

基于异构图的双通道交叉自适应对比学习推荐

范 伟^{1,2}, 周 魏^{1,2}, 文俊浩^{1,2}

(1. 重庆大学大数据与软件学院, 重庆 400044; 2. 信息物理社会可信服务计算教育部重点实验室(重庆大学), 重庆 400044)

摘要: 通过用户多行为进行推荐任务中, 各个行为通常不是独立作用的, 行为之间的协同作用和依赖关系挖掘更能增强用户行为模式建模, 反映用户偏好. 而用户多行为关系的引入也会增加用户物品交互图与表征空间中的异质性(heterogeneity). 针对上述问题, 本文设计了一种基于异构图的双通道交叉自适应对比学习推荐模型MB-DCAC (Multi-Behavior Recommendation through Dual-channel Cross-Adaptive Contrast learning), 创新性的从异构数据卷积过程构建对比学习方案, 并基于异构连接进行表征属性增强, 以提升模型挖掘用户行为模式与表达能力. 实验结果表明, 本文模型在Tmall、IJCAI-Context、Beibei三个数据集上, 相较于基准模型在HR@10指标上分别提升了16.7%、18.3%、2.76%. 且模型在挖掘多行为之间的依赖挖掘等任务上表现优异.

关键词: 推荐系统; 多行为; 异构图; 对比学习; 行为依赖; 异质性

基金项目: 国家自然科学基金(No.72074036, No.62072060); 中国博士后科学基金(No.2020M673145); 中央高校基金(No.2022CDJXY-022)

中图分类号: TP311

文献标识码: A

文章编号: 0372-2112(2023)07-1929-10

电子学报URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20230003

Recommendation Based on Graph Heterogeneous Using Dual Channel Cross-Adaptive Contrast Learning

FAN Wei^{1,2}, ZHOU Wei^{1,2}, WEN Jun-hao^{1,2}

(1. School of Big Data & Software Engineering, Chongqing University, Chongqing 400044, China;

2. Key Laboratory of Dependable Service Computing in Cyber Physical Society (Chongqing University),
Ministry of Education, Chongqing 400044, China)

Abstract: In the task of recommendation through multiple behaviors, individual behaviors usually do not work independently. The mining of collaborative effects and dependencies between behaviors can better enhance user behavior modeling and reflect user preferences. The introduction of multiple user behavior relationships also increases the heterogeneity in the user-item interaction graph and representation space. To address these issues, this paper proposes a dual-channel cross-adaptive contrast learning recommendation model (MB-DCAC), based on heterogeneous graphs. To improve the model's ability to mine user behavior patterns and expressions, this model innovatively constructs a comparative learning scheme from the convolution process of heterogeneous data and enhances the representation features based on heterogeneous connections. Experimental results show that compared with the baseline model, the proposed model improves the HR@10 metric by 16.7%, 18.3%, and 2.76% on the Tmall, IJCAI-Context, and Beibei datasets, respectively. This model also performs well in tasks such as mining dependencies between multiple behaviors.

Key words: recommendation system; multi-behavior; graph heterogeneous; contrastive learning; behavioral dependencies; heterogeneity

Foundation Item(s): National Natural Science Foundation of China (No.72074036, No.62072060); China Postdoctoral Science Foundation (No.2020M673145); Fundamental Research Funds for the Central Universities (No.2022CDJXY-022)

1 引言

推荐系统作为一种缓解信息过载的工具, 在电子

商务、视频流、音乐流等线上应用平台发挥着重要作用. 通过为用户提供满足需求的个性化平台业务, 不仅

能提升用户使用体验,同时可以有效增加企业营收.自1992年Goldberg等^[1]提出基于用户协同过滤的邮件分类推荐模型以来,推荐系统在工业和学界都取得了重要成果.Koren等^[2]通过对用户物品交互矩阵进行矩阵分解,获取了用户与物品更具泛化性的表示.深度学习时代,模型发展更加多元.何向南等^[3]设计了轻量且高效的图卷积方案,获取节点高阶邻接表示,更简洁地实现了基于用户或物品的图卷积协同过滤推荐;Zhang等^[4]基于观测数据构建因果图并施加干预,从而获取对某物品点击的条件概率,进行因果推荐;李泽超等^[5]通过挖掘与用户交互过的物品长期或短期序列来实现基于用户交互序列的会话推荐等.

而一般的推荐算法通常面临数据稀疏、冷启动等问题^[6,7].针对该问题,引入多行为信息成为一种重要的解决方式.如图1所示,除了目标行为(推荐平台最关注的业务行为比如购买),用户与物品之间往往还伴随点击、收藏、加入购物车等辅助行为.Jin等^[8]通过计算行为权重聚合多行为信息,再基于图卷积技术进行信息传递;夏良昊等^[9]在多行为交互数据基础上引入了物品关系的先验知识,先获取各个行为下的语义,再基于图注意力网络进行消息传递,捕获用户动态交互特征.在其MB-GMN^[10]工作中,采用了元学习算法从用户角度个性化捕获用户行为习惯.包括这些模型在内的多个推荐模型从不同方向给出了多行为交互数据的处理思路,极大丰富了多行为推荐的内容.然而,其中关于行为数据的研究,多是将多行为连接作为辅助信息来构建行为视图或增强语义关联.没有或仅在一定程度上关注行为间的协同依赖以及引入多行为数据后异构空间中的异质性问题.

针对上述问题,本文提出了一种双通道交叉自适应对比学习多行为推荐模型,通过设计行为聚合与消息传递范式,更准确的捕获行为依赖及其协同作用.结合异构数据特征构建多任务训练框架,提高异构数据

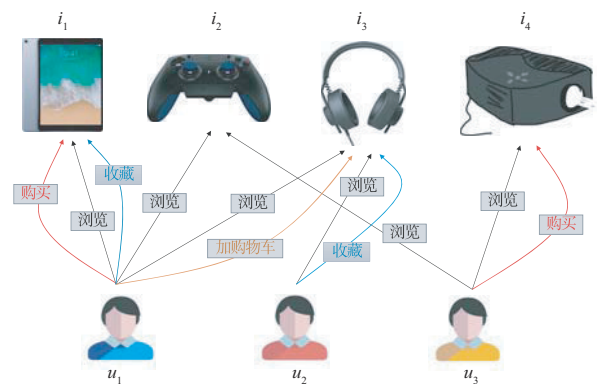


图1 多行为场景示意图

的使用效率,并缓解其带来的空间异质性问题.

2 MB-DCAC 推荐模型

针对多行为推荐模型行为模式捕获需求与空间分布异质性问题,本文基于图卷积技术提出双通道交叉自适应对比学习推荐模型,通过交叉执行图卷积与多行为聚合两个模块以捕捉行为模式,在双通道中通过噪声增强并构建对比学习任务来聚合双通道优势和调整表征空间结构.如图2所示,模型主要由两部分组成:(1)行为模式编码,该部分基于现有行为聚合与信息传递研究,针对异构信息聚合需求,引入了关系依赖感知参数;根据信息传递特征,提出了双通道卷积对比模式,形成一套新颖的行为模式挖掘框架;(2)表征空间分布增强,针对异构空间中的连接关系异质性,本文在对比学习基础上引入了嵌入在高维空间中的集合特性调节组件,通过增强表征空间的对齐性和均匀性来提升模型性能.

2.1 问题描述

异构图中包含多种连接关系的边信息,是普通图的泛化,在行为异构图中通过边关系映射用户行为连接关系.通过行为异构图进行多行为推荐可做如下推

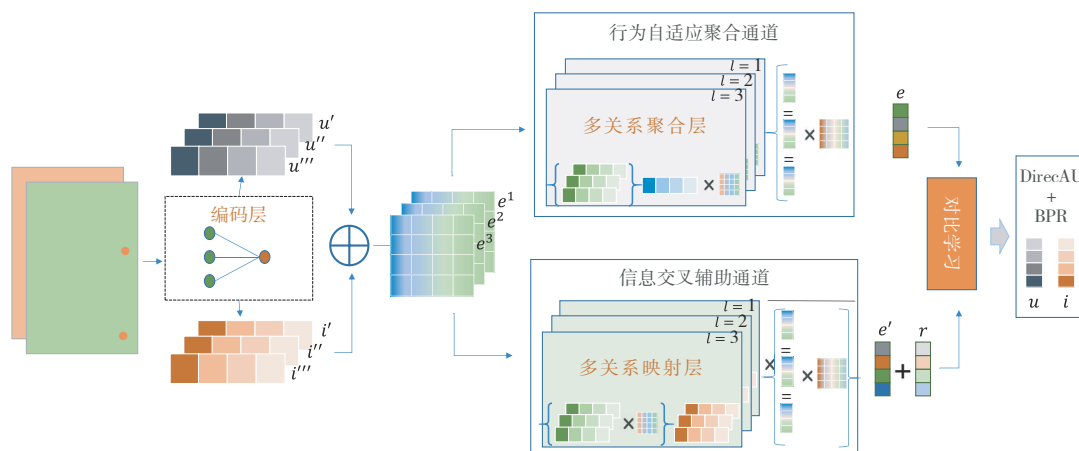


图2 基于双通道交叉自适应对比的异构图推荐模型

述:给定 $G=\{G_1, G_2, \dots, G_K\}$ 为行为异构图,其中元素表示某行为下的交互矩阵, K 表示行为类型总数. $G_k=[g_{ui}^k]_{MN} \in \{0, 1\}$ 表示用户 u 和物品 i 在行为 k 下是否发生交互,发生交互则为 1,未发生交互为 0; G_k 表示目标行为下的交互矩阵. 本文模型的目标是对给定用户 u , 从物品集 I 中找到最有可能与用户 u 发生目标行为交互的物品集合,并根据交互概率排序,形成 Top-N 推荐序列. 本文涉及的重要符号定义详见表 1 所示.

2.2 行为模式建模

多行为异构图中蕴藏着用户与物品的高阶多路复用关系. 为了更有效挖掘多行为之间的依赖关系和协同作用,本文构建了一个基于图消息传递的行为模式挖掘模块. 该模块受基于图的信息聚合^[11]与消息传递^[3,12]等模型启发,通过交叉执行行为聚合与消息多层卷积两个部分来挖掘用户行为模式.

2.2.1 行为自适应聚合通道

(1) 多行为聚合

基于图神经网络的信息聚合与消息传递是捕获用户行为模式的两个重要步骤. 区别于普通信息聚合方式,为了进一步挖掘行为间的协作作用,提高模型信息聚合能力,本文结合行为异构数据特征,分析信息聚合方式,构建了行为全局依赖捕获与行为特征交互的自适应学习模块. 通过可学习权重自适应感知行为之间的协同作用以及依赖关系,并通过可学习关系权重进行表征特性增强. 具体对于用户 u_m ,通过式(1)构建具有感知能力的行为捕获模块.

$$u_m^{a,(l+1)} = \sum_{k=1}^K a_{uk} \left(\sum_{j=0}^{s_{u_m}^k} I_{u_m,j}^{k,(l)} \right) \quad (1)$$

$s_{u_m}^k$ 表示用户 u_m 在 k 行为下的度, $I_{u_m,j}^{k,(l)}$ 表示与用户 u_m 在行为 k 有过交互的物品, l 表示层数. a_{uk} 表示可学习权重,用于反应各个行为交互项对用户表征的影响,通过自适应学习获取行为之间的依赖关系. 为了进一步挖掘特征之间的关系,在式(1)基础上,关系权重自适应处理如式(2)所示.

$$u_m^{(l+1)} = \text{sigmoid} \left(u_m^{a,(l+1)} W_u^1 \right) \quad (2)$$

$W_u^1 \in \mathbf{R}^{d \times d}$ 是对应表征长度的可训练参数,用来区分用户有效特征,从个体角度增强模型识别能力,两个模块共同完成用户行为模式自适应学习. 相应地可以获取物品的表征方式,如式(3)所示.

$$i_n^{(l+1)} = \text{sigmoid} \left(\left(\sum_{k=1}^K a_{ik} \left(\sum_{j=0}^{s_{i_n}^k} U_{i_n,j}^{k,(l)} \right) \right) W_i^1 \right) \quad (3)$$

值得注意的是,不同于 He^[3]提出的 LightGCN 模型,本文只聚合了节点的邻居项,而没有聚合节点本身的信息,通过该方式可以学习到更直接的协同关系. 模型中从行为关系和特征关系两个角度构造了可学习权重,更易提取用户行为依赖关系.

(2) 多层卷积

图卷积模型在消息传递和信息表示等方面性能突出,在多层信息传递过程挖掘层信息之间的关系可有效增强模型信息传递能力,本文受特征交互^[13,14]机制的启发,在多层卷积信息聚合中引入特征交叉. 通过将多层卷积结果进行拼接,再经过一次全连接操作可有效增强信息层间的信息传递,具体操作如式(4)所示.

$$u_m = (\|u^l\|) W_u^2, i_n = (\|i^l\|) W_i^2 \quad (4)$$

$W_u^2, W_i^2 \in \mathbf{R}^{d \times d}$ 表示可训练权重, l 表示卷积层数. 拼接 l 层聚合操作的结果,再经过一次全连接,完成层之间以及嵌入之间的特征交叉,可有效增强信息之间的交互作用.

2.2.2 信息交叉辅助通道

区别于单个目标行为下的推荐模型,多行为推荐需聚合多行为交互信息. 前文通过具有感知能力的行为模式捕捉模块,获取了行为之间的依赖,再经过多层卷积捕捉节点高阶邻接关系. 根据行为语义分析,捕获单个行为下的协同关系,是挖掘用户行为模式的另一关键操作. 本文在行为自适应聚合模块基础上,交叉执行基于行为的卷积操作,捕获单个行为下的协同关系,并将其作为主通道行为模式挖掘补充,可强化模型对行为模式的挖掘. 交叉操作如式(5)、(6)所示.

表 1 符号定义

Notation	Description	Notation	Description	Notation	Description
U	User set	V	Number of users and items	e	Feature vector
u	Vector of user	K	Number of behavior type	a	Trainable parameters
I	Item set	k	Behavior variables	W	Trainable matrix
i	Vector of item	G	Adjacency matrix set	d	Feature vector length
M	Number of users	G_k	Adjacency matrix for behavior k	ϵ, γ	Hyper-parameters
m	User variables	L	Number of convolutions	α, β, μ, η	Coefficient
N	Number of items	l	Variable of convolution count	L_*, l_*	Loss function
n	Item variables	s	Degree of nodes		

$$u'_m = \frac{1}{K} \sum_{k=1}^K \left\{ \left\| \text{sigmoid} \left(\left(\sum_{j=0}^{s_{u_m}^k} I_{u_m,j}^{(l)} \right) W_u^1 \right) \right\| W_u^2 \right\} \quad (5)$$

$$i'_n = \frac{1}{K} \sum_{k=1}^K \left\{ \left\| \text{sigmoid} \left(\left(\sum_{j=0}^{s_{i_n}^k} U_{i_n,j}^{(l)} \right) W_i^1 \right) \right\| W_i^2 \right\} \quad (6)$$

其中的 $W_u^1, W_u^2, W_i^1, W_i^2$ 是自适应多关系建模部分的可训练参数, $I_{u_m,j}^{(l)}$ 与 $U_{i_n,j}^{(l)}$ 采用主通道卷积结果, 形成双通道信息交叉. 两个通道从两个方向共同捕捉用户行为模式, 并通过双通道相同语义的参数进行共享, 捕捉更全面的行行为模式. 在交叉通道中移除捕捉行为依赖参数 a , 以保留更多的关系交互信息, 补充主通道基础信息.

2.3 表征空间增强

深度模型通过学习嵌入来完成各项任务^[15,16], 表征的嵌入质量直接关系到模型性能. 在 DirectAU 等^[17,18]工作中, 通过理论结合实验的方式论证了正例之间的对齐性和空间分布的均匀性直接影响模型最终的性能. 其中对齐性表示相关联的两个嵌入在高维空间中彼此接近, 均匀性表示嵌入表征在整个空间应分布均匀. 本文为进一步提高双通道表达优势, 优化表征空间结构, 在表征空间增强模块, 提出了加入噪声的对比学习方案.

噪声增强方案, 通过对表征向量施加常数级扰动, 可对模型提供优化动力^[19]. 本文通过双通道交叉自适应模块, 获取了关于用户与物品的两个表征. 其中多关系聚合模块为主要模型通道, 包含了更多的用户行为模式信息; 单行为协同聚合模块为辅助通道, 保留了数据更多基本信息. 为更有效利用双通道表达优势, 本文基于双通道模型, 将噪声作为辅助通道的信息增强手段, 进一步研究其在增强表征分布上的作用, 具体操作如式(7)所示.

$$E' = E + \varepsilon \cdot \nabla(\text{rand}(E)) \quad (7)$$

其中 $E \in V \times d$ 为描述用户和物品的表征空间, $\text{rand}(E)$ 表示生成与 E 形状相同且在 0-1 之间均匀分布的矩阵, ε 表示噪声大小, 这里将其作为一个训练超参数. $\nabla = \text{sign}(E) \odot \nabla'$ 中 sign 表示与 E 符号相关的函数, 将正向噪声作为模型组件. ∇' 表示对 $\text{rand}(E)$ 按行标准化.

经过双通道和噪声增强后, 为进一步发挥两个通道的优势, 本文基于 InfoNCE^[20] 对比学习算法研究双通道对比学习方案. 结合模型表征, 将双通道生成的用户或物品的两个嵌入作为正例, 随机抽取用户或物品的两个嵌入为负例. 单个用户或物品的表征如式(8)所示.

$$L_{\text{ssl}} = -\log \frac{1}{1 + e^{-\langle e, e' \rangle}} - \log \left(1 - \frac{1}{1 + e^{-\langle e, e' \rangle}} \right) \quad (8)$$

这里 e^+ 表示正例嵌入, e^- 表示负例嵌入. 通过该方法, 可以增加两个通道表征嵌入的互通性, 增强整个表征空间的均匀性. 经过上述方法处理后的所有用户和物品嵌入, 共生成 $M+N$ 个嵌入对比损失, 求和后得到模型对比损失.

2.4 MB-DCAC 训练框架

本小节将从模型训练任务与模型时间复杂度两个方面进一步介绍模型训练框架.

2.4.1 训练框架

BPR (Bayesian Personalized Ranking) 损失^[21] 是推荐领域重要的优化函数, 其在训练过程中强化与用户交互过的物品概率高于未交互过的物品概率符合一般用户习惯. 本文结合行为异构数据特征, 拓展 BPR 训练任务, 根据用户和与物品的多种异构连接, 增强用户与物品的协同关系. 具体训练任务如式(9)所示.

$$L_{\text{BPR}}^k = \sum_{(u, i^+, i^-) \in O_k} -\ln \left(\text{sigmoid} \left(\hat{x}_{u, i^+}^k - \hat{x}_{u, i^-}^k \right) \right) \quad (9)$$

O_k 表示在行为 k 下的训练数据抽样对, $O_k = \{(u, i^+, i^-) | (u, i^+) \in R^{k+}, (u, i^-) \in R^{k-}\}$. 其中 R^{k+} 表示在 k 行为下存在交互, R^{k-} 表示在行为 k 下不存在交互. $\hat{x}_{u, i} = \langle e_u, e_i \rangle$ 表示对应用户和物品嵌入的内积.

此外, 本文将 DirectAU 训练作为辅助任务. DirectAU 通过引入高维空间中的欧式距离来增强正例对之间的对齐性, 并分别在用户和物品嵌入中增强均匀性. 具体操作如式(10)、式(11)所示.

$$l_{\text{align}}^k = E_{(u, i) \in R^{k+}} \|e_u - e_i\|^2 \quad (10)$$

$$l_{\text{uniform}} = \frac{1}{2} \left(\begin{aligned} &\log E_{u, u' \sim E_u} e^{-2\|e_u - e_{u'}\|^2} \\ &+ \log E_{i, i' \sim E_i} e^{-2\|e_i - e_{i'}\|^2} \end{aligned} \right) \quad (11)$$

其中 E_u 表示用户的表征空间, E_i 表示物品的表征空间. 通过拉近有交互的两个表征的欧式距离来提高对齐性, 通过增强表征空间的均匀分布来提升表征空间的均匀性. 对应 BPR 任务, 在每个关系下构建损失函数, 如式(12)所示.

$$L_{\text{AU}}^k = l_{\text{align}}^k + \gamma l_{\text{uniform}} \quad (12)$$

其中 γ 为 DirectAU 训练目标的调节参数, 为本模型的另一超参.

优化目标确定后, 进一步从模型训练角度整合参数学习的损失函数. 模型方面, 构建了双通道对比学习任务; 目标任务方面, 构建了适用多行为的 BPR + DirectAU 推荐任务学习目标. 为了防止模型过拟合, 本文对训练参数进行正则化操作. 模型整体损失如式(13)所示.

$$L_{\text{all}} = \frac{1}{K} \sum_{k \in K} (\alpha L_{\text{BPR}}^k + \beta L_{\text{AU}}^k) + \mu L_{\text{ssl}} + \eta \|\theta\|^2 \quad (13)$$

其中的 α, β, μ, η 表示损失系数, θ 表示可训练参数.

2.4.2 复杂度分析

本节根据模型的关键模块定性分析 MB-DCAC 框架的时间复杂度. 双通道交叉卷积模块时间复杂度是 $O(L \times K \times V \times d)$, L 表示卷积层数, K 表示行为个数, V 表示用户与物品数量总和, d 表示嵌入维度; 数据增强模块、对比模块的时间复杂度均为 $O(V \times d)$; 模型训练模块总时间复杂度为 $O(L \times V \times d)$. 四个模块在模型中满足顺序结构, 故模型总的时间复杂度为 $O(L \times K \times V \times d)$, 主要描述了异构信息的大小与模型的深度. 与基于图卷积技术的其它简易且高效的推荐模型 (LightGCN^[3]、MBGCN^[8] 等) 等价, 都主要描述了模型在基础数据上面的卷积操作.

3 实验

本节将 MB-DCAC 在三个公开推荐数据集上进行实验, 将实验结果与其它基准模型进行对比分析, 并对模型模块进行消融实验, 以验证模型性能. 主要回答了以下问题:

RQ1: MB-DCAC 框架相较于多个方向的基准模型在不同数据集上表现如何?

RQ2: 不同的形态噪声如何工作以及对最终性能影响如何?

RQ3: MB-DCAC 中各个子模块对最终的推荐结果有什么影响?

RQ4: 模型对行为依赖关系挖掘能力如何?

RQ5: 模型中的超参数如何调节, 不同的超参配置会如何影响 MB-DCAC 性能?

3.1 实验设置

3.1.1 数据描述

为有效评估本文模型效果, 在三个公开数据集上进行实验. 数据集细节如表 2 所示, 表中数量单位为个.

表 2 数据集统计表

数据集	用户数	物品数	交互数	行为交互类型
Tmall	31 882	31 232	1 451 219	浏览、收藏、加购物车、购买
IJCAI-Contest	17 435	35 920	799 368	浏览、收藏、加购物车、购买
Beibei	21 716	7 977	987 383	浏览、加购物车、购买

Tmall: 该数据集是由电商平台天猫收集并发布, 主要用于复购预测, 其中包括了用户浏览、收藏、加购物车、购买等信息. 本文采用与 MB-GMN^[22] 相同的数据处理方式.

IJCAI-contest: 该数据集最早被用于 2015 年 IJCAI

的一场推荐竞赛中, 其中包含了用户在线上零售平台中的一些购买行为数据. 包含的用户行为类型和 Tmall 数据相同, 数据处理方式同上.

Beibei: 该数据来自婴幼儿产品销售线上平台, 包含用户在线上购买婴幼儿产品交互信息, 主要包含浏览、添加购物车、购买三种行为, 数据处理方式同上.

3.1.2 评估方法

评估指标方面, 本文采用目前被推荐领域广泛使用的两种方式: Normalized Discounted Cumulative Gain (NDCG@N)^[13] 和 Hit Ratio (HR@N)^[22] 作为 top-N 推荐任务的评估指标, 分别描述推荐物品是否满足了用户需求, 以及推荐目标在推荐序列中的位置; 在数据划分上采用留一法^[13,23], 结合推荐数据特征, 选择一定数量用户, 将其目标行为 (购买行为) 的最后一个交互项作为验证数据, 其余数据则用于训练; 评估方式与文献 [10,24] 采用相同的实验设置, 将选取的正例物品与 99 个随机负例进行组合. 模型任务是向用户推荐一组物品序列, 使满足用户需求的物品尽可能排在序列前面.

3.1.3 评估基准

为全面评估模型性能, 将 MB-DCAC 与多个方向的基准模型进行比较, 具体如下.

(1) 单行为推荐模型

BPR^[21]: 推荐领域经典模型, 基于矩阵分解算法, 提出并采用了贝叶斯个性化排序方法, 对提升模型 NDCG 指标有重要作用.

NGCF^[13]: 将图神经网络用于推荐领域, 以图卷积方式模拟信息在用户与物品之间的传递, 为学习用户嵌入提供更好的协同效果.

LightGCN^[3]: NGCF 的改进模型, 其通过实验和理论分析, 去掉了 NGCF 中的非线性和激活函数, 使其在模拟信息传递任务中更加简洁、高效, 在协同过滤推荐任务中可以更好地传递协同信息, 达到更好的推荐性能.

(2) 多行为推荐模型

MB-GCN^[8]: 将多行为与图卷积相结合, 在用户多个行为之间以图卷积方式捕获用户行为模式, 获取用户与物品的高阶连通关系, 从而学习到更好的用户物品表征.

MATN^[25]: 采用了具有记忆增强的自注意力机制, 可学习用户多个行为与目标行为之间的协同关系, 提升对目标行为为交互项的预测能力.

EHCF^[26]: 设计了一种非采样迁移学习方法, 即高效异质协同网络, 通过丰富负例样本来提高用户、项目表征效果. 模型中考虑用户粒度信息以获取用户和项目之间更具体的关系, 从而提高推荐性能.

MB-GMN^[10]: 解决不同用户对应不同行为习惯的

问题,模型提出通过元学习的方式,获取用户个性化行为习惯,增强模型学习能力。

3.1.4 参数设置

本文的实验环境是 Ubuntu 20.04.1 和 NVIDIA GeForce RTX 3090,通过 Anaconda 环境下的 python 3.10 和 PyTorch 1.11.0 来进行实验。在基准模型的实验结果获取上,通过知名的共享推荐框架 QRec 及模型源代码进行实验,并保持实验过程中模型参数不变。

3.2 总体推荐性能

MB-DCAC 与基准模型在三个数据集上的实验结果如表 3 所示,加粗部分表示基准模型在某数据集的某个指标上最好的实验结果。

表 3 BM-DCAC 与其它模型性能比较(N=10)

Dataset	Metric	BPR	NGCF	LightGCN	MB-GCN	MATN	EHCF	MB-GMN	MB-DCAC
Tmall	HR	0.243	0.322	0.342	0.381	0.406	0.433	0.466	<u>0.544</u>
	NDCG	0.143	0.184	0.205	0.213	0.225	0.26	0.277	<u>0.326</u>
IJCAI-Contest	HR	0.163	0.256	0.257	0.304	0.369	0.409	0.356	<u>0.484</u>
	NDCG	0.085	0.124	0.122	0.16	0.209	0.237	0.1987	<u>0.286</u>
Beibei	HR	0.443	0.573	0.613	0.642	0.656	0.683	0.685	<u>0.704</u>
	NDCG	0.267	0.347	0.340	0.379	0.385	0.391	0.408	<u>0.432</u>

最后,分析模型在不同数据集上的提升效果。可以看到模型在 Tmall 和 IJCAI-Contest 上相较几个经典模型有 15% 以上提升,而在 Beibei 数据集上性能提升了 2.76%。本模型主要探索多行为依赖在提升模型性能上面的作用,Beibei 数据集相较其余两个数据集,仅包含了浏览、加购物车、购买三种行为信息,这一定程度上降低了模型性能提升效果。

3.3 噪声形态比较

SimGCL^[19]中通过实验结合理论分析获得结论——“数据增强对于对比学习而言并不一定是有用的”,文中以噪声来增强数据构建对比任务。与本文通过噪声来增强表征性能的思想相同。本文进一步讨论不同的噪声形态会对模型性能的影响,分别为噪声符号与原表征相同(N-s)、噪声符号与原表征相反(N-c)、噪声符号正向(N-p)以及没有噪声(N-n)。分别采用固定的模型参数在每个数据集进行实验,实验结果如表 4 所示。

从中可以看出,在添加噪声增强的情况下,推荐性能大部分高于没有噪声的情况。但也存在相反的情况,比如在 IJCAI-contest 数据集中添加同向噪声或在 Tmall 数据集上添加反向噪声时推荐性能相较无噪声时模型性能更低。实验结果表明,噪声增强在提升推荐性能方面有显著作用,但噪声的方向对最终推荐结果也会有

影响,不合适的噪声方向甚至会起反作用。本文模型中采用正向噪声增强方案,在三个数据集上都能产生更好的推荐性能。

表 4 噪声变体性能比较(N=10)

噪声方向	Beibei		IJCAI-Contest		Tmall	
	HR	NDCG	HR	NDCG	HR	NDCG
N-s	0.699	0.431	0.481	0.284	0.542	0.324
N-c	0.702	0.432	0.482	0.284	0.535	0.321
N-p	0.704	0.432	0.484	0.286	0.544	0.326
N-n	0.698	0.430	0.482	0.284	0.539	0.323

影响,不合适的噪声方向甚至会起反作用。本文模型中采用正向噪声增强方案,在三个数据集上都能产生更好的推荐性能。

3.4 消融实验

为进一步验证模型组件的有效性,对三个模型变体设计了消融实验。

MB-DCAC/a: 去掉了聚合多行为信息的自适应组件,无法捕获行为之间的协同作用关系。

MB-DCAC/c: 去掉了噪声增强组件,无法对交叉通道信息进行增强。

MB-DCAC/au: 去掉了辅助学习任务 AU 模块,无法动态调节模型对齐性和均匀性。

实验结果如图 3 所示,各个变体中推荐性能都有一定程度的下降,这验证了模型各个组件的重要性。其次可以看到各个组件在不同数据集上的作用并不是完全

相同的,Beibei数据集上,缺少DirectAU组件,模型性能下降最快,这说明DirectAU组件发挥更加突出的作用.而在IJCAI-Contest和Tmall数据集上,自适应组件发挥了更加重要的作用.DirectAU组件是调节表征空间均匀性和对齐性的重要部分;自适应部分是协调多行为

之间的依赖的重要部分.两部分在功能上的不同,在一定程度上解释了该现象.IJCAI-Contest和Tmall数据集上行为类型数量更多,行为依赖协调组件可以更好的发挥行为协同作用.Beibei数据集上,DirectAU组件调节空间分布特性,能更显著提升性能.

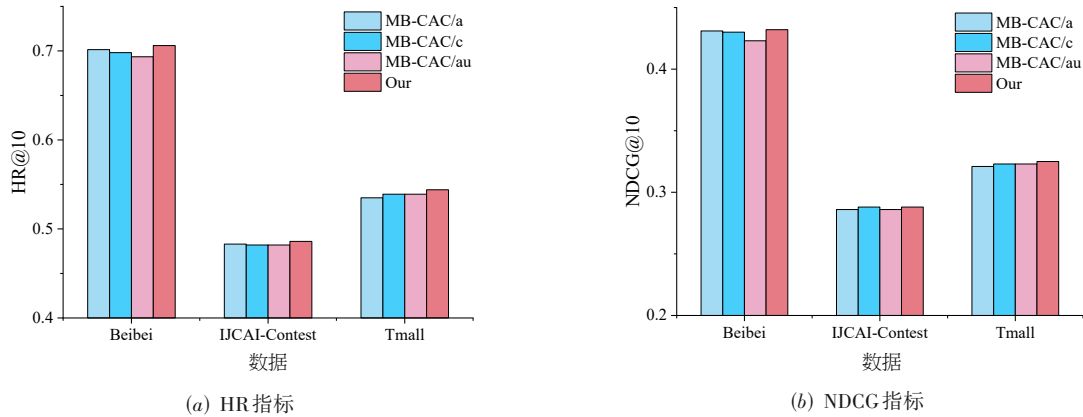


图3 消融变体在HR与NDCG两各个指标上的性能比较

3.5 行为协同分析

本节评估各个辅助行为对目标行为推荐任务的影响.在实验过程中打印了 a_{uk} 的结果,该参数是MB-DCAC中捕获行为依赖的重要部分.这里将模型达到最佳效果时候的参数值进行可视化操作如图4.从Beibei和Tmall的实验结果可以知道,购买行为即目标行为本身对最终的推荐任务贡献是最大的,其次是收藏或者加入购物车,最后是浏览.这与日常生活中的线上购

买行为习惯相一致,侧面印证了模型在捕获行为依赖上面的突出能力.但是在IJCAI-Contest数据集中,购买行为的权重却低于加入购物车的权重.分析其原因,IJCAI-Contest数据集主要收集于商品零售行业,结合日常购买习惯,先将商品加入购物车,再进行统一购买,加入购物车的行为能充分展现用户购买意图.在购买行为上的权重偏低,也能解释各个模型在该数据集上通过协同过滤进行推荐整体效果较差的问题.

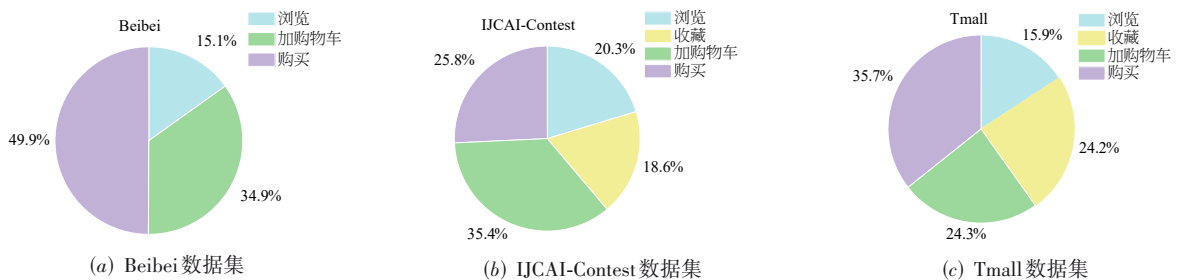
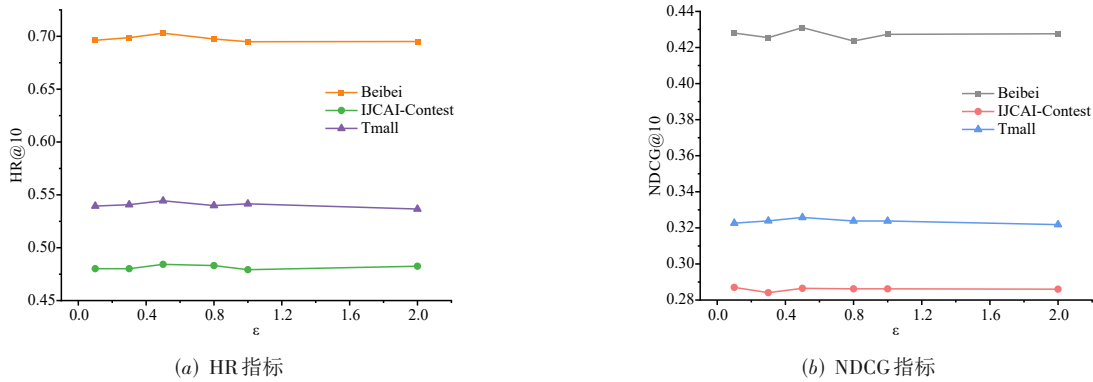



图4 三个数据集上行为依赖分析

3.6 超参分析

本文设计了噪声增强模块,通过超参 ϵ 控制噪声强度,其值越大噪声的影响越大.这里将其取值 $\{0.1, 0.3, 0.5, 0.8, 1, 2\}$ 进行实验,结果如图5所示.在三个数据集中将该值设为0.5时能达到峰值.其次在表征空间均匀性增强模块,通过超参 γ 来调节表征空间对齐与均匀性之间的关系,对其取值 $\{0.1, 0.3, 0.5, 0.8, 1, 2\}$,实验

结果如图6所示.在Tmall、Beibei、IJCAI-Contest三个数据集中分别取到1、0.8、0.3时达到峰值.这是因为三个数据集在稀疏度上有所不同,对于交互次数最多的Tmall数据集,其连接稀疏度在三个数据集中更低,达到峰值时的 γ 取值也是最大的,其对均匀性的提升更显著.同理分析IJCAI-Contest数据集稀疏度更高,在达到峰值时的 γ 取值也相对较小,其对均匀性的提升较缓.

图5 ε 值在HR与NDCG两个指标上对MB-DCAC性能影响图6 γ 值在HR与NDCG两个指标上对MB-DCAC性能影响

4 总结与未来工作

本文在行为异构数据上基于图神经网络提出了一种双通道交叉自适应对比学习推荐模型. 主要研究了在高阶多路复用异构图中的多边依赖关系挖掘, 与基于图卷积过程的对比学习范式构建. 对后续基于异构图的信息聚合与传递、对比学习范式构建等研究具有重要意义. 在三个数据集上的大量实验, 验证了本文方法的有效性. 未来工作中, 将进一步研究模型可解释性与异构数据的解耦表示.

致谢 感谢匿名外审专家的修改意见以及编辑部老师的辛勤工作, 感谢实验室高旻教授、刘虎、熊志英等同学的意见和建议.

参考文献

- [1] GOLDBERG D, NICHOLS D, OKI B M, et al. Using collaborative filtering to weave an information tapestry[J]. Communications of the ACM, 1992, 35(12): 61-70.
- [2] KOREN Y, BELL R, VOLINSKY C. Matrix factorization

techniques for recommender systems[J]. Computer, 2009, 42(8): 30-37.

- [3] 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.
- [4] ZHANG Y, FENG F L, HE X N, et al. Causal intervention for leveraging popularity bias in recommendation[C]//Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2021: 11-20.
- [5] 闫昭, 项欣光, 李泽超. 基于交互序列商品相关性建模的图卷积会话推荐[J]. 中国科学: 信息科学, 2022, 52(6): 1069-1082.
- YAN Z, XIANG X G, LI Z C. Item correlation modeling in interaction sequence for graph convolutional session recommendation[J]. Scientia Sinica (Informationis), 2022, 52(6): 1069-1082. (in Chinese)
- [6] 方晨, 张恒巍, 王娜, 等. 基于随机游走和多样性图排序的个性化服务推荐方法[J]. 电子学报, 2018, 46(11):

- 2773-2780.
- FANG C, ZHANG H W, WANG N, et al. Personalized service recommendation method based on random walk and diversified graph ranking[J]. *Acta Electronica Sinica*, 2018, 46(11): 2773-2780. (in Chinese)
- [7] ZHU Y C, XIE R B, ZHUANG F Z, et al. Learning to warm up cold item embeddings for cold-start recommendation with meta scaling and shifting networks[C]//Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2021: 1167-1176.
- [8] 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.
- [9] 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.
- [10] 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.
- [11] ZHANG C X, SONG D J, HUANG C, et al. Heterogeneous graph neural network[C]//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM, 2019: 793-803.
- [12] JI H Y, ZHU J X, WANG X A, et al. Who you would like to share with? A study of share recommendation in social E-commerce[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2021, 35(1): 232-239.
- [13] 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.
- [14] ZHANG H W, YANG Y, LUAN H B, et al. Start from scratch: Towards automatically identifying, modeling, and naming visual attributes[C]//Proceedings of the 22nd ACM International Conference on Multimedia. New York: ACM, 2014: 187-196.
- [15] 罗会兰, 袁璞, 童康. 基于深度学习的显著性目标检测方法综述[J]. *电子学报*, 2021, 49(7): 1417-1427.
- LUO H L, YUAN P, TONG K. Review of the methods for salient object detection based on deep learning[J]. *Acta Electronica Sinica*, 2021, 49(7): 1417-1427. (in Chinese)
- [16] LI Z C, TANG J H, MEI T. Deep collaborative embedding for social image understanding[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2019, 41(9): 2070-2083.
- [17] WANG C Y, YU Y Q, MA W Z, et al. Towards representation alignment and uniformity in collaborative filtering[C]//Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York: ACM, 2022: 1816-1825.
- [18] WANG T Z, ISOLA P. Understanding contrastive representation learning through alignment and uniformity on the hypersphere[C]//Proceedings of the 37th International Conference on Machine Learning. New York: PMLR, 2020: 9929-9939.
- [19] 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.
- [20] OORD A V D, LI Y, VINYALS O. Representation learning with contrastive predictive coding[EB/OL]. (2019-01-22)[2022-12-27]. <http://arxiv.org/abs/1807.03748>.
- [21] RENDLE S, FREUDENTHALER C, GANTNER Z, et al. BPR: Bayesian personalized ranking from implicit feedback[C]//UAI 2009, Proceedings of the Twenty-Fifth Conference on Uncertainty in Artificial Intelligence. Montreal: AUAI Press, 2009: 452-461.
- [22] BAI T, ZOU L X, ZHAO W X, et al. CTRec: A long-short demands evolution model for continuous-time recommendation[C]//Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2019: 675-684.
- [23] HE X N, ZHANG H W, KAN M Y, et al. Fast matrix factorization for online recommendation with implicit feedback[C]//Proceedings of the 39th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2016: 549-558.
- [24] WEI W, HUANG C, XIA L H, et al. Contrastive meta learning with behavior multiplicity for recommendation[C]//Proceedings of the Fifteenth ACM International Con-

ference on Web Search and Data Mining. New York: ACM, 2022: 1120-1128.

- [25] 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.
- [26] 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.

作者简介



范 伟 男,1998年生,现为重庆大学大数据软件学院在读硕士研究生.主要研究方向为数据挖掘、推荐系统.

E-mail: fanwei@cqu.edu.cn



周 魏(通讯作者) 男,1987年生,工学博士,重庆大学大数据与软件学院副教授、博士生导师.主要研究方向为推荐系统、信息检索、机器学习.中国电子学会会员编号:E190073018M.

E-mail: zhouwei@cqu.edu.cn



文俊浩 男,1969年生,工学博士,重庆大学大数据与软件学院教授.主要研究方向为计算智能、推荐系统.

E-mail: jhwen@cqu.edu.cn