

图神经网络驱动的个性化推荐：多行为建模、技术 进展与前沿趋势

成英超¹⁾ 吴赣生^{1),2)} 何玉林¹⁾ 黄哲学¹⁾ 陈炳丰³⁾

¹⁾(人工智能与数字经济广东省实验室(深圳) 广东 深圳 518107)

²⁾(深圳大学计算机与软件学院 广东 深圳 518060)

³⁾(广东工业大学计算机学院 广州 510006)

摘要 本文旨在全面综述个性化推荐系统的近期进展,并重点聚焦于图神经网络(GNN)在多行为用户建模中的应用。传统推荐系统依赖单一交互类型,难以全面刻画用户复杂的兴趣偏好。为应对这一挑战,本文系统梳理并归纳了现有基于GNN的多行为推荐方法,并从“统一编码模式”和“分解增强模式”两个角度对主要研究路线进行结构化分类与比较分析。通过结构化对比分析、图示展示与方法评估,深入解析各类方法的共性与差异。与此同时,本文还详细探讨了分层融合、统一图建模、对比学习和级联建模机制等关键技术路线。此外,本文在Tmall和IJCAI-Contest数据集上开展了多行为与单行为推荐方法的实证对比,系统评估了对比学习、分层融合、统一图建模和级联方法在多行为场景下的表现。本文的主要贡献在于构建了一个系统性的多行为推荐方法分类框架,并全面整合了当前研究热点,包括GNN与大语言模型的融合、跨领域行为关联、多模态数据融合以及动态图推荐等前沿方向,为多行为推荐系统的发展提供了系统性的理论综述与研究参考。

关键词 图神经网络;多行为推荐;数据稀疏性;统一编码模式;分解增强模式;冷启动问题

中图分类号 TP18 DOI号 10.11897/SP.J.1016.2026.00796

A Survey on Graph Neural Network-Driven Personalized Recommendation: Multi-Behavior Modeling, Technical Advances and Emerging Trends

CHENG Ying-Chao¹⁾ WU Gan-Sheng^{1),2)} HE Yu-Lin¹⁾ HUANG Zhe-Xue¹⁾
CHEN Bin-Feng³⁾

¹⁾(Guangdong Laboratory of Artificial Intelligence and Digital Economy (SZ), Shenzhen, Guangdong 518107)

²⁾(College of Computer Science and Software Engineering, Shenzhen University, Shenzhen, Guangdong 518060)

³⁾(School of Computer Science, Guangdong University of Technology, Guangzhou 510006)

Abstract This paper aims to provide a comprehensive review of the recent advances in personalized recommender systems, with a particular focus on the application of Graph Neural Networks (GNNs) in multi-behavior user modeling. Traditional recommender systems typically rely on a single type of interaction, such as purchase or rating, which makes it difficult to capture

收稿日期:2025-04-21;在线发布日期:2025-12-05。本课题得到国家重点研发计划(2025YFC3410000)、广东省基础与应用基础研究基金重点项目(No. 2023B1515120020)、广东省自然科学基金面上项目(2023A1515011667)、深圳市科技重大专项项目(KJZD20230923114809020)、人工智能与数字经济广东省实验室(深圳)开放课题(GML-KF-24-23)资助。成英超(通信作者),博士,教授级高工,中国计算机学会(CCF)高级会员,主要研究领域为人工智能与类脑计算、数字经济与数据空间、分布式计算与算力网络。E-mail: chengyingchao.dr@gmail.com。吴赣生,硕士研究生,主要研究领域为图神经网络、推荐系统。何玉林(通信作者),博士,研究员,中国计算机学会(CCF)会员,主要研究领域为新型大数据理论模型、大数据高性能/并行计算平台、面向大数据的机器学习算法、复杂型大数据应用系统等。E-mail: csylhe@126.com。黄哲学,博士,教授,中国计算机学会(CCF)会员,主要研究领域为大数据技术应用、数据挖掘。陈炳丰,博士,正高级工程师,中国计算机学会(CCF)高级会员,主要研究领域为机器学习、情感计算。

the multifaceted nature of users' interests and preferences in real-world scenarios. In contrast, multi-behavior recommendation incorporates multiple interaction types—such as viewing, clicking, adding to the cart, and purchasing—thereby enabling a richer and more fine-grained understanding of user intent. However, effectively modeling such diverse behaviors remains a challenging problem that requires sophisticated graph-based representations and learning mechanisms. To address these challenges, this survey systematically reviews and categorizes existing GNN-based approaches for multi-behavior recommendation. Specifically, we classify current research into two major methodological paradigms: the ‘unified encoding mode’ and the ‘decomposition-enhanced mode’. Based on this taxonomy, we conduct a structured comparison and analysis of representative methods from both paradigms, providing an in-depth examination of their theoretical motivations, architectural designs, and empirical performance. Furthermore, this paper provides a detailed exploration of several key technological routes that have been widely adopted in GNN-based multi-behavior recommendation, including hierarchical fusion mechanisms, unified graph modeling, contrastive learning strategies, and cascade modeling frameworks. Hierarchical fusion techniques aim to integrate behavior signals at different semantic levels, while unified graph modeling seeks to represent multiple types of behaviors within a single heterogeneous graph structure. Contrastive learning is leveraged to enhance representation robustness by distinguishing behavior-level differences, and cascade modeling enables the progressive refinement of user and item embeddings across behavioral hierarchies. In addition to theoretical analysis, we conduct extensive empirical evaluations using the Tmall and IJCAI-Contest benchmark datasets. By comparing multi-behavior recommendation models with single-behavior baselines, we systematically assess the effectiveness of different strategies—such as contrastive learning, hierarchical fusion, unified graph modeling, and cascade mechanisms—under realistic multi-behavior settings. The experimental results demonstrate that GNN-based multi-behavior models consistently outperform traditional single-behavior approaches, highlighting the importance of jointly modeling diverse user interactions. The major contribution of this work lies in establishing a systematic classification framework for multi-behavior recommendation methods and in comprehensively integrating current research frontiers in this area. Beyond summarizing existing work, this paper also discusses several emerging research directions, including the integration of GNNs with large language models (LLMs) for semantic-aware recommendation, cross-domain behavioral association modeling for user intent transfer, multimodal data fusion for unified representation learning, and dynamic graph-based recommendation for capturing temporal evolution of user preferences. By synthesizing these perspectives, this survey provides not only a structured overview of the state of the art but also a forward-looking reference for researchers and practitioners. It serves as a theoretical and methodological foundation for advancing the development of scalable, interpretable, and intelligent multi-behavior recommender systems in the era of graph learning and large-scale data analytics.

Keywords graph neural networks; multi-behavior recommendation; data sparsity; unified encoding model; decomposition-enhanced model; cold-start problem

1 引言

在信息技术迅速发展的背景下,个性化推荐系

统已成为缓解信息过载的重要工具,其核心目标是高效发现用户感兴趣的内容。传统协同过滤(Collaborative Filtering, CF)方法仅依赖单一行为数据(如购买记录),易受数据稀疏和冷启动问

题影响。相比之下,多行为推荐(Multi-Behavior Recommendation, MBR)通过融合浏览、收藏、加购、购买等多种行为,更全面地刻画用户兴趣,有效缓解数据稀疏与冷启动困境,显著提升推荐精度与用户体验^[1]。

根据技术演进路线,目前的MBR方法总体上可分为三类:传统机器学习方法、基于深度神经网络(Deep Neural Networks, DNN)的方法以及基于图神经网络(Graph Neural Networks, GNN)的方法^[2]。传统机器学习方法主要利用矩阵分解技术或通过辅助行为数据的采样来增强用户与物品的嵌入表示^[3-5]。尽管此类方法在推荐系统早期阶段表现良好,但在应对当下多样化和高复杂度的用户行为数据时,其建模能力已显不足。基于DNN的方法则充分发挥其强大的非线性建模能力,通常结合协同过滤和注意力机制,深入挖掘用户与物品之间的复杂关系^[6-7]。这类方法能够自动学习高维特征表示,捕捉用户行为数据中的潜在非线性模式,并通过注意力机制聚焦于关键行为信号。然而,其性能往往依赖大量高质量的训练数据,计算开销较大,且模型的泛化能力仍有待提升。

与上述方法相比,基于GNN的方法能够显式

建模用户与物品之间的协同关系,有效捕捉图结构数据中的复杂交互模式,在处理复杂图结构数据时表现出显著优势^[8]。例如,GNN可以建模高阶邻居节点之间的潜在语义关联,挖掘用户的潜在偏好,并提升表示学习能力。在MBR场景下,不同类型的用户行为被视作独立的子图,用户和物品构成图中的节点,各种交互行为则作为边连接这些节点。GNN通过图卷积等机制实现节点信息的传播与聚合,使节点嵌入能够有效融合邻域节点的信息,从而更精准地捕捉用户与物品之间的复杂交互关系^[9]。因此,近年来基于GNN的MBR方法逐渐成为研究热点,吸引了学术界和工业界的广泛关注。

近年来,GNN在多行为推荐领域取得了大量创新成果(如图1所示)。最早,MBGCN^[1]通过多行为图卷积传播机制建模行为强度与语义特征,而MGNN^[10]则进一步提出多重图结构,以同时学习行为间的共享与个性化表示,显著提升了模型的表达能力与推荐精度。随后,研究者开始融合时间、语义等多维辅助信息,并引入元学习以增强模型的自适应与泛化能力。例如,KHGT^[11]引入时间属性与物品关系以优化推荐性能,MB-GMN^[12]将多行为建模融入元学习框架以捕捉个性化偏好。

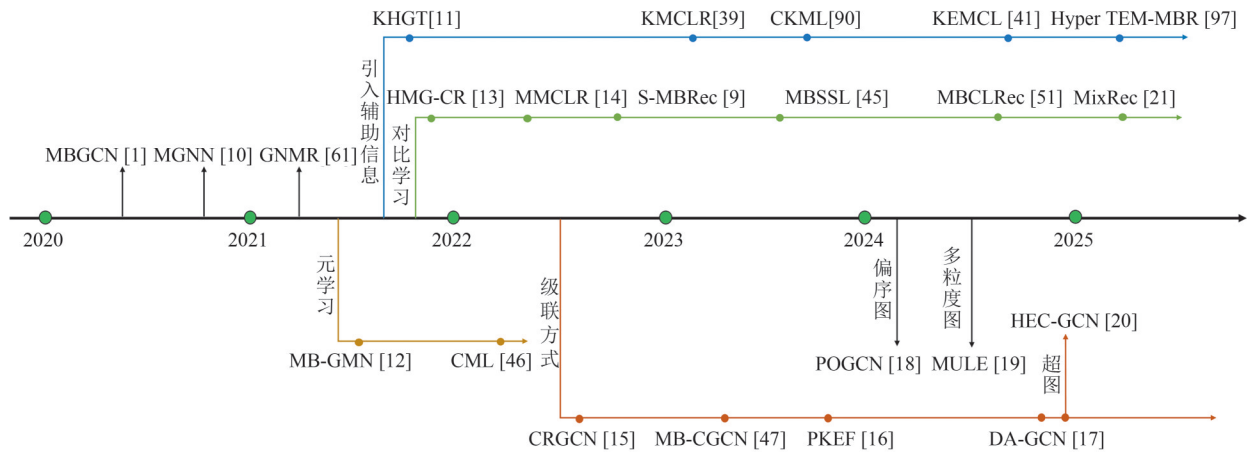


图1 基于GNN的多行为推荐方法发展历程

随着研究深入,MBR逐渐转向自监督学习方向。HMG-CR^[13]结合超元路径与图对比学习以捕捉跨行为依赖;S-MBRec^[9]通过目标与辅助行为的对比学习提取行为共性;MMCLR^[14]设计多层次对比任务以全面建模行为间的共性与差异。同时,级联建模策略亦受到关注,如CRGCN^[15]通过残差机制显式建模行为顺序依赖,PKEF^[16]采用并行知识

增强低频行为表示,而DA-GCN^[17]则以个性化有向无环行为图灵活建模多样化行为路径。

最新研究进一步拓展了多行为建模的多样性。POGCN^[18]采用偏序图结构以捕捉行为组合关系;MULE^[19]以多粒度图学习实现从统一行为到目标行为的逐层信息提取;HEC-GCN^[20]结合可学习超图与级联机制以建模高阶关系;MixRec^[21]通过参数

化异构超图编码用户关系感知意图,实现多样化交互表示的解耦与聚合。

针对多行为推荐的综述研究,Chen等人^[22]从背景、定义到挑战对多行为序列推荐进行了全面剖析,并从多维视角归纳了相关工作,为该领域研究者提供了系统性的参考框架,具有重要的启发意义。尽管该综述提及了基于GNN的方法,但其讨论的深度与广度仍有不足。Kim等人^[23]构建了一个“数据建模-表示编码-模型训练”的三阶段分类框架,逻辑清晰、层次分明,在方法归类方面具有较强的实用价值。该框架在表示编码阶段的分类主要基于并行编码与序列编码两种策略,但这种分类方式难以完整覆盖所有主流方法。因此,从“统一编码范式”与“分解增强范式”这两个更具本质性的视角出发,对多行为建模方法进行系统划分,是一种更为合理的方案。该分类框架不仅覆盖了更为广泛的编码机制,也更准确地揭示了当前多行为建模研究的核心思想与发展脉络。

尽管已有文献^[24-26]分别从多任务推荐、图神经网络推荐以及自监督推荐的角度进行了综述,但针对“基于GNN的多行为推荐方法”这一细分方向,尚缺乏系统性回顾。为了填补这一研究空白,本文从基于GNN的多行为推荐的研究现状出发,首先系统筛选了相关的代表性文献,进而从模型输入特征、多行为建模策略、推荐任务设置等多维度进行全面回顾与分析。本文以“统一编码模式”和“分解增强模式”两种基本架构为依据,对基于GNN的多行为推荐方法进行了系统归纳,并分析了两种模式的适用场景及优缺点。此外,本文还深入探讨了多行为推荐领域中亟待解决的关键挑战,包括行为共性与差异性建模、多任务学习中的负迁移问题、行为依赖关系建模与数据噪声处理等,并提出了未来值得关注的研究方向。最后,本文总结了目前常用的基准数据集与推荐系统评价指标,以期后续研究提供清晰的研究框架与实用的指导。

本文的主要贡献概括如下:

- 系统梳理了基于GNN的多行为推荐研究工作,并沿着“统一编码”与“分解增强”这两个核心策略的方向,对现有方法构建了清晰的分类体系;
- 深入分析了多行为推荐任务的关键技术挑战,并对现有方法的优缺点进行了客观的总结与对比;
- 从多行为推荐的实际应用需求出发,提出了若干具有启发性的未来研究方向,并探讨了当前面临的挑战及其潜在解决路径。

2 多行为推荐基础知识

2.1 推荐系统基础概念

推荐系统(recommendation system, RS)是一种通过分析用户历史行为与物品特征,预测用户潜在兴趣并实现个性化信息过滤的智能系统。随着互联网与数据规模的迅速增长,推荐系统已广泛应用于电商、社交、娱乐等领域,成为缓解信息过载、提升用户体验与平台收益的关键技术。

传统推荐方法主要包括三类^[27]:(1)基于内容的推荐(Content-based Recommendation)依据用户过去偏好的物品特征学习兴趣向量,并按相似度生成推荐,但依赖高质量特征且难发现新兴趣;(2)协同过滤推荐利用用户-物品交互及群体共同行为模式进行推荐,但易受数据稀疏与冷启动问题影响^[28];(3)混合推荐(Hybrid Recommendation)结合两者优势,综合内容与行为信息以提升推荐的稳定性与准确性。

此外,近年来随着深度学习技术的兴起,推荐系统方法也经历了快速的技术升级与创新,深度推荐(Deep Recommendation)成为新兴的主流方向^[29]。随后,图神经网络的引入进一步推动了推荐技术的发展,使模型能够在结构层面显式捕捉用户-物品交互关系与高阶邻居信息,从而显著提升推荐的表达能力与泛化性能,并受到学术界与工业界的广泛关注。

多行为推荐则是推荐系统的重要细分领域,旨在融合用户在平台上的多类型交互数据(如浏览、收藏、加购、购买等),以更深入地挖掘用户潜在兴趣并优化推荐效果。

2.2 多行为推荐问题定义

多行为推荐(MBR)通过综合用户的多种交互行为能够更全面地刻画用户兴趣,从而显著提升推荐性能^[1]。

具体而言,给定用户集合 $U = \{u_1, \dots, u_m, \dots, u_M\}$ 和物品集合 $V = \{v_1, \dots, v_n, \dots, v_N\}$,其中 M 和 N 分别表示用户和物品的数量。用户与物品之间的多种交互行为可以用一个三维张量 $X \in R^{M \times N \times K}$ 表示,其中 K 表示不同的行为类型。当用户 u_m 对物品 v_n 执行了第 k 种行为时,张量元素 $x_{m,n}^k = 1$,否则为0。

在实际应用中,一般将某种特定的行为类型(如购买)定义为目标行为,而其他行为类型(如浏览、收藏、加购物车等)则作为辅助行为,以提升对目标行

为的预测准确性。因此,MBR问题可被正式定义为:

•输入:用户集合 U 和物品集合 V 在 K 种行为类型下的多行为交互张量 $X \in R^{M \times N \times K}$;

•输出:预测函数,用于估计用户 u_m 在目标行为类型下与物品 v_j 进行交互的概率。

2.3 图神经网络基础

传统神经网络模型(如卷积神经网络CNN^[30]和循环神经网络RNN^[31])在处理图像或序列等规则结构数据时表现优异,但难以适应图这种非欧几里得结构数据。为此,图神经网络(Graph Neural Network, GNN)应运而生,专为建模图结构数据而设计^[32]。

GNN能够同时捕捉图的拓扑结构与节点特征,近年来被广泛应用于推荐系统、节点分类和链接预测等任务中^[33]。其核心思想是通过“消息传递”机制^[34],在每一层聚合邻居节点信息并更新节点表示,使节点能够逐层整合多阶邻居特征,从而实现局部结构建模与全局语义捕获。

具体而言,第1层中节点的嵌入更新过程通常包括以下两个关键步骤:

$$h_i^{(l)} = \text{Aggregate}^{(l)}(\{e_j^{(l-1)} | \forall j \in \mathcal{N}_i\}) \quad (1)$$

$$e_i^{(l)} = \text{Update}^{(l)}(h_i^{(l)}, e_i^{(l-1)}) \quad (2)$$

其中, \mathcal{N}_i 表示节点 i 的邻居节点集合, $h_i^{(l)}$ 为节点 i 在第 l 层邻居节点聚合后的中间嵌入表示, $e_i^{(l)}$ 为节点 i 在第 l 层更新后的嵌入表示。“聚合函数” $\text{Aggregate}^{(l)}$ 可采用GCN式的归一化加权求和或GAT式的注意力加权等实现,而“更新函数” $\text{Update}^{(l)}$ 则可通过MLP/残差或门控等机制将邻域表征与自身状态融合,从而在局部与高阶结构范围内有效捕获图信息并获得高质量节点表示。

3 模型输入与数据类型

为增强模型对用户偏好和物品特性的理解,多行为推荐方法除了利用核心的用户-物品交互数据外,通常还融合多样化的辅助信息。这些信息包括带有时间属性的多行为交互、行为序列特征、用户社交关系以及知识图谱等。表1对不同方法的输入信息进行了总结。

表1 不同方法输入分类汇总

交互属性	额外信息	方法
	社交关系	MSSR ^[35] , MB-Soc ^[36] , CMBSR ^[37] , SHGCN ^[38]
	知识图谱	CMBSR ^[37] , KMCLR ^[39] , KDMBR ^[40] , KEMCL ^[41] , KEMB-Rec ^[42] , MBGL ^[43] , MBKGIN ^[44]
静态信息		MBGCN ^[1] , BCIPM ^[2] , S-MBREC ^[9] , MGNN ^[10] , MB-GMN ^[12] , HMG-CR ^[13] , CRGCN ^[15] , PKER ^[16] , DA-GCN ^[17] , POGCN ^[18] , MULE ^[19] , MixRec ^[21] , MBSSL ^[45] , CML ^[46] , MB-CGCN ^[47] , GHCF ^[48] , MBHCR ^[49] , MK-GCN ^[50] , MBCLREC ^[51] , CGCL ^[52] , CIGP ^[53] , HPMR ^[54] , MB-GR ^[55] , FPD ^[56] , IICL ^[57] , SaGCN ^[58] , MB-HGCN ^[59] , MB-EBIH ^[60] , GNMR ^[61] , MB-SVD ^[62] , AMR ^[63] , VCGAE ^[64] , MB-GCL ^[65] , MORO ^[66] , DCMBR ^[67] , MB-AGCN ^[68] , DGAMR ^[69] , MixMBR ^[70] , DCL ^[71] , CGCCN ^[72] , CEMBR ^[73] , Disen-CGCN ^[74] , HEM-GNN ^[75] , MB-DCGBN ^[76] , ECR-GCN ^[77] , DLACN ^[78] , IMGCF ^[79] , V-GMR ^[80] , SSPGNN ^[81] , BRGC-Net ^[82] , DCMGNN ^[83] , MBRC ^[84] , DVCL ^[85] , TSL-MBR ^[86] , MB-LGCA ^[87] , MPC ^[88] , UIPL ^[89]
	无	
时间敏感信息	知识图谱	KHGT ^[11] , CKML ^[90] , TKMBR ^[91] , TMBCL ^[92] , TKMB ^[93]
	交互序列	MMCLR ^[14] , MFBR ^[94] , MBSRHGNN ^[95] , BDMR ^[96] , HyperTEM-MBR ^[97] , MB-TGAT ^[98]
	无	TMCL ^[99] , RCL ^[100] , GTCF4MB ^[101]

静态信息:当前,多数方法的输入信息仍以静态(即无时间属性)的多行为交互为主。在此基础上,部分研究通过融合外部信息进行了增强。一方面,为建模社交影响, MSSR^[35]与 MB-Soc^[36]等工作将社交网络信息融入用户表示中。另一方面,为利用外部知识,部分方法引入了知识图谱(Knowledge Graph)^[102]。其中, KMCLR^[39]专注于增强物品的层级信息; KDMBR^[40]则不仅丰富了物品端的属性,还通过图重构和对比学习强化了用户端的语义;

KEMCL^[41]通过并行采用两种嵌入策略(翻译距离与语义匹配)来从不同视角捕捉项目语义;而 KEMB-Rec^[42]设计了基于元路径的模块,旨在为不同行为精准挖掘相关的语义知识。

时间敏感信息:在推荐系统中,用户与物品之间的交互往往具有显著的时间敏感性,即用户的兴趣与偏好会随时间持续演化。因此,如何有效捕捉和建模时间信息,是刻画用户兴趣动态变化规律的关键。现有研究主要从时间编码建模、时间序列建模、

动态图建模以及时间知识图建模四个维度展开,具体如下:

(1) 时间编码建模。该类方法通过时间编码模块将交互时间映射为可学习向量,以捕捉时间动态与周期性特征。典型方法如KHGT^[11]、CKML^[90]、TMBCl^[92]、TMCL^[99]、GTcf4MB^[101]等,均利用正弦与余弦函数对时间戳进行周期性编码,从而在向量空间中刻画时间模式与偏好变化。TMCL^[99]进一步引入时间注意力机制以自适应区分不同时段偏好;除时间编码外,KHGT^[11]与CKML^[90]融合知识语义增强多行为表达;TMBCl^[92]结合社交与知识视角实现多视图对比优化;TKMB^[93]通过局部—全局双视角融合时间与知识信息,局部视图利用自适应时间编码建模个性化偏好,全局视图结合知识图谱与注意力机制以优化交互表示。

(2) 时间序列建模。时间序列建模聚焦多行为时间序列,通过序列编码器捕捉用户偏好的时序演化规律。代表性方法包括MMCLR^[14]、MFBR^[94]和BDMR^[96],它们协同利用序列编码器建模时间依赖,并结合图编码器挖掘结构关系;HyperTEMMBR^[97]结合GRU与GCN实现个性化时间偏好学习与结构协同建模;MB-TGAT^[98]则显式引入时间序列建模用户兴趣演化,利用位置编码与单向自注意力机制保留时间顺序并模拟时间推进,同时结合行为感知注意力为不同时段交互分配动态权重,从而自适应地捕捉短期与长期偏好变化。

(3) 动态图建模。动态图建模方法通过时间片划分与跨时间信息传递,捕捉用户偏好的持续演化。代表性模型RCL^[100]采用“时间片滚动”与“跨时间记忆”机制:将交互按时间顺序划分为多个时间片,并在每个时间片中构建多行为交互图,通过GNN进行消息传递以学习阶段性特征与短期偏好;随后在边上注入基于Transformer的时间位置编码,并在节点初始化中引入前一时间片的嵌入以实现历史信息继承;最后,利用动态跨关系记忆网络融合多时间片表示,使用户与物品嵌入随时间持续演化,从而实现高保真的兴趣动态建模。

(4) 时间知识图建模。时间知识图建模方法通过在知识图谱中引入时间戳信息,实现语义关系的时序扩展与动态语义增强。代表性模型TKMBR^[91]将传统三元组扩展为带时间标签的四元组形式,构建时间知识图以捕捉不同行为在时间维度上的语义关联。该模型在结构上融合了时间感知的知识表示学习与多行为建模框架,通过时间嵌入与关系嵌入

的联合更新机制,有效刻画了行为间的时序依赖与语义迁移。此外,模型通过统计历史与非历史交互频率来区分长期与短期偏好变化,并结合时间对比学习强化同一时段的偏好一致性、区分不同时段兴趣差异,从而实现用户动态兴趣的时序感知与语义增强表达。

4 基于GNN的多行为推荐方法

4.1 方法分类概述

根据多行为推荐方法在行为信息建模策略上的不同,现有的基于图神经网络的多行为推荐方法通常可分为两种主要模式:统一编码模式和分解增强模式。图2展示了基于GNN的多行为推荐方法的分类汇总。

统一编码模式通过对用户多种行为信息的统一处理与整合,生成全局一致的用户表示,以全面捕获用户多维度的兴趣和偏好^[103]。具体而言,统一编码模式又可进一步细分为两类实现方式:分层融合与统一图建模。(1) 分层融合:将不同类型的行为分别构建为独立的子图,对每种行为子图独立地学习嵌入表示,随后通过特定的融合策略(例如注意力机制或加权求和)合并这些嵌入,形成统一的用户或物品表示。这种方式在行为间保留了一定的独立性,能够有效减轻行为间的相互干扰。(2) 统一图建模:将多种行为统一整合至单一图结构中,每一种行为以不同类型的边或权重进行标识,并在统一的多行为图上进行图卷积操作,直接生成统一的用户或物品表示。这种方式的优势在于能更自然地捕获多行为之间的相互依赖关系,但对模型设计的精细化和图结构定义的合理性提出了更高要求。

分解增强模式则侧重于将多行为信息明确划分为不同的子任务或子图结构,分别进行特征嵌入学习,再通过对比、级联等方式,将辅助行为信息整合到目标行为的预测中。这种模式的核心思想是通过行为特征的解耦,分别学习每种行为独特的模式与特征,从而避免统一嵌入过程中可能产生的不同行为特征冲突问题,更精细化地捕获各行为的差异性与细粒度特征,进而为目标行为提供更加丰富的信息。具体的整合策略包括但不限于:(1) 对比学习:通过构造正负样本对,明确建模不同类型行为之间的一致性与差异性。(2) 级联机制:通过行为间的明确传递机制,将辅助行为的预测结果或表示级联到目标行为预测过程中,以增强目标任务的

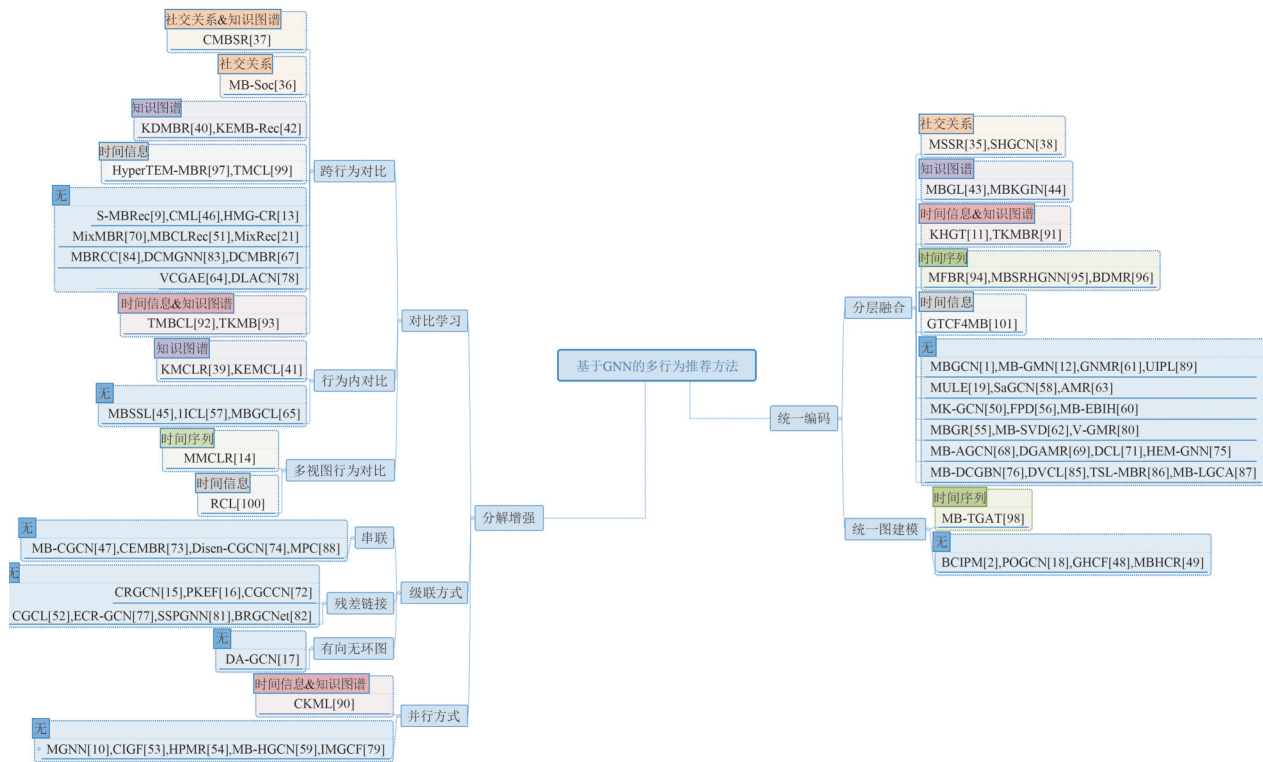


图2 基于GNN的多行为推荐方法分类

表现。(3)并行建模机制:在各行为图上独立进行表示学习,并通过信息共享机制与表示解耦策略两个维度协同建模,更精确地刻画行为间的关联与差异。

上述两种模式各有优势和不足,统一编码模式

在实现的复杂性上通常较低,但易忽略行为间的细粒度差异;而分解增强模式能更好地捕捉行为特征的差异性,但模型设计复杂度和计算成本相对更高。表2对这两类方法的优缺点进行了系统性总结与比较。

表2 多行为建模架构对比

模式	方法类型	优点	缺点
统一编码	分层融合	避免了不同行为之间的相互干扰;引入注意力或加权策略以控制行为贡献	行为子图交互有限难以建模高阶依赖;依赖融合策略设计
	统一图建模	统一多种行为于单一图结构以显式捕获交互关联;全局卷积传播信息以建模高阶关系	统一建模易掩盖行为细粒度差异;统一图结构复杂度高
分解增强	对比学习	有效克服数据中的噪声和稀疏性问题;能够挖掘不同行为之间的共性	对正负样本选择依赖性强;训练难度较高
	级联方式	层次化建模行为间的依赖关系;捕捉用户行为的逐步转化逻辑	行为依赖关系设计复杂难以泛化到多行为场景
	并行建模机制	有助于挖掘各行为特有的语义特征;有效缓解行为数据分布不均的问题	各行为模型间缺乏统一协调机制;信息整合需要额外设计

4.2 多行为建模架构

本节将多行为推荐方法归纳为两大类:统一编码模式与分解增强模式(如表2所示)。前者强调在统一表示空间中整合多行为信息,通过共享嵌入或联合图结构系统地刻画用户的多样化兴趣,其典型策略包括分层融合与统一图建模,分别侧重于细粒度行为特征的层次化整合与多行为关系的全局结构建模;后者则聚焦于各类行为特征的独立建模,通

过对比学习、级联建模与并行协同等机制挖掘行为间的差异性、共性与依赖性,从而实现更精细的偏好表达与鲁棒的特征提取。本节将在此分类框架下系统分析代表性方法的核心思想与技术特征,比较其适用场景与发展脉络,揭示不同建模范式间的内在联系与演化趋势。

4.2.1 统一编码模式

统一编码模式旨在通过学习机制将用户的多种

行为统一映射到同一表示空间,以捕捉兴趣与偏好的全局特征。该模式假设不同行为间存在较强关联,通过统一的信息融合策略充分挖掘行为协同效应,从而全面刻画用户的多维兴趣,提升推荐的准确性与泛化能力。该方法常用于电子商务、社交媒体等多行为交互密集场景,主要包括分层融合与统一图建模两种实现方式。

(1) 分层融合

在分层融合中,这种框架可以概括为:首先通过

对用户的多种行为(如浏览、加购物车、购买等)分别建模,在各行为中分别利用图卷积网络提取用户和物品的嵌入表示,然后通过融合层整合各行为的特征,生成最终的用户和物品嵌入。整个分层融合的多行为建模过程如图3所示,行为感知传播层能够区分并调整不同类型的行为特征,使得节点在传播过程中自适应地捕捉行为间的差异,确保多行为信息的有效表达^[61];而行为感知融合则负责将各类行为特征有机整合,实现行为信息间的协同和互补^[62]。

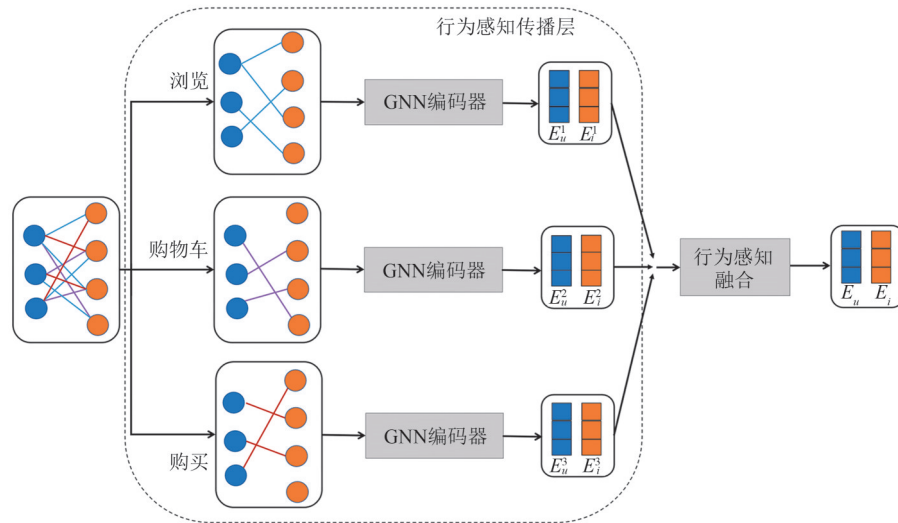


图3 分层融合的多行为建模示意图

① 行为感知传播层。本小节深入探讨行为感知传播层的核心建模范式,并回顾其从简单图卷积到图注意力等机制的演进。在多行为推荐中,用户在浏览、收藏、购买等不同行为下与物品的交互反映了差异化偏好。若将所有行为直接混合,易掩盖行为特定特征。为区分行为影响强度,需在各行子图上分别进行GNN编码,学习对应的用户与物品嵌入表示。GNN编码器总结如表3所示。

受LightGCN^[106]有效性的启发,已有多项研究^[2,35,56,60]采用简化的图卷积操作来学习不同行为下的嵌入表示。LightGCN的节点嵌入传播层实现如下:

$$q_u^{l+1} = \sum_{v \in N_u} \frac{q_v^l}{\sqrt{|N_u| |N_v|}} \quad (3)$$

$$q_v^{l+1} = \sum_{u \in N_v} \frac{q_u^l}{\sqrt{|N_u| |N_v|}} \quad (4)$$

其中, q_u^{l+1} 和 q_v^{l+1} 分别表示第 l 图卷积层中用户和物品的嵌入, N_u 表示与用户 u 交互过的物品集合, N_v

表示与物品 v 交互过的用户集合。在这里,这种操作应用于各行为中,在各行为交互中更新每层中节点行为感知嵌入。在此基础上,DCL^[71]设计了两个不对称视图编码器,在交互视图和折叠视图中分别通过LightGCN图编码器学习嵌入。其中,交互视图编码器作为推荐的主要编码器,而折叠视图编码器提供额外的信息来增强前者,这两个视图可以分别捕获局部和高阶结构,并通过互补机制使学习到的嵌入相互关联。为了进一步增强模型的表达能力,MK-GCN^[50]、MBGR^[55]和MB-SVD^[55]等方法在LightGCN的图卷积网络中额外加入了残差卷积。这种残差连接有助于保留原始节点信息,避免信息丢失,更好地建模高阶行为关系,并有效解决梯度消失和过平衡等问题。

除了简化的图卷积外,部分研究还引入图注意力机制(Graph Attention Network, GAT)来学习不同行为下的表示。MULE^[19]通过一种多粒度图学习策略来区分用户的重叠行为(如浏览并购买)与非重叠行为(如仅浏览)。该模型首先构建一个

表3 GNN编码器总结

GNN 编码器	特点	方法
LightGCN	在传统图卷积网络的基础上去除非线性变换与权重矩阵,仅保留邻居聚合与层间加权机制,从而实现结构简洁、训练高效的特征传播。	MB-EBIH ^[60] , MSSR ^[35] , FPD ^[56] , MB-GMN ^[12] , MK-GCN ^[50] , MB-GR ^[55] , MB-SVD ^[62] , DCL ^[71] , MB-AGCN ^[68] , TMBCL ^[92] , MULE ^[19] , DVCL ^[85] , TSL-MBR ^[86] , UIPL ^[89] , HGIB ^[104]
GAT	通过自注意力机制自适应地分配邻居节点权重,突出关键交互关系并抑制噪声影响,从而提升模型在多行为关系建模中的表达能力与鲁棒性。	KHGT ^[11] , GTCF4MB ^[101] , DGAMR ^[69] , MB-DCGBN ^[76] , MB-GL ^[43] , MULE ^[19]
HetGNN	针对异构图中多类型节点与边的特征差异,引入异质信息聚合机制,从行为空间中挖掘潜在语义关联,为每个行为的嵌入学习提供更细粒度且语义区分度更高的表征能力。	GNMR ^[61] , MFBR ^[94] , MBKGIN ^[44]
VGAE	变分图自编码器通过概率建模捕捉用户与物品的潜在结构依赖,在潜在空间学习分布式表示并结合正则化约束,以提升表示的鲁棒性与泛化性,支持多行为推荐中的不确定性建模与偏好推断。	V-GMR ^[80] , CVID ^[105]

目标相关行为图以分离两类交互,进而对重叠行为采用LightGCN编码器捕捉显式兴趣,同时利用GAT赋予非重叠行为中潜在相关的交互更高权重,从而有效捕获用户的潜在偏好。KHGT^[11]则采用多头注意力机制,通过加权求和聚合邻居节点的消息,提取邻居节点对中心节点行为特征的影响,动态调整每个邻居节点的贡献,以强化关键交互表示。在GAT的基础上,MBGL^[43]通过一种基于关系的ResGAT来更新节点嵌入。通过引入残差连接,使每一层的输出不仅依赖于当前层的变换结果,还直接添加前一层的原始输入,从而确保梯度可以从深层有效传播至浅层,提高深层网络的可训练性。

此外,为了更好地刻画多种行为之间的异质性关系,部分方法采用了异构图神经网络HetGNN^[107]来建模不同的行为。基于此,GNMR^[61]提出了一种类型特定的行为嵌入层,用于捕捉每种行为类型的特征,并深入理解和表示各类用户-物品交互行为所蕴含的独特语义和模式。其实现方式如下所示:

$$H_{i \rightarrow}^{k,(l)} = \eta\left(\left\{H_j^{k,(l)} : x_{i,j}^k = 1\right\}\right) \quad (5)$$

$$H_{j \rightarrow}^{k,(l)} = \eta\left(\left\{H_i^{k,(l)} : x_{i,j}^k = 1\right\}\right) \quad (6)$$

其中, $H_{i \rightarrow}^{k,(l)}$ 和 $H_{j \rightarrow}^{k,(l)}$ 分别表示传递给用户 u_i 和物品 v_j 的嵌入。函数 η 表示嵌入层,用于保留每种用户行为类型(即 k)的独特特性。在消息传递架构中,函数 η 被设计为根据类型特定的行为上下文信号(如行为频率)为每种行为类型 k 获取表示。形式化地表示 η 如下:

$$\alpha_{(c,k)} = \delta\left(\sum_{j \in N(i,k)} W_1 \cdot H_j^{k,(l)} + b_1\right)(c) \quad (7)$$

$$\eta\left(\left\{H_j^{k,(l)}\right\}\right) = \sum_{c=1}^C \alpha_{c,k} W_{(2,c)} \cdot \sum_{j \in N(i,k)} H_j^{k,(l)} \quad (8)$$

其中, $\alpha_{(c,k)}$ 表示从投影到第 c 个潜在维度中学到的 k 类用户行为的权重。 $N(i,k)$ 表示在交互图 G 中与用户 u_i 连接且行为类型为 k 的邻居物品节点。 W_1 和 b_1 为学习参数。 $\delta(\cdot)$ 为ReLU激活函数。在嵌入过程中,利用权重 $\alpha_{(c,k)}$ 和变换参数 $W_{(2,c)}$ 聚合来自不同潜在维度的嵌入。针对目标物品节点 v_j ,其在行为类型为 k 的相邻用户节点 $N(j,k)$ 中的信息传递过程与上述方式类似。通过这种方式,模型能够为每种行为类型学习到独特且富有上下文信息的表示。

V-GMR^[80]在多行为推荐中引入变分图自编码器^[108]。模型在行为感知传播层中利用GCN捕捉用户在不同行为下的高阶偏好,并通过注意力机制动态调整邻居节点的贡献。随后采用多变分自编码器(Variational Autoencoder, VAE)^[109]结构,对目标行为和辅助行为分别编码,其中目标VAE包含编码器 E^T 和解码 D^T ,辅助VAE仅含编码器 E^k ,各编码器通过均值与方差建模行为的潜在变量。

② 行为感知融合层。行为感知融合层用于建模用户在浏览、收藏、购买等不同行为下的多样化特征。通过引入行为间的相关性与互补性机制,该层实现多行为信息的协同融合。由于不同行为类型之间存在复杂的关系,在融合行为嵌入之前,已有多项研究采用了多头自注意力机制(Multi-Head Self-

Attention, MH-Att)^[110]以增强行为间的关系建模能力。例如, KHGT^[11], MB-GMN^[12], MK-GCN^[50], MBGR^[55], SaGCN^[58], GNMR^[61]和 MFBR^[94]等方法均采用该机制来加强行为间的关系建模。该机制最早由 MATN^[111]引入,用于联合建模特定行为与其相关行为的依赖关系,从而保持行为关联并促进表示协同。MH-Att的核心在于通过多头自注意力机制计算行为表示间的注意力权重,从而捕捉行为间的隐式关系。其计算过程如下所示:

$$\tilde{q}_i^k = //_{h \rightarrow H} \left(\sum_{k'=1}^K \lambda_{k,k'}^{i,h} \cdot \mathbf{V}^h \cdot \mathbf{q}_i^{k'} \right) \quad (9)$$

$$\lambda_{k,k'}^{i,h} = \frac{\exp \overline{\lambda_{k,k'}^{i,h}}}{\sum_{k''=1}^K \exp \overline{\lambda_{k,k''}^{i,h}}} \quad (10)$$

$$\overline{\lambda_{k,k'}^{i,h}} = \frac{(\mathbf{Q}^h \cdot \mathbf{q}_i^k)^T (\mathbf{K}^h \cdot \mathbf{q}_i^{k'})}{\sqrt{\frac{d}{H}}} \quad (11)$$

其中,第 \mathbf{Q}^h 、 \mathbf{K}^h 、 \mathbf{V}^h 分别为学习子空间中的可学习投影矩阵, \mathbf{q}_i^k 表示经过图编码器后所学习到的第 k 个特定行为类型节点 i (用户或物品)的嵌入表示, $//$ 表示拼接操作, K 表示所有行为类型的数目。

在多行为信息融合成统一性表示的过程中,不同的方法采用了不同的融合策略。部分方法(如 MB-GMN^[12]、MK-GCN^[50]和 MBGR^[55])通过平均或池化操作对所有行为嵌入进行统一融合,从而得到全局表示。KHGT^[11]进一步引入物品侧信息,将其一并整合进融合过程。FPD^[56]则将多个行为偏好嵌入连接后输入多层感知机(Multilayer Perceptron, MLP)^[112],以建模行为之间的偏好差异。

加权融合是常见的融合策略,其基本思想是根据不同行为对节点的贡献度分配融合权重。加权融合方式表示如下:

$$\mathbf{q}_i = \sum_{k=1}^K \alpha_{i,k} \cdot \mathbf{q}_{i,k} \quad (12)$$

其中, $\mathbf{q}_{i,k}$ 为节点 i 在行为 k 下学习到的表示, $\alpha_{i,k}$ 表示对于节点 i 来说而言行为 k 的重要性,如何为每个节点学习到最优的行为权重 $\alpha_{i,k}$ 是加权融合方式的重点。

GNMR^[61]和 MFBR^[94]均通过神经网络自动学习各类行为在推荐任务中的权重,以建模其相对重要性。MBGCN^[1]则结合行为重要性与用户行为频率进行建模,具体来说,融合权重由全局可学习的行为重要性参数与用户的行为次数共同决定,确保权重满足归一性。类似地, MSSR^[35]设计了一个可学

习的融合机制,同时考虑每种行为的内在影响力和行为数量,并在训练过程中自动优化相关参数。AMR^[63]采用行为级注意力机制,以捕捉辅助行为对目标行为的贡献程度,并动态调整各行为的融合比重。DeMBR^[113]通过“去噪—对齐—融合”三阶段优化多行为表示:先利用记忆剪枝模块去除辅助行为噪声,再以强表达行为(如购买)为参照,通过语义引导模块对齐弱行为(如点击、加购)表示,最后以可学习权重融合去噪后的多行为嵌入,生成统一表示并提升推荐精度。

此外,为减少模型对多个超参数的依赖,V-GMR^[80]通过引入VAE^[109]来建模用户多行为信息,从而避免过多参数导致模型适用性差的问题。该方法通过使用VAE对用户行为进行编码,有效捕获多行为信息的特征表示并学习行为潜在表示。随后,通过设计偏好融合增强器来捕获多种行为之间的关联信息,该模块将目标行为与辅助行为的数据结合,通过混合交互信息生成更准确的潜在表示。

CVID^[105]结合因果推断与变分推断,以系统化方式分离多行为数据中的真实偏好与混杂效应。模型为各行为构建子图并利用变分图自编码器学习潜在表示;通过因果推断识别混杂因子,并在扩散去噪中执行因果干预以消除虚假相关;最后,模型对多行为的去混杂表示进行注意力加权融合,并通过轻量级图卷积网络完成高阶特征聚合,生成更纯净、可解释的用户与物品嵌入。

UIPL^[89]将多种用户行为划分为不同“环境”,利用环境分布差异并引入不变风险最小化(Invariant Risk Minimization, IRM)原则,学习跨环境稳定的用户内在偏好。模型通过变分自编码器在各环境下生成潜在不变表示,借助IRM损失保持跨环境预测一致,结合正交与对比学习分离行为特定偏好并强化不变特征,从而提取反映真实兴趣的稳定表示,减少辅助行为噪声干扰。

HGIB^[104]将信息瓶颈原理引入多行为推荐的分层结构,构建自上而下的信息筛选机制,以“保留有用信息、压缩无关信息”为核心思想。模型首先融合多行为图并通过图精炼编码器提取全局特征、去除显性噪声;随后在行为子图上进一步编码,挖掘行为间差异与互补;进一步地,将辅助行为划分为与目标行为相关的交集部分和无关的差集部分,实现信息保留与噪声压缩;最后,模型采用两级目标注意力机制融合统一表示、行为特定表示与成分表示,生成更聚焦目标语义的用户与物品嵌入,并结合多重损失

协同优化,实现多行为信息的逐层净化与目标语义强化。

ITGCN^[114]提出分层多兴趣建模框架,利用多层GCN在不同行为子图上逐层聚合邻居信息,捕捉用户由粗到细的兴趣结构;并借助胶囊网络将单一嵌入解耦为多个独立兴趣胶囊,以刻画多语义偏好。结合兴趣迁移模块,根据与目标行为的相似度筛选并迁移辅助行为中的有效兴趣,实现噪声过滤与语义对齐;最终通过注意力融合机制自适应地分配行为权重,生成更纯净且符合目标语义的用户表示。

(2)统一图建模

统一图建模方式通过构建一个融合多种行为的统一图结构,将不同类型的用户行为整合在同一张图中。然后在该统一多行为图上应用图卷积操作,从而直接学习得到融合所有行为信息的用户和物品嵌入表示,如图4所示。

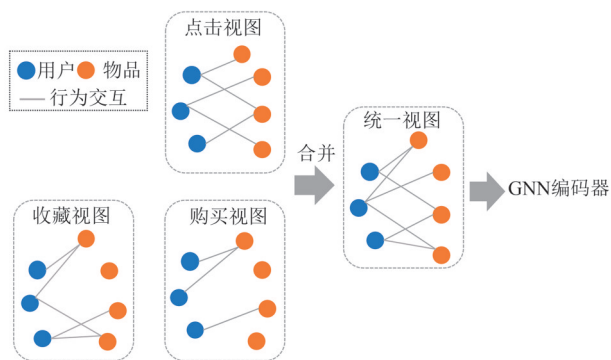


图4 统一图建模的多行为建模示意图

POGCN^[118]将多个单独的行为图转换为一个偏序顺序图。具体转换过程为:首先定义行为的偏序和行为组合的偏序,一旦定义了顺序,就可以将单独的行为图转换为行为组合图,之后再转换为偏顺序推荐图,采用这种方式来捕捉行为间复杂的关系。

BMGCN^[115]提出了一种基于行为合并机制的统一建图方式。模型首先依据行为的语义重要性定义偏序关系及权重函数,用以衡量不同行为的相对强度;随后计算各行为组合的加权秩值并确定合并顺序,在语义层面形成层级结构;接着通过秩变换将秩值映射为连续权重,赋予用户—物品边以不同强度;最终融合所有行为形成加权统一图,从而在结构层面刻画多行为间的关联与影响,为统一表示学习奠定基础。

在统一图对多行为建模的基础上,GHCF^[48]引

入关系—实体组合机制,使得图卷积网络既能学习节点嵌入,又能学习关系嵌入。在完成统一性建模后,GHCF通过引入行为特定的关系向量来建模用户对物品的多种交互行为,以区分不同行为类型,保证模型在学习用户偏好时能够捕捉到各类行为的差异性。

为了保留用户—物品交互的完整语义信息,MBHCR^[49]创新性地构建了基于多行为交互的统一异构图。该方法将用户和物品作为节点,不同类型的行为(如浏览、收藏、购买等)作为连接用户和物品的边,并为每种行为类型分配不同的边标记。即便用户对同一物品存在多种行为,这些行为也会分别通过带有标记的边连接至物品节点,从而在统一图结构中同时实现行为信息的融合与差异性的保留。

BCIPM^[2]在统一交互图上采用LightGCN^[106]对用户与物品嵌入进行预训练,以捕获全局多行为协同信息并获得基础嵌入。随后,这些嵌入被输入至行为上下文偏好网络(Behavioral Interactive Preference Network, BIPN),该网络通过预过滤层、物品感知层与后过滤层逐步提取特定行为场景下的用户偏好。考虑到BIPN所学表示可能不足以全面反映用户兴趣,BCIPM在目标行为图上再次应用LightGCN,以预训练嵌入为初始化,并融合高阶邻居信息对嵌入进行更新。最终,融合BIPN学得表示与目标行为特定表示,使模型同时兼顾全局协同性与目标行为特异性,从而显著提升个性化表达能力。

MB-TGAT^[98]基于图神经网络设计了分阶段消息传递机制以学习用户的静态偏好。模型在统一多行为图上通过多行为注意力区分各类行为对用户—物品关系的影响,借鉴TransE思想计算用户—行为—物品三元组的合理性得分,并利用自注意力捕捉行为间依赖以分配自适应权重。随后,模型以行为加权注意力进行局部聚合,并基于时间顺序构建用户上下文图,通过LightGCN式传播捕获高阶关系,从而在统一图中融合局部与全局信息,实现静态偏好建模。

4.2.2 分解增强模式

分解增强模式的基本思想是对用户的不同类型行为分别独立建模,以充分捕捉各类行为背后的特定信息与细微差异,随后再通过级联、对比等手段进行有效整合,从而强化目标行为的推荐性能。这种模式尤其适用于用户行为类型差异较大、行为数据异质性强的场景,例如在电子商务平台或多场景推

荐系统,用户的浏览行为与购买行为往往存在显著差别。通过对各类行为特征的精细建模,分解增强模式能够有效提升推荐系统对行为特征细微差异的辨识能力,进一步提升推荐的精准性与个性化水平。具体而言,该模式包括对比学习、级联、并行建模三种方式:

(1)对比学习

本小节比较分析了以对比学习为代表的自监督范式下的不同技术路径,并阐释其如何为模型注入更强的表示鲁棒性。在多行为推荐中,通过对比学习,系统能够更有效地整合来自多种行为

的数据,从而提升对用户兴趣的准确建模。对比学习通过设计正负样本对,利用用户在不同情境下的多种行为(如浏览、点击、购买等)之间的关系,帮助模型更好地学习和区分不同行为模式。大多数基于对比学习的多行为推荐的方法框架可以分为行为感知传播层与多行为对比学习模块这两个部分:前者在各行为中分别利用GNN编码器提取用户和物品的嵌入表示,后者则将学习到的表示用于对比学习任务,整个过程如图5所示。以下重点总结多行为推荐中的对比学习模块,相关方法汇总于表4。




图5 对比学习的多行为建模示意图

① 跨行为对比。跨行为对比旨在对不同行为类型下的表示进行对比学习,以提升模型对行为共性特征的建模能力并提升去噪效果。

其中,星型对比机制指将目标行为与每一种辅助行为所构建的关联视图之间的表示进行配对对比^[9](如图6所示)。该方法不仅能够捕捉行为之间的共享表示,还能缓解监督信号稀疏问题,并减少辅助行为间的冗余,从而提取对推荐最关键的行为信息。多项研究采用了该机制来建模行为间的共性,例如S-MBRec^[9]、MBCLRec^[51]、MixMBR^[70]、HyperTEM-MBR^[97]、TMCL^[99]以及SA-MBGCL^[116]等。

在此基础上,CML^[46]引入元知识编码器以建模个性化的多行为偏好特征,并通过元权重网络为不同对比实例分配自适应权重,从而更有效地学习行为间的依赖关系。MBRCC^[84]引入了对比聚类机制以挖掘用户和物品嵌入中的潜在共性;MixRec^[21]扩展至图级对比学习,通过构建异构超图视图并在图结构层面执行增强与对比,更好地整合多关系上下文信息。ADCL-MBRec^[117]则提出邻居原型对比学习,以缓解目标行为稀疏和视角单一问题;模型以锚点用户为中心,在目标行为下选取兴趣相似的邻居,

并在辅助行为中对其嵌入加权聚合生成多行为一致性的原型表示,与锚点用户的目标行为表示共同参与对比训练,从而充分挖掘跨行为协同信号。

除星型对比机制外,部分研究引入其他跨行为视图增强策略以提升对比学习的效果。HMG-CR^[13]通过构建递增复杂度的超元图序列分阶段建模用户多行为信息。模型从仅含“购买”行为的超元图起步,逐步加入“收藏”“浏览”等行为,以刻画多行为演化轨迹。各超元图经独立编码后,以相邻超图为正负样本进行对比学习,从而在避免行为干扰的同时挖掘行为差异并捕捉潜在语义联系。

MBR-DGC^[118]则从行为强度与语义解耦的角度出发,首先依据行为强度(购买>加购>收藏>点击)对多行为交互进行去重,构建非重叠的行为子图以削弱弱行为对强行为的噪声影响;随后在各子图上引入解耦图卷积网络,通过多通道邻居路由机制将用户与物品的潜在交互因素分离学习,获取语义层次更清晰的行为表示;最后利用跨行为对比学习拉近同一用户在不同行为下的嵌入、区分不同用户间的特征,从而实现个性化的跨行为一致性建模与语义对齐。

部分研究还通过更精细的正负样本定义,更准

表4 对比学习方法总结

对比视图构建方式	代表方法	具体构建策略	特点
跨行为对比	S-MBRec ^[9] , MixRec ^[21] , CML ^[46] , MBCL-Rec ^[51] , MixMBR ^[70] , DCMGNN ^[83] , MBRCC ^[84] , HyperTEM-MBR ^[97] , TMCL ^[99] , SA-MBG-CL ^[116]	星型对比: 构建目标行为与各辅助行为的对比视图	利用星型对比结构提取目标与辅助行为间的共性, 方法结构简洁, 适用于多种行为建模场景
	HMG-CR ^[13] , KEMB-Rec ^[42]	多级超元图, 按行为复杂性逐步扩展	通过逐步组合行为构建超图, 揭示隐式行为演化与语义连接
	KDMBR ^[40] , TKMB ^[93]	相邻行为对比	利用同用户在相邻行为间的嵌入相似性, 建模行为共性信息
	TMBCCL ^[92]	行为层级划分构建正负样本对比视图	根据行为价值层级划分正负样本, 细粒度感知行为优先级与语义倾向
	DCMBR ^[67]	构建行为子图以区分购买意图与低兴趣行为	利用行为后果差异构建对比样本, 有效识别真实用户意图
	VCGAE ^[64]	基于行为语义强度构建对比正则化视图	根据行为语义相似度构造正负样本, 强化行为影响力的差异化建模
行为内对比	MB-Soc ^[36]	潜在意图嵌入与不同行为嵌入之间构造对比视图	全面建模用户多行为的整体意图与行为间的差异性
	MBSSL ^[45]	目标行为内自监督	有效抑制辅助行为为噪声对表示的干扰
	MBGCL ^[65]	对各行为视图施加噪声扰动	提升模型的鲁棒性和泛化能力
	IICL ^[57]	行为内引入图拓扑空间与语义空间	通过图结构拓扑与行为语义双重空间对比增强用户表示能力
	KMCLR ^[39]	结合知识图谱增强	引入知识图谱增强物品语义表达
多视图行为对比	KEMCL ^[41]	图随机扰动与知识图谱增强	解决噪声传播问题, 挖掘目标行为与知识图谱的语义关联
	MMCLR ^[14]	多视图对比、跨视图对比、行为区分对比三类任务	从行为、视图与优先级角度全面建模用户行为共性与差异
	RCL ^[100]	短期图与长期偏好视图分别进行跨行为对比	联合建模短期兴趣与长期偏好

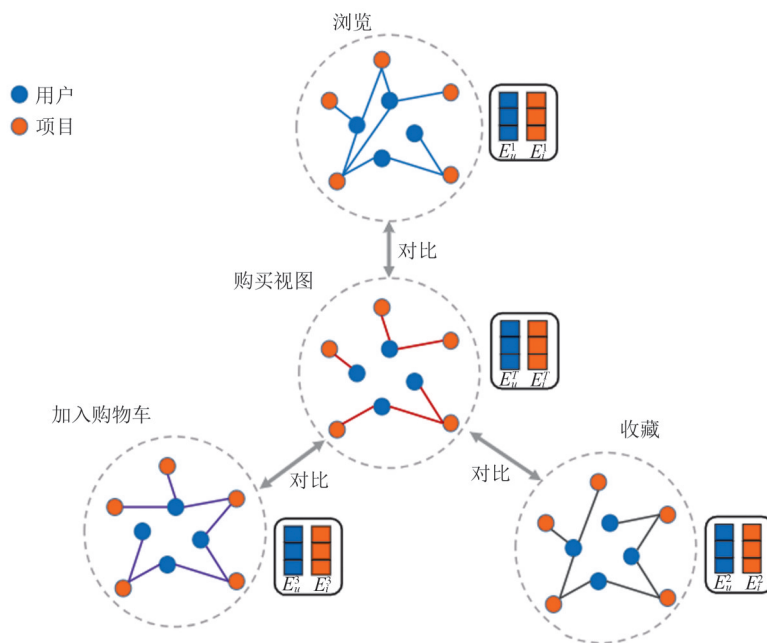


图6 星型对比的多行为建模示意图

确地刻画用户行为间的复杂性与差异性。KDMBR^[40]将同一用户在相邻行为类型下的表示作为正样本,不同用户在不同行为下的表示作为负样本,以此学习行为之间的共享表示。TMBCL^[92]则根据行为对目标行为的指导程度进行分级,将指导性最强的几类行为选为正样本,而指导性较弱的行为作为负样本,通过构建分级样本对建模行为间的共性与差异。DCMBR^[67]更注重用户意图建模,模型将子图中“加购”行为的表示作为正样本,而将用户“点击但无后续行为”的行为表示作为负样本,从而更准确地区分用户的真实兴趣与无效行为。VCGAE^[64]提出了基于语义相似度的行为对比正则化机制,通过计算行为间的余弦相似度来区分行为的正负对:若辅助行为与目标行为的语义相似度高于其他行为,即被视为正样本对,从而提升模型对目标行为语义的刻画能力。MB-DCAC^[119]通过双通道交叉自适应模块学习用户与物品的双重表征:主通道多关系聚合捕捉丰富的行为模式,辅助通道单行为聚合保留基础信息,并基于InfoNCE实现双通道对比融合;MB-Soc^[36]则利用潜在意图嵌入建模用户整体行为偏好。在对比学习中,模型通过相似度损失拉近潜在意图嵌入与各类行为嵌入的距离,确保其能统一表达多种行为信息;同时引入差异性损失来强化不同行为嵌入之间的区分性,从而更有效地捕捉行为间的多样性与异质性。

② 行为内对比。行为内对比学习聚焦于同一行为类型下的增强视图表示之间的对比建模,旨在从行为自身构造的多样化视图中提取更加稳定、有效的监督信号,从而增强模型对行为特征的特征能力,提升推荐精度与鲁棒性。

MBSSL^[45]提出基于目标行为子图的结构增强视图对比方法,通过对目标行为自身进行图结构扰动来生成增强视图,并开展对比学习,以强化目标行为表示的语义表达能力。类似地,MBGCL^[65]对每种行为构建增强视图,并通过添加噪声的方式进行视图扰动,再利用生成的视图进行对比学习,从而提升模型的泛化性能并增强行为表示的稳健性。IICL^[57]在行为内对比学习中引入图拓扑空间与语义空间双视角建模,以提升表示能力。在拓扑空间中,模型利用图信息传播的偶数层聚合同构邻居节点,将原始嵌入与偶数层嵌入构成对比视图以捕获结构关系;在语义空间中,将具有相似行为偏好的用户作为正样本,以强化语义相似用户间的表征一致性。

部分研究进一步融合知识增强机制以提升行为

内对比的语义表达能力。KMCLR^[39]引入关系感知的知识聚合模块,结合知识图谱信息生成更具语义丰富度的视图表示,从而提升目标行为图的表示能力。KEMCL^[41]则利用随机丢弃增强机制构建目标行为的两个扰动子图,以生成额外的行为内自监督信号,有效解决辅助行为噪声带来的干扰问题。同时,KEMCL进一步引入知识图谱构建知识增强视图,并在目标行为图与知识图之间开展双重对比学习,以捕捉更全面的语义关系。

③ 多视图行为对比。多视图行为对比旨在建模用户在多种视角(如行为类型、表示视图、时间偏好)下的共性与差异性,以增强用户兴趣表示的泛化能力和区分能力。

MMCLR^[14]设计了多行为、多视图和行为区分三类对比学习任务,以全面捕获用户在不同视图与行为间的共性与差异。多行为对比学习在序列与图视图中优化用户表示,前者关注不同行为间的一致性,后者挖掘全局行为关系;多视图对比学习对齐序列视图与图视图的表示,协调局部与全局偏好信息;行为区分对比学习则强化目标行为(如购买)与辅助行为(如点击、加购)的差异性,从而提升目标行为建模的准确性与鲁棒性。

RCL^[100]融合时间建模与行为感知对比学习,包含短期兴趣建模、长期偏好建模和跨行为对比三个模块。短期模块通过多关系图神经网络捕捉用户的即时兴趣,长期模块学习跨时间片的偏好演化;跨行为对比模块基于短期与长期表示构建行为感知对比视图,最大化同一用户多行为表示间的相似度,最小化与其他用户的相似度,从而同时刻画行为共性与个体差异。

(2) 级联方式

在实际应用中,用户往往按照一定顺序执行行为以逐步了解商品并做出决策,如“点击→加购→购买”。不同类型的行为在不同程度上反映用户偏好^[120],且行为链中后续行为通常比前序行为更能体现真实兴趣。在级联式多行为推荐框架中,用户的行为路径被建模为一个行为级联序列,每种行为对应一个图神经网络编码块(即级联块)。前一块的输出作为后一块的输入,以逐层捕捉行为间的依赖关系。每个级联块不仅学习当前行为特征,还融合来自前序行为的信息,从而逐步构建完整的行为链表示。典型的级联块连接方式包括串联连接、残差连接和有向无环图连接。

① 串联连接。这种方式是通过行为链(如点击→加入购物车→购买)进行逐层学习,前一个级联

块学习到的输出作为输入传递给下一个级联块中。整个过程如图7所示。

MB-CGCN^[47]提出了一种结构简洁的多行为推荐模型,由多层GCN模块组成。模型通过特征转换机制将前序行为的嵌入传递至后续行为学习,以缓解直接传递可能造成的信息差异与噪声干扰,从而更有效地实现跨行为特征迁移与表示优化。其具体转换过程如下:

$$e_u^{(b+1,0)} = W_u^b e_u^{(b)}, e_i^{(b+1,0)} = W_i^b e_i^{(b)}, \quad (13)$$

其中, W_u^b 和 W_i^b 分别表示用户和物品在第 b 个行为中学习到的嵌入传递给下一个行为初始嵌入的转换变量。

CEMBR^[73]的级联嵌入传播层中不仅通过级联策略将不同的行为关联起来,捕捉行为之间的顺序

关系,还对用户-物品图中的节点(用户和物品)和关系(不同类型的用户行为)进行编码。具体来说,设计了一个关系感知门控单元^[121-122],该单元将关系嵌入纳入节点表示,并在不同类型行为的消息聚合过程中对节点特征进行过滤。

现有多数级联式多行为推荐方法仅建模单一购买链(如“点击→加购→购买”),难以覆盖如“浏览→购买”等更复杂的行为路径,从而限制了对用户多层次决策依赖的刻画。为此,MPC^[88]引入多条购买链联合建模,以提升兴趣建模的完整性与推荐性能。同时,针对辅助行为可能带来负迁移的问题,MPC将前序但未延续至后续的物品视为负样本,构建负交互图以注入行为层级的负面语义,从而削弱无效行为对目标预测的干扰。




图7 串联连接式多行为建模结构

② 残差连接。CRGCN^[15]提出了级联残差块,该模块不仅能从每种类型的行为中学习用户和物品嵌入,还能捕获了不同行为之间的级联效应。残差设计可以确保在当前行为没有交互数据的情况下,信息仍能被保留并传递给下一个行为。在这种结构中,前一个残差块的输出被作为下一个残差块的输入,从而实现行为信息的跨层传递。具体来说,嵌入在级联残差块中的学习与优化方式如下:

$$\begin{aligned} e_1 &= e_0 + \tilde{e}_1, \\ e_2 &= e_1 + \tilde{e}_2, \\ e_B &= e_{B-1} + \tilde{e}_B \end{aligned} \quad (14)$$

其中, B 是行为的数量, e_{B-1} 表示第 B 个残差块的输入(即第 $B-1$ 个残差块的输出), \tilde{e}_B 表示从第 B 个行为中学习到的行为特征, e_0 为初始化的用户和物品嵌入(即基本特征)。基于该设计,可以在不同行为残差块之间实现嵌入层实现消息传递。残差连接的过程如图8所示。




图8 残差连接式多行为建模结构

为进一步提升级联图卷积模块的表示学习能力,已有研究尝试将对比学习机制引入残差结构之中。CGCL^[52]在每个级联图卷积块之后加入了对比学习模块,通过对最终嵌入添加噪声生成扰动嵌入,

使其与原始嵌入共同构成两种视图,用于对比学习,从而提升模型的表示学习效果。CGCCN^[72]则在级联结构基础上考虑到不同行为之间的相似性,提出了对比学习任务,通过比较每个辅助行为嵌入与目

标行为嵌入来提高预测准确性。类似地, ECR-GCN^[77]将对表示学习引入到多行为依赖关系的级联建模中, 以增强残差结构在建模行为依赖关系时对目标行为学习的影响。BRCGCNet^[82]利用残差块学习用户与物品嵌入并捕捉级联效应, 通过跨行为信息传播细化嵌入, 并利用注意力权重融合不同行为信息, 同时采用对比增强模块来减少多行为聚合表示中的信息丢失。SSPGNN^[81]则通过双行为链GCN块逐步传递和学习用户与物品嵌入, 并在最终级联块之前整合学习到的表示, 再利用行为内与行为间的自监督对比学习来提升推荐能力。NSED^[123]引入轻量化与去噪机制, 将多行为图拆分为单行为子图, 通过轻量级GCN聚合与层内对比强化稀疏监督; 沿行为链级联融合实现跨行为偏好传递, 并结合结构对比与教师去噪以提升表示的鲁棒性与语义纯净度。

HEC-GCN^[20]提出了一种超图增强的级联图卷积多行为推荐方法。该模型结合用户-物品交互图与行为特定超图, 通过级联结构捕捉多层次的行为依赖。行为超图用于建模用户或物品间的粗粒度关

联, 以缓解交互稀疏问题。同时, HEC-GCN设计了行为一致性引导的对比学习模块, 包括行为内与行为间一致性学习: 前者对齐交互图与超图中的嵌入表示, 后者对齐各行为嵌入与融合所有行为的全局嵌入, 从而强化多行为语义一致性。

在多行为推荐中, 级联结构虽能建模行为依赖, 但容易放大行为分布不平衡问题。例如, “点击”行为远多于“购买”, 导致下游表示被上游行为主导。为此, PKEF^[16]提出并行知识融合模块, 在并行关系增强网络中独立学习各行为表示, 并与级联流对应层的知识融合。通过投影增强机制^[124-125], 将并行表示映射至级联表示空间, 从而缓解信息偏差并提升整体表示能力。

③ 有向无环图。DA-GCN^[17]将单一行为链扩展为个性化有向无环行为图, 以刻画用户交互模式与物品属性。模型为每个用户或物品构建包含多种行为路径的有向图, 并在其上进行消息传递, 包含有向边编码器与注意力聚合模块: 前者提取行为间的协同信号, 后者通过可学习的注意力机制从前序行为中聚合高价值信息, 优化行为级嵌入表示。具体过程如图9所示。




图9 有向无环图式多行为建模结构

1) 有向边编码器

将起始行为的表示视为初始消息, 即

$$M^{k' \rightarrow k, (0)} = E^{k'}, E^{k'} \in R^{(|U|+|I|) \times d} \quad (15)$$

其中, d 是嵌入的维度。接下来, 消息更新公式表示为

$$M^{k' \rightarrow k, (l+1)} = \left(D^{k-\frac{1}{2}} A^k D^{k-\frac{1}{2}} \right) M^{k' \rightarrow k, (l)} \quad (16)$$

其中, $M^{k' \rightarrow k, (l+1)}$ 表示经过 $l+1$ 层传播后的消息, A^k 为行为 b_k 下的用户-物品交互矩阵, D^k 是行为 b_k 的对角度数矩阵。经过 $L^{k' \rightarrow k}$ 层传播后, 最终输出表示为

$$M^{k' \rightarrow k} = M^{k' \rightarrow k, L^{k' \rightarrow k}} \quad (17)$$

2) 注意力消息聚合模块

随后, 沿着行为链对所有终止行为的节点(用户

与物品)的表示进行优化。对于终止行为 b_k 的嵌入矩阵 $E^k \in R^{(|U|+|I|) \times d}$,基于个性化行为分布的注意力聚合公式如下:

$$E^k = \sum_{k'}^{k-1} Broadcast(\tilde{W}^{k' \rightarrow k}) \odot Norm(M^{k' \rightarrow k})$$

$$E^k = E^{k-1} + E' \quad (18)$$

其中, $M^{k' \rightarrow k}$ 表示从起始行为 $b_{k'}$ 到终止行为 b_k 的跨行为转换消息,且 $\tilde{W}^{k' \rightarrow k}$ 表示归一化后的权重向量; $Norm(\cdot)$ 为消息归一化操作,而 $Broadcast(\cdot)$ 是用于扩展维度的操作符,符号 \odot 表示Hadamard积。为了保持维度一致,需先将向量 $\tilde{W}^{k' \rightarrow k}$ 广播,再与归一化后的 $M^{k' \rightarrow k}$ 进行逐元素乘积。

通过堆叠:

$$\tilde{W}^k = [\tilde{W}^{0 \rightarrow k}, \tilde{W}^{1 \rightarrow k}, \dots, \tilde{W}^{k-1 \rightarrow k}] \quad (19)$$

获得了终止行为 b_K 对可能的前继行为(即 $\{b_1, b_2, \dots, b_K\}$)的整体个性化分布。基于该矩阵化传播规则,可同时沿行为链更新所有用户和物品的嵌入。个性化的有向无环行为图使DA-GCN能够以更贴近现实且更精细的方式建模用户与物品在多行为场景中的复杂交互。

(3)并行建模机制

除了对比学习和级联建模策略外,部分研究还将每种用户行为(如浏览、加购、购买等)视为独立子图,分别进行嵌入学习。这类方法被归类为并行建模方法。其核心思想是在不同行为图之间并行地进行信息处理与表示学习,既能缓解行为数据分布不均的问题,又有助于挖掘各行为特有的语义特征。

为更准确地建模多行为推荐中的行为关联与语义差异,研究者们从信息共享机制与表示解耦策略两个维度出发,提出了多种精细化的并行建模方法。这些方法的核心思路在于如何有效分离各自独特的特定信息,并融合多种行为中共享的通用信

息。其中,一类代表性方法通过嵌入表征实现上述目标。例如,MGNN^[10]利用多层图神经网络为每种行为分别学习用户和物品嵌入,并将其分为共享嵌入与行为特定嵌入,分别用于捕捉行为共性与行为特异性。MB-HGCN^[59]进一步提出层次化图结构,先在统一多行为图中获得全局嵌入,再以此为基础输入至行为特定图中,以捕捉粗粒度与细粒度的用户偏好。IMGCF^[79]设计了聚合增强机制,通过将高频行为的嵌入信息整合至低频行为中,以缓解数据不均衡问题,从而提升稀疏行为的表示能力。CKML^[79]将多兴趣学习引入多行为建模中,将兴趣解耦为共享兴趣与行为特有兴趣,通过粗粒度兴趣提取与细粒度行为关联建模模块,更好地刻画多行为之间复杂的语义依赖,并在预测阶段对各类兴趣独立预测后取最大值作为最终推荐结果。

另一类方法则从模型结构角度出发,设计多任务学习框架以提供更丰富的监督信号和跨行为知识迁移能力。CIGF^[53]构建了基于压缩交互图的多行为建模框架,该框架由压缩交互图卷积网络(Compressed Interaction Graph Convolution Network, CIGCN)和多专家独立输入(Multi-ExpertwithSeparate Input, MESI)网络组成。其中的CIGCN利用显式图结构建模高阶关系,MESI则通过分离输入机制提升各行为的任务感知能力,缓解多任务之间的梯度冲突,从而提升训练稳定性与推荐效果。HPMR^[54]引入了分层投影机制,以显式建模上下游行为之间的共享与独特信息,在各行为子图完成图编码后,通过唯一表示监督、共享信息传输与唯一表示再投影三个模块,分别强化行为特定信息表达、避免有害的共享迁移、并提升唯一信息的区分性,从而实现更稳健的多行为推荐。表5汇总了现有基于GNN的多行为推荐方法。

表5 基于GNN的多行为推荐模型汇总

方法	建模方式	GNN编码器	训练数据集	训练任务	年份
MBGCN ^[13] ①	分层融合	GCN	Tmall、Beibei	目标行为预测	SIGIR 2020
MGNN ^[10]	并行方式	GCN	YooChoose、Steam、Douban Book	目标行为预测	CIKM 2020
MB-GMN ^[12] ②	分层融合	LightGCN	Taobao、Beibei、IJCAI	多行为预测	SIGIR 2021
KHGT ^[11] ③	分层融合	GAT	Yelp、ML10M、Online Retail	目标行为预测	AAAI 2021
SaGCN ^[58]	分层融合	GCN	Taobao、Beibei	多行为预测	ICDM 2021
GNMR ^[61] ④	分层融合	HetGNN ^[107]	Yelp、ML10M、Taobao	目标行为预测	ICDE2021

①<https://github.com/tsinghua-fib-lab/MBGCN>

②<https://github.com/akaxlh/MB-GMN>

③<https://github.com/akaxlh/KHGT>

④<https://github.com/akaxlh/gnmr>

续表

方法	建模方式	GNN编码器	训练数据集	训练任务	年份
GHCF ^[48] ①	统一图建模	GCN	Taobao, Beibei	多行为预测	AAAI 2021
HMG-CR ^[13] ②	对比学习	GIN ^[126]	Taobao, Tmall	目标行为预测、自监督任务	ICDM 2021
CML ^[46] ③	对比学习	LightGCN	Tmall, IJCAI, Retail	多行为预测、自监督任务	WSDM 2022
S-MBR ^[9]	对比学习	GCN	Taobao, Beibei, Yelp	目标行为预测、自监督任务	IJCAI2022
MMCLR ^[14]	对比学习	LightGCN	Tmall, CIKM	目标行为预测、自监督任务	DASFAA 2022
MB-AGCN ^[68] ④	分层融合	LightGCN	Beibei, Taobao, IJCAI	多行为预测	KBS2023
MBSSL ^[45] ⑤	对比学习	R-GCN ^[127]	Taobao, Beibei, Tmall, IJCAI, Videos	多行为预测、自监督任务	SIGIR 2023
KMCLR ^[39] ⑥	对比学习	LightGCN	Tmall, Yelp, Online Retail	目标行为预测、自监督任务	WSDM 2023
TMCL ^[99]	对比学习	LightGCN	Tmall, IJCAI, Retail	目标行为预测、自监督任务	DASFAA 2023
RCL ^[100] ⑦	对比学习	LightGCN	Taobao, IJCAI, E-Commerce	多行为预测、自监督任务	RecSys 2023
MixMBR ^[70]	对比学习	LightGCN	Taobao, Beibei	目标行为预测、自监督任务	DASFAA 2023
CRGCN ^[15] ⑧	级联方式	LightGCN	Beibei, Tmall, Jdata	多行为预测	TOIS2023
MB-CGCN ^[47] ⑨	级联方式	LightGCN	Beibei, Tmall	目标行为预测	WWW 2023
PKEF ^[16] ⑩	级联方式	LightGCN	Taobao, Beibei, Tmall	多行为预测	CIKM 2023
CIGF ^[53] ⑪	并行方式	CIGCN ^[53]	Beibei, Taobao, IJCAI	多行为预测	WWW 2023
CKML ^[90] ⑫	并行方式	GCN	Yelp, OnlineRetail, Tmall	多行为预测	TOIS2023
HPMR ^[54] ⑬	并行方式	GCN	Taobao, Beibei	多行为预测	KDD2023
POGCN ^[18] ⑭	统一图建模	GCN	BeiBei, Taobao, Tenrec	多行为预测	KDD2024
BCIPM ^[2] ⑮	统一图编码	LightGCN	Taobao, Tmall, Yelp, ML10M	预训练、目标行为预测	SIGIR 2024
MBCLRec ^[51]	对比学习	HetGNN	Tmall, BeiBei, IJCAI	目标行为预测、自监督任务	KBS2024
KEMCL ^[41]	对比学习	LightGCN	Tmall, IJCAI, Online Retail	目标行为预测、自监督任务	RecSys 2024
CGCCN ^[72]	级联方式	LightGCN	Tmall, Jdata	多行为预测、自监督任务	DASFAA 2024
MULE ^[19] ⑯	分层融合	LightGCN, GAT	Taobao, Tmall, Jdata	目标行为预测	CIKM 2024
HEM-GNN ^[75] ⑰	分层融合	GCN, GAT	Taobao, Beibei, IJCAI	目标行为预测	IPM2024
MBRCC ^[84] ⑱	对比学习	LightGCN	Taobao, Beibei, Tmall	目标行为预测、自监督任务	TOIS2024
DA-GCN ^[17] ⑲	级联方式	LightGCN	Tmall, Taobao	多行为预测	TOIS2024
MixRec ^[21] ⑳	对比学习	GCN, HGNN ^[128]	Tmall, BeiBei, IJCAI	目标行为预测、自监督任务	WSDM 2025
UIPL ^[89] ㉑	分层融合	LightGCN	Tmall, Taobao, Yelp, M110M	目标行为预测、自监督任务	TOIS2025
MPC ^[88]	级联方式	LightGCN	BeiBei, Taobao	多行为预测	AAAI 2025
HyperTEM-MBR ^[97]	对比学习	TempGCN ^[97] , HGNN ^[128]	Tmall, BeiBei, IJCAI	多行为预测、自监督任务	EAAI2025
DeMBR ^[113]	分层融合	GCN	Taobao, IJCAI	目标行为预测、自监督任务	WSDM 2025
BMGCN ^[115]	统一图建模	BMGCN ^[115]	Taobao, BeiBei, Tenrec	多行为预测	TKDE 2025
HGIB ^[104] ㉒	分层融合	LightGCN	Tmall, Taobao, Jdata	目标行为预测、自监督任务	RecSys 2025

① <https://github.com/chenchongthu/GHCF>② <https://github.com/Haoran-Young/HMG-CR>③ <https://github.com/weiwei1206/CML>④ <https://github.com/3endurance/MB-AGCN>⑤ <https://github.com/Scotfield666/MBSSL>⑥ <https://github.com/xuanhongrui/KMCLR>⑦ <https://github.com/HKUDS/RCL>⑧ <https://github.com/MingshiYan/CRGCN>⑨ <https://github.com/SS-00-SS/MBCGCN>⑩ <https://github.com/MC-CV/PKEF>⑪ <https://github.com/MC-CV/CIGF>⑫ <https://github.com/MC-CV/CKML>⑬ <https://github.com/MC-CV/HPMR>⑭ <https://github.com/wings236/pogcn>⑮ <https://github.com/MingshiYan/BIPN>⑯ <https://github.com/geonwooko/MULE>⑰ <https://github.com/SamuelZack/MultiRec>⑱ <https://github.com/lambiolab/MBRCC>⑲ <https://github.com/xizhu1022/DA-GCN>⑳ <https://github.com/HKUDS/MixRec>㉑ <https://github.com/MingshiYan/UIPL>㉒ <https://github.com/zhy99426/HGIB>

5 推荐任务与优化目标

在多行为推荐任务建模过程中,主要存在两种典型范式:单任务学习与多任务学习(见表6)。

(1)单任务学习仅将目标行为作为预测标签,模型优化目标明确且实现成本低。然而,这种方法对目标行为数据的稀疏性较为敏感,尤其在数据量有限时,其预测性能容易受到限制。

(2)多任务学习(Multi-task Learning, MTL)同时对多种行为(如点击、收藏、购买等)进行联合建模,并通过综合损失函数对模型进行训练,如公式(20)所示;

$$L = \sum_{k=1}^K \lambda_k \mathcal{L}_r^{(k)} \quad (20)$$

其中, $\mathcal{L}_r^{(k)}$ 表示第 k 种行为的任务损失, λ_k 表示该行为任务的权重。权重的选择通常反映任务的重要性,当所有任务权重均等时,则表示所有任务同等重要。

表6 多行为推荐任务建模典型范式

学习模式	推荐损失函数	方法
单任务学习	BPR	KHGT ^[111] , MBGCN ^[1] , MB-SVD ^[62] , AMR ^[63] , MFBR ^[94] , MB-EBIH ^[60] , MSSR ^[35] , GNMR ^[61] , MB-CGCN ^[47] , KM-CLR ^[39] , MBHCR ^[49] , MBCLRec ^[51] , S-MBRec ^[9] , MMCLR ^[14] , MBGCL ^[65] , TMCL ^[99] , MixMBR ^[70] , Disen-CGCN ^[74] , SSPGNNC ^[81] , KDMBR ^[40] , MBRCC ^[84] , KEMCL ^[41] , MixRec ^[21] , VCGAE ^[64] , CMBSR ^[37] , DGAMR ^[69] , DLACN ^[78] , MB-DCGBN ^[76] , MBKGIN ^[44] , MB-TGAT ^[98] , TKMBR ^[91] , TMBCL ^[92] , MULE ^[19] , UIPL ^[89] , DeMBR ^[113]
	BCE	HMG-CR ^[13] , DCMBR ^[67] , KEMB-Rec ^[42] , HGIB ^[104] , MBR-DGC ^[118]
	MSE	MB-Soc ^[36] , HEM-GNN ^[75]
多任务学习	MSE	FPD ^[56] , SaGCN ^[58] , CEMBR ^[73] , GHCF ^[48] , MBGL ^[43]
	BPR	MB-GMN ^[12] , MK-GCN ^[50] , BCIPM ^[2] , MBGR ^[55] , POGCN ^[18] , GTCF4MB ^[101] , MGNN ^[10] , CRGCN ^[15] , DA-GCN ^[17] , CIGF ^[53] , CGCL ^[52] , CKML ^[90] , IICL ^[57] , MBSSL ^[45] , PKEF ^[16] , MORO ^[66] , RCL ^[100] , CGCCN ^[72] , ECR-GCN ^[77] , IMGCF ^[79] , CML ^[46] , MB-HGCN ^[59] , BRGCNNet ^[82] , DCMGNN ^[83] , MB-AGCN ^[68] , BMGCN ^[115] , NSED ^[123]

尽管多任务学习能够更好地利用辅助行为数据以缓解数据稀疏问题,但其实现复杂度较高,且容易产生负迁移(Negative Transfer)问题,即某些辅助任务可能干扰目标任务的学习效果。为应对多任务学习中的负迁移问题,研究者提出了如动态权重分配、元学习和混合专家模型等一系列解决方案。

DA-GCN^[17]提出了一种基于Jaccard相似性的动态用户特定相关性评分机制,以量化辅助行为对目标行为预测的贡献度,有效降低不相关行为造成的负迁移;POGCN^[18]引入了偏序贝叶斯个性化排序机制,通过行为组合抽样优化重要行为,以降低计算复杂性并避免无关行为带来的干扰。

元学习框架MB-GMN^[12]通过挖掘用户与物品交互中的元知识关系,动态生成预测网络参数,从而在更高层次上缓解多任务间的冲突。该方法引入了元预测网络,在多任务学习框架下建模复杂跨行为类型依赖关系。借助这一机制,不同类型的用户行为不仅用于调控图神经网络的参数更新,还可提供辅助监督信号,有效提升了模型在预测阶段的表达能力与泛化性能。

此外,CIGF^[53]提出了多专家分离输入网络,通过Hadamard积生成不同专家的输出,再通过自动门控机制选择适合特定任务的专家子集,以缓解任务间的梯度冲突。HPMR^[54]则设计了基于投影的传输网络^[124],通过独特表示监督、共享信息转移以及独特表示再投影三个组件,有效防止无关信息在多任务学习中的传递,缓解负迁移效应。

上述方法为解决多行为推荐中的核心难题提供了重要的理论基础与实证经验,为进一步的多行为推荐方法架构奠定了坚实的理论基础。

6 数据集与评价指标

6.1 数据集

表7汇总了当前多行为推荐领域常用的一些基准数据集,包括用户数、物品数、交互行为数量及类型。该表系统性地整理了多行为推荐领域常用的12个数据集,涵盖电商、社交、影视与竞赛等多种应用场景,展示了各数据集的来源平台、用户与项目规模、交互数量及行为类型。

表7 数据集汇总

数据集	平台/来源	用户数	项目数	交互数	交互行为类型
Beibei	中国婴儿用品在线零售平台	21 716	7977	3.3×10^6	浏览, 加入购物车, 购买
Taobao	淘宝	48 749	39 493	1.9×10^6	浏览, 加入购物车, 购买
Tmall	阿里巴巴天猫平台	31 882	31 232	1.4×10^6	浏览, 收藏, 加入购物车, 购买
Yelp	美国商业评论平台	19 800	22 734	1.4×10^6	不喜欢, 中性, 喜欢
JDATA	京东	93 334	24 624	2.1×10^6	浏览, 收藏, 加入购物车, 购买
Online Retail	英国在线零售平台	147 784	99 037	7.7×10^6	浏览, 收藏, 加入购物车, 购买
IJCAI	IJCAI 竞赛发布	17 435	35 920	7.9×10^5	浏览, 收藏, 加入购物车, 购买
ML10M	MovieLens	67 788	8704	9.9×10^6	不喜欢, 中性, 喜欢
Yoochoose	电商平台	509 126	19 034	3.2×10^6	浏览, 加入购物车, 购买
Douban	豆瓣平台	13 024	22 347	7.9×10^6	不喜欢, 中性, 喜欢
Videos	在线短视频平台	2917	23 251	2×10^6	浏览, 点赞, 评论, 下载
E-commerce	在线零售平台	31 021	1827	3.7×10^6	浏览, 评论, 购买

Beibei数据集来自母婴电商平台,包含浏览、加购、购买行为,适用于垂类商品偏好建模;Taobao与Tmall记录完整购物链,便于复杂路径分析;Yelp为社交评论平台,用户以情感标签表达偏好,适合评分预测;JDATA来源京东,行为多样且具真实性;Online Retail为英国零售数据,常用于行为序列分析;IJCAI数据结构规范,适合算法评估;MovieLens(ML10M)为典型评分数据集;Yoochoose为点击流数据,涵盖浏览、加购、购买;Douban以评分体现兴趣;Videos为短视频平台数据,交互类型丰富;E-commerce数据整合浏览、评论、购买行为,适用于文本与行为融合建模。这些数据集在行为类型与任务适配上各具特色,为多行为推荐研究提供了多样化实验基础。

6.2 评价指标

针对隐性反馈的推荐方法旨在提升Top-N推荐任务的准确性。常用评估指标包括归一化折扣累积增益(NDCG)^[129]、平均倒数排名(MRR)^[130]、Precision、Recall以及命中率(HR)。

(1)NDCG反映了在每个方法中推荐给用户 p_i 的前 N 个项目在集合 R_{p_i} 中的排名重要性。让 y_k 作为第 k 个项目的二值向量表示。当 y_k 属于 R_{p_i} 时, y_k 为1,否则为0。在此情况下, $NDCG_{p_i}@N$ 的计算方法如下:

$$NDCG_{p_i}@N = \frac{DCG_{p_i}@N}{IDCG_{p_i}@N} \quad (21)$$

$$DCG_{p_i}@N = \sum_{k=1}^N \frac{2^{y_k} - 1}{\log_2(k+1)} \quad (22)$$

其中, $IDCG_{p_i}@N$ 为理想的DCG,即对于前 N 个项目 $i_k \in N_{p_i}$,将 y_k 设为1。

(2)MRR反映了第一个相关项 i_k 在集合 R_{p_i} 中的平均倒数排名。MRR的计算公式如下:

$$MRR_{p_i}@N = \frac{1}{rank_{p_i}} \quad (23)$$

其中, $rank_{p_i}$ 表示集合 R_{p_i} 中第一个相关项的排名位置。

(3)Precision和Recall分别定义为

$$Precision_{p_i}@N = \frac{|N_{p_i} \cap R_{p_i}|}{|R_{p_i}|} \quad (24)$$

$$Recall_{p_i}@N = \frac{|N_{p_i} \cap R_{p_i}|}{|N_{p_i}|} \quad (25)$$

其中, $Precision_{p_i}@N$ 和 $Recall_{p_i}@N$ 分别表示在 N 个项目中的准确率和召回率。

(4)HR(命中率)是 R_{p_i} 中包含用户真实兴趣物品的用户比例,其计算公式为

$$HR@N = \frac{\sum_{p_i \in U} hit_{p_i}}{m} \quad (26)$$

其中, m 表示用户数量。若 $R(p_i)$ 包含 p_i 的任何真实物品,则赋值 $hit(p_i)=1$,否则为0。

这些指标各有侧重,提供了不同的见解:NDCG同时考虑了所有推荐物品的相关性和排名,适合用来评估推荐系统的整体排名质量。MRR关注推荐列表中第一个相关物品的位置,适用于关注用户首选物品的准确性的任务。Precision和Recall是基础的分指标,分别衡量推荐系统中相关物品的准确性和召回能力。HR侧重衡量推荐系统是否能够成功包含用户感兴趣的物品,适用于评估推荐覆盖的能力,不考虑排名。

6.3 实验分析

为直观展示多行为推荐算法的优势,本小节对比了部分单行为和多行为推荐算法在 Tmall 和 IJCAI 两个数据集上的表现,评估指标为 Hit@10 和 NDCG@10,实验结果如表 8 和表 9 所示。从结果可见,多行为推荐在两个数据集上均优于单行为推荐。其中,对比学习方法表现最佳,级联方式在 Tmall 上接近其效果但在 IJCAI-Contest 上略有下降;统一图建模方法表现稳定,优于分层融合,但整体略逊于前两者;分层融合因行为间信息共享不足,难以充分挖掘协同关系。

表 8 单行为推荐方法实验结果

方法	Tmall		IJCAI-Contest	
	Hit@10	NDCG@10	Hit@10	NDCG@10
BPR ^[131]	0.243	0.143	0.163	0.085
PinSage ^[132]	0.274	0.151	0.176	0.091
NGCF ^[8]	0.322	0.184	0.256	0.124
LightGCN ^[106]	0.342	0.205	0.257	0.122
SGL ^[133]	0.350	0.210	0.249	0.123
HGT ^[134]	0.357	0.210	0.250	0.119

表 9 多行为推荐方法实验结果

方法分类	方法	Tmall		IJCAI-Contest	
		Hit@10	NDCG@10	Hit@10	NDCG@10
分层融合	MBGCN ^[1]	0.381	0.213	0.304	0.160
	KHGT ^[11]	0.391	0.323	0.317	0.182
	MB-GMN ^[12]	0.460	0.281	0.381	0.210
统一图建模	BCIPM ^[2]	0.501	0.317	0.390	0.234
	CML ^[46]	0.543	0.327	0.477	0.283
对比学习	IICL ^[57]	0.558	0.339	0.487	0.297
	TMCL ^[99]	0.557	0.345	0.489	0.298
	CRGCN ^[15]	0.522	0.330	0.418	0.255
级联方式	MB-CGCN ^[47]	0.505	0.313	0.412	0.238
	DA-GCN ^[17]	0.527	0.351	0.410	0.251

对比学习的优势在于有效缓解多行为噪声与稀疏性问题,并能深入挖掘行为共性以构建稳健偏好表示,但其训练代价较高,适合精度优先场景。相比之下,级联方式性能接近对比学习且计算更高效,更适用于效率优先的应用环境。

7 当前挑战与研究前沿

尽管近年来多行为推荐技术已取得显著进展,当前研究仍然面临若干关键挑战与问题。除了常见

的行为共性与差异建模、行为依赖关系、负迁移以及噪声问题外,研究前沿还包括流行度偏差、隐式交互挖掘以及模型复杂度与计算开销等问题亟待深入探索与解决。

7.1 关键挑战

多行为推荐核心挑战主要集中在以下几个方面:

(1)行为间粗粒度共性建模。行为间的粗粒度共性指不同类型行为(如浏览、点击、加购、购买等)所共享的用户兴趣特征与模式。这种共性有助于推荐系统从整体层面理解用户兴趣偏好,提升用户需求预测能力^[39,51]。例如,各类行为虽然形式不同,但均反映用户对特定商品的兴趣,因此通过有效建模这些共性,推荐系统能够更精准地把握用户的整体兴趣。

(2)多行为细粒度差异建模。细粒度差异主要体现为不同行为背后的特定意图与用户偏好差别。如果推荐模型忽视这些差异,则可能造成误导,降低推荐精度^[39,67]。例如,点击行为可能仅代表用户的初步兴趣,而购买行为明确表现为用户的购买决策。精细化差异建模可帮助推荐系统更准确地捕捉用户真实需求,从而显著提高推荐效果^[51]。

(3)行为间依赖关系建模。用户行为通常存在从初步兴趣到最终决策的渐进式依赖关系(如浏览→加入购物车→购买)^[111,135,136]。行为序列中的依赖结构体现用户兴趣演变过程与决策路径。如何有效捕获这些依赖关系并将其整合到模型中,是当前多行为推荐研究的重要挑战之一。

(4)多任务学习的负迁移问题。在多任务学习框架下,多种行为被视作为不同任务同时学习。然而,若简单地将多行为视作为独立任务,可能忽视行为间存在的差异和关联,从而引发负迁移问题^[48,137]。这种效应会导致某一任务的学习过程对其他任务产生干扰,降低整体模型性能。因此,设计更有效的任务权重分配策略,明确任务之间的共享与独立特征,是当前亟待解决的关键问题。

(5)噪声问题。用户行为通常带有偶然性和不确定性,尤其在隐式反馈(如点击、浏览等)数据中更为明显^[2,39]。此类数据缺乏明确正负标签,难以准确刻画用户的真实偏好,极易引入噪声。这些噪声一定程度上会严重干扰甚至“污染”用户兴趣的有效表征,从而降低推荐的精准度。因此,如何准确识别、过滤或减轻噪声影响,以提升模型稳定性与准确性,是当前研究的重要难题之一^[45,57]。

7.2 前沿研究问题

除上述关键挑战之外,当前研究中仍存在若干核心难题尚未得到充分关注,亟须在未来的研究中进一步深入挖掘与系统解决。

7.2.1 科学问题

(1)流行度偏差问题。用户行为数据分布通常表现为显著的不平衡性:少数热门商品占据大量交互数据,辅助行为(如点击)频率远超目标行为(如购买)。这一双重的不均衡导致模型倾向推荐热门商品,限制推荐结果的公平性与多样性。因此,如何缓解流行度偏差,平衡热门和冷门商品的推荐比例,是多行为推荐领域亟须解决的关键问题。

(2)隐式交互挖掘的挑战。传统方法多基于显式交互数据构建用户偏好模型,而忽略了隐式交互中蕴含的丰富信息。隐式交互中未发生交互的行为并不一定代表负反馈,可能反映用户潜在兴趣。如何在保留数据结构完整性的前提下,有效挖掘用户潜在偏好与隐式关系信号,是未来研究的重要方向之一。

(3)多行为数据的选择与稀疏性问题。在多行为场景中,用户与物品间可能存在多种交互(如点击、收藏、加购、购买),但这些行为数据在统计分布上往往极度不均。例如,高频行为如点击数量众多,稀有行为如购买则更具代表性。如何在模型中合理选择与融合不同行为类型,缓解长尾行为的稀疏性,平衡各类行为的建模权重,是多行为学习中的重要挑战。

(4)冷启动与行为间共现冲突的处理。多行为推荐系统常需面向新用户和新物品进行个性化建模,而冷启动问题在多行为场景中更为复杂:某些行为可能存在,另一些则完全缺失。同时,行为之间还可能存在着逻辑冲突(如用户点击但未购买),这类行为间的“共现冲突”容易干扰建模效果。如何通过跨行为迁移学习、增强式建模或引入行为先验规则来缓解此类问题,是一个值得深入探索的研究方向。

(5)跨域与跨平台多行为建模的挑战。在实际应用中,用户的多行为数据往往分散于不同的业务域或平台(如电商、短视频、社交媒体等),而这些域之间普遍存在着显著的语义差异、数据异质性与行为迁移障碍。一方面,不同行为在不同域中的语义存在偏移,例如“点赞”在社交平台中代表情感偏好,而在内容平台中则体现对内容质量的认可;另一方面,各域的数据稀疏性和分布模式差异显著,导致跨域知识迁移与兴趣共享面临较大挑战。

7.2.2 工程问题

(1)实时图构建的复杂性。在实际应用中,用户行为具有高度动态性,新行为数据持续产生,这对图结构的实时更新与维护提出了更高的要求。构建能够高效接入流式行为、增量更新节点与边属性的实时图系统,既需保证结构一致性,又需兼顾计算成本,是兼具工程与算法挑战的关键问题。此外,不同行为之间的异质性进一步增加了图构建逻辑的复杂性。

(2)推理效率与在线服务部署挑战。多行为推荐需要同时处理多种行为的复杂交互关系,导致模型结构复杂、计算资源消耗增加。在大规模在线服务中,这可能引发推荐延迟上升、系统吞吐下降等问题。如何在保证推荐性能的前提下,通过模型裁剪、量化优化与异构部署(如结合边缘计算与云计算)实现高效在线服务,是推进多行为推荐系统落地的关键工程难题。

(3)系统的可扩展性与维护成本。随着业务拓展与行为类型不断增加,原有系统架构可能面临模型膨胀、特征冲突与表示混淆等问题。例如,从“点击-购买”扩展到“点击-收藏-加购-购买”等更复杂链路,可能需要重构图结构和调整建模策略。若系统架构缺乏模块化与可扩展设计,将显著增加后期维护与升级成本。因此,如何在保持建模灵活性的同时,提升系统对行为复杂性变化的适应能力、降低维护复杂度并实现持续演进,已成为多行为推荐系统可持续发展的重要要求。

8 未来研究方向与展望

(1)深度图神经网络的探索。为解决图神经网络(GNN)中的过平滑问题,研究者们正从多个维度探索构建深度GNN的方法^[138-141],旨在捕获更高层的图拓扑信息。

主要技术路径包括:

①引入先进的神经网络架构,如借鉴计算机视觉领域的成功,将残差连接(Residual Connections)与空洞卷积(Dilated Convolutions)集成到GNN中^[138],前者通过构建“信息高速公路”来缓解梯度消失,后者在不增加计算成本的前提下扩展了节点的感受野;

②发展正则化与随机化策略,例如DropEdge^[139]在训练中随机移除图的边,以此作为一种数据增强手段来减缓节点表示的趋同,从而抑制过平滑;

③ 设计自适应的传播机制,如 Policy-GNN^[140]创新性地利用强化学习为每个节点动态学习最佳的信息传播深度,以适应不同节点的局部结构特性;

④ 优化训练过程中的采样效率,如 FastGCN^[141]通过为每一层独立进行重要性采样来构造计算图,在降低训练复杂度的同时也缓解了全图传播导致的过平滑效应。

尽管这些研究显著推动了深度 GNN 的发展,但如何在提升模型表达能力的同时,合理权衡网络深度、计算开销与训练效率,仍是该领域亟待解决的重要问题^[142]。

(2) 大规模图神经网络的研究与进展。目前,大多数图神经网络模型主要在小规模图数据集上进行验证,而在面对大规模图时,因模型复杂度高、计算资源消耗大,难以实现高效训练和推理。

为解决这一问题,现有研究主要沿两条技术路线展开^[143]:

第一条路线是模型结构优化,旨在提升 GNN 的可扩展性与计算效率。例如,Cluster-GCN^[144]基于图聚类思想,将原始图划分为多个高密度子图,仅在子图内部进行邻居节点的采样与训练,兼顾训练效率与模型性能;SIGN^[145]则通过引入多尺度图卷积滤波器,预先计算特征变换,避免图采样过程,从而实现高效的图表示学习;SGQuant^[146]设计了一套面向 GNN 的量化机制和微调流程,在基本保持精度的前提下大幅降低内存占用。

第二条路线分布式训练与并行计算。代表性方法如 DistDGL^[147],通过图划分和多机并行,将节点及其特征分布至不同计算节点,并采用最小图割策略与负载均衡优化,以降低跨节点通信成本;DistGNN^[148]则通过共享内存设计、稀疏嵌入更新和延迟通信机制,有效缓解了分布式环境中的通信瓶颈;GraNNDIS^[149]综合采用共享预加载、扩展感知采样和协同批处理等关键技术,在 GPU 资源受限的条件下显著提升大规模图训练性能。

此外,众多高效图学习框架也不断涌现,加速了 GNN 在工业推荐系统中的落地应用。例如,PyG^[150]、DGL^[151]和 AliGraph^[152]等提供了灵活的图建模与训练接口,而 PlatoGL^[153]在兼顾高效性与可扩展性的同时,为大规模 GNN 在实时推荐场景中的部署提供了可行方案。

尽管如此,构建真正可用于工业级推荐的大规模 GNN 系统仍面临诸多挑战,如处理海量特征信息、建模异构关系结构,以及应对实时性和系统复杂

性等问题。这些挑战对模型的表示能力与系统工程设计均提出了更高要求。

(3) 图神经网络与大语言模型融合。图神经网络(GNN)通过在图结构中传播与聚合节点信息,能够有效捕捉结构特征并显著提升模型性能。然而,其仍面临图结构不完整、噪声干扰及数据稀疏等问题^[154],且在新图或新增节点上的泛化能力有限^[155]。构建更稳健、具适应性的图学习模型仍是关键方向^[156]。与此同时,大型语言模型(LLMs)凭借强大的泛化与推理能力,在多领域取得突破,促使研究者尝试将其强大的推理与生成能力引入到图相关任务之中,推动 GNN 与 LLM 的融合发展^[157]。

当前,已有多种方法将 LLM 的能力迁移至图学习场景。一类前景方案是通过精巧的提示词(prompts)引导 LLM 理解图结构并高效完成问答或推理任务。例如,InstructGLM^[158]与 NLGraph^[159]等方法通过自然语言提示帮助模型在图数据上进行有效推理并生成准确输出。另一类思路则是将 GNN 与 LLM 进行深度融合,先由 GNN 对图结构进行编码,生成 token 序列后输入到 LLM 中处理。典型代表如 GraphGPT^[160]与 GraphLLM^[161],实现了模型对图结构的深度理解与有效利用。该协同框架不仅在节点分类、链接预测、推荐等下游图任务上取得了更高的精度,还展现出强大的零样本泛化能力,使模型能够在新图结构或新增节点的情况下依然做出准确预测^[157]。

GNN 与 LLM 的融合为图学习带来了新的建模范式,为应对复杂结构、数据稀疏和隐含关系提供了有效途径。随着 LLM 理解与推理能力的提升,二者的深度结合有望推动图学习迈向更通用、更智能的发展,并为推荐系统等应用带来变革性突破。

(4) 大语言模型在多行为推荐中的应用。大语言模型(LLMs)凭借强大的语言理解与知识推理能力^[162-163],正成为推荐系统的重要研究方向。相比传统 ID 表示,LLMs 可利用丰富的文本信息建模用户与物品特征,尤其在多行为序列推荐中表现突出^[164,165]。其自然语言建模范式可融合多行为信号与语义特征,有效捕捉行为间的潜在关联与动态依赖。

例如,TMF^[166]在多行为推荐中引入了 LLM,通过混合提示词设计将用户行为和商品信息整合到 LLM 中,在每个商品和其相关行为后添加专门的模态标记,并通过适配模块将这些模态标记的嵌入向量映射到 LLM 的嵌入空间中,通过这种方法,使

LLM能理解多种模态的数据(如商品和行为),并根据用户行为和候选物品集生成推荐,从而预测下一个最可能的商品。这种设计增强了LLM处理复杂推荐任务的能力。

此外,EAGER-LLM^[167]则提出了一种新颖的基于解码器结构的LLM生成式推荐框架,将大量的外部信号压缩为少量新增的token,压缩率高;并引入了非侵入式的多尺度对齐重建任务和多阶段训练机制,帮助LLM在不干扰原有参数的基础上,高效理解并融合外部行为、语义信号以及推荐领域知识。

高效整合多行为信息至LLM,并利用其强大的上下文理解和知识融合能力,已成为提升推荐性能与实现个性化推荐的重要研究方向,也为未来研究指明了新的探索路径。

(5)跨领域泛化与多模态融合联合建模。随着推荐系统的发展,多行为建模正由单一场景拓展至多领域与多模态的复杂场景建模。用户兴趣的跨领域泛化能力与多模态的感知融合能力,正成为下一代推荐系统实现高效、精准推荐的关键支撑。

在真实应用中,用户行为往往跨越多个领域(如电商、短视频、社交等)并涉及多种模态(如图像、文本、音频等)。例如,电商中的购买偏好可能受短视频浏览习惯影响,而该偏好由商品图像、视频内容与文本描述等多模态特征共同体现。因此,单一领域或模态难以全面刻画用户复杂而动态的兴趣结构。

多行为推荐系统亟须构建统一的跨域多模态表示空间,充分整合不同场景下的多种行为与多模态内容,实现更强的语义迁移与行为推理能力。在跨领域建模方面,需要挖掘跨平台或跨领域之间的行为迁移路径、潜在兴趣迁移与语义映射。例如,CCDR^[168]为充分利用用户和不同域之间的其他关联(例如标签、词语、媒体等),为每个领域构建了一个全局化的多样化偏好网络,将推荐中的六类关键对象(物品、用户、标签、类别、媒体和词语)作为节点,并以其异质交互作为边;在用户-物品交互中考虑了多种用户行为(如点击、喜欢、分享等)来构建此边,并赋予不同的权重;GCTN^[169]提出了“图结构建模—行为竞争—跨域迁移”的统一框架,实现多行为与多领域的深度融合。模型在单域内通过图卷积聚合多行为特征,并以动态行为竞争机制自适应分配权重;在跨域层面,以共享用户为桥梁构建领域竞争机制,依据源域与目标域表示差异调整迁移方向与强度,从而在保持语义一致性的同时实现信息共享与负迁移抑制。在多模态融合方面,已有研究尝试

将多模态信息与多行为建模相结合,以提升推荐系统的表达能力。例如,MMUB-GNN^[170]在微视频推荐中融合图像、音频等多模态数据与多行为信息,设计带注意力机制的异构内容编码器,并借助异构GNN学习用户与物品间的丰富关系;TMF^[166]则提出面向多行为推荐的三模态融合(视觉、文本、图数据)并与LLM对齐的框架。

未来的研究应更注重跨领域行为间的潜在关联建模与多模态信息的深度融合,在多领域、多模态、多粒度的行为数据中挖掘出更多隐含的语义联系,从而提升系统在复杂场景下的灵活性、精度与用户体验。

(6)动态图推荐的探索。动态图能够更真实地反映用户兴趣与交互关系的时间演化。相比静态图,其通过引入时间维度同时建模节点属性与边的动态变化,更好地捕捉用户偏好的时序依赖。在多行为推荐中,用户行为具有时间间隔与顺序特征,引入时间序列模块(如TGAT^[171]、TGN^[172])可使GNN结合历史与当前行为信息,从而生成更精准、个性化的推荐结果。

在动态图推荐中,DGCF^[173]通过零阶继承、一阶传播和二阶聚合三种机制分别建模节点的自演化、交互传播与高阶协同,并结合时间感知损失实现节点嵌入的动态一致性。DGSR^[174]将用户序列转化为时序动态图,利用动态注意力与递归模块联合建模长期与短期偏好,并将下一物品预测视为链路预测任务。DGEL^[175]进一步提出动态图演化学习框架,通过固有交互潜力、时间衰减邻居增强与共生局部结构学习更新动态嵌入,并引入重新缩放增强网络(RENNet)保持嵌入一致性,结合交互匹配与未来预测任务提升时间演化建模能力。

尽管这些基于动态图的推荐方法已经取得了显著进展,但在结合多行为和复杂信息的推荐中,仍然面临诸多挑战。因此,如何在捕捉动态演化的同时,全面考虑多种行为之间的相互作用和依赖关系,仍然是一个需要进一步解决的难题。

(7)隐私保护与公平性。随着大数据与人工智能的发展,用户隐私与伦理问题已成为推荐系统的重要挑战。多行为数据(如浏览、点击、购买等)往往包含敏感信息,若缺乏保护易导致隐私泄露与数据滥用。因此,在保障隐私与保持推荐精度间取得平衡成为关键研究方向。此外,图学习同样面临隐私与安全风险^[176]。

隐私保护技术(如联邦学习^[177]和差分隐私^[178])

为解决这一问题提供了可行的方案:联邦学习允许多终端在不上传原始数据的前提下进行联合训练,从而有效保护隐私;差分隐私通过在数据或梯度中引入噪声,保护个体信息不被泄露^[179]。此外,PF-GNR^[180]提出了面向图神经推荐的隐私保护框架,由本地隐私编码、图神经推荐与隐私安全更新三部分组成。用户首先采用本地差分隐私技术扰动数据,服务器再利用GNN建模用户-物品偏好关系,并通过同态加密保障训练过程安全。该框架在无可信第三方条件下兼顾隐私保护与模型性能,实现了高安全性与可用性的平衡。

除隐私保护外,公平性亦是推荐系统的重要议题。推荐算法可能在不同用户群体间产生偏差,导致部分用户或物品被过度推荐,而其他对象被忽视。为实现公平推荐,模型需在利用敏感特征(如性别、年龄、种族等)时避免歧视性偏差,确保结果公正可解释。同时,应探索个体公平与群体公平的平衡机制,在保障整体公正性的同时兼顾个体层面的推荐多样性与满意度。

此外,在分布式场景下,公平联邦学习同样具有重要意义:通过公平的客户端选择、贡献评估与激励机制,不仅能够在保护隐私的同时缓解数据分布不均问题,还能提升系统的鲁棒性与可信度^[181]。

9 总 结

本文系统性地回顾了基于图神经网络的多行为推荐领域的最新研究进展。从问题定义、方法分类到应用场景分析,详细介绍了多行为推荐系统的关键技术和挑战。具体而言,本文首先明确了多行为推荐的核心任务与技术目标,随后深入讨论了统一编码模式与分解增强模式两大主要方法架构:统一编码模式着重通过分层融合或统一图建模实现行为信息的整体表达,而分解增强模式则强调行为的独立学习,并通过对比或级联等方式融合行为特征。这些方法在捕捉用户兴趣多样性、缓解数据稀疏性问题上均表现出明显优势。此外,本文还从数据集选择、评价指标体系及性能对比分析等方面,客观地展示了当前多行为推荐方法的实际表现与优缺点。进一步,本文总结了当前研究中存在的关键挑战,如行为间的共性与差异建模、依赖关系、负迁移问题、噪声影响以及模型复杂性等,并提出了未来值得深入探索的研究方向。未来研究应着力于构建更深层次的图神经网络结构,融合大语言模型能力以强化

语义理解,加强跨域行为建模、多模态数据融合,以及探索动态图建模方法。此外,如何兼顾推荐的公平性与用户隐私保护,将成为未来推荐系统研究与应用中的关键议题。同时,结合因果推理与自监督学习的多行为建模将为推荐系统的可解释性与泛化能力提供新的发展方向。

总之,随着技术的进一步发展,基于图神经网络的多行为推荐系统将持续提升推荐的准确性与用户体验,在金融风险监控、电子商务、内容推荐与社交网络等领域具有广阔的应用前景与重要的研究价值。

致 谢 本课题得到深圳市科技重大专项项目“基于信创的一体化全球支付清算平台及智能风险监控系统的核心技术研发”(KJZD20230923114809020)、广东省基础与应用基础研究省自然科学基金面上项目(2023A1515011667)、国家重点研发计划(2025YFC3410000)、人工智能与数字经济广东省实验室(深圳)开放课题(GML-KF-24-23)资助。

参 考 文 献

- [1] JIN B, GAO C, HE X, et al. Multi-behavior recommendation with graph convolutional networks//Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. Online, 2020: 659-668
- [2] 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
- [3] ZHAO Z, CHENG Z, HONG L, et al. Improving user topic interest profiles by behavior factorization// Proceedings of the 24th International Conference on World Wide Web. Florence, Italy, 2015: 1406-1416
- [4] 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
- [5] QIU H, LIU Y, GUO G, et al. Bprh: Bayesian personalized ranking for heterogeneous implicit feedback. Information Sciences, 2018, 453: 80-98
- [6] CHEN C, ZHANG M, ZHANG Y, et al. Efficient heterogeneous collaborative filtering without negative sampling for recommendation//Proceedings of the AAAI Conference on Artificial Intelligence: Vol.34. New York, USA, 2020: 19-26
- [7] WU D, LUO X, MA Z, et al. Argo: Modeling heterogeneity in e-commerce recommendation//2021 International Joint Conference on Neural Networks (IJCNN). Shenzhen, China, 2021: 1-8

- [8] WANG X, HE X, WANG M, et al. Neural graph collaborative filtering//Proceedings of the 42nd international ACM SIGIR Conference on Research and Development in Information Retrieval. Paris, France, 2019:165-174
- [9] GU S, WANG X, SHI C, et al. Self-supervised graph neural networks for multi-behavior recommendation. //IJCAI. Vienna, Austria, 2022: 2052-2058
- [10] ZHANG W, MAO J, CAO Y, et al. Multiplex graph neural networks for multi-behavior recommendation// Proceedings of the 29th ACM International Conference on Information & Knowledge Management. Online, 2020: 2313-2316
- [11] XIA L, HUANG C, XU Y, et al. Knowledge-enhanced hierarchical graph transformer network for multi-behavior recommendation//Proceedings of the AAAI Conference on Artificial Intelligence:Vol.35. Vancouver, Canada, 2021: 4486-4493
- [12] 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. Online, 2021:757-766
- [13] YANG H, CHEN H, LI L, et al. Hyper meta-path contrastive learning for multi-behavior recommendation//2021 IEEE International Conference on Data Mining (ICDM). Auckland, New Zealand, 2021: 787-796
- [14] WU Y, XIE R, ZHU Y, et al. Multi-view multi-behavior contrastive learning in recommendation//International Conference on Database Systems for Advanced Applications. Online, 2022: 166-182
- [15] 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
- [16] 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
- [17] XIANGYU Z, 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
- [18] 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
- [19] 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
- [20] YIN Y, ZHU X, WANG W, et al. Hec-gen: Hypergraph enhanced cascading graph convolution network for multi-behavior recommendation. 2024. arXiv:2412.14476
- [21] XIA L, XIE M, XU Y, et al. Mixrec: Heterogeneous graph collaborative filtering//Proceedings of the Eighteenth ACM International Conference on Web Search and Data Mining. Hannover, Germany, 2025:136-145
- [22] CHEN X, LI Z, PAN W, et al. A survey on multi-behavior sequential recommendation.2023.arXiv:2308.15701
- [23] KIM K, KIM S, LEE G, et al. Multi-behavior recommender systems: A survey//Proceedings of the 29th Pacific-Asia Conference on Advances in Knowledge Discovery and Data Mining. Sydney, Australia, 2025: 435-452
- [24] WANG Y, LAM H T, WONG Y, et al. Multi-task deep recommender systems: A survey.2023.arXiv:2302.03525
- [25] 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
- [26] REN X, WEI W, XIAL, et al. A comprehensive survey on self-supervised learning for recommendation.2024. arXiv:2404.03354
- [27] RICCI F, ROKACH L, SHAPIRA B. Introduction to recommender systems. Recommender Systems Handbook, 2011, 532:1-35
- [28] KOREN Y, BELL R, VOLINSKY C. Matrix factorization techniques for recommender systems. Computer, 2009, 42(8): 30-37
- [29] ZHANG S, YAO L, SUN A, et al. Deep learning based recommender system: A survey and new perspectives. ACM Computing Surveys (CSUR), 2019, 52(1):1-38
- [30] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition. Proceedings of the IEEE, 1998, 86(11): 2278-2324
- [31] HOCHREITER S, SCHMIDHUBER J. Long short-term memory. Neural Computation, 1997, 9(8): 1735-1780
- [32] SCARSELLI F, GORI M, TSOI A C, et al. The graph neural network model. IEEE Transactions on Neural Networks, 2008, 20(1): 61-80
- [33] WU Z, PAN S, CHEN F, et al. A comprehensive survey on graph neural networks. IEEE Transactions on Neural Networks and Learning Systems, 2020, 32(1): 4-24
- [34] GILMER J, SCHOENHOLZ S S, RILEY P F, et al. Neural message passing for quantum chemistry//International Conference on Machine Learning. Sydney, Australia, 2017: 1263-1272
- [35] LIU S, XU Y. Multi-behavior enhanced self-supervised graph learning for social recommendation//2024 27th International Conference on Computer Supported Cooperative Work in Design (CSCWD). Tianjin, China, 2024:1092-1097
- [36] WU X, HUANG A, YANG H, et al. Multi-behavior enhanced graph neural networks for social recommendation//Chinese Conference on Pattern Recognition and Computer Vision (PRCV). Xiamen, China, 2023: 40-52
- [37] FU J, ZONG Y, SHEN X, et al. Cmbsr: Contrastive multi-behavior social recommendation via graph neural networks// 2024 China Automation Congress (CAC). Qingdao, China, 2024: 4722-4727
- [38] ZHANG L, ZHANG W, WU L, et al. Shgen: Socially enhanced heterogeneous graph convolutional network for multi-behavior prediction. ACM Transactions on the Web, 2023, 18(1): 1-27

- [39] XUAN H, LIU Y, LI B, et al. Knowledge enhancement for contrastive multi-behavior recommendation//Proceedings of the sixteenth ACM International Conference on Web Search and Data Mining. Singapore, 2023:195-203
- [40] 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
- [41] MENG Z, YI Z, OUNIS I. Knowledge-enhanced multi-behaviour contrastive learning for effective recommendation//Proceedings of the 18th ACM Conference on Recommender Systems. Bari, Italy, 2024:1016-1021
- [42] GUO F, WANG Z. Kemb-rec: Knowledge-enhanced explainable multi-behavior recommendation with graph contrastive learning. IEEE Internet of Things Journal, 2025, 12(4): 3563-3576
- [43] ZHOU S, ZHANG J, CHEN L, et al. Multiple behaviors recommendation with graph learning//2022 IEEE 24th International Workshop on Multimedia Signal Processing (MMSP). Shanghai, China, 2022: 1-6
- [44] PAN X, GAN M. Multi-behavior recommendation based on intent learning. Multimedia Systems, 2023, 29(6):3655-3668
- [45] 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. Taipei, China, 2023: 496-505
- [46] WEI W, HUANG C, XIA L, et al. Contrastive meta learning with behavior multiplicity for recommendation//Proceedings of the fifteenth ACM International Conference on Web Search and Data Mining. Tempe, USA, 2022:1120-1128
- [47] 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
- [48] CHEN C, MA W, ZHANG M, et al. Graph heterogeneous multi-relational recommendation//Proceedings of the AAAI Conference on Artificial Intelligence: Vol. 35. Vancouver, Canada, 2021: 3958-3966
- [49] RANG R, XING L, ZHANG L, et al. Heterogeneous multi-behavior recommendation based on graph convolutional networks. IEEE Access, 2023, 11(2):22574-22584
- [50] LI R, LI Y, LEI J, et al. A multi-behavior recommendation method for users based on graph neural networks. Applied Sciences, 2023, 13(16): 9315
- [51] ZHAO Z, TONG X, WANG Y, et al. Multi-behavior contrastive learning with graph neural networks for recommendation. Knowledge-Based Systems, 2024, 300: 112221
- [52] YANG J, LI X, LI B, et al. Cascading graph contrastive learning for multi-behavior recommendation. Neurocomputing, 2024, 610:128618
- [53] 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
- [54] 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
- [55] LIU X, XIAO W, LIU C, et al. Meta graph network recommendation based on multi-behavior encoding. Journal of King Saud University-Computer and Information Sciences, 2024, 36(5):102050
- [56] 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
- [57] LI Q, MA H, ZHANG R, et al. Intra-and inter-behavior contrastive learning for multi-behavior recommendation//International Conference on Database Systems for Advanced Applications. Tianjin, China, 2023: 147-162
- [58] WU D, LUO X, MA Z, et al. Composition-enhanced graph collaborative filtering for multi-behavior recommendation//2021 IEEE International Conference on Data Mining(ICDM). Auckland, New Zealand, 2021:1427-1432
- [59] YAN M, CHENG Z, SUN J, et al. Mb-hgcn: A hierarchical graph convolutional network for multi-behavior recommendation. 2023. arXiv:2306.10679
- [60] ZHANG Z, JIA Y, HOU Y, et al. Explicit behavior interaction with heterogeneous graph for multi-behavior recommendation. Data Science and Engineering, 2024, 9(2): 133-151
- [61] XIAL, HUANG C, XU Y, et al. Multi-behavior enhanced recommendation with cross-interaction collaborative relation modeling//2021 IEEE 37th International Conference on Data Engineering (ICDE). Chania, Greece, 2021:1931-1936
- [62] FU S, REN Q, LV X, et al. Multi-behavior recommendation with svd graph neural networks. Expert Systems with Applications, 2024, 249(Part A):123575
- [63] WEI Y, MA H, WANG Y, et al. Multi-behavior recommendation with two-level graph attentional networks//International Conference on Database Systems for Advanced Applications. Online, 2022:248-255
- [64] LIU Y, RAO Q, PAN W, et al. Variational collective graph autoencoder for multi-behavior recommendation//2023 IEEE International Conference on Data Mining (ICDM). Shanghai, China, 2023: 438-447
- [65] BIN C, LI W, WU F, et al. Multi-behavior-based graph contrastive learning recommendation. Knowledge and Information Systems, 2024, 66(6): 3477-3496
- [66] JIANG W, DUAN L, DING X, et al. Moro: A multi-behavior graph contrast network for recommendation//Asia-Pacific Web (APWeb) and Web-Age Information Management (WAIM) Joint International Conference on Web and Big Data. Nanjing, China, 2022:117-131
- [67] YU J, JIANG F, DU J, et al. A multi-behavior recommendation based on disentangled graph convolutional networks and contrastive learning//CCF Conference on Computer Supported

- Cooperative Work and Social Computing. Harbin, China, 2023: 195-207
- [68] PENG X, SUN J, YAN M, et al. Attention-guided graph convolutional network for multi-behavior recommendation. Knowledge-Based Systems, 2023, 280: 111040
- [69] WEI Y, MA H, WANG Y, et al. Dual graph attention networks for multi-behavior recommendation. International Journal of Machine Learning and Cybernetics, 2023, 14(8): 2831-2846
- [70] QIAO Z, YAN H, HAN L. Mixmbr: Contrastive learning for multi-behavior recommendation// International Conference on Database Systems for Advanced Applications. Tianjin, China, 2023: 434-445
- [71] LI Q, MA H, ZHANG R, et al. Dual-view co-contrastive learning for multi-behavior recommendation. Applied Intelligence, 2023, 53(17): 20134-20151
- [72] LIU N, MENG S, JIANG Y, et al. Cascading graph convolution contrastive learning networks for multi-behavior recommendation//International Conference on Database Systems for Advanced Applications. Gifu, Japan, 2024: 3-18
- [73] JIANG S, ZHAO C. A cascaded embedding method with graph neural network for multi-behavior recommendation. International Journal of Machine Learning and Cybernetics, 2024, 15(6): 2513-2526
- [74] 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
- [75] 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
- [76] TAN Z, ZENG X, CHEN J, et al. Multi-behavior recommendation with dual channel behavior perception based on graph attention network//CCF Conference on Computer Supported Cooperative Work and Social Computing. Hohhot, China, 2024: 324-339
- [77] LIU H, LU X, ZHOU W, et al. Advancing cascading residual graph convolution networks for multi-behavior recommendation: An innovative approach within representation learning// International Conference on Intelligent Computing. Tianjin, China, 2024: 287-299
- [78] HE J, YANG C, LIU J, et al. Denoising long-tail augmented contrastive network for multi-behavior recommendation. IEEE Access, 2024, 12(2): 177456-177467
- [79] ZHANG Y, BEI Y, YANG S, et al. Alleviating behavior data imbalance for multi-behavior graph collaborative filtering//2023 IEEE International Conference on Data Mining Workshops (ICDMW). Shanghai, China, 2023:528-532
- [80] 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
- [81] LIU T, ZHOU H, LI C, et al. Self-supervised progressive graph neural network for enhanced multi-behavior recommendation. International Journal of Machine Learning and Cybernetics, 2025, 16(3): 1573-1588
- [82] RONG M, HAN Y, ZHANG J, et al. A behavior relation-aware graph contrastive networks for multi-behavior recommendation// 2024 IEEE 6th Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC): Vol. 6. Chongqing, China, 2024: 1663-1670
- [83] 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
- [84] LAN W, ZHOU G, CHEN Q, et al. Contrastive clustering learning for multi-behavior recommendation. ACM Transactions on Information Systems, 2024, 43(1):1-23
- [85] Li Qing-Feng, Jin Liu, Ma Hui-Fang, et al. Dual-view contrastive learning guided multi-behavior recommendation method. Computer Engineering and Science, 2024, 46(04): 707-715 (in Chinese)
(李清风, 金柳, 马慧芳, 等. 双视图对比学习引导的多行为推荐方法. 计算机工程与科学, 2024, 46(04):707-715)
- [86] Yan Ming-Shi, Cheng Zhi-Yong, Sun Jing, et al. Multi-behavior recommendation based on two-stage learning. 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)
- [87] Gao Yu-Lan, Huang Xian-Ying, Tao Jia. Multi-behavior recommendation model based on lightweight graph convolution and attention enhancement. Application Research of Computers, 2022, 39(06): 1753-1759 (in Chinese)
(高钰澜, 黄贤英, 陶佳. 基于轻量图卷积和注意力增强的多行为推荐模型. 计算机应用研究, 2022, 39(06): 1753-1759)
- [88] GONG S, LIU Y, DANG Y, et al. Multiple purchase chains with negative transfer elimination for multi-behavior recommendation//Proceedings of the AAAI Conference on Artificial Intelligence: Vol. 39. Philadelphia, USA, 2025:11717-11725
- [89] YAN M, CHENG Z, LIU F, et al. User invariant preference learning for multi-behavior recommendation. ACM Transactions on Information Systems, 2025, 43(4): 110(1-24)
- [90] 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
- [91] ZHANG X, ZHANG L, BI X, et al. Tkmb: Temporal knowledge graph-based multi-behavior recommendation//2024 International Joint Conference on Neural Networks (IJCNN). Yokohama, Japan, 2024:1-8
- [92] WEI C, HU C, WANG C D, et al. Time-aware multibehavior contrastive learning for social recommendation. IEEE Transactions on Industrial Informatics, 2024, 20(4): 6424-6435
- [93] LI X, WANG N, LIU X, et al. Time-based knowledge-aware framework for multi-behavior recommendation. Expert Systems with Applications, 2025, 273:126840
- [94] MU X, ZENG Z, SHEN D, et al. Multi-feature behavior relationship for multi-behavior recommendation. Applied Sciences, 2022, 12(24): 12909

- [95] Lu Jia-Wei, Li Duan-Ni, Wang Ce-Ce, et al. Multi-behavior aware service recommendation method based on hypergraph convolutional neural network. *Journal of Zhejiang University (Engineering Science)*, 2023, 57(10): 1977-1986 (in Chinese)
(陆佳伟, 李端倪, 王策策, 等. 基于超图卷积神经网络的多行为感知服务推荐方法. *浙江大学学报(工学版)*, 2023, 57(10):1977-1986)
- [96] Gu Jun-Hua, Li Ning-Ning, Wang Xin-Xin, et al. Personalized recommendation model integrating behavior dependency into multi-task learning. *Journal of Frontiers of Computer Science and Technology*, 2024, 18(01): 231-243 (in Chinese)
(顾军华, 李宁宁, 王鑫鑫, 等. 将行为依赖融入多任务学习的个性化推荐模型. *计算机科学与探索*, 2024, 18(01): 231-243)
- [97] CHOI J, KWON J, KIM Y, et al. Hypergraph temporal multi-behavior recommendation. *Engineering Applications of Artificial Intelligence*, 2025, 145:110112
- [98] XU W, LI H, WANG M. Multi-behavior guided temporal graph attention network for recommendation//*Pacific-Asia Conference on Knowledge Discovery and Data Mining*. Osaka, Japan, 2023: 297-309
- [99] XUAN H, LI B. Temporal-aware multi-behavior contrastive recommendation//*International Conference on Database Systems for Advanced Applications*. Tianjin, China, 2023: 269-285
- [100] WEI W, XIA L, HUANG C. Multi-relational contrastive learning for recommendation//*Proceedings of the 17th ACM Conference on Recommender Systems*. Singapore, Singapore, 2023: 338-349
- [101] ZHU W, XIE Y, HUANG Q, et al. Graph transformer collaborative filtering method for multi-behavior recommendations. *Mathematics*, 2022, 10(16): 2956
- [102] HOGAN A, BLOMQUIST E, COCHEZ M, et al. Knowledge graphs. *ACM Computing Surveys (Csur)*, 2021, 54(4):1-37
- [103] LI H, CHENG Z, YU X, et al. Behavior pattern mining-based multi-behavior recommendation//*Proceedings of the 47th International ACM SIGIR Conference on Research and Development in Information Retrieval*. Washington, USA, 2024: 2291-2295
- [104] ZHANG H, SHEN C, SUN X, et al. Hierarchical graph information bottleneck for multi-behavior recommendation//*Proceedings of the Nineteenth ACM Conference on Recommender Systems*. Prague, Czech Republic, 2025:155-164
- [105] CHEN Y, CAO J, WANG Y, et al. Causal variational inference for deconfounded multi-behavior recommendation. *ACM Transactions on Information Systems*, 2025, 43(6): 1-26
- [106] HE X, DENG K, WANG X, et al. Lightgcn: Simplifying and powering graph convolution network for recommendation//*Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval*. Online, 2020: 639-648
- [107] 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
- [108] KIPF T N, WELING M. Variational graph auto-encoders. *CoRR*, 2016, abs/1611.07308
- [109] KINGMA D P, WELING M. Auto-encoding variational bayes. *CoRR*, 2013, abs/1312.6114
- [110] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need//*Advances in Neural Information Processing Systems 30 (NeurIPS 2017)*. Long Beach, USA, 2017
- [111] XIA L, HUANG C, XU Y, et al. Multiplex behavioral relation learning for recommendation via memory augmented transformer network//*Proceedings of the 43rd international ACM SIGIR Conference on Research and Development in Information Retrieval*. Online, 2020: 2397-2406
- [112] POPESCU M C, BALAS V E, PERESCU-POPESCU L, et al. Multilayer perceptron and neural networks. *WSEAS Transactions on Circuits and Systems*, 2009, 8 (7): 579-588
- [113] ZHANG S, CHU H, LI J, et al. Dembr: Denoising model with memory pruning and semantic guidance for multi-behavior recommendation//*Proceedings of the Eighteenth ACM International Conference on Web Search and Data Mining*. Hannover, Germany, 2025: 521-529
- [114] FAN M, FAN Y, DU Y, et al. Interest transfer graph convolutional networks for multi-behavior recommendation. *Neurocomputing*, 2025, 648: 130659
- [115] CHEN H, LI Z, BEI Y, et al. Behavior merging graph convolution network for multi-behavior recommendation. *IEEE Transactions on Knowledge and Data Engineering*, 2025
- [116] Qian Zhong-Sheng, Huang Heng, Wan Zi-Long. 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)
- [117] ZHENG J, LI J, HUANG M. Personalized anchor debiased-contrastive learning for multi-behavior recommendation. *Expert Systems with Applications*, 2025, 286: 127685
- [118] YU X, DING P, YU J, et al. Multi-behavioral recommendation algorithm based on decoupled graph convolution. *Expert Systems with Applications*, 2026, 298: 129618
- [119] Fan Wei, Zhou Wei, Wen Jun-Hao. Dual-channel cross-adaptive contrastive learning recommendation based on heterogeneous graph. *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)
- [120] WAN M, MCAULEY J. Item recommendation on monotonic behavior chains//*Proceedings of the 12th ACM Conference on Recommender Systems*. Vancouver, Canada, 2018: 86-94
- [121] HUSSAIN M S, ZAKIM J, SUBRAMANIAND. Global self-attention as a replacement for graph convolution// *Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. Washington, USA, 2022: 655-665
- [122] KUMAR C, ABUZAR M, KUMAR M. Mgu-gnn: Minimal gated unit based graph neural network for session-based recommendation. *Applied Intelligence*, 2023, 53(20): 23147-

- 23165
- [123] CAI W, ZHENG Z, ZHANG X, et al. Neighborhood structure enhancement and denoising method for multi-behavior recommendation. *Neural Networks*, 2025, 191(2): 107760
- [124] BIAN Z, ZHOU S, FU H, et al. Denoising user-aware memory network for recommendation//Proceedings of the 15th ACM Conference on Recommender Systems. Amsterdam, Netherlands, 2021: 400-410
- [125] ZHOU C, BAI J, SONG J, et al. Atrank: An attention-based user behavior modeling framework for recommendation//Proceedings of the AAAI Conference on Artificial Intelligence. New Orleans, Louisiana, Vol. 32. 2018
- [126] XU K, HU W, LESKOVEC J, et al. How powerful are graph neural networks?. 2018. arXiv:1810.00826.
- [127] SCHLICHTKRULL M, KIPF T N, BLOEM P, et al. Modeling relational data with graph convolutional networks//Lecture Notes in Computer Science: Vol. 10843 The Semantic Web: 15th International Conference, ESWC 2018. Heraklion, Greece, 2018:593-607
- [128] FENG Y, YOU H, ZHANG Z, et al. Hypergraph neural networks//Proceedings of the AAAI Conference on Artificial Intelligence. Honolulu, USA, 2019, 33(01): 3558-3565
- [129] JÄRVELIN K, KEKÄLÄINEN J. Ir evaluation methods for retrieving highly relevant documents. *SIGIR Forum*, 2017, 51(2):243-250
- [130] BREESE J S, HECKERMAN D, KADIE C. Empirical analysis of predictive algorithms for collaborative filtering//Proceedings of the Fourteenth Conference on Uncertainty in Artificial Intelligence (UAI'98). Morgan Kaufmann Publishers Inc. Madison, Wisconsin, 1998: 43-52
- [131] RENDLE S, FREUDENTHALER C, GANTNER Z, et al. BPR: Bayesian personalized ranking from implicit feedback//Proceedings of the Twenty-Fifth Conference on Uncertainty in Artificial Intelligence (UAI'09). Montreal, Canada, 2009: 452-461
- [132] YING R, HE R, CHEN K, et al. Graph convolutional neural networks for web-scale recommender systems//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. London, UK, 2018: 974-983
- [133] WU J, WANG X, FENG F, et al. Self-supervised graph learning for recommendation//Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. Online, 2021: 726-735
- [134] HU Z, DONG Y, WANG K, et al. Heterogeneous graph transformer//Proceedings of The Web Conference 2020. Online, 2020: 2704-2710
- [135] WEN H, LIU X, YAN C, et al. Leveraging multiple implicit feedback for personalized recommendation with neural network//Proceedings of the 2019 International Conference on Artificial Intelligence and Advanced Manufacturing. Dublin, Ireland, 2019: 1-6
- [136] GUO L, HUA L, JIA R, et al. Buying or browsing?: Predicting real-time purchasing intent using attention-based deep network with multiple behavior//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. Anchorage, USA, 2019: 1984-1992
- [137] MA J, ZHAO Z, YI X, et al. Modeling task relationships in multi-task learning with multi-gate mixture-of-experts//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. Anchorage, USA, 2018: 1930-1939
- [138] LI G, MULLER M, THABET A, et al. Deepgcn: Can gcn be as deep as cnns?//Proceedings of the IEEE/CVF International Conference on Computer Vision. Seoul, Republic of Korea, 2019: 9267-9276
- [139] RONG Y, HUANG W, XU T, et al. Dropedge: Towards deep graph convolutional networks on node classification. 2019. arXiv:1907.10903
- [140] LAI K H, ZHA D, ZHOU K, et al. Policy-gnn: Aggregation optimization for graph neural networks//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. San Diego, USA, 2020: 461-471
- [141] CHEN J, MA T, XIAO C. Fastgcn: Fast learning with graph convolutional networks via importance sampling. 2018. arXiv:1801.10247
- [142] ZHOU K, HUANG X, LI Y, et al. Towards deeper graph neural networks with differentiable group normalization//Advances in Neural Information Processing Systems 33 (NeurIPS 2020). Vancouver, Canada, 2020: 4917-4928
- [143] SHAO Y, LI H, GU X, et al. Distributed graph neural network training: A survey. *ACM Computing Surveys*, 2024, 56(8):1-39
- [144] CHIANG W L, LIU X, SI S, et al. Cluster-gcn: An efficient algorithm for training deep and large graph convolutional networks//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. Anchorage, USA, 2019: 257-266
- [145] FRASCA F, ROSSI E, EYNARD D, et al. Sign: Scalable inception graph neural networks. 2020. arXiv:2004.11198
- [146] FENG B, WANG Y, LI X, et al. Sgquant: Squeezing the last bit on graph neural networks with specialized quantization//2020 IEEE 32nd International Conference on Tools with Artificial Intelligence (ICTAI). Baltimore, USA, 2020: 1044-1052
- [147] ZHENG D, MA C, WANG M, et al. Distdgl: Distributed graph neural network training for billion-scale graphs//2020 IEEE/ACM 10th Workshop on Irregular Applications: Architectures and Algorithms (IA3). Georgia, USA, 2020: 36-44
- [148] MD V, MISRA S, MA G, et al. Distgcn: Scalable distributed training for large-scale graph neural networks//Proceedings of the International Conference for High Performance Computing, Networking, Storage and Analysis. Georgia, USA, 2021: 1-14
- [149] SONG J, JANG H, JUNG J, et al. Grandis: Efficient unified distributed training framework for deep GNNs on large clusters. 2023. arXiv:2311.06837
- [150] FEY M, LENSSEN J E. Fast graph representation learning with pytorch geometric. 2019. arXiv:1903.02428
- [151] WANG M, ZHENG D, YE Z, et al. Deep graph library: A

- graph-centric, highly-performant package for graph neural networks. 2019. arXiv:1909.01315
- [152] ZHU R, ZHAO K, YANG H, et al. Aligraph: A comprehensive graph neural network platform. 2019. arXiv:1902.08730
- [153] LIN D, SUN S, DING J, et al. Platogl: Effective and scalable deep graph learning system for graph-enhanced real-time recommendation//Proceedings of the 31st ACM International Conference on Information & Knowledge Management. Georgia, USA, 2022: 3302-3311
- [154] YOU Y, CHEN T, SHEN Y, et al. Graph contrastive learning automated//International Conference on Machine Learning. Boston, USA, 2021: 12121-12132
- [155] GARG V, JEGELKA S, JAAKKOLA T. Generalization and representational limits of graph neural networks// International Conference on Machine Learning. Online, 2020: 3419-3430
- [156] XIA L, KAO B, HUANG C. Opengraph: Towards open graph foundation models. 2024. arXiv:2403.01121
- [157] REN X, TANG J, YIN D, et al. A survey of large language models for graphs//Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. Barcelona, Spain, 2024: 6616-6626
- [158] YER, ZHANG C, WANG R, et al. Language is all a graph needs//Findings of the Association for Computational Linguistics: EACL 2024. St. Julian's, Malta: Association for Computational Linguistics, 2024:1955-1973
- [159] WANG H, FENG S, HE T, et al. Can language models solve graph problems in natural language?// Proceedings of the 37th International Conference on Neural Information Processing Systems: Vol. 36. New Orleans, USA, 2023:30840-30861
- [160] TANG J, YANG Y, WEI W, et al. Graphgpt: Graph instruction tuning for large language models//Proceedings of the 47th International ACM SIGIR Conference on Research and Development in Information Retrieval. Washington, USA, 2024: 491-500
- [161] CHAI Z, ZHANG T, WU L G, et al. Graphllm: Boosting graph reasoning ability of large language model. 2023. arXiv: 2310.05845
- [162] FLORIDI L, CHIRIATTI M. Gpt-3: Its nature, scope, limits, and consequences. *Minds and Machines*, 2020, 30: 681-694
- [163] ZHAO W X, ZHOU K, LI J, et al. A survey of large language models. 2023. arXiv:2303.18223
- [164] WU L, ZHENG Z, QIU Z, et al. A survey on large language models for recommendation. *World Wide Web*, 2024, 27(5): 60
- [165] ZHAO Z, FAN W, LI J, et al. Recommender systems in the era of large language models (LLMs). *IEEE Transactions on Knowledge and Data Engineering*, 2024, 36(11): 6889-6907
- [166] MA L, LI X, FAN Z, et al. Triple modality fusion: Aligning visual, textual, and graph data with large language models for multi-behavior recommendations. 2024. arXiv:2410.12228
- [167] HONG M, XIA Y, WANG Z, et al. Eager-llm: Enhancing large language models as recommenders through exogenous behavior-semantic integration//Proceedings of the ACM on Web Conference 2025. Sydney, Australia, 2025:2754-2762
- [168] XIE R, LIU Q, WANG L, et al. Contrastive cross-domain recommendation in matching//Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. Washington, USA, 2022: 4226-4236
- [169] ZHANG L, ZHANG W, WU L, et al. Gctn: Graph competitive transfer network for cross-domain multi-behavior prediction. *IEEE Transactions on Knowledge and Data Engineering*, 2025, 37(7): 4075-4088
- [170] ZHANG W, TIAN B, WANG T, et al. Research on micro-videos recommendation method integrating multimodal data and user multi-behavior//International Conference on Web Information Systems Engineering. Doha, Qatar, 2024: 3-16
- [171] XU D, RUAN C, KORPEOGLU E, et al. Inductive representation learning on temporal graphs. 2020. arXiv: 2002.07962
- [172] ROSSI E, CHAMBERLAIN B, FRASCA F, et al. Temporal graph networks for deep learning on dynamic graphs. 2020. arXiv:2006.10637
- [173] LI X, ZHANG M, WU S, et al. Dynamic graph collaborative filtering//2020 IEEE International Conference on Data Mining (ICDM). Sorrento, Italy, 2020:322-331
- [174] ZHANG M, WU S, YU X, et al. Dynamic graph neural networks for sequential recommendation. *IEEE Transactions on Knowledge and Data Engineering*, 2022, 35(5): 4741-4753
- [175] TANG H, WU S, XU G, et al. Dynamic graph evolution learning for recommendation//Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval. Taipei, China, 2023: 1589-1598
- [176] Xian Xing-Ping, Wu Tao, Qiao Shao-Jie, et al. A survey on privacy and security issues in graph learning. *Chinese Journal of Computers*, 2023, 46(06): 1184 - 1212 (in Chinese)
(先兴平, 吴涛, 乔少杰, 等. 图学习隐私与安全问题研究综述. *计算机学报*, 2023, 46(06): 1184-1212)
- [177] MCMAHAN B, MOORE E, RAMAGE D, et al. Communication-efficient learning of deep networks from decentralized data//Artificial Intelligence and Statistics. Florida, USA, 2017: 1273-1282
- [178] DWORK C. Differential privacy//International Colloquium on Automata, Languages, and Programming. Venice, Italy, 2006: 1-12
- [179] Wang Yong, Luo Chen-Hong, Deng Jiang-Zhou, et al. Local differential privacy matrix factorization recommendation algorithm based on objective perturbation. *Chinese Journal of Computers*, 2025, 48(02): 451 - 462 (in Chinese)
(王永, 罗陈红, 邓江洲, 等. 基于目标扰动的本地化差分隐私矩阵分解推荐算法. *计算机学报*, 2025, 48(02): 451-462)
- [180] Wang Kun, Wang Yong, Zhang Zhi-Qiang, et al. A privacy-preserving graph neural network for recommender systems. *Chinese Journal of Computers*, 2025, 48(05): 1116-1133 (in Chinese)
(王锷, 王永, 张智强, 等. 一种面向推荐系统的隐私保护图神经网络. *计算机学报*, 2025, 48(05):1116-1133)
- [181] Gu Tian-Long, Li Long, Chang Liang, et al. A survey on fair

federated learning and its design. *Chinese Journal of Computers*, 2023, 46(9): 1991-2024. (in Chinese)

(古天龙, 李龙, 常亮, 等. 公平联邦学习及其设计研究综述. *计算机学报*, 2023, 46(9): 1991-2024)



CHENG Ying-Chao, Ph. D., research fellow. His current research interests include brain-inspired AI, data spaces, and distributed computing.

WU Gan-Sheng, M. S. candidate. His main research interests include graph neural networks and spiking neural networks.

HE Yu-Lin, Ph. D., research fellow. His current

research interests include semi-supervised learning, imbalanced learning, Bayesian classifier construction, probability density estimation, and approximate computing technologies for big data.

HUANG Zhe-Xue, Ph. D., professor. His current research interests include big data technology and applications and data mining.

CHEN Bing-Feng, Ph. D., senior engineer. His research interests include machine learning, data mining, and natural language processing.

Background

This paper provides a comprehensive review of recent advances in personalized recommender systems, emphasizing the application of graph neural networks (GNNs) to multi-behavior user modeling. Personalized recommender systems play a pivotal role in alleviating information overload by precisely capturing user preferences and interactions. Multi-behavior modeling incorporates various user interactions such as browsing, clicking, adding items to carts, and purchasing, enabling a more holistic representation of user interests.

Graph neural networks have emerged as a leading methodology due to their superior capacity to represent complex relational structures within user-item interactions. Despite substantial progress, GNN-based multi-behavior recommender systems continue to face critical challenges, including effectively distinguishing different behavior types, accurately capturing behavior dependencies, mitigating data sparsity, and managing noisy interaction data.

This survey systematically summarizes current methodologies, identifies key challenges, and discusses future research directions such as deeper GNN architectures,

integration with large language models, cross-domain behavior modeling, multi-modal data fusion, dynamic graph techniques, as well as privacy preservation and fairness in recommendations. The authors have published several high-quality research papers in this domain, contributing significantly to its advancement.

The research context of this survey is anchored in the “Intelligent Risk Monitoring System for Payment Clearing Platforms”-Science and Technology Major Project of Shenzhen (KJZD20230923114809020). This project leverages cutting-edge AI and graph neural network methodologies to enhance anomaly detection and fraud prevention within financial transaction systems. By synthesizing recent advancements in multi-behavior recommendation, this review supports the project’s overarching goal of building robust and intelligent risk monitoring frameworks, thereby ensuring the security and reliability of financial transactions. Besides, this work was supported in part by the Natural Science Foundation of Guangdong Province (2023A1515011667) and Guangdong Basic and Applied Basic Research Foundation (2023B1515120020).