

融合自注意力机制的多行为图对比学习推荐方法

钱忠胜, 黄 恒, 万子琰

(江西财经大学计算机与人工智能学院, 江西南昌 330013)

摘 要: 图卷积网络因其强大的高阶协作信号学习能力被广泛地应用在多行为推荐系统中. 然而, 目前大多数基于图卷积的多行为推荐方法未能有效建模不同用户/项目节点与各行为间的关系, 且目标行为的稀疏性也困扰着多行为推荐算法性能的进一步提升. 基于此, 提出一种融合自注意力机制的多行为图对比学习推荐模型(Multi-Behavior Graph Contrastive Learning recommendation method with Self-Attention mechanism, SA-MBGCL). 该方法将用户/项目节点嵌入与行为嵌入相结合, 并使用自注意力机制增强嵌入表示, 以有效建模不同节点与各行为间的依赖关系. 同时, 构建一种图对比学习方式, 将同一用户的目标行为与辅助行为视为正例对, 而不同用户的视为负例对, 以强化不同用户的行为差异, 达到缓解目标行为稀疏性的目的. 将非采样的推荐任务与多行为图对比学习进行多任务联合优化, 在 Beibei 与 Taobao 这 2 个公开数据集上, 和 6 个单行为模型与 10 个多行为模型进行对比, 结果表明, 所提模型 SA-MBGCL 在 HR (Hit Ratio) 和 NDCG (Normalize Discounted Cumulative Gain) 这 2 个指标上分别平均提升 5.21% 和 8.30%, 说明本文方法是有效的.

关键词: 自注意力机制; 图对比学习; 图卷积网络; 多任务; 多行为; 推荐系统

基金项目: 国家自然科学基金(No.62262025); 江西省自然科学基金(No.20224ACB202012)

中图分类号: TP399

文献标识码: A

文章编号: 0372-2112(2024)11-3684-15

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20231084

The Multi-Behavior Graph Contrastive Learning Recommendation Method with Self-Attention Mechanism

QIAN Zhong-sheng, HUANG Heng, WAN Zi-long

(School of Computer and Artificial Intelligence, Jiangxi University of Finance & Economics, Nanchang, Jiangxi 330013, China)

Abstract: Graph convolutional network has been widely applied in multi-behavior recommender systems due to its powerful ability to learn high-order collaborative signal. However, most existing graph convolution-based multi-behavior recommendation methods have failed to effectively model the relationships between different user-item nodes and various behaviors. The sparsity of target behaviors also poses challenges to further improve the performance of multi-behavior recommendation algorithms. Based on this, we propose the multi-behavior graph contrastive learning recommendation model with self-attention mechanism (SA-MBGCL). This method combines user-item node embeddings with behavior embeddings and employs a self-attention mechanism to enhance embedding representations, effectively modeling the dependency relationships between different nodes and behaviors. In the meanwhile, a graph contrastive learning approach is constructed, treating the target behavior and auxiliary behaviors of the same user as positive pairs, while considering those of different users as negative pairs, thereby reinforcing behavioral differences among different users to alleviate the sparsity of target behaviors. The proposed model combines unsampled recommendation tasks with multi-behavior graph contrastive learning to perform multi-task joint optimization. It was compared with 6 single-behavior models and 10 multi-behavior models on two public datasets, Beibei and Taobao. The results show that the proposed model SA-MBGCL achieves an average improvement of 5.21% in Hit Ratio (HR) and 8.30% in Normalized Discounted Cumulative Gain (NDCG). This demonstrates the effectiveness of the method presented in this work.

Key words: self-attention mechanism; graph contrastive learning; graph convolutional network; multi-task; multi-behavior; recommender system

Foundation Item(s): National Natural Science Foundation of China (No.62262025); Jiangxi Provincial Natural Sci-

ence Foundation (No.20224ACB202012)

1 引言

推荐系统能有效地帮助用户从海量的数据中迅速找到所需内容. 因其能缓解信息过载现象, 目前被广泛应用于各大领域. 但推荐系统中目标行为的稀疏性问题依旧长期存在, 信息融合推荐算法^[1]在一定程度上缓解了这一问题. 当前的信息融合推荐算法大多关注显式信息的融合, 而显式信息在实际应用场景中存在获取难度大、数据量不足及数据缺乏真实性等问题. 隐式信息凭借其数据量丰富、获取难度低等优点, 开始受到研究人员的青睐^[2,3].

对于隐式信息的利用, 目前绝大部分推荐算法主要依赖于单一种类型的交互(如购买行为)^[4-9], 但在实际应用场景中, 往往会涉及多种类型的交互数据. 在没有目标行为的情况下, 辅助行为也能很好地体现用户偏好. 在电子商务场景下, 我们通常把购买行为作为目标行为, 其他行为(如点击、加入购物车等)作为辅助行为. 为充分利用多种行为的数据, 近年来基于多行为的推荐算法应运而生^[10-12], 这些行为体现了丰富的用户偏好, 有利于进行更细粒度的推荐.

早期的一些工作中, 人们采用矩阵分解(Matrix Factorization, MF)的方法, 来探索从多种行为的交互中揭示用户潜在偏好的途径. 如 Zhao 等人^[13]通过共享项嵌入来执行不同行为的矩阵分解. 受贝叶斯个性化排名(Bayesian Personalized Ranking, BPR)的启发, Loni 等人^[14]在 BPR 的基础上, 设计一种新的采样方法, 旨在将不同行为映射到不同级别上, 以反映各种行为在模型训练过程中的贡献. Shi 等人^[15]将显式反馈和隐式反馈相结合, 把传统的 BPR 模型扩展为多重反馈. Ding 等人^[16]设计一种带有加权损失的目标函数来编码 BPR 采样器中的多种关系, 对多个行为赋予不同权重.

然而上述方法均仅直接使用用户与项目的交互信息, 未充分利用高阶的协同信息, 使模型获取用户高阶偏好的能力有限. 随着图卷积网络(Graph Convolutional Network, GCN)的出现, 研究人员开始利用其能捕获高阶邻域信息的强大能力, 将它应用在多行为推荐系统中. Zhang 等人^[17]在一个图中构建所有用户行为, 并执行图卷积操作. Chen 等人^[11]揭示多行为交互的潜在关系, 并联合行为与节点的嵌入, 以利用异构图中的高阶信息. 它们主要是将多种行为融入到图卷积网络中, 但未考虑不同节点与各行行为间的内在关系. 为区分不同行为的语义, Xia 等人^[18]将不同的可学习权重分配给不同的边, 以对行为的重要性进行建模. Jiang 等人^[19]提出一种基于邻域感知注意力的异质关系网络, 利用注意力机制捕获用户对不同项目的偏好. 它们主

要关注不同行为的权重或用户对项目的偏好强度, 而忽略了目标行为稀疏性对模型性能的影响.

尽管基于多行为的推荐方法已得到一定发展, 但依旧存在如下问题: (1) 目前大多数的多行为推荐模型未能有效捕获不同节点(即用户/项目)与各行行为间的依赖关系; (2) 尽管辅助行为的交互数据可为目标行为的推荐提供非常有效的互补信息, 但当前大部分多行为推荐模型对目标行为和辅助行为的联系不足, 导致目标行为的数据稀疏性现象依然未得到有效缓解.

针对以上问题, 本文提出一种融合自注意力机制的多行为图对比学习推荐方法(Multi-Behavior Graph Contrastive Learning recommendation method with Self-Attention mechanism, SA-MBGCL). 一方面, 在考虑节点与行为间的关系时, 引入自注意力机制建模节点和行为间的依赖, 以增强最终节点嵌入表示. 另一方面, 利用图对比学习的思想构建目标行为与辅助行为的联系, 强化不同用户的行为差异, 以此缓解目标行为的稀疏性. 主要工作如下:

(1) 使用自注意力机制建模用户项目节点和行为间的依赖. 在利用 GCN 聚合各节点嵌入与行为嵌入的同时, 采用自注意力机制的方式计算节点与行为的权重, 强化最终的节点嵌入表示.

(2) 利用图对比学习增强目标行为与辅助行为间的联系. 通过用户不同行为的对比学习, 来有效建模目标行为和辅助行为间的关系, 更充分地利用辅助行为信息提升目标行为的推荐效果.

(3) 在 2 个公开数据集上展开对比实验与消融实验. 与当前主流的单行为推荐模型以及多行为推荐模型相比, 所提模型 SA-MBGCL 的推荐性能在 HR (Hit Ratio) 和 NDCG (Normalize Discounted Cumulative Gain) 这 2 个指标均占优, 同时也验证了该模型中各组件的必要性.

2 相关工作

由于 GCN 对图结构数据具有强大的处理能力, 近年来, 越来越多的研究人员将其应用于推荐系统中, 并取得了良好效果. 如 Berg 等人^[20]基于用户-项目二部图, 提出一种图自编码器框架, 在图上应用了 GCN, 使用一个卷积层来获取用户和项目间的直接联系, 从链路预测的视角解决推荐算法中评分预测问题. Wang 等人^[21]提出的 NGCF (Neural Graph Collaborative Filtering) 遵循标准 GCN 方法, 通过特征变换、邻域聚合、非线性激活, 在用户-项目交互图上传播嵌入以利用高阶邻域信号. He 等人^[8]提出通过去除非线性激活函数和特征

变换以简化模型,进一步将 NGCF 扩展到 LightGCN,提高模型推荐性能. 随之发展的模型也越来越多^[22,23]. 然而,基于 GCN 的推荐模型通常易受数据稀疏的困扰,难以学习到高质量的节点嵌入. 最近的研究发现,利用多行为与对比学习的推荐方法可有效缓解此类问题.

2.1 多行为推荐

多行为推荐是推荐系统研究领域的一个新兴分支,旨在利用多种用户行为数据来提高目标行为上的推荐性能. 早期的研究自然地扩展了基于 MF 的方法,以执行不同行为的多重学习^[24]. 另一条研究路线从模型训练的角度来解决这个问题,它通过改变负采样策略和从辅助行为数据中丰富训练集来考虑多类型行为^[14-16]. 最近,大量研究人员试图开发神经网络模型来捕捉用户和项目间复杂的、多类型的交互. 例如,Chen 等人^[11]提出 GHCF (Graph Heterogeneous Collaborative Filtering) 模型,揭示异构用户-项目交互间的潜在关系,并设计一种新的 GCN 传播层,使得节点(用户和项目)的表示和行为联合嵌入到图中,以明确利用协作的高阶信号. Jin 等人^[12]提出 MBGCN (Multi-Behavior Graph Convolutional Network) 模型,在多行为异构图上执行不同行为中的用户-项目传播和项目-项目传播,以学习不同行为的影响强度和语义. Meng 等人^[25]提出一个包含兴趣提取模块和行为相关模块的多兴趣学习框架 CKML (Coarse-to-fine Knowledge-enhanced Multi-interest Learning),以更好地对多个行为间的复杂依赖关系进行建模. Cheng 等人^[26]构建一种级联图卷积网络 MB-CGCN (Multi-Behavior recommendation model with Cascading Graph Convolution Networks),以捕捉嵌入学习中的行为依赖. Xia 等人^[27]提出 MB-GMN (Multi-Behavior recommendation framework with Graph Meta Network) 框架,赋予用户-项目交互学习以揭示依赖于类型的行为表示能力,利用图元网络来提取行为异质性和交互多样性信息用于推荐.

可知,目前多行为推荐普遍关注如何对多种行为间的关系进行建模,而忽略了不同节点与各行为间的依赖. 并且,在大多数情况下,目标行为相对于辅助行为的交互数较为稀少,大部分多行为推荐算法均难以充分利用目标行为与辅助行为间的关系.

2.2 对比学习

随着对比学习在计算机视觉 (Computer Vision, CV) 和自然语言处理 (Natural Language Processing, NLP) 领域的快速发展,最近有研究对基于图的对比学习在推荐中的应用进行探索^[28,29], Wu 等人^[30]提出 SGL (Self-supervised Graph Learning) 模型,使用随机节点/边丢弃和随机游走在图结构和嵌入上实行数据增强,构建出多个子视图进行对比学习. Yu 等人^[31]提出

SimGCL (Simple Graph Contrastive Learning) 模型,放弃随机丢弃的图增强方式,而是通过将噪声均匀添加到每一层嵌入以生成正实例,从而创建对比视图. Li 等人^[32]提出 GFormer (Graph transFormer for recommendation) 模型,利用图神经网络自动编码器来重建被屏蔽的用户-项目交互以进行数据增强,通过这种方式生成增强的训练数据,模型可学习用户和项目的更有效的表示. 受这些工作的启发,近期有研究人员将多行为与对比学习结合,更好地提升模型性能. Gu 等人^[33]提出了 S-MBRec (Self-supervised graph collaborative filtering model for Multi-Behavior Recommendation) 模型,设计不同的策略来分别聚合多行为用户和项目的嵌入,并采用一种新型的对比学习任务来捕捉目标行为和辅助行为间的共性.

可知,对比学习主要是通过拉近相似样本(即正例对)、推远不同样本(即负例对)的方式使模型更好地捕捉数据的结构与关系,并进一步缓解数据的稀疏性问题.

上述研究表明,多行为推荐已得到一定的发展,但其仍存在一些不足. 而对比学习可通过构建正负例对帮助模型更好地捕获节点与行为间的关系. 基于此,本文提出 SA-MBGCL 模型,通过自注意力机制有效地建模各节点与各行为间的依赖关系,进而提高节点嵌入质量. 同时根据目标行为与辅助行为的关系构建对比学习,以缓解目标行为的稀疏性现象,充分利用辅助行为为提高目标行为的推荐效果.

3 SA-MBGCL 模型

下面先给出本文模型 SA-MBGCL 的整体框架,如图 1 所示,主要包含如下几个模块:

(1) 多行为感知图卷积网络模块. 利用图卷积网络传播节点与行为嵌入,并采用自注意力机制建模不同节点与各行为的联系,从而增强节点嵌入表示.

(2) 多行为图对比学习模块. 利用同一用户的目标行为与辅助行为构建正例对,不同用户的则构建负例对,以此建立多行为图对比学习,从而更好地建模目标行为与辅助行为的关系,缓解了目标行为的稀疏性问题.

(3) 模型预测与推荐模块. 采用多任务学习的方法训练模型,推荐任务为主任务,采用非采样策略计算损失,而多行为图对比学习为辅助任务,以此来联合优化总损失,训练模型参数,进而达到更优的推荐效果.

3.1 问题定义与符号说明

在多行为推荐中,用户、项目和行为是最重要的 3 个组成部分. 用户集为 $U = \{u_1, u_2, \dots, u_m\}$, 项目集为 $I = \{i_1, i_2, \dots, i_n\}$, 行为集为 $R = \{r_1, r_2, \dots, r_k\}$, 其中 m, n, k 分

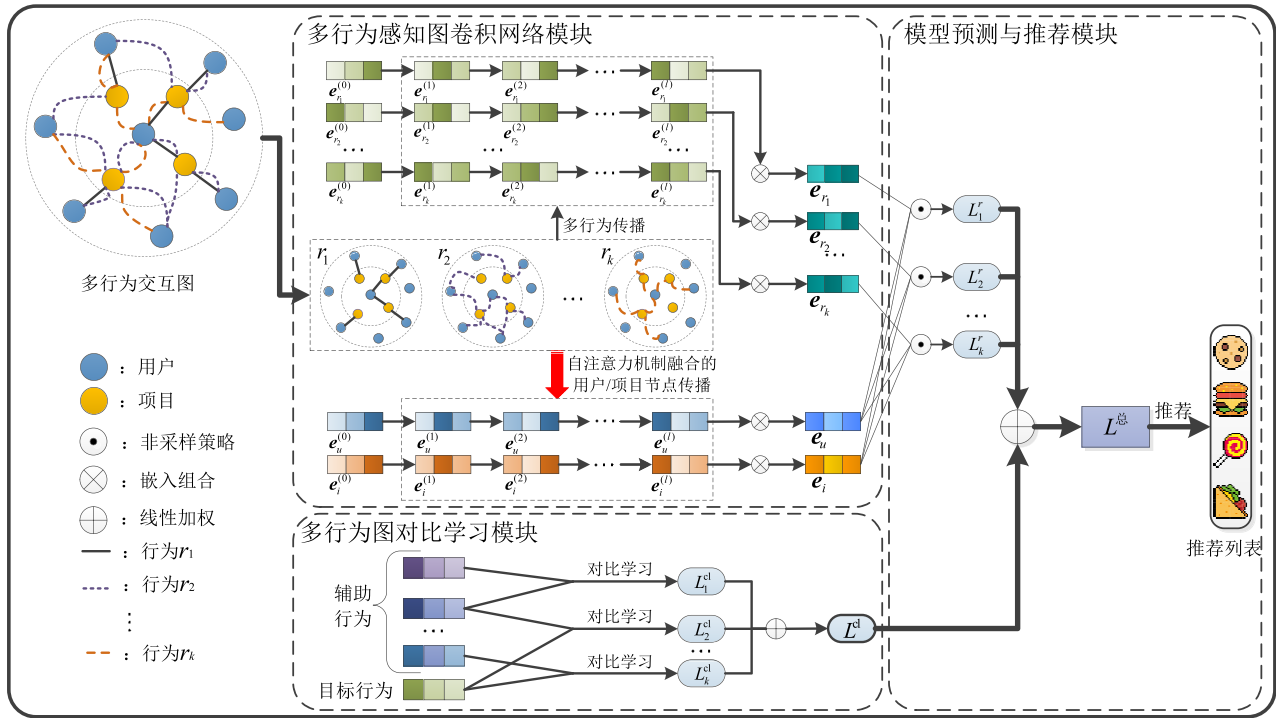


图1 SA-MBGC模型的整体框架

别表示用户数、项目数、行为类型数。在单行为下,交互矩阵 $\mathbf{Y}_{m \times n} = \{y_{ui} | u \in U, i \in I\}$ 中的元素 $y_{ui} = 1$ 时表示 u 和 i 有交互。对于多行为,每种行为都有其对应的交互矩阵,可表示为 $\{\mathbf{Y}^1, \mathbf{Y}^2, \dots, \mathbf{Y}^k\}$ 的形式,若用户 u 通过行为 r 与项目 i 有交互,则 $y_{(r)ui} = 1$, 否则为 0。通常多行为推荐具有需优化的目标行为,比如电子商务中的购买行为,其辅助行为包括点击、加入购物车等。本文模型的任务是评估用户 u 在目标行为下与项目 i 交互的可能性,并按照概率排序,以提供 Top- N 项目推荐列表。

为便于阐述,先对文中一些主要符号进行说明,如表 1 所示。

表 1 主要符号说明

符号	含义
$U = \{u_1, u_2, \dots, u_m\}$	用户集
$I = \{i_1, i_2, \dots, i_n\}$	项目集
$R = \{r_1, r_2, \dots, r_k\}$	行为集
L	网络层数
N_u	用户 u 交互的项目集
N_i	与项目 i 交互的用户集
$e_u^{(0)}, e_i^{(0)}, e_r^{(0)}$	用户 u 、项目 i 、行为 r 的初始嵌入
$e_u^{(l)}, e_i^{(l)}, e_r^{(l)}$	用户 u 、项目 i 、行为 r 的第 l 层的潜在嵌入
e_u, e_i, e_r	用户 u 、项目 i 、行为 r 的最终嵌入

3.2 多行为感知图卷积网络

受 GCN 中消息传递架构的启发,本文模型的嵌入传播机制建立在 GCN 消息传递架构之上,用以捕获用

户-项目多行为交互图中的协同信号,使用其联合节点及其对应的行为嵌入来建模用户-项目交互。此外,通过自注意力机制增强用户/项目节点嵌入。

3.2.1 多行为嵌入传播

在嵌入传播之前,我们需要先初始化嵌入,在用户-项目二部图中,节点表示用户或项目,用户-项目的不同交互行为用边表示。对于第一跳传播, $e_u^{(0)}, e_i^{(0)}, e_r^{(0)}$ 分别表示用户 u 、项目 i 、行为 r 的初始嵌入。在这样的多行为设置下,我们对其进行嵌入传播以获得每种行为下的各节点嵌入表示。为显式地体现每个行为的区别并捕获用户偏好,行为被嵌入到节点中进行 GCN 的消息传递^[11]。这样,用户(或项目)的嵌入表示是根据来自所有行为下的项目(或用户)信息建模的,如式(1)所示:

$$e_{u,r}^{(l)} = \sigma \left(\sum_{(i,r) \in N_u} \frac{1}{\sqrt{|N_u||N_i|}} \mathbf{W}^{(l)} \phi_u(e_i^{(l-1)}, e_r^{(l-1)}) \right) \quad (1)$$

$$e_{i,r}^{(l)} = \sigma \left(\sum_{(u,r) \in N_i} \frac{1}{\sqrt{|N_u||N_i|}} \mathbf{W}^{(l)} \phi_i(e_u^{(l-1)}, e_r^{(l-1)}) \right)$$

其中, $e_{u,r}^{(l)}$ 和 $e_{i,r}^{(l)}$ 分别表示在特定行为 r 下用户 u 和项目 i 的第 l 层嵌入, $e_u^{(l-1)}, e_i^{(l-1)}, e_r^{(l-1)}$ 分别表示用户 u 、项目 i 、行为 r 的第 $l-1$ 层嵌入。 $\mathbf{W}^{(l)} \in \mathbb{R}^{d \times d}$ 表示第 l 层参数矩阵, d 为嵌入向量维度, $\sigma(\cdot)$ 表示 LeakyReLU 激活函数, $\frac{1}{\sqrt{|N_u||N_i|}}$ 为对称归一化项,其作用是避免嵌入的规模随着图卷积的增加而增大, N_u 表示用户 u 交互的项目

集, N_i 表示与项目 i 交互的用户集. ϕ 是一个组合函数, 其作用是将行为嵌入集成到 GCN 的消息传递中, 考虑了多种行为类型, 分别聚合特定关系的邻居, 可更好地挖掘用户的潜在偏好, 它采用对应向量的元素乘积, 如式(2)所示:

$$\begin{aligned}\phi_u(\mathbf{e}_i^{(l-1)}, \mathbf{e}_r^{(l-1)}) &= \mathbf{e}_i^{(l-1)} \odot \mathbf{e}_r^{(l-1)} \\ \phi_i(\mathbf{e}_u^{(l-1)}, \mathbf{e}_r^{(l-1)}) &= \mathbf{e}_u^{(l-1)} \odot \mathbf{e}_r^{(l-1)}\end{aligned}\quad (2)$$

在节点的嵌入表示传播的同时, 进行行为的嵌入传播, 如式(3)所示:

$$\mathbf{e}_r^{(l)} = \mathbf{W}_r^{(l)} \mathbf{e}_r^{(l-1)} \quad (3)$$

其中, $\mathbf{W}_r^{(l)} \in \mathbb{R}^{d \times d}$ 表示对应行为 r 的第 l 层参数矩阵, d 为嵌入向量维度, 它将所有的行为投影到与节点相同的嵌入空间, 并使行为嵌入可在下一个 GCN 层中被使用.

3.2.2 自注意力机制融合

通过 GCN 传播后的节点嵌入可有效聚集用户(或项目)和行为的嵌入. 由于不同的行为间相互交织, 且不同节点间的行为相关性有所不同, 所提模型 SAMBGCL 利用自注意力机制来建模不同节点与各行为间的依赖关系. 具体来说, 我们将所有行为下的节点嵌入连接起来, 然后计算反映节点与行为之间依赖的系数, 如式(4)所示:

$$\begin{aligned}\alpha_{u,r}^{(l)} &= \text{softmax}((\mathbf{W}_2^{(r)})^T \tanh(\mathbf{e}_u^{(l)} \mathbf{W}_1^{(r)})^T) \\ \alpha_{i,r}^{(l)} &= \text{softmax}((\mathbf{W}_2^{(r)})^T \tanh(\mathbf{e}_i^{(l)} \mathbf{W}_1^{(r)})^T)\end{aligned}\quad (4)$$

其中, $\mathbf{W}_1^{(r)} \in \mathbb{R}^{d \times d'}$ 和 $\mathbf{W}_2^{(r)} \in \mathbb{R}^{d'}$ 是行为 r 的参数, d 为嵌入向量维度, d' 为注意力输出的维度. $\alpha_{u,r}^{(l)}$ 和 $\alpha_{i,r}^{(l)}$ 分别表示用户 u 与项目 i 在行为 r 下的权重系数. $\mathbf{e}_u^{(l)}$ 和 $\mathbf{e}_i^{(l)}$ 分别表示增强嵌入前所有行为下用户 u 与项目 i 在第 l 层嵌入拼接后的表示.

在行为 r 下的增强节点嵌入, 如式(5)所示:

$$\begin{aligned}\mathbf{e}_{u,r}^{(l)*} &= \alpha_{u,r}^{(l)} \mathbf{e}_u^{(l)} \\ \mathbf{e}_{i,r}^{(l)*} &= \alpha_{i,r}^{(l)} \mathbf{e}_i^{(l)}\end{aligned}\quad (5)$$

其中, $\mathbf{e}_{u,r}^{(l)*}$ 和 $\mathbf{e}_{i,r}^{(l)*}$ 分别表示通过自注意力机制增强后的行为 r 下用户 u 和项目 i 的第 l 层嵌入.

对于经过多层消息传播的节点嵌入, 我们还需将其不同行为下用户 u 及其项目 i 的嵌入组合起来, 其每一层传播节点嵌入表示的组合, 如式(6)所示:

$$\begin{aligned}\mathbf{e}_u^{(l)} &= \sum_{r \in R} \mathbf{e}_{u,r}^{(l)*} \\ \mathbf{e}_i^{(l)} &= \sum_{r \in R} \mathbf{e}_{i,r}^{(l)*}\end{aligned}\quad (6)$$

其中, $\mathbf{e}_u^{(l)}$ 和 $\mathbf{e}_i^{(l)}$ 分别表示用户 u 和项目 i 在第 l 层的嵌入表示.

显然, 经历 L 层嵌入传播后, 可得到用户 u 、项目 i 和行为 r 的多个嵌入表示, 每一层的嵌入表示均聚合了该层的邻域信息. 为获得最终表示, 我们将不同层的嵌入进行组合, 如式(7)所示:

$$\begin{aligned}\mathbf{e}_u &= \frac{1}{L+1} \sum_{l=0}^L \mathbf{e}_u^{(l)} \\ \mathbf{e}_i &= \frac{1}{L+1} \sum_{l=0}^L \mathbf{e}_i^{(l)} \\ \mathbf{e}_r &= \frac{1}{L+1} \sum_{l=0}^L \mathbf{e}_r^{(l)}\end{aligned}\quad (7)$$

其中, \mathbf{e}_u 、 \mathbf{e}_i 、 \mathbf{e}_r 分别表示用户 u 、项目 i 、行为 r 的最终嵌入表示. 经过 L 层传播之后, 图中的节点可聚合来自高阶邻域的信息.

3.3 多行为图对比学习

通过多行为感知的 GCN 聚合后, 模型可有效建模不同节点与行为间的关系, 但目标行为的稀疏性问题依旧存在, 即目标行为数(如购买)远小于辅助行为数(如点击、加入购物车等), 而现有模型挖掘辅助行为与目标行为间关系的能力不足.

为提升模型对多行为数据的建模能力, 受文献[33]启发, 我们将对比学习引入目标行为与辅助行为的建模中. 与该文献不同的是, 为减少人为设置阈值的风险性, 并减轻模型计算负担, 我们放弃了其通过点间互信息(Pointwise Mutual Information, PMI)计算相似用户并构造额外正例对的方式, 而是在用户的视角下, 直接将同一个用户的目标行为与辅助行为视为正例对($\mathbf{e}_{u,r'}$, $\mathbf{e}_{u,r''}$), 这里 r' 表示目标行为, r'' 表示辅助行为; 不同用户的辅助行为被认为是负样本($\mathbf{e}_{u,r'}$, $\mathbf{e}_{v,r''}$). 图对比学习中自监督信号加强了不同用户的行为差异. 用户侧的多行为图对比学习损失函数 L_u^{cl} , 如式(8)所示:

$$L_u^{\text{cl}} = - \sum_{r' \in R} \sum_{r'' \in U} \log \frac{\exp(\text{sim}(\mathbf{e}_{u,r'}, \mathbf{e}_{u,r''})/\tau)}{\sum_{v \in U, v \neq u} \exp(\text{sim}(\mathbf{e}_{u,r'}, \mathbf{e}_{v,r''})/\tau)} \quad (8)$$

其中, $\text{sim}(\cdot)$ 表示余弦相似度, τ 是一个温度超参数, 有助于模型学习困难负样本. $\mathbf{e}_{u,r'}$ 与 $\mathbf{e}_{u,r''}$ 分别表示用户 u 在行为 r' 和 r'' 下的嵌入表示, $\mathbf{e}_{v,r''}$ 表示用户 v 在行为 r'' 下的嵌入表示.

同理, 我们可得项目侧的多行为图对比学习损失函数 L_i^{cl} , 如式(9)所示:

$$L_i^{\text{cl}} = - \sum_{r' \in R} \sum_{r'' \in I} \log \frac{\exp(\text{sim}(\mathbf{e}_{i,r'}, \mathbf{e}_{i,r''})/\tau)}{\sum_{j \in I, j \neq i} \exp(\text{sim}(\mathbf{e}_{i,r'}, \mathbf{e}_{j,r''})/\tau)} \quad (9)$$

其中, $\mathbf{e}_{i,r'}$ 与 $\mathbf{e}_{i,r''}$ 分别表示项目 i 在行为 r' 和 r'' 下的嵌入表示, $\mathbf{e}_{j,r''}$ 表示项目 j 在行为 r'' 下的嵌入表示.

综上, 将 2 个损失函数相结合可得到最终的多行为图对比学习损失函数, 如式(10)所示:

$$L^{\text{cl}} = L_u^{\text{cl}} + L_i^{\text{cl}} \quad (10)$$

所提模型 SAMBGCL 通过图对比学习捕获不同行为类型交互的复杂依赖关系, 可有效缓解目标行为稀疏性问题, 同时建模辅助行为与目标行为间的关系, 进

而更好地捕捉不同用户的行为差异性,将其与推荐任务相结合可极大地提高模型性能。

3.4 模型预测与推荐算法

下面给出本文模型 SA-MBGCL 的预测过程,并详细阐述所提模型的整体推荐流程。

3.4.1 模型预测

为预测用户与项目在各行行为下交互的概率,每种行为的学习表示被合并到一个单独的预测层。用户 u 在项目 i 上执行行为 r 的可能性,如式(11)所示:

$$\hat{y}_{(r)ui} = \mathbf{e}_u^T \cdot \text{diag}(\mathbf{e}_r) \cdot \mathbf{e}_i \quad (11)$$

其中, $\hat{y}_{(r)ui}$ 表示用户 u 在行为 r 下与项目 i 交互的概率, $\text{diag}(\mathbf{e}_r)$ 表示对角矩阵, r 的最终嵌入表示 \mathbf{e}_r 作为对角线元素。

为更加有效地学习模型的参数,采用高效的非采样策略来优化模型,该策略是最近提出的一种新的优化学习方法,已被证明在有效性和效率方面均优于传统基于采样的学习方法^[7]。以单个行为 r 为例,利用非采样策略优化损失的过程,如式(12)所示:

$$L^r = \sum_{u \in B} \sum_{i \in I_u^r} \left((c_i^{r+} - c_i^{r-}) \hat{y}_{(r)ui}^2 - 2c_i^{r+} \hat{y}_{(r)ui} \right) + \sum_{a=1}^d \sum_{b=1}^d \left((\mathbf{e}_{r,a} \mathbf{e}_{r,b}) \left(\sum_{u \in B} \mathbf{e}_{u,a} \mathbf{e}_{u,b} \right) \left(\sum_{i \in I} c_i^{r-} \mathbf{e}_{i,a} \mathbf{e}_{i,b} \right) \right) \quad (12)$$

其中, L^r 表示行为 r 的非采样损失函数, B 是一批次用户, I 表示整个项目集, I_u^r 表示用户 u 在行为 r 下的交互项目集, c_i^{r+} 为正样例的权重, c_i^{r-} 为负样例的权重, d 为嵌入向量维度。

得到非采样策略的损失函数后,我们将其与 3.3 节提出的多行为图对比损失函数相结合进行多任务的联合优化过程,如式(13)所示:

$$L^{\text{总}} = \sum_{r \in R} \lambda_r L^r + \lambda_1 L^{\text{cl}} + \lambda_2 \|\Theta\|_2^2 \quad (13)$$

其中, λ_r 的作用是控制行为 r 对联合训练影响的超参数, λ_1 是多行为图对比学习损失函数权重的超参数, λ_2 是正则化系数, Θ 表示模型的可训练参数, $\|\cdot\|_2^2$ 表示 L_2 正则化。

3.4.2 推荐算法

SA-MBGCL 模型通过联合节点与行为的嵌入进行 GCN 嵌入传播,利用自注意力机制获取节点和各行行为间的依赖关系,以强化节点嵌入表示。通过构建多行为图对比学习进一步建模目标行为与辅助行为的关系,并采用多任务学习的方式训练模型,具体过程见算法 1。

在算法 1 中,第 1 行得到用户 u 、项目 i 和行为 r 的初始节点嵌入表示;第 2~6 行表示多行为感知图卷积网络操作过程,其通过多行为传播与自注意力机制融合的用户/项目嵌入传播,并将每一层的嵌入进行组合,得到

算法 1 融合自注意力机制的多行为图对比学习推荐

输入:用户集 U ,项目集 I ,行为集 R ,交互矩阵 $\{\mathbf{Y}^1, \mathbf{Y}^2, \dots, \mathbf{Y}^k\}$ 。

输出:推荐项目列表 List。

BEGIN

1. 初始化用户 u 、项目 i 和行为 r 的嵌入 $\mathbf{e}_u^{(0)}, \mathbf{e}_i^{(0)}, \mathbf{e}_r^{(0)}$;
/* 多行为感知图卷积网络 */
2. 利用初始嵌入计算 u 与 i 在每种行为 r 下第 l 层的嵌入 $\mathbf{e}_{u,r}^{(l)}, \mathbf{e}_{i,r}^{(l)}$; //见式(1)和式(2)
3. 计算每种行为 r 下的第 l 层嵌入 $\mathbf{e}_r^{(l)}$; //见式(3)
4. 计算节点与行为间的依赖系数 $\alpha_{u,r}^{(l)}, \alpha_{i,r}^{(l)}$; //见式(4)
5. 通过依赖系数增强 u 和 i 的节点嵌入 $\mathbf{e}_{u,r}^{(l)}, \mathbf{e}_{i,r}^{(l)}$; //见式(5)
6. 聚合 u 、 i 、 r 每一层潜在嵌入形成最终嵌入 $\mathbf{e}_u, \mathbf{e}_i, \mathbf{e}_r$; //见式(6)和式(7)
/* 多行为图对比学习 */
7. 计算多行为图对比学习的损失函数 L^{cl} ; //见式(8)~(10)
/* 模型预测 */
8. 计算 u 与 i 在行为 r 下交互的预测概率 $\hat{y}_{(r)ui}$; //见式(11)
9. 计算联合训练损失函数 $L^{\text{总}}$ 并更新参数; //见式(12)和式(13)
10. 根据在目标行为下的预测概率,输出推荐项目列表 List。

END

各行行为的嵌入表示与增强后的用户/项目嵌入表示;第 7 行表示多行为图对比学习流程,其利用对比学习的思想获取目标行为与辅助行为的多行为图对比学习损失;第 8~10 行表示模型预测过程,利用前面得到的用户、项目、行为的嵌入表示来计算预测概率,并联合非采样策略损失和多行为图对比学习损失对模型参数进行更新,最终根据在目标行为下的预测概率获得最终的推荐列表。

4 实验设计与分析

为验证所提模型 SA-MBGCL 的性能,我们在 2 个公开数据集上进行了系统性的实验,并对实验结果进行详细分析,重点研究以下问题。

RQ1:与经典的、最新的单行为与多行为模型相比,所提模型 SA-MBGCL 表现如何?针对该问题,在 4.4 节展开了对比实验,将所提模型 SA-MBGCL 在 2 个公开数据集上与 6 个单行为推荐模型以及 10 个多行为推荐模型进行充分对比,在命中率(HR)和归一化折损累计增益(NDCG)这 2 个评价指标上,我们的模型均优于对比模型。

RQ2:SA-MBGCL 模型的不同组件对模型性能有何影响?是否具有必要性?针对该问题,在 4.5 节设置了消融实验,重点研究了所提模型 SA-MBGCL 中的自注意力机制与多行为图对比学习对模型性能的影响。实验结果表明,各变体模型的推荐效果均在不同程度上弱于本文模型,说明了各个组件的必要性和有效性。

RQ3: SA-MBGCL模型中不同类型行为的融合是否会影响目标行为的预测? 针对该问题, 在4.6节设置了辅助行为对目标行为影响的实验, 分别构建了只包含购买行为、包含点击与购买行为、包含加入购物车与购买行为的辅助行为影响实验. 实验结果显示, 去掉任何一种辅助行为都会对模型的性能产生不同程度的影响, 说明了辅助行为对目标行为具有促进作用.

RQ4: 超参数对 SA-MBGCL 模型性能的影响如何? 针对该问题, 在4.7节设置了超参数的敏感度实验, 并重点选择温度超参数 τ 与控制多行为图对比学习损失权重的 λ , 进行研究, 选择它们在不同数据集上使模型达到最优值时的取值, 并分析其潜在的原因.

RQ5: SA-MBGCL模型的时间复杂度如何? 针对该问题, 在4.8节进行了时间复杂度分析, 与经典的单行为推荐模型 LightGCN 和多行为推荐模型 GHCF 进行对比, 分析本文模型在复杂度上的表现.

4.1 数据集

为说明模型的效果, 我们采用2个现实世界的电子商务数据集进行实验, 分别是 Beibei 和 Taobao, 这2个数据集包含3种类型的用户行为, 包括点击、加入购物车和购买, 推荐任务的目标行为是购买. 具体统计信息如表2所示.

表2 2种数据集的数据统计表

数据集	用户数	项目数	点击数	加入购物车数	购买数
Beibei	21 716	7 977	2 412 586	642 622	304 576
Taobao	48 749	39 493	1 548 126	193 747	259 747

(1) Beibei, 来源于 <https://www.beibei.com>, 是中国最大的婴幼儿用品电商平台贝贝的数据集. 包含了2017年7月1日至2017年7月31日间贝贝平台上用户的各种行为数据.

(2) Taobao, 来源于 <https://tianchi.aliyun.com/dataset/dataDetail?dataId=649>, 是中国最大的电子商务平台淘宝的数据集, 记录了2017年11月25日至2017年12月3日间淘宝用户的各种行为数据.

4.2 实验环境

所提模型 SA-MBGCL 采用 PyTorch 框架, 实验环境为: Windows10 64 位操作系统, PyCharm 2022, Python 3.9, 内存 64 GB, CPU 为 Intel Xeon E5-2683 v3 2.00 GHz, GPU 为 Nvidia GeForce RTX 3090.

参考文献[11], 本文模型的嵌入向量维度设置为64, 训练批大小为256, 学习率为0.001, epoch为500, 图卷积层数为4, 正则化系数在 Beibei 中为10, 在 Taobao 中为0.01, 负采样权重在 Beibei 中为0.01, 在 Taobao 中为0.1. 使用 Adam 作为优化器优化模型, 采用 Xavier 作为网格参数初始化的方法, 训练过程中采用早停技术

防止过拟合, 推荐列表长度 N 为10或50.

4.3 评价指标

训练模型后, 通过对训练集中未与用户交互的项目进行排名, 为用户生成个性化排名列表, 然后采用2个广泛使用的指标命中率(HR)和归一化折损累计增益(NDCG)评估排名的效果.

(1) 命中率. 作为一个衡量召回率的指标, 通过计算所测试的目标项目是否在生成的 Top- N 列表中, 来衡量该列表中是否包含用户实际发生过交互的项目. 如式(14)所示:

$$HR = \frac{1}{m} \sum_{i=1}^m \text{hits}(i) \quad (14)$$

其中, m 表示用户总数量, $\text{hits}(i)$ 表示第 i 个用户访问的项目是否在推荐列表中, 是则为1, 否则为0.

(2) 归一化折损累计增益. 作为一个对位置敏感的指标, 它为项目排名列表中较高位置的命中分配较高的得分, 该指标是对折损累计增益(Discounted Cumulative Gain, DCG)的一种改进. 鉴于不同用户的推荐列表长度存在差异, 直接比较不同用户的 DCG 可能不够准确. 为全面评估预测的准确性, 需对不同用户的指标进行归一化操作, 使用 NDCG 可反映推荐项目是否出现在用户更显著的位置上. 如式(15)所示:

$$NDCG = \sum_{u \in U_{\text{test}}} \frac{1}{Y_u} \sum_{i=1}^k \frac{2^{t_i} - 1}{\log_2(i+1)} \quad (15)$$

其中, U_{test} 表示为测试用户集, Y_u 表示为用户 u 的最大 NDCG 值; $t_i = 1$ 表示击中, $t_i = 0$ 表示未击中.

对于这2个指标, 更大的值意味着更好的性能. 使用 HR 和 NDCG 能从推荐结果的命中率和排序角度综合反映推荐的准确性.

4.4 对比实验分析(RQ1)

本节将所提模型 SA-MBGCL 与当前较为流行的单行为以及多行为推荐模型进行对比分析, 阐述本文模型的优势.

4.4.1 对比模型

对比模型分为2类: (1) 仅利用目标行为记录的单行为模型. BPR^[4]是一种经典的基于贝叶斯个性化排名的推荐算法. ExpoMF (Exposure Matrix Factorization)^[5]在矩阵分解的基础上, 引入指数函数来建模用户和项目间的交互关系. NCF (Neural Collaborative Filtering)^[6]结合神经网络与协同过滤的思想, 改进个性化推荐性能. ENMF (Efficient Neural Matrix Factorization)^[7]采用非采样策略优化广义矩阵分解 (Generalized Matrix Factorization, GMF). LightGCN^[8]是轻量级的图卷积推荐模型. IMP-GCN (Interest-aware Message-Passing GCN)^[9]则将具有相似兴趣的用户划分为同一子图, 在子图中执行高阶图卷积操作. (2) 考虑各种行为的多行为模型.

CMF(Collective Matrix Factorization)^[13]同时分解不同行为类型的交互矩阵,并将多个分解过程组合起来. MF-BPR (Multi-Feedback Bayesian Personalized Ranking)^[14]是 BPR 的扩展版本,旨在更好地处理多行为信息. NMTR(Neural Multi-Task Recommendation)^[34]是一种结合了 NCF 和多任务学习的推荐算法. MATN(Memory-Augmented Transformer Networks)^[35]通过不同类型行为的协同信号探索多行为关系结构. EHCF(Efficient Heterogeneous Collaborative Filtering)^[36]以迁移的方式将每个行为的预测关联起来,并采用非采样学习进行多关系推荐. MBGCN^[12]利用图卷积网络来处理数据,并考虑不同行为的建模权重. GHCF^[11]联合节点和行为的嵌入表示进行高阶图卷积操作. S-MBRec^[33]同时考虑了行为的差异和同性. NAH^[19]利用注意力机制区分不同邻居节点的权重. IMG4MR^[37]通过划分具有相似兴趣的用户,在子图中进行多行为图卷积操作.

选取的对比模型均是与本文研究相关的主流模型,将所提模型 SA-MBGCL 与上述模型进行对比,可较全面地验证本文模型的有效性,同时也有助于发现不同类型的、基于不同方法的模型之间所表现出的差异性.

(1) 单行为推荐模型

①BPR:一种使用贝叶斯个性化排名损失函数训练 MF 的方法,该损失函数优化了成对损失,假设观察到的交互比未观察到的交互具有更高的分数.

②ExpoMF:一种基于全数据的项目推荐 MF 方法,将所有缺失的交互视为负面,并根据项目受欢迎程度对其进行加权.

③NCF:一种基于深度学习的方法,将 MF 与多层感知机(MultiLayer Perceptron, MLP)模型相结合用于项目排名.

④ENMF:一种非采样学习推荐框架,该框架通过高效的非采样策略优化 GMF 模型,用于 Top- N 推荐.

⑤LightGCN:一种轻量级的 GCN 推荐模型,修改了 NGCF 的设计,使其更简洁,更加适合推荐.

⑥IMP-GCN:一种兴趣感知消息传递 GCN 推荐模型,通过用户特征和图结构有效识别具有共同兴趣的用户划分子图,并在子图中执行高阶图卷积操作,提高推荐性能.

(2) 多行为推荐模型

①CMF:通过同时分解多种行为类型的数据矩阵,并共享公共实体的嵌入来关联多个分解过程.

②MF-BPR:一种基于 BPR 中的负采样规则,并将其扩展到异构数据上的模型.

③NMTR:基于级联的方式考虑行为的相关性,并通过多任务学习框架捕获多类型交互.

④MATN:通过保留跨类型行为协作信号和特定类型的行为上下文信息来显式编码多行为结构.

⑤EHCF:对细粒度的用户-项目关系进行建模,并使用非采样策略有效地从异构数据中学习模型的参数,也是基于 GMF 的,本质上是 ENMF 的异构版本.

⑥MBGCN:考虑不同行为的强度进行建模,并使用图卷积网络来利用数据.

⑦GHCF:目前多行为推荐中较先进的非采样模型,利用图卷积网络的优势,联合嵌入用户和项目的表示以及关系进行多关系预测.

⑧S-MBRec:一种基于自监督的推荐算法,考虑了多种行为的差异和共性.

⑨NAH:一种强调用户偏好强度的多行为推荐算法,在嵌入传播过程中利用注意力机制区分不同的相邻节点,并根据不同项目的重要性分配不同的权重,以增强推荐.

⑩IMG4MR:将具有相似兴趣的用户及其交互项从原始交互图中分离出来构建子图,并在子图中执行高阶的多行为图卷积操作.

4.4.2 对比结果与分析

为评估所提模型 SA-MBGCL 的效果,我们与主流的 6 种单行为推荐模型以及 10 种多行为推荐模型在 2 个数据集上对 HR@ N 值和 NDCG@ N 值进行详细对比,这里的 N 取 10 或 50,具体见表 3.

由表 3 可看出,本文模型 SA-MBGCL 在 2 个指标 HR@ N 和 NDCG@ N (N 取 10 或 50) 上,均优于对比模型. 下面是具体分析,其中“最少提升”的计算,以对比模型 BPR 的 HR@ N 指标为例,从本文模型 SA-MBGCL 相对于模型 BPR 在 2 个数据集的 HR@ N (N 取 10 或 50) 指标上的 4 个提升比例中选取最小值,为 145.48%.

(1) 与单行为的推荐模型相比. 多行为的推荐模型在各个指标上普遍优于单行为的推荐模型,本文模型与表现较优的单行为对比模型(如 ENMF、LightGCN、IMP-GCN)相比在 HR@ N 和 NDCG@ N 指标上分别最少提升 114.65%、108.03%.

由此可见,多种行为的融合建模对提升推荐效果具有积极作用. 在用户未展现购买行为(目标行为)的情况下,考虑点击、加入购物车等辅助行为同样有助于系统发现用户可能感兴趣的项目. 因此,融合多种行为信息至模型中是十分有效的.

(2) 与基于矩阵分解的方法相比. 在单行为推荐中,使用图卷积神经网络的模型(如 LightGCN、IMP-GCN)效果普遍优于传统基于矩阵分解的模型(如 BPR、ExpoMF). 同理,在多行为推荐中,使用图卷积神经网络的模型(如 SA-MBGCL、IMG4MR、HAN、GHCF、MBGCN)效果也普遍优于传统模型(如 EHCF、MF-

表3 Beibei和Taobao数据集上的各模型性能对比

模型	Beibei				Taobao			
	HR@10	HR@50	NDCG@10	NDCG@50	HR@10	HR@50	NDCG@10	NDCG@50
BPR	0.043 7	0.124 6	0.021 3	0.040 7	0.037 6	0.070 8	0.022 7	0.026 9
ExpoMF	0.045 2	0.146 5	0.022 7	0.042 6	0.038 6	0.071 3	0.023 8	0.027 0
NCF	0.044 1	0.156 2	0.022 5	0.044 5	0.039 1	0.072 8	0.023 3	0.028 1
ENMF	0.046 4	0.163 7	0.024 7	0.048 4	0.039 8	0.074 3	0.024 4	0.029 8
LightGCN	0.045 1	0.161 3	0.023 2	0.046 6	0.041 5	0.081 4	0.023 7	0.032 5
IMP-GCN	0.045 9	0.161 6	0.023 3	0.046 2	0.043 0	0.079 3	0.024 9	0.032 9
CMF	0.048 2	0.158 2	0.025 1	0.046 2	0.048 3	0.077 4	0.025 2	0.029 3
MF-BPR	0.050 4	0.174 3	0.025 4	0.050 3	0.054 7	0.079 1	0.026 3	0.029 7
NMTR	0.052 4	0.204 7	0.028 5	0.060 9	0.058 5	0.094 2	0.027 8	0.033 4
MATN	0.115 7	0.289 2	0.062 2	0.099 7	0.069 1	0.148 7	0.038 1	0.056 4
EHCF	0.152 3	0.331 6	0.081 7	0.121 3	0.071 7	0.161 8	0.040 3	0.059 4
MBGCN	0.156 4	0.343 4	0.082 8	0.128 2	0.070 1	0.152 2	0.039 0	0.057 1
GHCF	0.192 2	0.379 4	0.101 2	0.142 6	0.080 7	0.189 2	0.044 2	0.067 8
S-MBRec	0.169 7	0.370 8	0.087 2	0.131 3	0.081 4	0.187 8	<u>0.044 6</u>	0.067 7
NAH	0.192 2	<u>0.387 8</u>	0.100 6	<u>0.144 3</u>	<u>0.081 5</u>	<u>0.190 5</u>	0.044 4	<u>0.068 1</u>
IMG4MR	<u>0.192 9</u>	0.381 0	<u>0.102 2</u>	0.142 5	0.076 3	0.175 6	0.042 2	0.063 4
SA-MBGCL	0.202 1	0.388 1	0.107 1	0.147 8	0.092 3	0.195 7	0.051 8	0.074 8
提升/%	4.77	0.08	4.78	2.43	13.25	2.73	16.14	9.84

注:本文模型SA-MBGCL的指标值用加粗标示,对比模型的最优值用下划线标示,表底给出SA-MBGCL相对于最优值的性能提升情况.例如,就Beibei的HR@10指标,在对比模型中,IMG4MR表现最优,SA-MBGCL相较于它,提升了4.77%.

BPR,CMF).本文模型SA-MBGCL与基于矩阵分解最优的对比模型EHCF相比,在HR@N和NDCG@N指标上分别最少提升17.04%、21.85%.

主要原因在于,传统的基于矩阵分解的推荐模型难以有效地获取高阶的协同信息,而图卷积网络将初始嵌入放入图卷积层中传播,可有效地获取用户和项目的高阶信息.但目标行为的稀疏性问题也限制了图卷积网络在多行为推荐中的进一步发挥,因此,本文模型采用对比学习建模目标行为与辅助行为的关系,以有效缓解目标行为的稀疏性问题.

(3)与基于采样策略的推荐模型相比.基于非采样策略的模型(如SA-MBGCL、IMG4MR、HAN、GHCF)效果普遍优于其他基于采样策略的模型(如S-MBRec、NMTR、MBGCN、MATN),与基于采样策略的最优对比模型S-MBRec相比,本文模型SA-MBGCL在HR@N和NDCG@N指标上分别最少提升4.21%、10.49%.

基于采样的方法可能无法捕获足够的协同过滤信号,并在多行为场景中带来有偏见的结果.因此,本文模型使用非采样策略优化模型以提高推荐性能.与大多数基于非采样策略模型不同的是,所提模型还考虑了对比学习所捕获的监督信号,将两者相结合一起优化,进而达到更优的推荐效果.

(4)与近期的模型相比.HAN模型认为现有模型无法有效捕获用户对不同项目的偏好,因此利用注意力

机制捕获用户偏好强度,使其能更好地进行高阶嵌入传播.与其相比,本文模型SA-MBGCL在HR@N和NDCG@N指标上分别最少提升0.08%、2.43%.IMG4MR模型认为传统图卷积的过渡平滑问题会影响多行为模型的性能,因此将具有相似兴趣的用户及其交互项目划分为同一子图,在子图中执行高阶多行为图卷积操作.与其相比,本文模型SA-MBGCL在HR@N和NDCG@N指标上分别最少提升1.86%、3.72%.

HAN考虑了不同邻域之间的权重关系,IMG4MR关注到了图卷积自身的过渡平滑给模型造成的不良影响.但它们均对节点与行为的关系建模不足,且并未考虑目标行为的稀疏性对模型效果带来的负面影响.所提模型SA-MBGCL通过自注意力机制捕获不同节点与各行为间的关系,进一步增强了嵌入表示,并采用对比学习建模目标行为与辅助行为的关系,从而达到更优的推荐效果.

综合以上分析,本文模型SA-MBGCL在Beibei和Taobao这2个数据集上与最优的对比模型相比,HR@N分别最少提升0.08%、2.73%,NDCG@N分别最少提升2.43%、9.84%.从提升效果看,模型在Taobao数据集上的提升大于Beibei,原因在于Taobao数据集更加稀疏且用户、项目关系更为复杂,这更有利于发挥本文模型的优势.本文模型在各个数据集的各项指标上均达到最优效果,这主要归功于:(1)引入自注意力机制更好地

建模不同节点与行为间的关系;(2)采用图对比学习建模目标行为与辅助行为的关系,有效地缓解了目标行为的稀疏性问题;(3)使用了非采样的优化策略,使得对模型的优化更加稳定高效.

4.5 消融实验分析(RQ2)

为阐明本文模型 SA-MBGCL 中自注意力机制和多行为图对比学习的必要性和有效性,我们对模型做消融实验对比,构建 3 种变体模型,分别用 MBGCF、MBGCL、SA-MBGCF 表示.(1)MBGCF 是在 SA-MBGCL 模型中同时去掉自注意力机制和多行为图对比学习模块;(2)MBGCL 是在 SA-MBGCL 模型中去掉自注意力机制模块;(3)SA-MBGCF 是在 SA-MBGCL 模型中去掉了多行为图对比学习模块.表 4 是 3 种变体模型的组件构成详细情况.

表 4 变体模型组件构成情况

变体模型	自注意力	多行为图对比学习	GCN
MBGCF	×	×	○
MBGCL	×	○	○
SA-MBGCF	○	×	○
SA-MBGCL	○	○	○

注:“×”表示去掉该组件;“○”表示保留该组件.

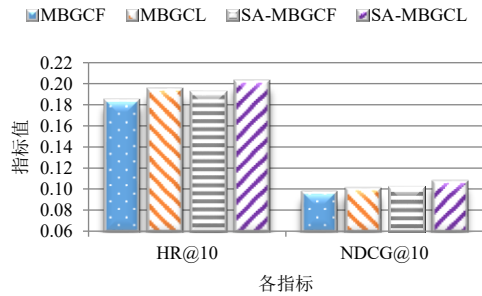
我们选取 HR@10 和 NDCG@10 指标进行消融实验对比,如图 2 所示.

从图 2 可知,模型的 2 个关键组件自注意力机制和多行为图对比学习均对模型性能有不同程度的影响.变体模型 MBGCF、MBGCL、SA-MBGCF 的性能均低于本文模型 SA-MBGCL,其中同时去除 2 个组件的变体模型 MBGCF 性能最差,见如下分析.


(1)自注意力机制对模型性能有较大影响.本文模型引入自注意力机制建模不同节点与各行为间的关系.通常情况下,Taobao 数据集的用户、项目繁杂程度高于 Beibei 数据集,节点与行为的关系也更复杂,而自注意力机制可通过合适的权重分配帮助模型更好地学习不同节点与行为的依赖关系.也就是说,相对复杂的场景蕴含着更丰富的潜在信息,而自注意力机制可充分考虑全局性的依赖进而更大程度地增强节点表示.故模型在更复杂的 Taobao 数据集中,更能发挥自身的优势.

(2)多行为图对比学习同样对模型性能有较大影响.所提模型利用多行为图对比学习建模目标行为与辅助行为的关系,以缓解目标行为的稀疏性问题.而 Taobao 数据集的数据稀疏性高于 Beibei 数据集,故多行为图对比学习可得到更好的发挥.

综上分析,模型的各个组件对提升模型的效果均有一定程度的作用.但在 Taobao 数据集中的作用更大,其原因在于 Taobao 数据集的数据关系更为复杂且数据



(a) beibei 数据集



(b) Taobao 数据集

图 2 各变体模型与 SA-MBGCL 的 HR@10 和 NDCG@10 值对比

也更稀疏,更有利于发挥本文模型的优势.

4.6 辅助行为对目标行为的影响分析(RQ3)

为验证辅助行为对目标行为的促进作用,构建 3 种辅助行为影响实验.(1)SA-GCL/P:仅使用购买数据的 SA-MBGCL 模型.(2)SA-GCL/PC:使用购买和加入购物车数据的 SA-MBGCL 模型.(3)SA-GCL/PV:使用购买和点击数据的 SA-MBGCL 模型.各变体操作的详细情况如表 5 所示.

表 5 各变体操作使用不同行为数据的情况


变体操作	点击	加入购物车	购买
SA-GCL/P	×	×	○
SA-GCL/PC	×	○	○
SA-GCL/PV	○	×	○
SA-MBGCL	○	○	○

注:“×”表示未触发该行为;“○”表示触发该行为.

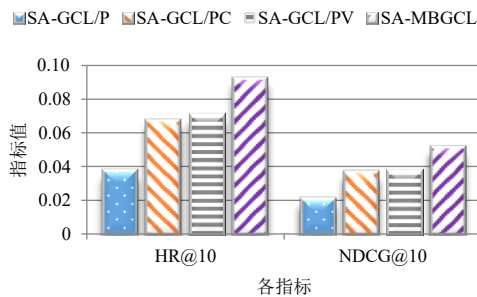
我们同样选取 HR@10 和 NDCG@10 指标进行辅助行为影响实验对比,如图 3 所示.

从图 3 可知,使用完整行为的 SA-MBGCL 效果最佳,缺少了任意辅助行为的模型在性能上均低于该模型.可知,添加辅助行为有助于提升模型的整体性能.我们发现:

(1)Beibei 数据集中加入购物车的行为贡献大于



(a) Beibei 数据集



(b) Taobao 数据集

图3 辅助行为影响对比

Taobao 数据集,原因在于,在原始数据集中 Beibei 的加入购物车行为就多于 Taobao 数据集,辅助行为的次数不同造成了对目标行为有不同的促进程度.

(2)在2个数据集中,点击行为次数均远大于加入购物车行为,而在 Beibei 数据集中,利用加入购物车行为和目标行为的 SA-GCL/PC 模型性能远大于利用点击行为和目标行为的 SA-GCL/PV 模型,在 Taobao 数据集中两者相差不大,这说明加入购物车行为更能体现用户的兴趣偏好.

综上分析,使用一种辅助行为的 SA-GCL/PC 与 SA-GCL/PV 在性能上均高于仅使用目标行为的 SA-GCL/P,而使用2种辅助行为融合的 SA-MBGCL 则达到最优效果.可见,辅助行为可体现用户的潜在兴趣,不同辅助行为的融合有助于模型对目标行为的推荐.

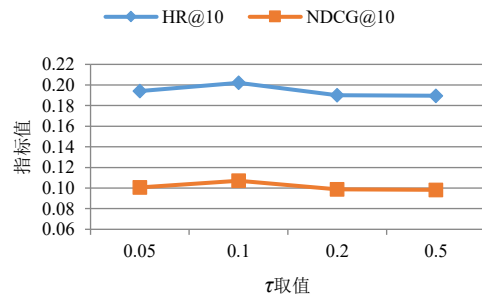
4.7 参数敏感度分析(RQ4)

这里对模型中2个关键超参数:温度超参数 τ 和控制多行为图对比学习损失权重的 λ_1 进行实验分析,阐述它们在不同数据集上对模型性能的影响.


4.7.1 超参数 τ 的影响

τ 表示对比学习中的温度超参数,其作用是调节模型对困难负样本的重视程度. τ 越大,重视程度越低, τ 越小,重视程度越高.当 τ 很小的时候,模型会特别关注困难负样本,但其实这些负样本很可能就是潜在的正

样本,这样会导致模型难以收敛或泛化能力差.而当 τ 增至无穷大时,会使对比学习对所有负样本一视同仁,导致模型学习没有轻重.为选取最优的 τ 值,实验设置其取值来自集合 $\{0.05, 0.1, 0.2, 0.5\}$.不同数据集下 HR@10 和 NDCG@10 指标值随 τ 取值变化情况,如图4所示.



(a) Beibei 数据集



(b) Taobao 数据集

图4 参数 τ 的影响

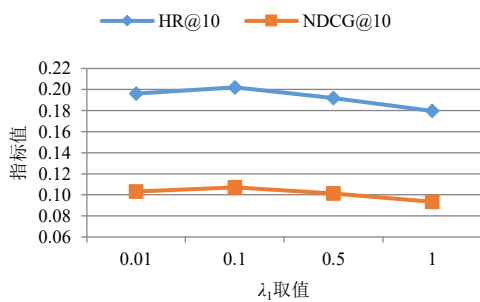
从图4可看出,随着 τ 值的增大,模型性能先提升后降低.在 Beibei 数据集中, τ 取0.1时,模型性能达到最佳,在 Taobao 数据集中, τ 同样为0.1时,模型获得最佳效果.

可见,温度超参数 τ 对模型性能有着较大影响,需要调节其取值以适应自身数据集的特点,进而达到最优的推荐效果.

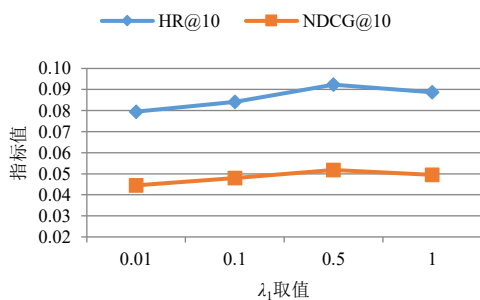
4.7.2 超参数 λ_1 的影响

λ_1 是控制多行为图对比学习辅助任务占联合学习任务比重的参数,其值越大,多行为图对比学习对模型性能的影响越大.为选取最优的 λ_1 值,实验设置其取值来自集合 $\{0.01, 0.1, 0.5, 1.0\}$.不同数据集下 HR@10 和 NDCG@10 指标值随 λ_1 取值变化情况,如图5所示.

从图5可看出,在 Beibei 数据集中, λ_1 取0.1时,模型性能达到最优,之后随着 λ_1 取值的增大而逐渐降低;



(a) Beibei 数据集



(b) Taobao 数据集

图5 参数 λ_1 的影响

在 Taobao 数据集中, λ_1 取 0.5 时, 各指标达到最大值。

可见, 在这 2 个数据集上, 参数 λ_1 的最优取值有所不同, 我们认为这是合理的。在不同的数据集中, 原始数据情况并不相同, 合适的 λ_1 取值能更好地调节多行为图对比学习任务在整体任务中的比重, 进而实现更优的推荐性能。

综上对各主要超参数的分析可知, 在 Beibei 和 Taobao 数据集中, 设置 τ 取值分别为 0.1、0.1, λ_1 取值分别为 0.1、0.5 时, 模型整体可达到最优效果。

4.8 时间复杂度分析(RQ5)

与经典的单行为与多行为模型相比, 本文模型 SA-MBGCL 引入自注意力机制建模不同节点与各行为的关系, 并利用多行为图对比学习缓解目标行为的稀疏性问题, 致使模型在时间复杂度上略有增加, 但其推荐性能却优于对比模型, 具体分析如下。

(1) 就本文模型 SA-MBGCL 而言, 其聚合节点与行为嵌入的同时, 利用自注意力机制计算不同节点与行为间的权重, 这部分的时间复杂度大致为 $O(kELd^2)$, 其中 k 表示行为类型数, E 表示多行为交互图的边数, L 表示图卷积的层数, d 表示嵌入向量维度; 多行为图对比学习模块的时间复杂度大致为 $O(kVLd)$, 其中 V 表示交互图的节点数; 模型训练的时间复杂度大致为 $O((M_u+n)d^2+Ed+BMd)$, 其中 B 表示批量大小, M 表示一个批次

中的节点数, M_u 表示一个批次中的用户数, n 表示总项目数。由于在一般情况下, Ed 大于 V , 因此, 本文模型时间复杂度大致为 $O(kELd^2+(M_u+n)d^2+BMd)$ 。

(2) 就单行为推荐模型 LightGCN 而言, 该模型是轻量级的图卷积模型, 运算主要体现在执行图卷积的操作过程中, 时间复杂度为 $O(2ELd)$, 其模型训练的时间复杂度为 $O(2Bd)$, 因此, 该模型时间复杂度大致为 $O(ELd+Bd)$ 。本文模型 SA-MBGCL 与其相比复杂度有所增加, 但换来了较大的性能提升, 这是值得的。

(3) 就经典的多行为推荐模型 GHCF 而言, 该模型是目前较先进的多行为推荐模型, 其运算主要体现在将行为融入到节点中进行图卷积操作, 时间复杂度大致为 $O(kELd)$, 其模型训练的时间复杂度为 $O((M_u+n)d^2+Ed)$, 因此, 该模型的时间复杂度大致为 $O(kELd+(M_u+n)d^2)$ 。所提模型 SA-MBGCL 与其相比复杂度略有增加, 但性能提升可观, 这点牺牲也是值得的。

综上分析, 各模型时间复杂度高低为 SA-MBGCL > GHCF > LightGCN。尽管从时间复杂度上看, 本文模型 SA-MBGCL 的效率略逊于对比模型, 但结合实验效果分析, 所提模型依旧是极有意义的。由于本文模型需要处理多行为的数据并挖掘其间关系, 因此对比轻量级的单行为模型 LightGCN, 时间复杂度有一定程度的增加, 但性能上有较大的提升。本文模型 SA-MBGCL 相较于 LightGCN, 在 HR@N 和 NDCG@N 指标上分别最少提升 122.41%、130.15%。对比多行为推荐模型 GHCF, 本文模型引入自注意力机制建模不同节点与行为间关系, 利用对比学习缓解目标行为的稀疏性, 致使模型时间复杂度有所增加, 但就数量级而言, 两者相差并不大, 对于目前大多数 GPU/CPU 而言, 这是可接受的。且就性能而言, 所提模型 SA-MBGCL 相较于 GHCF, 在 HR@N 和 NDCG@N 指标上分别最少提升 2.29%、3.65%。

5 总结与下一步工作

本文提出一种融合自注意力机制的多行为图对比学习推荐模型 SA-MBGCL。该模型将行为嵌入组合到节点嵌入中, 并通过自注意力机制捕获不同节点与各行为间的依赖关系, 以获得更高质量的嵌入表示。另外, 采用对比学习建模目标行为与辅助行为间的关系, 更好地缓解目标行为的稀疏性问题。主要工作如下:

(1) 为捕获不同节点与各行为间的关系, 融合了自注意力机制。通过将行为嵌入组合到节点嵌入中进行高阶图卷积操作, 捕获节点与行为间的高阶关系, 同时融合自注意力机制以进一步提升模型的嵌入表示, 以此来建模不同节点与各行为的关系。

(2) 为建模目标行为与辅助行为的联系, 采用了对比学习。通过将同一用户的目标行为与辅助行为构建

为正例对,不同用户的构建为负例对,来建模目标行为与辅助行为的关系,从而更好地缓解目标行为的稀疏性问题.

(3)根据多种实验分析所提模型的有效性.在2个公开数据集上与相关模型进行对比实验,阐明了所提模型的优势.通过消融实验,验证了模型各个组件的必要性.利用辅助行为影响实验,说明了辅助行为对目标行为的促进作用.另外,开展超参数敏感度实验,优化了模型的关键参数.

虽然本文模型SA-MBGCL在一定程度上优于相关对比模型,但依旧存在一些不足.所提模型利用自注意力机制建模节点和行为依赖,采用图对比学习方式强化目标行为与辅助行为的联系,但未考虑用户的行为顺序.下一步我们将在模型中融入用户的行为顺序,希望进一步提升推荐性能.

参考文献

- [1] 钱忠胜,赵畅,俞情媛,等.结合注意力CNN与GNN的信息融合推荐方法[J].软件学报,2023,34(5):2317-2336.
QIAN Z S, ZHAO C, YU Q Y, et al. Information fusion recommendation approach combining attention CNN and GNN[J]. Journal of Software, 2023, 34(5): 2317-2336. (in Chinese)
- [2] REN Y, TANG H Y, RONG J P, et al. Unbiased pairwise learning from implicit feedback for recommender systems without biased variance control[C]//Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2023: 2461-2465.
- [3] LIN J, HE M K, PAN W K, et al. Collaborative filtering with sequential implicit feedback via learning users' preferences over item-sets[J]. Information Sciences, 2023, 621: 136-155.
- [4] RENDLE S, FREUDENTHALER C, GANTNER Z, et al. BPR: Bayesian personalized ranking from implicit feedback[J]. Proceedings of the 25th Conference on Uncertainty in Artificial Intelligence. Montreal: AUAI Press, 2009: 452-461.
- [5] LIANG D W, CHARLIN L, MCINERNEY J, et al. Modeling user exposure in recommendation[C]//Proceedings of the 25th International Conference on World Wide Web. Montreal: International World Wide Web Conferences Steering Committee, 2016: 951-961.
- [6] HE X N, LIAO L Z, ZHANG H W, et al. Neural collaborative filtering[C]//Proceedings of the 26th International Conference on World Wide Web. Perth: International World Wide Web Conferences Steering Committee, 2017, 173-182.
- [7] CHEN C, ZHANG M, ZHANG Y F, et al. Efficient neural matrix factorization without sampling for recommendation[J]. ACM Transactions on Information Systems, 2020, 38(2): 1-28.
- [8] HE X N, DENG K, WANG X, et al. LightGCN: Simplifying and powering graph convolution network for recommendation[C]//Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2020, 639-648.
- [9] LIU F, CHENG Z Y, ZHU L, et al. Interest-aware message-passing GCN for recommendation[C]//Proceedings of the Web Conference 2021. New York: ACM, 2021: 1296-1305.
- [10] XUAN H R, LIU Y, LI B H, et al. Knowledge enhancement for contrastive multi-behavior recommendation[C]//Proceedings of the Sixteenth ACM International Conference on Web Search and Data Mining. New York: ACM, 2023: 195-203.
- [11] CHEN C, MA W Z, ZHANG M, et al. Graph heterogeneous multi-relational recommendation[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(5): 3958-3966.
- [12] JIN B W, GAO C, HE X N, et al. Multi-behavior recommendation with graph convolutional networks[C]//Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2020: 659-668.
- [13] ZHAO Z, CHENG Z Y, HONG L C, et al. Improving user topic interest profiles by behavior factorization[C]//Proceedings of the 24th International Conference on World Wide Web. Republic and Canton of Geneva, Switzerland: International World Wide Web Conferences Steering Committee, 2015: 1406-1416.
- [14] LONI B, PAGANO R, LARSON M, et al. Bayesian personalized ranking with multi-channel user feedback[C]//Proceedings of the 10th ACM Conference on Recommender Systems. New York: ACM, 2016: 361-364.
- [15] SHI C, LIU J, ZHANG Y D, et al. MFPR: A personalized ranking recommendation with multiple feedback[J]. ACM Transactions on Social Computing, 2018, 1(2): 1-22.
- [16] DING J T, YU G H, HE X N, et al. Sampler design for Bayesian personalized ranking by leveraging view data[J]. IEEE Transactions on Knowledge and Data Engineering,

- 2021, 33(2): 667-681.
- [17] ZHANG W F, MAO J W, CAO Y, et al. Multiplex graph neural networks for multi-behavior recommendation[C]// Proceedings of the 29th ACM International Conference on Information & Knowledge Management. New York: ACM, 2020: 2313-2316.
- [18] XIA L H, HUANG C, XU Y, et al. Knowledge-enhanced hierarchical graph transformer network for multi-behavior recommendation[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(5): 4486-4493.
- [19] JIANG N, HU Z H, WEN J, et al. NAH: Neighbor-aware attention-based heterogeneous relation network model in E-commerce recommendation[J]. World Wide Web, 2023, 26(5): 2373-2394.
- [20] VAN DEN BERG R, KIPF T N, WELLING M. Graph convolutional matrix completion [C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2018: 974-983.
- [21] WANG X, HE X N, WANG M, et al. Neural graph collaborative filtering[C]//Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2019: 165-174.
- [22] 曹阳,高旻,余俊良,等. 基于双图混合随机游走的社会化推荐模型[J]. 电子学报, 2023, 51(2): 286-296.
CAO Y, GAO M, YU J L, et al. Bi-graph mix-random walk based social recommendation model[J]. Acta Electronica Sinica, 2023, 51(2): 286-296. (in Chinese)
- [23] 周俊,胡斌斌,张志强,等. MoGE:基于图上下文增强的多任务推荐算法[J]. 电子学报, 2023, 51(11): 3377-3387.
ZHOU J, HU B B, ZHANG Z Q, et al. MoGE: Graph context enhanced multi-task recommendation method[J]. Acta Electronica Sinica, 2023, 51(11): 3377-3387. (in Chinese)
- [24] TANG L, LONG B, CHEN B C, et al. An empirical study on recommendation with multiple types of feedback[C]// Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2016: 283-292.
- [25] MENG C, ZHAO Z Q, GUO W, et al. Coarse-to-fine knowledge-enhanced multi-interest learning framework for multi-behavior recommendation[J]. ACM Transactions on Information Systems, 2024, 42(1): 1-27.
- [26] CHENG Z Y, HAN S, LIU F, et al. Multi-behavior recommendation with cascading graph convolution networks[C]// Proceedings of the ACM Web Conference 2023. New York: ACM, 2023: 1181-1189.
- [27] XIA L H, XU Y, HUANG C, et al. Graph meta network for multi-behavior recommendation[C]//Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2021: 757-766.
- [28] 张帅,高旻,文俊浩,等. 基于自监督学习的去流行度偏差推荐方法[J]. 电子学报, 2022, 50(10): 2361-2371.
ZHANG S, GAO M, WEN J H, et al. Self-supervised learning for alleviating popularity bias in recommender systems[J]. Acta Electronica Sinica, 2022, 50(10): 2361-2371. (in Chinese)
- [29] 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[J]. 电子学报, 2023, 51(7): 1929-1938.
FAN W, ZHOU W, WEN J H. Recommendation based on graph heterogeneous using dual channel cross-adaptive contrast learning[J]. Acta Electronica Sinica, 2023, 51(7): 1929-1938. (in Chinese)
- [30] WU J C, WANG X, FENG F L, et al. Self-supervised graph learning for recommendation[C]//Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2021: 726-735.
- [31] YU J L, YIN H Z, XIA X, et al. Are graph augmentations necessary? Simple graph contrastive learning for recommendation[C]//Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2022: 1294-1303.
- [32] LI C L, XIA L H, REN X B, et al. Graph transformer for recommendation[C]//Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2023: 1680-1689.
- [33] GU S Y, WANG X, SHI C, et al. Self-supervised graph neural networks for multi-behavior recommendation[C]// Proceedings of the 31st International Joint Conference on Artificial Intelligence. Vienna: IJCAI, 2022: 2052-2058.
- [34] GAO C, HE X N, GAN D H, et al. Neural multi-task recommendation from multi-behavior data[C]//2019 IEEE 35th International Conference on Data Engineering (ICDE). Piscataway: IEEE, 2019: 1554-1557.
- [35] XIA L H, HUANG C, XU Y, et al. Multiplex behavioral relation learning for recommendation via memory augmented transformer network[C]//Proceedings of the 43rd

International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2020: 2397-2406.

- [36] CHEN C, ZHANG M, ZHANG Y F, et al. Efficient heterogeneous collaborative filtering without negative sampling for recommendation[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(1): 19-26.
- [37] CHANG Y H, ZHOU W, WEN J H. IHG4MR: Interest-oriented heterogeneous graph for multirelational recommendation[J]. Expert Systems with Applications, 2023, 228: 120321.

作者简介



钱忠胜 男, 1977年1月出生, 江西鹰潭人. 2008年在上海大学获工学博士学位. 江西财经大学教授, 博士生导师. 主要研究方向为软件工程、机器学习、智能化软件等.

E-mail: changesme@163.com



黄恒 男, 1999年6月出生, 浙江金华人. 江西财经大学计算机与人工智能学院硕士. 主要研究方向智能推荐系统、软件工程等.

E-mail: hh2902195506@163.com



万子琰 男, 1999年8月出生, 江西九江人. 江西财经大学计算机与人工智能学院硕士研究生. 主要研究方向为智能推荐系统、软件工程等.

E-mail: 913220568@qq.com