

图卷积宽度跨域推荐系统

黄 玲¹ 黄镇伟¹ 黄梓源¹ 关灿荣¹ 高月芳¹ 王昌栋²

¹(华南农业大学数学与信息学院 广州 510642)

²(中山大学计算机学院 广州 510006)

(huanglinghl@hotmail.com)

Graph Convolutional Broad Cross-Domain Recommender System

Huang Ling¹, Huang Zhenwei¹, Huang Ziyuan¹, Guan Canrong¹, Gao Yuefang¹, and Wang Changdong²

¹ (*College of Mathematics and Informatics, South China Agricultural University, Guangzhou 510642*)

² (*School of Computer Science and Engineering, Sun Yat-sen University, Guangzhou 510006*)

Abstract Cross-domain recommendation (CDR) can effectively alleviate the data sparsity problem suffered by the traditional recommendation systems via leveraging additional knowledge from other domains. How to model the interaction information of users and items from the source to target domains is a key issue in CDR. In the current CDR methods, the higher-order information implied by the user-item interaction graph is ignored. To this end, we propose a new framework called graph convolutional broad cross-domain recommender system (GBCD). Specifically, we extend the traditional bipartite graph of user-item interactions to a $(D + 1)$ -partite graph to model the relationship between users and items in each domain, and then use common users as a bridge between the source domain and target domain to transfer information. The higher-order relationships between users and items are learned by graph convolutional network (GCN) to aggregate neighbor information. However, GCN converges very slowly with a large number of nodes and tends to absorb unreliable interaction noise, resulting in poor robustness. Therefore, we feed the domain-aggregated features to broad learning system (BLS), which enhances the robustness of GCN by exploiting the stochastic mapping features of BLS, achieving superior recommendation performance. Experiments conducted on two real datasets show that GBCD outperforms the existing state-of-the-art cross-domain recommendation methods.

Key words cross-domain recommendation; multipartite graph construction; broad learning system; graph convolutional network; recommender system

摘要 跨域推荐 (cross-domain recommendation, CDR) 通过利用其他域的额外知识, 有效缓解了传统推荐系统遭遇的数据稀疏性问题。但是当前的 CDR 方法忽略了用户-项交互图所蕴含的高阶信息。为此, 提出了一个新的框架, 称为图卷积宽度跨域推荐系统 (graph convolutional broad cross-domain recommender system, GBCD)。具体地, 将传统的用户-项交互的 2-部图扩展到一个 $(D+1)$ -部图, 以建模每个域中用户和项之间的关系, 然后使用公共用户作为源域和目标域之间的桥梁来传递信息。通过图卷积网络 (graph convolutional network, GCN) 学习用户与项之间的高阶关系, 以聚合领域信息。然而, 由于 GCN 在大量节点下收敛速度非常慢, 并倾向于吸收不可靠的交互噪声, 导致鲁棒性较差。为此, 将域聚合特征输入到宽度学习系统 (broad learning system, BLS), 并利用 BLS 的随机映射特征增强了 GCN 的鲁棒性, 进而获得了较好的推荐性能。在 2 个真实数据集上进行的实验结果表明, GBCD 优于各种先进的跨域推荐方法。

收稿日期: 2023-07-31; 修回日期: 2023-12-22

基金项目: 国家自然科学基金项目(62106079)

This work was supported by the National Natural Science Foundation of China (62106079).

通信作者: 高月芳 (gaoyuefang@scau.edu.cn)

关键词 跨域推荐;多部图构造;宽度学习系统;图卷积网络;推荐系统

中图法分类号 TP181

随着信息时代的发展,人们被越来越多的信息数据包围。企业为了从海量的信息数据中提取出有用信息并为企业带来效益,推荐算法被广泛应用于各大企业的在线服务中^[1-7]。推荐系统旨在通过历史交互数据对用户和项的表征进行建模,发现隐藏在数据背后的模式和规律,进而为决策提供支持和指导^[8-18]。然而,传统的推荐系统只关注用户与项在单一域的交互,这相对于用户-项交互关系的总数量来说是相当小的,意味着数据稀疏性仍然是一个需要克服的问题^[19-23]。同时,对于进入系统的新用户和新项来说,缺乏历史交互数据造成的数据稀疏也是一个严重问题,也就是所谓的冷启动问题^[24-32]。

为解决数据稀疏问题并提高推荐准确性,跨域推荐(cross-domain recommendation, CDR)方法被提出^[33-34]。CDR利用其他域的相关信息来协助目标域的预测任务。例如,喜欢喜剧电影而不喜欢爱情电影、喜欢笑话集而不喜欢爱情小说的用户,其个人表征反映了他们对喜剧项的偏好和对爱情项的厌恶。现有的CDR方法通常通过学习不同域之间重叠用户或项的潜在表征,再结合来自不同域的共享信息来作为信息传递的桥梁。

尽管传统的CDR方法已取得一定的研究进展,但仍然存在一定局限性。如现有的非图的CDR方法忽略了用户-项交互关系的高阶隐含特征和用户-项交互图的高阶结构特征,导致不能完全捕捉到用户-项交互的复杂性^[35]。这种局限性导致推荐效果有待改善。具体来说,传统方法只能隐式地捕捉协同信号(即使用用户-项交互信息作为监督信号),可以看作是利用一跳邻居的交互信息来进行用户的表征学习。而将用户与项交互信息显示建模成交互图(即拓扑结构),利用图神经网络在交互图上提取出来的高阶交互信息可以自然、显式地编码关键的协同信号。利用图神经网络提取用户-项交互信息时,每个节点(用户或项)不仅能够与一跳邻居进行交互,还能通过图结构与间接相连的用户或项(多跳邻居)进行交互,因此得到的高阶交互信息能够包含更多的上下文关系和更丰富的特征,从而提高推荐性能。因此,设计能够捕捉高阶特征的新方法对于提高跨域推荐的准确性至关重要。

为了从用户-项交互图中捕捉高阶信息,图卷积网络(graph convolutional network, GCN)已被广泛应

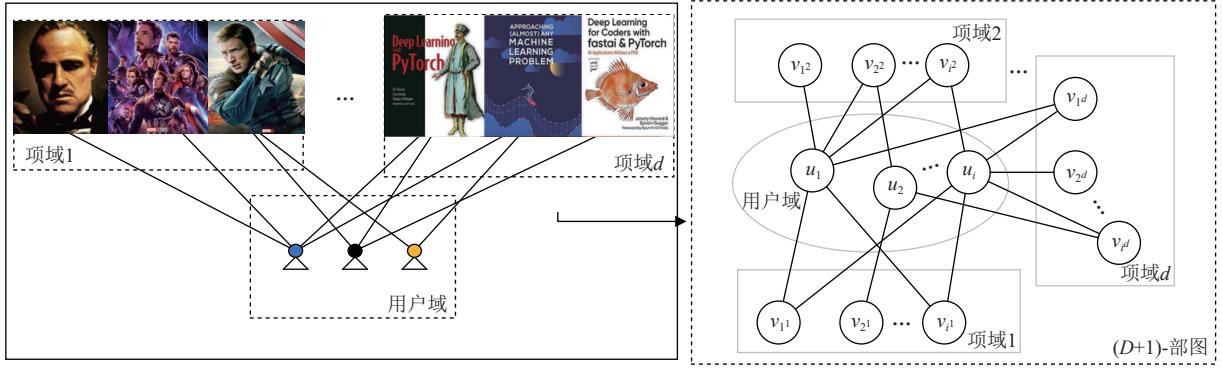
用于推荐系统^[36-37]。GCN使用初始属性或结构特征初始化节点表示,通过递归聚合更新每个节点,最后根据下游任务读出节点或图的最终表示^[38]。基于GCN的推荐模型通常将用户与项的交互视为用户与项的2-部图,并在图中传播信息和聚合邻近节点的特征,从而获得用户和项的高质量特征嵌入。最近,一些研究工作通过使用GCN来实现跨域推荐任务^[39-41]。但这些工作在跨域特征提取上为每一个用户交互序列构建交互子图或在每个域上单独构建域的子图,并没有构建一个统一的不同域间用户-项交互图。由于非活跃用户通常交互项较少,只依靠用户子图不足以生成高质量的跨域表示从而限制了推荐系统的偏好表达能力,而分开建模域的子图无法提取到丰富的跨域特征。建模一个统一的用户-项交互图有助于提取丰富的跨域特征,提高跨域推荐性能。此外,现有的基于图的CDR方法也没有考虑到基于图卷积的方法普遍面临的过平滑问题。

针对上述问题,我们提出了一个新框架,称为图卷积宽度跨域推荐系统(graph convolutional broad cross-domain recommender system, GBCD)。该推荐系统利用GCN获取多个域内的高阶相似性和结构特征,从而进一步提高推荐性能,并缓解上述问题。

本文在建立的模型过程中必须应对2个主要挑战。第1个挑战是构建不同域之间的用户-项交互图,第2个挑战是制定有效的策略在不同域中通过GCN提取高阶信息所构成的高质量用户-项跨域嵌入向量。为了应对这2个挑战,本文提出了一种基于多部图概念的新方法。具体地说,我们开发了一个(D+1)-部图,该图建立了多个域的项和重叠用户之间的关系,其中重叠用户作为传递信息的桥梁,如图1所示。在同一域内,类似的项也被链接起来。然后,使用GCN来聚合邻近节点的关系,并提取用户和项的特征。

针对基于GCN方法普遍面临的过度平滑问题,即由于邻近节点信息的信息过度聚合,模型的鉴别性能降低。我们引入了宽度学习系统(broad learning system, BLS)^[42]作为非线性近似器, BLS可以根据任何连续概率分布使用随机隐藏层权重将原始样本映射到一个具有区分度的特征空间。通过随机权重向模型中引入随机噪声,可以有效地增强模型的鲁棒性,进而缓解过度平滑问题。

在GBCD中,我们遵循了大多数GCN推荐模型

Fig. 1 Illustration of the proposed $(D+1)$ -partite graph图1 所提出的 $(D+1)$ -部图示意图

的思路,摒弃了对特征聚合帮助不大的非线性激活部分.但与简化图卷积推荐系统(simplifying and powering graph convolution network for recommendation, L-GCN)^[43]不同的是,我们没有放弃权重矩阵的训练过程,实现了输入节点特征的降维.在模型训练过程中,我们将每个GCN的结果输入BLS进行评分预测.由于GCN网络的训练易受噪音的影响,例如:不可靠的交互等,为此我们提出了一种新的面向任务的优化损失函数.该损失函数根据最终推荐任务的BLS输出性能反馈训练GCN网络.通过这种方法,可有效地训练GBCD并提高其在推荐任务中的性能.

本文的主要贡献有3个方面:1)专注于探索如何从多个域学习高阶特征,创新性地将不同域的用户-项交互信息构建成 $(D+1)$ -部图.2)提出了一种新的模型GBCD,它是一种基于图神经网络的宽度跨域推荐系统.此外,还设计了一种新的面向任务的损失函数来训练GBCD.3)在2个大规模真实数据集上对GBCD进行了综合实验评估,结果表明GBCD显著提高了推荐性能.

1 相关工作

1.1 跨域推荐

CDR方法已被提出作为解决推荐系统中冷启动和数据稀疏性挑战的一种解决方案.多年来,CDR的各种变体被开发出来,每一种都有其独特的特点和局限性.例如,集体矩阵分解(collective matrix factorization, CMF)^[44]假设存在一个跨所有域共享的全局嵌入矩阵,并同时从多个域分解该矩阵.在低秩和稀疏的跨域推荐(low-rank and sparse cross-domain recommendation, LSCD)^[2]中,对每个域分别提取用户和项的潜在特征矩阵,而不是将每个域的评分矩阵

分解为3个低维矩阵3次.此外,用户的特性被自适应地分为共享组件和域特定组件.近年来,深度学习模型也被引入CDR中.例如,在文献[3]中提出一种新的自动编码器框架,它可以跨域传输和融合信息,以做出更准确的评分预测.Zhu等人^[45]提出一个基于矩阵分解模型和全连接深度神经网络的跨域和跨系统推荐的深度框架.嵌入映射跨域推荐系统(cross-domain recommendation: an embedding and mapping approach, EMC DR)^[46]在每个域中利用隐因子模型学习用户和项特征,在不同域间将数据从丰富域映射到稀疏域实现跨域推荐.用户偏好个性化迁移(personalized transfer of user preferences, PTUP)推荐系统^[27]使用元网络为每个用户生成1个个性化的信息桥梁功能,进而为每个用户学习个性化跨域表示.同时,Li等人^[28]提出了一种新的对抗性学习方法,该方法将从不同域中生成的用户嵌入向量统一为每个用户的1个全局用户表示来进行跨域推荐.Cao等人^[29]通过信息瓶颈的原理建模领域间去偏共享信息来实现跨域推荐.而解耦跨域推荐系统(disentangled representations for cross-domain recommendation, DisenCDR)^[47]通过解耦领域共享和领域特定信息,并利用互信息规则来增强跨域推荐性能.Xu等人^[48]通过双重嵌入结构、自适应的传递矩阵、注意机制,有效地处理特征维度和潜在空间的异质性来实现跨域推荐.Xie等人^[26]通过构建多样化偏好网络和域内域间的对比学习任务来解决跨域推荐中的数据偏差问题.

1.2 基于GCN的推荐

近年来,研究人员一直在探索利用图神经网络提取用户-项交互图中的特征以更好地预测用户的偏好.其中一种方法是基于图卷积的矩阵补全(graph convolutional matrix completion, GC-MC)^[49],该方法在编码交互特征时,通过GCN来利用用户和项之间的

连接. 另一种方法将 GCN 集成到嵌入表征学习过程中的框架——神经图协同滤波(neural graph collaborative filtering, NGCF)^[50]. NGCF 覆盖多个嵌入传播层, 通过传播层捕获用户和项之间的高阶连接的协同信息. Chen 等人^[51]去掉非线性激活函数, 并使用残差学习方法来解释连接各层输出的原因. 为简化 NGCF, L-GCN^[43]删除了对协同滤波没有正面作用的激活和转换函数等操作. 此外, 还有一种新的跨域推荐的双向迁移学习方法被提出, 即基于图协同滤波网络的双向转移(bi-directional transfer graph collaborative filtering networks, BiTGCF)模型^[52]. BiTGCF 不仅通过一个新的特征传播层建模单域用户-项图中的高阶连通性, 还利用公共用户作为桥梁实现 2 个知识跨域的双向转移.

1.3 宽度学习系统 (BLS)

2017 年, BLS^[42]作为一种新型的浅层神经网络模型被提出. 类似于深度神经网络, BLS 可以近似逼近非线性函数, 并对此进行了严格的分析论证^[53]. BLS 被设计为一个浅层的扁平网络, 其中原始输入

数据通过连续的概率分布映射到特征节点中, 然后在宽度扩展中用节点进行增强. 这种设计可以实现快速的训练过程, 因为只需要使用伪逆向算法训练从隐藏层到输出层的权重. 因此, 与基于深度神经网络的模型相比, BLS 不需要大量训练时间, 而且由于其存储的参数数量较少, 更适用于大规模数据集.

2 GBCD 模型

在本节中, 我们将详细描述所提出的 GBCD, 如图 2 所示. GBCD 的目标是为多个领域中的重叠用户进行推荐, GBCD 的关键思路是从 $(D+1)$ -部图中提取潜在的特征, 该图是利用源域和目标域的信息构造的. 利用 $(D+1)$ -部图上的多图卷积网络(MGCN), 生成了一个捕获相关信息的特征向量. 进一步地, 为了优化所获得的特征向量并消除任何相关的噪声, 我们利用 BLS 从数据中分析和提取有价值的特征. 表 1 中记录了本文中出现的符号汇总.

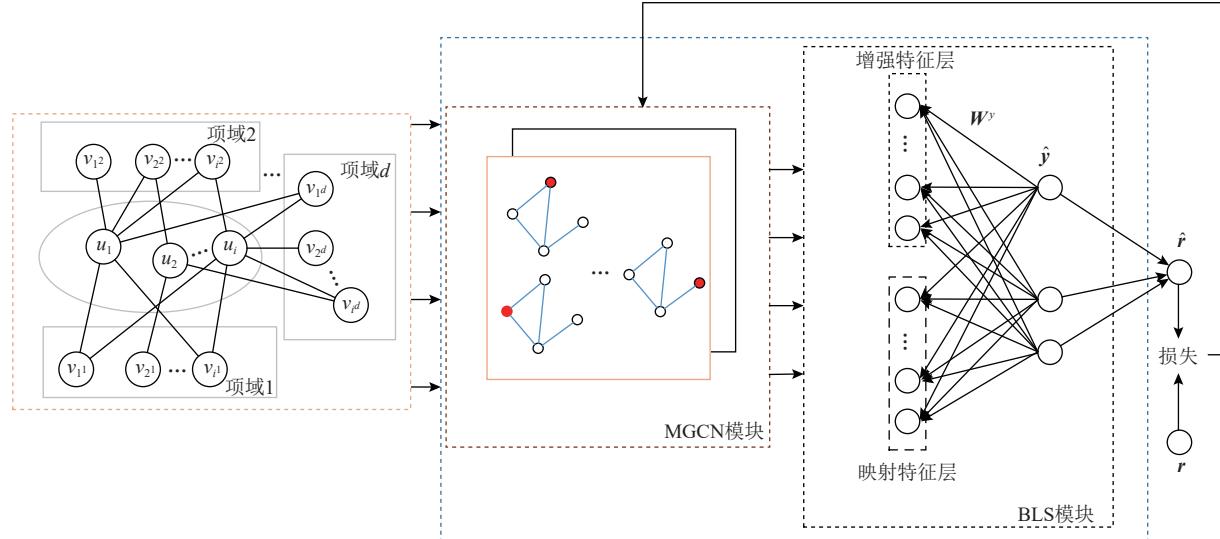


Fig. 2 An overall framework of graph convolutional broad cross-domain recommender system (GBCD)

图 2 图卷积宽度跨域推荐系统 (GBCD) 的整体框架

2.1 跨域特征提取

2.1.1 构造多部图

GBCD 利用了 $(D+1)$ -部图, 使用公共用户作为桥梁来连接跨不同域的项. 这种方法可以实现不同域之间的间接联系, 并便于在每个域中提取潜在的协同滤波嵌入向量. 假设在由 D 个项域组成的跨域推荐任务中, \mathcal{U} 为用户集, \mathcal{V}^d 为第 d 个项域中的项集, $\mathbf{R}^d \in \mathbb{R}^{|\mathcal{U}| \times |\mathcal{V}^d|}$ 为第 d 个项域中的用户-项评分矩阵, $\mathcal{G}^{D+1} = \{\mathcal{U}, \mathcal{V}, \mathcal{E}\}$ 表示 $(D+1)$ -部图. 在 $(D+1)$ -部图中,

$\mathcal{V} = \{\mathcal{V}^1, \mathcal{V}^2, \dots, \mathcal{V}^D\}$ 表示 D 个项域组成的项节点集, 每个 \mathcal{V}^d 对应于第 d 个项域中的项集, $\mathcal{E} = \{\mathcal{E}^1, \mathcal{E}^2, \dots, \mathcal{E}^D\}$ 表示边集, 每个 \mathcal{E}^d 都是连接 \mathcal{U} 和 \mathcal{V}^d 之间节点的边, 即在第 d 个域中用户-项的交互. 每条边的权重取决于用户相应项的评分. 对于 $(D+1)$ -部图, 表示多域用户项评分信息的加权邻接矩阵可以构造为

$$\mathbf{A} = \begin{pmatrix} \mathbf{0} & (\mathbf{R}^1, \dots, \mathbf{R}^D)^T \\ (\mathbf{R}^1, \dots, \mathbf{R}^D) & \mathbf{0} \end{pmatrix}. \quad (1)$$

Table 1 Description Table of the Main Notations**表 1 主要符号描述表**

符号	描述
$\mathcal{U}, \mathcal{V}^d, \mathcal{V} = \{\mathcal{V}^1, \mathcal{V}^2, \dots, \mathcal{V}^D\}$	用户集, 第 d 个项域中的项集, D 个项域组成的项节点集
$\mathbf{R}^d \in \mathbb{R}^{ \mathcal{U} \times \mathcal{V}^d }$	第 d 个域中的用户-项评分矩阵
$\mathcal{G}^{D+1} = \{\mathcal{U}, \mathcal{V}, \mathcal{E}\}$	$(D+1)$ -部图
$\mathcal{E} = \{\mathcal{E}^1, \mathcal{E}^2, \dots, \mathcal{E}^D\}$	边集, 每个 \mathcal{E}^d 都是连接 \mathcal{U} 和 \mathcal{V}^d 之间节点的边
\mathbf{A}	多域用户项的加权邻接矩阵
$\hat{\mathbf{A}}$	基于 \mathbf{A} 增加自连接的邻接矩阵
$\hat{\mathbf{D}}$	$\hat{\mathbf{A}}$ 的度矩阵
$\mathbf{e}_{v^d}^u = [\mathbf{U} \mathbf{V}^d] \in \mathbb{R}^{1 \times 2N}$	跨域协同滤波嵌入向量
$\mathbf{E}^0, \mathbf{E}^k$	\mathbf{E}^0 是 $(D+1)$ -部图的特征矩阵, \mathbf{E}^k 是第 k 层的特征矩阵
\mathbf{E}	跨域协同矩阵, 由跨域协同滤波嵌入向量拼接得到
$\mathcal{W}^g = \{\mathbf{W}^1, \mathbf{W}^2, \dots, \mathbf{W}^k\}$	MGCN 模块的权重参数集合
$\mathcal{W}^b = \{\mathbf{W}_{zj}, \mathbf{W}_{hj}, \mathbf{W}^b, \boldsymbol{\beta}_{zj}, \boldsymbol{\beta}_{hj}\}$	BLS 模块的权重参数集合
$\mathbf{Z}^m, \mathbf{Z}_j$	映射特征矩阵, 第 j 个映射特征矩阵节点
ϕ_j, ξ_j	第 j 个非线性映射特征映射函数, 第 j 个非线性特征增强映射函数
$\mathbf{H}^b, \mathbf{H}_j$	特征增强矩阵, 第 j 个特征增强层节点
$\hat{\mathbf{Y}}$	BLS 输出层的输出矩阵
$\hat{\mathbf{r}}_{v^d}^u$	用户 u 与项 v^d 的预测向量

2.1.2 基于多部图的图卷积神经网络

在该模型中, 设计了一个 MGCN 模块, 用于处理和提取 $(D+1)$ -部图中不同域之间潜在的高阶特征. 与普通的 GCN 网络相比, 该模块摒弃了对特征聚合贡献较少的非线性激活部分, 但保留权重矩阵的训练过程. 该网络定义为

$$\mathbf{e} = f_{\text{MGCN}}(\mathcal{G}^{D+1}; \mathcal{W}^g), \quad (2)$$

其中 \mathbf{e} 为跨域协同滤波嵌入向量, \mathcal{W}^g 为 MGCN 模块的权重参数集合.

MGCN 的核心思想是利用公共用户作为桥梁, 在不同域的项之间建立连接, 然后通过线性的 GCN 来聚合跨域信息学习这些实体的嵌入向量. 该方法可促进信息的递归传递或特征的传播. 具体来说, 其计算步骤为

$$\mathbf{E}^{(k+1)} = \hat{\mathbf{D}}^{-0.5} \hat{\mathbf{A}} \hat{\mathbf{D}}^{-0.5} \mathbf{E}^k \mathbf{W}^k, \quad (3)$$

其中 $\hat{\mathbf{A}} = \mathbf{A} + \mathbf{I}$ 是添加自连接的邻接矩阵, \mathbf{I} 为单位矩阵, $\hat{\mathbf{D}}$ 是 $\hat{\mathbf{A}}$ 的度矩阵, \mathbf{W}^k 是第 k 层中的权值矩阵.

为了使用户-项的嵌入向量尽可能保留原始评分数据, 特征矩阵 \mathbf{E}^0 表示为

$$\mathbf{E}^0 = \begin{pmatrix} (\mathbf{R}^1, \dots, \mathbf{R}^D)^T & \mathbf{I} \\ \mathbf{I} & (\mathbf{R}^1, \dots, \mathbf{R}^D) \end{pmatrix}. \quad (4)$$

通过将特征矩阵 \mathbf{E}^0 输入到 MGCN 中, 可以得到跨域嵌入向量矩阵 $\mathbf{E} = \mathbf{E}^k$, 其中 k 为 MGCN 的层数. 从跨域嵌入向量矩阵 \mathbf{E} 中, 可以得到用户 u 的嵌入向量, 记为 \mathbf{U} . 在第 d 域中的项 v^d 的跨域嵌入向量, 记为 \mathbf{V}^d . 连接形成跨域协同滤波嵌入为

$$\mathbf{e}_{v^d}^u = [\mathbf{U} | \mathbf{V}^d] \in \mathbb{R}^{1 \times 2N}, \quad (5)$$

其中 N 为跨域协同滤波嵌入的维数.

MGCN 利用其特征提取能力来处理 $(D+1)$ -部图, 通过公共用户实现不同域之间的间接连接, 更高效地在每个域内提取潜在的高阶结构嵌入向量. 由此产生的跨域协作滤波嵌入向量捕获了跨不同域的用户和项之间的底层关系和交互, 从而提高了系统的推荐性能.

2.2 跨域 BLS

在此使用跨域 BLS 来映射从 MGCN 模块获得的跨域预测向量, 以减轻潜在的噪声. 传统的 BLS 由 3 个主要部分组成: 映射特征层、特征增强层和输出层. 这 3 个部分共同作用, 以增强模型的鲁棒性和预测能力. BLS 网络定义为

$$\hat{\mathbf{r}} = f_{\text{BLS}}(\mathbf{E}; \mathcal{W}^b), \quad (6)$$

其中 $\mathbf{E} \in \mathbb{R}^{|D| \times 2N}$ 为不同用户-项 $\mathbf{e}_{v^d}^u$ 组合的矩阵, \mathcal{W}^b 为 BLS 模块的权重参数集合.

2.2.1 映射特征层

在映射特征层中, 对嵌入进行初步处理使随机映射嵌入到映射特征矩阵节点 $\mathbf{Z}_j \in \mathbb{R}^{|D| \times d_z}$ 上, 表示为

$$\mathbf{Z}_j = \phi_j(\mathbf{E} \mathbf{W}_{zj} + \boldsymbol{\beta}_{zj}), \quad j=1, 2, \dots, m, \quad (7)$$

其中 $|D|$ 为样本大小, d_z 为每个映射特征组的维数, m 为映射特征组的个数, ϕ_j 为第 j 个非线性映射特征映射函数. 在映射特征层中, 采用了简单的线性变化函数. 与此同时, 在上述过程中, $\mathbf{W}_{zj} \in \mathbb{R}^{2N \times d_z}$ 和 $\boldsymbol{\beta}_{zj} \in \mathbb{R}^{|D| \times d_z}$ 在初始化过程中随机生成. 然后, 将映射特征层中的节点输出组合成映射特征矩阵 \mathbf{Z}^m , 表示为

$$\mathbf{Z}^m = (\mathbf{Z}_1 | \mathbf{Z}_2 | \dots | \mathbf{Z}_m) \in \mathbb{R}^{|D| \times md_z}. \quad (8)$$

2.2.2 特征增强层

特征增强层以映射特征层的输出 \mathbf{Z}^m 作为输入, 特征增强层节点 $\mathbf{H}_j \in \mathbb{R}^{|D| \times d_h}$ 计算为

$$\mathbf{H}_j = \xi_j(\mathbf{Z}^m \mathbf{W}_{hj} + \boldsymbol{\beta}_{hj}), \quad j=1, 2, \dots, h, \quad (9)$$

其中 d_h 表示每个特征增强组的维数, h 表示特征增强组的个数, ξ_j 为第 j 个非线性特征增强映射函数. 在上述过程中, 采用 ReLu 作为非线性映射函数. $\mathbf{W}_{hj} \in \mathbb{R}^{md_z \times d_h}$ 和 $\boldsymbol{\beta}_{hj} \in \mathbb{R}^{|D| \times d_h}$ 在初始化过程中随机生成. 然后, 将特征增强层中的节点输出组合成特征增强矩阵 \mathbf{H}^h , 即

$$\mathbf{H}^h = (\mathbf{H}_1 | \mathbf{H}_2 | \cdots | \mathbf{H}_h) \in \mathbb{R}^{|D| \times hd_h}. \quad (10)$$

2.2.3 输出层

在输出层中, BLS 模块用映射的特征矩阵 \mathbf{Z}^m 和增强的特征矩阵 \mathbf{H}^h 计算输出 $\hat{\mathbf{Y}}$, 即

$$\hat{\mathbf{Y}} = (\mathbf{Z}^m | \mathbf{H}^h) \mathbf{W}^y, \quad (11)$$

其中 $\mathbf{W}^y \in \mathbb{R}^{(md_z + hd_h) \times d_y}$ 为可训练的权重矩阵, d_y 为输出标签的数量. 在训练过程中, 只需要调整可训练的矩阵, 这可以通过使用岭回归算法得到一个伪逆矩阵来近似, 即

$$\mathbf{W}^y = (\mathbf{Z}^m | \mathbf{H}^h)^+ \mathbf{Y}. \quad (12)$$

在获得 BLS 模块输出层的输出矩阵 $\hat{\mathbf{Y}}$ 后, 便可以得到相对应的用户 u 与项 v^d 的预测向量 $\hat{\mathbf{y}}_{v^d}^u$. 同时, 需要对其进行规范化和加权计算预测用户-项评分 $\hat{r}_{v^d}^u$, 即

$$\hat{r}_{v^d}^u = \sum_{j=1}^{d_y} \frac{\hat{\mathbf{y}}_{v^d}^u[j] - \min(\hat{\mathbf{y}}_{v^d}^u)}{\max(\hat{\mathbf{y}}_{v^d}^u) - \min(\hat{\mathbf{y}}_{v^d}^u)} \hat{\mathbf{y}}_{v^d}^u[j]. \quad (13)$$

2.3 损失函数及方法

使用传统的基于 GCN 方法训练 MGNC 网络时, 由于在图网络中使用 MGNC 聚合邻居节点信息会导致学习不合理的交互信息, 学习到的高阶信息可能不够准确和合理, 导致模型预测精度较低、模型鲁棒性较差. 为克服这一问题, 本文利用 BLS 的随机映射特性来增强 MGNC 模型的鲁棒性. 因此, GBCD 方法不使用中间结果进行 MGNC 的训练, 而是端对端对网络进行更新, 直接利用最终推荐任务的输出也就是 BLS 的输出作为优化目标, 即面向任务的训练优化方法. 在本文中, 最终推荐任务的目标是预测评分, GBCD 方法的损失函数表示为

$$\min_{\mathbf{W}^g, \mathbf{W}^b} \frac{1}{|\mathcal{R}|} \sum_{r_{v^d}^u \in \mathcal{R}} (r_{v^d}^u - \hat{r}_{v^d}^u)^2, \quad (14)$$

其中 \mathcal{R} 表示输入样本集合.

算法 1 提供了本文所提出的 GBCD 的伪代码.

算法 1. 图卷积宽度跨域推荐系统 (GBCD).

输入: $(D+1)$ -部图 \mathcal{G}^{D+1} , 映射特征组的个数 m , 映射特征组的维数 d_m , 特征增强组的个数 h , 每个特征增强组的维数 d_h , 训练轮数 N_{epoch} .

输出: 用户-项的预测评分 \hat{r} .

- ① 初始化权重参数 \mathbf{W}^g 和 \mathbf{W}^b ;
- ② $\mathbf{A}, \mathbf{E}^0 \leftarrow \mathcal{G}^{D+1}$; /* 将 $(D+1)$ -部图转换为相应加权邻接矩阵和特征矩阵 */
- ③ for N_{epoch} do
- ④ $\mathbf{E} \leftarrow f_{\text{MGNC}}(\mathbf{A}, \mathbf{E}^0; \mathbf{W}^g)$; /* 通过 MGNC 提取和学习不同域之间的嵌入向量 */

- ⑤ for j in 1 to m do
- ⑥ $\mathbf{Z}_j \leftarrow \phi_j(\mathbf{E} \mathbf{W}_{zj} + \boldsymbol{\beta}_{zj})$; /* 对嵌入向量进行随机映射生成 BLS 映射层输出 */
- ⑦ end for
- ⑧ $\mathbf{Z}^m \leftarrow (\mathbf{Z}_1 | \mathbf{Z}_2 | \cdots | \mathbf{Z}_m)$; /* 映射特征层中的节点输出组合成映射特征矩阵 */
- ⑨ for j in 1 to h do
- ⑩ $\mathbf{H}_j = \xi_j(\mathbf{Z}^m \mathbf{W}_{hj} + \boldsymbol{\beta}_{hj})$; /* 对 BLS 映射层输出进行非线性变化生成 BLS 增强层输出 */
- ⑪ end for
- ⑫ $\mathbf{H}^h \leftarrow (\mathbf{H}_1 | \mathbf{H}_2 | \cdots | \mathbf{H}_h)$; /* 特征增强层中的节点输出组合成特征增强矩阵 */
- ⑬ $\mathbf{W}^y \leftarrow (\mathbf{Z}^m | \mathbf{H}^h)^+ \mathbf{Y}$; /* 通过使用岭回归算法得到一个近似的伪逆矩阵与标签信息矩阵 \mathbf{Y} , 计算出所需权重矩阵 */
- ⑭ $\hat{\mathbf{Y}} \leftarrow (\mathbf{Z}^m | \mathbf{H}^h) \mathbf{W}^y$;
- ⑮ $\hat{r} \leftarrow \hat{\mathbf{Y}}$;
- ⑯ 计算并最小化式(14); /* 通过最小化该损失函数学习 GBCD */
- ⑰ end for
- ⑱ 返回 \hat{r} .

3 实验

在本节实验中, 我们打算回答 3 个研究问题:

研究问题 1. 为什么有必要使用 CDR 方法, 以及利用来自源域的信息是否能提高其有效性. 此外, 与其他最先进的跨域方法相比, 我们提出的 GBCD 方法性能表现如何.

研究问题 2. 利用 MGNC 聚合多部图的特征是否有优势. 此外, 结合 BLS 随机映射的特征是否增强了模型的鲁棒性.

研究问题 3. 超参数如何影响 GBCD 的性能.

3.1 实验设置

3.1.1 数据集和评估指标

根据现有文献 [2], 本文实验使用 2 个具有多个领域的公共数据集, 即 Amazon 数据集和 MovieLens 数据集, 如表 2 所示.

1) Amazon. 该数据集包含 1996 年 5 月至 2018 年 10 月的 2.331 亿条评论(评分), 每个记录均为一个元组(用户、项、评分、时间戳). 由于数据集的规模相当大, 评分记录很少的用户倾向于对随机项进行评分, 这将降低效率和有效性. 因此, 在我们的实验中按照文献 [2] 的规定, 将在 4 个域汇总评分记录中数

Table 2 Two Datasets Used in Experiments

表 2 实验中使用的 2 个数据集

数据集	域	用户数	项数	评分数	密度/%
Amazon	Books	12 761	7 346	85 400	0.09
	CDs	12 761	2 541	85 865	0.27
	Music	12 761	778	28 680	0.29
	Movies	12 761	8 270	188 507	0.18
	Beauty	30 000	302 782	345 231	0.01
	Fashion	30 000	146 794	140 648	0.01
MovieLens	COM	2 113	3 029	332 038	5.19
	DRA	2 113	3 975	381 616	4.54
	ACT	2 113	1 277	241 211	8.94
	THR	2 113	1 460	226 975	7.36

量小于 5 的用户和项删除, 即书本(books)、光盘(CDs)、音乐(music)和电影(movies)。同时, 我们保留 2 个域为原始数据集大小, 即美容(beauty)和时尚(fashion)。

2) MovieLens. 数据集来自马德里自治大学的信息检索组, 该数据集包含 2 113 名用户、10 197 部电影、855 598 个 1970—2009 年的电影评分。我们使用电影的标签将电影划分为 18 个域, 并在我们的实验中使用了 4 个电影域, 即喜剧(COM)、戏剧(DRA)、动作(ACT)和惊悚(THR)。

如表 3 所示, 我们从这 2 个不同的数据集中定义了 23 个 CDR 任务。

3.1.2 对比方法

由于 GBCD 属于 CDR 方法的类别, 本文的重点是将其性能与经典的和最先进的 CDR 方法进行比较。因此, 我们选择 6 种方法作为对比算法: 1) 单域推荐模型(target, TGT)是一种经典的单域 MF 模型, 仅使用目标域数据进行训练。2) CMF^[44]是 MF 的扩展, 它考虑了目标域和源域的交互矩阵, 在这 2 个域之间共享用户的嵌入内容。3) L-GCN^[43]是一个简化的图卷积推荐方法, 它是一个单领域方法。我们将多个域的数据进行合并, 利用 L-GCN 在合并数据上进行推荐计算。4) EMCDR^[46]是一种常用的冷启动 CDR 方法。它将用户偏好编码为源域和目标域中的向量, 然后学习一个映射函数, 将用户向量从源域映射到目标域。5) PTUP^[27]是一种个性化的桥接 CDR 方法, 它通过学习由用户特征嵌入组成的元网络来定制用户桥接。PTUP 提供了 3 种变体版本 PTUP-MF, PTUP-DNN, PTUP-GMF, 每种版本都使用不同的模型进行个性化桥接。6) DisenCDR^[46]通过解耦领域共享和领域特定信息以及利用互信息规则来增强跨域推荐性能。

Table 3 Statistics of the Cross Domain Tasks

表 3 跨域任务的统计信息

数据集	CDR 任务	源域	目标域
Amazon	1	Books	CDs
	2	Books	Music
	3	Books	Movies
	4	CDs	Music
	5	CDs	Movies
	6	Music	Movies
	7	Books+CDs	Music
	8	Books+CDs	Movies
	9	Books+Music	Movies
	10	CDs+Music	Movies
	11	Books+CDs+Music	Movies
	12	Beauty	Fashion
MovieLens	1	COM	DRA
	2	COM	ACT
	3	COM	THR
	4	DRA	ACT
	5	DRA	THR
	6	ACT	THR
	7	COM+DRA	ACT
	8	COM+DRA	THR
	9	COM+ACT	THR
	10	DRA+ACT	THR
	11	COM+DRA+ACT	THR

3.1.3 实施细节

GBCD 方法以及对比方法均基于 PyTorch 实现。其中 TGT, CMF, EMCDR 的实现是由 PTUP 的公开代码一并实现的。Adam 优化器的初始学习速率在 {0.001, 0.001, 0.005, 0.01, 0.02, 0.02, 0.1} 范围内使用网格搜索进行调整。另外, 所有模型的批处理大小均设置为 256, 每个模型的嵌入维度为 10。

在 GBCD 方法中, 我们将映射特征组数量 m 和特征增强组数量 h 均设置为 25, 映射的特征维度 d_m 设置为 10, 增强的特征维度 d_h 设置为 15。将测试用户设置为 25% 的重叠用户。所有的实验均在一台拥有英特尔酷睿 i9-10900 CPU, GeForce RTX 3090 的服务器上运行。GBCD 的代码可以在 <https://github.com/BroadRS/GBCD> 下载。

3.2 性能比较(研究问题 1)

在本节中, 我们将介绍实验结果, 并深入讨论将 GBCD 方法应用于 23 个跨域任务数据集的实验效果。实验结果如表 4 和表 5 所示, 其中 MAE 和 RMSE 分别表示平均绝对误差和均方差。结果如下: 首先, TGT

是一种单域模型, 只利用目标域的数据, 而忽略源域的数据, 其性能并不令人满意。相比之下, 其他利用源域数据进行跨域推荐的跨域方法始终优于单域TGT。因此, 结合源域数据的方法被证明是缓解数据稀疏性和提高目标域推荐性能的有效方法。其次, CMF, L-GCN 将多个域的数据合并到一个域中, 并共享用户的嵌入, 但在大多数任务中特别是在 Amazon 数据集, CMF, L-GCN 的表现都差于 CDR。造成这种差异的原因是, CMF, L-GCN 对来自不同域的数据一视同仁, 从而忽略了潜在的特定域特征。另一方面, CDR 通过采用特定方法将源域嵌入转化为目标特征空间, 从而有效解决域转移问题。L-GCN 相比 CMF 性能优异, 这是因为与 CMF 相比, L-GCN 考虑到了用户与项之间的高阶交互信息。最后, 值得注意的是, 在大多数情况下, 与跨域对比算法相比, GBCD 的性能始终

优于最佳对比方法。这是由于与 L-GCN 相比, GBCD 通过 $(D+1)$ -部图来提取跨域特征信息, 比将多个域的数据进行简单合并更加有效。与 EMCDR, PTUP, DisenCDR 相比, GBCD 利用 MGNC 在 $(D+1)$ -部图上显式捕捉了不同域之间高阶的交互信息, 进而提升了跨域推荐的性能。这进一步证明了 GBCD 在跨域推荐方面的有效性。

GBCD 的时间复杂度主要来自于 2 部分: MGNC 模块和 BLS 模块。MGNC 模块每层在进行图卷积的过程中, 每个节点都需要与邻居节点进行信息交换。在每次的信息交换中, 都需要对 N 维的特征向量进行操作, 所以 MGNC 每层的时间复杂度为 $O(|\mathcal{E}|N)$ 。BLS 模块映射特征层生成中需要进行归一化和矩阵运算等操作, 时间复杂度约为 $O(|D|Nm_{\mathcal{D}})$, 增强特征层需要进行非线性激活和矩阵运算等操作, 时间复杂度

Table 4 Comparison of Performance Results on Amazon Dataset
表 4 在 Amazon 数据集上的性能结果比较

任务	评估指标	方法								提升度/%	
		TGT	CMF	L-GCN	EMCDR	PTUP-MF	PTUP-DNN	PTUP-GMF	DisenCDR		
1	MAE	4.412 6	2.076 1	1.428 4	2.980 7	1.409 5	0.848 1	1.219 9	1.142 6	0.807 7	4.76
	RMSE	5.139 0	2.893 8	1.531 5	3.396 8	1.971 8	1.165 5	1.745 5	1.322 6	1.012 4	13.14
2	MAE	4.412 1	2.223 4	1.450 1	3.325 4	1.388 5	0.817 9	1.167 3	1.011 2	0.771 5	5.67
	RMSE	5.144 1	3.042 4	1.572 9	3.654 7	1.917 3	1.128 7	1.702 7	1.181 2	1.003 3	11.11
3	MAE	4.275 3	1.992 2	1.364 9	3.142 2	1.193 1	0.838 8	1.056 7	0.979 6	0.824 3	1.73
	RMSE	4.997 4	2.705 5	1.488 5	3.537 5	1.614 6	1.117 8	1.496 0	1.308 6	1.053 2	5.78
4	MAE	4.409 0	1.074 5	1.387 5	1.559 1	1.039 6	0.788 1	0.942 8	1.265 0	0.760 5	3.50
	RMSE	5.144 0	1.613 3	1.504 5	1.973 0	1.520 9	1.080 9	1.460 1	1.387 4	0.974 3	9.86
5	MAE	4.266 2	1.158 1	1.354 9	1.176 2	0.857 2	0.797 8	0.846 8	1.016 5	0.795 9	0.24
	RMSE	4.969 7	1.636 2	1.489 2	1.584 2	1.149 4	1.054 0	1.115 5	1.277 9	1.015 1	3.69
6	MAE	4.242 3	1.040 8	1.462 5	1.002 6	0.833 2	0.816 2	0.827 0	1.232 2	0.807 1	1.11
	RMSE	4.930 4	1.468 6	1.598 5	1.338 3	1.107 6	1.042 5	1.090 4	1.308 3	0.981 6	5.84
7	MAE	4.470 5	0.986 6	1.389 9	1.598 8	1.033 5	0.758 9	0.941 2	1.048 0	0.749 4	1.25
	RMSE	5.200 0	1.447 6	1.501 2	1.959 7	1.472 0	1.051 5	1.364 4	1.221 6	0.995 4	5.34
8	MAE	4.328 5	1.072 6	1.337 1	1.093 8	0.875 3	0.824 5	0.851 2	1.217 2	0.814 6	1.20
	RMSE	5.004 2	1.501 0	1.465 1	1.472 6	1.161 1	1.052 5	1.124 4	1.318 2	1.020 1	3.08
9	MAE	4.262 7	1.008 1	1.363 2	0.986 2	0.846 7	0.776 1	0.821 0	1.156 2	0.803 5	-3.53
	RMSE	4.939 8	1.413 3	1.494 3	1.309 3	1.121 0	1.039 8	1.086 7	1.317 2	0.999 5	3.88
10	MAE	4.211 2	0.957 2	1.349 3	0.976 6	0.854 8	0.780 2	0.822 2	1.324 6	0.778 9	0.16
	RMSE	4.890 5	1.336 5	1.485 1	1.270 1	1.144 0	1.031 8	1.089 8	1.451 4	0.974 0	5.60
11	MAE	4.444 6	0.961 0	1.334 3	0.978 6	0.870 2	0.782 1	0.826 4	1.311 8	0.753 0	3.72
	RMSE	5.112 1	1.328 7	1.457 1	1.277 1	1.157 8	1.036 0	1.104 3	1.471 4	0.958 6	7.47
12	MAE	4.376 1	4.133 7	2.522 7	3.922 9	2.119 5	2.070 4	2.102 9	3.211 2	1.455 2	29.71
	RMSE	5.202 2	4.773 4	2.964 6	4.170 3	2.694 9	2.654 7	2.688 2	4.186 7	1.968 4	25.85

注: 加粗为最优结果, 提升度=(最佳基线性能-GBCD 的性能)/最佳基线性能。

Table 5 Comparison of Performance Results on MovieLens Dataset
表 5 在 MovieLens 数据集上的性能结果比较

任务	评估指标	方法								提升度/%	
		TGT	CMF	L-GCN	EMCDR	PTUP-MF	PTUP-DNN	PTUP-GMF	DisenCDR		
1	MAE	3.5187	0.7259	0.7206	0.7093	0.7087	0.6912	0.6943	0.9793	0.6550	5.66
	RMSE	4.0828	0.9454	0.9892	0.9183	0.9203	0.9035	0.9066	1.0842	0.8523	5.99
2	MAE	3.4289	0.7524	0.8395	0.7484	0.7461	0.7289	0.7343	0.8931	0.6793	7.49
	RMSE	4.0343	0.9715	1.0485	0.9637	0.9689	0.9377	0.9509	0.9520	0.8720	8.30
3	MAE	3.6157	0.7597	0.8823	0.7402	0.7337	0.7203	0.7217	0.8597	0.6732	6.72
	RMSE	4.2084	0.9847	1.0985	0.9562	0.9481	0.9339	0.9412	0.9576	0.8657	8.02
4	MAE	3.3605	0.7036	0.8390	0.7131	0.7086	0.6924	0.6903	0.9571	0.6834	1.00
	RMSE	3.9528	0.9122	1.0550	0.9178	0.9152	0.8945	0.8944	1.0122	0.8861	0.93
5	MAE	3.5322	0.7205	0.8955	0.7380	0.7130	0.7056	0.7025	0.9522	0.6817	2.96
	RMSE	4.1614	0.9349	1.1055	0.9499	0.9291	0.9158	0.9157	1.0321	0.8754	4.40
6	MAE	3.5005	0.7063	0.874	0.7170	0.7064	0.6971	0.6911	0.9160	0.6643	3.88
	RMSE	4.1662	0.9169	1.0900	0.9241	0.9168	0.9020	0.8939	0.9774	0.8584	3.97
7	MAE	3.4866	0.7187	0.8145	0.7360	0.7153	0.7052	0.7002	0.9363	0.6985	0.86
	RMSE	4.0680	0.9342	1.0435	0.9473	0.9245	0.9251	0.9097	0.9871	0.9019	0.24
8	MAE	3.4522	0.7260	0.8760	0.7480	0.7303	0.7133	0.7056	0.9279	0.6719	4.78
	RMSE	4.0307	0.9446	1.1065	0.9618	0.9391	0.9246	0.9206	0.9939	0.8758	4.87
9	MAE	3.4793	0.7324	0.8765	0.7379	0.7282	0.7161	0.7111	0.9040	0.6793	4.47
	RMSE	4.1414	0.9467	1.1080	0.9467	0.9406	0.9231	0.9183	0.9585	0.8720	5.04
10	MAE	3.5241	0.7147	0.8870	0.7395	0.7124	0.6995	0.6956	0.8730	0.6641	4.52
	RMSE	4.1439	0.9283	1.1070	0.9517	0.9283	0.9120	0.9078	0.9313	0.8580	5.49
11	MAE	3.5005	0.7063	0.7057	0.7170	0.7125	0.7064	0.6995	0.9325	0.6701	4.20
	RMSE	4.1662	0.9169	1.1069	0.9241	0.9122	0.9168	0.8946	0.9870	0.8691	2.85

注: 加粗为最优结果, 提升度=(最佳基线性能-GBCD 的性能)/最佳基线性能.

约为 $O(|D|m d_m h d_h)$, 所以 BLS 模块的时间复杂度约为 $O(|D|(N m d_m + m d_m h d_h))$. 各种方法的训练时间与时间复杂度、早停策略、批量大小有关.

表 6 和表 7 给出 GBCD 与对比方法在 23 个跨域任务上的训练时间. 从表 6 和表 7 中可以看出, 基于图模型的训练时间在大部分跨域任务的耗时高于传统模型, 如 L-GCN 和 GBCD 的训练耗时高于其他的对比方法. 这是由于基于图的模型需要处理图结构, 导致计算复杂度增加, 以及 GCN 所采用的全批量训练方法导致收敛较慢. 同时, 由于 Amazon 数据集相比 MovieLens 数据集评分分数较少, 所以 GBCD 在 MovieLens 数据集上的大部分跨域任务比在 Amazon 数据集上的跨域任务更加耗时.

3.3 消融实验 (研究问题 2)

在本节中, 我们将进行实验, 分析 GBCD 的不同组成部分, 并开发 2 种变体, 以更好地验证其有效性. 其中, GCD 是在 GBCD 的基础上去掉 BLS 模块的变

体; GMCD 采用 MLP 代替 BLS 模块; GATBCD 采用图注意网络 (GAT) 代替 GCN. 在此使用 MAE 和 RMSE 指标评估了 GBCD 及其变体的性能, 结果见表 8 和表 9. 表 8 和表 9 中的结果清楚地表明, GBCD 模型的性能优于其他 2 个变体: GCD 和 GMCD. 与这 2 个变体相比, GBCD 的性能提升幅度高达 22.41%. 这表明, 通过使用 BLS 随机映射功能可增强了模型的鲁棒性, 有助于提高模型的预测性能. 此外, 表 8 和表 9 还显示, GBCD 模型显著优于 GATBCD. 这表明与使用 GAT 相比, 利用 GCN 聚合邻域特征有利于提高模型的预测性能. 这些实验结果不仅验证了 GBCD 不同组件的有效性, 还可以看出使用 BLS 增强模型鲁棒性和利用 GCN 聚合图邻域特征对提高模型预测性能的重要性.

3.4 超参数分析 (研究问题 3)

在本节中, 我们将对 GBCD 方法的超参数即映射特征组数 m 、映射特征维数 d_m 、特征增强组数 h 和

Table 6 Training Time on Amazon Dataset

表 6 在 Amazon 数据集上的训练时间

s

任务	方法								GBCD (本文)
	TGT	CMF	L-GCN	EMCDR	PTUP-MF	PTUP-DNN	PTUP-GMF	DisenCDR	
1	53.64	79.95	645.80	11.07	125.85	126.6	123.66	502.80	485.86
2	50.82	70.92	370.23	10.92	74.25	77.82	72.57	301.23	343.17
3	97.05	117.78	844.94	17.07	137.37	149.79	142.65	962.10	809.02
4	50.52	93.45	386.85	11.34	69.84	76.89	75.27	285.08	395.48
5	98.01	140.61	444.71	16.56	141.30	152.82	147.57	837.20	667.92
6	97.68	151.17	695.96	17.43	141.39	149.67	148.53	972.04	621.51
7	52.35	119.58	640.57	11.04	69.72	77.82	73.20	235.24	618.98
8	96.315	170.58	563.02	17.36	143.10	177.72	157.59	556.95	1 048.18
9	100.29	167.73	471.31	17.52	137.25	145.86	142.62	456.99	918.02
10	99.12	200.52	470.87	16.92	134.64	147.72	142.44	4 475.96	906.53
11	117.45	275.55	1 196.02	16.98	144.69	161.52	154.86	3 722.65	1 138.08
12	238.32	1 067.19	4 229.78	24.07	175.64	173.42	179.11	5 308.28	3 902.21

Table 7 Training Time on MovieLens Dataset

表 7 在 MovieLens 数据集上的训练实验

s

任务	方法								GBCD (本文)
	TGT	CMF	L-GCN	EMCDR	PTUP-MF	PTUP-DNN	PTUP-GMF	DisenCDR	
1	155.07	219.78	967.29	24.87	256.44	258.33	264.57	2 381.35	1 947.48
2	216.75	292.02	907.18	31.53	352.05	347.73	347.22	1 579.22	1 597.79
3	347.22	320.64	867.99	39.09	426.90	426.42	430.53	1 525.28	1 478.47
4	219.15	387.15	872.87	31.89	341.13	350.64	362.67	1 822.40	1 719.06
5	268.89	447.06	872.75	41.52	427.35	436.35	455.10	1 522.30	1 661.04
6	402.18	724.77	774.60	49.62	438.03	433.20	707.58	1 147.83	1 223.79
7	257.52	566.34	1 212.95	35.10	356.19	392.37	408.51	1 421.16	2 633.87
8	332.25	598.35	1 186.57	42.51	451.23	461.94	476.58	1 333.53	2 593.37
9	278.28	680.82	1 055.66	40.35	457.86	474.75	466.12	1 004.09	2 158.97
10	326.55	819.60	1 111.12	43.08	529.47	464.76	468.04	2 423.01	2 358.87
11	218.73	906.75	1 508.44	40.89	579.32	523.79	518.25	4 297.78	3 610.48

Table 8 Ablation Study on Amazon Dataset

表 8 在 Amazon 数据集上的消融实验

任务	评估指标	方法				提升度/%
		GCD	GMCD	GATBCD	GBCD (本文)	
1	MAE	1.030 4	0.870 8	1.241 9	0.807 7	7.24
	RMSE	1.140 3	1.236 7	1.649 8	1.012 4	11.22
2	MAE	1.018 1	0.831 7	1.212 3	0.771 5	7.24
	RMSE	1.127 2	1.198 7	1.652 5	1.003 3	11.00
3	MAE	0.920 1	0.853 8	1.103 2	0.824 3	3.56
	RMSE	1.197 4	1.182 1	1.503 3	1.053 2	10.90
4	MAE	0.836 0	0.820 0	1.005 4	0.760 5	7.26
	RMSE	1.144 0	1.218 7	1.376 7	0.974 3	14.83

表 8 (续)

任务	评估指标	方法				提升度/%
		GCD	GMCD	GATBCD	GBCD (本文)	
5	MAE	0.850 8	0.863 6	0.983 9	0.795 9	6.45
	RMSE	1.169 7	1.209 9	1.380 9	1.015 1	13.21
6	MAE	0.942 3	0.882 3	1.031 3	0.807 1	8.52
	RMSE	1.230 4	1.186 9	1.216 7	0.981 6	17.30
7	MAE	1.025 8	0.891 8	0.994 3	0.749 4	15.97
	RMSE	1.250 0	1.237 5	1.306 6	0.995 4	19.56
8	MAE	0.928 5	0.895 2	1.025 6	0.814 6	9.00
	RMSE	1.104 2	1.212 8	1.217 9	1.020 1	7.62
9	MAE	0.923 7	0.906 8	0.948 2	0.803 5	11.39
	RMSE	1.173 2	1.205 1	1.239 0	0.999 5	14.81
10	MAE	0.918 0	0.882 9	0.967 0	0.778 9	11.78
	RMSE	1.290 5	1.242 9	1.260 8	0.974 0	21.63
11	MAE	0.841 2	0.869 5	0.952 0	0.753 0	13.40
	RMSE	1.255 3	1.211 5	1.260 4	0.958 6	20.87
12	MAE	1.698 6	1.722 8	2.187 2	1.455 2	14.33
	RMSE	2.174 0	2.217 6	2.344 9	1.968 4	9.45

注: 加粗为最优结果, 提升度=(最佳基线性能-GBCD 的性能)/最佳基线性能.

Table 9 Ablation Study on MovieLens Dataset

表 9 在 MovieLens 数据集上的消融研究

任务	评估指标	方法				提升度/%
		GCD	GMCD	GATBCD	GBCD (本文)	
1	MAE	0.901 7	0.779 6	1.041 9	0.655 0	15.98
	RMSE	1.374 9	0.982 7	1.280 9	0.852 3	13.27
2	MAE	0.855 9	0.822 3	1.004 0	0.679 3	17.39
	RMSE	1.163 1	1.062 5	1.160 8	0.872 0	17.93
3	MAE	0.890 0	0.809 1	0.896 9	0.673 2	16.80
	RMSE	1.175 8	1.017 4	1.169 9	0.865 7	14.91
4	MAE	0.850 3	0.838 3	0.879 9	0.683 4	18.48
	RMSE	1.104 4	1.059 8	1.155 4	0.886 1	16.39
5	MAE	0.830 5	0.812 1	1.104 1	0.681 7	16.06
	RMSE	1.094 6	1.043 3	1.302 4	0.875 4	16.09
6	MAE	0.835 4	0.788 8	0.837 5	0.664 3	15.78
	RMSE	1.096 6	0.997 7	1.039 3	0.858 4	13.96
7	MAE	0.927 4	0.884 5	0.913 9	0.698 5	21.03
	RMSE	1.272 9	1.122 5	1.213 9	0.901 9	19.65
8	MAE	0.836 5	0.817 3	0.851 8	0.671 9	17.79
	RMSE	1.126 1	1.038 4	1.205 9	0.875 8	15.66
9	MAE	0.810 5	0.800 8	0.885 5	0.679 3	15.17
	RMSE	1.074 7	1.010 3	1.097 2	0.872 0	13.69
10	MAE	0.873 4	0.855 9	0.897 1	0.664 1	22.41
	RMSE	1.112 3	1.083 8	1.189 7	0.858 0	20.83

表9(续)

任务	评估指标	方法				提升度/%
		GCD	GMCD	GATBCD	GBCD(本文)	
11	MAE	0.8403	0.8063	0.9081	0.6701	16.89
	RMSE	1.0406	1.0169	1.1133	0.8691	14.53

注: 加粗为最优结果, 提升度=(最佳基线性能-GBCD 的性能)/最佳基线性能.

特征增强维数 d_h 进行敏感性分析. 在对 1 个参数进行分析时, 其他参数都是固定的. 通过这种灵敏度分析, 我们旨在研究每个超参数对 GBCD 方法性能的影响. 限于篇幅, 我们仅给出 2 个数据集上的任务 1, 6, 7, 11, 其他任务上的结果可以类似得到.

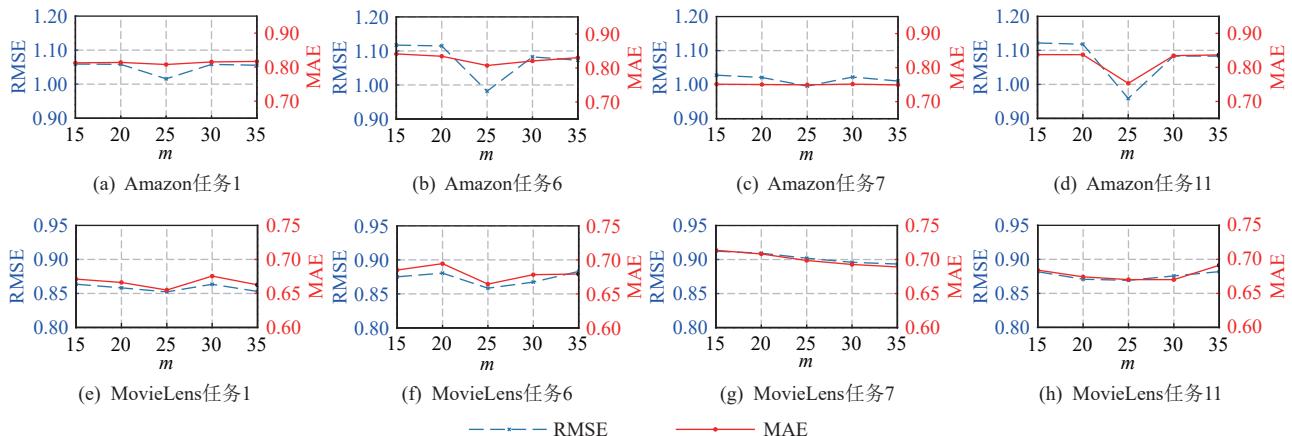
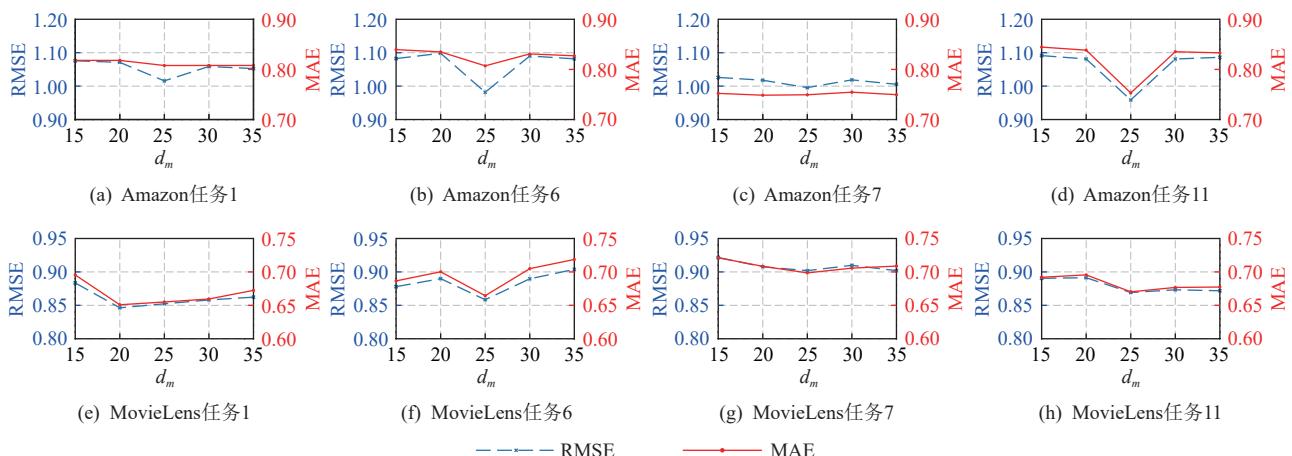
3.4.1 特征映射模块中的超参数

在敏感性分析中, 首要分析 GBCD 方法中特征映射模块的超参数, 包括映射特征组数 m 和映射特征维数 d_m . 为分析 GBCD 方法对这 2 个超参数的敏感性, 在 {15, 20, 25, 30, 35} 范围内测试 m , 在 {5, 10, 15, 20, 25} 范围内测试 d_m . 在此用 MAE, RMSE

评估不同值对性能的影响, 结果如图 3 和图 4 所示. 从图 3 和图 4 中可以看出, GBCD 方法对特征映射层中超参数的敏感度相对较低. 这表明在测试范围内, GBCD 方法的性能不易受到 m 和 d_m 的特定值的影响.

3.4.2 特征增强模块中的超参数

在敏感性分析中, 在此分析 GBCD 方法特征增强模块中的超参数, 包括特征增强组数 h 和特征增强维数 d_h . 为分析 GBCD 方法对这些超参数的敏感性, 在 {15, 20, 25, 30, 35} 范围内测试 h , 在 {5, 10, 15, 20, 25} 范围内测试 d_h . 在此同样使用 MAE 和 RMSE 评估了不同值对性能的影响, 结果如图 5 和图 6 所

Fig. 3 Analysis of RMSE and MAE values by GBCD with different number of mapped feature groups m 图3 GBCD 对不同映射特征组数 m 获得的 RMSE 和 MAE 值分析Fig. 4 Analysis of RMSE and MAE values by GBCD with different number of mapped feature dimensions d_m 图4 GBCD 通过不同数量的映射特征维数 d_m 获得的 RMSE 和 MAE 值分析

示。从图 5 和图 6 中可以看出, GBCD 方法对特征增强模块中超参数的敏感度相对较低。这表明在测试

范围内, GBCD 方法的性能不易受到 h 和 d_h 的特定值的影响。

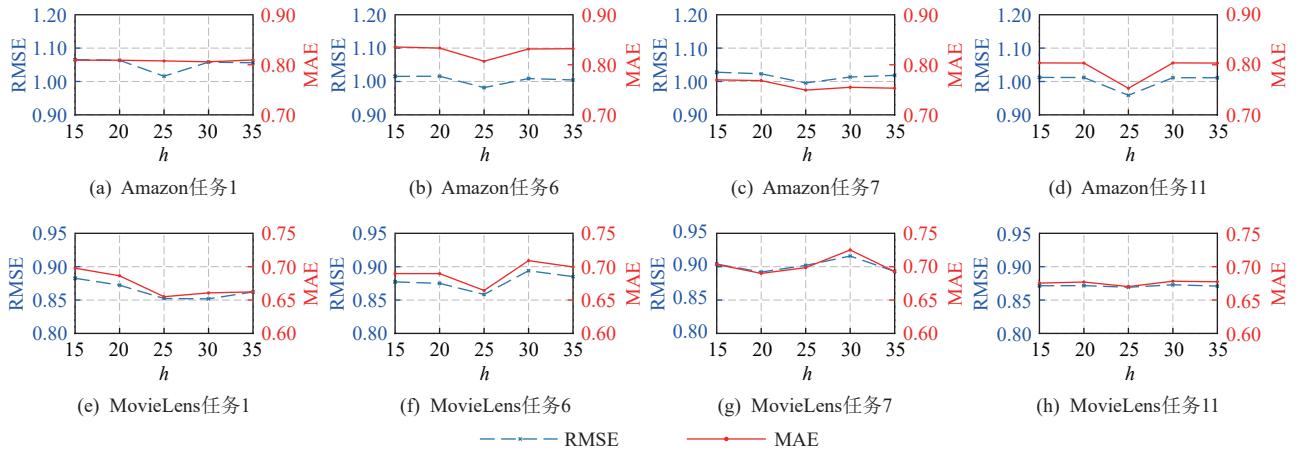


Fig. 5 Analysis of RMSE and MAE values obtained by GBCD with different number of enhanced feature groups h

图 5 GBCD 通过不同特征增强组数 h 获得的 RMSE 和 MAE 值分析

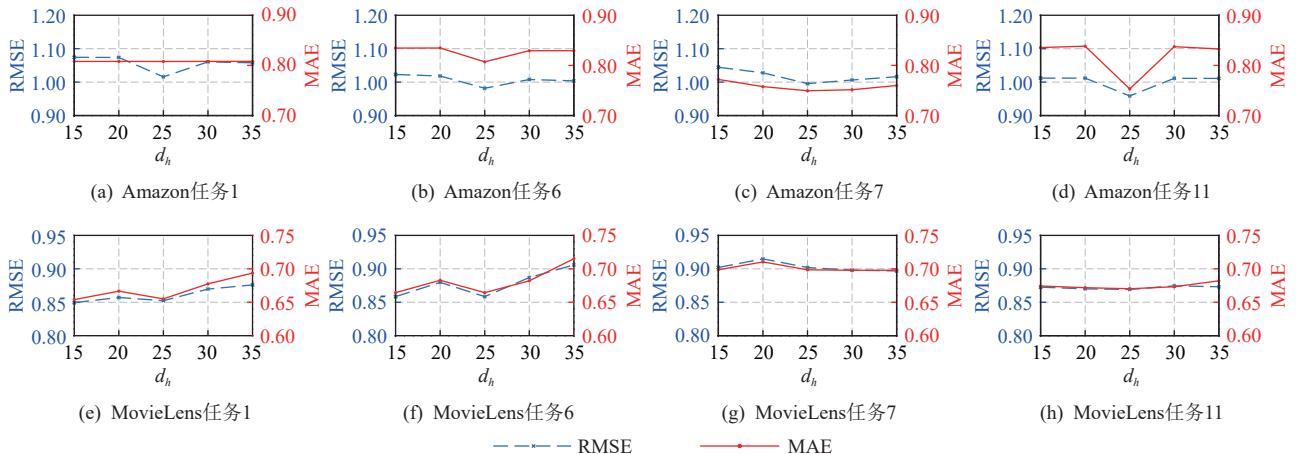


Fig. 6 Analysis of RMSE and MAE values by GBCD with different number of enhanced feature dimensions d_h

图 6 GBCD 通过不同特征增强维数 d_h 得到的 RMSE 和 MAE 值分析

3.5 案例分析

我们进行了案例分析以验证 GBCD 的有效性, 表 10 中列出了在 Amazon 和 MovieLens 数据集中部分跨域任务的具体案例, 其中“真实评分”表示原始的真实评分, “预测评分”表示 GBCD 和部分基线的预测评分。如表 10 所示, GBCD 在大部分的具体案例

上的表现更好。跨域推荐的基线都比单域的基线在大多数的具体案例下表现得要更好, 这说明结合源域数据被证明是缓解数据稀疏性和提高目标域推荐性能的有效方法。

3.6 可视化分析

在本节中, 我们进一步分析 GBCD 是否通过

Table 10 Case Study of the Effectiveness of GBCD

表 10 GBCD 有效性的案例研究

数据集	任务	用户编号	项编号	真实评分	不同算法的预测评分					
					TGT	L-GCN	EMCDR	PTUP-DNN	DisenCDR	GBCD (本文)
Amazon	1	360	8 874	1	2.874 8	3.381 8	1.540 8	1.893 0	1.635 3	1.350 3
	6	1 569	5 363	5	2.233 0	3.187 4	3.162 2	4.014 4	3.605 0	4.497 5
	7	4 067	15 249	5	1.126 0	4.044 8	3.735 7	4.625 8	4.739 0	4.683 5
	11	1 188	27 555	5	1.705 5	3.445 1	4.535 9	4.728 1	3.577 2	4.743 4

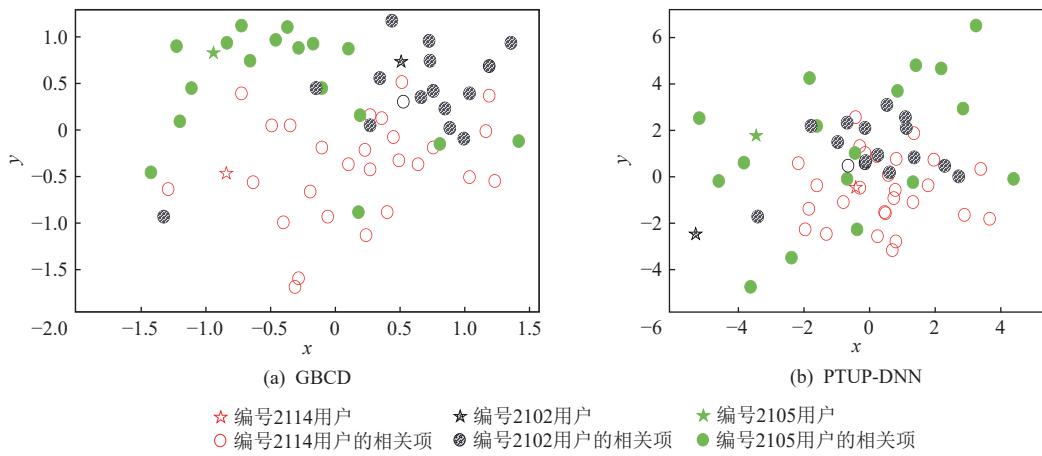
表 10 (续)

数据集	任务	用户编号	项编号	真实评分	不同算法的预测评分					
					TGT	L-GCN	EMCDR	PTUP-DNN	DisenCDR	GBCD (本文)
MovieLens	1	414	4 042	4	0.755 7	4.462 4	2.275 7	4.119 1	3.324 2	4.439 5
	6	814	4 220	3	1.103 7	3.211 8	2.028 9	3.635 9	3.116 1	3.098 9
	7	1 703	7 248	5	0.168 1	3.829 7	3.011 7	4.205 3	3.471 8	4.073 9
	11	896	12 777	3	1.957 7	2.700 0	2.151 2	2.868 0	3.982 8	3.038 5

注:加粗为最优结果.

$(D+1)$ -部图提取到高阶的交互信息从而学习到更好的用户和项表征来提升推荐的性能.为此,我们从 MovieLens 数据集的 COM 到 DRA 跨域任务中随机选择 3 名用户及相关项,并在图 7 中给出从 GBCD 与 PTUP-DNN 提取的用户和项跨域表征进行对比.

通过图 7(a)(b)联合分析(如 2102 和 2105)可以发现: GBCD 提取到的用户历史项的跨域嵌入往往更加接近,该现象验证了 GBCD 相比传统的跨域推荐算法(如 PTUP)能够捕捉到更复杂的用户-项的高阶交互信息.



每个星形形状代表 MovieLens 数据集 DRA 域中的某个具体编号的用户,相同形状的圆代表对应用户对应交互项.

Fig. 7 User and item features learned in GBCD and PTUP-DNN visualised by t-SNE transformation

图 7 从 GBCD 和 PTUP-DNN 中学习得到的用户和项特征经过 t-SNE 转换可视化

4 结 论

在本文中,我们建立了一个基于图卷积宽度跨域推荐系统(GBCD).该方法引入多项关键创新以提高模型的性能和鲁棒性.首先,将多域用户-项交互图建模为 $(D+1)$ -部图,从而能够探索更高阶的特征.其次,利用图卷积网络(GCN)来学习这些高阶特征,从而捕捉跨域用户与项之间的复杂关系.最后,采用 BLS 来增强模型的鲁棒性,从而提高其预测能力.此外,我们还提出了一种新的面向任务的优化损失函数,以有效优化 GBCD 方法, GBCD 方法包括单域和跨域方法.在 2 个真实数据集上进行的大量实验表明, GBCD 优于对比方法,这验证了 GBCD 在应对跨域推荐任务挑战方面的优越性.

在未来的工作中,我们将尝试纳入语义信息,如用户的社交信息和项知识图谱.通过利用这些附加信息,可以提取更多丰富的特征,并更准确地模拟用户的细粒度偏好.这种扩展可以进一步提升 GBCD 模型的性能和个性化能力,为用户提供更全面、更有针对性的推荐.此外,当前存在一些用预训练模型来解决稀疏性问题的研究^[54],这是另一个解决数据稀疏性问题的思路.作为未来工作,我们会尝试用预训练语言模型解决数据稀疏性问题.

作者贡献声明: 黄玲、王昌栋提出了算法思路和实验方案; 黄镇伟、黄梓源负责完成实验并撰写论文; 关灿荣负责实验数据采集和预处理; 高月芳、王昌栋提出指导意见并修改论文.

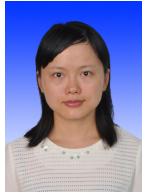
参 考 文 献

- [1] Wang Changdong, Deng Zhihong, Lai Jianhuang, et al. Serendipitous recommendation in e-commerce using innovator-based collaborative filtering[J]. *IEEE Transactions on Cybernetics*, 2018, 49(7): 2678–2692
- [2] Huang Ling, Zhao Zhilin, Wang Changdong, et al. LSCD: Low-rank and sparse cross-domain recommendation[J]. *Neurocomputing*, 2019, 366: 86–96
- [3] Zhong Shiting, Huang Ling, Wang Changdong, et al. An autoencoder framework with attention mechanism for cross-domain recommendation[J]. *IEEE Transactions on Cybernetics*, 2020, 52(6): 5229–5241
- [4] Fu Wenjing, Peng Zhaohui, Wang Senzhang, et al. Deeply fusing reviews and contents for cold start users in cross-domain recommendation systems[C]//Proc of the 31st AAAI Conf on Artificial Intelligence. Palo Alto, CA: AAAI, 2019: 94–101
- [5] Huang Ling, Guan Canrong, Huang Zhenwei, et al. Broad recommender system: An efficient nonlinear collaborative filtering approach[J]. arXiv preprint, arXiv: 2204.11602, 2022
- [6] He Ming, Zhang Jiuling, Yang Peng, et al. Robust transfer learning for cross-domain collaborative filtering using multiple rating patterns approximation[C]//Proc of the 11th ACM Int Conf on Web Search and Data Mining. New York: ACM, 2018: 225–233
- [7] Hu Peng, Du Rong, Hu Yao, et al. Hybrid item-item recommendation via semi-parametric embedding[C]//Proc of the 28th Int Joint Conf on Artificial Intelligence. Freiburg, German: IJCAI, 2019: 2521–2527
- [8] Lei Xu, Jiang Chunxiao, Yan Chen. User participation in collaborative filtering-based recommendation systems: A game theoretic approach[J]. *IEEE Transactions on Cybernetics*, 2019, 49(4): 1339–1352
- [9] Barkan O, Koenigstein N, Yogeve E, et al. CB2CF: A neural multiview content-to-collaborative filtering model for completely cold item recommendations[C]//Proc of the 13th ACM Conf on Recommender Systems. New York: ACM, 2019: 228–236
- [10] Hu Qiyi, Zhao Zhilin, Wang Changdong, et al. An item orientated recommendation algorithm from the multi-view perspective[J]. *Neurocomputing*, 2017, 269: 261–272
- [11] Ferraro A. Music cold-start and long-tail recommendation: Bias in deep representations[C]//Proc of the 13th ACM Conf on Recommender Systems. New York: ACM, 2019: 586–590
- [12] Xiong Fei, Shen Wenhan, Chen Hongshu, et al. Exploiting implicit influence from information propagation for social recommendation[J]. *IEEE Transactions on Cybernetics*, 2019, 50(10): 4186–4199
- [13] Chen Jihong, Chen Wei, Huang Jinjing, et al. Co-purchaser recommendation for online group buying[J]. *Data Science and Engineering*, 2020, 5(3): 280–292
- [14] Koren Y, Bell R, Volinsky C. Matrix factorization techniques for recommender systems[J]. *Computer*, 2009, 42(8): 30–37
- [15] Chen Jiaying, Yu Jiong, Yang Xingyao. A feature extraction based recommender algorithm fusing semantic analysis[J]. *Journal of Computer Research and Development*, 2020, 57(3): 562–575 (in Chinese)
- [16] (陈嘉颖, 于炳, 杨兴耀. 一种融合语义分析特征提取的推荐算法[J]. *计算机研究与发展*, 2020, 57(3): 562–575)
- [17] Yu Yixin, Liu Meng, Zhang Hongyu. Research on user behavior understanding and personalized service recommendation algorithm in Twitter social networks[J]. *Journal of Computer Research and Development*, 2020, 57(7): 1369–1380 (in Chinese)
- [18] (于亚新, 刘梦, 张宏宇. Twitter 社交网络用户行为理解及个性化服务推荐算法研究[J]. *计算机研究与发展*, 2020, 57(7): 1369–1380)
- [19] Yu Yixin, Zhang Wenchao, Li Zhenguo, et al. Hypergraph-based personalized recommendation & optimization algorithm in EBSN[J]. *Journal of Computer Research and Development*, 2020, 57(12): 2556–2570 (in Chinese)
- [20] (于亚新, 张文超, 李振国, 等. 基于超图的 EBSN 个性化推荐及优化算法[J]. *计算机研究与发展*, 2020, 57(12): 2556–2570)
- [21] Sun Xiaoyi, Liu Huafeng, Jing Liping, et al. Deep generative recommendation based on list-wise ranking[J]. *Journal of Computer Research and Development*, 2020, 57(8): 1697–1706 (in Chinese)
- [22] (孙肖依, 刘华峰, 景丽萍, 等. 基于列表级排序的深度生成推荐方法[J]. *计算机研究与发展*, 2020, 57(8): 1697–1706)
- [23] He Xiangnan, Du Xiaoyu, Wang Xiang, et al. Outer product-based neural collaborative filtering[C]//Proc of the 27th Int Joint Conf on Artificial Intelligence. Freiburg, German: IJCAI, 2018: 2227–2233
- [24] Herlocker J L, Konstan J A, Borchers A, et al. An algorithmic framework for performing collaborative filtering[C]//Proc of the 22nd Annual Int ACM SIGIR Conf on Research and Development in Information Retrieval. New York: ACM, 1999: 230–237
- [25] Schafer J B, Frankowski D, Herlocker J, et al. Collaborative filtering recommender systems[M]//The Adaptive Web: Methods and Strategies of Web Personalization. Berlin: Springer, 2007: 291–324
- [26] Chae D K, Kang J S, Kim S W, et al. Rating augmentation with generative adversarial networks towards accurate collaborative filtering[C]//Proc of the 26th World Wide Web Conf. New York: ACM, 2019: 2616–2622
- [27] Shin H, Kim S, Shin J, et al. Privacy enhanced matrix factorization for recommendation with local differential privacy[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2018, 30(9): 1770–1782
- [28] Zhang Haijun, Sun Yanfang, Zhao Mingbo, et al. Bridging user interest to item content for recommender systems: An optimization model[J]. *IEEE Transactions on Cybernetics*, 2019, 50(10): 4268–4280
- [29] Huang Ling, Wang Changdong, Chao Hongyang, et al. A score prediction approach for optional course recommendation via cross-user-domain collaborative filtering[J]. *IEEE Access*, 2019, 7: 19550–19563
- [30] Xie Ruobing, Liu Qi, Wang Liangdong, et al. Contrastive cross-domain recommendation in matching[C]//Proc of the 28th ACM SIGKDD Conf on Knowledge Discovery and Data Mining. New York: ACM, 2022: 4226–4236
- [31] Zhu Yongchun, Tang Zhenwei, Liu Yudan, et al. Personalized transfer of user preferences for cross-domain recommendation[C]//Proc of the 15th ACM Int Conf on Web Search and Data Mining. New York:

- ACM, 2022: 1507–1515
- [28] Li Chenglin, Zhao Mingjun, Zhang Huanming, et al. RecGURU: Adversarial learning of generalized user representations for cross-domain recommendation[C]//Proc of the 15th ACM Int Conf on Web Search and Data Mining. New York: ACM, 2022: 571–581
- [29] Cao Jiangxia, Sheng Jiawei, Cong Xin, et al. Cross-domain recommendation to cold-start users via variational information bottleneck[C]//Proc of the 38th Int Conf on Data Engineering (ICDE). Piscataway, NJ: IEEE, 2022: 2209–2223
- [30] Liu Weiming, Zheng Xiaolin, Hu Mengling, et al. Collaborative filtering with attribution alignment for review-based non-overlapped cross domain recommendation[C]//Proc of the 29th ACM Web Conf 2022. New York: ACM, 2022: 1181–1190
- [31] Liu Weiming, Zheng Xiaolin, Su Jiajie, et al. Exploiting variational domain-invariant user embedding for partially overlapped cross domain recommendation[C]//Proc of the 45th Int ACM SIGIR Conf on Research and Development in Information Retrieval. New York: ACM, 2022: 312–321
- [32] Wu Meihan, Li Li, Chang Tao, et al. Fedcdr: Federated cross-domain recommendation for privacy-preserving rating prediction[C]//Proc of the 31st ACM Int Conf on Information & Knowledge Management. New York: ACM, 2022: 2179–2188
- [33] Ren Hao, Liu Baisong, Sun Jinyang, et al. A time and relation-aware graph collaborative filtering for cross-domain sequential recommendation[J]. *Journal of Computer Research and Development*, 2023, 60(1): 112–124 (in Chinese)
(任豪, 刘柏嵩, 孙金杨, 等. 基于时间和关系感知的图协同过滤跨域序列推荐[J]. *计算机研究与发展*, 2023, 60(1): 112–124)
- [34] Guo Lei, Li Qiuju, Liu Fang'ai, et al. Shared-account cross-domain sequential recommendation with self-attention network[J]. *Journal of Computer Research and Development*, 2021, 58(11): 2524–2537 (in Chinese)
(郭磊, 李秋菊, 刘方爱, 等. 基于自注意力网络的共享账户跨域序列推荐[J]. *计算机研究与发展*, 2021, 58(11): 2524–2537)
- [35] Wu Shiwen, Sun Fei, Zhang Wentao, et al. Graph neural networks inrecommender systems: A survey[J]. *ACM Computing Surveys*, 2022, 55(5): 1–37
- [36] Zhang Si, Tong Hanghang, Xu Jiejun, et al. Graph convolutional networks: A comprehensive review[J]. *Computational Social Networks*, 2019, 6(1): 1–23
- [37] Wu Felix, Souza A, Zhang Tianyi, et al. Simplifying graph convolutional networks[C]//Proc of the 36th Int Conf on Machine Learning. New York: PMLR, 2019: 6861–6871
- [38] Zhao Gang, Wang Qiange, Yao Feng, et al. Survey on large-scale graph neural network systems[J]. *Journal of Software*, 2022, 33(1): 150–170 (in Chinese)
(赵港, 王千阁, 姚烽, 等. 大规模图神经网络系统综述[J]. *软件学报*, 2022, 33(1): 150–170)
- [39] Guo Lei, Zhang Jinyu, Tang Li, et al. Time interval-enhanced graph neural network for shared-account cross-domain sequential recommendation[J]. arXiv preprint, arXiv: 2206.08050, 2022
- [40] Guo Lei, Tang Li, Chen Tong, et al. DAGCN: A domain-aware attentive graph convolution network for shared account cross-domain sequential recommendation[J]. arXiv preprint, arXiv: 2105.03300, 2021
- [41] Jing Zhiwen, Zhao Ziliang, Feng Yang, et al. GReS: Graphical cross-domain recommendation for supply chain platform[C]//Proc of the 31st ACM Int Conf on Information & Knowledge Management. New York: ACM, 2022: 4094–4098
- [42] Chen C L P, Liu Zhulin. Broad learning system: An effective and efficient incremental learning system without the need for deep architecture[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, 29(1): 10–24
- [43] 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
- [44] Singh A P, Gordon G J. Relational learning via collective matrix factorization[C]//Proc of the 14th ACM SIGKDD Int Conf on Knowledge Discovery and Data Mining. New York: ACM, 2008: 650–658
- [45] Zhu Feng, Wang Yan, Chen Chaochao, et al. A deep framework for cross-domain and cross-system recommendations[J]. arXiv preprint, arXiv: 2009.06215, 2020
- [46] Man Tong, Shen Huawei, Jin Xiaolong, et al. Cross-domain recommendation: An embedding and mapping approach[C]//Proc of the 26th Int Joint Conf on Artificial Intelligence. Freiburg, German: IJCAI, 2017: 2464–2470
- [47] Cao Jiangxia, Lin Xixun, Cong Xin, et al. DisenCDR: Learning disentangled representations for cross-domain recommendation[C]//Proc of the 45th Int ACM SIGIR Conf on Research and Development in Information Retrieval. New York: ACM, 2022: 267–277
- [48] Xu Ke, Wang Ziliang, Zheng Wei, et al. A centralized-distributed transfer model for cross-domain recommendation based on multi-source heterogeneous transfer learning[C]//Proc of the 38th Int Conf on Data Mining (ICDM). Piscataway, NJ: IEEE, 2022: 1269–1274
- [49] Berg R, Kipf T N, Welling M. Graph convolutional matrix completion[J]. arXiv preprint, arXiv: 1706.02263, 2017
- [50] 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
- [51] Chen Lei, Wu Le, Hong Richang, et al. Revisiting graph based collaborative filtering: A linear residual graph convolutional network approach[C]//Proc of the 32nd AAAI Conf on Artificial Intelligence. Palo Alto, CA: AAAI, 2020: 27–34
- [52] Liu Meng, Li Jinjun, Li Guohui, et al. Cross domain recommendation via bi-directional transfer graph collaborative filtering networks[C]//Proc of the 29th ACM Int Conf on Information & Knowledge Management. New York: ACM, 2020: 885–894
- [53] Chen C L P, Liu Zhulin, Feng Shuang. Universal approximation capability of broad learning system and its structural variations[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018,

30(4): 1191–1204

- [54] Zhai Jianyang, Zheng Xiawu, Wang Changdong, et al. Knowledge prompt-tuning for sequential recommendation[J]. arXiv preprint, arXiv: 2308.08459, 2023



Huang Ling, born in 1985. PhD, assistant professor. Member of CCF. Her main research interests include data mining and machine learning.
黄玲, 1985年生. 博士, 讲师. CCF会员. 主要研究方向为数据挖掘、机器学习.



Huang Zhenwei, born in 1999. Master. His main research interests include data mining and machine learning.
黄镇伟, 1999年生. 硕士. 主要研究方向为数据挖掘、机器学习.



Huang Ziyuan, born in 1999. Master. His main research interests include data mining and machine learning.
黄梓源, 1998年生. 硕士. 主要研究方向为数据挖掘、机器学习.



Guan Canrong, born in 1999. Master. His main research interests include data mining and machine learning.

关灿荣, 1999年生. 硕士. 主要研究方向为数据挖掘、机器学习.



Gao Yuefang, born in 1979. PhD, associate professor. Member of CCF. Her main research interests include data mining, computer vision, and machine learning.

高月芳, 1979年生. 博士, 副教授. CCF会员. 主要研究方向为数据挖掘、计算机视觉、机器学习.



Wang Changdong, born in 1984. PhD, associate professor, PhD supervisor. Distinguished member of CCF. His main research interests include data mining and machine learning. (changdongwang@hotmail.com)

王昌栋, 1984年生. 博士, 副教授, 博士生导师. CCF杰出会员. 主要研究方向为数据挖掘、机器学习.