

# 基于跨域元学习框架的冷启动用户表示学习方法

刘玉芳,王绍卿\*,郑顺,张丽杰,孙福振

(山东理工大学计算机科学与技术学院,山东 淄博 255000)

**摘要:**为解决跨域推荐方法过度依赖重叠用户、在冷启动场景中由于数据稀疏导致泛化能力差两个问题,利用元学习快速适应数据稀疏任务的优势,提出一个基于跨域元学习框架的冷启动用户表示学习方法。设计一个多级注意力融合机制,门控循环单元(gate recurrent unit, GRU)获取用户的短期偏好,多级特征注意力融合源域中用户的长短期偏好,获取用户的广义表示。设计一个元网络训练映射函数的初始化参数,将用户在源域中的偏好转移到目标域,获得冷启动用户在目标域中的初始嵌入表示,并以此进行推荐,取得较好结果。利用亚马逊数据集构建了3个跨域推荐任务并进行广泛试验,试验结果表明,本研究模型在平均绝对误差和均方根误差评价中均优于其他基线模型。

**关键词:**跨域推荐;冷启动推荐;元学习;长短期偏好;多级注意力

**中图分类号:**TP399

**文献标志码:**A

**引用格式:**刘玉芳,王绍卿,郑顺,等.基于跨域元学习框架的冷启动用户表示学习方法[J].山东大学学报(工学版),2024,54(6):29-37.

LIU Yufang, WANG Shaoqing, ZHENG Shun, et al. Cold-start user representation learning method based on cross-domain meta-learning framework[J]. Journal of Shandong University (Engineering Science), 2024, 54(6):29-37.

## Cold-start user representation learning method based on cross-domain meta-learning framework

LIU Yufang, WANG Shaoqing\*, ZHENG Shun, ZHANG Lijie, SUN Fuzhen

(School of Computer Science and Technology, Shandong University of Technology, Zibo 255000, Shandong, China)

**Abstract:** To solve the two problems of over-reliance on overlapping users and poor generalization ability due to data sparsity in cold-start scenarios, which existed in cross-domain recommendation methods, and took advantage of meta-learning's ability to quickly adapt to data-sparse tasks, a cold-start user representation learning method based on a cross-domain meta-learning framework was proposed. A multi-level attention fusion mechanism was first designed, where the gate recurrent unit extracted the user's short-term preferences and the multi-level feature attention fused the user's long short-term preferences in the source domain to obtain the user's generalized representation. A meta-network was designed to train the initialization parameters of the mapping function to transfer the user's preferences in the source domain to the target domain to obtain the initial embedded representation of the cold-start user in the target domain and used it to make a recommendation to achieve better results. Three cross-domain recommendation tasks were constructed using the Amazon dataset, and extensive experiments were conducted, the test results indicated that the model in this study outperformed other baseline models in terms of both mean absolute error and root mean square error evaluations.

**Keywords:** cross-domain recommendation; cold-start recommendation; meta-learning; long short-term preference; multi-level attention

## 0 引言

随着信息数量的急剧增加,推荐系统成为一个

重要的信息过滤工具,通过学习用户的个性化兴趣帮助他们发现可能感兴趣的产品和服务,从而缓解信息过载问题。协同过滤和基于深度学习的模型是较有效的推荐方法,二者根据用户最近和长期的

收稿日期:2023-05-19

基金项目:山东省自然科学基金资助项目(ZR2020MF147, ZR2021MF017);山东省高等学校青创科技计划创新团队基金资助项目(2021KJ031)

第一作者简介:刘玉芳(1998—),女,河南周口人,硕士研究生,主要研究方向为推荐系统。E-mail: liuyf0820@163.com

\*通信作者简介:王绍卿(1981—),男,山东聊城人,副教授,硕士生导师,博士,主要研究方向为推荐系统。E-mail: wsq0533@163.com

行为估计用户购买商品的可能性<sup>[1-2]</sup>。然而,新用户交互数据通常非常稀疏,这导致冷启动场景<sup>[3]</sup>。用户冷启动问题是指一些用户的历史数据很少或根本没有,导致很难做出令人满意的推荐。跨域推荐(cross-domain recommendation, CDR)是解决冷启动问题的一个很有前景的解决方案<sup>[4]</sup>。最近关于跨域推荐的研究侧重于从不同角度对用户和项目信息进行迁移学习。例如,通过学习出现在两个域中的用户行为,提出了利用映射函数将用户表示从一个域映射到另一个域<sup>[5]</sup>。然而,这种方法假设所有用户在源域和目标域之间共享相同的关系,并学习所有用户共享的映射函数。在实际场景中,源域和目标域的用户偏好之间的关系复杂多变,单个映射函数很难准确捕获所有用户关系。为了缓解这一问题,使用个性化的映射函数建模不同域中用户偏好之间的复杂关系。此外,在跨域推荐中,部分用户与多个域有交互,这部分用户称为重叠用户<sup>[6]</sup>。现有的主流方法都遵循嵌入映射方案,使用重叠用户的数据训练映射函数<sup>[7]</sup>。具体来说,这类方法通过潜在因子方式分别为两个域训练模型:首先,训练一个映射函数;其次,将冷启动用户在源域的嵌入映射到目标域;最后,用于推荐任务<sup>[8]</sup>。

在冷启动场景下,稀缺的重叠用户会影响映射函数的性能,导致泛化能力不足,降低了模型在目标域上冷启动用户的性能。元学习通过在大量相似的训练任务上训练模型,能够提高模型的泛化能力<sup>[9]</sup>。考虑到用户过去时间段内的顺序交互动态表示,同时利用元学习的优势,提出一个基于跨域元学习框架的冷启动用户表示学习方法。具体来说,采用门控循环单元(gate recurrent unit, GRU)提取源域中用户的长短期偏好,构建多层次的特征注意力机制,用于独立学习长期特征和短期特征的权重,通过对这些特征进行加权求和,可以构建用户的兴趣表示。为了迁移用户偏好,训练一个元网络,将源域中的用户嵌入输入到元网络生成的映射函数中,得到转换后的用户嵌入。将其用作目标域中的初始嵌入。通过初始嵌入,该方法对于在目标域中没有交互的冷启动用户是有效的。

## 1 相关工作

### 1.1 跨域推荐

跨域推荐为数据稀疏性和冷启动挑战提供了一个有效的解决方案。跨域推荐基本思路是利用数据丰富的源域(source domain)数据提升稀疏的

目标域(target domain)的推荐精度<sup>[10]</sup>。现有跨域推荐方法中,多数采用的是基于协同过滤的推荐方法。随着迁移学习技术兴起,基于迁移学习的跨域推荐为解决该类问题提供了可能。面向知识迁移的跨域推荐算法通过引入与目标域密切相关的辅助知识,优化目标域内的推荐效果。近年来,研究人员一直致力于利用递归神经网络(recursive neural network, RNN)和注意力机制解决推荐问题。文献[11]学习重叠用户上的映射函数,用于跨域映射用户偏好。文献[12]以重叠用户作为锚点,通过半监督学习、 $k$ 近邻聚类等方法计算冷启动用户的偏好特征实现跨域推荐。文献[13]通过一种潜在正交映射方法提取用户在多个域上的偏好,同时保留了在不同潜在空间上用户之间的关系。与多任务方法<sup>[14]</sup>类似,这些方法侧重于提出一个设计良好的深层结构,显式建模不同域之间知识迁移的框架,而不是采用特殊的深层结构隐式转移知识。

### 1.2 冷启动推荐

协同过滤在推荐系统中取得了相当大成功,但在处理冷启动用户时性能不佳<sup>[15]</sup>。传统的冷启动解决方案利用辅助信息进行数据增强,一定程度缓解了冷启动问题。文献[16]整合了来自不同模态的用户信息,并在决策级别上结合各种网络,对各个数据源的组合进行处理。文献[17]使用全局交互过的用户特征作为输入,生成一个偏移函数,加强物品表示。文献[18]充分利用四元数空间模拟用户的长期和短期偏好,通过一种基于QUaternion的自注意力编码学习用户的长短期兴趣。文献[19]充分利用辅助域信息,将原始用户嵌入划分为用户域不变和域特定特征,然后利用多层注意力机制动态学习单个特征的注意力得分确定它们对最终个性化用户偏好嵌入的贡献。

### 1.3 元学习

近年来,元学习已经逐渐应用到推荐系统中<sup>[20]</sup>。元学习的灵感来自于人类的学习过程,可以基于少量例子快速学习新的任务。基于度量的方法在任务上学习度量或距离函数<sup>[21]</sup>。基于模型的方法旨在设计一个架构或训练过程,用于跨任务的快速泛化<sup>[22]</sup>。文献[23]提出了一种元增强技术,通过为用户-项目对生成合理的评分增加数据量,有效缓解元过拟合问题。而基于优化的元学习直接调整优化算法,使其能够实现快速适应<sup>[24]</sup>。文献[25]通过元转移模块连接不同的网络,并设计了一种训练策略分层更新模型参数。基于优化的元学习算法对每个任务使用支持集和查询集两个集合。

支持集和查询集分别用于计算每个任务上的训练损失和测试损失。在局部更新过程中,算法调整每个支持集中模型的参数(学习过程)。在全局更新过程中,该算法训练该参数,通过在查询集上最小化自适应参数的损失训练参数(从学习到学习的过程)。当学习-学习过程达到之前任务的终止条件时,该算法只接受新任务的支持集。使用支持集,该模型可以适应新的任务<sup>[26]</sup>。

尽管异构图神经网络(heterogeneous graph neural networks, HGNN)基于对抗学习的推荐方法在解决冷启动问题方面具有一定优势,但也存在一些弊端。HGNN 通过异构图编码所有节点和边,内部结构复杂,导致更高的计算成本和较低的可解释性。基于对抗学习的推荐方法通过生成器和判别器之间的博弈过程学习用户兴趣,但这个过程通常会导致模型收敛性不稳定,而且需要大量对抗样本进行训练,耗费更多计算资源和时间更新模型。基于元网络的跨域推荐相较于异构图神经网络和基于对抗学习的方法,其优势在于利用元学习思想,通过在源域上学习通用的知识和模型参数,实现更好的知识迁移,从而有效解决跨域推荐中的数据稀疏和冷启动问题。元网络能够快速适应新的目标领域,减少对目标领域数据的依赖,同时能够灵活地学习源领域和目标领域之间的映射关系,提高了推荐效果和推荐系统的泛化能力。

## 2 模型

### 2.1 符号定义

本研究的 CDR 问题,包含一个源域  $s$  和一个目标域  $t$ 。设  $U^d = \{u_1^d, u_2^d, \dots\}$ 、 $V^d = \{v_1^d, v_2^d, \dots\}$  和  $R$  分别表示用户集、项目集和评分矩阵。 $u_i^d \in \mathbf{R}^k$  和  $v_j^d \in$

$\mathbf{R}^k$  分别表示用户  $u_i$  和项目  $v_j$  的嵌入, $k$  为嵌入的维数。 $r_{ij} \in \mathbf{R}$  表示用户  $u_i$  和项目  $v_j$  之间的交互情况。重叠用户定义为  $U = U^s \cap U^t$ ,  $U^s$  为源域中的用户集,  $U^t$  为目标域中的用户集。 $V^s$  为源域中的项目集,  $V^t$  为目标域中的项目集,对于项目而言,  $V^s$  和  $V^t$  是不相交的,这意味着两个域之间不存在重叠项目。

使用嵌入方法将用户和项目转换为低维稠密向量。用  $S_u = \{v_{t_1}^s, v_{t_2}^s, \dots, v_{t_n}^s\}$  表示用户  $u_i$  按时间顺序交互的项目列表,  $v_{t_n}^s$  是用户在  $t_n$  时刻交互的项目,  $|S_u|$  表示用户行为序列中的行为数。本研究的任务属于基于嵌入的用户建模范畴,即给定  $S_u$ , 将生成一个稠密的向量  $p_u$ , 编码用户的偏好,并可预测对目标域项目的偏好得分(与其他丰富的特征一起)。

### 2.2 总体框架

本研究提出的 CDR 模型框架,结合用户的长期(静态)和短期(动态)偏好进行下一个项目的推荐<sup>[27]</sup>,分为广义用户表示提取阶段和元学习阶段两个阶段。前者学习可转移的用户个性化偏好,后者通过设计的元网络得到个性化的映射函数。然后,将用户在源域中的偏好嵌入转换到目标域以实现下一个项目推荐任务的跨域协作。

模型的整体架构如图 1 所示。GRU 将长期行为序列作为输入,提取用户的短期偏好。利用一种分离用户特征的多层次注意力结构融合长短期特征获得用户广义表示,通过动态学习权重因子确定长期特征和短期特征对最终的个性化偏好嵌入的贡献。为了捕获源域和目标域的不同用户偏好之间复杂的关系,设计一个元网络,该网络将用户在源域中的特征嵌入作为输入,并为每个用户生成个性化的映射函数。经过训练后,将源域中的用户嵌入输入到映射函数中,得到转换后的用户嵌入。转换后的用户嵌入被用作目标域中的初始嵌入。

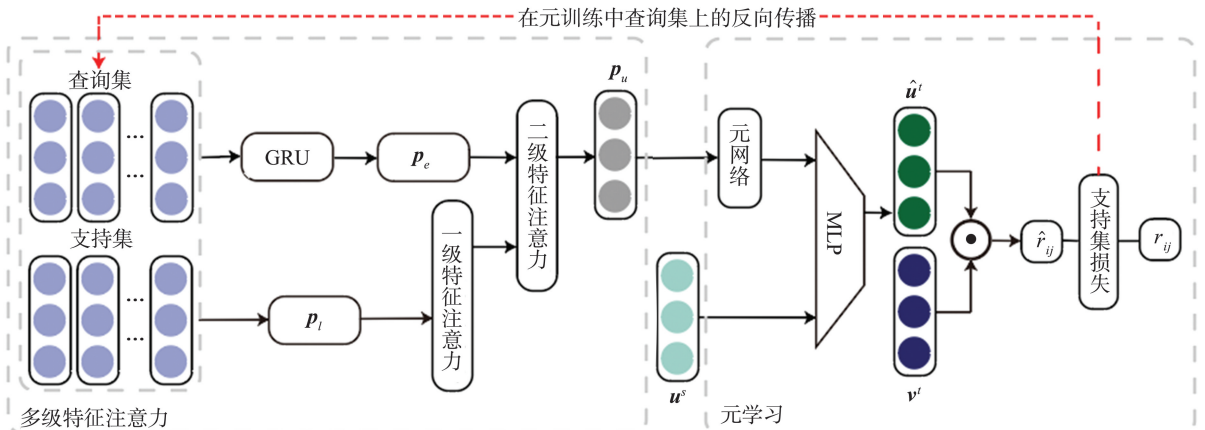


图 1 基于元学习的多级特征提取模型图

Fig.1 Diagram of multi-level feature extraction model based on meta-learning

### 2.3 广义用户表示提取阶段

为了捕获用户的个性化偏好,将该模块中的用户序列嵌入分解为长期和短期特征向量。推荐系统不仅可以提取用户稳定的长期序列,还可以从中挖掘动态的短期偏好。将用户长期序列作为输入,通过 GRU 门控捕捉用户的短期偏好。为了融合用户的长短期偏好,设计了一种新的针对分离用户特征的多层次注意力结构,通过动态学习权重因子确定用户长期特征和短期特征对最终个性化偏好嵌入的贡献。

#### 2.3.1 长短期用户表示学习

近年来,循环神经网络(recurrent neural network, RNN)在序列用户建模方面的卓越表现,在学术界和工业界引起了极大的关注。序列更新过程

$$h_k = g(x_k W + h_{k-1} U + d),$$

式中, $g$ 为激活函数, $x_k$ 为用户的交互序列, $h_{k-1}$ 为最后一个隐藏状态, $W$ 为权重参数, $d$ 为可学习参数。

在所有基于 RNN 的模型中,长短期记忆(long short-term memory, LSTM)和门控循环单元最常用于推荐系统中<sup>[28]</sup>。相比于 LSTM, GRU 内部少了一个门控,参数比 LSTM 少,但是能够达到与 LSTM 相当的功能,并且相比之下更容易进行训练,能够很大程度提高训练效率,因此将 GRU 应用于其历史交互序列来提取用户短期偏好,其公式为:

$$r_i = \sigma(W_r \cdot [h_{i-1}, S_u]),$$

$$z_i = \sigma(W_z \cdot [h_{i-1}, S_u]),$$

$$\tilde{h}_i = \tanh(W_h \cdot [r_i \otimes h_{i-1}, S_u]),$$

$$h_i = (1 - z_i) \otimes h_{i-1} + z_i \otimes \tilde{h}_i,$$

式中: $r_i, z_i \in \mathbf{R}^d$ 分别为控制过去和现在信息的门, $W_r, W_z, W_h \in \mathbf{R}^{d \times (d+1)}$ 为可学习的权重, $\sigma(\cdot)$ 为 sigmoid 函数, $[\cdot]$ 为连接, $\otimes$ 为 element-wise 乘法, $\tilde{h}_i$ 是通过遗忘门之后的用户表示, $h_{i-1}$ 是隐藏状态,初始隐藏状态  $h_0$  为零初始化。

通过 GRU 提取的用户短期偏好  $p_e$  利用输出的隐藏层状态  $h_i$  通过线性变换得到

$$p_e = W_1 h_i + b,$$

式中  $W_1 \in \mathbf{R}^d$  和  $b \in \mathbf{R}^d$  为可学习的参数。

由于长期偏好是固有的、静态的,直接利用用户交互的项目序列嵌入作为用户的长期偏好

$$p_l = E_{\text{mbed}}(v_{i_1}^s, v_{i_2}^s, \dots, v_{i_n}^s),$$

式中: $v_{i_1}^s, v_{i_2}^s, \dots, v_{i_n}^s$ 为用户  $u_i$  按时间顺序交互的项目列表。

#### 2.3.2 长短期的偏好融合

用户的长期和短期偏好嵌入反映了信息的不同方面,维度也不完全相同,不能简单使用加权求

和融合。基于注意力的模型不仅可以捕获不同成分之间的关系,还可以选择性构建特征强调关键信息,削弱冗余信息<sup>[29]</sup>。

由于长期偏好和短期偏好对用户表示贡献不一样,首先利用一级注意力机制增强长期特征表示,捕捉关键项目信息;其次应用二级注意力分配不同的权重,从而融合用户表示。一级注意力

$$p'_i = W_1 p_i,$$

式中: $p'_i$ 为一级注意力机制后得到的嵌入, $W_1$ 为动态学习到的权重参数。

长期用户表示对应于长期偏好,而短期用户表示则显示了动态偏好和近期偏好。这两种类型的表示形式是互补的,它们的融合具有更强的表达能力。为了进一步确定跨域长期偏好和短期偏好的比例,利用二级特征注意力帮助做出判断:

$$p_u = W_2 p'_i + W_3 p_e.$$

式中  $P_u$  为用户偏好。

计算长短期偏好的权重参数:

$$W_1 = \exp(h_1^T \text{ReLU}(V_1 p_i) + \varphi_1),$$

$$W_2 = \exp(h_2^T \text{ReLU}(V_2 [p'_i \oplus p_e]) + \varphi_2),$$

$$W_3 = \exp(h_3^T \text{ReLU}(V_3 [p'_i \oplus p_e]) + \varphi_3),$$

式中, $V_1, V_2, V_3 \in \mathbf{R}^{D_h \times D_{p_i}}$ 为实现维度映射的矩阵参数, $h_1, h_2, h_3 \in \mathbf{R}^{D_i}$ 为向量参数, $\varphi_1, \varphi_2, \varphi_3$ 为标量参数,ReLU 为激活函数。

### 2.4 元学习阶段

用户之间的偏好关系因个体而异,因此在偏好转移过程中需要考虑个性化因素。直觉上,用户的偏好关系与其特征之间存在一定联系。为了解决这个问题,提出了一个元网络,用户的可转移特征为输入,并通过对源域和目标域用户嵌入的训练,得到个性化参数。元网络的个性化参数

$$\gamma = g(p_u; \phi),$$

式中  $g(\cdot)$  采用由  $\phi$  参数化的两层前馈网络。

将训练得到的个性化参数  $\gamma$  作为映射函数  $f(\cdot)$  的初始参数,映射函数可以采用任何结构。多层感知机(multilayer perceptron, MLP)可以学习更复杂的特征,提高训练速度和准确率,还可以在较少数据上进行微调,从而在新的域中获得较好的表现。因此,使用 MLP 构建映射函数进行知识迁移,并将  $\gamma$  作为映射函数的参数而不是输入。生成的映射函数因用户而异,并取决于用户的特征。

将源域中用户的嵌入表示输入到映射函数,得到转换后的用户嵌入表示,将其视为用户在目标域中的初始嵌入。

通过映射函数,可以得到转换后的个性化用户

嵌入

$$\hat{\mathbf{u}}' = M_{LP}(\mathbf{u}^s; \gamma),$$

式中,  $\mathbf{u}^s$  为用户  $u_i$  在源域中的嵌入,  $M_{LP}$  为多层感知机。最后利用  $\hat{\mathbf{u}}'$  进行预测。

## 2.5 训练

基于用户的项目消费历史记录,构建超过 10 组训练任务。每组任务中,在序列中随机选择 10 个项目作为查询集,其余项目作为支持集。通过这种方式,能够根据用户独特的项目消费历史更新元网络的参数,反映用户兴趣。本研究引入了匹配网络概念<sup>[30]</sup>,并且不限制项目消费历史的长度(即支持集的长度可以变化),这与文献[31]中限制序列长度不同。

现有基于映射的方法直接使用转换后的用户嵌入  $\hat{\mathbf{u}}'$  最小化损失<sup>[32-33]</sup>。然而,由于某些冷启动用户的交互项目数量有限,用户嵌入  $\mathbf{u}'$  可能不合理且不准确,这可能对模型产生负面影响。

为了训练元网络和注意力模型,采用面向任务的训练方法,直接使用最终推荐任务的评分作为优化目标。损失函数

$$L_\theta = \frac{1}{|R'_o|} \sum_{r_{ij} \in R'_o} (r_{ij} - \hat{r}_{ij})^2, \quad (1)$$

式中,  $R'_o = \{r_{ij} | u_i \in U^o, v_j \in V\}$  为目标域中重叠用户的交互,  $\hat{r}_{ij}$  为用户  $i$  对项目  $j$  的预测评分,  $r_{ij}$  为用户  $i$  对项目  $j$  的真实评分。

将元网络和多级注意力结构的参数记为  $\theta$ , 即  $\theta = \{\theta^s, \theta^p\}$ 。通过计算  $L_\theta$  的梯度进行梯度下降步骤,得到了一个新的自适应参数:

$$\theta' = \theta - \alpha \frac{\partial L_\theta}{\partial \theta},$$

式中:  $\alpha$  为梯度下降的步长(学习速率),  $\alpha > 0$ 。

现在有了一个新的参数  $\theta'$ , 由划分的支持集进行训练,在查询集上测试自适应的参数  $\theta'$ , 然后通过最小化  $L_{\theta'}$ , 更新  $\theta$ :

$$\theta_1 = \theta - \beta \frac{\partial L_{\theta'}}{\partial \theta},$$

式中,  $\frac{\partial L_{\theta'}}{\partial \theta}$  用式(1)计算,  $\beta$  为全局更新的学习率。

元学习阶段的目的是优化面向任务的模型参数,通过模拟冷启动用户并采取少量的梯度步长,可以最大限度提高现实世界中冷启动用户的行为有效性。最后,得到模型的整体训练算法 1,可以通过小批量的随机梯度下降更新元参数。

### 算法 1 元学习器

输入 超参数  $\alpha, \beta$ , 随机初始参数  $\theta$

输出 模型参数  $\theta$

1. 初始化参数  $\theta$
2. while 不收敛 do
3.     从  $p(B)$  中采样一个用户批次  $B$
4.     For  $B$  中的每个用户  $i$
5.         计算  $\nabla \theta L_i(\mathbf{f}_\theta)$
6.      $\theta'_i = \theta - \alpha \nabla_\theta L_i(\mathbf{f}_\theta)$
7.     End For
8.     更新  $\theta \leftarrow \theta - \beta \nabla_\theta \sum_{i \in B} L_i(\mathbf{f}_{\theta'_i})$
9. End while

## 3 试验

### 3.1 试验设置

#### 3.1.1 数据集

亚马逊评论数据集是被广泛使用的电子商务推荐公共数据集之一<sup>[34]</sup>。本研究采用了 Amazon-5 核心数据集,其中每个用户或项目至少有 5 个评分。该数据集包含 24 个不同的项目域。选择了电影(movies\_and\_tv)、音乐(cds\_and\_vinyl)和书籍(books)3 个流行类别。根据这些选择,定义了 3 个 CDR 任务。任务 1: 电影  $\rightarrow$  音乐; 任务 2: 书籍  $\rightarrow$  电影; 任务 3: 书籍  $\rightarrow$  音乐。表 1 列出了跨域任务信息,如表 1 所示,源域中的评分数量明显多于目标域。与许多现有工作不同的是,直接使用所有数据模拟真实世界应用场景,而不仅仅选择数据集的一部分进行评估。

表 1 跨域任务信息

Table 1 Cross-domain task information

跨域任务	域		项目/个		用户/个		评分		
	源域	目标域	源域	目标域	重叠用户	源域	目标域	源域	目标域
任务 1	电影	音乐	50 052	64 443	18 031	123 960	75 258	1 697 533	1 097 592
任务 2	书籍	电影	367 982	50 052	37 388	603 668	123 960	8 898 041	1 697 533
任务 3	书籍	音乐	367 982	64 443	16 738	603 668	75 258	8 898 041	1 097 592

### 3.1.2 评估指标

Amazon 审查数据集包含评分数据(0~5分)。采用平均绝对误差  $M_{AE}$  和均方根误差  $R_{MSE}$  作为评价指标,计算式为:

$$M_{AE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i|,$$

$$R_{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2},$$

式中,  $n$  为用户数量,  $\hat{y}_i$  为预测值,  $y_i$  为真实值。

### 3.1.3 基线模型

基线模型分为单域和跨域两组。在单域中,将源域和目标域视为单独的域,使用流行的矩阵分解方法进行推荐。在跨域中,利用源域丰富的交互信息缓解冷启动问题。由于基于跨域元学习框架的冷启动用户表示学习方法(cold-start user representation learning method based on cross-domain meta-learning framework, CUCM)是一种基于映射的跨域推荐方法,主要与其他基于映射的方法进行比较。比较方法如下。

- 1) MF: 仅使用目标域数据进行训练。
- 2) CMF<sup>[35]</sup>: 是 MF 的延伸,在 CMF 中,用户的嵌入向量可以跨源域和目标域进行共享。
- 3) SSCDR: 一种基于半监督的桥接的方法。
- 4) DCDCSR: 考虑个体用户在不同域的评分稀疏程度。
- 5) EMCDR: 首先采用矩阵分解学习嵌入,然后利用网络将用户嵌入从辅助域连接到目标域。

6) PTUPCDR<sup>[36]</sup>: 通过使用用户特征嵌入的元网络生成个性化的桥接功能,以实现每个用户的个性化偏好转移。

### 3.1.4 实施细节

使用 PyTorch 实现了提出的框架。对于每个任务和方法,通过在  $\{0.001, 0.005, 0.010, 0.020, 0.100\}$  范围内进行网格搜索调整 Adam<sup>[37]</sup> 优化器的初始学习率,在  $\{900, 1000, 10, 2020, 500\}$  调整随机种子,并将训练次数设置为 10。此外,将嵌入的维度设置为 10,小批量大小设置为 512。为了方便比较 EMCDR、DCDCSR、SSCDR、PTUPCDR 和 CUCM,采用相同的全连接层结构。CUCM 的映射函数由元网络生成,该元网络是一个具有  $2 \times m$  隐藏单元的两层线性模型,其中  $m$  表示嵌入维度,元网络的输出维度为  $m \times m$ ;多层注意力模块采用三层线性模型,嵌入维度为  $m$ 。

为了评估 CUCM 性能,从目标域中随机选择一部分重叠用户作为测试用户,其他重叠用户样本用于训练模型。在试验中,将测试(冷启动)用户  $\varepsilon$  的

比例设置为总重叠用户的 20%、50%、80%。筛选了训练数据中项目消费历史长度在 13 到 100 之间的重叠用户。对于训练数据中的每个重叠用户,随机选择项目序列中的 10 个项目作为查询集,剩余的项目作为支持集,局部更新的次数从 1 次到 5 次。这意味着支持集的长度(即项目消费历史的长度)在 3~90 之间变化,即使长度不是固定的,模型仍然展现出良好的性能。

### 3.2 对比试验

表 2 展示了 CUCM 在 3 个跨域推荐任务上的性能。对于每个任务,进行  $t$  检验并报告了 5 次随机运行的平均结果。

表 2 不同模型在 3 个跨域任务上的性能比较  
Table 2 Performance comparison of different models on three cross-domain tasks

模型	任务 1					
	$M_{AE}$			$R_{MSE}$		
	20%	50%	80%	20%	50%	80%
MF	4.480 3	4.498 9	4.502 0	5.158 0	5.173 6	5.189 1
CMF	1.520 9	1.689 3	2.418 6	2.015 8	2.227 1	3.093 6
DCDCSR	1.491 8	1.814 4	2.7194	1.921 0	2.343 9	3.306 5
SSCDR	1.301 7	1.376 2	1.504 6	1.657 9	1.7477	1.922 9
EMCDR	1.235 0	1.3277	1.500 8	1.551 5	1.6644	1.877 1
PTUPCDR	1.150 4	1.2903	1.557 0	1.519 5	1.7546	2.153 6
CUCM	<b>1.068 7</b>	<b>1.271 0</b>	<b>1.520 3</b>	<b>1.404 2</b>	<b>1.735 1</b>	<b>2.121 1</b>
提升	7.10%	1.50%	2.36%	7.59%	1.11%	1.51%
模型	任务 2					
	$M_{AE}$			$R_{MSE}$		
	20%	50%	80%	20%	50%	80%
MF	4.183 1	4.228 8	4.212 3	4.753 6	4.792 0	4.814 9
CMF	1.363 2	1.581 3	2.157 7	1.791 8	2.088 6	2.677 7
DCDCSR	1.397 1	1.673 1	2.361 8	1.7346	2.055 1	2.770 2
SSCDR	1.239 0	1.213 7	1.317 2	1.652 6	1.560 2	1.702 4
EMCDR	1.116 2	1.183 2	1.315 6	1.412 0	1.498 1	1.643 3
PTUPCDR	1.074 0	1.101 4	1.199 9	1.382 9	1.439 5	1.591 6
CUCM	<b>0.990 0</b>	<b>1.020 4</b>	<b>1.108 4</b>	<b>1.283 5</b>	<b>1.338 8</b>	<b>1.495 1</b>
提升	7.82%	7.36%	7.63%	7.19%	7.00%	6.07%
模型	任务 3					
	$M_{AE}$			$R_{MSE}$		
	20%	50%	80%	20%	50%	80%
MF	4.487 3	4.507 3	4.520 4	5.167 2	5.172 7	5.230 8
CMF	1.828 4	2.128 2	3.013 0	2.382 9	2.727 5	3.694 8
DCDCSR	1.841 1	2.173 6	3.140 5	2.295 5	2.677 1	3.584 2
SSCDR	1.541 4	1.473 9	1.641 4	1.928 3	1.844 1	2.140 3
EMCDR	1.352 4	1.472 3	1.719 1	1.673 7	1.800 0	2.111 9
PTUPCDR	1.262 1	1.434 7	1.755 0	1.694 4	1.930 3	2.388 3
CUCM	<b>1.196 4</b>	<b>1.331 9</b>	<b>1.689 9</b>	<b>1.620 8</b>	<b>1.825 6</b>	<b>2.342 1</b>
提升	5.21%	7.17%	3.71%	4.35%	5.43%	1.94%

注:加粗表示 CUCM 与最佳基线的 0.05 水平配对  $t$  检验,提升表示相对于最佳基线的改善。

由表2可知, MF 是一种只利用目标域数据的单域模型, 其性能并不令人满意。相比之下, 所有其他跨域方法都可以利用源域数据, 从而获得更好的效果。因此, 利用辅助域数据是缓解数据稀疏性、提高目标域推荐性能的有效方法。CMF 将来自不同域的数据组合到单个域中进而利用辅助数据, 而 CDR 方法则专门为域映射设计。在大多数任务中, CDR 方法通常优于 CMF, 这是因为 CMF 将来自两个域的数据视为相同并忽略了域之间的潜在转移。相反地, 映射函数能够将源域嵌入转换到目标域特征空间中, 有效降低了域间转移的影响。因此, 专注于 CDR 方法能够更有效地利用辅助域。通过进行置信度为 95% 的  $t$  检验得知, 在大多数情况下, CUCM 明显优于最佳基线。这表明 CUCM 是一个有效的解决方案, 可以应对冷启动推荐的问题。

### 3.3 消融试验

消融试验进一步探索 CUCM 各个组成部分对性能的影响。评估模型如下。

(1) All: 文中提出的完整模型框架。

(2) -Multi Attention: 用自注意力机制代替模型中的多级特征注意力结构, 并将用户长期序列特征作为自注意力机制的输入。

(3) -MLP: 用桥接函数代替 MLP 映射层, 将源域知识迁移到目标域, 用于推荐。

(4) -Meta: 去掉元学习, 将通过多级注意力结构学习到的用户偏好通过简单的矩阵相乘映射到目标域。

(5) -TOO: 将面向任务的优化损失替换为面向映射的优化过程最小化距离, 利用转换后的用户嵌入  $\hat{u}'$  接近目标嵌入  $u'$ 。

表3展示了引入的变体在3个跨域推荐任务上的消融测试结果。

表3 在3个跨域任务上的消融试验

Table 3 Ablation experiments on three cross-domain tasks

模型	任务 1		任务 2		任务 3	
	$M_{AE}$	$R_{MSE}$	$M_{AE}$	$R_{MSE}$	$M_{AE}$	$R_{MSE}$
All	1.072 1	1.416 3	0.990 0	1.283 5	1.196 4	1.620 8
-Multi Attention	1.090 4	1.434 6	1.007 8	1.309 3	1.201 6	1.651 8
-MLP	1.146 9	1.493 9	1.079 5	1.389 2	1.326 9	1.770 8
-Meta	2.882 7	3.111 9	2.670 6	2.917 5	2.742 5	2.920 9
-TOO	3.428 4	4.008 5	4.553 2	4.954 6	3.440 9	4.048 3

在完整的模型上逐步减去子模块或特征时, 可以观察到整体推荐性能的改善。由表3可知, 相比于自注意力机制, 多层特征注意力能够更细致的捕捉用户兴趣, 减少交互行为中有害信息的影响; 相比

于桥接函数, -MLP 能够学习更复杂的非线性映射关系, 适应更广泛的数据特征, 提高知识迁移的灵活性和效率; -Meta 的性能明显下降, 这证明了元网络的有效性, 从而表明了对个性化映射函数建模的必要性; 面向任务的优化过程能有效地提高基于映射函数方法的性能。

### 3.4 参数试验

在任务1上探索局部更新次数对模型的影响。图2展示了迭代次数对该模型推荐性能的影响。即使在局部更新很少的情况下, 模型在两个指标上都取得了显著的改进。经过单次迭代后, 该方法的  $M_{AE}$  和  $R_{MSE}$  均显著降低。当增加局部更新次数时, 结果略有不同, 这与现有的 MAML<sup>[31]</sup> 结果相反, 其性能随着迭代次数的增加而提高。本研究的模型能够快速适应用户, 这是由于仅仅一次局部更新就足够了。这种快速自适应能力使提出的方法适用于基于用户评分的在线推荐场景。




图2 改变局部更新次数模型在任务1上的  $M_{AE}$  和  $R_{MSE}$

Fig.2  $M_{AE}$  and  $R_{MSE}$  results on task 1 according to the model of changing the number of local updates

## 4 结论

为了在冷启动跨域推荐中更好地转移用户偏好, 引入元学习方法。针对每个用户的历史交互项目, 使用元网络为模型训练一个个性化的元学习参数, 从而实现个性化推荐。本研究学习了一个包含用户特征嵌入的元网络, 得到因用户而异的个性化参数。通过映射函数初始化用户嵌入, 实现用户偏好的个性化转移。在真实数据集上进行了广泛的试验评估模型, 结果验证了该模型在冷启动跨域推荐中的有效性。未来将在元网络的基础上加入对抗学习, 训练更准确的用户迁移函数, 在提高模型泛化能力的同时避免过拟合现象, 以进一步缓解用户冷启动问题。

### 参考文献:

[1] WANG C, YU Y, MA W, et al. Towards representation

- alignment and uniformity in collaborative filtering [C]// Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York, USA: Association for Computing Machinery, 2022: 1816-1825.
- [2] TALWADKER R, CHAKRABARTY S, PAREEK A, et al. CognitionNet: a collaborative neural network for play style discovery in online skill gaming platform [C]// Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York, USA: Association for Computing Machinery, 2022: 3961-3969.
- [3] LI J, JING M, LU K, et al. From zero-shot learning to cold-start recommendation [C]// Proceedings of the Thirty-Third AAAI Conference on Artificial Intelligence. Honolulu, USA: AAAI Press, 2019: 4189-4196.
- [4] ZANG T, ZHU Y, LIU H, et al. A survey on cross-domain recommendation: taxonomies, methods, and future directions [J]. ACM Transactions on Management Information Systems, 2022, 41(2): 1-39.
- [5] WANG Jie, YUAN Fajie, CHENG Mingyue, et al. TransRec: learning transferable recommendation from mixture-of-modality feedback [C]// Proceedings of the 8th International Joint Conference. Jinhua, China: Springer, 2024: 193-208.
- [6] PAN W. A survey of transfer learning for collaborative recommendation with auxiliary data [J]. Neurocomput, 2016, 177(5): 447-453.
- [7] PAN F, LI S, AO X, et al. Warm up cold-start advertisements: improving CTR predictions via learning to learn ID embeddings [C]// Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, USA: Association for Computing Machinery, 2019: 695-704.
- [8] WANG Y, YAO Q, KWOK J. A scalable, adaptive and sound nonconvex regularizer for low-rank matrix learning [C]// Proceedings of the Web Conference 2021. New York, USA: Association for Computing Machinery, 2021: 1798-1808.
- [9] DU Z, WANG X, YANG H, et al. Sequential scenario-specific meta learner for online recommendation [C]// Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York, USA: Association for Computing Machinery, 2019: 2895-2904.
- [10] ZHANG W, ZHANG P, ZHANG B, et al. A collaborative transfer learning framework for cross-domain recommendation [C]// Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. Long Beach, USA: Association for Computing Machinery, 2023: 2306-16425.
- [11] MAN T, SHEN H, JIN X, et al. Cross-domain recommendation: an embedding and mapping approach [C]// Proceedings of the 26th International Joint Conference on Artificial Intelligence. Melbourne, Australia: AAAI Press, 2017: 2464-2470.
- [12] KANG S, HWANG J, LEE D, et al. Semi-supervised learning for cross-domain recommendation to cold-start users [C]// Proceedings of the 28th ACM International Conference on Information and Knowledge Management. Beijing, China: Association for Computing Machinery, 2019: 1563-1572.
- [13] LI P, TUZHILIN A. DDTCDR: deep dual transfer cross domain recommendation [C]// Proceedings of the 13th International Conference on Web Search and Data Mining. New York, USA: Association for Computing Machinery, 2020: 331-339.
- [14] BAI T, XIAO Y, WU B, et al. A contrastive sharing model for multi-task recommendation [C]// Proceedings of the ACM Web Conference. New York, USA: Association for Computing Machinery, 2022: 3239-3247.
- [15] WANG X, HE X, WANG M, et al. Neural graph collaborative filtering [C]// Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. Paris, France: Association for Computing Machinery, 2019: 165-174.
- [16] FARNADI G, TANG J, COCK M D, et al. User profiling through deep multimodal fusion [C]// Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining. New York, USA: Association for Computing Machinery, 2018: 171-179.
- [17] ZHU Y, XIE R, ZHUANG F, et al. Learning to warm up cold item embeddings for cold-start recommendation with meta scaling and shifting networks [C]// Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, USA: Association for Computing Machinery, 2021: 1167-1176.
- [18] TRAN T, YOU D, LEE K. Quaternion-based self-attentive long short-term user preference encoding for recommendation [C]// Proceedings of the 29th ACM International Conference on Information and Knowledge Management. New York, USA: Association for Computing Machinery, 2020: 1455-1464.
- [19] ZHANG X, LI J, SU H, et al. Multi-level attention-based domain disentanglement for bidirectional cross-domain recommendation [J]. ACM Transactions on Management Information Systems, 2023, 41(4): 1046-1070.
- [20] TIMOTHY M, ANTREAS A, PAUL M, et al. Meta-learning in neural networks: a survey [J]. IEEE

- Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(9): 5149-5169.
- [21] LAKE B M. Compositional generalization through meta sequence-to-sequence learning [C]//Proceedings of the 33rd International Conference on Neural Information Processing Systems. New York, USA: Curran Associates Inc., 2019: 9791-9801.
- [22] VUORIO R, SUN S H, HU H, et al. Multimodal model-agnostic meta-learning via task-aware modulation [C]//Proceedings of the 33rd International Conference on Neural Information Processing Systems. New York, USA: Curran Associates Inc., 2019: 1-12.
- [23] XU H, LI C, ZHANG Y, et al. MetaCAR: cross-domain meta-augmentation for content-aware recommendation [J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(8): 8199-8212.
- [24] RAJESWARAN A, FINN C, KAKADE S M, et al. Meta-learning with implicit gradients [C]//Proceedings of the 33rd International Conference on Neural Information Processing Systems. New York, USA: Curran Associates Inc., 2019: 113-124.
- [25] GUAN R, PANG H, GIUNCHIGLIA F, et al. Cross-domain meta-learner for cold-start recommendation [J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(8): 7829-7843.
- [26] LEE H, IM J, IANGS, et al. MeLU: meta-learned user preference estimator for cold-start recommendation [C]//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York, USA: Association for Computing Machinery, 2019: 1073-1082.
- [27] XU M, LIU F, XU W, et al. A survey on sequential recommendation [C]//Proceedings of the 2019 6th International Conference on Information Science and Control Engineering (ICISCE). Shanghai, China: IEEE Computer Society, 2019: 106-111.
- [28] DUAN J, ZHANG P, QIU R, et al. Long short-term enhanced memory for sequential recommendation [J]. World Wide Web, 2023, 26(2): 561-583.
- [29] SHAW P, USZKOREIT J, VASWANI A. Self-attention with relative position representations [C]//Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics. New Orleans, USA: Association for Computational Linguistics, 2018: 464-468.
- [30] CAI Q, PAN Y, YAO T, et al. Memory matching networks for one-shot image recognition [C]//Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: Computer Vision Foundation, 2018: 4080-4088.
- [31] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks [C]//Proceedings of the 34th International Conference on Machine Learning-Volume 70. Sydney, Australia: Journal of Machine Learning Research, 2017: 1126-1135.
- [32] FU W, PENG Z, WANG S, et al. Deeply fusing reviews and contents for cold start users in cross-domain recommendation systems [C]//Proceedings of the Thirty-Third Conference on Artificial Intelligence. Honolulu, USA: AAAI Press, 2019: 94-101.
- [33] ZHU F, WANG Y, CHEN C, et al. A deep framework for cross-domain and cross-system recommendations [C]//Proceedings of the 27th International Joint Conference on Artificial Intelligence. Stockholm, Sweden: AAAI Press, 2018: 3711-3717.
- [34] NI J, LI J, MCAULEY J J. Justifying recommendations using distantly-labeled reviews and fine-grained aspects [C]//Proceedings of the 2019 Conference on Empirical Methods in Natural Language. Hong Kong, China: Association for Computational Linguistics, 2019: 188-197.
- [35] SINGH A P, GORDON G J. Relational learning via collective matrix factorization [C]//Proceedings of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Las Vegas, USA: Association for Computing Machinery, 2008: 650-658.
- [36] ZHU Y, TANG Z, LIU Y, et al. Personalized transfer of user preferences for cross-domain recommendation [C]//Proceedings of the Fifteenth ACM International Conference on Web Search and Data Mining. New York, USA: Association for Computing Machinery, 2022: 1507-1515.
- [37] KINGMA D P, BA J. Adam: a method for stochastic optimization [J/OL]. Computer Science. (2015-05-19) [2022-03-13]. <http://arxiv.org/abs/1412.6980>.

(编辑:李骏)