

MB-HGCN: 基于层次图卷积网络的多行为推荐方法

严明时¹ 陈慧临² 程志勇² 韩亚洪¹

¹(天津大学智能与计算学部 天津 300354)

²(合肥工业大学计算机与信息学院 合肥 230002)

(neo.ms.yan@gmail.com)

MB-HGCN: Hierarchical Graph Convolutional Network Based Multi-Behavior Recommendation Method

Yan Mingshi¹, Chen Huilin², Cheng Zhiyong², and Han Yahong¹

¹(College of Intelligence and Computing, Tianjin University, Tianjin 300354)

²(School of Computer Science and Information Engineering, Hefei University of Technology, Hefei 230002)

Abstract Collaborative filtering-based recommender systems that only rely on single-behavior data often encounter serious sparsity problems in practical applications, resulting in poor performance. Multi-behavior recommendation (MBR) is a method that seeks to learn user preferences, represented as vector embeddings, from auxiliary behavior interaction data. By leveraging these preferences for target behavior recommendations, MBR can mitigate the data sparsity challenge and enhance predictive precision for recommendations. We introduce MB-HGCN, a novel recommendation method designed to exploit multi-behavior data. The method leverages a hierarchical graph convolutional network to learn user and item embeddings from a coarse-grained global level to a fine-grained behavior-specific level. Our method learns global embeddings from a unified homogeneous graph constructed by the interactions of all behaviors, which are then used as initialized embeddings for behavior-specific embedding learning in each behavior graph. Moreover, we also emphasize the distinct of the user and item behavior-specific embeddings and design two simple-yet-effective strategies to aggregate the behavior-specific embeddings for users and items, respectively. Finally, we adopt multi-task learning for optimization. Extensive experimental results on three real-world benchmark datasets show that MB-HGCN can substantially outperform the state-of-the-art methods, achieving a relative improvement of 73.93% and 74.21% for $HR@10$ and $NDCG@10$, respectively, on Tmall dataset.

Key words hierarchical graph convolutional; collaborative filtering; multi-behavior recommendation (MBR); graph convolutional network; multi-task learning

摘要 基于协同过滤 (collaborative filtering, CF) 的单行为推荐系统在实际应用中经常面临严重的数据稀疏性问题, 从而导致性能不理想. 多行为推荐 (multi-behavior recommendation, MBR) 旨在利用辅助行为数据来帮助学习用户偏好, 以缓解数据稀疏性问题并提高推荐精度. MBR 的核心在于如何从辅助行为中学习用户偏好 (表示为向量表征), 并将这些信息用于目标行为推荐. 介绍了一种旨在利用多行为数据的新推荐方法 MB-HGCN (hierarchical graph convolutional network for multi-behavior recommendation). 该方法通过从全局层面的粗粒度 (即全局向量表征) 到局部层面的细粒度 (即行为特定向量表征) 来学习用户和物品的向量表征. 全局向量表征是从所有行为交互构建的统一同构图中学习得到的, 并作为每个

收稿日期: 2024-10-10; 修回日期: 2025-03-28

基金项目: 国家自然科学基金项目 (62376186, 61932009, 6227225)

This work was supported by the National Natural Science Foundation of China (62376186, 61932009, 6227225).

通信作者: 韩亚洪 (yahong@tju.edu.cn)

行为图中行为特定向量表征学习的初始化向量表征. 此外, MB-HGCN 还强调了用户和物品在行为特定表征上的差异, 并设计了 2 种简单但有效的策略来分别聚合用户和物品的行为特定表征. 最后, 采用多任务学习进行优化. 在 3 个真实数据集上的实验结果表明, 所提方法显著优于基准方法, 尤其是在 Tmall 数据集上, MB-HGCN 在 $HR@10$ 和 $NDCG@10$ 指标上分别实现了 73.93 个百分点和 74.21 个百分点的性能提升.

关键词 分层图卷积; 协同过滤; 多行为推荐; 图卷积网络; 多任务学习

中图法分类号 TP391

DOI: 10.7544/issn1000-1239.202440770 **CSTR:** 32373.14.issn1000-1239.202440770

个性化推荐是解决信息过载问题最有效的技术之一, 在各种信息系统中得到了广泛应用. 由于其简单性和有效性, 协同过滤(collaborative filtering, CF)^[1]已成为当前推荐系统的主流方法. 在过去几十年中, 研究并提出了许多基于 CF 的方法, 从早期的基于矩阵分解(matrix factorization, MF)^[2-3]的方法, 到基于深度神经网络(deep neural network, DNN)^[4-5]的方法, 再到最近出现的基于图神经网络(graph neural network, GNN)^[6-8]的方法. 推荐技术的快速发展极大地提升了方法的推荐性能. 然而, 由于基于 CF 的方法主要依赖用户与物品之间的交互来学习用户偏好并进行推荐, 所以这些方法在可用交互数据稀疏时性能会急剧下降, 这是其固有的限制.

大多数现有的基于 CF 的方法仅考虑用单一行为进行建模, 通常是平台上的目标行为, 例如电子商务平台上的购买行为. 然而, 在现实世界的系统中, 这种行为数据往往非常稀疏, 导致这些方法存在严重的稀疏性问题. 实际上, 在用户做出最终决策(即进行目标行为)之前, 往往会发生多种类型的行为(例如浏览和收藏), 通过与物品的互动生成相关信息. 这些行为也包含有价值的用户偏好信息, 并且它们的交互信息通常比目标行为更丰富. 因此, 可以利用这些辅助行为来帮助挖掘用户偏好, 从而缓解数据稀疏性问题.

利用辅助行为来促进目标行为推荐的方法被称为多行为推荐(multi-behavior recommendation, MBR)^[9-10]. MBR 方法近年来受到了极大关注, 其核心在于如何利用辅助行为的信息来帮助学习用户和物品的表征. 早期的方法尝试将矩阵分解方法从单个矩阵场景扩展到多矩阵场景, 或者使用不同的采样策略, 用辅助行为数据丰富训练数据. 随着越来越多的研究证明了 MBR 的有效性, 它吸引了更多的关注, 并且最近引入了更先进的技术来处理这一任务. 例如, 文献[11]将 DNN 用于建模行为序列, 而文献[12]采用多头注意力机制来建模多个行为. 此外, 基于图卷积网

络(graph convolutional network, GCN)的方法采用各种策略在由所有行为构建的统一图上学习用户偏好. 文献[13]构建了一个异构图, 用不同的边区分不同类型的行为, 分别对每种行为进行建模, 然后根据其预测的重要性聚合用户表征.

MBR 方法的基本假设是用户各种行为的交互数据从不同角度或程度上反映了用户的偏好信息. 现有基于 DNN 或 GNN 的 MBR 方法中, 常见的范式是使用特定策略(例如, 包含或不包含注意力机制)将从各种行为数据构建的网络中学习到的表征进行整合, 以用于预测目标行为. 不同方法的区别在于如何设计网络结构以从不同行为中学习更优的表征, 以及如何从每种行为中提取有价值的信息. 现有的 MBR 方法并未考虑对初始化表征的预处理, 而是直接将初始化表征共享于多个行为中, 这可能面临因行为间信息不一致而导致的次优表现. 此外, 现有的方法将用户表征与物品表征同等对待, 并未考虑用户在不同行为中表现出不同的偏好, 而物品的特征不应随行为的变化而变化这一事实.

为了应对上述挑战, 本文设计了一种基于分层图卷积网络(hierarchical graph convolutional network for multi-behavior recommendation, MB-HGCN)的 MBR 方法, 以利用辅助行为进行用户和物品表征的学习. 与现有的直接从统一的异图中学习用户和物品表征的基于 GCN 的方法不同^[14], MB-HGCN 方法采用了一种创新的分层网络结构进行表征学习. 与传统方法不同, 该方法提出了一种新的范式. 具体而言, MB-HGCN 首先通过合并所有行为的交互记录, 构建了一个统一的同构图, 用于学习全局用户和物品的表征. 这一设计的核心目的是通过学习一种统一的粗粒度的用户偏好表征, 捕捉用户的基本偏好信息, 而不依赖于特定行为类型的细粒度差异. 尽管这种全局表征的粒度较粗, 可能无法精确区分各行为类型的偏好特征, 但它能够为后续每个行为特定图提供有效的初始化输入, 确保后续的学习过程的全局一

致性,从而有助于加速模型的训练并提高收敛速度.在全局表征学习阶段,MB-HGCN通过在包含所有行为交互信息的统一同构图上执行图卷积操作,全面整合所有行为数据,进而学习到用户和物品的全局表征.虽然该全局表征所表示的用户偏好相对宽泛且模糊,但其重要优势在于,作为初始化输入,它为每个行为特定图中的表征学习提供了强有力的支持,从而不仅加速了模型训练过程,还有效缓解了每个行为图中的数据稀疏问题.随着训练的深入,通过专门优化每个行为图,逐步捕捉与该行为相关的细粒度特征.这一层次化的学习机制,不仅能提升推荐的准确性,还能更好地捕捉用户在不同情境下的偏好,从而最终提升推荐系统的整体效果.

在2层表征学习之后,采用了2种不同的策略分别对用户和物品的行为特定表征进行聚合.具体地,对于用户表征,为了从不同行为中提取有效的信息用于目标行为预测,依据行为特定表征与目标行为特定表征的相似度为行为特定表征分配权重.直观上,2个表征越相似,它们对目标行为的贡献越大.对于物品表征,采用了基于不同行为的交互数量的加权方案^[13].这一设计背后的原理是物品特征在不同行为之间应该是一致的,而从不同行为中学习到物品表征的差异是由不同用户的交互引起的.最后,将全局表征和聚合的行为特定表征结合起来,以得到更全面的表示.通过采用多任务学习方法,将每个行为视为一个独立的任务进行优化.在3个真实数据集上对MB-HGCN进行了全面评估,以验证其有效性.实验结果表明,本文所提出的方法在 $HR@10$ 和 $NDCG@10$ 这2个指标上相对于最佳基线有显著改进.在Tmall数据集上,MB-HGCN分别相对于最优基线取得了73.93个百分点和74.21个百分点的性能提升.此外,本文还进行了全面的消融研究,详细验证了每个组件的有效性.

综上所述,本文研究的主要贡献包括:

1)提出了一种用于多行为推荐的分层卷积图网络.该网络首先在统一图的全局层面以粗粒度方式学习用户和物品表征,然后在每个行为图中以细粒度方式进行行为特定表征学习.这种学习模式可以更有效地利用多行为信息,并生成高质量的用户和物品表征.

2)强调了用户和物品行为特定表征的独特性,为此设计了2种简单而有效的聚合策略,分别用于

聚合用户和物品的行为特定表征.这与使用相同聚合机制的主流聚合方法有很大不同.

3)在3个真实数据集上进行了大量实验来评估MB-HGCN方法的有效性.结果表明,与最先进的方法相比,MB-HGCN在推荐精度方面取得了显著提高.此外,代码和所涉及参数也已发布在GitHub^①中,以供其他研究人员使用和参考.

1 相关工作

1.1 多行为推荐(MBR)方法

MBR涉及利用多种类型的用户-物品交互数据进行推荐^[11,13,15],其优势在于缓解了单一行为推荐方法中存在的数据稀疏性问题.近年来,这种方法取得了显著的成效,并引起了广泛关注.

早期的MBR方法扩展了传统的基于CF的方法^[16-19].最直接的方式是将单行为数据中的矩阵分解方法应用到多行为数据中.例如,Zhao等人^[16]扩展了集体矩阵分解方法,对不同行为分别进行矩阵分解,并在它们之间共享物品表征.此外,一些研究者设计了不同的采样策略以利用多行为数据.例如:Ding等人^[17]提出了一种改进的负采样策略,以达到更好的数据利用率,并进一步扩展了该思想;Guo等人^[18]提出了一种采样策略,根据相似性从多个辅助行为中生成正样本和负样本;Qiu等人^[19]提出了一种新颖的采样策略,基于不同行为之间样本的不相关平衡特性实现自适应采样.这些方法通过利用辅助行为的交互数据来补充对目标行为的训练,从而增强了多行为推荐的性能.

随着深度学习的发展,基于DNN的MBR算法逐渐被提出^[11-12,20].这类方法的主要思想是设计DNN,分别从每个行为中学习用户和物品的表征,然后对它们进行聚合以用于推荐.这些方法的区别主要体现在DNN的设计和聚合策略上.例如:Gao等人^[11]采用了顺序建模方法,通过将当前行为的预测分数向前传递来探索不同行为之间的依赖关系;Xia等人^[12]设计了一个由Transformer和多头注意力机制组成的网络,以学习每个行为中的表征,然后通过采用全连接网络进行聚合;Guo等人^[20]提出了一种层次化注意力机制,用于聚合从不同行为中学习到的用户偏好.与其他将从不同行为中学习到的信息进行聚合的方法不同,DNN在表示学习方面的优势使得基于DNN

① <https://github.com/MingshiYan/MB-HGCN>

的 MBR 方法在提升推荐性能上取得了巨大进展。

由于 GCN 建模非结构化数据方面的出色性能,涌现出了许多基于 GCN 的 MBR 方法^[9,21-24]。这类方法的一般范式是使用 GCN 单独对每个行为进行建模,以学习用户和物品的表征,然后采用不同的策略对其进行聚合。例如: Xia 等人^[21]提出了一种图元网络,将多行为与元学习范式相结合,以对多个行为之间的异构性和多样性进行建模; Gu 等人^[22]设计了不同的策略来单独聚合多行为用户和物品的表征,并采用星形对比学习来捕捉目标行为和辅助行为之间的共性; Cheng 等人^[9]设计了不同行为图网络的级联结构,通过在消息传递过程中引入可学习权重,不断细化用户的偏好。另外一些方法将 GCN 作为挖掘协同信息的骨干网络,在此基础上进行更加精细化的偏好学习。例如: Yan 等人^[23]设计了一个 3 层过滤网络,从 GCN 输出中提取更加细化的用户偏好; Xu 等人^[24]引入对比学习框架对 GCN 提取的协同信息进行去噪。

与上述研究不同,本文提出了一种新的分层图卷积网络结构,通过采用不同的范式来挖掘多行为数据中用户和物品表征。该方法首先从包含所有行为数据的统一同构图中学习全局表征,然后将其作为后续行为特定表征学习的初始表征。这一学习策略能够充分利用多行为信息,并确保在每个行为图中进行良好的表征初始化。此外,本文方法采用了 2 种不同的策略来聚合用户和物品的行为特定表征。通过与现有先进 MBR 方法的实验比较,验证本文方法的有效性。

1.2 基于 GCN 的推荐方法

近年来,基于 GCN 的推荐方法因其在处理非欧几里得结构数据方面的强大能力而受到广泛关注^[25-28]。GCN 的基本原理是利用用户-物品交互矩阵构建图结构,并通过在图上执行卷积操作来更新节点。研究人员已将基于 GCN 的推荐方法与各种技术相结合,应用于不同的场景中。

一些研究对 GCN 模型进行了简化。例如: He 等人^[29]通过消除非线性和冗余的特征转换结构,简化了 GCN 操作中的消息传递机制,极大降低了模型的复杂性,同时提高了推荐性能; Mao 等人^[30]提出了一种更简洁的 GCN 操作,消除了显式消息传递,并通过约束损失函数和灵活的权重分配来近似无限层 GCN 的有限结果。此外,为了区分节点的重要性或聚合不同的属性信息,一些方法将注意机制整合到 GCN 中。例如: Wang 等人^[31]通过引入知识图谱进一步扩展了这一概念,结合用户行为数据和知识图谱信息以增

强对用户兴趣的理解; Yue 等人^[28]考虑了不同属性的影响,提出了一种基于注意力的属性融合策略,缓解了数据稀疏性的问题; Qiao 等人^[32]通过设计 3 层注意力图,分别利用了用户之间的社交关系、用户-物品兴趣关系和物品之间的相关性。另外,一些研究引入了知识图谱,以更好地捕捉用户和物品之间的语义和上下文信息,从而提高模型的可解释性。Ma 等人^[33]增强了 GCN 中的知识感知能力,提高了推荐性能,同时确保了解释多样性。Wang 等人^[34]聚合了具有显式和隐式关系的所有实体对,并区分了不同关系中上下文信息的重要性。最近,一些研究还从其他角度探索了 GCN 的应用。例如: Liu 等人^[35]将 GCN 应用于汉明空间,通过用户-物品二分图显式建模汉明空间中的 1 阶和高阶相似性; Hu 等人^[36]将联邦学习与 GCN 结合,利用分布式用户-物品交互图中的高阶连接信息,同时保护用户隐私。

毫无疑问,基于 GCN 的方法在这些探索中取得了显著进展。本文着重强调 GCN 在表示学习中高效捕获邻居信息的能力。因此,在表征学习阶段,直接采用 GCN 作为骨干网络来实现表征的学习。此外,为了应对 GCN 中存在的数据稀疏性问题,本文设计了一个层次化的图卷积结构,以更准确地捕获信息。

2 MB-HGCN 方法

2.1 问题定义

MBR 通过利用用户在平台上的辅助行为(如浏览和加入购物车)来帮助学习用户偏好。这些行为反映了用户对物品的兴趣,包含了丰富的用户偏好信息,从而有效缓解数据稀疏性问题。这项工作旨在通过利用辅助行为更好地学习用户和物品的表征,以提高推荐性能。

令 \mathcal{U} 和 \mathcal{I} 分别为用户和物品的集合,总用户数和总物品数分别为 M 和 N 。设 K 表示行为类型的数量, $k(1 \leq k \leq K)$ 表示第 k 种行为,其中 K 表示目标行为。令 \mathcal{R}_k 为行为 k 的交互矩阵,该矩阵是一个二进制矩阵,对于 r_{ui} 是 \mathcal{R}_k 的元素,如果观察到用户 u 和物品 i 之间发生交互,则 $r_{ui} = 1$; 否则 $r_{ui} = 0$ 。

本文研究问题的正式定义如下。

输入: 用户集合 \mathcal{U} 和物品集合 \mathcal{I} 以及用户-物品在不同行为下的交互矩阵集合 $\{\mathcal{R}_1, \mathcal{R}_2, \dots, \mathcal{R}_K\}$ 。

输出: 估计用户 u 在目标行为中与物品 i 交互的概率。

在详细介绍 MB-HGCN 方法之前,先定义 2 个

概念:

1) 行为特定图. 行为特定图定义为 $\mathcal{G}_k = (V_k, E_k)$, 其中 \mathcal{G}_k 是由第 k 个行为下用户-物品的交互矩阵 \mathcal{R}_k 构造的二分图. V_k 由用户节点 $u \in \mathcal{U}$ 和物品节点 $i \in \mathcal{I}$ 构成, E_k 定义为图 \mathcal{G}_k 中用户-物品的交互边. 假如用户与物品交互矩阵 \mathcal{R}_k 中 $r_{ui} = 1$ 则该用户和物品之间有边相连.

2) 统一图. 统一图定义为 $\mathcal{G} = (V, E)$, 该图是基于所有类型行为的交互构建的. 它是一个同构图, 这意味着无需区分这个图中不同类型的交互. 对于用户 u 和物品 i 之间不同类型的交互, 它们的边是相同的, 即 $E = E_1 \cup E_2 \cup \dots \cup E_K$.

2.2 方法介绍

用户与物品的交互反映了用户的兴趣. 在 MBR 中, 人们普遍认为不同类型的行为从不同角度或不同程度揭示了用户的偏好^[14-15]. 基于这一共同假设, 许多多行为方法被提出, 并从中提取有价值的信息来学习用户偏好. 以往大多数多行为方法首先分别从不同的行为中学习用户与物品的表征, 然后采用不同的策略进行聚合. 最终目的是利用辅助行为来学习更好的用户和物品的表征, 从而提高对目标行为的推荐性能.

本文提出了一个层次 GCN, 以利用多行为数据学习用户和物品的表征. 具体来说, MB-HGCN 首先采用由所有行为交互信息构造的统一图来学习全局表征. 然后将全局表征用作初始化的向量, 并将其输入到行为特定图中, 以学习每种行为类型的行为特定向量. 直观地说, 用户在不同的行为中包含一个共

享的宽泛的兴趣, 而且每个行为都包含一些特定的用户偏好特征. 从统一图中学习到的全局表征表示一般兴趣或粗粒度偏好, 从每个行为特定的图中学习到的用户表征表示对行为特定的细化或细粒度用户偏好. 接下来, MB-HGCN 分别采用 2 种不同的策略获得最终的用户和物品的表征用于预测, 并采用多任务学习进行优化.

图 1 展示了 MB-HGCN 方法的总体结构, 主要包括 3 个模块: 1) 表征学习, 通过分层图网络结构学习用户和物品的表征. 2) 表征聚合, 采用 2 种不同的策略对用户和物品的表征进行聚合. 具体而言, 设计了一种新的权重方案, 从不同的行为中自适应提取有价值的信息, 用于用户表征的聚合; 采用线性聚合方法进行物品表征的聚合. 3) 多任务学习, 将每个行为的交互信息作为用户和物品表征学习的监督信号. 接下来将依次详细描述这 3 个模块.

2.2.1 表征初始化

在具体介绍各个模块之前, 首先了解一下如何对表征进行初始化. 当前主流方法是将用户 $u \in \mathcal{U}$ 和物品 $i \in \mathcal{I}$ 的编号分别初始化为 d 维向量 e_u^0 和 e_i^0 . 令 $P \in \mathbb{R}^{M \times d}$ 和 $Q \in \mathbb{R}^{N \times d}$ 分别为用户和物品的初始化向量矩阵, 其中 M 和 N 分别表示用户和物品的数量. 每个用户和物品的编号均对应一个唯一的向量. 给定所有用户和物品的 one-hot 编码矩阵 ID^u 和 ID^i , 用户 u 和物品 i 的向量表征初始化为

$$e_u^0 = P \cdot ID_u^u, e_i^0 = Q \cdot ID_i^i, \quad (1)$$

其中 ID_u^u 和 ID_i^i 分别代表用户 u 和物品 i 所对应的 one-hot 编码.

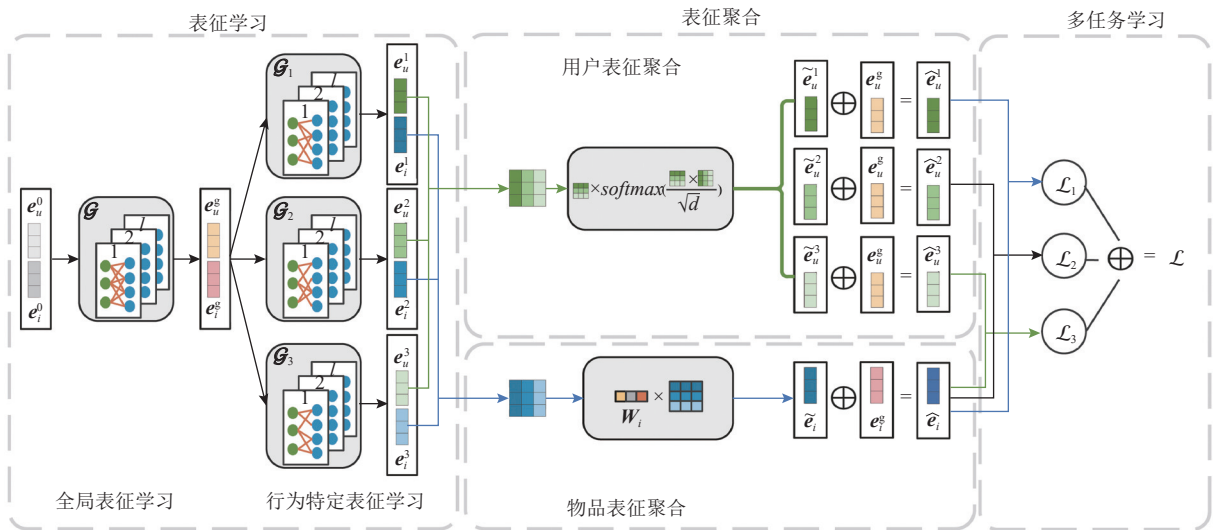


Fig. 1 Overview of MB-HGCN method

图 1 MB-HGCN 方法概述

2.2.2 表征学习

MB-HGCN 采用了一个分层的 GCN 结构来利用多行为进行表征学习. 为了简单起见, 对于每个图中的表征学习均采用 LightGCN^[29] 来实现, 该方法是一个轻量级的基于 CF 的单行为推荐方法 (也可以采用其他 GCN 方法来代替, 如 UltraGCN^[30] 和 SVD-GCN^[37] 等). LightGCN 的核心思想是采用邻域聚合进行信息传递以更新自身节点:

$$\begin{aligned} \mathbf{e}_u^{(l+1)} &= \sum_{i \in N_u} \frac{1}{\sqrt{|N_u|} \sqrt{|N_i|}} \mathbf{e}_i^{(l)}, \\ \mathbf{e}_i^{(l+1)} &= \sum_{u \in N_i} \frac{1}{\sqrt{|N_i|} \sqrt{|N_u|}} \mathbf{e}_u^{(l)}, \end{aligned} \quad (2)$$

其中 $1/\sqrt{|N_u|} \sqrt{|N_i|}$ 表示正则化系数, $N_u(N_i)$ 表示与用户 u (物品 i) 交互过的物品 (用户) 的集合. 经过 l 层递归后, 将每层表征聚合起来作为最终用户和物品的表征:

$$\mathbf{e}'_u = \sum_{l=0}^L \alpha_l \mathbf{e}_u^{(l)}, \quad \mathbf{e}'_i = \sum_{l=0}^L \alpha_l \mathbf{e}_i^{(l)}, \quad (3)$$

其中 α_l 是超参数, 用来表示第 l 层向量表征的重要性.

如图 1 所示, 在统一图 \mathcal{G} 和行为特定图 \mathcal{G}_k 中均采用 LightGCN 来学习用户和物品的表征.

1) 全局向量表征. 在统一图 \mathcal{G} 中, 遵循式 (2) 经过 L 层传播后, 分别得到用户和物品的向量表征集合 $\{\mathbf{e}_u^{(1)}, \mathbf{e}_u^{(2)}, \dots, \mathbf{e}_u^{(L)}\}$ 和 $\{\mathbf{e}_i^{(1)}, \mathbf{e}_i^{(2)}, \dots, \mathbf{e}_i^{(L)}\}$. 随后对这些表征进行聚合作为最终的用户和物品的表征:

$$\begin{aligned} \mathbf{e}_u^g &= \mathbf{e}_u^{(0)} + \sum_{l=1}^L \alpha_l \frac{\mathbf{e}_u^{(l)}}{\|\mathbf{e}_u^{(l)}\|_2}, \\ \mathbf{e}_i^g &= \mathbf{e}_i^{(0)} + \sum_{l=1}^L \alpha_l \frac{\mathbf{e}_i^{(l)}}{\|\mathbf{e}_i^{(l)}\|_2}, \end{aligned} \quad (4)$$

其中 \mathbf{e}_u^g 和 \mathbf{e}_i^g 分别为从统一图 \mathcal{G} 中学习到的全局表征. 同时, 它们也是行为特定图 \mathcal{G}_k 的共享输入. $\mathbf{e}_u^{(0)}$ 和 $\mathbf{e}_i^{(0)}$ 是图 \mathcal{G} 的输入 (即初始化向量表征 \mathbf{e}_u^0 和 \mathbf{e}_i^0). 通常来讲, 越远的邻居重要性越低. 因此, 式 (4) 中的 α_l 设置为 $1/(l+1)$. 对图网络中每层学习到的表征 ($\mathbf{e}_u^{(l)}$ 和 $\mathbf{e}_i^{(l)}$) 进行归一化是为了减轻不同数量级特征叠加所带来的影响.

2) 行为特定向量表征. 类似地, 将 \mathbf{e}_u^g 和 \mathbf{e}_i^g 作为初始向量表征输入行为特定图 \mathcal{G}_k 中, 能够分别得到特定行为下的用户 u 与物品 i 的表征集合 $\{\mathbf{e}_u^1, \mathbf{e}_u^2, \dots, \mathbf{e}_u^K\}$ 和 $\{\mathbf{e}_i^1, \mathbf{e}_i^2, \dots, \mathbf{e}_i^K\}$.

2.2.3 表征聚合

通过表征学习过程, 已经分别学习到了用户 u 与物品 i 的全局表征 \mathbf{e}_u^g 和 \mathbf{e}_i^g 以及行为特定表征的集合 $\{\mathbf{e}_u^1, \mathbf{e}_u^2, \dots, \mathbf{e}_u^K\}$ 和 $\{\mathbf{e}_i^1, \mathbf{e}_i^2, \dots, \mathbf{e}_i^K\}$. 接下来, MB-HGCN 通过

采用不同的策略, 分别对上述用户表征和物品表征进行聚合, 以获得最终的向量表征用于推荐任务.

1) 用户表征聚合. 考虑到不同的行为可能传达一些关于用户偏好的独特信息, 所以为了从不同行为特定的表征中提取有价值的信息进行目标行为预测, 我们设计了一种新颖的用户表征聚合加权方案. 以用户 u 为例, 聚合方式为:

$$\mathbf{U} = \mathbf{e}_u^1 \|\mathbf{e}_u^2\| \cdots \|\mathbf{e}_u^K\|, \quad (5)$$

$$\tilde{\mathbf{e}}_u^k = \mathbf{U} \boldsymbol{\delta}^T, \quad (6)$$

其中 $\|\cdot\|$ 表示堆叠操作, $\mathbf{U} \in \mathbb{R}^{d \times K}$ 是堆叠从每个行为中学习到的用户向量表征而得到的矩阵, 其中 d 为向量的维度, K 为行为数量; $\boldsymbol{\delta}$ 是根据不同行为与目标行为的相关性计算得到的权重向量, 其计算过程为

$$\boldsymbol{\delta} = \text{softmax} \left(\frac{(\mathbf{e}_u^k)^T \mathbf{U}}{\sqrt{d}} \right), \quad (7)$$

其中 $(\mathbf{e}_u^k)^T \mathbf{U}$ 计算了第 k 个行为和其他行为之间向量表征的相似性; \sqrt{d} 用来防止梯度消失; $\text{softmax}(\cdot)$ 用来进行归一化.

式 (7) 通过注意力机制计算第 k 个行为和其他行为之间的相关性来为用户分配权重. 直觉上, 与行为 k 之间具有更多相关性的行为应该分配更大的权重, 采用这种策略进行权重分配, 模型能够自适应地从其他行为中提取有价值的信息用于目标行为的预测. 此外, 结合多任务学习, 这种方法还能避免在学习过程中将行为特定的表征过度优化为目标行为.

重复上述操作, 模型可以获得一个综合的表征集合 $\{\tilde{\mathbf{e}}_u^1, \tilde{\mathbf{e}}_u^2, \dots, \tilde{\mathbf{e}}_u^K\}$.

2) 物品表征聚合. 物品特征在不同行为中的一致性使得我们可以通过简单的线性组合来聚合学习到的表征. 在不同类型的行为中, 与物品交互的用户数量和总的交互数量存在差异. 直观地说, 在具有更多交互的行为中学习到的物品特征更全面. 因此, 行为 k 中分配给物品 i 的行为特定表征的权重为

$$\gamma_{ik} = \frac{w_k n_{ik}}{\sum_{m=1}^K w_m n_{im}}, \quad (8)$$

其中 w_k 是第 k 个行为下的可学习参数, n_{ik} 表示在第 k 个行为中与物品 i 交互的用户数量. 聚合后的物品 i 的特定行为表征为

$$\tilde{\mathbf{e}}_i = \sum_{k=1}^K \gamma_{ik} \mathbf{e}_i^k. \quad (9)$$

值得注意的是, 用户表征 $\tilde{\mathbf{e}}_u^k$ 和物品表征 $\tilde{\mathbf{e}}_i$ 都是从特定行为的信息中获得的. 为了获得更全面而丰富

的表征, 将它们与全局表征相结合, 最终的表征为

$$\hat{e}_u^k = \tilde{e}_u^k \oplus e_u^g, \quad \hat{e}_i = \tilde{e}_i \oplus e_i^g, \quad (10)$$

其中 \oplus 表示对应位置元素相加.

2.2.4 多任务学习

多任务学习是一种联合优化不同但相关的任务的学习策略. 为了更好地利用表征学习中的多行为信息, MB-HGCN 将每个行为视为独立的训练任务. 采用计算内积的方式来估计预测得分. 以第 k 个行为为例:

$$y_{ui}^k = (\hat{e}_u^k)^T \hat{e}_i. \quad (11)$$

对每个任务的优化采用贝叶斯个性化排序 (Bayesian personalized ranking, BPR) 损失:

$$\mathcal{L}_k = \sum_{(u,i,j) \in O} -\ln \sigma(y_{ui}^k - y_{uj}^k), \quad (12)$$

其中 $O = \{(u, i, j) | (u, i) \in O^+, (u, j) \in O^-\}$ 定义为正负样本对; $O^+(O^-)$ 表示在当前行为中已观察到 (未观察到) 的样本; $\sigma(\cdot)$ 代表 sigmoid 函数. 根据式 (12), 能够得到所有 K 个任务的损失函数, 即 $\{\mathcal{L}_1, \mathcal{L}_2, \dots, \mathcal{L}_K\}$, 然后对 K 个损失函数求和, 进行联合优化. 通常来讲, 不同任务的贡献应该是不同的. 为不同的损失分配不同的权重可能会提高最终的性能, 然而这不是本节研究的重点. 在这里, 将它们视为同等重要进行简单相加, 本文专注于研究表征学习与聚合策略的有效性, 将对损失函数中不同权重的研究作为未来的工作重点. 最终的损失函数表示为

$$\mathcal{L} = \sum_{k=1}^K \mathcal{L}_k + \beta \|\theta\|_2, \quad (13)$$

其中 θ 表示模型中所有可训练的参数, β 为正则化系数, 用于防止过拟合. 为了提高泛化能力, 在训练中还采用了广泛使用的 node dropout 和 message dropout 策略, 分别用来随机丢弃图中的节点和向量中的信息.

3 实验结果与分析

本节在 3 个公开的基准数据集上进行了全面的实验, 以评估 MB-HGCN 模型的有效性. 具体而言, 本节旨在回答以下研究问题:

1) 与最先进的推荐方法相比, MB-HGCN 模型的性能如何.

2) MB-HGCN 模型各组成部分对推荐性能有何影响.

3) MB-HGCN 能否缓解冷启动问题.

4) 增加 GCN 层数对模型性能有何影响.

3.1 实验设置

1) 数据集. 实验中使用了 Tmall, Beibei, Jdata 这 3 个真实数据集. Tmall 和 Jdata 数据集包含 4 种行为类别, 分别为浏览 (view)、收藏 (collect)、加购物车 (cart) 和购买 (buy), 而 Beibei 数据集包含 3 种行为类别, 严格按照浏览、加入购物车然后购买的顺序发生. 在这 3 个数据集中, 购买行为被设定为目标行为, 其他所有行为都视为辅助行为. 为了确保数据的质量和一致性, 对上述数据集进行了预处理, 去除了重复记录并保留了最早发生的记录. 预处理方法遵循了之前研究中使用的标准, 这为实验提供了可靠的数据基础. 详细信息见表 1 所示.

Table 1 Statistics of the Experimental Datasets

表 1 实验数据集统计信息

统计明细	数据集		
	Tmall	Beibei	Jdata
用户	41 738	21 716	93 334
物品	11 953	7 997	24 624
购买	255 586	304 576	333 383
加购物车	1 996	642 622	49 891
收藏	221 514		45 613
浏览	1 813 498	2 412 586	1 681 430

2) 评估协议. 为了评估模型的性能, 采用了常用的留一法方法. 在训练阶段, 选择每个用户的最后一个交互物品构建验证集, 以进行超参数调优. 在评估阶段, 计算测试集中所有物品的预测分数, 并对它们进行排名, 从而生成用户的推荐列表. 为全面评估模型性能, 实验采用了 2 个广泛使用的评估指标: 命中率 (hit ratio, $HR@K$) 和归一化折损累计增益 (normalized discounted cumulative gain, $NDCG@K$).

3) 基准模型. 为了展示 MB-HGCN 模型的有效性, 与其他基准推荐方法进行了性能比较.

① 单行为方法

MFBPR^[2]. 该方法将矩阵分解与 BPR 优化框架相结合, 用于个性化推荐.

LightGCN^[29]. 该方法仅保留邻居聚合操作, 同时去除冗余的非线性变换, 相比标准 GCN 大大简化了模型架构, 从而实现更优秀的推荐性能.

② 多行为方法

RGCN^[38]. 该模型是一种关系图卷积网络, 通过聚合图中节点邻域的信息来学习节点表征, 可以区分不同类型的边, 从而在异构图上进行表示学习.

NMTR^[11]. 该模型是级联建模用户的多个行为的

深度模型,用于捕捉其顺序偏好并提供个性化推荐.

MBGCN^[13]. 该模型利用多行为的用户-物品交互数据来学习表征并预测个性化推荐. 此外, 还利用物品-物品传播来处理冷启动问题.

GNMR^[10]. 该模型通过融合交叉交互协作关系建模, 捕捉多个行为之间的复杂用户-物品交互, 并提升推荐性能.

SMBRec^[22]. 该模型采用对比学习策略进行星型结构的表征学习, 从而利用辅助行为的信息来提高目标行为的推荐准确性.

CRGCN^[14]. 这项工作对行为序列进行建模, 并在信息传播中建立不同行为之间的连接, 实现了行为之间的依赖性探索.

MBRec^[39]. 该方法提出了一个相互关系编码器, 以自适应地发现复杂的关系结构并跨特定于层的行为表示进行聚合.

4) 参数设置. 该模型由 PyTorch 实现. 所有方法每个 batch 大小统一设置为 1 024, 向量表征维度统一设置为 64. 本文选择了 Adam 优化器. 此外, 通过网格搜索技术优化模型的超参数, 具体来说, 对学习率和正则化权重分别在 {1E-2, 5E-3, 3E-3, 1E-3} 和 {1E-2, 1E-3, 5E-4, 3E-4} 范围内进行调优.

3.2 整体性能评估

本节介绍了 MB-HGCN 模型和所有基线方法性能的详细比较分析. 实验结果如表 2 所示.

总体而言, 多行为方法在整体上优于单行为方法, 凸显了建模多个行为的有效性. 在多行为方法中, MB-HGCN 显著优于其他多行为方法. 与最佳基准模型相比, 该模型在推荐准确性方面取得了显著改进. 这些结果展示了该模型的出色性能.

在单行为方法中, LightGCN 方法在 3 个数据集上的性能表现明显优于 MFBPR. 这个结果归因于基于 GCN 的方法在捕捉用户-物品交互信息方面的有效性.

在多行为方法中, RGCN 通过简单的求和方法将分别从每个行为中学习的表征直接组合起来, 导致结果不佳, 甚至在某些情况下低于单行为方法 LightGCN 的准确率. 这表明对辅助行为表征进行直接聚合可能对推荐准确性产生不利影响. 相反, MBGCN 和 GNMR 采用了替代的表征聚合策略, 两者相比 RGCN 都取得了更好的性能, 这验证了不同行为对目标行为的贡献不同. 此外, NMTR 和 CRGCN 通过级联建模考虑多个行为之间的关系, 并且两者的性能都优于前面提到的方法. NMTR 通过不同行为的交互分数间接建模级联效应. 相比之下, CRGCN 直接将级联影响融入到表征学习过程中, 从而在性能上优于 NMTR. MBRec 精心设计了跨行为特定层的融合方案, 因此也获得了出色的性能表现. MB-HGCN 能够大幅度优于 MBRec 和 CRGCN, 主要归功于其层级学习策略和聚合策略. 与 CRGCN 相比, MB-HGCN 对用户和物品表征的聚合更加精细化, 而不是直接进行级联传递影响. 与 MBRec 相比, MB-HGCN 的层级学习获取了层次丰富的多行为用户表示, 能够更好地促进信息的聚合. 消融研究进一步证明了 MB-HGCN 中不同组件的有效性.

值得注意的是, 在 Tmall 数据集上取得的改进远远超过了其他 2 个数据集. 这个巨大差距的主要原因可以归因于不同数据集之间的行为交互的多样性. 与 Jdata 相比, Tmall 的收藏行为产生了与购买行为相当数量的数据, 提供了丰富的信息. 而 Jdata 数据集的加购物车和收藏行为与购买行为相比相差 1 个数量级, 因此会受到数据不平衡问题的影响. 相比之下, 在 Beibei 平台上, 用户在购买时需要遵循严格的行为顺序, 即浏览→加购物车→购买. 因此, 模型中学到的全局表征反映了浏览行为, 这限制了模型的性能.

3.3 消融研究

通过广泛的消融研究, 本节评估了 MB-HGCN 模

Table 2 Compared with the Performance of Baselines

表 2 与基准模型性能比较

数据集	指标	单行为方法		多行为方法								相对提升/%
		MFBPR	LightGCN	RGCN	NMTR	MBGCN	GNMR	SMBRec	MBRec	CRGCN	MB-HGCN (本文)	
Tmall	HR@10	0.023 0	0.039 3	0.031 6	0.051 7	0.054 9	0.039 3	0.069 4	0.077 1	<u>0.084 0</u>	0.146 1*	73.93
	NDCG@10	0.012 4	0.020 9	0.015 7	0.025 0	0.028 5	0.019 3	0.036 2	0.041 6	<u>0.044 2</u>	0.077 0*	74.21
Beibei	HR@10	0.026 8	0.030 9	0.032 7	0.031 5	0.037 3	0.039 6	0.048 9	0.050 9	<u>0.053 9</u>	0.061 9*	14.84
	NDCG@10	0.013 9	0.016 1	0.016 1	0.014 6	0.019 3	0.021 9	0.025 3	0.023 1	<u>0.025 9</u>	0.029 7*	14.67
Jdata	HR@10	0.185 0	0.225 2	0.240 6	0.314 2	0.280 3	0.306 8	0.412 5	0.476 3	<u>0.500 1</u>	0.533 8*	6.74
	NDCG@10	0.123 8	0.143 6	0.144 4	0.171 7	0.157 2	0.158 1	0.277 9	0.288 6	<u>0.291 4</u>	0.323 8*	11.12

注: 符号“*”表示通过双边成对 t 检验确定的具有统计显著性的改进, 其中 $p < 0.05$. 最优和次优分别用黑体数值和下划线数值表示.

型中各种成分的有效性.

1) 统一图 \mathcal{G} 中表征学习的有效性. MB-HGCN 中包含一个用于表征学习的分层图卷积网络, 在该网络中, 利用统一的图 \mathcal{G} 来学习粗粒度的全局表征, 并将其作为共享初始化用于细化行为特定图中的表征. 为了验证粗粒度全局表征的有效性, 进行了一项实验, 在模型中移除了统一图组件, 并将其与保留统一图的原始模型进行了比较. 具体而言, 在没有统一图 \mathcal{G} 的情况下训练模型, 并利用初始化的表征 (即 \mathbf{e}_u^0 和 \mathbf{e}_i^0) 作为行为特定图 $\mathcal{G}_k (k \in \{1, 2, \dots, K\})$ 的初始化. 实验结果如表 3 所示.

Table 3 Effect of the Representation Learning in Graph \mathcal{G}
表 3 图 \mathcal{G} 中表征学习的效果

数据集	评估指标	w/o. \mathcal{G}	w. \mathcal{G}
Tmall	HR@10	0.039 4	0.146 1
	NDCG@10	0.019 8	0.077 0
Beibei	HR@10	0.042 0	0.061 9
	NDCG@10	0.021 3	0.029 7
Jdata	HR@10	0.270 9	0.533 8
	NDCG@10	0.160 8	0.323 8

注: w. \mathcal{G} 和 w/o. \mathcal{G} 分别表示在图 \mathcal{G} 中进行表征学习和不进行表征学习.

表 3 表明, 移除统一图 \mathcal{G} 会显著降低模型的性能. 这个结果归因于在图 \mathcal{G} 中学习的粗粒度全局表征可以为行为特定图中的表征提供更好的初始化, 从而在这些图中实现更准确的学习. 此外, 观察到 2 个模型 (w. \mathcal{G} 和 w/o. \mathcal{G}) 之间存在巨大的性能差异. 实际上, 没有统一图 \mathcal{G} 时, 模型退化为 RGCN 的一种变体, 其唯一的区别在于表征聚合策略. 与表 2 相比, 不带统一图 \mathcal{G} 的模型的性能仍然明显优于 RGCN 的结果. 实验结果支撑了我们提出的用户和物品表征聚合策略的有效性, 并进一步验证了统一图设计的有效性.

2) 用户表征聚合策略的影响. 用户表征聚合策略设计的初衷在于用户在不同行为中的兴趣可能存在差异, 并且并非所有辅助行为中的用户偏好都对目标行为的预测任务有贡献. 因此, 设计了一种自适应用户表征聚合策略. 为了验证该策略的有效性, 进行了 3 个实验: ① 求和聚合 (sum), 移除了自适应用户表征聚合模块, 直接对不同行为特定的表征进行求和以进行信息聚合; ② 线性聚合 (linear), 将自适应用户表征聚合模块替换为线性聚合, 根据每个行为的交互数量分配不同的权重, 即与物品聚合策略相同; ③ 自适应聚合 (adaptive), 使用提出的自适应表征聚合策略. 实验结果见表 4.

Table 4 Comparison of Different User Representation Aggregation Strategies
表 4 不同的用户表征聚合策略比较

数据集	评估指标	sum	linear	adaptive
Tmall	HR@10	0.097 1	0.126 3	0.146 1
	NDCG@10	0.048 8	0.068 7	0.077 0
Beibei	HR@10	0.051 6	0.057 5	0.061 9
	NDCG@10	0.025 7	0.028 8	0.029 7
Jdata	HR@10	0.406 8	0.488 8	0.533 8
	NDCG@10	0.235 6	0.293 5	0.323 8

从表 4 可以看出, 自适应聚合策略取得了最佳性能. 求和聚合策略由于用户在不同行为中表现出的兴趣差异以及聚合策略缺乏对每个行为重要性的考虑, 导致性能较差. 尽管线性聚合策略考虑了不同行为的重要性, 但交互次数更多的行为不一定反映更准确的用户偏好. 相比之下, 自适应聚合策略基于不同行为之间的相似度, 在特征级别上聚合相关信息. 值得注意的是, 该聚合方案不会向模型中添加任何额外的参数, 从而消除了聚合方案引入额外参数对表征学习过程产生负面影响的潜在风险.

为了验证这一点, 进行了额外的实验. 首先, 预训练了模型, 并保留了从每个行为中学习到的最佳表征, 同时移除了全局表征的聚合 (即式 (10) 的操作), 以消除全局表征的影响. 为了消除多任务学习的影响, 仅保留了目标行为的训练. 在此基础上进行了以下实验: ① M_{unfix} , 采用线性聚合策略进行用户表征聚合; ② M_{fix} , 在第 1 次实验的基础上固定了表征学习过程中的参数; ③ M_{adapt} , 采用自适应聚合策略进行用户表征聚合. 实验结果如图 2 所示.

从图 2 中可以观察到, 对于 2 种线性聚合方法而言, 固定参数的方法明显优于未固定参数的方法. 这是因为在固定参数的方法中, 监督信号无法传递到表征学习过程中, 只有线性聚合过程的参数得到优化.

这表明, 聚合参数的优化可能导致表征学习的局部最优解. 此外, 采用自适应聚合策略优于采用求和聚合与线性聚合. 其原因在于自适应聚合策略不引入任何参数, 有利于表征学习朝着正确的方向进行优化.

3) 物品表征聚合策略的影响. 考虑到交互次数更多的行为可能会反映出物品更全面的特征, 所以采用了一种加权方案, 即根据每个行为的交互次数按比例分配权重, 如式 (8) 所示. 通过以下实验评估这种设计的有效性: ① fix γ_{ik} , 为表征聚合分配相同的




Fig. 2 Impact of different aggregating for user representations

图2 不同用户表征聚合方式的影响

权重(即 $\gamma_{ik} = 1$); ② w/o. w_k , 移除可学习参数 w_k , 并严格按照每个行为的交互次数按比例分配权重; ③ w. w_k , 保留可学习参数 w_k , 允许对不同行为的重要性进行微调, 即本文采用的方法. 实验结果如表5所示.

Table 5 Analysis of Item Aggregation Strategy

表5 物品聚合策略分析

数据集	评估指标	fix γ_{ik}	w/o. w_k	w. w_k
Tmall	$HR@10$	0.128 5	0.140 8	0.146 1
	$NDCG@10$	0.068 6	0.076 2	0.077 0
Beibei	$HR@10$	0.058 7	0.027 6	0.061 9
	$NDCG@10$	0.059 4	0.030 4	0.029 7
Jdata	$HR@10$	0.468 5	0.481 4	0.533 8
	$NDCG@10$	0.279 5	0.290 6	0.323 8

表5表明, 相比于非加权方法(fix γ_{ik}), 2种加权方法显著改善了性能, 这支持了交互次数更多的行为反映了更全面的物品特征这一观点. 在这2种加权方法中, 通过可学习参数对权重进行微调的方法(w. w_k)取得了更好的性能, 表明不同行为对不同物品的贡献存在差异. 因此, 通过可学习参数对权重进行微调可以更好地聚合物品的表示, 进一步验证了所提出策略的有效性.

3.4 冷启动研究

在推荐系统中, 冷启动问题指的是由于缺乏足

够的历史数据, 难以为新用户或物品生成个性化推荐. MBR是一种通过利用多种行为数据来缓解冷启动问题的方法. 这些行为数据可能包含有助于更好地理解用户偏好的丰富信息. 本节旨在验证模型在缓解冷启动问题方面的潜力. 将MB-HGCN与2个方法MBGCN和CRGCN进行比较, 其中MBGCN利用一个基于物品的评分模块来缓解冷启动问题, 而CRGCN是表现最佳的基准模型. 遵循之前的研究^[13-14], 随机选择测试集中的1 000个用户作为冷启动用户进行研究, 将他们的购买记录作为冷启动用户的测试集. 接下来, 从训练集中删除所选用户的全部购买记录, 并且从辅助行为中删除测试集中出现过的交互以防止信息泄露. 实验结果如图3所示.

从图3中可以观察到, 在3个数据集上, MB-HGCN的表现始终优于CRGCN和MBGCN. 这一结果表明, MB-HGCN能够更有效地利用多行为数据进行用户偏好学习. 这种优越的性能归因于分层图卷积网络架构, 它能够从全局层次到行为特定层次学习用户偏好. 因此, 即使用户没有购买行为, 模型仍然能够通过学习粗粒度的用户偏好来进行目标行为推荐. 相比之下, CRGCN的顺序建模未能有效地学习随机行为, 例如收藏行为, 这种行为的发生是不确定的, 从而导致了次优的表现. 此外, 与MBGCN相比, CRGCN表现出明显的性能提升, 这归因于其级联设

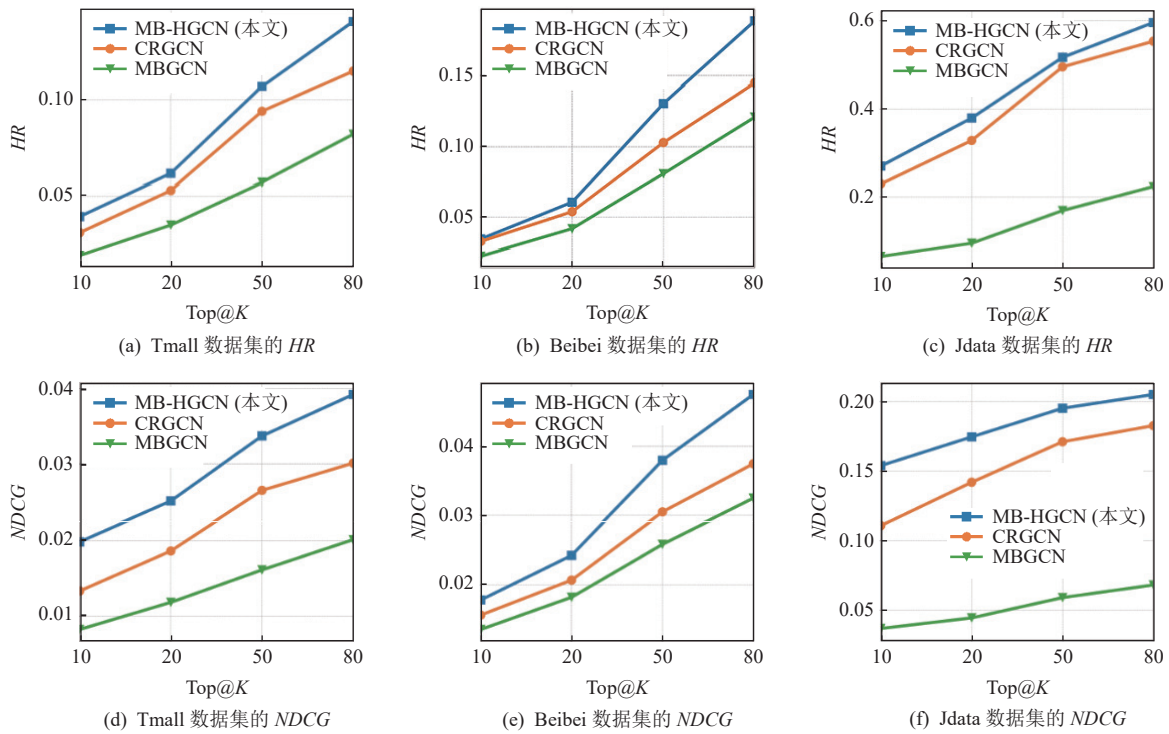


Fig. 3 Performance comparison for cold-start users

图3 冷启动用户的性能比较

计能够有效利用级联行为的影响来优化用户偏好。相反, MBGCN 采用的加权聚合策略可能无法捕捉行为之间的复杂相互关系。

3.5 模型运行效率分析

为了清晰展示模型的计算效率, 基于每个 epoch 的平均训练时间, 我们比较了 MB-HGCN 与相同设置下的 4 种代表性基线模型, 结果如表 6 所示。本实验的所有方法均在 PyTorch 框架下实现, 实验环境配置为: CPU 为 Intel® Xeon® CPU E5-2650 v4@2.20 GHz, GPU 为 GeForce RTX 2080 Ti Rev. A, 批量大小为 1 024, 表征维度为 64。

Table 6 Computational Efficiency Analysis

表 6 计算效率分析

数据集	多行为				
	LightGCN	MBGCN	SMBRec	CRGCN	MB-HGCN (本文)
Tmall	3.58	106.72	109.79	10.66	11.24
Beibei	2.86	139.36	158.61	6.78	19.97
Jdata	7.92	105.69	168.29	19.58	19.97

从表 6 可以看出, MB-HGCN 在计算效率上展现出较好的结果, 特别是在多行为模型中表现突出。值得注意的是, 同样是基于 GCN 的方法, MB-HGCN 和 CRGCN 的计算效率远高于 MBGCN 和 SMBRec。与仅使用购买行为的单行为模型 LightGCN 相比, MB-

HGCN 利用了更多的交互数据(见表 1 中的交互数量), 因此其总时间成本是可以接受的。这与时间复杂度所显示的结果一致, 即 MB-HGCN 与 LightGCN 的计算复杂度基本相同, 其中 MB-HGCN 整体计算所需总的时间复杂度为 $O(2|E| + 2|E|nLd|E|/b + 2|E|nd + 2nd)$, LightGCN 与轻量级多行为方法 CRGCN 的时间复杂度均为 $O(2|E| + 2|E|nLd|E|/b + 2|E|nd)$, 其中 $|E|$ 为图中边的数量, n 为 epoch 数量, b 为训练批次大小, d 为表征维度, L 为 GCN 层数。对于行为数量为 b 的数据集而言, MB-HGCN 运行时间理论值为 LightGCN 的 $b+1$ 倍左右, 这与表 6 统计结果一致。上述讨论说明 MB-HGCN 具有广泛的应用前景。

3.6 GCN 层数分析

MB-HGCN 采用 LightGCN 作为骨干, 在每个图中执行卷积操作。整体结构中, 对图 \mathcal{G} 和 \mathcal{G}_k 执行卷积操作类似于增加 GCN 层数。我们比较了不同数量设置的 GCN 层对推荐性能的影响, 结果如图 4 所示。

图 4 显示, 随着 GCN 层数的增加, MB-HGCN 性能一开始会提高, 但在继续堆叠更多层时开始下降。这一观察结果与 LightGCN 和 NGCF^[40] 等单一行为方法中的情况一致。实验表明, 使用 2 层 GCN 时能够获得最佳性能表现。这一发现表明, 在模型中增加 GCN 层数并不总是直接导致性能的提升。相反, 性能可能在一定层数后出现下降, 这可能是由于过多的层会

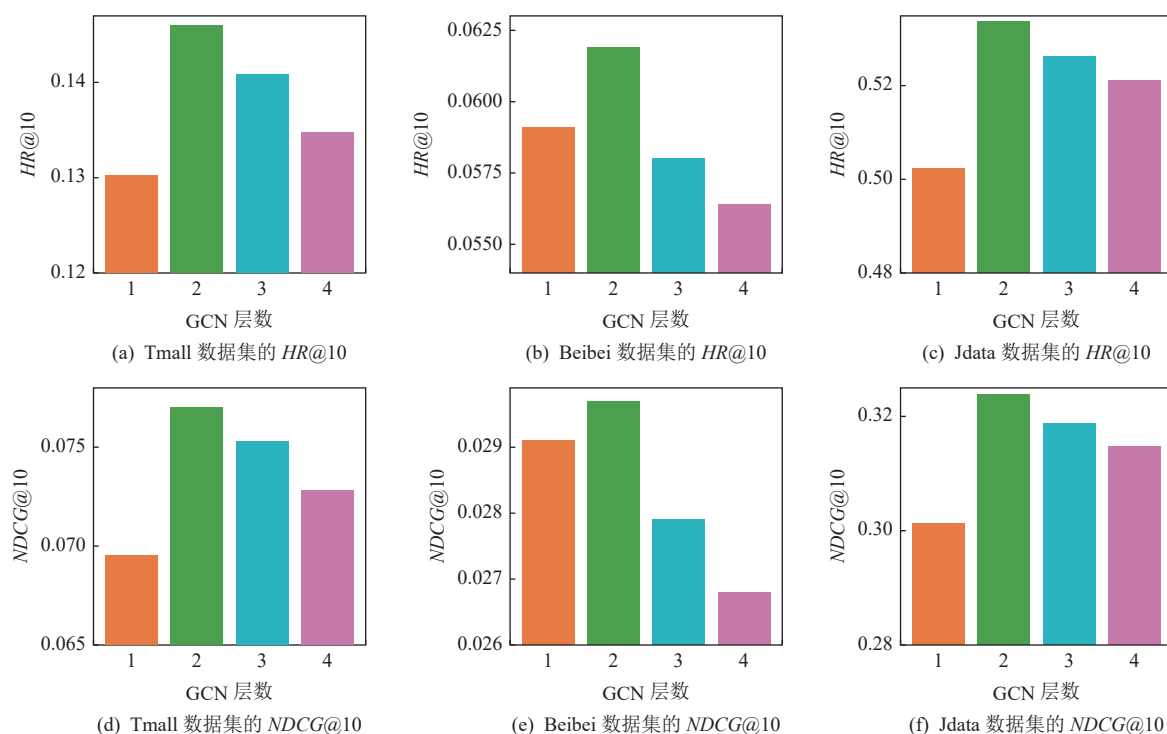


Fig. 4 Impact of different layer number of GCN settings on performance

图 4 不同层数 GCN 设置对性能的影响

导致过平滑等问题. 因此, 选择适当数量的 GCN 层对于获得最佳性能至关重要.

3.7 超参数分析

为了验证不同学习率对模型性能的影响, 我们

统计了不同学习率时 MB-HGCN 在 3 个数据集上的性能表现, 具体结果如图 5 所示.

从图 5 可以观察到, 随着学习率的增加, 模型在

3 个数据集上 $HR@10$ 和 $NDCG@10$ 均呈现先上升后

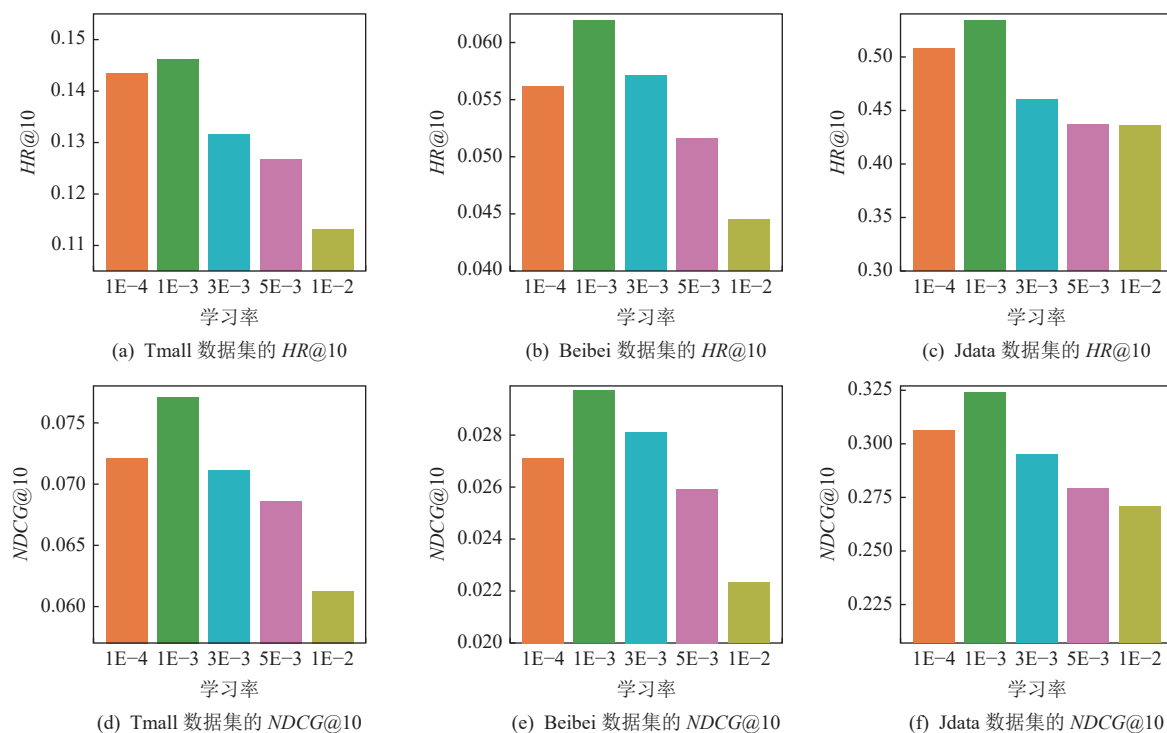


Fig. 5 Impact of different learning rate on performance

图 5 不同学习率对性能的影响

下降的趋势.这是由于当学习率较小时可能会导致模型训练过程变得缓慢以及难以收敛到最优解,容易受到噪声干扰,甚至停留在局部最优解或鞍点附近.当学习率过高时可能导致参数更新过大,使模型在参数空间中来回摆动,难以收敛到最优解,甚至会出现发散的情况,从而严重影响模型的泛化能力.因此,一个合适的学习率对模型的性能至关重要.

4 总 结

本文提出了一种新的多行为推荐方法 MB-HGCN,这是一种采用分层图卷积网络来有效利用多行为数据的推荐方法.具体而言,设计了一个分层图网络,能够从全局到行为特定的层次学习用户偏好.此外,MB-HGCN采用了2种不同的聚合策略,用于聚合从不同行为中学习到的用户和物品表征.通过在3个真实数据集上进行的广泛实验,证明了模型的有效性.此外,充分的消融研究评估了模型的各个组成部分,验证了它们设计的合理性.未来,计划探索表征学习过程中多行为交互之间的关系,并在在线系统上进行实验,以评估所提出模型的性能.

作者贡献声明: 严明时提出了算法思路和实验方案,并撰写论文;陈慧临负责完成实验;程志勇和韩亚洪提出指导意见并修改论文.

参 考 文 献

- [1] Koren Y, Bell R M, Volinsky C. Matrix factorization techniques for recommender systems[J]. *Computer*, 2009, 42(8): 30–37
- [2] Rendle S, Freudenthaler C, Gantner Z, et al. BPR: Bayesian personalized ranking from implicit feedback[C]//Proc of the 25th Int Conf on Uncertainty in Artificial Intelligence. New York: ACM, 2009: 452–461
- [3] Luo Xin, Zhou Mengchu, Li Shuai, et al. A nonnegative latent factor model for large-scale sparse matrices in recommender systems via alternating direction method[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2016, 27(3): 579–592
- [4] Xi Wudong, Huang Ling, Wang Changdong, et al. Deep rating and review neural network for item recommendation[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 33(11): 6726–6736
- [5] Ni Juan, Huang Zhenhua, Yu Chang, et al. Comparative convolutional dynamic multi-attention recommendation model[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 33(8): 3510–3521
- [6] Zhang Jinyu, Ma Chenxi, Li Chao, et al. Towards lightweight cross-domain sequential recommendation via tri-branches graph external attention network[J]. *Journal of Computer Research and Development*, 2024, 61(8): 1930–1944 (in Chinese)
(张劲羽, 马晨曦, 李超, 等. 基于三分支图外部注意力网络的轻量化跨域序列推荐[J]. *计算机研究与发展*, 2024, 61(8): 1930–1944)
- [7] Wang Lei, Xiong Yuning, Li Yunpeng, et al. A collaborative recommendation model based on enhanced graph convolutional neural network[J]. *Journal of Computer Research and Development*, 2021, 58(9): 1987–1996 (in Chinese)
(王磊, 熊于宁, 李云鹏, 等. 一种基于增强图卷积神经网络的协同推荐模型[J]. *计算机研究与发展*, 2021, 58(9): 1987–1996)
- [8] Berg R V D, Kipf T N, Welling M. Graph convolutional matrix completion[C]//Proc of the 24th ACM SIGKDD Int Conf on Knowledge Discovery and Data Mining. New York: ACM, 2018 [2025-02-20]. https://www.kdd.org/kdd2018/files/deep-learning-day/DLDay18_paper_32.pdf
- [9] Cheng Zhiyong, Han Sai, Liu Fan, et al. Multi-behavior recommendation with cascading graph convolution networks[C]//Proc of the 32nd ACM Web Conf. New York: ACM, 2023: 1181–1189
- [10] Xia Lianghao, Huang Chao, Xu Yong, et al. Multi-behavior enhanced recommendation with cross-interaction collaborative relation modeling[C]//Proc of the 37th IEEE Int Conf on Data Engineering. Piscataway, NJ: IEEE, 2021: 1931–1936
- [11] Gao Chen, He Xiangnan, Gan Dahua, et al. Learning to recommend with multiple cascading behaviors[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2021, 33(6): 2588–2601
- [12] Xia Lianghao, Huang Chao, Xu Yong, et al. Multiplex behavioral relation learning for recommendation via memory augmented transformer network[C]//Proc of the 43rd Int ACM SIGIR Conf on Research and Development in Information Retrieval. New York: ACM, 2020: 2397–2406
- [13] Jin Bowen, Gao Chen, He Xiangnan, et al. Multi-behavior recommendation with graph convolutional networks[C]//Proc of the 43rd Int ACM SIGIR Conf on Research and Development in Information Retrieval. New York: ACM, 2020: 659–668
- [14] Yan Mingshi, Cheng Zhiyong, Gao Chen, et al. Cascading residual graph convolutional network for multi-behavior recommendation[J]. *ACM Transactions on Intelligent Systems and Technology*, 2024, 42(1): 10: 1–10: 26
- [15] Meng Chang, Zhao Ziqi, Guo Wei, et al. Coarse-to-fine knowledge-enhanced multi-interest learning framework for multi-behavior recommendation[J]. *ACM Transactions on Intelligent Systems and Technology*, 2024, 42(1): 30: 1–30: 27
- [16] Zhao Zhe, Cheng Zhiyuan, Hong Lichan, et al. Improving user topic interest profiles by behavior factorization[C]//Proc of the 24th Int Conf on World Wide Web. New York: ACM, 2015: 1406–1416
- [17] Ding Jingtao, Yu Guanghui, He Xiangnan, et al. Improving implicit recommender systems with view data[C]//Proc of the 27th Int Joint Conf on Artificial Intelligence. 2018: 3343–3349. [2025-02-20]. <https://doi.org/10.24963/ijcai.2018/464>
- [18] Guo Guibing, Qiu Huihui, Tan Zhenhua, et al. Resolving data

- sparsity by multi-type auxiliary implicit feedback for recommender systems[J]. *Knowledge-Based Systems*, 2017, 138: 202–207
- [19] Qiu Huihui, Liu Yun, Guo Guibing, et al. BPRH: Bayesian personalized ranking for heterogeneous implicit feedback[J]. *Information Sciences*, 2018, 453: 80–98
- [20] Guo Long, Hua Lifeng, Jia Rongfei, et al. Buying or browsing?: Predicting real-time purchasing intent using attention-based deep network with multiple behavior[C]//Proc of the 25th ACM SIGKDD Int Conf on Knowledge Discovery and Data Mining. New York: ACM, 2019: 1984–1992
- [21] Xia Lianghao, Xu Yong, Huang Chao, et al. Graph meta network for multi-behavior recommendation[C]//Proc of the 44th Int ACM SIGIR Conf on Research and Development in Information Retrieval. New York: ACM, 2021: 757–766
- [22] Gu Shuyun, Wang Xiao, Shi Chuan, et al. Self-supervised graph neural networks for multi-behavior recommendation[C/OL]//Proc of the 31st Int Joint Conf on Artificial Intelligence. 2022: 2052–2058. [2025-02-20]. <https://www.ijcai.org/proceedings/2022/285>
- [23] Yan Mingshi, Liu Fan, Sun Jing, et al. Behavior-contextualized item preference modeling for multi-behavior recommendation[C]//Proc of the 47th Int ACM SIGIR Conf on Research and Development in Information Retrieval. New York: ACM, 2024: 946–955
- [24] Xu Jingcao, Wang Chaokun, Wu Cheng, et al. Multi-behavior self-supervised learning for recommendation[C]//Proc of the 46th Int ACM SIGIR Conf on Research and Development in Information Retrieval. New York: ACM, 2023: 496–505
- [25] Huang Ling, Huang Zhenwei, Huang Ziyuan, et al. Graph convolutional broad cross-domain recommender system[J]. *Journal of Computer Research and Development*, 2024, 61(7): 1713–1729 (in Chinese)
(黄玲, 黄镇伟, 黄梓源, 等. 图卷积宽度跨域推荐系统[J]. *计算机研究与发展*, 2024, 61(7): 1713–1729)
- [26] Zhao Rongmei, Sun Siyu, Yan Fanli, et al. Multi-interest aware sequential recommender system based on contrastive learning[J]. *Journal of Computer Research and Development*, 2024, 61(7): 1730–1740 (in Chinese)
(赵容梅, 孙思雨, 鄢凡力, 等. 基于对比学习的多兴趣感知序列推荐系统[J]. *计算机研究与发展*, 2024, 61(7): 1730–1740)
- [27] Li Ting, Jin Fusheng, Li Ronghua, et al. Light-HGNN: Lightweight homogeneous hypergraph neural network for circle content recommendation[J]. *Journal of Computer Research and Development*, 2024, 61(4): 877–888 (in Chinese)
(李挺, 金福生, 李荣华, 等. Light-HGNN: 用于圈层内容推荐的轻量同质超图神经网络[J]. *计算机研究与发展*, 2024, 61(4): 877–888)
- [28] Yue Guowei, Xiao Rui, Zhao Zhongying, et al. AF-GCN: Attribute-fusing graph convolution network for recommendation[J]. *IEEE Transactions on Big Data*, 2023, 9(2): 597–607
- [29] He Xiangnan, Deng Kuan, Wang Xiang, et al. LightGCN: Simplifying and powering graph convolution network for recommendation [C]//Proc of the 43rd Int ACM SIGIR Conf on Research and Development in Information Retrieval. New York: ACM, 2020: 639–648
- [30] Mao Kelong, Zhu Jieming, Xiao Xi, et al. UltraGCN: Ultra simplification of graph convolutional networks for recommendation[C]//Proc of the 30th ACM Int Conf on Information and Knowledge Management. New York: ACM, 2021: 1253–1262
- [31] Wang Xiang, He Xiangnan, Cao Yixin, et al. KGAT: Knowledge graph attention network for recommendation[C]//Proc of the 25th ACM SIGKDD Int Conf on Knowledge Discovery and Data Mining. New York: ACM, 2019: 950–958
- [32] Qiao Pengpeng, Zhang Zhiwei, Li Zhetao, et al. TAG: Joint triple-hierarchical attention and GCN for review-based social recommender system[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(10): 9904–9919
- [33] Ma Ting, Huang Longtao, Lu Qianqian, et al. KR-GCN: Knowledge-aware reasoning with graph convolution network for explainable recommendation[J]. *ACM Transactions on Intelligent Systems and Technology*, 2023, 41(1): 4: 1–4: 27
- [34] Wang Jihu, Shi Yuliang, Yu Han, et al. A novel KG-based recommendation model via relation-aware attentional GCN[J]. *Knowledge-Based Systems*, 2023, 275: 110702
- [35] Liu Han, Wei Yinwei, Yin Jianhua, et al. HS-GCN: Hamming spatial graph convolutional networks for recommendation[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(6): 5977–5990
- [36] Hu Pengqing, Lin Zhaozhao, Pan Weike, et al. Privacy-preserving graph convolution network for federated item recommendation[J]. *Artificial Intelligence*, 2023, 324: 103996
- [37] Peng Shaowen, Sugiyama K, Mine T. SVD-GCN: A simplified graph convolution paradigm for recommendation[C]//Proc of the 31st ACM Int Conf on Information and Knowledge Management. New York: ACM, 2022: 1625–1634
- [38] Schlichtkrull M S, Kipf T N, Bloem P, et al. Modeling relational data with graph convolutional networks[C]//Proc of the 15th European Semantic Web Conf. Berlin: Springer, 2018: 593–607
- [39] Xia Lianghao, Huang Chao, Xu Yong, et al. Multi-behavior graph neural networks for recommender system[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2024, 35(4): 5473–5487
- [40] Wang Xiang, He Xiangnan, Wang Meng, et al. Neural graph collaborative filtering[C]//Proc of the 42nd Int ACM SIGIR Conf on Research and Development in Information Retrieval. New York: ACM, 2019: 165–174



Yan Mingshi, born in 1989. PhD. His main research interests include artificial intelligence and personalized information recommendation.

严明时, 1989年生. 博士. 主要研究方向为人工智能、个性化信息推荐.



Chen Huilin, born in 1995. PhD. His main research interests include artificial intelligence and personalized information recommendation.

陈慧临, 1995年生. 博士. 主要研究方向为人工智能、个性化信息推荐.



Cheng Zhiyong, born in 1985. PhD, professor, PhD supervisor. His main research interests include multimedia information retrieval and recommendation systems.

程志勇, 1985年生. 博士, 教授, 博士生导师. 主要研究方向为多媒体信息检索、推荐系统.



Han Yahong, born in 1977. PhD, professor, PhD supervisor. His main research interests include multimedia analysis and retrieval, computer vision, and machine learning.

韩亚洪, 1977年生. 博士, 教授, 博士生导师. 主要研究方向为多媒体分析与检索、计算机视觉、机器学习.