捕捉用户多兴趣演化轨迹与多行为间的高阶依赖关系。该框架通过超图和时间序列建模用户动态行为,并设计跨视图协同学习机制,融合兴趣提取与行为依赖建模两个任务的信息,实现多视角下的联合优化。Wu 等人<sup>[76]</sup>提出多兴趣自监督学习方法,聚合表示空间中语义一致的兴趣,并模拟兴趣演变过

程与行为模式变化,增强模型对行为稀疏性的鲁棒性能并加速收敛。上述两种序列推荐方法结合多兴趣学习,不仅提升了用户表示的质量,也在一定程度上缓解了行为间信号不均导致的建模偏差问题。

#### 4.2.2 讨论

综上分析,多行为序列推荐方法可显著缓解单行为序列推荐对用户长期兴趣的认知偏差问题,精准捕捉用户从浅层交互到深度转化的决策轨迹,有效解析用户行为序列中隐含的内容偏好强化过程。通过序列中的购买行为可分析用户的付费意愿拐点,从而在视频推荐等需平衡用户黏性与商业价值的场景中实现动态策略优化。然而,序列长度的增加会使所需的时间和空间发生平方级的增长。这为计算成本和内存成本带来了严峻挑战,使模型在社交平台、在线阅读平台等场景中难以捕获更长期的行为依赖,或满足新闻资讯更新等实时推荐场景的

低延迟需求。因此,如何克服多行为序列推荐的训练缓慢和内存瓶颈问题,是当前研究的热点。

#### 4.3 多行为会话推荐

多行为会话推荐是一种专注于用户当前会话的推荐方法,主要特点在于实时性和上下文敏感性,侧重于利用用户短期内的行为数据分析即时兴趣和需求,如图 5 所示。本节总结和分析了多行为会话推荐方法,一般采用异构图或多重图结构建模多关系项目图(Multi-Relational Item Graph, MRIG),刻画项目之间的依赖关系,预测用户可能感兴趣的下一个项目,如表 8 所示。



图 5 多行为会话推荐示意图

表 8 多行为会话推荐方法

策略	模型	发表	年份	结构	GNN 类型
多行为会话推荐	EMBSR <sup>[77]</sup>	ICDE	2022	多重图	门控 GNN
	GNNH <sup>[78]</sup>	GeoInformatica	2022		GCN
	AMAN <sup>[79]</sup>	KBS	2022	异构图	GAT
	MMFSR <sup>[80]</sup>	World Wide Web	2023		R-GCN
	MUIR <sup>[81]</sup>	ESWA	2025		GAT

#### 4.3.1 多行为会话推荐方法

Yuan 等人<sup>[77]</sup>结合行为序列与 U-I,通过门控 GNN 与注意力网络联合建模序列结构与成对行为语义,增强推荐准确性。然而,模型未显式区分多行为的重要性,导致行为信号在意图表达中的权重难以调控,影响用户偏好捕捉的精度。此外,该方法局限于对单一会话内行为的建模,未能考虑跨会话的长期偏好演化和复杂行为模式,限制了其在复杂场景下的泛化能力。

Yu 等人<sup>[78]</sup>提出的基于神经网络的多行为序列推荐模型,将均值池化和注意力机制结合,充分捕捉辅助行为模式。该模型能为多行为交互序列提供项目特征,在 MRIG 和多关系特征图 MRFG (Multi-Relational Feature Graph) 上进行表示学习,充分保留多行为会话中项目之间以及特征之间的关系,更大程度保留有价值的信息。然而,MRFG 假设特征间的转换关系在全局会话中具有一致性,但实际上不同的会话可能具有不同的上下文,模型在捕捉特定会话的动态特征依赖上可能泛化性较低。

Qiao 等人<sup>[79]</sup>提出自适应多注意力网络模型,额外考虑多会话对同一项目的影响及会话间依赖性,

从用户初始兴趣出发捕捉兴趣变化。模型引入微观行为协同注意力,突出会话首尾的项目在兴趣形成中的作用,增强行为序列的表达能力。然而,其对初始兴趣的建模依赖理想化假设,易受噪声干扰,需引入去噪机制以提升初始兴趣建模的鲁棒性。

Yu 等人<sup>[80]</sup>提出记忆增强的元学习框架,通过软聚类引导会话划分至意图相似的簇,实现共享初始化并提升泛化效果。该方法在捕捉意图共性与个体差异之间取得良好平衡,增强了冷启动场景下的建模能力。然而,对簇中心权重初始化方法的不统一会导致软聚类算法的不稳定性增强,进而影响模型在不同数据集上的一致性与鲁棒性。可通过探索簇中心初始化的正则机制与结构感知的聚类过程建模,增强模型的稳定性与可解释性。

Zhang 等人<sup>[81]</sup>从多行为建模潜在的信息混杂问题出发,提出融合全局与局部特征的多行为用户意图建模方法,以缓解对用户意图识别的不完全性。该模型引入用户行为辨识任务,划分不同行为对应的意图,缓解多行为间的语义纠缠。然而,该任务未考虑行为间依赖关系,限制了捕捉行为语义演变过程的能力。若将行为顺序编码到任务中,结合行为

演变的动态性判别用户意图,能够进一步提升模型的推荐效果。

#### 4.3.2 讨 论

综上所述,深入挖掘和利用多行为数据,能够有效缓解会话推荐面临的数据规模较小的问题,捕捉用户短时决策过程中的多维兴趣信号,从而在促销活动推荐等需实时响应的场景中促进购买行为转化。然而,引入多行为数据可能放大噪声,导致无关信息干扰推荐效果。此外,会话数据的强隐私属性限制了对多行为关联的深度挖掘,如医疗推荐中症状查询与药品搜索行为的敏感关联,导致模型在隐私合规约束下难以结合多源信息进行推荐。在这种情况下,如果受到噪声干扰,会导致预测误差增大,影响用户体验。因此,多行为会话推荐模型的设计,需要充分考虑如何去噪,并防止受到数据稀疏的影响。不仅要适当筛选用户多行为数据,还要构建鲁棒的学习机制,确保推荐结果的准确。

## 5 多行为推荐模型的优化

多行为推荐模型的优化是研究的一个重要方

向,如何充分合理利用多样化行为数据的潜力,并弥补可能出现的不足,成为了研究者关注的核心问题。目前主要包括优化监督信号分布<sup>[33,44]</sup>和辅助行为信息去噪<sup>[82-83]</sup>的方法,分别关系到多行为推荐模型在数据质量和噪声干扰方面的关键挑战,可以从数据、结构和处理方式三个角度实现。

### 5.1 监督信号分布的优化

多行为推荐系统在现实场景中往往面临监督信号稀疏或者分布不均,缺乏足够的训练数据支持模型训练,影响推荐精度<sup>[30,84]</sup>。因此,一些方法通过自监督学习或知识增强等手段,优化监督信号分布,弥补多行为推荐的训练数据,实现性能提升。本节总结和分析的优化监督信号分布的多行为推荐方法,主要从数据和建模结构两个角度实现,如表 9 所示。为进行定量的方法评估和比较并保证公平性,本节通过调查原文数据或实验等方式,收集了部分方法在贝贝上的性能数据,如表 10 和表 11 所示。

#### 5.1.1 自监督学习方法

(1)对比学习方法。对比学习作为一种突出的自监督学习方法,充分利用数据本身的信息作为监督信号,在多行为推荐中得到了广泛应用<sup>[85]</sup>,通过

表 9 优化监督信号分布的多行为推荐方法

问题	模型	发表	年份	优化角度	GNN 类型
监督信号分布	V-GMR <sup>[35]</sup>	Applied Intelligence	2024	数据优化	GCN/GAT
	VCGAE <sup>[57]</sup>	ICDM	2023		GCN
	MBSSL <sup>[86]</sup>	SIGIR	2023		GCN
	MBGCL <sup>[87]</sup>	KAIS	2024		GCN
	MBCLRec <sup>[88]</sup>	KBS	2024		GCN
	SA-MBGCL <sup>[89]</sup>	电子学报	2024		GCN/GAT
	CIGF <sup>[90]</sup>	WWW	2023	GCN	
	HEM-GNN <sup>[91]</sup>	IP&M	2024	建模结构优化	HGNN
	POGCN <sup>[92]</sup>	SIGKDD	2024		GCN

表 10 监督信号优化方法性能比较

方法	HR@10	NDCG@10
V-GMR <sup>[35]</sup>	0.0746	0.0399
MBSSL <sup>[86]</sup>	0.1533	0.0790
MBGCL <sup>[87]</sup>	0.0857	—
MBCLRec <sup>[88]</sup>	0.6810	0.4050
SA-MBGCL <sup>[89]</sup>	0.2021	0.1071
CIGF <sup>[90]</sup>	0.7000	0.4430
HEM-GNN <sup>[91]</sup>	0.2310	0.0930

表 11 POGCN 性能数据

行为	HR@20	NDCG@20
点击	0.935	0.0841
加购	0.1542	0.0948
购买	0.2029	0.1083
平均值	0.1502	0.0907

生成正负样本对,最大化正样本对之间的相似性,同时最小化负样本对之间的相似性<sup>[93]</sup>。在进行对比学习过程中,所生成的视图强调了数据不同方面的差异,能够增强模型鲁棒性,或改善推荐系统对全局协同信息的处理<sup>[94]</sup>。在推荐场景下,对比学习损失函数如公式(4)所示:

$$\mathcal{L}_{con} = \sum_{u \in U} -\log \frac{\exp(\phi(e_u^1, e_u^2)/\tau)}{\sum_{v \in U} \exp(\phi(e_u^1, e_v^2)/\tau)} \quad (4)$$

推荐系统可以通过数据增强或结构增强等方式创建对比视图,并在此基础上选择正负样本对。 $e_u^1$  和  $e_u^2$  为正样本对,  $e_u^1$  和  $e_v^2$  为负样本对,  $\phi(\cdot)$  表示向量内积操作,  $\tau$  为温度参数。损失函数  $\mathcal{L}_{con}$  通过最大化正样本对之间的相似性,同时最小化负样本间的

相似性,能够使模型学习到增强且鲁棒的表示,改善推荐中监督信号不足的问题。

Xu 等人<sup>[86]</sup>提出的多行为自监督推荐框架,在行为间和行为内引入对比学习,实现从辅助行为到目标行为的信息迁移。该框架强化目标行为监督信号,有效缓解了数据稀疏带来的性能瓶颈。实验结果显示,在推荐列表较短且交互密度稀疏的条件下,模型表现仍优于多种采用对比学习的方法。说明其提升表征质量并有效抑制了多行为语义差异引发的负迁移。但模型本质上通过巩固和放大目标行为影响,却未考虑从根本上阻止辅助行为信息负迁移的发生。从实验结果来看,相比 HEM-GNN 等优化图结构的方法仍有提升空间。若引入去噪和多任务平衡手段,可进一步增强推荐效果。Bin 等人<sup>[87]</sup>基于 GCN 设计多行为图对比学习方法,向每个行为表示中添加噪声生成对比视图。通过设计嵌入噪声对比学习任务,使嵌入能够更加稳定地表示节点特征,缓解流行度偏差和数据稀疏现象。原文数据显示,冷门项目的命中率由 0.0062 提升至 0.0145,但热门项目仅由 0.3078 提升至 0.3441。这说明嵌入噪声对比学习放大了冷门项目的信号强度,使得模型更倾向于修正这些节点的表示,抑制了对热门项目的学习。虽然有效缓解了流行度偏差,却削弱了系统对流行项目的捕捉。应进一步改进对不同类型节点的学习,提升均衡的增益分布。Zhao 等人<sup>[88]</sup>通过构建交叉传播层关系学习模块,从结构层面引导多行为特征的融合与对比,实现了在行为感知表征上的层次性区分与联合优化。实验结果体现了模型对稀疏目标行为进行结构性补偿的有效性。但原文消融实验显示,去除对比学习模块后,模型在  $NDCG@10$  上的性能仅下降 0.0024,降幅低于  $HR@10$  的 0.112。这一现象揭示了对比约束在稠密或行为均衡的数据中主要起到粗粒度筛选作用,而在细粒度排序层面贡献微弱,暴露出在区分度优化上的局限。

钱忠胜等人<sup>[89]</sup>设计基于 GCN 的多行为图对比推荐方法,通过高阶邻域信息聚合构建更鲁棒的节点表示,并强化辅助行为信息与目标行为关联,实现多行为信号对推荐的协同增强。该方法在贝贝上表现良好,并通过消融实验证明了对比学习部分的增益。需要说明的是,模型在淘宝上的  $HR@10$  水平仅有 0.0923,远低于贝贝,体现其对于高相关性数据的强依赖。可见复杂且一致性弱的数据不仅削弱模型捕捉行为依赖性的能力,更会带来噪声干扰。

因此,需考虑引入去噪手段,同时进一步挖掘行为转换权重,提升模型优化监督信号分布的能力。

(2)生成学习方法。生成学习将真实数据分布的似然估计最大化,使学习到的表示能够捕捉到数据的潜在结构和模式,应用于下游任务。其中,VAE 作为一种生成方法,在多行为推荐场景中得到应用。在多行为推荐中,VAE 作为典型生成模型被引入以建模用户特征。作为变分图编码器变体,一方面推导每个行为的方差向量,一方面利用行为迁移网络生成均值向量,共同构成潜在因子,实现多行为表示在图结构中的传递与重构。但在天猫上的消融实验结果显示,VCGAE<sup>[57]</sup>借助浏览和购买数据进行推荐的效果,相比仅利用购买数据推荐更低。这凸显了模型对弱关联行为的过滤能力不足,导致部分扩展的监督信号稀释了目标行为的语义纯度,造成监督信号分布优化与性能提升间的冲突。V-GMR<sup>[35]</sup>将用户多行为数据映射到潜在表示空间,并引入偏好增强机制实现多行为信号的融合。通过生成学习,能从概率层面学习行为间依赖性。然而,模型采用的 KL 散度在约束隐变量分布的同时,会弱化辅助行为和目标行为间差异,易放大辅助行为干扰。虽然在贝贝上未受影响,但原文数据显示,在淘宝上的  $HR@80$  性能相比最优方法下降了 11.4%。这一现象揭示了 V-GMR 缺乏保护行为差异的显式机制。当目标行为极度稀疏时,模型易因隐空间平滑产生性能波动,表明其在极端场景中的鲁棒性仍存局限。

### 5.1.2 其他方法

Guo 等人<sup>[90]</sup>对交互图进行筛选和压缩以提升学习效率,并通过融合 GCN 与残差连接结构保留高阶语义。在多任务学习层面,该框架对每种行为的预测采用独立输入,缓解联合优化中的梯度冲突。模型通过在优化目标和建模路径上实现交叉增强,优化了监督信号分布并提升了训练稳定性。但模型在贝贝上的命中率相比次优模型仅提升 1.30%,远低于在淘宝上的提升(20.57%)。说明模型性能提升依赖差异明显的交互数据。当行为数据相关性强时,框架会重复利用已有的稠密信号,限制了其在低多样性场景上的泛化能力。

Hao 等人<sup>[91]</sup>引入单纯形结构设计 U-I 交互图,增强多行为推荐,并提出适用于该结构的 GNN 模型。单纯形结构紧凑,能体现出更强的节点相似性。模型通过单纯形聚合节点,保留隐式信息,补充显式交互数据。原文表明,面对交互次数不多于 5 次的

用户时,模型相比 MBSSL 在  $HR@10$  上有 15.3% 的提升,说明了单纯形结构对监督信号分布的优化效果。然而,尽管单纯形在信号的静态分布优化上表现出色,但隐式关系的迭代计算依赖稳定的数据组成,对新增的交互存在响应延迟。这导致模型难以适应新闻推荐等实时性强的场景。因此,可考虑引入时序建模和门控 GNN 等方式以适应监督信号的动态变化,增强模型鲁棒性和泛化能力。

利用辅助行为增强目标行为预测可能引发“跷跷板现象”,即模型在某一行为预测上性能提升的同时,在其他行为上的表现下降。该现象不仅源于不同优化目标的冲突,也与行为间的复杂依赖以及数据分布偏差相关。为缓解该现象,Zhang 等人<sup>[92]</sup>设计偏序图结构,基于优先级建模行为顺序关系,并提出适用于偏序图的 GCN 和 BPR 采样策略。如表 11 所示,模型性能在多项预测上表现良好,证明其在单一嵌入空间中优化多行为目标,能有效缓解跷跷板现象。但模型在购买行为上性能相对提升幅度最小(命中率仅提升 1.47%),表明当行为分布差异显著时,高阶行为的增益趋于饱和。因此在极端稀疏场景下,仍需额外正则化或数据增强策略以进一步挖掘长尾行为潜力。

### 5.1.3 讨 论

综合分析,监督信号分布可以从数据及结构两方面进行优化。数据优化可以采用自监督学习方式。例如,对比学习无需显式标注即可挖掘多行为间的隐式关联,有效提升长尾项目的嵌入质量。但该方法面临过度参数化挑战,在大规模图场景下,构建对比视图与生成正负样本会产生高昂计算开销。因此可以结合参数共享机制与轻量级编码器提升效率,或引入高效的非采样策略优化对比损失,还可以基于行为语义相似性筛选正负样本对,减少冗余运算。生成学习能够为行为设计合理的重构损失,弥补稀疏的目标行为信号。但单独或加权设计损失均

会增加模型训练成本,可采用元学习框架动态生成权重参数,兼顾性能与效率。结构优化可通过改良交互图结构来平衡数据分布。但在短视频平台等大规模场景中,图重构、存储与消息传递过程消耗大量计算资源,会制约模型扩展性。未来应探索参数可控的结构增强方式,或设计低阶图表示压缩策略,实现对精度与计算效率的协同优化。

### 5.2 辅助行为信息的去噪

尽管现有方法通过多行为的异质性有效提升了推荐性能,但大量辅助行为信息可能会引入噪声和无关的语义,为多行为推荐带来了挑战:

(1)辅助行为中的噪声交互。在多行为推荐中,U-I 交互通常包含一些固有又不可预测的噪声(如偶然的交互),这些交互无法准确反映用户兴趣。如果处理不当,多行为表示可能会不可避免地受到此类数据中的噪声影响。

(2)多类型行为间的语义差距。尽管在多行为下某些 U-I 交互是重叠的,但从语义特征角度来看,目标行为与辅助行为仍存在差异。弥合这种语义差距的核心挑战在于,如何从多行为中学习到的知识中有效提取目标行为特定的语义,并将其迁移到目标行为推荐中,同时确保知识的信息量不被削弱。

为了应对上述挑战,多行为推荐方法考虑两个方面:一方面,捕捉充足的监督信号,以准确预测用户的目标行为;另一方面,避免过多的辅助行为导致模型学习到噪声,影响目标行为的预测精度。如何优化模型,整合不同类型的有效的行为信息,成为提升多行为推荐效果的关键。本节总结和分析了多行为去噪的推荐方法,可从处理方式、数据和建模结构三种视角实现,如表 12 所示。为进行定量的方法评估和比较并保证公平性,本节通过调查原文数据或实验等方式,收集了方法在天猫上的性能数据,如表 13 所示。

表 12 辅助行为去噪的多行为推荐方法

问题	模型	发表	年份	优化角度	GNN 类型
辅助行为的偏差信息	PKEF <sup>[95]</sup>	CIKM	2023	处理方式优化	GCN
	IHG4MR <sup>[96]</sup>	ESWA	2023	建模结构优化	GCN
	DPT <sup>[82]</sup>	WWW	2023		GCN
	BCIPM <sup>[83]</sup>	SIGIR	2024		GCN
	MULE <sup>[97]</sup>	CIKM	2024	数据优化	GAT
	GHTID <sup>[98]</sup>	WSDM	2024		GCN
	TMCL <sup>[99]</sup>	DASFAA	2023		GAT
	MSSR <sup>[100]</sup>	CSCWD	2024		GCN

表 13 辅助行为信息去噪方法性能比较

行为	HR@20	NDCG@20
点击	0.935	0.0841
加购	0.1542	0.0948
购买	0.2029	0.1083
平均值	0.1502	0.0907

### 5.2.1 多行为去噪的推荐方法

多行为推荐去噪指在建模用户多行为时,识别并消除行为数据或项目序列中可能存在的无效或误导性数据,以提升推荐系统的鲁棒性和准确性。用户行为的随机性,高频行为对多任务学习的主导,或模型的过平滑现象均有可能导致噪声。噪声会干扰用户偏好的建模,或导致行为间关联的学习出现偏差,并降低模型的泛化能力,削弱推荐效果。

Meng 等人<sup>[95]</sup>提出基于“并行知识”的多行为推荐方法,避免多任务学习的效果被高频行为主导。该方法并行处理不同的行为,纠正不平衡的交互引入的信息偏差。模型将多任务学习解耦成共享部分和特有部分,共享部分用于聚合,特有部分用于优化并促进共同输入的互补效果。这种方法能够缓解负迁移现象和梯度冲突问题,排除可能出现的噪声。值得注意的是,尽管贝贝数据集规模更小、行为关联更强,但模型取得的效果反而较低( $HR@10$  为 0.1130、 $NDCG@10$  为 0.0582)。这一反差并非来自去噪机制的负优化,而是天猫数据集庞大的规模使模型的去噪优势得以充分发挥。训练过程中,天猫中四类行为的协同会导致更尖锐的梯度冲突。而贝贝中仅有三种行为,噪声有限,去噪收益相应减少,导致模型优势存在落差。这种落差实际与数据特性相关,而非去噪引入负优化。

Chang 等人<sup>[96]</sup>设计 IHG4MR 模型,基于特征相似度进行用户重分组,构建多个结构不同的新交互图。每个图中用户嵌入相似,使图卷积操作仅在局部高相关范围内进行,提高了信息传播的集中性。该策略可理解为对原始图的结构正则化,核心思想是通过局部聚集效应减少传播过程中的干扰信号,缓解过平滑问题的影响。然而,该策略仅允许每个用户归属于一个图,意味着用户表示被施加语义约束,虽然能够提升卷积的稳定性,却极大忽略了用户偏好多样性,存在推荐结果同质化的潜在风险。

Zhang 等人<sup>[82]</sup>设计三阶段学习实现多行为推荐中的去噪和提示调优。第一阶段,通过基于 GNN 的模式增强图编码器,以数据驱动的方式学习有价

值的项目嵌入,并识别固有噪声。第二阶段,模型对第一阶段学习到的参数重初始化,进一步减弱噪声影响。第三阶段,在图编码器的每一层引入提示信息调整节点嵌入,缓解多行为之间的语义差距。模型去除了天猫数据集中 18859 条浏览数据,在两个指标上表现出色,证明了三阶段范式在去噪和提高推荐效果上的有效性。但剔除数据占比仅 1.7%,说明去噪趋于保守,更倾向于保留潜在有效信息,对隐性噪声的识别和去除缺乏针对性措施。另外,原文与实验讨论均围绕“偶然交互”,未涉及恶意刷单等系统性噪声的模拟或检测,模型的鲁棒性在该类场景下仍需进一步证实。

Yan 等人<sup>[83]</sup>提出的多行为上下文偏好建模方法,关键特点在于将辅助行为数据选择性用于训练 GCN 参数,实现对多行为信息的约束性利用。该方法在嵌入聚合阶段仅考虑与用户目标行为相关的项目节点,有效抑制了辅助行为对最终推荐结果的直接干扰。这种选择性干预策略有效平衡了对监督信号的控制和对推荐结果的预测,实现了去噪与个性化感知的合理统一。

Lee 等人<sup>[97]</sup>提出多粒度图学习策略,通过目标引导去噪注意力为用户潜在兴趣分配较高的权重,并抑制相关性低或存在噪声的辅助行为,以获得质量更高的表示空间。在此基础上,模型通过 GAT 整合多粒度嵌入,使最终的用户表征不仅具备目标导向,同时在多行为层面体现出足够的表达能力。实验显示,模型为天猫中转化为购买的浏览数据分配了 0.041 的注意力权重,显著高于未转化数据的 0.026,差异幅度达 58%。表明模型有效区分了用户潜在兴趣与数据噪声。但对比可知,模型仍与 DPT、TMCL 等方法存在差距。首先,TMCL 对数据源头进行清理,清除不稳定节点。而 DPT 采用三阶段范式,逐步削弱噪声。二者去噪手段更加细致,更难被噪声干扰。其次,TMCL 和 DPT 分别引入对比学习和残差连接,采取了补充或保护监督信号的措施。因此,模型可以考虑精细化目标引导去噪注意力机制,同时深入挖掘并利用辅助行为信息,达到更优的效果。

Xuan 等人<sup>[100]</sup>提出时序多行为对比学习框架,通过子图提取算法生成去噪图用于对比学习。该算法为每个节点计算采样概率,评估节点稳定性及对于特定行为的重要程度,选择应被保留的节点。通过调节采样概率,算法可实现对不同行为在噪声敏感性上的差异性控制。原文显示,添加 10% 噪声

后,模型在天猫上  $HR@10$  仅下降约 0.03。证明去噪后的子图结构稳定、语义明确,赋予了模型在复杂环境下的鲁棒性。然而在冷启动场景下,随机采样计算节点稳定性的方式易受干扰,稳定性得分的方差增大,影响后续去噪的可靠性。另外,模型的时间截断阈值需人为预设,可能抑制对周期性复购等长期行为模式的挖掘和学习。

Li 等人<sup>[98]</sup>提出基于异构图的目标兴趣去噪方法,基于不同行为在预测任务上的贡献程度,将 GNN 获得的多行为表示经由 softmax 归一化为概率分布。模型通过这种在特征空间中差异化建模多行为的方式,抑制与目标任务无关的噪声。虽然模型性能逊于前述方法,但原因主要来自任务类型与实现方式存在本质区别。模型面向序列化预测,采用“留一法”验证性能,不引入额外负采样。而 PKEF 等方法在训练过程中采用随机负采样,并通过预处理的测试集评估效果。两种任务间存在的系统性差异是造成性能差距的根本原因。原文数据表明,相比次优的序列推荐方法,在  $HR@10$  和  $ND-CG@10$  上分别提升了 18.11% 和 21.17%,直观体现了模型去噪手段在序列推荐任务上的有效性。

多行为社交推荐面临交互数据和社交关系双重噪声,包括交互数据中的异常信息及非兴趣驱动的社交连接所带来的干扰。为此,Liu 等人<sup>[100]</sup>提出多行为增强的自监督学习框架,向多行为交互和社交关系的表示空间同时添加扰动,模拟对抗性攻击并生成扰动视图。通过在扰动视图间执行对比学习,引导模型捕捉稳定的潜在特征,提升其对语义相似性的感知能力,联合抑制结构噪声与语义噪声。由于添加的扰动是原始嵌入被随机打乱的结果,具备分布一致性,因此可避免原始嵌入的分布被破坏,保证模型鲁棒性。但如表 14 所示,模型性能在两个数据集上差距较大。由表 15 可知,豆瓣规模更小,且数据集行为类型分别为不喜欢、一般和喜欢三种。从数据集角度分析,用户在豆瓣中的社交关系基于共同兴趣,同质性高。模型对社交关系较真实的场景适配性较好,但面对社交噪声大、行为更复杂的电商场景时泛化性较差。因此需进一步优化恶劣场景下的行为建模与噪声抑制机制,并注意权衡社交关系和行为交互在表示空间中的均匀优化。

表 14 MSSR 性能数据

数据集	$HR@20$	$NDCG@20$
天猫	0.0696	0.0358
豆瓣	0.1885	0.1511

表 15 天猫、豆瓣数据集规模

数据集	用户数量	项目数量	交互总量	社交关系总量
天猫	41738	11953	2292594	864785
豆瓣	13024	22347	792062	169150

### 5.2.2 讨 论

综合分析,多行为推荐的去噪手段多样。从数据角度优化,可以通过消除低价值交互提升数据纯度,优势在于可直接作用于原始数据分布。通过抑制偶然性点击对用户核心购买意图的干扰,可显著提升加购等行为的建模权重。然而,该方法易引发语义割裂问题——例如在线教育场景中,用户短期高频访问行为可能同时包含真实学习意图(反复观看难点视频)与系统性噪声(视频连续自动播放),简单阈值过滤可能导致关键学习模式丢失。从结构角度优化,可以重构图拓扑实现噪声抑制,但当用户兴趣由于突发事件产生迁移时,该方法难以适应动态演变。此外,上述两种方法均面临去噪粒度与语义保留的平衡问题,需避免关键数据或图结构被删除,造成语义丢失。从处理方式角度优化,并行范式可以减少多任务学习带来的噪声,但是需单独为每种行为训练参数,且需专门的模块融合多行为特征,在大规模场景中会产生显著开销。

优化监督信号分布优化与辅助行为去噪两种技术进行协同往往具有更高性能。一方面,去噪机制可为监督信号优化提供更清晰的语义空间,而监督信号的优化则能补偿去噪损失的有效信息。在稀疏场景下,去噪机制通过抑制辅助行为中的干扰信息,可降低对比学习中假负例的生成概率,提升负采样质量。同时,采用对比学习策略的监督信号优化模块能够基于去噪行为图,构建更具判别力的正负样本,进一步挖掘去噪后行为数据的深层关联模式。这种组合尤其适用于“辅助行为密集但目标行为稀疏”的典型场景。另一方面,去噪机制过滤浏览等噪声含量高的行为后,自监督学习等手段可聚焦收藏、加购等高质量辅助行为与目标行为的语义映射,提升推荐结果的召回率与排序准确性。例如,TMCL 将去噪手段与对比学习结合,初步实现了双重优化的效果。因此,构建联合信息去噪与监督信号分布优化的统一框架,有望成为突破现有多行为模型性能瓶颈的关键技术。

## 6 代表方法性能比较

为直观体现基于 GNN 的多行为推荐方法的发

展和性能,本文选择部分有代表性的模型,在淘宝和贝贝两个公开数据集上进行实验,以体现它们的性能,数据集规模如表 16 所示。

表 16 贝贝、淘宝数据集规模

数据集	用户数量	项目数量	浏览	加购	购买
贝贝	21716	7977	2412586	642622	304576
淘宝	48749	39493	1548126	193747	259747

数据集的稀疏程度本质为数据缺失程度的量化指标,计算方式为  $1 - |\text{交互数量}| / (|\text{用户数量}| \times |\text{项目数量}|)$ 。经计算,贝贝和淘宝数据集中,目标行为的稀疏程度分别为 99.82% 和 99.98%,每个用户的平均目标行为数量为 14.03 次和 5.33 次,可见其非常稀疏。另外,本文通过香农熵衡量数据集中行为种类的多样性,计算方法如公式(5)所示:

$$H = - \sum_{i=1}^k p_i \log_2 p_i \quad (5)$$

其中,  $k$  为行为种类数量,  $p_i$  为行为的交互数量占交互总数的比例,  $H$  为香农熵。经计算可知,贝贝

数据集中,浏览、加购、购买三种行为的比例分别为 0.7181、0.1913 和 0.0907,可得熵为 1.1135 比特。淘宝数据集中,三种行为的比例分别为 0.7734、0.0968、0.1298,可得熵为 0.9951 比特。理论上,当三类行为分布均匀时,  $p_i$  均为 0.3333,可得最大熵约为 1.585 比特。分析可知,两个数据集的熵较低,意味着行为多样性有限,数据集偏向单一行为(浏览)分布。

为评估方法的推荐效果,本文选择推荐系统中两个常用的排序指标:命中率( $HR@K$ ,简写为  $H@K$ )和归一化折损累计增益( $NDCG@K$ ,简写为  $N@K$ )。更高的  $H@K$  和  $N@K$  代表更好的推荐效果,其中  $K$  是推荐的项目数。当  $K$  值分别为 10 和 50 时,代表性方法的推荐效果如表 17 所示。为便于后续研究,本文将数据集的来源和预处理方式,实验参数的设置,以及文中部分方法的开源地址公布在:<https://github.com/PeijinYang/MBRec-survey> 中,供读者参考。

表 17 代表方法性能比较

方法	贝贝				淘宝			
	$H@10$	$H@50$	$N@10$	$N@50$	$H@10$	$H@50$	$N@10$	$N@50$
NAH <sup>[33]</sup>	0.1922	0.3878	0.1006	0.1443	0.0815	0.1905	0.0444	0.0681
S-MBRec <sup>[44]</sup>	0.1697	0.3708	0.0872	0.1313	0.0774	0.1740	0.0434	0.0642
CML <sup>[45]</sup>	0.0588	0.1953	0.0292	0.0584	0.0299	0.0914	0.0150	0.0282
COPF <sup>[52]</sup>	0.1657	0.3627	0.0891	0.1323	0.0287	0.1050	0.0129	0.0293
BCIPM <sup>[83]</sup>	0.0681	0.2496	0.0467	0.0945	0.1131	0.2473	0.0631	0.0922
MBSSL <sup>[88]</sup>	0.1533	0.3334	0.0790	0.1176	0.1003	0.2081	0.0567	0.0801
SA-MBGCL <sup>[91]</sup>	0.2021	0.3881	0.1071	0.1478	0.0923	0.1957	0.0518	0.0748
IHG4MR <sup>[96]</sup>	0.1555	0.3298	0.0845	0.1224	0.0762	0.1605	0.0448	0.0632
EHCF <sup>[101]</sup>	0.1555	0.3298	0.0845	0.1224	0.0762	0.1605	0.0448	0.0632
GHCF <sup>[102]</sup>	0.1915	0.3810	0.0987	0.1046	0.0798	0.1816	0.0450	0.0671

贝贝数据集规模较小且项目品类分布集中,用户行为间相关性较强。淘宝数据集的用户和项目规模更大,但交互数据更稀疏。在对比实验中,除 BCIPM 外的其他方法在贝贝上表现更优。以 COPF 等探索多行为转换方式的方法在贝贝上的表现尤其突出。分析 BCIPM 和 IHG4MR 两个去噪方法可以发现,前者在淘宝上表现优秀,而后者恰恰相反,原因主要在于两个模型对噪声和信号的权衡处理不同。BCIPM 的全局过滤策略在去除噪声的同时也丢弃了大量可用的细粒度协同信号,在邻域丰富的贝贝数据集上收益有限。但该机制对噪声干扰的有效抑制,能使其在交互更复杂的淘宝数据集上达到最优性能。IHG4MR 采用子图划分方式,既能抑制跨兴趣的噪声传播,又能充分利用数据中的高阶协同信号,在贝贝上收效明显。在淘宝数据集上,子图

划分稀释了数据集中本就稀少的邻域信息,导致信号损失超出去噪优化,降低了推荐效果。需要说明的是,BCIPM 虽然通过节点嵌入的相关计算过滤噪声,但忽略了节点嵌入自身即含有噪声的事实。从建模角度分析,EHCF、GHCF 与 S-MBRec 通过联合建模行为间共性与差异,实现了辅助行为的有效利用,在两个数据集上性能稳健。NAH 通过学习用户整体偏好增强预测,并缓解了冷启动的干扰,性能相比 EHCF 等三种方法有小幅提高。从优化角度来看,MBSSL 与 SA-MBGCL 采用对比学习策略优化监督信号分布,在稀疏场景下效果突出——从淘宝数据集  $H@10$  指标可见,二者相较表中基于建模的方法分别提升了 23.07%~31.63% 和 13.25%~21.13%。此外,本文观测到的 CML 性能水平低于原文,原因可能为数据规模差异。原文涉及的三种

数据集体量小,同时均含有四种行为类型,更有利于 CML 学习多行为间关联。但当模型面临交互密度低但整体规模庞大的数据时,交互的弱关联特性与模型的行为强相关假设存在冲突,导致知识迁移效率降低,难以发挥出最优水平。

## 7 未来工作

当前,多行为推荐的核心目标是提升推荐的准确性和个性化。近年来,由于大语言模型在自然语言处理领域的卓越的能力,其在提升多行为推荐准确性前景逐渐受到关注。同时,与推荐准确性密切相关的多样性和公平性,以及因果推断在用户多行为研究中的重要意义,也为多行为推荐提供了新的研究视角。本文基于多行为推荐研究现状,结合推荐系统的四个重要目标:准确性、多样性、公平性和因果性,提出了四个具有研究价值的未来方向,包括大模型增强的多行为推荐、多行为推荐的公平性问题、多行为推荐的多样性问题以及基于因果推断的多行为推荐。

### 7.1 基于动态 GNN 的多行为推荐

随着用户行为的实时变化,多行为推荐系统需要动态更新图结构以反映最新的交互模式,而当前大多数 GNN 模型主要针对静态图设计,难以高效适应动态场景下的增量更新需求。而动态图上的 GNN 训练和推理计算成本较高,特别是在大规模推荐系统中,这限制了其实时应用能力。未来研究可以聚焦于开发轻量级的动态图神经网络,例如通过子图采样或时间感知的节点嵌入更新机制,降低动态图更新的计算复杂度。同时,结合在线学习框架,设计能够快速适应新行为模式的 GNN 模型,以提升系统的实时响应能力。这些研究方向将有助于解决 GNN 在动态多行为推荐场景中的可扩展性瓶颈,为构建高效、实时的推荐系统提供技术支持。

### 7.2 GNN 视角下的多行为推荐公平性

推荐系统中的不公平性问题通常源于数据特征的分布不均,例如用户性别、年龄或地域等敏感属性带来的偏差。然而在图结构中,除特征偏差外,图本身的结构也可能隐含不平等关系<sup>[103-104]</sup>。图中的邻接结构体现了个体之间在连接方式和强度上的差异性,这种差异会导致信息传播与聚合过程在节点间的表现不平衡。尤其在 GNN 中,节点通过邻居聚合获取表示,邻接性强的节点在信息传播中处于优势地位,而邻居较少的节点则可能因信息稀缺,导致

其学习过程受限。在多行为推荐任务中,不公平问题更为复杂,基于不同行为构建的图结构加剧了节点间邻接的异质性与行为表达的不均衡性,使得低强度行为或弱连接用户在图表示学习中受到抑制,易引发推荐结果的不公平。此外,现有的公平性优化方法多聚焦于单一行为推荐场景<sup>[105-106]</sup>,对于多行为场景中行为类型的多样性与行为强度的异质性缺乏有效建模机制。因此,未来研究需进一步探索如何在多行为图结构中缓解 GNN 因邻接性差异引发的信息传播不均与表示偏倚,设计适应行为多样性结构特征的公平建模机制,从而实现多行为推荐中的结构公平性优化。

### 7.3 多行为推荐的多样性问题

为挖掘用户潜在兴趣,满足用户需求的多元化,实现多样性成为推荐系统的重要目标之一<sup>[107]</sup>。推荐系统中通常考虑两种类型的多样性来减少信息茧房效应,即个体多样性和系统多样性。个体多样性反映了推荐列表涵盖的主题数量以及推荐项目在不同主题上的分布是否平衡;系统多样性要求不同用户的推荐结果彼此不同。系统多样性低意味着总是流行项目才能得到推荐,而长尾项目总是被忽略;高系统多样性才有可能兼顾推荐流行项目和长尾项目,与此同时也能满足推荐系统对物品公平性的要求。然而无论是对于个体还是系统,信号强度的差异是实现多样性的主要挑战,这种差异在多行为推荐中更加明显。对于男性用户来说,和电子产品的互动频率可能远高于服饰,而对于女性用户来说情况可能恰好相反;而从多行为视角出发,无论是对于辅助行为还是目标行为,流行项目的信号强度都远高于长尾项目。因此,在弱监督情况下,实现多行为推荐的多样性是具有挑战性的。此外,多样性有时会与推荐准确性产生冲突,如何在二者之间寻求平衡也是一项值得研究的问题。

### 7.4 基于因果推断的多行为推荐

因果性也称因果关系,其中原因在某种程度上导致了结果,而结果在某种程度上依赖于原因。因果推断是基于事件发生的条件,推断因果关系的过程<sup>[108]</sup>。对于多行为推荐而言,行为相关性是重要的考量。然而,相关性并不意味着因果关系,目前的大多数推荐系统仍是相关性驱动,面对着如数据偏差和数据噪声等挑战。因果推断的引入为推荐系统提供了一种新的视角,特别是在对推荐系统进行理解和优化时,能够明确区分相关性和因果性,不再只是把行为之间和项目之间的关联当做关注重点。另

外,因果推断可以帮助推荐系统完成数据消偏、数据增强和数据去噪,以及在不损害准确性的情况下实现可解释性和公平性等目标<sup>[109]</sup>。可预见的是,因果推断能够帮助解决多行为推荐中准确性和多样性的冲突,还能利用用户行为中的因果关系,理解用户对某些项目的消费原因。这有助于系统帮助用户拓展项目类别,满足更丰富的用户需求。

## 8 结 论

为了满足用户的个性化需求,推荐系统在在线平台中发挥着重要作用。随着互联网数据规模增大,用户各种行为都对推荐起到了不可忽视的参考价值,多行为推荐受到了越来越多的关注。又因为图结构在描述多行为场景上具备天然优势,所以已经成为了大多数方法的建模基础。尽管学术界和工业界对多行为推荐的研究数量少于单行为推荐,但日益增多的工作表明了其在推荐系统中的重要性。

本文从建模方式、关键场景和模型优化三个角度对相关工作进行了分类和讨论。基于建模的方法包括三个方面,分别为面向用户偏好学习的方法、面向行为语义信息挖掘的方法和知识辅助增强的方法。面向不同场景的方法部分,本文介绍了基于GNN的多行为社交推荐方法、多行为序列推荐方法和多行为会话推荐方法。最后,本文从监督信号分布优化和辅助行为信息去噪两个角度,对目前通过优化多行为推荐模型提升性能的方法做出介绍。

通过对现有工作的讨论,可以发现基于图神经网络的多行为推荐仍存在很大的潜力和发展空间,因此本文提出了四个可能的未来方向,包括基于动态GNN的多行为推荐,GNN视角下的多行为推荐公平性,以及多行为推荐中多样性和因果推断的实现前景,希望能为读者提供一些关于如何解决多行为推荐问题的前瞻性指导。

## 参 考 文 献

- [1] Huang Z, Lin W, Wu Z, et al. Incremental news recommendation method based on optimal transport and knowledge replay. *Chinese Journal of Computers*, 2023, 46(10): 2161-2177(in Chinese)  
(黄震华, 林威, 吴正洋, 等. 基于最优传输和知识回放的新闻推荐模型增量学习方法. *计算机学报*, 2023, 46(10): 2161-2177)
- [2] Hao J, Zhang K, Wu L, et al. Conformity-aware debiased neural news recommendation with causal reasoning. *Chinese Journal of Computers*, 2024, 47(10): 2333-2351(in Chinese)  
(鲍纪敏, 张琨, 吴乐, 等. 从众性感知的因果去偏新闻推荐方法. *计算机学报*, 2024, 47(10): 2333-2351)
- [3] Gao C, Zheng Y, Li N, et al. A survey of graph neural networks for recommender systems: challenges, methods, and directions. *ACM Transactions on Recommender Systems*, 2023, 1(1): 1-51
- [4] Bell R M, Koren Y. Scalable collaborative filtering with jointly derived neighborhood interpolation weights//*Proceedings of the 17th IEEE International Conference on Data Mining*. Omaha, USA, 2007: 43-52
- [5] Koren Y, Bell R, Volinsky C. Matrix factorization techniques for recommender systems. *Computer*, 2009, 42(8): 30-37
- [6] Rendle S. Factorization machines//*Proceedings of the 20th IEEE International Conference on Data Mining*. Sydney, Australia, 2010: 995-1000
- [7] He X, Liao L, Zhang H, et al. Neural collaborative filtering//*Proceedings of the 26th International Conference on World Wide Web*. Perth, Australia, 2017: 173-182
- [8] Guo H, Tang R, Ye Y, et al. Deepfm: a factorization-machine based neural network for ctr prediction//*Proceedings of the 26th International Joint Conference on Artificial Intelligence*. Melbourne, Australia, 2017:1725-1731
- [9] Lou Z, Zhu J, Zhang W, et al. Role-guided graph neural recommendation in user-generated content scenarios. *Chinese Journal of Computers*, 2024, 47(6): 1288-1303(in Chinese)  
(娄铮铮, 朱军娇, 张万闯, 等. 用户生成内容场景下角色导向图神经推荐方法. *计算机学报*, 2024, 47(6): 1288-1303)
- [10] Xiao G, Li X, Chen Y, et al. A survey of large-scale graph neural networks. *Chinese Journal of Computers*, 2024, 47(1): 148-171(in Chinese)  
(肖国庆, 李雪琪, 唐卓, 等. 大规模图神经网络研究综述. *计算机学报*, 2024, 47(1): 148-171)
- [11] Gai L, Lei L. Dual collaborative topic modeling from implicit feedbacks//*Proceedings of the IEEE International Conference on Security, Pattern Analysis, and Cybernetics*. Wuhan, China, 2014: 395-404
- [12] Singh A P, Gordon G J. Relational learning via collective matrix factorization//*Proceedings of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. Las Vegas, USA, 2008: 650-658
- [13] Cheng J, Yuan T, Wang J, et al. Group latent factor model for recommendation with multiple user behaviors//*Proceedings of the 37th International ACM SIGIR Conference on Research & Development in Information Retrieval*. Gold Coast, Australia, 2014: 995-998
- [14] Koren Y. Factorization meets the neighborhood: a multifaceted collaborative filtering model//*Proceedings of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. Las Vegas, USA, 2008: 426-434
- [15] Liu J, Shi C, Hu B, et al. Personalized ranking recommen-

- ation via integrating multiple feedbacks//Proceedings of the 21st Pacific-Asia Conference on Knowledge Discovery and Data Mining. Jeju, Republic of Korea, 2017: 131-143
- [16] Loni B, Pagano R, Larson M, et al. Bayesian personalized ranking with multi-channel user feedback//Proceedings of the 10th ACM Conference on Recommender Systems. Boston, USA, 2016: 361-364
- [17] Li X, Sun L, Ling M, et al. A survey of graph neural network based recommendation in social networks. *Neurocomputing*, 2023, 549: 126441
- [18] Sharma K, Lee Y C, Nambi S, et al. A survey of graph neural networks for social recommender systems. *ACM Computing Surveys*, 2024, 56(10): 1-34
- [19] Chen X, Li Z, Pan W, et al. A survey on multi-behavior sequential recommendation. *arXiv preprint arXiv:2308.15701*, 2023
- [20] He Z, Liu W, Guo W, et al. A survey on user behavior modeling in recommender systems//Proceedings of the 32nd International Joint Conference on Artificial Intelligence. Macao, China, 2023: 6656-6664
- [21] Bing R, Yuan G, Cai Z, et al. Automated modeling of influence diversity with graph convolutional network for social recommendation//Proceedings of the 8th Asia-Pacific Web and Web-Age Information Management Joint International Conference on Web and Big Data. Jinhua, China, 2024: 33-49
- [22] Zhao W, Yuan G, Bing R, et al. Periodicity aware spatial-temporal adaptive hypergraph neural network for traffic forecasting. *GeoInformatica*, 2025, 29(2): 201-232
- [23] O'Shea K. An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*, 2015
- [24] Zhang C, Song D, Huang C, et al. Heterogeneous graph neural network//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. Anchorage, USA, 2019: 793-803
- [25] Yu P, Fu C, Yu Y, et al. Multiplex heterogeneous graph convolutional network//Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. Washington, USA, 2022: 2377-2387
- [26] Feng Y, You H, Zhang Z, et al. Hypergraph neural networks//Proceedings of the 33rd AAAI Conference on Artificial Intelligence; Vol. 33. Honolulu, USA, 2019:3558-3565
- [27] Kipf T N, Welling M. Semi-supervised classification with graph convolutional networks//Proceedings of the 5th International Conference on Learning Representations. Toulon, France, 2017
- [28] Veličković P, Cucurull G, Casanova A, et al. Graph attention networks//Proceedings of the 6th International Conference on Learning Representations. Vancouver, Canada, 2018
- [29] Koren Y, Rendle S, Bell R. Advances in collaborative filtering. *Recommender Systems Handbook*, 2021: 91-142
- [30] Yu J, Yin H, Xia X, et al. Self-supervised learning for recommender systems: A survey. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 36(1): 335-355
- [31] Gan M, Xu G, Ma Y. A multi-behavior recommendation method exploring the preference differences among various behaviors. *Expert Systems with Applications*, 2023, 228: 120316
- [32] Wei Y, Ma H, Wang Y, et al. Multi-behavior recommendation with two-level graph attentional networks//Proceedings of the International Conference on Database Systems for Advanced Applications. Virtual, India, 2022: 248-255
- [33] Jiang N, Hu Z, Wen J, et al. Nah: neighbor-aware attention-based heterogeneous relation network model in e-commerce recommendation. *World Wide Web*, 2023, 26(5): 2373-2394
- [34] Li Q, Ma H, Zhang R, et al. Intra-and inter-behavior contrastive learning for multi-behavior recommendation//Proceedings of the 21st International Conference on Database Systems for Advanced Applications. Tianjin, China, 2023: 147-162
- [35] Yang H, Rang R, Xing L, et al. V-gmr: a variational autoencoder-based heterogeneous graph multi-behavior recommendation model. *Applied Intelligence*, 2024, 54(4): 3337-3350
- [36] Yan M, Cheng Z, Sun J, et al. Two-stage learning for multi-behavior recommendation. *Journal of Software*, 2024, 35(05): 2446-2465(in Chinese)  
(严明时, 程志勇, 孙静, 等. 基于两阶段学习的多行为推荐. *软件学报*, 2024, 35(05): 2446-2465)
- [37] Yu W, Bin C, Liu W, et al. Contrastive learning-based multi-behavior recommendation with semantic knowledge enhancement//Proceedings of the 23rd IEEE International Conference on Data Mining. Shanghai, China, 2023:1511-1516
- [38] Pan X, Gan M. Multi-behavior recommendation based on intent learning. *Multimedia Systems*, 2023, 29(6): 3655-3668
- [39] Xia L, Huang C, Xu Y, et al. Multi-behavior graph neural networks for recommender system. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 35(4):5473-5487
- [40] Jiang W, Duan L, Ding X, et al. Moro: a multi-behavior graph contrast network for recommendation//Proceedings of the Asia-Pacific Web and Web-Age Information Management Joint International Conference on Web and Big Data. Nanjing, China, 2022: 117-131
- [41] Wei W, Xia L, Huang C. Multi-relational contrastive learning for recommendation//Proceedings of the 17th ACM Conference on Recommender Systems. Singapore, 2023: 338-349
- [42] Xu W, Li H, Wang M. Multi-behavior guided temporal graph attention network for recommendation//Proceedings of the Pacific-Asia Conference on Knowledge Discovery and Data Mining. Osaka, Japan, 2023: 297-309

- [43] Meng C, Zhao Z, Guo W, et al. Coarse-to-fine knowledge-enhanced multi-interest learning framework for multi-behavior recommendation. *ACM Transactions on Information Systems*, 2023, 42(1): 1-27
- [44] Gu S, Wang X, Shi C, et al. Self-supervised graph neural networks for multi-behavior recommendation//*Proceedings of the 31th International Joint Conference on Artificial Intelligence*. Vienna, Austria, 2022: 2052-2058
- [45] Wei W, Huang C, Xia L, et al. Contrastive meta learning with behavior multiplicity for recommendation//*Proceedings of the 15th ACM International Conference on Web Search and Data Mining*. New York, USA, 2022: 1120-1128
- [46] Wu Y, Xie R, Zhu Y, et al. Multi-view multi-behavior contrastive learning in recommendation//*Proceedings of the 20th International Conference on Database Systems for Advanced Applications*. Virtual, India, 2022: 166-182
- [47] Yang H, Chen H, Li L, et al. Hyper meta-path contrastive learning for multi-behavior recommendation//*Proceedings of the 21st IEEE International Conference on Data Mining*. Auckland, New Zealand, 2021: 787-796
- [48] Cheng Z, Han S, Liu F, et al. Multi-behavior recommendation with cascading graph convolution networks//*Proceedings of the ACM Web Conference 2023*. Austin, USA, 2023: 1181-1189
- [49] Liu N, Meng S, Jiang Y, et al. Cascading graph convolution contrastive learning networks for multi-behavior recommendation//*Proceedings of the 22nd International Conference on Database Systems for Advanced Applications*. Gifu, Japan, 2024: 3-18
- [50] Yan M, Cheng Z, Gao C, et al. Cascading residual graph convolutional network for multi-behavior recommendation. *ACM Transactions on Information Systems*, 2023, 42(1): 1-26
- [51] Cheng Z, Dong J, Liu F, et al. Disentangled cascaded graph convolution networks for multi-behavior recommendation. *ACM Transactions on Recommender Systems*, 2024, 2(4): 1-27
- [52] Zhai C, Meng C, Yang Y, et al. Combinatorial optimization perspective based framework for multi-behavior recommendation. *arXiv preprint arXiv:2502.02232*. 2025
- [53] Meng C, Zhang H, Guo W, et al. Hierarchical projection enhanced multi-behavior recommendation//*Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. Long Beach, USA, 2023: 4649-4660
- [54] Xia L, Xu Y, Huang C, et al. Graph meta network for multi-behavior recommendation//*Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval*. Virtual, Canada, 2021: 757-766
- [55] Zhu X, Lin F, Zhao Z, et al. Multi-behavior recommendation with personalized directed acyclic behavior graphs. *ACM Transactions on Information Systems*, 2024, 43(1): 1-30
- [56] Li X, Fu C, Zhao Z, et al. Dual-channel multiplex graph neural networks for recommendation. *IEEE Transactions on Knowledge and Data Engineering*, 2025, 37(6): 3327-3341
- [57] Liu Y, Rao Q, Pan W, et al. Variational collective graph autoencoder for multi-behavior recommendation//*Proceedings of the 23rd IEEE International Conference on Data Mining*. Shanghai, China, 2023: 438-447
- [58] Fan W, Zhou W, Wen J. Recommendation based on graph heterogeneous using dual channel cross-adaptive contrast learning. *ACTA ELECTRONICA SINICA*, 2023, 51(07): 1929-1938(in Chinese)  
(范伟, 周魏, 文俊浩. 基于异构图的双通道交叉自适应对比学习推荐. *电子学报*, 2023, 51(07): 1929-1938)
- [59] Xuan H, Liu Y, Li B, et al. Knowledge enhancement for contrastive multi-behavior recommendation//*Proceedings of the 16th ACM International Conference on Web Search and Data Mining*. Singapore, 2023: 195-203
- [60] Liang S, Zhao J, Li C, et al. Knowledge-aware multi-intent contrastive learning for multi-behavior recommendation. *arXiv preprint arXiv:2404.11993*. 2024
- [61] Liu T, Li Y. Knowledge-based multi-behavior recommendation with factor disentanglement//*Proceedings of the IEEE/ACIS 22nd International Conference on Computer and Information Science*. Zhuhai, China, 2022: 223-228
- [62] Li X, Wang N, Zeng J, et al. Knowledge-enhanced dynamic modeling framework for multi-behavior recommendation//*Proceedings of the 33rd ACM International Conference on Information and Knowledge Management*. Boise, USA, 2024: 3882-3886
- [63] Park G, Yang H, Yeom K, et al. Knowledge-constrained interest-aware multi-behavior recommendation with behavior pattern identification. *Information Sciences*, 2025, 692: 121652
- [64] Liu H, Zhang X, Yang B, et al. An enhanced influence diffusion model for social recommendation. *Chinese Journal of Computers*, 2023, 46(3): 626-642(in Chinese)  
(刘会, 张璇, 杨兵, 等. 用于社交推荐的增强影响扩散模型. *计算机学报*, 2023, 46(3): 626-642)
- [65] Guo J, Zhou Y, Zhang P, et al. Trust-aware recommendation based on heterogeneous multi-relational graphs fusion. *Information Fusion*, 2021, 74: 87-95
- [66] Xu H, Huang C, Xu Y, et al. Global context enhanced social recommendation with hierarchical graph neural networks//*Proceedings of the 20th IEEE International Conference on Data Mining*. Sorrento, Italy, 2020: 701-710
- [67] Huang C, Xu H, Xu Y, et al. Knowledge-aware coupled graph neural network for social recommendation//*Proceedings of the 35th AAAI Conference on Artificial Intelligence*. Virtual, Canada, 2021: 4115-4122
- [68] Zhang L, Zhang W, Wu L, et al. Shgn: socially enhanced heterogeneous graph convolutional network for multi-behavior prediction. *ACM Transactions on the Web*, 2023, 18(1): 1-27

- [69] Wu X, Huang A, Yang H, et al. Multi-behavior enhanced graph neural networks for social recommendation//Proceedings of the 6th Chinese Conference on Pattern Recognition and Computer Vision. Xiamen, China, 2023: 40-52
- [70] Xia L, Huang C, Xu Y, et al. Multi-behavior sequential recommendation with temporal graph transformer. *IEEE Transactions on Knowledge and Data Engineering*, 2022, 35(6): 6099-6112
- [71] Jiang X, Sun H, He L. Novel behavior-enhanced long-and short-term interest model for sequential recommendation. *Information Sciences*, 2024, 679: 121127
- [72] Gao Y, Huang X, Tao J. Sequential recommendation model integrating micro-behaviors and attribute enhancement. *Neurocomputing*, 2023, 548: 126393
- [73] Lu X, Feng J, Han Y, et al. Graphmlp-mixer: A graph-mlp architecture for efficient multi-behavior sequential recommendation method. *Journal of Computer Research and Development*, 2024, 61(08): 1917-1929(in Chinese)  
(卢晓凯, 封军, 韩永强, 等. Graphmlp-mixer: 基于图-多层感知机架构的高效多行为序列推荐方法. *计算机研究与发展*, 2024, 61(08): 1917-1929)
- [74] Zheng Z, Hu X, Qiu Z, et al. Bilateral multi-behavior modeling for reciprocal recommendation in online recruitment. *IEEE Transactions on Knowledge and Data Engineering*, 2024, 36(11): 5681-5694
- [75] Li Q, Ma H, Jin W, et al. Hypergraph-enhanced multi-interest learning for multi-behavior sequential recommendation. *Expert Systems with Applications*, 2024: 124497
- [76] Wu B, Cheng Y, Yuan H, et al. When multi-behavior meets multi-interest: Multi-behavior sequential recommendation with multi-interest self-supervised learning//Proceedings of the 40th International Conference on Data Engineering. Utrecht, Netherlands, 2024: 845-858
- [77] Yuan J, Ji W, Zhang D, et al. Micro-behavior encoding for session-based recommendation//Proceedings of the IEEE 38th International Conference on Data Engineering. Kuala Lumpur, Malaysia, 2022: 2886-2899
- [78] Yu B, Zhang R, Chen W, et al. Graph neural network based model for multi-behavior session-based recommendation. *GeoInformatica*, 2022, 26(2): 429-447
- [79] Qiao J, Wang L. Modeling user micro-behaviors and original interest via adaptive multi-attention network for session-based recommendation. *Knowledge-Based Systems*, 2022, 244: 108567
- [80] Yu B, Li X, Fang J, et al. Memory-augmented meta-learning framework for session-based target behavior recommendation. *World Wide Web*, 2023, 26(1): 233-251
- [81] Zhang Y, Zhu X, He G, et al. Learning multi-behavior user intent for session-based recommendation. *Expert Systems with Applications*, 2025, 259: 125269
- [82] Zhang C, Chen R, Zhao X, et al. Denoising and prompt-tuning for multi-behavior recommendation//Proceedings of the ACM Web Conference 2023. Austin, USA, 2023: 1355-1363
- [83] Yan M, Liu F, Sun J, et al. Behavior-contextualized item preference modeling for multi-behavior recommendation//Proceedings of the 47th International ACM SIGIR Conference on Research and Development in Information Retrieval. Washington, USA, 2024: 946-955
- [84] Yuan G, Yang P, Cai Z, et al. Multibehavior recommendation with nonoverlapping heterogeneous graph collaborative filtering. *IEEE Transactions on Computational Social Systems*, 2025, (1): 1-13
- [85] Jaiswal A, Babu A R, Zadeh M Z, et al. A survey on contrastive self-supervised learning. *Technologies*, 2020, 9(1): 2
- [86] Xu J, Wang C, Wu C, et al. Multi-behavior self-supervised learning for recommendation//Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, USA, 2023: 496-505
- [87] Bin C, Li W, Wu F, et al. Multi-behavior-based graph contrastive learning recommendation. *Knowledge and Information Systems*, 2024: 1-20
- [88] Zhao Z, Tong X, Wang Y, et al. Multi-behavior contrastive learning with graph neural networks for recommendation. *Knowledge-Based Systems*, 2024, 300: 112221
- [89] Qian Z, Huang H, Wan Z. The multi-behavior graph contrastive learning recommendation method with self-attention mechanism. *ACTA ELECTRONICA SINICA*, 2024, 52(11): 3684-3698(in Chinese)  
(钱忠胜, 黄恒, 万子珑. 融合自注意力机制的多行为图对比学习推荐方法. *电子学报*, 2024, 52(11): 3684-3698)
- [90] Guo W, Meng C, Yuan E, et al. Compressed interaction graph based framework for multi-behavior recommendation//Proceedings of the ACM Web Conference 2023. Austin, USA, 2023: 960-970
- [91] Hao Q, Wang C, Xiao Y, et al. Simplicies-based higher-order enhancement graph neural network for multi-behavior recommendation. *Information Processing & Management*, 2024, 61(5): 103790
- [92] Zhang Y, Bei Y, Chen H, et al. Multi-behavior collaborative filtering with partial order graph convolutional networks//Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. Barcelona, Spain, 2024: 6257-6268
- [93] Wang T, Isola P. Understanding contrastive representation learning through alignment and uniformity on the hypersphere//Proceedings of the 37th International Conference on Machine Learning. Virtual, Austria, 2020: 9929-9939
- [94] Xia L, Huang C, Xu Y, et al. Hypergraph contrastive collaborative filtering//Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2022: 70-79
- [95] Meng C, Zhai C, Yang Y, et al. Parallel knowledge enhancement based framework for multi-behavior recommendation//

- Proceedings of the 32nd ACM International Conference on Information and Knowledge Management. Birmingham, UK, 2023; 1797-1806
- [96] Chang Y, Zhou W, Wen J. Ihg4mr: interest-oriented heterogeneous graph for multirelational recommendation. *Expert Systems with Applications*, 2023, 228; 120321
- [97] Lee S, Ko G, Song H J, et al. Mule: multi-grained graph learning for multi-behavior recommendation//Proceedings of the 33rd ACM International Conference on Information and Knowledge Management. Boise, USA, 2024; 1163-1173
- [98] Li X, Chen H, Yu J, et al. Global heterogeneous graph and target interest denoising for multi-behavior sequential recommendation//Proceedings of the 17th ACM International Conference on Web Search and Data Mining. Merida, Mexico, 2024; 387-395
- [99] Xuan H, Li B. Temporal-aware multi-behavior contrastive recommendation//Proceedings of the 21st International Conference on Database Systems for Advanced Applications. Tianjin, China, 2023; 269-285
- [100] Liu S, Xu Y. Multi-behavior enhanced self-supervised graph learning for social recommendation//Proceedings of the 27th International Conference on Computer Supported Cooperative Work in Design. Tianjin, China, 2024; 1092-1097
- [101] Chen C, Zhang M, Zhang Y, et al. Efficient heterogeneous collaborative filtering without negative sampling for recommendation//Proceedings of the 34th AAAI Conference on Artificial Intelligence; Vol. 34. New York, USA, 2020; 19-26
- [102] Chen C, Ma W, Zhang M, et al. Graph heterogeneous multi-relational recommendation//Proceedings of the 35th AAAI Conference on Artificial Intelligence; Vol. 35. Virtual, Canada, 2021; 3958-3966
- [103] Zhang G, Cheng D, Zhang S. Fpgnn: fair path graph neural network for mitigating discrimination. *World Wide Web*, 2023, 26(5); 3119-3136
- [104] Zhang G, Cheng D, Yuan G, et al. Learning fair representations via rebalancing graph structure. *Information Processing & Management*, 2024, 61(1); 103570
- [105] Qi T, Wu F, Wu C, et al. Pp-rec: news recommendation with personalized user interest and time-aware news popularity//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. Bangkok, Thailand, 2021; 5457-5467
- [106] Qi T, Wu F, Wu C, et al. Profairrec: Provider fairness-aware news recommendation//Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2022; 1164-1173
- [107] Peng Y, Meng X, Du Z. Survey on diversified recommendation. *Journal of Computer Research and Development*, 2025, 62(02); 285-313(in Chinese)  
(彭迎涛, 孟小峰, 杜治娟, 等. 多样化推荐综述. *计算机研究与发展*, 2024, 62(02); 285-313)
- [108] Yang X, Liu Z, Lu S, et al. A survey on debiasing recommendation based on causal inference. *Chinese Journal of Computers*, 2024, 47(10); 2307-2332(in Chinese)  
(杨新新, 刘真, 卢思博, 等. 基于因果推断的推荐系统去偏研究综述. *计算机学报*, 2024, 47(10); 2307-2332)
- [109] Wang Y, Liang D, Charlin L, et al. Causal inference for recommender systems//Proceedings of the 14th ACM Conference on Recommender Systems. Virtual, Brazil, 2020; 426-431



**YANG Pei-Jin**, Ph. D. candidate. His research interests include Graph Neural Networks and recommender systems.

**YUAN Guan**, Ph. D., professor. His research interests include intelligent information and data processing and

large-scale graph data computation.

**ZHANG Gui-Xian**, Ph. D. candidate. His research interests include trustworthy artificial intelligence and graph

representation learning.

**QIAO Shao-Jie**, Ph. D., professor. His research interests include big data technologies and applications, and domain-specific big data analysis.

**WANG Sen-Zhang**, Ph. D., professor. His research interests include spatiotemporal big data mining and graph data mining.

**LI Bo-Han**, Ph. D., associate professor. His research interests include recommender systems and knowledge graphs.

## Background

Compared to traditional recommender systems, multi-behavior recommendation can leverage implicit feedback from multiple interaction data, and by considering various user behaviors and their interrelations, it can more comprehensively explore users' interests and behavior patterns. This approach overcomes the limitations of single-behavior recommendation methods, providing more accurate personalized

recommendations. Given that the graph structure can effectively capture the characteristics of multi-behavior recommendation, and that Graph Neural Networks have demonstrated significant advantages in learning representations for non-Euclidean data, GNN-based multi-behavior recommendation has developed rapidly in recent years and has garnered considerable attention.

In this survey, we investigate and summarize the current research on multi-behavior recommendation based on Graph Neural Networks. First, we provide a brief overview of the graph structures and GNN frameworks applicable to multi-behavior recommendation and analyze the reasons why GNNs are suitable for this task. Next, we categorize and analyze the latest advancements in GNN-based multi-behavior recommendation methods across various scenarios, including general scenarios, social recommendation, sequential recommendation, and session-based recommendation. Third, we classify and discuss optimization techniques for GNN-based multi-behavior recommendation models, including methods

for optimizing the distribution of supervisory signals and techniques for denoising auxiliary behavior information. Finally, we outline future research directions in light of existing challenges.

This work was supported in part by the National Natural Science Foundation of China under Grant 62172443, Xuzhou K&D Program under Grant KC23296, the Graduate Innovation Program of China University of Mining and Technology 2024WLKXJ183, the Fundamental Research Funds for the Central Universities 2024-10949, and the Postgraduate Research & Practice Innovation Program of Jiangsu Province KYCX24\_2781.