



计算机科学

COMPUTER SCIENCE

基于多嵌入融合的top-N推荐

杨真真, 王东涛, 杨永鹏, 华仁玉

引用本文

杨真真, 王东涛, 杨永鹏, 华仁玉. 基于多嵌入融合的top-N推荐[J]. 计算机科学, 2024, 51(7): 140-145.

YANG Zhenzhen, WANG Dongtao, YANG Yongpeng, HUA Renyu. [Multi-embedding Fusion Based on top-N Recommendation](#) [J]. Computer Science, 2024, 51(7): 140-145.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[针对系统调用的基于语义特征的多方面信息融合的主机异常检测框架](#)

Host Anomaly Detection Framework Based on Multifaceted Information Fusion of Semantic Features for System Calls

计算机科学, 2024, 51(7): 380-388. <https://doi.org/10.11896/jsjcx.230400023>

[基于深度确定性策略梯度与注意力Critic的多智能体协同清障算法](#)

Multi-agent Cooperative Algorithm for Obstacle Clearance Based on Deep Deterministic Policy Gradient and Attention Critic

计算机科学, 2024, 51(7): 319-326. <https://doi.org/10.11896/jsjcx.230600129>

[融合多图卷积与层级池化的文本分类模型](#)

Text Classification Method Based on Multi Graph Convolution and Hierarchical Pooling

计算机科学, 2024, 51(7): 303-309. <https://doi.org/10.11896/jsjcx.230400164>

[基于联合学习的语言粒度融合的重叠事件抽取方法](#)

Overlap Event Extraction Method with Language Granularity Fusion Based on Joint Learning

计算机科学, 2024, 51(7): 287-295. <https://doi.org/10.11896/jsjcx.230700118>

[基于外部先验和自先验注意力的图像描述生成方法](#)

Image Captioning Generation Method Based on External Prior and Self-prior Attention

计算机科学, 2024, 51(7): 214-220. <https://doi.org/10.11896/jsjcx.230600167>

基于多嵌入融合的 top-N 推荐

杨真真¹ 王东涛¹ 杨永鹏^{1,2} 华仁玉¹

1 南京邮电大学宽带无线通信与传感网技术教育部重点实验室 南京 210023

2 南京信息职业技术学院网络与通信学院 南京 210023

摘要 异构信息网络(Heterogeneous Information Network, HIN)凭借其丰富的语义信息和结构信息被广泛应用于推荐系统中,虽然取得了很好的推荐效果,但较少考虑局部特征放大、信息交互和多嵌入聚合等问题。针对这些问题,提出了一种新的用于 top-N 推荐的多嵌入融合推荐(Multi-embedding Fusion Recommendation, MFRec)模型。首先,该模型在用户和项目学习分支中都采用对象上下文表示网络,充分利用上下文信息以放大局部特征,增强相邻节点的交互性;其次,将空洞卷积和空间金字塔池化引入元路径学习分支,以便获取多尺度信息并增强元路径的节点表示;然后,采用多嵌入融合模块以便更好地进行用户、项目以及元路径的嵌入融合,细粒度地进行多嵌入之间的交互学习,并强调了各特征的不同重要性程度;最后,在两个公共推荐系统数据集上进行了实验,结果表明所提模型 MFRec 优于现有的其他 top-N 推荐系统模型。

关键词: 异构信息网络;推荐系统;top-N 推荐;多嵌入融合;注意力机制

中图分类号 TP391

Multi-embedding Fusion Based on top-N Recommendation

YANG Zhenzhen¹, WANG Dongtao¹, YANG Yongpeng^{1,2} and HUA Renyu¹

1 Key Laboratory of Ministry of Education in Broadband Wireless Communication and Sensor Network Technology, Nanjing University of Posts and Telecommunications, Nanjing 210023, China

2 School of Network and Communication, Nanjing Vocational College of Information Technology, Nanjing 210023, China

Abstract Heterogeneous information network(HIN) is widely used in recommender systems since its rich semantic and structural information. Although the HIN and the network embedding have achieved good results in recommender systems, the local feature amplification, the interaction of embedding vectors, and the multi-embedding aggregation methods have not been fully considered. To overcome these problems, a new multi-embedding fusion recommendation(MFRec) model is proposed. Firstly, object-contextual representation network is introduced to both branches of user and node representation learning to amplify local features and enhance the interaction of neighbor nodes. Subsequently, the dilated convolution and the spatial pyramid pooling are introduced to the meta-paths learning to obtain multi-scale information and enhance the representation of meta-paths. In addition, the multi-embedding fusion module is introduced to better carry out the embedding fusion of users, items and meta-paths. The interaction between embeddings is carried out in a fine-grained way, and the different importance of each feature is emphasized. Finally, experimental results on two public recommendation system datasets show that the proposed MFRec has better performance than other existing top-N recommendation models.

Keywords Heterogeneous information network, Recommender system, Top-N recommendation, Multi-embedding fusion, Attention mechanism

1 引言

推荐系统通过准确捕捉用户的偏好,来为用户推荐可能感兴趣的项目,进而提高用户使用满意度。因此,如何设计

一个准确、鲁棒的推荐模型是当今推荐系统领域研究的热点之一。传统的推荐系统主要采用协同过滤(Collaborative Filtering, CF)有效地利用反馈信息向用户推荐感兴趣的项目^[1]。例如,基于项目的 K 近邻(ItemKNN)^[2]、贝叶斯个性化排名

到稿日期:2023-04-11 返修日期:2023-08-31

基金项目:国家自然科学基金(62171232);南京邮电大学宽带无线通信与传感网技术教育部重点实验室开放研究基金(JZNY202113);江苏省研究生科研与实践创新计划项目(KYCX22_0955, SJCX23_0251);南京邮电大学科研项目(NY220207)

This work was supported by the National Natural Science Foundation of China(62171232), Open Research Fund of Key Lab of Broadband Wireless Communication and Sensor Network Technology, Ministry of Education(JZNY202113), Postgraduate Research & Practice Innovation Program of Jiangsu Province(KYCX22_0955, SJCX23_0251) and Nanjing University of Posts and Telecommunications Science Fund(NY220207).

通信作者:杨真真(yangzz@njupt.edu.cn)

(Bayesian Personalized Ranking, BPR)^[3]、矩阵分解(Matrix Factorization, MF)^[4]和神经协同过滤(Neural Collaborative Filtering, NCF)^[5]等。近年来,随着机器学习的飞速发展,虽然越来越多的辅助信息被应用到推荐系统中以提升其性能^[6-7],但如何对复杂的异构信息进行处理仍是推荐系统领域面临的一项巨大挑战。

异构信息网络(HIN)受到人们越来越多的关注,该网络把复杂的不同对象和连接分别建模成图中不同类型的节点和边,不同的节点序列即元路径代表不同的语义信息^[8]。基于元路径,HIN能准确捕获各节点(如推荐系统中的用户和项目节点)之间的关系,从而有效地缓解稀疏反馈问题。近年来,研究者们提出了很多HIN的改进网络^[9],例如,异构图注意力网络(Heterogeneous graph Attention Network, HAN)^[10]提出了用于节点分类的节点级和语义级的注意力网络。此外,许多依赖元路径来捕获节点关系的基于HIN的异构图模型也被提出。异构信息嵌入推荐网络(Heterogeneous information network Embedding Recommendation, HERec)^[11]在元路径中构造具有类型约束和过滤的同构序列,将异构序列转化为同构序列进行处理,并用于推荐系统。但该模型仍是将异构图转换为同构图进行处理,损失了异构图包含的丰富的结构和语义信息。Hu等提出了基于元路径上下文的协同注意力推荐(Meta-path based Context Recommendation, MCRec)模型^[12],该模型开发了一种具有协同注意力机制的新型深度神经网络,并首次显式地结合了元路径的上下文嵌入进行top-N推荐,取得了较好的推荐效果,但没有考虑多嵌入的交互与融合。基于邻域的交互推荐(Neighborhood-based Interaction Recommendation, NIRec)模型^[13]通过卷积运算在节点级和路径级捕获和聚合丰富的交互模式,但未充分考虑节点本身特征的捕捉与放大。

虽然基于HIN的模型在推荐系统中取得了一定的成功,但仍存在两个主要缺陷。一方面,针对用户和项目等异构信息的表示,目前的研究较少强调嵌入学习过程中各节点的局部特征放大和交互,从而导致不能获得高质量的嵌入表示;另一方面,目前大多数的研究主要关注聚合的元路径的显式表示,基于元路径的模型几乎都是多支路的嵌入学习,这些研究未充分考虑多嵌入的融合,从而无法准确得到高质量、多维度的嵌入向量。例如,广义深度学习模型(Wide and Deep Learning, WDL)^[14]通过联合训练线性模型和深度神经网络,基于交叉特征的线性模型找出隐性表示的非线性特征,提高了模型的泛化能力,但未充分考虑特征之间的交互关系;深度交叉网络(Deep and Cross Network, DCN)^[15]显式地、有效地捕获特征交互,提高了模型的表达能力,但并未考虑各特征的不同重要程度。

针对上述问题,本文提出了一种基于多嵌入融合的推荐系统(MFRec)模型,针对用户、项目和元路径3种不同的异构信息采用不同的处理方式。首先,在用户和项目的嵌入学习部分,采用对象上下文表示网络(Object-Contextual Representation network, OCR-net)^[16]模块,增强同类型节点的特征放大与交互能力,并通过互注意力机制进行嵌入的改善。

其次,在元路径嵌入学习部分,采用空洞卷积(Dilated Convolution, DC)^[17]和空间金字塔池化(Spatial Pyramid Pooling, SPP)^[18]两个模块,有效获取多尺度信息并增强元路径的节点表示。此外,本文模型还采用多特征重要性选择和双线性特征交互网络(Feature importance and Bilinear feature interaction network, FiBinet)^[19]进行多嵌入融合。该模块通过压缩激励网络(Squeeze-Excitation Network, SENet)^[20]动态学习各特征的重要性,并使用一个双线性交互函数来更好地建模交叉特征,更细粒度地进行嵌入之间的交互,同时强调了各特征的重要性,再经过结合层进行拼接操作,并输入全连接层,得到了增强的融合嵌入。最后,将所提出的MFRec模型应用于两个公共推荐系统数据集并进行了大量的实验,结果表明MFRec模型性能优于其他几种经典的top-N推荐系统模型。

2 多嵌入融合推荐模型

2.1 多嵌入融合推荐模型的总体框架

本文提出了一种基于多嵌入融合的推荐系统即MFRec。针对异构信息,该模型将处理过程划分为用户嵌入表示学习、项目嵌入表示学习和元路径嵌入学习3个分支。首先,在用户和项目嵌入学习分支都采用OCR-net模块,以放大序列中的各节点特征,并增强特征之间的交互性,从而有效增强用户和项目的特征表示;其次,在元路径嵌入学习分支采用空洞卷积和空间金字塔池化模块,从而有效获取多尺度信息,并增强元路径的嵌入表示;最后,采用FiBinet对得到的新的用户嵌入表示、项目嵌入表示以及元路径嵌入表示进行异构信息的多嵌入融合,细粒度地加强各嵌入之间的交互和影响,从而得到最终的有效嵌入表示。本文提出的MFRec模型的整体框架如图1所示。

从图1可以看出,针对得到的用户、项目和元路径输入信息,其处理过程如下。

(1)元路径嵌入学习包括以下流程:首先,以UUUM和UMMM为例,采用优先级评分方法对实验选定的数据集中的元路径进行元路径实例采样,生成高质量的元路径表示;其次,分别经过空洞卷积和空间金字塔池化模块,进行不同维度的特征融合,获取多尺度信息,从而分别得到单个元路径的表示;最后,采用协同注意力机制,输入用户嵌入和项目嵌入,对元路径嵌入进行增强,得到最终的元路径嵌入表示。

(2)用户和项目的嵌入学习与元路径嵌入学习的流程类似:首先,采用查找层将输入的用户和项目信息分别转换为低维稠密向量;其次,用户和项目信息对应的低维稠密向量分别经过OCR-net以达到局部特征放大和信息交互的增强,从而获得优化的用户向量;最后,分别采用用户注意力和项目注意力机制对用户和项目嵌入进行处理,从而得到最终的用户和项目嵌入表示。

(3)得到用户、项目和元路径的嵌入表示之后,采用FiBinet模块获取最终的融合嵌入,有效地解决了忽略特征嵌入重要性程度以及多嵌入之间的交互粗粒度的问题。最后,通过批训练得到多用户-项目对的融合嵌入,并进行处理和对比,得到top-N推荐列表。

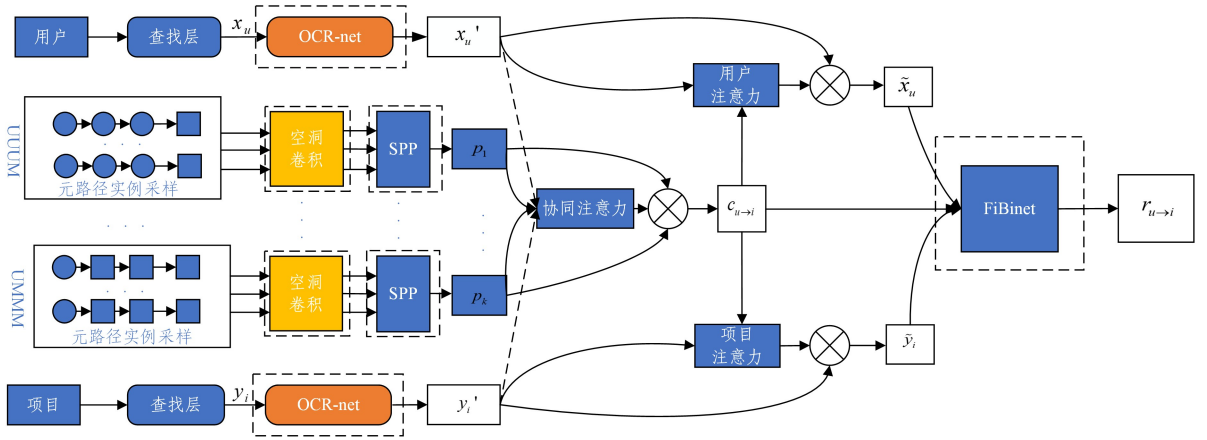


图1 MFRec 模型框架图

Fig. 1 Framework of MFRec model

2.2 用户和项目的嵌入学习

在用户和项目的嵌入学习部分,首先,利用一个全连接层即查找层分别将用户和项目的高维稀疏向量表示转换为低维稠密的向量,其格式分别为:

$$\begin{aligned} \mathbf{x}_u &= \mathbf{M}^T \mathbf{m}_u \\ \mathbf{y}_i &= \mathbf{N}^T \mathbf{n}_i \end{aligned} \quad (1)$$

其中, $\mathbf{m}_u \in \mathbf{R}^{|U| \times 1}$ 和 $\mathbf{n}_i \in \mathbf{R}^{|I| \times 1}$ 分别表示用户和项目, $\mathbf{M} \in \mathbf{R}^{|U| \times d}$ 和 $\mathbf{N} \in \mathbf{R}^{|I| \times d}$ 分别表示可学习的用户和项目转换矩阵, $|U|$ 和 $|I|$ 分别表示用户和项目数目, d 表示用户和项目的维度。

然后,采用 OCR-net 模块来处理用户和项目的表示。与经典的多尺度上下文增强网络相比,OCR-net 更关注对象本身的特征表示及其与上下文对象的关系的结合,更突出其交互性。采用 OCR-net 模块来增强用户和项目节点序列中的各节点特征表示与邻接节点的交互,以增强嵌入。由于 OCR-net 对用户嵌入和项目嵌入学习过程一致,此处仅以用户嵌入学习为例来描述 OCR-net 的处理过程,其嵌入学习过程为:

$$\mathbf{x}_u' = \text{OCR}(\mathbf{x}_u, \theta) \quad (2)$$

其中, θ 表示 OCR-net 模块的各参数。其具体处理过程分为以下 4 个步骤。

(1) 为了深入学习各用户节点之间的交互信息,首先将 \mathbf{x}_u 中每个表征与一个可学习的度相乘,得到特征放大的各表征,表示为:

$$\mathbf{f}_i = m_i' \mathbf{x}_{ui} \quad (3)$$

其中, \mathbf{x}_{ui} 是 \mathbf{x}_u 的第 i 个表征, m_i' 是学习的度。

(2) 计算 \mathbf{x}_u 中第 i 个表征与第 k 个表征之间的关系,表示为:

$$\mathbf{w}_{ik} = \frac{e^{\sigma(\mathbf{x}_{ui}, \mathbf{f}_k)}}{\sum_j e^{\sigma(\mathbf{x}_{ui}, \mathbf{f}_j)}} \quad (4)$$

其中, $\sigma(\mathbf{x}, \mathbf{f}) = \phi(\mathbf{x})^T \varphi(\mathbf{f})$, $\phi(\cdot)$ 和 $\varphi(\cdot)$ 为一维卷积、归一化和 ReLU 组合操作。

(3) 将原始特征 \mathbf{x}_u 进行局部特征增强,以获取更丰富的语义信息,表示为:

$$\mathbf{x}_i' = \rho\left(\sum_{k=1} \mathbf{w}_{ik} \delta(\mathbf{f}_k)\right) \quad (5)$$

其中, $\delta(\cdot)$ 和 $\rho(\cdot)$ 为一维卷积、归一化和 ReLU 组合操作。

(4) 将得到的局部增强特征 \mathbf{x}' 与原始特征 \mathbf{x}_u 进行拼接,

得到最终的用户表示:

$$\mathbf{x}_u' = \text{MLP}(\mathbf{x}' \parallel \mathbf{x}_u) \quad (6)$$

其中, \parallel 是拼接操作, $\text{MLP}(\cdot)$ 为多层感知机。

2.3 元路径的嵌入学习

元路径嵌入学习是为了学习元路径的显式表示,以促进用户和项目的交互。这种表示的关键点是根据路径实例的重要性生成元路径表示。采用空洞卷积和空间金字塔池化模块进行多条元路径实例的多尺度信息表示学习,增强元路径的节点表示。

2.3.1 高质量元路径实例的采样

不同的元路径代表不同的语义和交互关系,一个由该关系组成的实例被称为元路径实例。单个元路径的嵌入是由该关系路径实例的嵌入聚合得到的,因此,路径实例的高质量采样是必要的。然而,基于元路径的随机游走^[21]等路径实例采样方法效率低下,影响了元路径嵌入的生成。在路径中,源节点应该在每个步骤中连接到优先级更高的节点,以便新的节点序列比随机游走得到的路径具有更丰富的语义信息。为了区分不同节点的不同优先级,本文提出了基于节点相似度的优先级评分方法,优先级分数越高,节点之间的关系越紧密。首先,利用基于特征的矩阵分解方法,在没有元路径信息的情况下,为具有历史用户-项目交互记录的每个节点学习潜在向量;其次,计算当前节点和候选输出节点之间的余弦相似度,得到每个路径实例中连接节点之间的优先级得分;接着,对每条元路径实例上的优先级得分进行统一平均或求和运算;然后,比较并排序所有路径实例的最终优先级分数;最后,选择得分前 M 的路径实例来生成单个元路径嵌入。

2.3.2 元路径的嵌入聚合

在获得高质量的元路径实例后,学习路径实例嵌入并聚合以生成元路径嵌入。为了解决元路径嵌入表示的多尺度性以及多路嵌入维度不统一的问题,采用空洞卷积和空间金字塔池化对其进行处理。

采用空洞卷积来扩大接收域,增强同一条节点序列中各节点之间的交互,通过空洞卷积得到的单条元路径实例的嵌入可以表示为:

$$\mathbf{h}_p = \text{Dilated}(\mathbf{E}_p, \tilde{\omega}) \quad (7)$$

其中, $\text{Dilated}(\cdot)$ 表示对单个元路径实例进行空洞卷积操作,

E_p 是单个元路径实例矩阵, $\tilde{\omega}$ 是空洞卷积操作中的相关参数。

单条元路由多条元路径实例构成,故元路径的嵌入由多条高质量采样所得的元路径实例聚合而成。经过卷积层处理过的各类数据存在特征单一的问题,因此采用空间金字塔池化模块进行不同特征的维度融合,以增强最终的嵌入表示,更易于进行网络模型的训练,表示为:

$$c_p = SPP(h_p)_{p=1}^K \quad (8)$$

其中, K 是路径实例的数量。

2.4 协同注意力机制

2.4.1 元路径的注意力

不同的元路径可能具有不同的重要性,高质量的元路径嵌入应该包括每个元路径的语义,并能高度区分它们的重要程度,因此,引入注意力机制至关重要。考虑到用户和项目对不同元路径重要性的影响,我们将用户和项目嵌入协同注意力机制中来增强元路径嵌入的表示。与自注意力机制不同,它不仅考虑了每个元路径内的交互和影响,还考虑了用户和项目对元路径的影响。采用如下两层网络来计算注意力值:

$$\lambda_{u,i,p}^{(1)} = \text{ReLU}(w_u^{(1)} x_u' + w_i^{(1)} y_i' + a^{(1)}) \quad (9)$$

$$\lambda_{u,i,p}^{(2)} = \text{ReLU}(w^{(2)} \lambda_{u,i,p}^{(1)} + a^{(2)})$$

其中, $\lambda_{u,i,p}^{(1)}$ 和 $\lambda_{u,i,p}^{(2)}$ 分别表示第一层和第二层网络得到的注意力分数, ReLU 表示激活函数, $w_u^{(1)}$ 和 $w_i^{(1)}$ 分别是用户和项目的权重矩阵, $a^{(1)}$ 和 $a^{(2)}$ 分别是第一层和第二层网络的偏置向量, $w^{(2)}$ 是第二层的权重矩阵。最终的注意力权重由归一化注意力值得到:

$$\lambda_{u,i,p} = \frac{\lambda_{u,i,p}^{(2)}}{\sum_{a \in M_{u,i}} \lambda_{u,i,p}^{(2)}} \quad (10)$$

其中, $M_{u,i}$ 是元路径的集合。最后,通过协同注意力机制得到元路径嵌入:

$$c_{u \rightarrow i} = \sum_{p \in M_{u,i}} \lambda_{u,i,p} c_p \quad (11)$$

2.4.2 用户和项目的注意力

对于用户和项目嵌入而言,连接它们的元路径包含着丰富的语义信息和交互信息,因此元路径的嵌入表示会影响用户和项目的嵌入,故将用户、项目以及元路径的嵌入作为输入,通过单层网络来计算注意力值,如式(12)所示:

$$\beta_u = \text{ReLU}(w_u x_u' + w_{ui} c_{u \rightarrow i} + b_u) \quad (12)$$

$$\beta_i = \text{ReLU}(w_i' y_i' + w_{ui}' c_{u \rightarrow i} + b_i)$$

其中, w_u 和 w_{ui} 分别表示用户注意力层中自注意权重和互注意力权重矩阵, w_i' 和 w_{ui}' 分别表示项目注意力层中自注意权重和互注意力权重矩阵, b_u 和 b_i 分别是用户和项目的偏置向量。最后,经过优化的用户和项目的嵌入分别表示为:

$$\tilde{x}_u = \beta_u \odot x_u' \quad (13)$$

$$\tilde{y}_i = \beta_i \odot y_i'$$

其中, \odot 表示哈达玛积操作。

2.5 多嵌入的融合

为了解决各个特征嵌入不同重要性程度以及多嵌入之间的交互粗粒度的问题,所提模型采用 FiBinet 作为特征重要性和双线性特征交互网络。该模块包括压缩激励网络层、双线性交互层、结合层和 L 个全连接层。

压缩激励网络层的输入为用户、项目以及元路径的嵌入,即 \tilde{x}_u , \tilde{y}_i 和 $c_{u \rightarrow i}$ 。为了简化起见,本文将 3 个输入重新定义为

$e_1 = \tilde{x}_u$, $e_2 = \tilde{y}_i$, 和 $e_3 = c_{u \rightarrow i}$, 主要包括压缩、激活和重加权 3 个步骤。

首先,输入的 3 个嵌入向量组成矩阵 $E = [e_1, e_2, e_3]$ 分别进行数据压缩得到 3 个嵌入向量的全局信息表示 $Z = [z_1, z_2, z_3]$, 其中 Z 的第 i 个值为:

$$z_i = F_{sq}(e_i) = \frac{1}{R} \sum_{r=1}^R e_i^{(r)} \quad (14)$$

其中, $F_{sq}(\cdot)$ 表示压缩函数,本质上是平均池化操作; R 是 e_i 的特征个数。然后,对压缩阶段的输出 Z 采用两层全连接层进行加权学习:

$$A = [a_1, a_2, a_3] = F_{ex}(Z) = \sigma_2(w_2 \sigma_1(w_1 Z)) \quad (15)$$

其中, σ_1 和 σ_2 表示 ReLU 激活函数, w_1 和 w_2 表示每层网络的可学习加权矩阵。最后,通过重加权,将得到的 A 与输入 E 相乘得到新的嵌入表示:

$$V = F_{re}(A, E) = [a_1 \cdot e_1, a_2 \cdot e_2, a_3 \cdot e_3] = [v_1, v_2, v_3] \quad (16)$$

在双线性交互层,分别采用内积和哈达玛积的组合操作对原始输入嵌入 E 和经过压缩激励网络层处理的嵌入 V 进行操作,以增强特征的交互性。首先,对原始输入嵌入 E 进行交互处理:

$$p_{ui} = \tilde{x}_u \cdot w_1' \odot \tilde{y}_i$$

$$p_{ur} = \tilde{x}_u \cdot w_2' \odot c_{u \rightarrow i}$$

$$p_{ir} = \tilde{y}_i \cdot w_3' \odot c_{u \rightarrow i} \quad (17)$$

其中, \tilde{x}_u , \tilde{y}_i 和 $c_{u \rightarrow i}$ 分别是用户、项目和元路径的嵌入; w_1' , w_2' , w_3' 是可学习加权矩阵。同时,对经过压缩激励网络层处理的向量 V 进行双线性层的交互:

$$q_1 = v_1 \cdot w_1'' \odot v_2$$

$$q_2 = v_1 \cdot w_2'' \odot v_3$$

$$q_3 = v_2 \cdot w_3'' \odot v_3 \quad (18)$$

其中, w_1'' , w_2'' , w_3'' 是可学习加权矩阵。

在结合层中,将双线性交互层得到的 p_{ui} , p_{ur} , p_{ir} , q_1 , q_2 和 q_3 进行拼接:

$$C = p_{ui} \parallel p_{ur} \parallel p_{ir} \parallel q_1 \parallel q_2 \parallel q_3 \quad (19)$$

最后,采用 L 个全连接层对由结合层得到的 C 进行学习。设第一层的输入为 $a^{(0)} = C$, 则第 l 层的输出 $a^{(l)} = \sigma(w^{(l)} a^{(l-1)} + b^{(l)})$, 并得到模型的最终输出为 $r_{u \rightarrow i}$ 。其中 σ 是 ReLU 激活函数, $w^{(l)}$ 和 $b^{(l)}$ 分别是第 l 层的可学习权重和偏置, $a^{(l-1)}$ 为第 $l-1$ 层的输出。

3 实验结果及分析

为了验证本文提出的 MFRec 的优越性,分别进行了消融实验和对比实验。采用 LastFM 音乐数据集和 Movielens 电影数据集这两个被广泛使用的异构数据集作为实验对象来验证所提模型的优越性。其中, LastFM 包含用户、曲目名称、专辑等异构信息; Movielens 包含用户和电影的全类型信息,包括用户的性别、年龄、职业等以及电影的名称、类型等异构信息。使用的服务器 GPU 版本为 NVIDIA Tesla M40 (12GB), 采用 Pytorch 框架。

在实验中,采用高斯分布随机初始化模型参数,采用自适应运动估计算法优化模型并将相同的学习速率分配给每个参数。此外,在数据集中选择了适当的元路径实例, Movielens

中采用 NMUM, UMGM, UUUM 和 UMM, LastFM 中采用 UAT, UAUA, UUUA 和 UUA, 元路径实例数为 5。实验中的批尺寸、正则化参数和学习率分别设置为 256, 0.001 和 0.001。对于所有实验, 使用交叉验证将 80% 的数据集划分为训练集, 剩余的 20% 划分为测试集。所有的实验结果都是取 10 次实验的平均值。

为了定量评估本文提出的模型的性能, 使用了精确率 (Prec@k)、召回率 (Recall@k) 和归一化折损累计增益 (NDCG@k) 作为度量。其中, k 表示以推荐列表前 k 个项目作为

参考对象计算相关指标, 在实验中设置 $k=10$ 。精确率表示准确预测的项目占推荐的所有项目的比值, 召回率表示准确预测的项目占有真实数据的比值, 归一化折损累计增益表示用户的需求项在推荐列表中的位置。3 个指标都是数值越大, 推荐性能越好。

3.1 消融实验

为了验证本文提出的 MFRec 中各模块的有效性, 在 MovieLens 和 LastFM 上进行了消融实验, 实验结果如表 1 所列。

表 1 消融实验

Table 1 Ablation experiments

模型	MovieLens			LastFM		
	Prec@10	Recall@10	NDCG@10	Prec@10	Recall@10	NDCG@10
MFRec	0.3553	0.2358	0.6988	0.4921	0.5153	0.8603
去掉 OCR-net	0.3491	0.2301	0.6936	0.4863	0.5098	0.8563
去掉 DC	0.3526	0.2329	0.6959	0.4885	0.5111	0.8590
去掉 SPP	0.3524	0.2330	0.6954	0.4890	0.5108	0.8588
去掉 FiBinet	0.3481	0.2291	0.6934	0.4855	0.5091	0.8560

从表 1 可以看出, 相对于空洞卷积和空间金字塔池化, FiBinet 模块和 OCR-net 模块对整个模型的作用更大。对于 OCR-net 模块来说, 它在用户和项目嵌入学习分支上不仅仅放大了用户和项目嵌入的局部特征, 还相当于对原有嵌入进行了自注意力形式的学习, 获得了新的嵌入, 与后面的协同注意力机制相结合, 组成了分层注意力机制, 因而更好地学习到了用户和项目的嵌入。以往的推荐系统中对多嵌入结合的处理往往是粗粒度的, 只是简单的拼接或哈达玛积, 并没有考虑各结合嵌入的重要性程度, FiBinet 模块则利用压缩激励网络层和双线性交互层解决了这些问题, 因此具有更好的性能。

3.2 推荐性能对比实验

为了验证本文提出的 MFRec 模型的推荐性能, 将其与以下几种 top-N 推荐方法进行比较。

(1) ItemKNN^[2]: 该模型是协作过滤的经典方法, 通过用户看过、收藏过和评估过的电影及历史评分对某电影进行评分。

(2) BPR^[3]: 该模型采用用户的隐式反馈 (如点击、收藏夹等), 通过贝叶斯问题分析获得的最大后验概率对项目进行排序, 然后生成推荐。

(3) MF^[4]: 该模型解决了 CF 处理稀疏矩阵能力较弱的问题, 利用交叉熵损失进行模型优化。

(4) NCF^[5]: 该模型针对先前的 CF 内部操作过于简单, 无法很好地执行, 利用 MLP 来代替这种操作, 实现了神经网络与 CF 的结合。

(5) HAN^[10]: 该模型采用了注意机制的分层结构, 包括节点级和语义级注意。前者用于区分元路径中节点的重要性, 后者用于了解每个元路径对生成最终嵌入的贡献程度。

(6) MCR^[12]: 该模型是第一个显式表示元路径并将其与用户和项目嵌入相结合来进行推荐的方法, 还引入了协同注意力机制, 以相互增强元路径、用户和项目的表示。

推荐性能对比实验结果如表 2 所列。

表 2 与其他先进推荐方法的性能对比结果

Table 2 Performance comparison results with other advanced recommendation methods

模型	MovieLens			LastFM		
	Prec@10	Recall@10	NDCG@10	Prec@10	Recall@10	NDCG@10
ItemKNN	0.2578	0.1536	0.5692	0.4160	0.4513	0.7981
BPR	0.3010	0.1946	0.6459	0.4129	0.4492	0.8099
MF	0.3247	0.2053	0.6511	0.4364	0.4634	0.7921
NCF	0.3293	0.2090	0.6587	0.4540	0.4678	0.8104
HAN	0.3356	0.2155	0.6845	0.4720	0.4978	0.8421
MCR	0.3451	0.2256	0.6900	0.4807	0.5068	0.8526
MFRec	0.3553	0.2358	0.6988	0.4921	0.5153	0.8603

从表 2 可以看出: (1) 本文提出的 MFRec 在两个数据集上都优于所有基线模型。结果表明, 在用户和项目嵌入学习中考虑局部特征的放大和交互, 以及对传统多嵌入融合机制的改进, 能够提升推荐性能。(2) 在基于 HIN 的推荐方法中, MFRec 的性能优于 HAN 和 MCR。HAN 在节点级和语义级使用层次注意力机制, MCR 引入了显式的元路径表示并且在用户、项目和元路径嵌入之间使用协同关注机制。与两者相比, MFRec 模型在用户和项目的嵌入学习中引入 OCR-net 来加强局部特征的放大并加强节点交互, 并采用 FiBinet 模块进行多嵌入向量的融合, 加强了嵌入的交互。

3.3 时间复杂度对比实验

对本文提出的 MFRec 模型的时间复杂度进行对比实验, 因基于 HIN 的推荐方法的性能明显优于其他推荐方法, 故只比较该类推荐方法的时间复杂度。以每个 epoch 的平均训练时间作为指标, 各模型均在同等条件下进行实验, 其结果如表 3 所列。

由表 3 可知, 与 HAN 和 MCR 相比, 由于 MFRec 在多嵌入融合中加入了哈达玛积和内积的组合操作, 而非之前方法的简单拼接, 一定程度上增加了时间复杂度, 但在训练时间增加不多的情况下, 有效地提升了推荐性能。

表3 与其他先进推荐方法的训练时间对比

Table 3 Comparison of training time with other advanced recommendation methods (s)

模型	Movielens	LastFM
HAN	43.8	37.8
MCRec	45.0	40.8
MFRec	47.4	43.8

结束语 针对当前异构图推荐系统忽略各嵌入学习过程中的局部特征放大与交互,以及未充分考虑多嵌入融合方式的问题,本文提出了用于 top-N 推荐的 MFRec 模型。首先,该模型采用 OCR-net 模块对用户和项目嵌入进行处理,增强了同类型节点序列的特征放大与交互;其次,采用空洞卷积和空间金字塔池化模块,获取多尺度信息并增强元路径的节点表示;最后,采用 FiBinet 模块来更细粒度地进行嵌入之间的交互,并强调各特征的不同重要性程度,增强了最终的嵌入表示。为了验证本文模型的性能,进行了消融实验以及与其他先进推荐方法的对比实验。实验结果表明,本文提出的 MFRec 模型比其他先进的 top-N 推荐方法性能更优。但是,该模型主要针对静态推荐任务,并不适用于动态的推荐场景。在真实的推荐系统中,用户的兴趣偏好会发生变化,且物品的信息会不断地更新。在后续的工作中,可以进一步考虑对异构信息网络进行动态建模,以实时精准地把握用户不断变化的需求。

参 考 文 献

- [1] WU J, XIE H, JIANG W H. Survey of graph neural network in recommendation system[J]. Journal of Frontiers of Computer Science and Technology, 2022, 16(10): 2249-2263.
- [2] AIAEGHU C. An optimized item-based collaborative filtering algorithm[J]. Journal of Ambient Intelligence and Humanized Computing, 2021, 12(12): 10629-10636.
- [3] RENDLE S, FREUDENTHALER C, GANTNER Z, et al. BPR: Bayesian personalized ranking from implicit feedback[C]// Proceedings of the Twenty-Fifth Conference on Uncertainty in Artificial Intelligence. 2009: 452-461.
- [4] KOREN Y, BELL R, VOLINSKY C. Matrix factorization techniques for recommender systems [J]. Computer, 2009, 42(8): 30-37.
- [5] HE X, LIAO L, ZHANG H, et al. Neural collaborative filtering [C]// Proceedings of the 26th International Conference on World Wide Web. 2017: 173-182.
- [6] SHUAI J, ZHANG K, WU L, et al. A review-aware graph contrastive learning framework for recommendation[C]// Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2022: 1283-1293.
- [7] ZHENG C, FU X, DONG L. Recommendation model based on multi-aspect latent feature and neural network[J]. Journal of Chinese Computer Systems. 2022, 43(1): 35-41.
- [8] ZHAO B W, HU L, YOU Z H, et al. Hingrl: predicting drug-disease associations with graph representation learning on heterogeneous information networks[J]. Briefings in Bioinformatics, 2022, 23(1): 1-15.
- [9] WANG X, BO D, SHI C, et al. A survey on heterogeneous graph embedding: methods, techniques, applications and sources[J]. arXiv:2011.14867, 2022.
- [10] WANG X, JI H, SHI C, et al. Heterogeneous graph attention network[C]// The World Wide Web Conference. 2019: 2022-2032.
- [11] SHI C, HU B, ZHAO W X, et al. Heterogeneous information network embedding for recommendation[J]. IEEE Transactions on Knowledge and Data Engineering, 2018, 31(2): 357-370.
- [12] HU B, SHI C, ZHAO W X, et al. Leveraging meta-path based context for top-n recommendation with a neural co-attention model[C]// Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2018: 1531-1540.
- [13] JIN J, QIN J, FANG Y, et al. An efficient neighborhood-based interaction model for recommendation on heterogeneous graph [C]// Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2020: 75-84.
- [14] CHENG H T, KOC L, HARMSSEN J, et al. Wide & deep learning for recommender systems [C]// Proceedings of the 1st Workshop on Deep Learning for Recommender Systems. 2016: 7-10.
- [15] ZHANG W, DU T, WANG J. Deep learning over multi-field categorical data[C]// European Conference on Information Retrieval. 2016: 45-57.
- [16] NGUYEN Q C, PHAM M T, PHAN DD, et al. Efficient Multi-Organ Segmentation Using HRNet And OCRNet [C]// 2022 RIVF International Conference on Computing and Communication Technologies. 2022: 542-547.
- [17] ZHUANG C, LU Z, WANG Y, et al. ACDNet: Adaptively combined dilated convolution for monocular panorama depth estimation[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2022, 36(3): 3653-3661.
- [18] ZHOU W, LIU C, LEI J, et al. HFNet: Hierarchical feedback network with multilevel atrous spatial pyramid pooling for RGB-D saliency detection [J]. Neurocomputing, 2022, 490: 347-357.
- [19] HUANG T, ZHANG Z, ZHANG J. FiBINET: combining feature importance and bilinear feature interaction for click-through rate prediction[C]// Proceedings of the 13th ACM Conference on Recommender Systems. 2019: 169-177.
- [20] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018: 7132-7141.
- [21] DONG Y, CHAWLA N V, SWAMI A. Metapath2vec: Scalable representation learning for heterogeneous networks[C]// Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2017: 135-144.



YANG Zhenzhen, born in 1984, Ph.D., associate professor. Her main research interests include deep learning and multimedia information processing.