



# 计算机科学

COMPUTER SCIENCE

## 基于多空间属性信息融合的序列推荐

王子泓, 邵莹侠, 何吉元, 刘金宝

引用本文

王子泓, 邵莹侠, 何吉元, 刘金宝. 基于多空间属性信息融合的序列推荐[J]. 计算机科学, 2024, 51(3): 102-108.

WANG Zihong, SHAO Yingxia, HE Jiyuan, LIU Jinbao. [Sequential Recommendation Based on Multi-space Attribute Information Fusion](#) [J]. Computer Science, 2024, 51(3): 102-108.

---

## 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)

### [TMGAT:类型匹配约束的图注意力网络](#)

TMGAT:Graph Attention Network with Type Matching Constraint

计算机科学, 2024, 51(3): 235-243. <https://doi.org/10.11896/jsjcx.221200097>

### [基于标签信息融合与多任务学习的中文命名实体识别](#)

Chinese Named Entity Recognition Based on Label Information Fusion and Multi-task Learning

计算机科学, 2024, 51(3): 198-204. <https://doi.org/10.11896/jsjcx.230200114>

### [基于级联U-Net的遥感影像道路分割和轮廓提取方法](#)

Combined Road Segmentation and Contour Extraction for Remote Sensing Images Based on Cascaded U-Net

计算机科学, 2024, 51(3): 174-182. <https://doi.org/10.11896/jsjcx.221200032>

### [基于双分支串行混合注意力的输电线路缺陷检测深度神经网络模型](#)

Deep Neural Network Model for Transmission Line Defect Detection Based on Dual-branch Sequential Mixed Attention

计算机科学, 2024, 51(3): 135-140. <https://doi.org/10.11896/jsjcx.230600109>

### [基于注意力-生成对抗网络的任务分析方法研究](#)

Study on Task Analysis Methods Based on Attention-GAN

计算机科学, 2024, 51(3): 63-71. <https://doi.org/10.11896/jsjcx.221100012>

# 基于多空间属性信息融合的序列推荐

王子泓<sup>1</sup> 邵莹侠<sup>1</sup> 何吉元<sup>2</sup> 刘金宝<sup>2</sup>

1 北京邮电大学计算机学院 北京 100876

2 美团平台搜索推荐算法部 北京 100102

(wzhyt1@bupt.edu.cn)

**摘要** 序列推荐旨在从用户的历史行为中建模用户不断变化的兴趣,从而做出与用户兴趣相关的推荐。近年来,物品属性信息被证明可以提升序列推荐的性能,很多工作基于属性信息融合去提升序列推荐的性能,都取得了成效但仍存在一定的不足。首先,它们没有显式地建模出用户对物品属性的偏好或者只建模了一个属性偏好向量,无法充分表达用户的偏好。其次,它们的物品属性信息融合过程未考虑用户个性化信息的影响。因此,针对上述不足,提出了基于多空间属性信息融合的序列推荐(MAIF-SR)。文中提出了多空间属性信息融合框架,在不同的属性空间下融合属性序列并建模出用户对不同属性的偏好,用多维兴趣充分表达用户的偏好;设计了个性化属性注意力机制,在融合信息的过程中引入用户个性化信息,增强融合信息的个性化效果。在两个公开数据集以及一个工业私有数据集上进行实验,结果表明,MAIF-SR 优于用于对比的基于属性信息融合的序列推荐。

**关键词:** 序列推荐;物品属性;信息融合;用户个性化;注意力机制;多维兴趣

**中图分类号** TP391

## Sequential Recommendation Based on Multi-space Attribute Information Fusion

WANG Zihong<sup>1</sup>, SHAO Yingxia<sup>1</sup>, HE Jiyuan<sup>2</sup> and LIU Jinbao<sup>2</sup>

1 School of Computer Science, Beijing University of Posts and Telecommunications, Beijing 100876, China

2 Meituan Platform Search Recommendation Algorithm Department, Beijing 100102, China

**Abstract** The goal of sequential recommendation is to model users' dynamic interests from their historical behaviors, and hence to make recommendations related to the users' interests. Recently, attribute information has been demonstrated to improve the performance of sequential recommendation. Many efforts have been made to improve the performance of sequential recommendation based on attribute information fusion, and have achieved success, but there are still some deficiencies. First, they do not explicitly model user preferences for attribute information or only model one attribute information preference vector, which cannot fully express user preferences. Second, the fusion process of attribute information in existing works does not consider the influence of user personalized information. Aiming at the above-mentioned deficiencies, this paper proposes sequential recommendation based on multi-space attribute information fusion(MAIF-SR), and proposes a multi-space attribute information fusion framework, fuse attribute information sequence in different attribute information spaces and model user preferences for different attribute information, fully expressing user preferences using multi-dimensional interests. A personalized attribute attention mechanism is designed to introduce user personalized information during the fusion process, enhance the personalized effect of the fusion information. Experimental results on two public data sets and one industrial private data set show that MAIF-SR is superior to other comparative sequential recommendation models based on attribute information fusion.

**Keywords** Sequential recommendation, Item attributes, Information fusion, User personalization, Attention mechanism, Multi-dimensional interests

## 1 引言

由于社交网络、新闻机构和电子商务等在线服务中存在严重的信息过载问题,推荐算法已成为在线用户寻找其真正

感兴趣的的重要工具。更好的推荐可以帮助吸引更多用户点击或浏览,这是在线企业成功的最重要指标之一。序列推荐在线场景中有着广泛而实际的应用。序列推荐旨在根据用户的历史行为对其动态偏好进行建模,并进行下一项推荐。

到稿日期:2023-06-08 返修日期:2023-10-15

基金项目:国家自然科学基金(62272054, 62192784);小米青年学者

This work was supported by the National Natural Science Foundation of China(62272054, 62192784) and Xiaomi Young Talents Program.

通信作者:邵莹侠(shaoyx@bupt.edu.cn)

近几年,很多工作<sup>[1-4]</sup>围绕序列推荐展开,然而,大多数现有的序列推荐主要考虑物品序列,并重视对用户隐藏在序列中的物品偏好进行建模,但很少关注用户对物品属性(类别、品牌、价格等)的偏好。物品属性信息对提升推荐性能有很大帮助<sup>[5]</sup>。因此,有很多工作围绕物品属性信息融合展开,FD-SA<sup>[6]</sup>通过自注意力机制<sup>[7]</sup>建模物品属性序列,S<sup>3</sup>-Rec<sup>[8]</sup>在预训练阶段使用了自监督方法进行属性预测任务。NOVA<sup>[9]</sup>将融合后的物品属性序列引入对物品序列的融合过程,DIF<sup>[10]</sup>在NOVA的基础上对物品属性序列的融合过程作了进一步的优化,然后对物品序列进行融合。虽然这些方法在提升推荐性能方面取得了一定的成功,但它们仍然存在如下两方面的不足。

1)对物品属性信息的融合不能充分地表达用户的偏好。FDSA将物品属性序列融合成一个偏好向量,但物品属性是多样的,一个向量不能充分表达用户对物品属性的偏好。NOVA和DIF尽管对物品属性序列进行了融合,但其最终还是用来融合物品序列,用户对物品属性的偏好并没有被显式地建模出来参与目标预测。S3-Rec甚至没有使用用户交互的物品属性序列去进行目标预测。

2)在融合物品属性信息时没有考虑用户个性化信息的影响。用户个性化信息(性别、年龄、收入等)往往会影响用户对物品属性的偏好,例如收入较高的用户会比较注重商品的品质,老年用户会比较注重商品的价格等。FDSA和NOVA在进行物品属性信息融合时都只采用了可学习权重对其进行加权融合,但可学习权重主要根据目标函数学习而得,使得融合后的向量缺乏个性化的表达。

因此,为了解决上述不足,本文提出了基于多空间属性信息融合的序列推荐(MAIF-SR),在不同属性空间融合属性序列并显式地建模出用户的偏好,充分表达用户对物品属性的偏好,同时将用户个性化信息引入对物品属性序列的融合过程,增强融合信息的个性化效果。具体来说,MAIF-SR将物品序列和物品属性序列分离,独立地建模用户对物品以及物品属性的偏好。对于物品属性偏好建模,设计个性化属性注意力机制,该机制可在不同的属性空间下,利用属性空间信息和用户个性化信息对物品属性序列进行融合,生成用于后续属性偏好建模的融合序列。MAIF-SR将多属性空间下的融合序列再经过建模生成对应的属性偏好。最后MAIF-SR将物品偏好与物品属性偏好结合进行下一项预测。本文在两个公开数据集以及一个工业数据集上对所提出的模型进行了实验,实验结果表明本文模型优于业界最先进的物品属性信息融合技术。

本文的主要贡献包括3个方面:

- 1)设计了个性化属性注意力机制,将个性化信息引入对物品属性信息的融合过程,增强融合信息的个性化效果。
- 2)提出了多空间属性信息融合方法,在不同属性空间融合属性序列并显式地建模用户偏好,用多维兴趣充分表达用户对物品属性的偏好。
- 3)MAIF-SR在两个公开数据集和一个工业数据集上进行了实验,结果证明,MAIF-SR优于业界最先进的基于属性信息融合的序列推荐。

## 2 相关工作

### 2.1 序列推荐

序列推荐旨在从用户的历史顺序交互数据中获取用户的偏好,并进行下一项预测。早期的序列推荐研究<sup>[11-12]</sup>通常基于马尔可夫链假设和矩阵分解方法,但它们很难处理复杂的序列模式。随后,受深度学习技术在序列数据上成功应用的启发,许多研究人员提出利用神经网络,如卷积神经网络(CNN)<sup>[13-14]</sup>、递归神经网络(RNN)<sup>[15-17]</sup>、图形神经网络(GNN)<sup>[18]</sup>来建模用户-物品交互。此外,基于自注意力机制的方法,如SASRec和BERT4Rec<sup>[19]</sup>,由于具有捕捉物品之间的长期依赖性的能力,被认为具有强大的潜力。最近,考虑到个性化<sup>[20]</sup>、物品相似性<sup>[21]</sup>、多重兴趣<sup>[22]</sup>等,对基于自注意力机制的序列推荐提出了许多改进。上文提到的大多数序列推荐方法通常假设只有物品ID可用,并且不考虑诸如物品属性之类的信息,忽略了这样的高度相关信息可以提供额外的监督信号的事实。本文旨在设计有效的融合方法,以更好地利用各种物品属性信息。

### 2.2 序列推荐中的属性信息融合

近年来,属性信息融合在序列推荐中也得到了广泛的研究。FDSA采用不同的自注意力机制块来编码物品和属性信息,直到最后阶段才融合它们的向量表示。S<sup>3</sup>-Rec采用预训练来引入属性信息。具体而言,它设计了两个预训练任务来利用这些有意义的监督信号。NOVA提出在不损害物品嵌入空间一致性的情况下融合属性信息,其中融合属性嵌入仅用于为物品序列生成融合权重。DIF在NOVA的基础上对属性信息融合进行了优化,先对各个属性序列通过自注意力机制进行交叉学习,然后进行融合,使得融合属性嵌入具有更优的注意力表达能力。虽然上述属性信息融合方法取得了一定的成效,但也存在如下不足。首先它们对物品属性信息的融合不能充分表达用户的偏好,FDSA只生成了一个属性融合向量,对于用户对多属性偏好的表达是不充分的;NOVA和DIF使用融合后的物品属性序列去参与物品序列的融合,并没有显示地建模用户对物品属性的偏好去参与目标预测;S<sup>3</sup>-Rec都没有直接使用用户交互的物品属性序列去参与目标预测。其次上述提到的方法在进行属性信息融合时都没有考虑用户个性化信息的影响。

## 3 基于多空间属性信息融合的序列推荐

### 3.1 问题定义

设数据集中用户集合为 $U = \{u_1, u_2, \dots, u_p\}$ ,物品集合为 $V = \{v_1, v_2, \dots, v_q\}$ ,物品的属性集合为 $F = \{f_1, f_2, \dots, f_m\}$ ,其中 $f_i$ 为第 $i$ 个属性域。对于用户 $u \in U$ ,将用户 $u$ 的行为按照时间戳进行划分,用户 $u$ 的历史交互物品序列为 $H = \{h_1, h_2, \dots, h_m\}$ ,物品序列对应的属性组合序列为 $R_f = \{\{r_{1,f_1}, r_{1,f_2}, \dots, r_{1,f_m}\}, \{r_{2,f_1}, r_{2,f_2}, \dots, r_{2,f_m}\}, \dots, \{r_{q,f_1}, r_{q,f_2}, \dots, r_{q,f_m}\}\}$ 。

本文所研究的问题可以描述为给定用户的行为序列 $H$ 以及其对应的不同属性序列 $R_f$ ,预测目标用户的下一个行为,并向目标用户推荐合适的物品。

### 3.2 MAIF-SR 模型

多空间属性信息融合层、物品信息融合层和预测层,如图 1 所示。

本文提出的 MAIF-SR 模型主要包括 4 部分,即嵌入层、

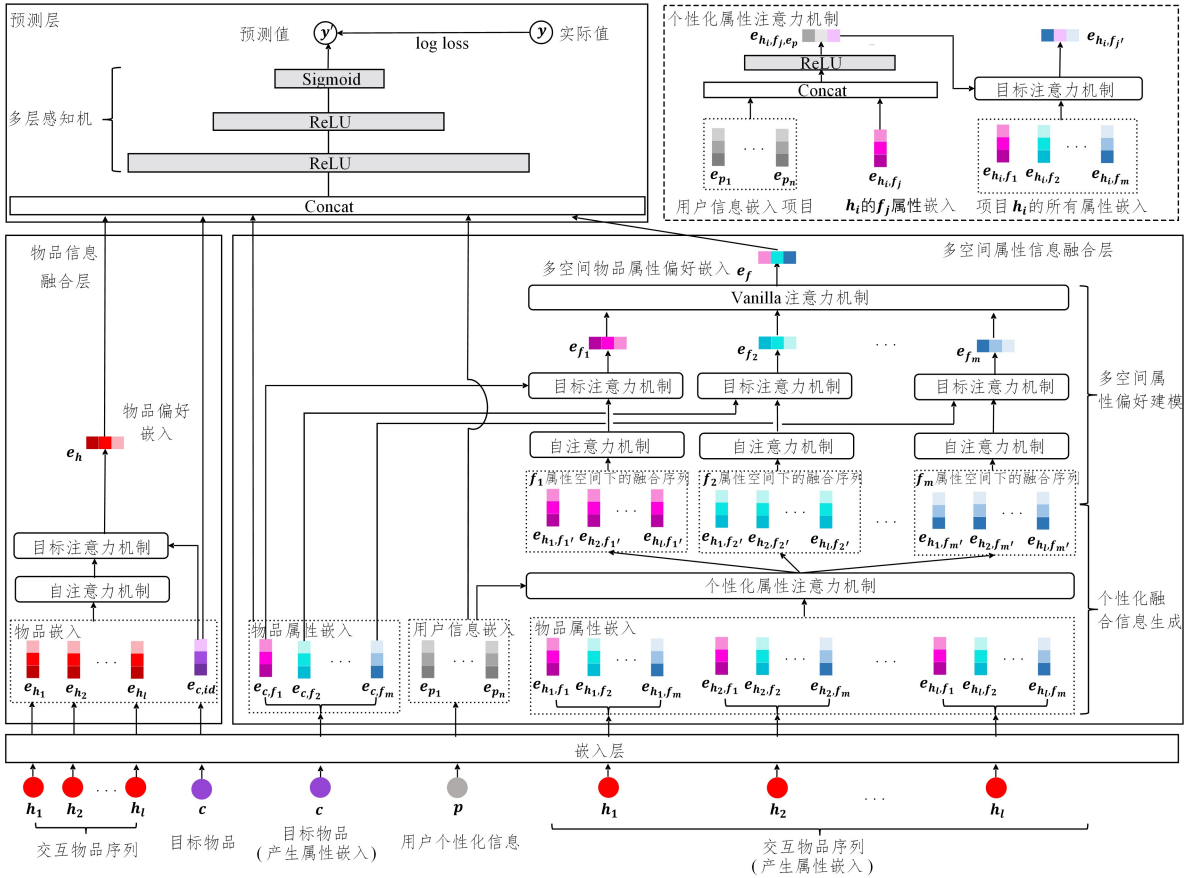


图 1 MAIF-SR 模型的架构图

Fig. 1 Model architecture of MAIF-SR

嵌入层创建了多个嵌入表征查找表,主要将数据集中稀疏的物品、物品属性以及用户属性表示转换为低维稠密的向量表示,并将转换后的向量输入物品偏好建模层和多空间属性信息融合层。物品信息融合层使用流行的自注意力机制和目标注意力机制<sup>[23]</sup>对用户历史交互的物品序列进行融合,生成用户对物品的偏好向量  $e_h$ 。多空间属性信息融合层为了充分表达用户偏好,增强融合信息的个性化效果,设计了个性化属性注意力机制,在不同属性空间下融合物品属性序列并显式生成不同属性空间下的多个属性偏好向量  $e_{f_1}, e_{f_2}, \dots, e_{f_m}$ , 并加权融合生成用户最终的属性偏好向量  $e_f$ 。最后模型将物品偏好向量、物品属性偏好向量和目标嵌入向量拼接送入预测层,预测层通过多层感知机(MLP)生成对目标物品的预测。神经网络通过 log loss 进行优化,最小化网络预测值与目标实际值之间的差距。

#### 3.2.1 嵌入层

首先为物品集合创建嵌入表征查找表  $\mathbf{M}^V \in \mathbf{R}^{V \times d}$ , 其中  $d$  表示嵌入层的维度。对于用户  $u$ , 通过检索物品集合的嵌入表征查找表来将用户交互的物品序列转换为嵌入表征  $\mathbf{E}_h = \{e_{h_1}, e_{h_2}, \dots, e_{h_l}\}$ , 对每个用户从序列末尾向前截取  $l$  个物品, 对于长度小于  $l$  的序列进行填充操作, 即在序列头部填充 0 项, 用零向量作为填充项的嵌入表征。

其次为每个物品属性域创建嵌入表征查找表  $\mathbf{M}^{f_i} \in$

$\mathbf{R}^{f_i \times d}$ ,  $f_i$  为第  $i$  个属性域。然后通过检索物品属性域的嵌入表征查找表, 找到用户交互的物品序列中每一项的所有属性嵌入表征, 并将其组合在一起形成该项的物品属性组合嵌入, 最终得到整个物品属性序列的嵌入表征  $\mathbf{E}_f = \{\{e_{h_1, f_1}, e_{h_1, f_2}, \dots, e_{h_1, f_m}\}, \{e_{h_2, f_1}, e_{h_2, f_2}, \dots, e_{h_2, f_m}\}, \dots, \{e_{h_l, f_1}, e_{h_l, f_2}, \dots, e_{h_l, f_m}\}\}$ 。最后通过物品和物品属性嵌入表征查找表得到预测的目标的物品嵌入和物品属性嵌入为  $e_{c, id}, e_{c, f} = \{e_{c, f_1}, e_{c, f_2}, \dots, e_{c, f_m}\}$ 。

此外, 为用户信息集合创建嵌入表征查找表  $\mathbf{M}^P \in \mathbf{R}^{P \times d}$ , 通过检索物品集合的嵌入表征查找表来找到用户信息嵌入, 得到其嵌入表征  $e_p = \{e_{p_1}, e_{p_2}, \dots, e_{p_n}\}$ 。

#### 3.2.2 多空间属性信息融合层

上文提到, 目前的物品属性信息融合工作无法充分地表达用户对物品属性的偏好, 同时在进行物品属性信息融合时没有考虑用户个性化信息的影响。因此, 本文设计了多空间属性信息融合层来解决这两个不足。为了充分表达用户对物品属性的偏好, 本文在不同的属性空间下显式地建模用户相应的偏好, 该网络层首先会通过个性化属性注意力机制在不同属性空间下利用属性空间信息和用户个性化信息对物品属性序列进行融合, 生成对应属性空间下的融合序列, 然后通过自注意力和目标注意力机制建模融合序列, 生成不同属性空间下的多个用户偏好。由于属性信息融合过程引入了用户

个性化信息,融合表示的用户个性化效果也得到了增强。

具体建模过程如下:给定用户历史交互物品的属性嵌入序列  $\mathbf{E}_f$ 、目标物品的属性嵌入  $\mathbf{e}_{c,f}$ 、用户信息嵌入  $\mathbf{e}_p$ 。首先利用个性化属性注意力机制在不同属性空间下对物品属性嵌入序列  $\mathbf{E}_f$  进行融合。以属性空间  $f_j$  为例,对于序列  $\mathbf{E}_f$  中的物品  $\mathbf{h}_i$ ,其所有属性嵌入为  $\mathbf{e}_{h_i,f} = \{\mathbf{e}_{h_i,f_1}, \mathbf{e}_{h_i,f_2}, \dots, \mathbf{e}_{h_i,f_m}\}$ ,考虑到不同属性在用户对  $\mathbf{h}_i$  物品决策时的重要性不同,同时考虑用户信息对其决策的影响,利用个性化属性注意力机制对  $\mathbf{e}_{h_i,f}$  进行融合。

个性化属性注意力机制:首先将用户信息嵌入  $\mathbf{e}_p$ ,将目标项  $\mathbf{h}_i$  的属性  $f_j$  嵌入  $\mathbf{e}_{h_i,f_j}$  进行拼接,然后通过一个线性层生成  $f_j$  空间下个性化目标向量  $\mathbf{e}_{h_i,f_j,p}$  如式(2)所示,通过目标注意力机制利用  $\mathbf{e}_{h_i,f_j,p}$  计算  $\mathbf{e}_{h_i,f}$  中每一个属性的权重,对所有属性加权融合,得到在  $f_j$  空间下  $\mathbf{h}_i$  的属性融合表示  $\mathbf{e}_{h_i,f_j'}$ ,如式(1)所示:

$$\mathbf{e}_{h_i,f_j'} = \text{TA}(\mathbf{e}_{h_i,f_j,p}, \mathbf{e}_{h_i,f}) = \sum_{k=1}^m (\mathbf{e}_{h_i,f_j,p} \mathbf{e}_{h_i,f_k}^T) \mathbf{e}_{h_i,f_k} \quad (1)$$

$$\mathbf{e}_{h_i,f_j,p} = \text{ReLU}(\mathbf{W}^j [\mathbf{e}_p; \mathbf{e}_{h_i,f_j}] + \mathbf{b}^j) \quad (2)$$

其中,  $\mathbf{W}^j, \mathbf{b}^j$  为可学习参数,ReLU 为激活函数,TA 为目标注意力函数。

然后,在属性空间  $f_j$ ,对于属性嵌入序列  $\mathbf{E}_f$  中其他的项,利用类似的方法进行其属性信息融合,得到在属性空间  $f_j$  下交互物品属性序列  $\mathbf{E}_f$  的属性融合嵌入序列  $\mathbf{E}_{f_j'} = \{\mathbf{e}_{h_1,f_j'}, \mathbf{e}_{h_2,f_j'}, \dots, \mathbf{e}_{h_m,f_j'}\}$ 。序列在其他属性空间下的融合过程与上述类似。

得到序列在各个属性空间下的融合序列后,为了显示建模用户对各个属性的偏好,对各个属性空间下的融合序列使用自注意力和目标注意力机制进行聚合。

以前文构建属性  $f_j$  空间下的融合序列  $\mathbf{E}_{f_j'}$  为例,首先利用自注意力机制对序列  $\mathbf{E}_{f_j'}$  进行交叉得到序列  $\mathbf{S}$ ,捕捉项与项之间的关系如式(3)、式(4)所示:

$$\mathbf{S} = \text{SelfAttnEnc}(\mathbf{E}_{f_j'}) = \text{softmax}\left(\frac{\mathbf{QK}^T}{\mathbf{V}}\right) \quad (3)$$

$$\mathbf{Q} = \mathbf{E}_{f_j'} \mathbf{W}^Q, \mathbf{K} = \mathbf{E}_{f_j'} \mathbf{W}^K, \mathbf{V} = \mathbf{E}_{f_j'} \mathbf{W}^V \quad (4)$$

其中,  $\mathbf{W}^Q, \mathbf{W}^K, \mathbf{W}^V$  是可学习参数,softmax 是激活函数,Self-AttnEnc 为自注意力函数。之后考虑到序列  $\mathbf{S}$  中的每一项对于目标项预测的重要性是不同的,因此通过目标注意力机制对序列  $\mathbf{S}$  进行聚合,生成用户  $\mathbf{u}$  对属性  $f_j$  的偏好  $\mathbf{e}_{f_j}$ ,如式(5)所示:

$$\mathbf{e}_{f_j} = \text{TA}(\mathbf{e}_{c,f_j}, \mathbf{S}) \quad (5)$$

TA 为目标注意力函数,TA 的目标项使用待预测物品的属性  $f_j$  对应的嵌入  $\mathbf{e}_{c,f_j}$ 。

最后通过类似的融合过程得到用户  $\mathbf{u}$  对所有属性的偏好  $\mathbf{E}_{pf} = \{\mathbf{e}_{f_1}, \mathbf{e}_{f_2}, \dots, \mathbf{e}_{f_m}\}$ 。考虑到用户不同的属性偏好对目标物品的预测重要性也不同,因此最后使用 vanilla 注意力机制对所有属性偏好进行加权融合,如式(6)、式(7)所示,生成最终的用户属性偏好向量  $\mathbf{e}_f$ 。

$$\boldsymbol{\alpha}_f = \text{softmax}(\mathbf{W}^f \mathbf{E}_{pf} + \mathbf{b}^f) \quad (6)$$

$$\mathbf{e}_f = \boldsymbol{\alpha}_f \mathbf{E}_{pf} \quad (7)$$

其中,  $\mathbf{W}^f, \mathbf{b}^f$  是可学习参数,softmax 是激活函数。

### 3.2.3 物品信息融合层

物品偏好建模层主要建模用户对物品的偏好,给定用户历史交互物品的嵌入序列  $\mathbf{E}_h$  和目标物品的嵌入  $\mathbf{e}_{c,id}$ ,然后利用自注意力机制和目标注意力机制对  $\mathbf{E}_h$  进行建模,得到用户的物品偏好  $\mathbf{e}_h$ ,如式(8)、式(9)所示:

$$\mathbf{S}' = \text{SelfAttnEnc}(\mathbf{E}_h) \quad (8)$$

$$\mathbf{e}_h = \text{TA}(\mathbf{e}_{c,id}, \mathbf{S}') \quad (9)$$

预测层主要产生对目标项的预测值,首先将各个层建模得到的所有嵌入进行拼接,然后通过多层感知机生成对目标的预测值  $y'$ ,如式(10)一式(12)所示:

$$y' = \text{sigmoid}(\text{FFN}(\text{FFN}(\mathbf{e}^{\text{total}}))) \quad (10)$$

$$\mathbf{e}^{\text{total}} = [\mathbf{e}_h; \mathbf{e}_p; \mathbf{e}_{c,id}; \mathbf{e}_{c,f}; \mathbf{e}_f] \quad (11)$$

$$\text{FFN}(\mathbf{e}^{\text{total}}) = \text{ReLU}(\mathbf{W}^x \mathbf{e}^{\text{total}} + \mathbf{b}^x) \quad (12)$$

其中,FFN 是前馈神经网络,ReLU 是激活函数,  $\mathbf{W}^x$  和  $\mathbf{b}^x$  为可学习参数, ; 是拼接操作。

MAIF-SR 对网络进行优化时,采用交叉熵损失函数优化预测值和目标值之间的差距,如式(13)所示:

$$\text{Loss} = -\frac{1}{N} \sum y \log(y') + (1-y) \log(1-y') \quad (13)$$

其中,  $y$  为目标值,  $y'$  为预测值,  $N$  为训练集样本数。

## 4 实验与分析

### 4.1 实验设置

#### 4.1.1 数据集

本文在两个公开数据集 Movie 和 Yelp 以及一个工业私有数据集 Industrial 上进行实验。实验前对所有数据集进行处理,使得数据集中每个用户和物品至少有 10 个交互。关于 3 个数据集的统计如表 1 所列,Movie 是一个包含大量用户对电影评分的数据集。同时电影数据集采用电影类型、年份,评分作为其属性信息;Yelp 是一个很有名的商户推荐数据集,本文采用商户的浏览量、城市,类型和评分作为其属性信息;Industrial 数据集是通过世界上最大的电子商务平台之一构建的,其中包含比公共数据集更丰富的用户个性化信息和物品属性信息,本文采用商品的类别、品牌、价格和地区作为其属性信息。此外,本文对于 Movie 和 Industrial 数据集都采用用户的 id、性别、年龄,职业作为用户个性化信息,对于 Yelp 采用用户注册年份、平均评分、浏览量作为用户个性化信息。由于 Movie 和 Yelp 数据集主要是用户对物品的评分,评分区间为 [1,5],因此本文将用户评分在 [4,5] 区间内的物品作为正例,其他均作为负例。

表 1 数据集统计

Table 1 Statistics of datasets

数据集	用户数	物品数	交互数
Movie	6040	3367	991365
Yelp	30499	20068	317182
Industrial	3257916	63548	10440315

#### 4.1.2 评价指标

本文主要采用 AUC 和 NDCG 作为实验结果的评价指标。

AUC 指标主要衡量模型的排序能力,它反映排序物品的

相对性即预测用户意向物品得分大于非意向物品得分的能力,计算式如式(14)所示:

$$AUC(L,R) = \frac{1}{|R|(|L|-|R|)} \sum_{i \in R} \sum_{i' \in L \setminus R} \delta(i > i') \quad (14)$$

其中, $L$ 为推荐列表, $R$ 为用户交互列表, $\delta$ 是比较函数,如果 $i$ 的评分大于 $i'$ ,则 $\delta(i > i') = 1$ ,反之 $\delta(i > i') = 0$ 。

归一化折损累计增益 NDCG@k 则更多的是考虑所推荐的物品是否出现在用户更容易关注的位置,即强调了推荐列表的顺序性,计算式如式(15)所示:

$$NDCG@k(L,R) = \frac{1}{k} \sum_{i=1}^k \frac{2^{\rho(i)} - 1}{\log_2(i+1)} \quad (15)$$

其中, $\rho(i)$ 是交互标识, $R$ 为用户交互列表,如果 $i \in R$ ,则 $\rho(i) = 1$ ,反之 $\rho(i) = 0$ 。

为了验证本文模型的有效性,本文将 MAIF-SR 与以下 4 个模型进行对比。

1) SASRec:一种基于注意力的模型,使用自注意力网络进行序列推荐。

2) FDSA:采用两个独立的自注意力分支分别建模用户对物品以及物品属性偏好,并在最后将两者结合进行序列推荐。

3) NOVA:一个采用非侵入性自我注意机制的模型,将属性序列融合后的物品属性序列用于物品序列的融合进行序列推荐,用于更好的注意力分配学习。

4) DIF:在 NOVA 的基础上,对各物品属性序列采用独立的自注意力分支建模后再进行融合,提升融合属性序列的性能。

其中,SASRec 是传统的序列推荐模型,FDSA,NOVA 和 DIF 是序列推荐中研究物品属性信息融合的工作。

#### 4.1.3 参数设置

对于 3 个数据集,由于 Yelp 和 Industrial 的数据量较大,本文首先对这两个数据集进行筛选,Yelp 只使用 2019 年的所有数据,Industrial 使用最近一个月的数据。对于所有数据集将所有用户按照 8:2 的比例进行划分,分别构建训练集和测试集。训练集中,针对每一个正样本,从所有物品中随机选取两个用户未交互过的物品作为负例;测试集中,本文利用测试用户的前 80% 历史行为去预测后 20% 的行为,随机选取 50 个负样本与用户后 20% 的行为组成该用户的测试集。实验中,本文设置用户、物品和属性信息的嵌入维度均为 16,批次大小设置为 256,学习率为 0.001,采用 Adam 优化器进行优化。用户历史交互物品序列和物品属性序列长度均设置为 25。

## 4.2 实验结果及分析

### 4.2.1 不同模型结果对比分析

MAIF-SR 对比不同模型的结果如表 2 所列,可以看到,MAIF-SR 的 AUC 和 NDCG 指标在 3 个数据集上都优于其他所有对比模型。

首先,基于属性信息融合的推荐 FDSA,NOVA,DIF 和 MAIF-SR 在 3 个数据集上的结果都比传统序列推荐 SASRec 要好,其中 MAIF-SR 在 Movie 数据集上相比 SASRec 提升最

明显,在 AUC, NDCG@10 和 NDCG@20 指标上分别有 2.43%, 7.33% 和 3.32% 的提升,说明了解耦并单独融合物品属性信息可以有效提升序列推荐的推荐性能。

其次,MAIF-SR 在 3 个数据集上的所有指标均优于 FD-SA。其中在 Movie 数据集上 AUC, NDCG@10 和 NDCG@20 指标分别有 1.01%, 5.22% 和 3.21% 的提升。这说明 FD-SA 只建模一个属性偏好向量不足以充分表达用户对物品属性的偏好,而 MAIF-SR 在多空间下建模用户对不同属性的偏好能更充分地表达用户偏好。

最后,MAIF-SR 在各个数据集上的指标均优于 NOVA 和 DIF,且相比基于属性信息融合的序列推荐模型中最好的 DIF,在 Yelp 数据集上的 AUC, NDCG@10 和 NDCG@20 指标分别有 0.51%, 1.10% 和 0.69% 的提升。这说明物品属性序列相比参与物品序列的融合,其被独立地显示融合并直接参与目标的预测,对提升推荐的性能有更好的效果。

表 2 不同模型在不同数据集上的表现对比

Table 2 Performance comparison between different models on different datasets

数据集	评估指标	SASRec	FDSA	NOVA	DIF	MAIF-SR
Movie	AUC	0.6190	0.6277	0.6309	<u>0.6312</u>	<b>0.6341</b>
	NDCG@10	0.3285	0.3351	0.3378	<u>0.3475</u>	<b>0.3526</b>
	NDCG@20	0.3697	0.3701	0.3727	0.3782	<b>0.3820</b>
Yelp	AUC	0.7278	0.7349	<u>0.7374</u>	0.7363	<b>0.7401</b>
	NDCG@10	0.3150	0.3250	0.3290	0.3260	<b>0.3296</b>
	NDCG@20	0.3634	0.3694	<u>0.3728</u>	0.3727	<b>0.3753</b>
Industrial	AUC	0.7185	0.7242	0.7255	<u>0.7260</u>	<b>0.7272</b>
	NDCG@10	0.5012	0.5088	0.5097	<u>0.5110</u>	<b>0.5119</b>
	NDCG@20	0.5998	0.6037	0.6051	<u>0.6064</u>	<b>0.6076</b>

注:最优结果用加粗方式标记,次优结果用下划线标记。

### 4.2.2 消融实验

为了验证本文提出的 MAIF-SR 中的两个重要设计,即个性化属性注意力机制和多空间属性信息融合对模型的影响,本节在 3 个数据集上进行了 MAIF-SR 消融实验,即 MAIF-SR 去掉任何一个设计形成一个新的模型并与原模型进行比较,设定 MAIF-SR 为包含全部两个设计的完整模型,MAIF-SR/PAIA 为 MAIF-SR 去除个性化属性注意力机制(Personalized Attribute Information Attention),MAIF-SR/MAIF 为 MAIF-SR 去除多空间属性信息融合(Multi-space Attribute Information Fusion),评价指标采用 AUC 和 NDCG@10。实验结果如表 3 所列。首先,MAIF-SR 去除任何一个设计在 3 个数据集上指标都有所下降,说明个性化属性注意力机制和多空间属性信息融合单独加在推荐模型上都有利于提升模型性能,并且在所有数据集上 MAIF-SR 指标最优,说明两个设计相结合效果更好。其次,MAIF-SR 去除多空间属性信息融合后,在 3 个数据集上的指标下降比去除个性化属性注意力机制更明显,其中在 Movie 数据集上下降最明显,相比 MAIF-SR 在 AUC 和 NDCG@10 指标上分别下降了 1.14% 和 4.53%,说明多空间属性信息融合相比个性化注意力机制对推荐性能的提升更明显。最后通过对比 3 个数据集发现,去除个性化属性注意力机制后,模型在 Movie 数据集上的指标下降得最明显,相比 MAIF-SR 在 AUC 和 NDCG@10 指标上分别有 0.60% 和 3.34% 的下降,说明用户的个性

化信息在进行电影推荐时作用更明显。

表3 消融实验结果

Table 3 Results of ablation experiment

数据集	模型	AUC	NDCG@10
Movie	MAIF-SR	<b>0.6341</b>	<b>0.3526</b>
	MAIF-SR/PAIA	0.6303	0.3412
	MAIF-SR/MAIF	0.6269	0.3373
Yelp	MAIF-SR	<b>0.7401</b>	<b>0.3296</b>
	MAIF-SR/PAIA	0.7360	0.3250
	MAIF-SR/MAIF	0.7337	0.3132
Industrial	MAIF-SR	<b>0.7272</b>	<b>0.5119</b>
	MAIF-SR/PAIA	0.7258	0.5096
	MAIF-SR/MAIF	0.7227	0.5057

注:最优结果加粗标记

#### 4.2.3 不同属性信息融合方式对比

为了验证本文设计的基于个性化属性注意力机制的多空间信息融合方式的先进性,本节在3个数据集上对比了业界流行的对序列中所有物品属性表示用可学习权重加权聚合的 vanilla attention<sup>[24]</sup>,对序列中所有物品属性表示加和取平均的 mean pooling<sup>[25]</sup>,对序列中所有物品属性表示求和的 sum pooling<sup>[26]</sup>以及本文的利用个性化属性注意力机制 personalized attribute information attention (PAIA)在多个属性空间对序列中的物品表示进行个性化融合这4种物品属性信息融合方式,AUC和NDCG@10的结果分别如图2和图3所示。可以看出,本文提出的基于个性化属性注意力的信息融合方式的AUC和NDCG指标在3个数据集上均优于其他所有属性信息融合方式,其中在Yelp数据集上的优势最明显,AUC,NDCG@10指标分别比次优的vanilla attention提升0.70%和1.41%。这说明相比对序列中物品属性信息直接相加融合、取平均融合和加权融合,在不同属性空间下利用空间信息和用户个性化信息去进行属性信息融合能更好地表达用户对属性的偏好。




图2 不同属性信息融合方式在不同数据集上的AUC表现

Fig. 2 AUC performance of different attribute information fusion methods on different datasets




图3 不同属性信息融合方式在不同数据集上的NDCG@10表现

Fig. 3 NDCG@10 performance of different attribute information fusion methods on different datasets

#### 4.2.4 属性偏好向量数量对MAIF-SR的影响

为了验证本文设计的基于个性化属性注意力机制的多空间属性信息融合方法中生成的偏好向量数量对推荐性能的影响,本文统计了3个数据集的物品属性域,然后进行了区间[1,4]的属性偏好向量数量的实验,AUC和NDCG的结果如图4和图5所示。可以看到,随着属性偏好数量的增加,AUC和NDCG在3个数据集上的结果也一直上升,其中属性偏好数量在区间[1,3]上增加时AUC和NDCG指标增幅较为明显,说明增加不同属性的偏好向量可以更充分地表达用户偏好,提升推荐性能。属性偏好数量在达到区间[3,4]后增幅开始变缓,这说明当属性偏好增加到一定数量后,新增加的属性偏好对于目标的预测作用变小,AUC和NDCG指标的增幅也相应减小。




图4 不同属性偏好数量的MAIF-SR在不同数据集上的AUC表现

Fig. 4 AUC performance of MAIF-SR with different attribute information preference vectors on different datasets




图5 不同属性偏好数量的MAIF-SR在不同数据集上的NDCG@10表现

Fig. 5 NDCG@10 performance of MAIF-SR with different attribute information preference vectors on different datasets

**结束语** 针对目前基于属性信息融合的序列推荐工作中,融合的属性信息无法充分表达用户偏好以及属性信息融合过程中未考虑用户个性化信息的影响的不足,本文提出了基于多空间属性信息融合的序列推荐,在不同属性空间下融合物品属性信息并显式地建模用户偏好,用多维兴趣充分地表达用户对物品属性的偏好。同时,在属性信息融合时引入用户个性化信息,提升了融合信息的个性化效果。在一个工业数据集和两个公开数据集上的实验结果证明,本文提出的MAIF-SR优于业界最先进的基于属性信息融合的序列推荐。

#### 参考文献

- [1] YU F, LIU Q, WU S, et al. A dynamic recurrent model for next basket recommendation[C]// Proceedings of the 39th Interna-

- tional ACM SIGIR Conference on Research and Development in Information Retrieval. 2016;729-732.
- [2] LIU Q, WU S, WANG D, et al. Context-aware sequential recommendation[C] // 2016 IEEE 16th International Conference on Data Mining(ICDM). IEEE, 2016;1053-1058.
- [3] WU Q, GAO Y, GAO X, et al. Dual sequential prediction models linking sequential recommendation and information dissemination[C] // Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2019;447-457.
- [4] KANG W C, MCAULEY J. Self-attentive sequential recommendation[C] // 2018 IEEE International Conference on Data Mining(ICDM). IEEE, 2018;197-206.
- [5] XIN X, HE X, ZHANG Y, et al. Relational collaborative filtering: Modeling multiple item relations for recommendation[C] // Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. 2019;125-134.
- [6] ZHANG T, ZHAO P, LIU Y, et al. Feature-level Deeper Self-Attention Network for Sequential Recommendation [C] // IJ-CAI. 2019;4320-4326.
- [7] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. arXiv:1706.03762, 2017.
- [8] ZHOU K, WANG H, ZHAO W X, et al. S3-rec: Self-supervised learning for sequential recommendation with mutual information maximization[C] // Proceedings of the 29th ACM International Conference on Information & Knowledge Management. 2020;1893-1902.
- [9] LIU C, LI X, CAI G, et al. Noninvasive self-attention for side information fusion in sequential recommendation [C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2021;4249-4256.
- [10] XIE Y, ZHOU P, KIM S. Decoupled side information fusion for sequential recommendation[C] // Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2022;1611-1621.
- [11] HE R N, MCAULEY J. Fusing similarity models with markov chains for sparse sequential recommendation [C] // 2016 IEEE 16th International Conference on Data Mining (ICDM). IEEE, 2016;191-200.
- [12] KABBUR S, NING X, KARYPIS G. Fism: factored item similarity models for top-n recommender systems[C] // Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2013;659-667.
- [13] TANG J, WANG K. Personalized top-n sequential recommendation via convolutional sequence embedding[C] // Proceedings of the eleventh ACM International Conference on Web Search and Data Mining. 2018;565-573.
- [14] YUAN F, KARATZOGLOU A, ARAPAKIS I, et al. A simple convolutional generative network for next item recommendation [C] // Proceedings of the Twelfth ACM International Conference on Web Search and Data Mining. 2019;582-590.
- [15] QUADRANA M, KARATZOGLOU A, HIDASI B, et al. Personalizing session-based recommendations with hierarchical recurrent neural networks[C] // Proceedings of the Eleventh ACM Conference on Recommender Systems. 2017;130-137.
- [16] YAN A, CHENG S, KANG W C, et al. CosRec: 2D convolutional neural networks for sequential recommendation[C] // Proceedings of the 28th ACM International Conference on Information and Knowledge Management. 2019;2173-2176.
- [17] ZHENG L, FAN Z, LU C T, et al. Gated spectral units: Modeling co-evolving patterns for sequential recommendation[C] // Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. 2019;1077-1080.
- [18] CHANG J, GAO C, ZHENG Y, et al. Sequential recommendation with graph neural networks[C] // Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2021;378-387.
- [19] SUN F, LIU J, WU J, et al. BERT4Rec: Sequential recommendation with bidirectional encoder representations from transformer [C] // Proceedings of the 28th ACM International Conference on Information and Knowledge Management. 2019;1441-1450.
- [20] WU L, LI S, HSIEH C J, et al. SSE-PT: Sequential recommendation via personalized transformer [C] // Proceedings of the 14th ACM Conference on Recommender Systems. 2020;328-337.
- [21] LIN J, PAN W, MING Z. FISSA: fusing item similarity models with self-attention networks for sequential recommendation [C] // Proceedings of the 14th ACM Conference on Recommender Systems. 2020;130-139.
- [22] FAN X, LIU Z, LIAN J, et al. Lighter and better: low-rank decomposed self-attention networks for next-item recommendation [C] // Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2021;1733-1737.
- [23] ZHOU G, ZHU X, SONG C, et al. Deep interest network for click-through rate prediction[C] // Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2018;1059-1068.
- [24] ZHOU C, BAI J, SONG J, et al. Atrank: An attention-based user behavior modeling framework for recommendation [C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2018;32(1).
- [25] COVINGTON P, ADAMS J, SARGIN E. Deep neural networks for youtube recommendations [C] // Proceedings of the 10th ACM Conference on Recommender Systems. 2016;191-198.
- [26] ZHOU G, BIAN W, WU K, et al. Can: Revisiting feature co-action for click-through rate prediction [J]. arXiv: 2011.05625, 2020.



**WANG Zihong**, born in 1998, postgraduate, is a student member of CCF (No. P2491G). His main research interest is recommender system.



**SHAO Yingxia**, born in 1988, Ph.D. associate professor, is a senior member of CCF (No. 17559S). His main research interests include large-scale graph analysis, parallel computing framework, and graph learning.