

撤稿声明

撤稿文章名: 基于融合特征动态方面表示的跨域推荐
作者: 何雅芳、刘兴林、郑小柏
*** 通讯作者:** 邮箱: 1011907093@qq.com
期刊名: 计算机科学与应用 (CSA)
年份: 2020
卷数: 10
期数: 10
页码 (从X页到X页): 1879-1887
DOI (to PDF): <https://doi.org/10.12677/CSA.2020.1010198>
文章ID: 1541895
文章页面: <https://www.hanspub.org/journal/PaperInformation.aspx?paperID=38410>

撤稿日期: 2021-3-29

撤稿原因 (可多选):

- 所有作者
 部分作者:
 编辑收到通知来自于 出版商
 科研机构:
 读者:
 其他:

撤稿生效日期: 2019-3-14

撤稿类型 (可多选):

- 结果不实
 实验错误 数据不一致 分析错误 内容有失偏颇
 其他:
 结果不可再得
 未揭示可能会影响理解与结论的主要利益冲突
 不符合道德
 欺诈
 编造数据 虚假出版 其他:
 抄袭 自我抄袭 重复抄袭 重复发表*
 侵权 其他法律相关:
 编辑错误
 操作错误 无效评审 决策错误 其他:
 其他原因:

出版结果 (只可单选)

- 仍然有效.
 完全无效.

作者行为 失误(只可单选):

- 诚信问题
 学术不端
 无 (不适用此条, 如编辑错误)

* 重复发表: "出版或试图出版同一篇文章于不同期刊."

历史

作者回应:

是, 日期: yyyy-mm-dd

否

信息改正:

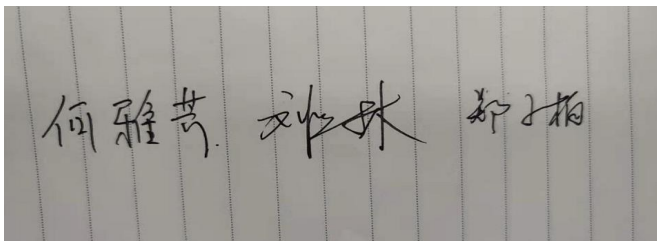
是, 日期: yyyy-mm-dd

否

说明:

“基于融合特征动态方面表示的跨域推荐”一文刊登在2020年10月出版的《计算机科学与应用》2020年第10卷第10期第1879-1887页上。作者发现文中的实验数据以及公式有误,需进一步修改。根据国际出版流程,编委会现决定撤除此稿件:何雅芳,刘兴林,郑小柏.基于融合特征动态方面表示的跨域推荐[J].计算机科学与应用,2020,10(10):1879-1887. <https://doi.org/10.12677/CSA.2020.1010198>

所有作者签名:



何雅芳 刘兴林 郑小柏

基于融合特征动态方面表示的跨域推荐

何雅芳, 刘兴林, 郑小柏

五邑大学智能制造学部, 广东 江门

Email: avon_he@126.com

收稿日期: 2020年10月7日; 录用日期: 2020年10月22日; 发布日期: 2020年10月29日

摘要

每一个评论-评分对反映出不同的用户偏好和商品特征, 如何从评论-评分对中挖掘出用户和商品的潜在特征是提高跨域推荐算法性能的关键。因此, 本文提出一种基于融合特征动态方面表示的跨域推荐模型。根据不同的评论-评分对, 利用卷积神经网络(CNN)结合注意力机制(Attention)的方式获取评论-评分对融合特征的动态方面表示, 通过这种方式为两个领域学习到更多的用户偏好和商品特征。然后, 利用多层感知机(MLP)实现辅助域到目标域中的知识迁移, 进行跨域推荐, 以解决数据稀疏和冷启动问题。该模型在公开数据集上进行对比实验, 通过对比RMSE评估指标, 实验结果表明该模型在跨域推荐上取得的效果更好。

关键词

跨域推荐, 评论-评分对, 卷积神经网络, 注意力机制, 多层感知机

Cross-Domain Recommendation Based on Dynamic Aspect Representation of Fusion Features

Yafang He, Xinglin Liu, Xiaobai Zheng

Faculty of intelligent Manufacturing, Wuyi University, Jiangmen Guangdong

Email: avon_he@126.com

Received: Oct. 7th, 2020; accepted: Oct. 22nd, 2020; published: Oct. 29th, 2020

Abstract

Each review-rating pair reflects different user preferences and product feature. How to dig out the potential features of users and products from the review-rating pair is the key to improving the

performance of the cross-domain recommendation algorithm. Therefore, this paper proposes a cross-domain recommendation based on dynamic aspect representation of fusion features. According to different review-rating pairs, convolutional neural network (CNN) combined with attention mechanism (Attention) is used to obtain the dynamic aspect of review-rating pairs. More user preferences and product features are learned for the two fields in this way. Then, the multi-layer perceptron (MLP) is used to realize the knowledge transfer of the auxiliary domain to the target domain, and cross-domain recommendation is used to solve the problem of data sparseness and cold start. A comparative experiment was carried out on open datasets. By comparing the RMSE evaluation index, the experimental results show that the model achieves better results in cross-domain recommendation.

Keywords

Cross-Domain Recommendation, Review-Rating Pair, Convolutional Neural Network, Attention Mechanism, Multi-Layer Perceptron

Copyright © 2020 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

目前大多数的推荐系统都是提供单一领域的商品推荐,比如 Netflix 电影推荐、MOOC 的课程推荐等。单领域推荐来源单一,往往存在着数据稀疏和冷启动问题,推荐效果不明显。因此,跨域推荐成为推荐系统中的一个热点。跨域推荐通过利用用户在经验丰富的领域中的反馈信息,推测出用户在经验缺乏的领域上的偏好,从而有效解决单领域下的数据稀疏和冷启动问题。在跨域推荐中,研究人员最常用的用户反馈信息是评分数据[1][2],通过利用不同领域间存在共同用户的关系,把数据密集的辅助域的知识迁移到数据稀疏的目标域中,解决数据稀疏和冷启动问题。然而,一些单域推荐[3][4]研究表明,伴随着评分的评论能很好展示出用户偏好和商品特征,有助于为用户和商品生成更好的潜在特征,从而改善推荐结果。因此,研究人员进一步把评论应用在跨域推荐上[5][6]。

虽然这些跨域算法取得的效果都不错,但是它们忽略了一个现象:不是所有的评论和评分都有意义,而且评论好不意味评分高,反之亦然。例如,有些用户写一堆无意义的评论,但评分就很随意。而本文认为这里的随意评分是根据用户对商品印象进行的。也就是说,虽然评论无意义,但也能从评分中获取到用户对商品的偏好。如果直接使用这些反馈信息建模,本文认为这样会损害到模型的性能。因此,对于如何整合这些的评论和评分信息既可以突出用户对商品的偏好又能减少对模型的损害是关键。

基于以上的想法,本文提出一种基于融合特征动态方面表示的跨域推荐模型(Cross-Domain Recommendation based on Dynamic Aspect Representation of Fusion Features, CDDAF)。该模型针对每一个评论-评分对,利用 CNN [7]提取出评论的特征,并将其融合相对应的评分向量得到融合特征,采用 Attention [8]对每个融合特征进行打分,捕获出不同融合特征的贡献度,获取融合特征的动态方面表示,进而提取不同域下的潜在特征。在学习到两个域的共同用户的潜在特征后,利用 MLP [9]学习两个域之间的特征映射,从而进行跨域推荐。

2. 相关研究

跨域推荐问题的核心在于如何利用辅助域的知识改善目标域中的推荐结果。因此,跨域推荐的前提

是建立起辅助域和目标域之间的关系, 比如利用共同物品的属性、关联规则等显示方式实现[10] [11], 也可以通过共享领域间的潜在特征等隐式方式来实现[12] [13]。由于评论在单域推荐领域上取得了不错的效果, 尤其是针对评分较低的用户和商品。因此, 一些单域推荐算法也逐渐扩展到跨域推荐上。

宋[5]通过把评论这种细粒度偏好信息引入到跨域推荐中, 提出了一种基于张量分解的跨域推荐模型, 通过提取出用户对项目关注不同的方面, 并在两个域建立起不同的三元张量后, 联合张量进行分解实现潜在特征的迁移。Xu [14]等意识到直接利用评论实现知识迁移, 会削弱掉用户某些情感信息。因此, Xu 提出了一种新的跨域推荐模型, 该模型可以有效识别用户评论的语义方向, 提取出用户的情感信息, 并利用 MLP 的多层映射方法, 将用户的情感信息从辅助域迁移到目标域中。付[15]考虑到评分矩阵和多种辅助信息的融合可能有助于提高跨域推荐的性能, 提出一种基于评论和内容深度融合的跨域推荐模型, 该模型首先通过扩展堆叠降噪自编码器(SDAE)模型[16]后, 再将 SDAE 的多个变体进行集成, 学习辅助域和目标域中的用户和商品潜在特征, 利用 MLP 来学习两个域之间的特征映射。

尽管这些模型取得了不错的结果, 但依然具有一定的局限性。这些模型没有考虑到不同评论和评分对模型的贡献度问题。此外, 这些模型通过把评论拼成长文档后建模, 容易扭曲评论原本的含义, 从而忽略用户对某一商品的特定偏好信息。Chen [4]等针对这个问题, 在单域推荐上提出了 NARRE 模型, 该模型利用注意力机制对每一条加入 id embedding 的评论进行加权打分, 对用户和商品质量进行建模。因此, 本文受到 NARRE [4]模型和 EMCDR [1]模型的启发, 设计出一种利用注意力机制获取评论和评分对融合特征动态方面表示的跨域推荐模型。

3. 模型设计与分析

3.1. 问题描述和框架概述

给定两个数据集 D^A 和 D^T (一个为辅助域, 一个为目标域), 它们满足: $U = \{u_1, u_2, \dots, u_n\}$ 是两个域中的共同用户, 在两个域中有反馈信息(评论、评分等), 而冷用户 $U_i = \{u_{i1}, u_{i2}, \dots, u_{im}\}$ 表示在辅助域中有反馈信息, 在目标域中无反馈信息。本文的目标是通过辅助域和目标域建模提取出共同用户的潜在特征, 实现辅助域到目标域中潜在特征的知识迁移, 从而预测出冷用户在目标域下对商品的评分。

如图 1 所示, $Net_u^{(A)}$ 和 $Net_i^{(T)}$ 分别为辅助域和目标域的用户建模, $Net_i^{(T)}$ 代表目标域中商品建模。 $U_u^{(A)}$ 和 $U_u^{(T)}$ 分别为辅助域和目标域某一共同用户 u 的潜在特征, $U^{(A)}$ 和 $U^{(T)}$ 分别为辅助域和目标域所有用户的潜在特征。 $V_i^{(T)}$ 代表目标域中商品 i 的潜在特征, $V^{(T)}$ 代表目标域中所有商品的潜在特征, $U_i^{(A)}$ 表示冷用户在辅助域中的潜在特征。本文把 CDDAF 模型分为三部分: 潜在特征的提取、跨域映射和评分预测。

图 1 中的第一部分为潜在特征的生成, 本文利用 CNN 结合 Max Pooling 的方式对用户的每一条评论向量进行文本特征提取, 让其与对应的评分向量进行融合, 再利用 Attention 捕获融合特征的权重, 以生成潜在特征; 第二部分利用 MLP 找出辅助域和目标域之间的映射函数; 第三部分是利用映射函数结合冷用户在辅助域中的潜在特征仿造出冷用户在目标域中的潜在特征后, 进行评分预测。

3.2. 潜在特征的生成

挖掘出用户的潜在特征是提高跨域推荐算法性能的关键, 因此本文借鉴 NARRE [7]模型的结构, 将评论和评分向量作为网络的输入, 采取并行训练的方式获取用户和商品的潜在特征。由于在辅助域和目标域采取相同的方法生成潜在特征, 因此本文以目标域为例解释潜在特征的生成, 在 $Net_u^{(T)}$ 中, 首先将用户 u 每一个评分通过嵌入层映射成一个稠密向量表达, 本文将其定义为 $R_{u1}^{(T)}, R_{u2}^{(T)}, \dots, R_{uj}^{(T)}$ 。同理, 对应的评论通过嵌入层转换成一个词向量表达, 本文将其定义为 $W_{u1}^{(T)}, W_{u2}^{(T)}, \dots, W_{uj}^{(T)}$ 。然后, 将评论向量输入

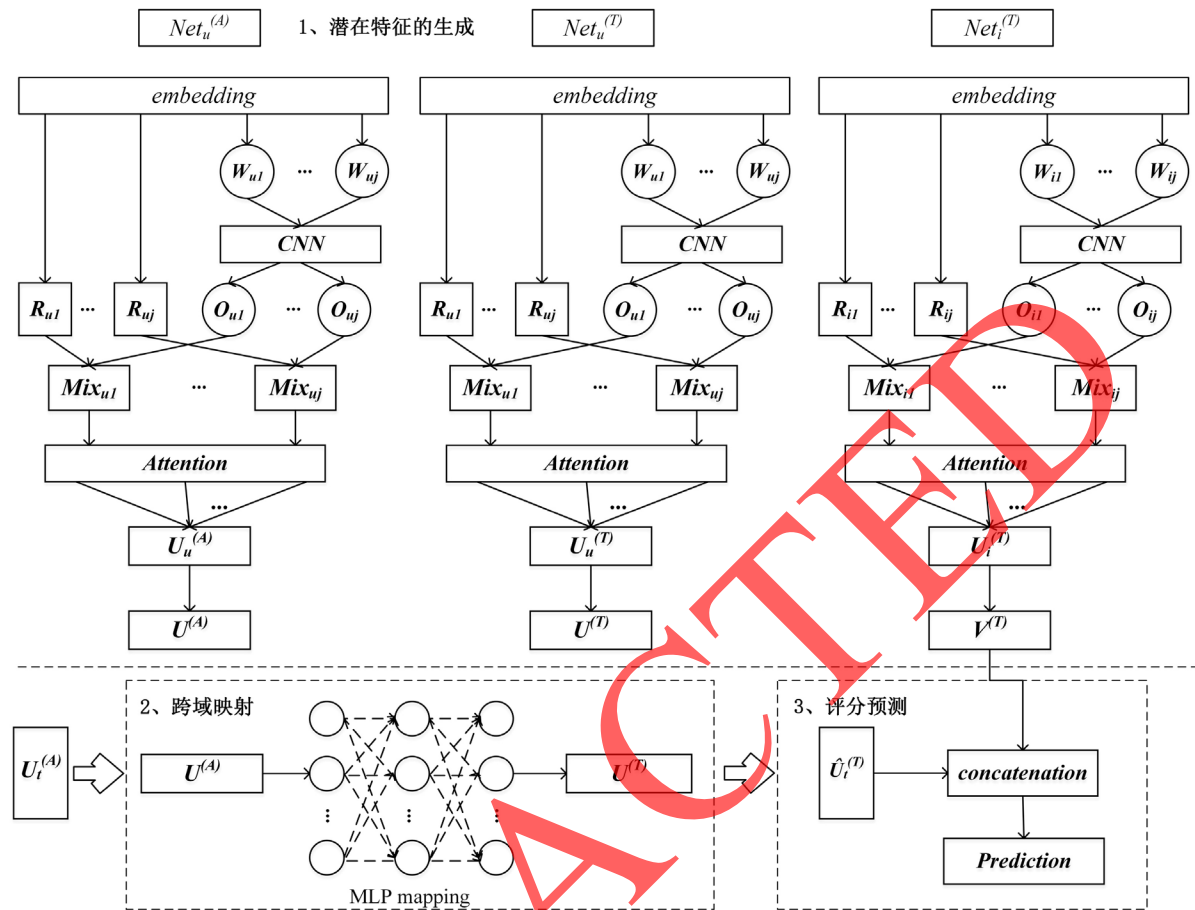


Figure 1. Model framework map
图 1. 模型框架图

到 CNN 文本处理器中，经过卷积层和最大池化层，提取到的评论特征表示为 $O_{u1}^{(T)}, O_{u2}^{(T)}, \dots, O_{uj}^{(T)}$ 。

本文认为评论 - 评分对是相辅相成的，融合评论特征和评分向量，更能反映出用户 u 的偏好。因此，本文首先在融合前分别为 $O_{uj}^{(T)}$ 和 $R_{uj}^{(T)}$ 添加各自全连接层，再采取相加策略进行特征融合，并使用非线性激活函数 relu 将它们映射到同一隐空间中，记融合特征为 $Mix_{uj}^{(T)}$ 。然而，此时获得的融合特征都具有相同的贡献度，但实际上不同的评论 - 评分对存在着不同意义，因此只有通过捕获融合特征中的动态表示才能表现出评论 - 评分对的贡献度。

注意力机制的基本思想是对不同的表示分配注意力权重，以增加这部分的贡献，忽略其他无关内容 [17]。因此，为了更好地获取融合特征中用户 u 具有代表性的偏好，本文把注意力向量定义为：

$$a_{uj}^{*(T)} = h^T \text{ReLU}(W_{mix} Mix_{uj}^{(T)} + b) \tag{1}$$

其中，得到的 $a_{uj}^{*(T)}$ 表示目标域中用户 u 第 j 对评论 - 评分对融合下的权重， b 为偏置项， W_{mix} 为权重矩阵， ReLU 表示非线性映射函数。

然后，利用 softmax 函数对 $a_{uj}^{*(T)}$ 进行归一化，得到用户 u 偏好的最终权重 $a_{uj}^{(T)}$ ，定义如下：

$$a_{uj}^{(T)} = \frac{\exp(a_{uj}^{*(T)})}{\sum_{j=1}^n \exp(a_{uj}^{*(T)})} \tag{2}$$

在获得每一个融合特征的权重后, 进行加权求和, 得到最终用户偏好特征 $Mix_u^{(T)}$, 定义如下:

$$Mix_u^{(T)} = \sum_{j=1}^n a_{uj}^{(T)} Mix_{uj}^{(T)} \quad (3)$$

接着把所求到的 $Mix_u^{(T)}$ 输入全连接层中, 因此用户 u 特征的最终表示为:

$$U_u^{(T)} = W_{mix} Mix_u^{(T)} + b \quad (4)$$

最后, 将 $Net_u^{(T)}$ 中间层的输出作为用户 u 的潜在特征, 记为 $U_u^{(T)}$, 在 $Net_i^{(T)}$ 中采取以上的方式获取到目标域中商品 i 的潜在特征, 记为 $V_i^{(T)}$ 。

由于本文关注的是评分预测问题, 而这实际上是一个回归问题。在线性回归模型中, 常用的损失函数是评分损失函数 MSE [4] [6]。因此, 对于目标域中的目标函数, 本文参考文献[4], 设置为:

$$L_r = \sum_{u,i \in T} (U_u^{(T)} V_i^{(T)} - r_{ui}^{(T)})^2 \quad (5)$$

其中 T 属于目标域中的训练集的样本, $r_{ui}^{(T)}$ 是目标域中训练集的真实评分。为了优化目标函数, 本文采取 Adam 优化器进行优化。此外, 本文利用 dropout 机制来防止过拟合。

同理, 本文使用上述的方法获取辅助域中用户的潜在特征以及冷用户在辅助域中的潜在特征。

3.3. 跨域映射

Man 等[1]指出 MLP 可以通过提前确定输入 - 输出学习到它们之间的非线性映射关系后进行跨域映射, 文献[2] [15]通过利用 MLP 实现两个域之间用户潜在特征非线性映射获取两域关系, 实现知识迁移。因此, 本文在 $Net_u^{(A)}$ 和 $Net_u^{(T)}$ 中通过学习得到辅助域和目标域中用户的潜在特征 $\{U^{(A)}, U^{(T)}\}$ 后, 参考此方法, 将 $U^{(A)}$ 作为输入, $U^{(T)}$ 作为输出, 得到非线性映射函数。该 MLP 的优化函数定义为:

$$\min_{\theta} \sum L(f_{mlp}(U_u^{(A)}; \theta), U_u^{(T)}) \quad (6)$$

其中 $f_{mlp}(\bullet; \theta)$ 是 MLP 映射函数, θ 是参数, 包括层之间的权重矩阵和偏差项。

3.4. 评分预测

由于冷用户在目标域中不存在任何反馈信息, 系统没有足够的信息计算出冷用户在目标域中的偏好。因此, 本文通过学习得到辅助域和目标域之间的映射函数 $f_{mlp}(\bullet; \theta)$, 以及冷用户在辅助域中得到的潜在特征 $U_i^{(A)}$, 仿造出冷用户在目标域中的潜在特征变量 $\hat{U}_i^{(T)}$, 定义如下:

$$\hat{U}_i^{(T)} = f_{mlp}(U_i^{(A)}; \theta) \quad (7)$$

在得到冷用户在目标域中的仿造潜在特征 $\hat{U}_i^{(T)}$ 和目标域中商品的潜在特征 $V_i^{(T)}$ 后, 采用 concatenate 拼接策略实现特征的交互。最后, 冷用户在目标域中的总体偏好表示为:

$$\hat{r} = W [\hat{U}_u^{(T)}, V_i^{(T)}] + b_u + b_i \quad (8)$$

其中, $[\]$ 表示拼接操作, b_u 为辅助域中的用户偏置, b_i 为目标域中的商品偏置。

4. 实验结果与分析

4.1. 数据集

本实验选取的实验数据集是公开的 Amazon 数据集[18], 其包含了 21 个不同类型的商品域。本实验主要在以下 6 个商品域中进行, 它们分别为 Movies_and_TV (M)、Electronics (E)、Books (B)、Video_Games

(V)、Apps_and_Android (A)、Kindle_Store (K)，这些数据集的用户评论都超过 5 条。

文献[2]表明数据稠密度的大小可以影响到模型的鲁棒性。因此，本文参考文献[15]的方法，采取对数据过滤的方式来提高数据的稠密度，并构建出具有一定数量的共同用户数据集，作为实验数据。以“M&B”数据集为例，本文首先在两个域中筛选出超过 50 条评论的商品，然后再筛选出两个域中少于 20 条但多于 5 条评论的共同用户。其余两对数据集采取相同的方式进行稠密度的提升。所构建的共同用户数据集如表 1 所示。

Table 1. Dataset statistics table

表 1. 数据集统计表

商品域	用户数	商品数	评分	稠密度(%)
V	723	3469	29,235	0.246
A		3258	25,836	0.320
M	824	3482	40,213	0.340
B		2056	34,575	0.490
K	2021	10,409	70,041	0.800
E		9000	72,464	0.920

4.2. 实验设置

本文根据数据稠密度的不同，将数据较为稠密的数据集称为辅助域，数据较为稀疏的称为目标域。与文献[15]类似，本实验设置的 CDDAF 模型适用于两个领域中存在共同用户的场景。本文随机选取不同比例的用户作为冷用户，将其在目标域中的全部反馈信息抹除，利用它们进行跨域推荐。为了实验的准确性，本文设置不同比例的冷用户作为测试集，分别为 20%，50% 和 80%，记为 γ ，其余用户作为训练集。此外，本文反复对用户进行随机采样，生成 5 次不同的用户集合进行实验，以平衡不同的冷用户比例对最终结果产生的影响。

在经过数据预处理后，本文利用 word2vec [19] 技术进行预训练词向量，获得静态词嵌入表示。在实验过程中，CDDAF 模型的卷积核参数设置为 100，卷积核大小为 5，词向量维度设置为 300，隐层节点数目(用户嵌入空间维度)设置为 32。

4.3. 对比模型

为了验证实验模型的性能，实验使用的评价指标为 RMSE (均方根误差)，其计算公式如下：

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{n=1}^N (\hat{r}_{ui} - r_{ui})^2} \quad (9)$$

其中， \hat{r}_{ui} 表示从模型中得出的预测评分， r_{ui} 表示在测试集中可以观察到的评分， N 表示测试集的个数。

为了评估该模型跨域推荐的有效性，本文将 CDDAF 模型与以下几个模型进行比较：

1) NMF [20]: 单域推荐模型，该模型在矩阵分解后使得所分解的分量为非负，并实现非线性的维数约减。

2) CMF [21]: 在 CMF 模型中，辅助域和目标域共享用户的潜在特征。

3) EMCDR [1]: 该模型利用矩阵分解获取两个域的潜在特征，并利用 MLP 捕获两个域的非线性映射关系后，进行跨域推荐。

考虑到 Attention 对于潜在特征提取的影响，本文设计了 CDDAF 的变体一起进行对比分析：

CDDF: 该模型是 CDDAF 的变体, 不考虑注意力机制, 只利用 CNN 处理用户 u 的每一条评论, 然后将生成的特征, 结合评分向量进行聚合, 定义为:

$$Mix_u = \sum_{j=1}^n \frac{1}{n} Mix_{uj} \quad (10)$$

4.4. 实验结果和分析

在 3 对数据集上进行实验结果如表 2 所示, 其中粗体表示在该数据集上的最好结果。通过观察实验结果, 可以发现相对于其他算法, 本文提出的 CDDAF 模型在跨域推荐上的效果更好。

Table 2. Comparison of the effects of each model in different datasets

表 2. 各模型在不同数据集中的效果比较

Dataset	γ	NMF	CMF	EMCDR	CDDF	CDDAF
V&A	20%	4.3130	1.1315	1.1272	1.3466	1.1026
	50%	4.3444	1.1577	1.1489	1.3984	1.1260
	80%	4.3467	1.1801	1.1576	1.4452	1.1324
M&B	20%	4.2267	1.1206	1.1190	1.2711	1.0928
	50%	4.2613	1.1460	1.1451	1.4073	1.1020
	80%	4.2714	1.1815	1.1607	1.4781	1.1327
K&E	20%	4.1599	1.0784	1.0670	1.1868	0.9757
	50%	4.2457	1.0869	1.0729	1.2082	0.9899
	80%	4.2897	1.1056	1.0908	1.2599	1.0054

从表 2 可以发现, 单域推荐模型 NMF 的 RMSE 评价指标高到 4.0 以上, 可见 NMF 依靠丰富的反馈信息才能发挥优势, 因此它在本文实验中并不能发挥优势, 说明了 NMF 不能有效解决冷启动问题。

本文通过对比 CMF、EMCDR 和 CDDAF 模型的 RMSE 评价指标, 可以发现 EMCDR 和 CDDAF 推荐性能较好, 侧面证明了深度学习在跨域推荐上具有高效性。

EMCDR 作为与本文提出的模型最为相关的一种, 都是利用 MLP 进行跨域映射。通过对比 EMCDR、CDDF 和 CDDAF 发现, 推荐效果最好的是 CDDAF, EMCDR 次之, CDDF 最差。由此可见, CDDF 的特征提取能力最弱, 本文猜测原因在于聚合每个融合特征时, 模型都赋予了相同的贡献度, 而实际上这种操作会损害到模型的性能, 因为并不是每个评论 - 评分对都有意义。而 EMCDR 的特征提取能力次之, 原因在于 EMCDR 的特征提取基于评分矩阵, 评分矩阵稀疏程度影响推荐效果。而与 EMCDR 相比, 在不同冷用户的比例下, CDDAF 在 RMSE 评价指标上都能取到 2% 到 9% 的提升, 与 CDDF 相比, CDDAF 在 RMSE 评价指标有大幅度的提升, 原因在于 CDDAF 不依赖于评分矩阵的稀疏程度, 而 CDDAF 结合 Attention 后, 模型赋予了融合特征不同的权重, 反映出融合特征的动态方面变化表示。因此, 本文所提出的 CDDAF 模型是有效且合理的。

5. 结束语

本文在已有的单域推荐模型上, 设计了一种利用注意力机制对评论 - 评分对的融合特征进行打分的方法来获取不同域的潜在特征, 并基于 MLP 实现跨域推荐。通过与类似的跨域算法进行对比实验, 实验

表明本文设计的模型推荐性能较好。对于下一步工作，本文可以考虑分两个模块处理评论和评分向量，也可以考虑使用 BERT 技术，结合 GRU 和 Attention 的方式来提取特征。

基金项目

广东省科技厅项目(2016A070708002, 2015A070706001, 2014A070708005); 研究生教育创新计划(2016SFKC_42, YJS-SFKC-14-05, YJS-PYJD-17-03)资助; 教育部“云数融合、科教创新”基金项目(2017B02101); 江门市基础与理论科学研究类科技计划项目(2017JC01021)资助。

参考文献

- [1] Man, T., Shen, H., Jin, X., *et al.* (2017) Cross-Domain Recommendation: An Embedding and Mapping Approach. *Twenty-Sixth International Joint Conference on Artificial Intelligence*, Melbourne, August 2017, 2464-2470. <https://doi.org/10.24963/ijcai.2017/343>
- [2] 王兴华. 基于潜在特征映射的跨域推荐方法研究[D]: [硕士学位论文]. 济南: 山东大学, 2018.
- [3] Liu, D., Li, J., Du, B., *et al.* (2019) DAML: Dual Attention Mutual Learning between Ratings and Reviews for Item Recommendation. In: *The 25th ACM SIGKDD International Conference*, ACM, New York, 1233-1236. <https://doi.org/10.1145/3292500.3330906>
- [4] Chen, C., Zhang, M., Liu, Y., *et al.* (2018) Neural Attentional Rating Regression with Review-Level Explanations. *Proceedings of the 2018 World Wide Web Conference on World Wide Web*, Lyon France, April 2018, 1583-1592. <https://doi.org/10.1145/3178876.3186070>
- [5] 宋天航. 基于评论挖掘的跨域推荐问题研究[D]: [硕士学位论文]. 济南: 山东大学, 2017.
- [6] 蔡泳. 基于评论信息的跨领域商品推荐研究[D]: [硕士学位论文]. 广州: 华南理工大学, 2019.
- [7] Kim, Y. (2014) Convolutional Neural Networks for Sentence Classification. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing*, Doha Qatar, 1746-1751. <https://doi.org/10.3115/v1/D14-1181>
- [8] Yin, W., Schütze, Hinrich, Xiang, B., *et al.* (2015) ABCNN: Attention-Based Convolutional Neural Network for Modeling Sentence Pairs. <https://doi.org/10.1162/tacl.2015.00244>
- [9] Ruck, D.W. and Rogers, S.K. (1990) The Multilayer Perceptron as an Approximation to a Bayes Optimal Discriminant Function. *IEEE Transactions on Neural Networks*, **1**, 296-298. <https://doi.org/10.1109/72.80266>
- [10] Cao, B., Liu, N.N. and Yang, Q. (2010) Transfer Learning for Collective Link Prediction in Multiple Heterogenous Domains. *International Conference on Machine Learning*, Madison, WI, June 2010, 159-166.
- [11] Zhang, Y., Cao, B. and Yeung, D.Y. (2012) Multi-Domain Collaborative Filtering. *Proceedings of the 26th Conference on Uncertainty in Artificial Intelligence*, Catalina Island, July 2010, 725-732.
- [12] Hu, L., Cao, J., Xu, G., *et al.* (2013) Personalized Recommendation via Cross-Domain Triadic Factorization. *The 22nd International Conference*, Rio de Janeiro Brazil, May 2013, 595-606. <https://doi.org/10.1145/2488388.2488441>
- [13] Pan, W., Xiang, E.W., Liu, N.N., *et al.* (2010) Transfer Learning in Collaborative Filtering for Sparsity Reduction. *Twenty-Fourth AAAI Conference on Artificial Intelligence*, Atlanta, July 2010, 230-234.
- [14] Xu, Y., Peng, Z., Hu, Y. and Hong, X. (2018) SARFM: A Sentiment-Aware Review Feature Mapping Approach for Cross-Domain Recommendation. In: *International Conference on Web Information Systems Engineering*, Springer, Cham, 3-18. https://doi.org/10.1007/978-3-030-02925-8_1
- [15] 付文静. 基于评论和内容深度融合的跨域推荐问题研究[D]: [硕士学位论文]. 济南: 山东大学, 2019.
- [16] Vincent, P., Larochelle, H., Lajoie, I., *et al.* (2010) Stacked Denoising Autoencoders: Learning Useful Representations in a Deep Network with a Local Denoising Criterion. *Journal of Machine Learning Research*, **11**, 3371-3408.
- [17] Maharjan, S., Montes-Y-Gómez, M., González, F.A., *et al.* (2018) A Genre-Aware Attention Model to Improve the Likability Prediction of Books. *Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing*, Brussels, 31 October-4 November 2018, 3381-3391. <https://doi.org/10.18653/v1/D18-1375>
- [18] McAuley, J., Pandey, R. and Leskovec, J. (2015) Inferring Networks of Substitutable and Complementary Products. *Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, Sydney, August 2015, 785-794. <https://doi.org/10.1145/2783258.2783381>
- [19] Mikolov, T., Chen, K., Corrado, G., *et al.* (2013) Efficient Estimation of Word Representations in Vector Space.

-
- [20] Lee, D.D. and Seung, H.S. (2000) Algorithms for Non-Negative Matrix Factorization. In: *International Conference on Neural Information Processing Systems*, MIT Press, Cambridge, 535-541.
- [21] Singh, A.P. and Gordon, G.J. (2008) Relational Learning via Collective Matrix Factorization. *ACM Sigkdd International Conference on Knowledge Discovery & Data Mining*, Las Vegas Nevada, August 2008, 650-658.

RETRACTED