

# 目标域特征感知与互补用户迁移的跨域推荐模型

段乐乐, 李博一, 丁滋钊, 朱小飞

(重庆理工大学 计算机科学与工程学院, 重庆 400054)

E-mail: zxf@cqut.edu.cn

**摘要:** 冷启动问题一直是推荐系统中十分有挑战性的问题。目前, 基于映射的跨域推荐技术在解决冷启动问题上已取得了十分不错的效果, 其方法主要分为两类, 一类关注共性, 即所有用户共享一个映射函数; 另一类则关注个性, 即为每个用户分别分配个性化的映射函数; 然而, 这两类方法均没有考虑到用户共性与个性的互补性; 此外, 这两类方法也忽视了目标域知识本身的挖掘。为了解决以上问题, 本文提出了目标域特征感知与互补用户迁移的跨域推荐模型。一方面, 提出个性-共性互补映射模块以显式建模用户个性和共性的互补信息, 另一方面, 提出了关系网络以挖掘目标域知识。最后, 在 Amazon 数据集上的实验取得了目前最优的效果, 验证了本文所提出模型的有效性。

**关键词:** 跨域推荐; 冷启动; 推荐系统; 数据稀疏性; 迁移学习

**中图分类号:** TP391

**文献标识码:**

A

## Cross-Domain Recommendation Model Based on Target Domain Feature Awareness and Complementary User Transfer

DUAN Le-le, LI Bo-yi, DING Zi-zhao, ZHU Xiao-fei

(College of Computer Science and Engineering, Chongqing University of Technology, Chongqing 400054, China)

**Abstract:** The cold-start problem has always been a very challenging problem in recommender systems. At present, mapping-based cross-domain recommendation technology has achieved very good results in solving the cold-start problem. The methods are mainly divided into two categories. One focuses on commonality, that is, all users share a mapping function; the other focuses on personality, that is, assign a personalized mapping function to each user; however, these two types of methods do not consider the complementarity of user commonality and personality; in addition, these two types of methods also ignore the mining of target domain knowledge itself. In order to solve the above problems, this paper proposes a cross-domain recommendation model that combines complementary knowledge transfer and target domain feature extraction. On the one hand, a personality-commonality complementary mapping module is proposed to explicitly model the complementary information of user personality and commonality, and on the other hand, a relational network is proposed to mine target domain knowledge. Finally, the experiments on the Amazon dataset have achieved the best results so far, which verifies the effectiveness of the model proposed in this paper.

**Key words:** cross-domain recommendation; cold-start; recommendation system; data sparsity; transfer learning

### 1 引言

推荐系统<sup>[1-2]</sup>被广泛应用于各种各样的商业场合中, 如电子商务系统、社交网络系统等<sup>[1-3]</sup>, 在信息过载问题越来越突出的背景下, 推荐系统因其能从海量的信息中筛选出合适的部分来为用户提供推荐服务而扮演着越来越重要的角色。近年来, 推荐系统的研究工作吸引了大量来自工业界和学术界的科研人员。然而, 大多数的推荐系统模型由于无法很好的解决数据稀疏性问题, 导致系统对于新用户始终无法

提供令人满意的推荐性能。

作为一种十分有效的数据稀疏性问题解决方案, 跨域推荐技术通过将用户信息相对丰富的源域知识迁移到目标领域中来缓解目标领域的数据稀疏性问题。为了更好的将源域的知识迁移到目标领域中去, 现存许多工作<sup>[4-7]</sup>基于“所有用户在源域和目标域中的偏好之间的关系共享”的假设, 在源域和目标域之间为所有用户学习一个公共的映射函数, 以实现将源域中的知识迁移到目标域中去。然而, 这个假设也许是不切实际的, 不同的用户在源域和目标域的偏好的关

收稿日期: 2022-06-10 收修改稿日期: 2022-07-08 基金项目: 国家自然科学基金项目(62141201)资助; 重庆市技术创新与应用发展专项(cstc2020jscx-dxwtBX0014)资助。 作者简介: 段乐乐, 男, 1996年生, 硕士研究生, CCF 学生会员, 研究方向为跨域推荐、自然语言处理; 李博一, 男, 2001年生, CCF 学生会员, 研究方向为自然语言处理; 丁滋钊, 男, 2000年生, 研究方向为自然语言处理; 朱小飞, 男, 1979年生, 博士, 教授, CCF 高级会员, 研究方向为自然语言处理、数据挖掘与信息检索。

系并不完全一致,这种在源域和目标域之间学习一个公共的映射函数来进行知识迁移的方法难以准确反映每一个用户的偏好信息,因此基于这种方式的跨域推荐系统无法反映用户的个性化偏好。对于这个问题,最近,Zhu 等人<sup>[8]</sup>的 PTUPCDR 模型提出了为每一个用户分别提供个性化的映射函数,考虑到了不同的用户的不同的偏好信息,较好的克服了基于公共的映射函数的方法的弊端,实现了更好的跨域推荐性能。

基于公共映射函数的方法<sup>[4-5]</sup>仅仅关注到了用户间的公共属性,缺乏对不同用户个性属性的显式建模;Zhu 等人<sup>[8]</sup>提出的 PTUPCDR 模型虽然考虑到了不同用户的不同的偏好信息,但其基于个性化映射函数的方法仅仅关注了单个用户的个性属性,缺乏了对所有用户的公共的属性的显式建模。因此,不管是基于公共的映射函数的方法还是基于个性化映射函数的方法,对于用户的建模都是有失偏颇的,单独建模任何一个方面都无法使模型性能达到最优,需要同时考虑到用户的公共属性和个性化的属性才能更全面刻画用户信息,达到更优的推荐性能。

除此之外,现有的跨域推荐算法<sup>[3-7]</sup>过多的将研究重点放在了如何将源域的知识更好的迁移到目标域中去,却忽视了对目标域知识本身的探索,忽略了目标域本身的某些信息对解决冷启动问题的作用。这也有可能将导致跨域推荐结果的次优。比如当源域中的某些用户的交互数据本身就不够充足时,学习到的源域知识相对不足,在这种情况下,源域迁移的知识对目标域的冷启动问题的帮助自然十分有限;另外,近年来,用于解决冷启动问题的单域推荐系统的发展也取得了相当的进展,因此,当源域知识相对不足时,目标领域本身的知识对于解决冷启动问题就至关重要。

对于以上问题,本文提出了一个新的跨域推荐模型 CDRTFC(a Cross-Domain Recommendation model based on Target domain Feature awareness and Complementary user Transfer),首先,CDRTFC 学习一个用户公有属性和私有属性互补的映射模块来更全面的迁移用户在源域中的知识;其次,CDRTFC 在目标域中学习一个关系网络来提取目标域的用户特征,最后,CDRTFC 通过互补的映射函数将源域迁移的知识与通过关系网络获得的目标域用户特征进行融合,得到最终的用户表示,最后进行推荐。本文的主要贡献可以总结为以下三个方面:

- 针对现存的基于映射函数的方法存在的“有偏”的问题,提出了个性-共性互补映射模块,实现用户个性与共性属性的互补,更全面刻画用户在目标域的特征。
- 针对现存的跨域推荐方法存在的缺乏对目标域知识的挖掘的不足,提出了用户感知目标域特征抽取模块,以抽取合适的目标域特征,实现更好推荐性能。
- 本文提出的方法在三个跨域推荐任务上均实现了最优的性能证明了本文所提出方法的有效性。

## 2 相关工作

### 2.1 跨域推荐

推荐系统中的冷启动问题长期以来都是十分具有挑战性的问题,是任何一个推荐系统都无法绕开的关键问题。近年来越来越多的研究者致力于推荐系统中冷启动问题的解决,并由此衍生出了各种各样的模型<sup>[9-12]</sup>,其中,在通过充分利用信息相对丰富的源域知识来帮助目标域缓解数据稀疏性和冷启动问题上取得了相当不错的效果。表明了源域知识对于目标域的推荐系统性能的提升的有效性。具体而言,Singh 等人<sup>[13]</sup>提出的 CMF 模型是对矩阵分解模型的扩展,源域和目标域重叠用户共享嵌入表示;Pan 等人<sup>[14]</sup>提出的 CST 模型利用源域预训练好的用户嵌入来初始化目标域的用户嵌入,同时约束共享的用户和商品使其在两个域的嵌入尽可能接近;Hu 等人<sup>[15]</sup>提出的 CoNet 模型在两个领域的结构中交互知识,实现对偶知识迁移;He 等人<sup>[16]</sup>提出的 MINDTL 模型将目标域的信息与从源域的评分矩阵中抽取的评分模式信息相结合进行推荐;Li 等人<sup>[17]</sup>提出的 DDTCDR 模型认为不论是源域和目标域都有各自特定的领域知识,提出了一种新的隐藏正交映射来抽取用户在源域和目标域中的知识,与此同时也保留了用户在不同领域的隐藏空间表示的关系;Man 等人<sup>[5]</sup>提出的 EMCDR 模型通过隐藏因子模型分别学习到源域和目标域的用户和商品嵌入表示,然后在学习到的嵌入表示的基础上利用两个域的公共用户学习一个映射函数,最后利用映射函数将源域用户表示映射到目标域,进行推荐;Zhu 等人<sup>[8]</sup>出的 PTUPCDR 模型利用元学习技术为每个用户分别学习一个映射函数,模型能够充分考虑到每个用户的个性化特征;本文的工作基于 PTUPCDR 模型,指出了 PTUPCDR 缺失了对用户共性特征的建模和对目标域特征本身的挖掘,提出了共性-个性互补映射模块和目标域特征挖掘的用户感知目标域特征抽取模块,并取得了最优的性能。

### 2.2 冷启动推荐

冷启动问题<sup>[18-20]</sup>是推荐系统不可避免的十分具有挑战性的问题,推荐系统主要目标在于解决信息过载的问题,向用户从海量的商品中挑选出用户可能感兴趣的进行推荐,其中涉及到用户和商品两类对象,不论是新商品推荐给合适的用户还是给新用户推荐合适的商品都十分具有挑战性,因为不论是新用户还是新商品,由于缺乏必要的交互数据,对于已有推荐系统来说难以准确刻画用户和商品的特征,导致推荐性能不理想。然而,在当今信息时代,尤其是对于互联网产品来说,新用户、新商品往往是持续产生的,冷启动问题更是常态,伴随着推荐系统运转的整个周期;此外,推荐系统拥有更好的冷启动推荐性能才能吸引更多的新用户,并提升用户粘性,实现更大的效益,因此,如何解决好冷启动问题就成为推荐系统的重中之重。

现有的工作主要利用一些辅助信息来帮助缓解冷启动

问题。对于新用户,可以利用先验数据信息进行推荐,比如给新用户推荐热门商品;也可以利用用户在注册时的信息进行推荐,比如性别、年龄、爱好等<sup>[21-22]</sup>;对于新的商品,可以利用商品本身的属性信息进行推荐,比如商品的品类、用途等描述<sup>[8,23]</sup>;除此之外,近年来,跨域推荐系统<sup>[24-26]</sup>在通过充分利用信息相对丰富的源域<sup>[5]</sup>来帮助目标域缓解冷启动问题上取得了十分不错的效果,越来越受到重视,吸引了越来越多的研究,本文也跟随这一脚步,提出了新的利用辅助域知识来缓解冷启动问题的跨域推荐方法 CDRTFC。

### 3 方法与模型

#### 3.1 问题定义

在跨域推荐系统中,通常包含源和目标两个域,每个域都有各自的用户集合  $U = \{u_1, u_2, \dots, u_{|U|}\}$ 、商品集合  $V = \{v_1, v_2, \dots, v_{|V|}\}$  和对应的评分矩阵  $\mathbf{R} \in \mathbb{R}^{|U| \times |V|}$ , 其中,  $u_i \in U$  表示用户集合中的第  $i$  ( $1 \leq i \leq n$ ) 个用户,  $v_j \in V$  表示商品集合中的第  $j$  ( $1 \leq j \leq m$ ) 个商品,  $r_{ij} \in \mathbb{R}$  表示用户  $u_i$  对商品  $v_j$  的评分。为了区别两个域的不同表示,本文使用上标  $d \in \{s, t\}$  来加以标识。比如,源域的用户、商品和评分矩阵分别表示为  $U^s$ 、 $V^s$  和  $\mathbf{R}^s$ , 目标域的用户、商品和评分矩阵分别表示为  $U^t$ 、 $V^t$  和  $\mathbf{R}^t$ 。此外,由于本文的方法基于两个域的公共用户,定义两个领域的公共用户表示为  $U^o = U^s \cap U^t$ , 因此,后文中不论是个性-共性互补映射函数模块的学习还是用户感知的目标域特征抽取模块的学习都基于公共用户集合  $U^o$ 。与此同时,  $V^s \cap V^t = \emptyset$ , 即在两个不同的领域之间不存在公共的商品。另外,对于跨域推荐系统来说,冷启动

用户表示那些存在于源域中但不存在于目标域中的用户,记为  $U^c = \{u | u \in U^s \text{ and } u \notin U^t\}$ 。跨域推荐的目标是利用源域的评分  $\mathbf{R}^s$  和目标域的评分  $\mathbf{R}^t$  来辅助目标域中的冷启动用户  $u \in U^c$  的推荐。本文所提出的 CDRTFC 模型框架如图 1 所示。

#### 3.2 单域隐藏因子建模

这一阶段,分别利用源域和目标域的评分矩阵信息独立的训练各自的单域推荐模型。对于单域推荐模型来说,最高效的模型莫过于隐藏因子模型<sup>[1-2]</sup>,其中基于深度学习和矩阵分解的模型近年来越来越受到关注并取得了显著的进步。由于本文的重点主要在于讨论跨域推荐的框架,而并不在乎具体的单域建模的模型,因此本文统一使用  $f_\theta$  表示底层的单域推荐模型,其中  $\theta$  为模型的参数,为了对源域与目标域加以区分,本文使用  $f_{\theta^s}$  表示源域推荐模型,  $f_{\theta^t}$  表示目标域推荐模型。在隐藏因子模型中,每一个用户和商品隐藏空间中会被分配一个分布式表示,也称作嵌入向量。本文使用  $\mathbf{u}_i^s \in \mathbb{R}^d$  和  $\mathbf{v}_j^s \in \mathbb{R}^d$  表示源域的第  $i$  个用户和第  $j$  个商品的嵌入向量表示,使用  $\mathbf{u}_i^t \in \mathbb{R}^d$  和  $\mathbf{v}_j^t \in \mathbb{R}^d$  表示目标域的第  $i$  个用户和第  $j$  个商品的嵌入向量表示,其中  $d$  表示向量嵌入维度。对于第  $i$  个用户对第  $j$  个商品的评分的概率可以进行如下的建模:

$$P(r_{ij} | \mathbf{u}_i, \mathbf{v}_j, \sigma^2) = N(r_{ij} | f_\theta(\mathbf{u}_i^T \mathbf{v}_j), \sigma^2) \quad (1)$$

上式表示评分的概率建模以  $f_\theta(\mathbf{u}_i^T \mathbf{v}_j)$  为均值,以  $\sigma^2$  为方差的高斯分布。其中,  $\sigma^2$  为超参数,  $\mathbf{u}_i^T \mathbf{v}_j$  表示嵌入向量  $\mathbf{u}_i$  和  $\mathbf{v}_j$  的内积,  $f_\theta$  的形式取决于具体的隐藏因子模型。

对于模型参数  $\theta$  的优化可通过以下公式进行:

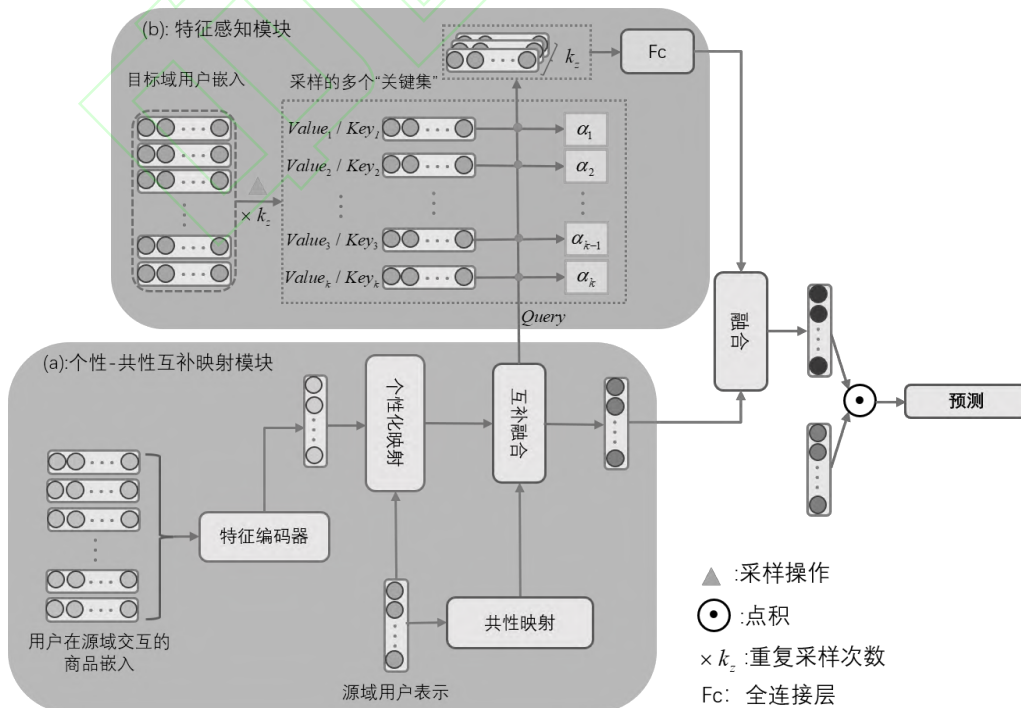


图 1 CDRTFC 模型整体框架图

Fig.1 Overall framework of the CDRTFC model

$$L(\hat{r}_{ij}, r_{ij}) = \frac{1}{|\mathbf{R}|} \sum_{r_{ij} \in \mathbf{R}} (\hat{r}_{ij} - r_{ij})^2 \quad (2)$$

其中,  $\hat{r}_{ij} = f_{\theta}(\mathbf{u}_i^T \mathbf{v}_j)$ , 表示模型预测评分,  $r_{ij}$  表示真实评分。通过以上公式分别在源域和目标域训练各自的单域推荐模型。

### 3.3 个性-共性互补映射

基于公共映射函数的方法仅仅关注到了用户间的公共属性, 缺乏对不同用户个性的属性的显式建模; 而基于个性化映射函数的方法仅仅关注了单个用户的个性化属性, 缺乏了对所有用户的公共属性的显式建模。因此, 不论单独对个性还是共性进行建模, 都有可能导导致结果次优, 而将两者结合起来, 相互补充进行建模, 更有可能取得更好的结果, 基于此, 本文提出了个性-共性互补映射模块来对用户的个性属性和公共属性进行互补建模, 如图1模块(a)所示。

#### 3.3.1 用户个性化映射

对于用户个性化映射表示, 本文借鉴 PTUPCDR<sup>[8]</sup>的做法, 首先根据用户的对商品的交互序列获取用户特征, 再将此用户特征输入元网络得到输出权重向量, 再以此权重向量作为映射函数的参数, 达到个性化映射表示的目的, 具体过程如下:

设用户  $u_i$  在源域的商品交互序列为  $S_{u_i}^s = \{v_{i_1}^s, v_{i_2}^s, \dots, v_{i_n}^s\}$ , 其中  $n$  表示交互的商品数量,  $v_{i_k}^s$  表示用户  $u_i$  在第  $k$  个时刻交互的商品。则根据源域推荐模型, 可以得到用户  $u_i$  在源域的商品交互序列的嵌入向量表示  $\mathbf{S}_{u_i}^s = \{v_{i_1}^s, v_{i_2}^s, \dots, v_{i_n}^s\}$ , 其中  $v_{i_k}^s = f_{\theta^s}(v_{i_k}^s)$ 。根据注意力机制<sup>[27-28]</sup>, 可以获得交互序列嵌入向量融合之后的单个向量表示如下:

$$\mathbf{p}_{u_i} = \sum_{v_j^s \in S_{u_i}^s} \alpha_j \mathbf{v}_j^s \quad (3)$$

其中,  $\alpha_j$  表示用户  $u_i$  对商品  $v_j$  的注意力分数,  $\mathbf{p}_{u_i} \in \mathbb{R}^d$  表示基于商品的用户特征。上式可以直观地理解为不同的交互商品对于刻画对目标域有用的可迁移的用户特征的贡献不同, 具体贡献的大小通过注意力分数  $\alpha_j$  来刻画, 分数越大, 贡献就越大。而具体的注意力分数  $\alpha_j$  可以通过注意力网络得到:

$$\alpha_j = \frac{\exp(a_j)}{\sum_{v_j^s \in S_{u_i}^s} \exp(a_j)} \quad (4)$$

其中,  $a_j = \text{Attn}(\mathbf{v}_j^s; \boldsymbol{\phi})$ ,  $\text{Attn}(\cdot)$  表示注意力网络,  $\boldsymbol{\phi}$  表示注意力网络的参数。

结合基于参数生成的元学习方法, 将前面获得的基于商品的用户特征表示  $\mathbf{p}_{u_i}$  作为元学习网络的输入, 生成相应的输出并进一步将其输出作为映射函数的权重参数, 最终通过该映射函数获得该源域用户在目标域的个性化表示。具体过程可作如下形式化:

$$\mathbf{w}_{u_i} = f^{\text{meta}}(\mathbf{p}_{u_i}; \boldsymbol{\varepsilon}) \quad (5)$$

$$\mathbf{u}_i^{t_p} = f^p(\mathbf{u}_i^s; \mathbf{w}_{u_i}) \quad (6)$$

其中,  $f^{\text{meta}}(\cdot)$  表示元网络, 使用两层感知机实现,  $\boldsymbol{\varepsilon}$  表示

元网络参数,  $\mathbf{w}_{u_i}$  表示元网络的输出, 其形状依赖于映射函数  $f^p$  的结构, 由于不同的用户的个性特征不同, 因此产生的元网络输出  $\mathbf{w}_{u_i}$  也会因个性化特征的不同而不同, 因此映射函数  $f^p$  的输出  $\mathbf{u}_i^{t_p}$  也会不同, 换句话说, 映射函数  $f^p$  的输出  $\mathbf{u}_i^{t_p}$  反映了用户的个性化特征, 从而实现用户的个性化映射, 在本文的实现中, 同样采用两层感知机作为个性化映射函数的基本结构。

#### 3.3.2 用户共有特征映射

尽管经过用户个性化映射函数的映射, 源域用户  $u_i$  在目标域中的表示  $\mathbf{u}_i^{t_p}$  已经能够较好的反映出用户  $u_i$  的个性特征, 但由于其一个用户独享一个映射函数的模式, 导致映射之后的表示  $\mathbf{u}_i^{t_p}$  可能会过于关注自己本身的个性化特征, 而忽略了源域中所有用户的到目标用户映射存在的共有特征, 这可能会导致部分共有特征信息的丢失, 从而导致映射到目标域中的用户表示不够准确。基于这个问题, 本文进一步提出了用于用户共有特征挖掘的用户共有特征映射模块。该模块直接以源域用户嵌入向量表示作为输入, 所有用户共享参数, 输出即为融合了所有用户共有特征的输入用户在目标域中的表示:

$$\mathbf{u}_i^{t_{com}} = f^{\text{com}}(\mathbf{u}_i^s; \boldsymbol{\omega}) \quad (7)$$

其中,  $\mathbf{u}_i^s$  为用户  $i$  在源域中的嵌入表示,  $\boldsymbol{\omega}$  为模块参数。对于  $f^{\text{com}}(\cdot)$ , 仍然采用两层感知机的结构。

### 3.4 用户感知目标域特征抽取

现有的跨域推荐算法大多仅仅着眼于如何更好的将源域的知识更准确地迁移到目标域中去, 却忽略了对目标域本身所蕴含的知识的探索, 尤其是当源域中的知识本就相对缺乏时, 迁移源域知识的做法并不能带来理想的推荐性能, 因此, 本文进一步提出了用于目标域知识挖掘的关系网络模块, 如图1模块(b)所示。首先, 根据前一节所描述的个性-共性映射函数模块, 可以获得源域用户的分别基于个性与共性的在目标域中的表示  $\mathbf{u}_i^{t_p}$  和  $\mathbf{u}_i^{t_{com}}$ , 进一步, 将两种互补表示进行融合, 获得融合后的在目标域中的表示  $\mathbf{u}_i^{t_{fuse}}$ :

$$\mathbf{u}_i^{t_{fuse}} = \frac{\mathbf{u}_i^{t_p} + \mathbf{u}_i^{t_{com}}}{2} \quad (8)$$

其次, 由于源域用户  $u_i^s$  映射在目标域中表示  $\mathbf{u}_i^{t_{fuse}}$  的所有信息都来源于对源域知识的迁移, 并没用显式的考虑到目标域用户的特征, 当源域知识本身就相对不足时, 直接使用  $\mathbf{u}_i^{t_{fuse}}$  在目标域中对商品进行推荐可能会导致结果次优, 因此, 对目标域中的用户特征的抽取并将抽取的特征融入到源域用户  $u_i^s$  在目标域中映射的表示  $\mathbf{u}_i^{t_{fuse}}$  中便十分有必要。受归纳关系模型<sup>[29]</sup> (Inductive Relation Model) 的启发, 对于目标域用户特征信息的抽取, 本文以  $\mathbf{u}_i^{t_{fuse}}$  作为查询, 通过注意力机制<sup>[26-27]</sup> 获得目标域中各个用户嵌入向量相对于查询向量  $\mathbf{u}_i^{t_{fuse}}$  的权重  $\alpha_{ji}^t$ , 其中  $i$  表示源域中用户  $u_i^s$ ,  $j$  表示目标域中用户  $u_j^t$ 。直觉上看, 权重  $\alpha_{ji}^t$  可以理解为了获取源域用户  $u_i^s$  在目标域中的嵌入向量表示, 目标域用户  $u_j^t$  所做的贡献的大小, 贡献与权重大小成正比。然而, 在实际中,

由于目标域的用户数量往往很大,对于目标域中的每一个用户都计算一个权重会导致巨大的计算量,这对于实际应用是不现实的,因此本文采用采样的策略从目标域用户集合中采样一部分用户作为整个目标域用户集合的模拟,并称这个用户子集为“关键集”,然后再基于这个“关键集”抽取目标域用户特征。考虑到仅仅采样单一关键集可能会导致采样偏差,无法更精确的学习到目标域用户特征,本文进一步采用了多“关键集”的采样策略,即从目标用户集合中采样多个不同的关键集,来对目标域用户集合进行模拟。假设从目标域用户集合  $U'$  中抽取的关键集为  $U_1^t, U_2^t, \dots, U_z^t$ , 其中  $z$  表示采样的关键集的个数, 则对于第  $k_z$  个关键集 ( $1 \leq k_z \leq z$ ) 中的用户  $u_j^{k_z}$ , 源域用户  $u_i^s$  通过注意力机制计算的注意力分数为:

$$\alpha_{u_i^s u_j^{k_z}}^{k_z} = \frac{(\mathbf{I}^{k_z})^T [\mathbf{W}_q^{k_z} \mathbf{u}_i^{f_{src}} \oplus \mathbf{W}_k^{k_z} \mathbf{u}_j^{k_z}]}{\sum_{u_o^{k_z} \in U_{k_z}^t} (\mathbf{I}^{k_z})^T [\mathbf{W}_q^{k_z} \mathbf{u}_i^{f_{src}} \oplus \mathbf{W}_k^{k_z} \mathbf{u}_o^{k_z}]} \quad (9)$$

其中,  $U_{k_z}^t$  表示第  $k_z$  个关键集,  $\mathbf{u}_j^{k_z}$ 、 $\mathbf{u}_o^{k_z}$  分别表示用户  $u_j^{k_z}$ 、 $u_o^{k_z}$  对应的向量嵌入,  $\mathbf{I}^{k_z} \in \mathbb{R}^{2d \times 1}$ ,  $\mathbf{W}_q^{k_z} \in \mathbb{R}^{d \times d}$ ,  $\mathbf{W}_k^{k_z} \in \mathbb{R}^{d \times d}$  是可训练参数,  $\oplus$  表示连接操作。则根据第  $k_z$  个关键集获得的基于用户  $u_i^s$  的目标域特征向量嵌入为:

$$\mathbf{u}_{y_i}^{k_z} = \sum_{u_o^{k_z} \in U_{k_z}^t} \alpha_{u_i^s u_o^{k_z}}^{k_z} \mathbf{W}_v^{k_z} \mathbf{u}_o^{k_z} \quad (10)$$

其中,  $\mathbf{W}_v^{k_z} \in \mathbb{R}^{d \times d}$  为可训练参数。

类似的,对每一个关键集都进行相同的操作,可以获得用户  $u_i^s$  在每一个关键集上对应的目标域特征向量嵌入:  $\mathbf{u}_{y_i}^1, \mathbf{u}_{y_i}^2, \dots, \mathbf{u}_{y_i}^z$ , 然后将每一个关键集的特征向量嵌入进行融合,得到最终的目标域特征,具体形式如下:

$$\mathbf{u}_{y_i}^{f_{tar}} = \mathbf{W}_a [\bigoplus_{k_z=1}^z \mathbf{u}_{y_i}^{k_z}] \quad (11)$$

其中,  $\mathbf{W}_a \in \mathbb{R}^{d \times zd}$  为可训练参数。

最后,将通过互补映射迁移的用户表示与用户感知的目标域特征表示进行融合,得到最终的用户表示:

$$\hat{\mathbf{u}}_i = \frac{\mathbf{u}_i^{f_{src}} + \mathbf{u}_{y_i}^{f_{tar}}}{2} \quad (12)$$

## 4 模型优化

由于本文的跨域推荐框架的学习主要基于两个域的公共用户,因此,本模型中的所有参数均基于公共用户的监督信号进行优化。为了学习映射函数,现存的大多数的基于映射函数的方法<sup>[3-6]</sup>采用一种映射导向的优化过程来学习,具体来讲就是直接通过最小化经过映射函数转换的源域的用户表示<sup>[30]</sup>与该用户在目标域中的表示的距离来学习映射函数。然而,由于某些用户的交互记录较少,学习到的用户或商品的嵌入表示可能并不准确,为了减少这种不准确的嵌入表示带来的影响,本文与 PTUPCDR<sup>[8]</sup>保持一致,采用任务导

向的优化过程来训练模型,这样模型的训练直接以推荐目标为导向,能尽可能的减少嵌入表示的不准确性带来的消极影响,具体优化目标如下:

$$\mathcal{L}(\hat{r}_{ij}, r_{ij}) = \frac{1}{|R_o'|} \sum_{r_{ij} \in R_o'} (r_{ij} - \hat{r}_{ij})^2 \quad (13)$$

其中,  $R_o' = \{r_{ij} | u_i \in U^o, v_j \in V^t\}$ , 表示目标域中公共用户的真实评分集合,  $\hat{r}_{ij} = (\hat{\mathbf{u}}_i^t)^T \mathbf{v}_j$  表示模型预测的评分。

## 5 实验

### 5.1 实验设置

#### 5.1.1 数据集

为便于与其他模型公平比较,本文选用现存的大多数方法<sup>[4,10,31]</sup>都采用的数据集,即 Amazon 数据集,它是现实场景下用户商品交互行为的大规模数据集。具体地,本文使用 Amazon-5cores 数据集,并且从总共 24 中类别中挑选出三种流行的数据类别: movies\_and\_tv (Movie), cds\_and\_vinyl (Music), and books (Book), 并据所选数据集定义三种跨域任务类别,分别为任务一: Movie-Music, 任务二: Book-Movie 和任务三: Book-Music。所有的数据划分与处理细节均与 PTUPCDR 保持一致。详细任务数据统计信息如表 1 所示。

#### 5.1.2 评价指标

亚马逊评论数据集包含每一次交互行为用户对于商品的评分 (0-5 分), 预测用户对商品的评分本质上属于回归问题,因此,与已有的工作<sup>[5,10,30]</sup>保持一致,本文选用平均绝对误差 (MAE) 和均方根误差 (RMSE) 作为评价指标,为了方便表示,在下文中,均方根误差和平均绝对误差均用 RMSE 和 MAE 表示。其计算方式如下:

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (14)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (15)$$

其中,  $n$  表示样本数量,  $\hat{y}_i$  表示模型预测值,  $y_i$  表示真实值。

#### 5.1.3 基线模型

本文所提出的 CDRTFC 模型大体上可以将其归为基于映射的跨域推荐算法,并且其并不借助除了用户商品交互数据之外的其他辅助信息,因此本文所提出的模型主要与同样基于映射的跨域推荐算法<sup>[4-5,7]</sup>进行比较,因此,本文选取以下模型作为比较的基线模型:

① TGT。接用目标域数据训练的矩阵分解模型。

② MF<sup>[12]</sup>。CMF 可以看做是矩阵分解模型 MF 的扩展,使其可以应用于跨域推荐系统中,其公共用户的嵌入表示在源域和目标域保持一致;

③ EMC<sup>[5]</sup>。CDR 是十分流行的一种跨域推荐算法,许多基于映射的跨域推荐算法均由其发展而来。其首先通过隐藏

因子模型分别学习到源域和目标域的用户和商品嵌入表示,然后根据学习到的嵌入表示利用两个域的公共用户学习一个映射函数,最后利用映射函数将源域用户和映射到目标域,进行推荐。

④DCDCSR<sup>[6]</sup>。DCDCSR 考虑到不同用户的稀疏度对于学习到的表示准确性的影响,缓解了过于稀疏导致的表示不准确的问题,提升了模型的鲁棒性。

⑤SSCDR<sup>[4]</sup>。SSCDR 考虑到源域和目标域重叠用户过少时映射函数容易过拟合的问题,并应用半监督学习来缓解这个问题。

⑥PTUPCDR<sup>[8]</sup>。PTUPCDR 利用元学习技术为每个用户分别学习一个映射函数,使模型能够充分考虑到每个用户的个性化特征,是目前性能最优的基线模型。

## 5.2 总体实验

总体实验结果如表 2、表 3 所示,最优的结果采用加粗表示, Imp%表示本文的方法 CDRTFC 相对于最好的基线性能的相对提升百分比。

表 2 展示了本文提出的模型 CDRTFC 在平均绝对误差 (MAE) 评价指标上与其他基线模型性能的对比,从表中可

以看到,本文提出的模型在平均绝对误差 (MAE) 指标上的表现超过了所有的基线模型,其中,在任务一和任务三中的效果提升明显,在任务二中的提升相对较小。原因可能在于对于任务一和任务三,由于两个域的重叠用户较少,可能导致映射函数的学习不够充分,无法准确迁移源域知识到目标域,也即是说源域知识对目标域的帮助有限,而通过本文提出的用户感知目标域特征抽取模块通过目标域本身的知识挖掘可以有效弥补这个不足,因此提升较大;而对于任务二,由于重叠用户较多,已有的基线模型就能学习到较好的映射函数,本文的方法的改进效果则相对减弱,因而最终的提升相对较小。

表 3 展示了本文提出的模型 CDRTFC 在均方根误差 (RMSE) 评价指标上与其他基线模型性能的对比,结果与表 2 类似,均取得了最优的性能,其中,在任务一和任务三中的效果提升明显,在任务二中的提升相对较小。具体原因分析与表 2 一致。

表 1 不同跨域任务数据集信息统计  
Table 1 Statistics of different cross-domain task datasets

跨域任务	商品			用户		评分	
	源域	目标域	重叠用户	源域	目标域	源域	目标域
任务一	50,052	64,443	18,031	123,960	75,258	1,697,533	1,097,592
任务二	367,982	50,052	37,388	603,668	123,960	8,898,041	1,697,533
任务三	367,982	64,443	16,738	603,668	75,258	8,898,041	1,097,592

表 2 本文提出的模型 CDRTFC 在平均绝对误差 (MAE) 评价指标上与其他模型的对比。  
Table 2 Comparison of the proposed CDRTFC in the mean absolute error (MAE) with other models.

	$\beta$	TGT	CMF	DCDCSR	SSCDR	EMCDR	PTUPCDR	CDRTFC	Imp%
任务一	20%	4.4803	1.5209	1.4918	1.3017	1.2350	1.1504	<b>1.0139</b>	11.86%
	50%	4.4989	1.6893	1.8144	1.3762	1.3277	1.2804	<b>1.1324</b>	11.56%
	80%	4.5020	2.4186	2.7194	1.5046	1.5008	1.4049	<b>1.2241</b>	12.87%
任务二	20%	4.1831	1.3632	1.3971	1.2390	1.1162	0.9970	<b>0.9672</b>	2.99%
	50%	4.2288	1.5813	1.6731	1.2137	1.1832	1.0894	<b>0.9810</b>	9.95%
	80%	4.2123	2.1577	2.3618	1.3172	1.3156	1.1999	<b>1.0490</b>	12.58%
任务三	20%	4.4873	1.8284	1.8411	1.5414	1.3524	1.2286	<b>0.9780</b>	20.40%
	50%	4.5073	2.1282	2.1736	1.4739	1.4732	1.3764	<b>1.0375</b>	24.62%
	80%	4.6204	3.0130	3.1405	1.6414	1.7191	1.5784	<b>1.2109</b>	23.28%

表 3 本文提出的模型 CDRTFC 在均方根误差 (RMSE) 评价指标上与其他模型的对比。  
Table 3 Comparison of the proposed CDRTFC in the root mean square error (RMSE) with other models.

	$\beta$	TGT	CMF	DCDCSR	SSCDR	EMCDR	PTUPCDR	CDRTFC	Imp%
任务一	20%	5.1580	2.0158	1.9210	1.6579	1.5515	1.5195	<b>1.3127</b>	13.61%
	50%	5.1736	2.2271	2.3439	1.7477	1.6644	1.6380	<b>1.4781</b>	9.76%
	80%	5.1891	5.1891	3.3065	1.9229	1.8771	1.8234	<b>1.6399</b>	10.06%
任务二	20%	4.7536	1.7918	1.7346	1.6526	1.4120	1.3317	<b>1.2352</b>	7.25%
	50%	4.7920	2.0886	2.0551	1.5602	1.4981	1.4395	<b>1.2665</b>	12.02%
	80%	4.8149	2.6777	2.7702	1.7024	1.6433	1.5916	<b>1.3711</b>	13.85%
任务三	20%	5.1672	1.3829	2.2955	1.9283	1.6737	1.6085	<b>1.2670</b>	24.61%
	50%	5.1727	2.7275	2.6771	1.8441	1.8000	1.7447	<b>1.3649</b>	21.77%
	80%	5.2308	3.6948	3.5842	2.1403	2.1119	2.0510	<b>1.6401</b>	20.03%

## 5.3 消融实验

为验证本文所提出的个性-共性互补映射模块与用户感知的目标域特征抽取模块的有效性,本文进一步对其做了

以下消融实验, 其中, w/o com 表示将个性-共性互补映射模块替换为 PTUPCDR 提出的个性化映射函数模块, 即仅考虑各个用户的个性化属性, 忽略其共有属性; w/o t\_fea 表示移除本文提出的用户感知目标域特征抽取模块, 即不考虑对目标域知识本身的挖掘与利用, 仅仅利用源域迁移的知识。具体结果见表 4、表 5。根据表 4、表 5, 可以发现, 本文所提出的任何一个单个模块的添加都能获得优于所有基线模型的结果, 尤其是个性-共性互补映射模块提升比较显著, 而用户感知的目标域特征抽取模块对性能的提升相对较小, 表明源域的知识仍然是性能提升的主要来源, 目标域抽取的特征的作用更多在于源域知识相对不足时的弥补, 这不仅证明了本文所提出的两大模块的有效性, 同时也说明了总体实验中提出的猜想的可靠性。值得注意的是, 在少数情况下, 本文所提出的两个模块在同时应用时效果会略低于仅应用个性-共性互补映射模块时的情形, 猜想原因可能在于在引入目标域特征时, 也可能会引入噪声, 导致模型性能下降, 这一部分的内容将作为未来的研究工作。

表 4 对于平均绝对误差 (MAE) 的消融实验

Table 4 Ablation experiments for mean absolute error (MAE)

	$\beta$	w/o com	w/o t_fea	CDRTFC
任务一	20%	1.1003	1.0793	<b>1.0139</b>
	50%	1.1661	<b>1.1091</b>	1.1324
	80%	1.2622	1.2516	<b>1.2241</b>
任务二	20%	0.9929	0.9713	<b>0.9672</b>
	50%	1.0213	1.0107	<b>0.9810</b>
	80%	2.6777	<b>1.0421</b>	1.0490
任务三	20%	0.9972	1.0003	<b>0.9780</b>
	50%	1.0600	1.0676	<b>1.0375</b>
	80%	1.2313	<b>1.1978</b>	1.2109

表 5 对于均方根误差 (RMSE) 的消融实验

Table 5 Ablation experiments for root mean square error (RMSE)

	$\beta$	w/o com	w/o t_fea	CDRTFC
任务一	20%	1.4045	1.3905	<b>1.3127</b>
	50%	1.5227	<b>1.4498</b>	1.4781
	80%	1.6885	1.6761	<b>1.6399</b>
任务二	20%	1.2762	1.2428	<b>1.2352</b>
	50%	1.3225	1.2980	<b>1.2665</b>
	80%	1.4157	<b>1.3610</b>	1.3711
任务三	20%	1.3080	1.2951	<b>1.2670</b>
	50%	1.3970	1.4066	<b>1.3649</b>
	80%	1.6577	<b>1.5996</b>	1.6401

#### 5.4 通用性实验

为验证本文所提出的模型在不同的底层模型上的泛化能力, 在该实验中, 进一步展示了本文所提出的模型在以 MF 和 GMF 为底层模型上的与其他的跨域推荐模型的性能比较, 具体比较结果如图 2、图 3、图 4 和图 5 所示, 可知不论是以 MF 为底层模型还是以 GMF 为底层模型, 本文所提出的模型均能取得最优性能, 表明本文所提出的具有一定的通用性。




图 2 基于 MF 模型, 本文所提出的 CDRTFC 模型与 EMCDR、PTUPCDR 关于平均绝对误差 (MAE) 性能对比实验。

Fig. 2 Based on the MF model, the CDRTFC model proposed in this paper compares the performance of the average absolute error (MAE) with EMCDR and PTUPCDR.




图 3 基于 MF 模型, 本文所提出的 CDRTFC 模型与 EMCDR、PTUPCDR 关于均方根 (RMSE) 性能对比实验。

Fig. 3 Based on the MF model, the CDRTFC model proposed in this paper is compared with EMCDR and PTUPCDR on root mean square (RMSE) performance.




图 4 基于 GMF 模型, 本文所提出的 CDRTFC 模型与 EMCDR、PTUPCDR 关于平均绝对误差 (MAE) 性能对比实验。

Fig. 4 Based on the GMF model, the CDRTFC model proposed in this paper compares the performance of the average absolute error (MAE) with EMCDR and PTUPCDR.




图 5 基于 GMF 模型, 本文所提出的 CDRTFC 模型与 EMCDR、PTUPCDR 关于均方根 (RMSE) 性能对比实验。

Fig. 5 Based on the GMF model, the CDRTFC model proposed in this paper is compared with EMCDR and PTUPCDR on root mean square (RMSE) performance.

### 5.5 参数敏感性实验

为验证本文所提出模型的鲁棒性，本实验分别测试了模型在目标域中采样关键集的个数和每一个关键集内包含的用户个数对模型性能的影响。同时，为了简便起见，在测试其中一个因素对模型性能影响时，固定另一个因素不变；即在测试关键集个数对模型性能影响时，固定每个关键集内的用户数量为100，类似地，当测试关键集内用户数量对模型性能影响时，固定采样的关键集个数为4；另外，为了尽可能真实地反映超参数对模型性能的影响，每一种任务的实验结果都基于 $\beta = 50\%$ 设置下进行。即训练集和测试集各占一半。具体的实验结果如图6、图7、图8和图9所示。根据实验结果，总体来看，不同超参数设置对于模型最终性能的影响比较小，说明CDRTFC模型对于超参数设置比较稳定。

对于各个任务而言，取得最优性能时超参数的组合不同。具体的，对于任务一而言，当关键集个数固定为4个的情况下，用户数量为100时取得最好的结果；当用户数量固定为100个的情况下，关键集数量取值为4时取得最好的结果；对于任务二，大体上也能获得类似的结果；但对于任务三而言，结果与前两个任务有一定的差别，当关键集个数固定为4时，用户数量为250个时效果最好；当用户数量固定为100个的情况下，关键集数量取值为3或5时取得最好的结果；但总体的结果波动不大，验证了本文所提出的模型的鲁棒性。




图6 对于不同任务，关键集内用户数量对平均绝对误差(MAE)的影响。  
Fig. 6 The effect of the number of users in the key set on the mean absolute error (MAE) for different tasks.




图7 对于不同任务，关键集内用户个数对方根误差(RMSE)的影响。  
Fig. 7 The effect of the number of users in the key set on the root mean square error (RMSE) for different tasks.




图8 对于不同任务，关键集数量对平均绝对误差(MAE)性能的影响。  
Fig. 8 The effect of the number of key sets on mean absolute error (MAE) performance for different tasks.




图9 对于不同任务，关键集数量对方均根误差(RMSE)性能的影响。  
Fig. 9 The effect of the number of key sets on root mean square error (RMSE) performance for different tasks.

## 6 总结

针对现有的基于映射的跨域推荐模型所存在的不足，本文提出了目标域特征感知与互补用户迁移的跨域推荐模型。一方面，互补知识迁移模块同时考虑到了用户的个性与共性信息，克服了原有模型或仅考虑用户共性信息或仅考虑用户个性信息的缺陷；另一方面，用户感知目标域特征抽取模块提出对目标域知识进行挖掘，弥补了现有跨域推荐模型忽略目标域本身知识挖掘的不足，进一步提升了模型的性能。实验结果表明，本文提出的目标域特征感知与互补用户迁移的跨域推荐模型总体性能在不同数据集下均优于基线模型。但通过消融实验表明，本模型对于目标域特征知识的抽取域融合方面仍存在一定缺陷，比如可能会引入噪声等，因此，对于如何更有效地抽取与融合目标域特征知识仍有待进一步研究，这也将作为作者未来的研究工作之一。

### References:

- [1] Covington, Paul, Jay K Adams, et al. Deep neural networks for YouTube recommendations[C]//Proceedings of the 10th ACM Conference on Recommender Systems, 2016: 191–198.
- [2] Yehuda Koren, Robert Bell, Chris Volinsky. Matrix factorization techniques for recommender systems[J]. Computer, 2009, 42(8): 30–37.



- [3] Eirinaki,Magdolini,Jerry Zeyu Gao,et al.Recommender systems for large-scale social networks: a review of challenges and solutions[J].Future Generation Computer Systems,2018,78(1): 413-418.
- [4] Fu Wenjing,Zhaohui Peng,Senzhang Wang,et al. Deeply fusing reviews and contents for cold start users in cross-domain recommendation systems[J].Proceedings of the AAAI Conference on Artificial Intelligence,2019,33(1):94-101
- [5] SeongKu Kang,Junyoung Hwang,Dongha Lee,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,2019:1563–1572.
- [6] Tong Man,Huawei Shen,Xiaolong Jin,et al. Cross-domain recommendation: an embedding and mapping approach[C]//Proceedings of the 26th International Joint Conference on Artificial Intelligence,2017:2464–2470.
- [7] Feng Zhu,Yan Wang,Chaochao Chen,et al.A deep framework for cross-domain and cross-system recommendations[C]//Proceedings of the 27th International Joint Conference on Artificial Intelligence,2018: 3662-4402.
- [8] Zhu,Yongchun,Zhenwei Tang,Yudan Liu,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,2022:1507-1515.
- [9] Yongchun Zhu,Ruobing Xie,Fuzhen Zhuang,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,2021:1167–1176 .
- [10] Misztal-Radecka J,Indurkha B,A Smywiński-Pohl. Meta-User2Vec model for addressing the user and item cold-start problem in recommender systems[J].User Modeling and User-Adapted Interaction, 2021,31(2):1-26.
- [11] Yongchun Zhu,Kaikai Ge,Fuzhen Zhuang,et al. Transfer-meta framework for cross-domain recommendation to cold-start users[C]//Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval,2021:1813–1817.
- [12] Obing Xie,Zhijie Qiu,Jun Rao, et al. Internal and contextual attention network for cold-start multi-channel matching in recommendation[C]//29th International Joint Conference on Artificial Intelligence and Seventeenth Pacific Rim International Conference on Artificial Intelligence ,2020:2732–2738.
- [13] Ajit Paul Singh,Geoffrey J Gordon.Relational learning via collective matrix factorization[C]//Proceedings of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining,2008:650–658.
- [14] Weike Pan,Evan Wei Xiang,Nathan Nan Liu,et al.Transfer learning in collaborative filtering for sparsity reduction[C]//Proceedings of the 24th AAAI Conference on Artificial Intelligence,2010:230-235.
- [15] Guangneng Hu,Yu Zhang,Qiang Yang.Conet: collaborative cross networks for cross-domain recommendation[C]//Proceedings of the 27th ACM International Conference on Information and Knowledge Management,2018:667–676.
- [16] Ming He, Jiuling Zhang,Peng Yang,et al.Robust transfer learning for cross-domain collaborative filtering using multiple rating patterns approximation[C]//Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining,2018: 225–233.
- [17] Pan Li,Alexander Tuzhilin.DDTCDR: deep dual transfer cross domain recommendation[C]//Proceedings of the 13th International Conference on Web Search and Data Mining,2020:331–339.
- [18] Andrew I Schein,Alexandrin Popescul,et al.Methods and metrics for cold-start recommendations[C]//Proceedings of the 25th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval,2002:253–260.
- [19] Ignacio Fernández-Tobías,Iván Cantador,Marius Kaminskis,et al.A generic semantic-based framework for cross-domain recommendation[C]//Proceedings of the 2nd International Workshop on Information Heterogeneity and Fusion in Recommender Systems,2011:25–32.
- [20] Seung-Taek Park,Wei Chu.Pairwise preference regression for cold-start recommendation[C]// Proceedings of the 3rd ACM Conference on Recommender Systems,2009:21-28.
- [21] Jingjing Li,Mengmeng Jing,Ke Lu,et al. From zero-shot learning to cold-start recommendation[C]//Proceedings of the AAAI Conference on Artificial Intelligence,2019,33(1):4189-4196.
- [22] Yanir Seroussi,Fabian Bohnert,Ingrid Zukerman. Personalised rating prediction for new users using latent

- factor models[C]//Proceedings of the 22nd ACM Conference on Hypertext and Hypermedia,2011:47–56.
- [23] Kaixiang Mo,Bo Liu,Lei Xiao,et al.Image feature learning for cold start problem in display advertising[C]//Proceedings of the 24th International Conference on Artificial Intelligence,2015:3728–3734.
- [24] Jie Tang,Sen Wu,Jimeng Sun,et al.Cross-domain collaboration recommendation[C]//Proceedings of the 18th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining,2012: 1285–1293.
- [25] Ali Mamdouh Elkahky,Yang Song,Xiaodong He.A multi-view deep learning approach for cross domain user modeling in recommendation systems[C]//Proceedings of the 24th International Conference on World Wide Web,2015:278–288.
- [26] Bin Li.Cross-domain collaborative filtering: a brief survey[C]//Proceedings of the IEEE 23rd International Conference on Tools with Artificial Intelligence,2011: 1085–1086.
- [27] Jun Xiao,Hao Ye,Xiangnan He,et al.Attentional factorization machines: learning the weight of feature interactions via attention networks[C]//Proceedings of the 26th International Joint Conference on Artificial Intelligence,2017:3119–3125.
- [28] Guorui Zhou,Xiaoqiang Zhu,Chenru Song,et al.Deep interest network for click-through rate prediction[C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery,2018:1059–1068.
- [29] Wu Qitian,Hengrui Zhang,Xiaofeng Gao,et al.Towards open-world recommendation: an inductive model-based collaborative filtering approach[C]//International Conference on Machine Learning,Proceedings of the 38th International Conference on Machine Learning,2021:11329-11339.
- [30] Feiyang Pan,Shuokai Li,Xiang Ao,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,2019: 695–704.
- [31] Cheng Zhao,Chenliang Li,Rong Xiao,et al.CATN: cross-domain recommendation for cold-start users via aspect transfer network[C]//Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval,2020:229–238.