

基于评论情感向量化表示的双向跨域推荐

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: 2021年1月17日; 录用日期: 2021年2月12日; 发布日期: 2021年2月19日

摘要

多数跨域推荐模型在利用评论文本进行跨域推荐时, 没有考虑到评论文本中的情感信息。而对于考虑到评论情感信息的跨域模型多数都是进行单向跨域推荐。因此, 本文提出一种基于评论情感向量化的双向跨域推荐模型。该模型对不同领域的评论文本利用bert + Transformer方法进行评论情感分类, 得到隐含用户情感信息的情感向量化表示, 再从中计算相对应的用户偏好向量和商品特征向量, 然后根据生成的特征向量进行跨域推荐。对于跨域学习, 本文在神经因子分解机(NFM)模型的基础上利用潜在正交映射函数学习两个域内的用户偏好以及跨域学习到的用户偏好, 从而进行双向推荐。通过在四组数据集上进行对比实验, 实验结果表明, 该模型能有效缓解了数据稀疏的问题。

关键词

跨域推荐, 评论文本, 情感向量化, 潜在正交映射

Dual Cross Domain Recommendation Based on Sentiment Vectorization of Reviews

Yafang He, Xinglin Liu, Xiaobai Zheng

Faculty of Intelligent Manufacturing, Wuyi University, Jiangmen Guangdong

Email: avon_he@126.com

Received: Jan. 17th, 2021; accepted: Feb. 12th, 2021; published: Feb. 19th, 2021

Abstract

When most cross-domain recommendation models use review text for cross-domain recommendation, they do not consider the emotional information in the review text. For cross-domain models that take into account the emotional information of comments, most of them are one-way cross-domain recommendations. Therefore, this paper proposes a dual cross-domain recommendation

model based on comment sentiment vectorization. The model uses the bert + Transformer method to classify the review emotions of review texts in different fields, and obtains the emotion vectorized representation of the implicit user emotion information, and then calculates the corresponding user preference vector and product feature vector from it, and then cross domain recommendation is carried out according to the generated feature vectors. For cross-domain learning, based on the neural factorization machine (NFM) model, this paper uses the latent orthogonal mapping function to learn the user preferences in the two domains and the user preferences learned across domains, so as to perform two-way recommendation. Through comparative experiments on four datasets, the experimental results show that the model can effectively alleviate the problem of data sparseness.

Keywords

Cross Domain Recommendation, Review Text, Sentiment Vectorization, Potential Orthogonal Mapping

Copyright © 2021 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

多数单领域推荐不能有效解决数据稀疏和冷启动问题,无法满足用户的需求,因此跨域推荐成为了推荐系统的热点之一。跨域推荐指通过把用户在领域 A 中丰富的反馈信息的知识迁移到用缺乏该用户反馈信息的领域 B 中进行商品推荐。因此,研究人员对于跨域推荐的研究多数是基于知识迁移上进行的[1]。而在研究跨域推荐过程中,常用的反馈信息是评论文本[2][3],原因在于评论文本中蕴含着丰富的用户偏好信息和商品特征信息,适合进行知识迁移。

然而,现有的多数跨域推荐模型都是基于数据密集的领域向数据稀疏的领域进行知识迁移的方式进行单向推荐[2][3][4],这些模型利用两个领域中的共同用户作为桥梁进行知识迁移,从而利用辅助域中的丰富信息来提高目标域的推荐效果,但这也意味着它们并没有利用目标域中的信息来帮助辅助域。然而,不同领域下的用户数据具有丰富性和多样性,如果可以同时利用这些用户的知识进行双向迁移,实现双向推荐,更能充分利用两个领域的知识,有利于缓解数据稀疏的问题。

基于上述问题,本文提出一种基于评论情感信息量化的双向跨域推荐模型(Dual Cross Domain Recommendation based on Sentiment Vectorization of Reviews, RSCDR)。该模型利用 bert [5] + Transformer [6]的方式对每条评论文本中的情感信息进行文本情感向量化,并分别计算出用户偏好向量和商品特征向量;然后,利用潜在正交映射的方式同时对两个领域进行跨域推荐,即在两个领域中,利用正交映射函数将用户的偏好从域 A 中迁移到域 B 中(反之亦然)。最后,本文利用 NFM [7]进行评分预测。

2. 相关研究

单向跨域推荐的核心在于辅助域的知识如何迁移到目标域中。Xu 等[2]认为利用评论文本中丰富的情感信息进行跨域推荐,能更好挖掘出用户偏好。因此, Xu 提出了一种新型的情感信息提取模型,该模型通过自动识别用户评论的语义方向提取出评论文本中的情感信息,并利用多层感知机 MLP [8]将辅助域中的情感信息向目标域中迁移,从而进行跨域推荐。Fu 等[3]利用扩展的堆叠降噪自编码器(SDAE) [9]将

多种辅助信息和评分矩阵进行融合,从而提取出不同领域下的潜在特征,再通过 MLP 来学习不同领域之间的特征映射。文献[10]利用情感分类器对不同领域的每条评论文本进行情感分类,并计算出两个领域内共同用户兴趣向量,再利用领域自适应网络分离出不同领域之间的共享的用户兴趣向量后再进行迁移的方法来进行跨域推荐。

对于多目标跨域推荐,多数文献利用两个领域中共同用户的共享特征进行跨域学习。文献[10]通过扩展 DeepCoNN [11]模型,提出了一种基于卷积神经网络(CNN) [12]的多域产品推荐模型 CCoNN,该模型利用多个域之间的公共用户评论信息生成用户偏好向量和项目特征向量,并在多任务学习(MTL) [13]的基础上通过分解机(FM) [14]对用户-产品对进行总体评级预测。Zhu 等[15]认为利用丰富的用户反馈信息就有可能同时提高两个领域的推荐性能,而不是单一的目标域。为此,Zhu 等提出了一种双目标跨域推荐模型来解决现有的单目标跨域推荐的局限性,该模型利用评分和评论文本信息生成用户和项目的评分和文档嵌入,并在多任务学习的基础上,设计了一种可适应的嵌入共享策略来组合共享跨域的公共用户嵌入,再利用 NCF [16]实现双目标跨域推荐,以用来提高推荐性能。而文献[17]提出了一种基于双重学习机制的跨域推荐的新方法,即利用潜在正交映射函数来提取不同领域中的用户偏好信息,同时保持不同潜在空间中用户之间的关系后,进行双向迁移,从而提高不同领域之间的推荐性能。

在文献[10]和文献[17]的研究基础上,本文提出一种基于评论情感向量化的双向跨域推荐模型。该模型利用情感分类的方法进行特征提取,并利用所提取的情感向量化计算出用户偏好和商品特征,再通过潜在正交映射函数进行双向跨域学习,从而预测出不同领域下用户对商品的评分。

3. 模型设计与分析

3.1. 评论情感信息向量化

用户在对商品进行评价时,给出的评分具有用户对商品的情感打分,而评论文本中往往包含着用户偏好信息和商品特征信息。评分的高低决定了用户对商品的喜爱程度,因此可以从评论文本中进行用户情感分析,从而挖掘出更深层次的用户偏好和商品特征。文献[18]提出了一种具有评论感知的推荐模型 SentiRec,该模型将每个评论文本编码为固定大小的评论向量,并对评论向量进行训练以体现评论文本的情感。文献[10]参照 SentiRec 模型,利用 word2vec [19] + CNN + 逻辑斯蒂回归的方式提取每一条评论文本的情感向量,再计算出对应的用户向量和商品特征。在文献[10]研究方法的基础上,本文利用 bert+Transformer 的方式挖掘出每条评论文本中隐含的用户情感向量。

多数电商平台把评分值设定在 1 到 5 之间,本文将情感阈值设定在 3。本文利用评分值来为每一条评论文本添加一个情感标签:当评分大于或等于 3 时,对应的评论文本的情感标签为积极,而小于 3 时,对应的评论文本的情感标签为消极;然后,通过情感分类器将评论情感标签融入到评论文本向量中,生成特定的用户情感向量,最终获取到对应的用户偏好向量和商品特征向量。

bert 模型具有多层 Transformer [6]结构,而 Transformer 是一种基于 Attention 机制进行特征提取的提取器。从图 1 中可以看出,Transformer Encoder 的结构包括自注意力和前馈神经网络。首先,自注意力对整条评论文本的单词序列进行关注,并帮助模型对单词进行编码,获取到评论文本的上下文语义,再将数据输送到前馈神经网络中进行计算。本文首先通过 bert 模型将评论文本的单词转换为词向量,再利用 Transformer 为编码器的方式进行特征提取,并利用分类器进行情感分类。处理流程如图 1 所示:

文献[6]指出 Transformer 并不包含递归和卷积,因此 Transformer 为 word embeddings 添加了位置编码,用来识别序列中的单词顺序。本文利用正弦函数 sin 和余弦函数 cos 的线性变换来提供位置信息:

$$PE(pos, 2i) = \sin\left(\frac{pos}{10000^{2i/d_{model}}}\right) \quad (1)$$

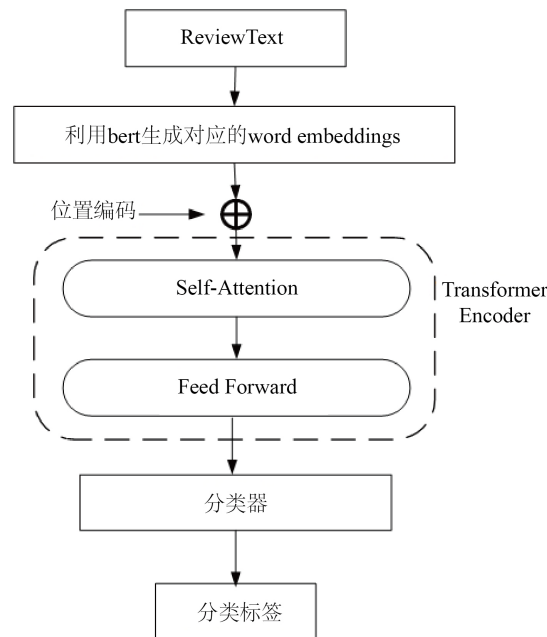


Figure 1. Sentiment classifier
图 1. 情感分类器

$$PE(pos, 2i+1) = \cos\left(\frac{pos}{10000^{2i/d_{model}}}\right) \quad (2)$$

模型把从 Transformer 解码器中提取到的特征向量输入到分类器中进行情感分类。然而，此时经过情感分类器得到的是每条评论文本的评论情感向量 $vector_{ui}$ ，文献[10]表明，用户和商品的关系存在一对多或多对多的，因此还需要将用户和商品对应的所有评论文本进行平均化，即：

$$u = \frac{\sum_i vector_{ui}}{len(I_u)}, i \in I_u \quad (3)$$

$$i = \frac{\sum_u vector_{ui}}{len(U_i)}, u \in U_i \quad (4)$$

其中， I_u 表示用户 u 对所有商品进行过评论的集合， U_i 表示对商品 i 进行过评论的用户集合。

通过上述方法，本文得到了两个不同领域中的用户偏好向量 u 和商品特征向量 i ，用来作为下一个模块的输入。

3.2. 基于 NFM 的跨域学习

本文设置的场景为两个领域存在相同的用户，他们都在两个领域中购买了商品。根据文献[17]的描述，如果两个用户在领域 A 中有类似偏好，那么他们在领域 B 中也应该存在着相似的偏好。因此，为了解领域 A 中的偏好，可以将领域 B 的用户偏好和它们组合在一起，反之亦然。文献[17]提出在两个 NCF 模型上进行双重迁移学习推荐，利用潜在的正交映射，在源域和目标域之间同时迁移用户偏好，最终得到不同领域的用户评分。然而，交互特征对于用分评分预测是非常重要的，深入考虑稀疏的特征之间的交互，挖掘出交互特征的深层次含义，有助于提高模型的迁移能力，从而提高模型的性能。因此，基于该文献提出的潜在正交映射函数的方法上，本文利用 NFM 模型进行评分预测。

框架如图 2 所示, r_{within} 表示域内学习, 用于预测目标域的用户偏好。 r_{cross} 表示通过利用潜在正交映射函数对源域用户进行操作, 捕获不同领域的差异性。因此, 两个领域的最终评分定义为

$$\hat{r}_A = (1-\alpha)NFM_A(u_A, i_A) + \alpha NFM_B(X * u_A, i_A) \tag{5}$$

$$\hat{r}_B = (1-\alpha)NFM_B(u_B, i_B) + \alpha NFM_A(X^T * u_B, i_B) \tag{6}$$

其中, α 表示两个 NFM 模型在预测用户偏好方面的相对重要性。

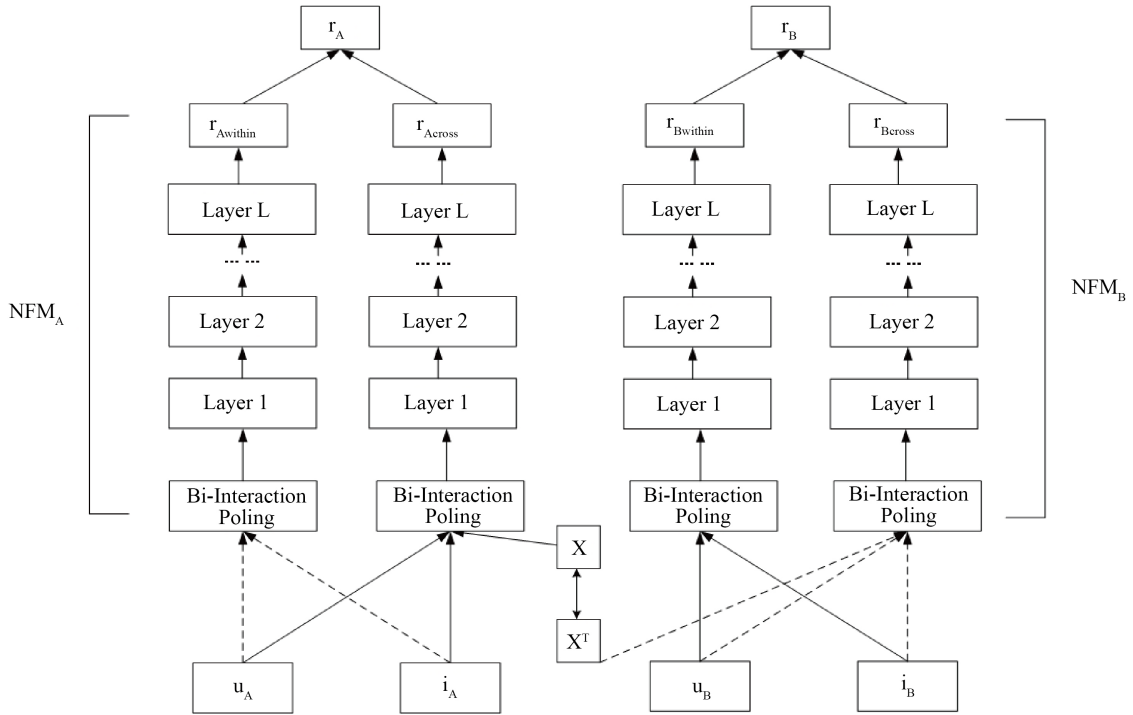


Figure 2. Potential orthogonal mapping on NFM model
图 2. NFM 模型上的潜在正交映射

用户评分的预测是基于文献[7]提出的 NFM 模型, NFM 模型因为在 embedding 层和 MLP 网络之间添加了一个特征交叉池化层, 从而能提取到深层次的交互特征。

对于 NFM 的 embedding 层, 本文直接把上一节中计算得到的用户偏好特征 u 和商品特征 v 充当网络输入的嵌入向量。本文通过相乘的方式来组合这两个特征, 定义如下:

$$x = u * v \tag{7}$$

NFM 模型的定义公式如下:

$$\hat{r}(x) = w_0 + \sum_{i=1}^n w_i x_i + f(x) \tag{8}$$

其中, x 表示两个特征组合成的交互特征, w_0 表示全局偏差, $x_i \in x$ 表示交互特征 i 的值, w_i 表示潜在特征向量的系数, $f(x)$ 代表 Bi-Interaction pooling, 一个多层前馈神经网络, 其公式定义如下:

$$f_{Bi}(x) = \frac{1}{2} \left[\left(\sum_{i=1}^n x_i v_i \right)^2 - \sum_{i=1}^n (x_i v_i)^2 \right] \tag{9}$$

而在 Bi-Interaction pooling 之上是一堆连接层, 用于学习特征之间的高阶交互, 从而获的更深层次的特征交互。NFM 模型的评分预测公式如下:

$$\hat{r}(x) = w_0 + \sum_{i=1}^n w_i x_i + h^T \sigma_L \left(W_L \left(\cdots \sigma_1 \left(W_1 f_{BI}(V_x) + b_1 \right) \cdots \right) + b_L \right) \quad (10)$$

其中, L 表示隐藏层数, W_l 、 b_l 、 σ_l 分别为第 l 层权重矩阵、第 l 层偏置向量和第 l 层激活函数。

3.3. 损失函数和目标函数

在评论文本情感向量化中, 本文利用交叉熵损失函数作为整个情感分类器的损失函数, 该公式定义如下:

$$l(y, \hat{y}) = y \log \hat{y} + (1 - y) \log (1 - \hat{y}) \quad (11)$$

而基于 NFM 的跨域学习中, 根据文献[17]描述, 设 V_A 、 V_B 分别为评分矩阵, 则模型的目标函数可以定义为:

$$\min |V_A - \hat{r}_A| + |V_B - \hat{r}_B| \quad (12)$$

其中, \hat{r}_A 、 \hat{r}_B 分别表示公式(6)和(7)。

4. 实验方案与结果分析

4.1. 数据集

本文选择的数据集是公开的 Amazon 数据集[20], 该数据包含不同类型的领域。本文选取了以下 5 个商品域中进行实验(表 1), 分别为 Movies_and_TV (Movie)、Books (Book)、Apps_and_Android (Android)、Toys_and_Games (Toy)、CDs_and_Vinyl_5 (Music)。由于 Movie、Book 和 Music 数据集过大, 因此本文对着三个数据集进行数据筛选。比如, 在“Movie-Book”数据中, 先筛选出商品数大于或等于 150 的商品, 再从中筛选用户数大于或等于 15 的用户。

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(%)
Android	848	4016	35831	0.2%
Toy		5330	40029	0.27%
Movie	990	2134	258776	3.05%
Book		5334	197328	0.9%
Movie	797	3498	287951	2.57%
Music		7498	258765	1.03%
Book	1107	7812	177222	0.49%
Music		7324	205100	0.6%

4.2. 数据预处理和参数设计

bert 预训练模型中使用的是 Transformers 提供的 Bert-base-uncased, 它的结构是 12 层的 Transformers, 输出层维度为 512 层, 隐向量的维度为 32。另外, 本文将所有数据集按照 8:1:1 的比例划分为训练集、

验证集和测试集。学习速率设为 0.002，dropout 设为 0.5，优化器为 Adam。

4.3. α 的取值

由公式(6)和(7)可得， α 的取值影响整个模型的性能。 α 表示指引两个领域中用户偏好的重要性。因此， α 取适宜数值才能让模型发挥更好的作用。文献[17]表明， α 取 0 到 0.2 之间的正值，模型的效果最好。但根据图 3 实验结果，本文模型在这个取值范围得到的结果并没达到最好的效果，原因可能在于模型不同、收敛性不同、数据集稀疏程度不同等。因此，本文将 α 的取值分别设置为 0.03, 0.1, 0.3, 0.5, 0.7, 0.9，并进行对比，从中挑选出 α 值，使得模型效果最好。

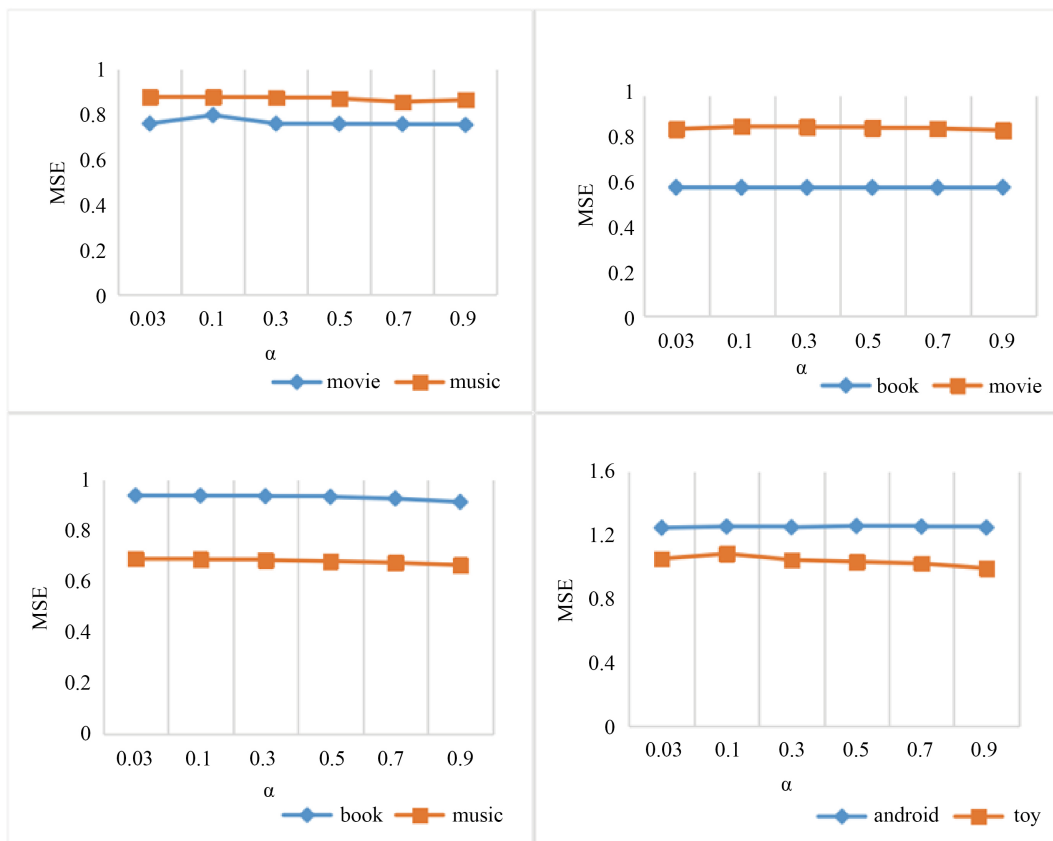


Figure 3. MSE values in different parameter α

图 3. 参数 α 对 MSE 值的影响

图 3 显示了不同 α 值对模型性能的影响，通过观察四个表的 MSE 可以发现， α 对不同的数据集的影响是不相同的，经过多次实验发现，当 $\alpha = 0.9$ 时，模型的性能较好。因此，本文将 α 的值设为 0.9。

4.4. 对比模型

本文采用均方误差 MSE 作为评价指标，MSE 值越低表示模型的性能越好，其公式如下：

$$\text{MSE} = \frac{1}{N} \sum_{n=1}^N (\hat{r}_{ui} - r_{ui})^2 \quad (11)$$

其中， N 表示样本个数， \hat{r}_{ui} 表示在模型中获得的预测评分， r_{ui} 表示可以真实评分。

本文选取了以下几个基线模型进行对比分析：

- 1) FM: 一种基于矩阵分解的模型, 可以解决由数据稀疏引起的特征组合问题。
 - 2) NFM: 在 FM 模型上, 引入 Bi-Interaction pooling 进行评分预测。
 - 3) DDTCDR: 该模型在 NCF 模型的基础上利用潜在正交映射进行跨域推荐。根据文献描述, 在 α 取 0 到 0.2 之间的正值, 模型的效果最好。在该模型中, 本文把 α 值设为 0.03。
- 所有模型的嵌入向量来自评论情感向量化生成的用户偏好特征和商品特征。
另外, FM、NFM 模型部分代码参考文献[21]。

4.5. 实验结果和分析

在四组数据集上进行实验分析, 粗体表示该组数据集中得到的最优结果。
如表 2 所示, 从总体上看, 相对于其他模型, 本文模型的性能效果较好。

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	FM	NFM	DDTCDR	RSCDR
Movie	0.6413	0.5846	0.8811	0.5855
Book	0.8926	0.8660	1.1303	0.8450
Movie	0.8115	0.7614	1.1164	0.7551
Music	0.9321	0.8810	1.2702	0.8662
Book	0.9520	0.9347	1.1966	0.9113
Music	0.7103	0.6905	0.9484	0.6643
Android	2.0938	1.2587	1.3605	1.2513
Toy	2.2199	1.0167	0.8647	0.9951

FM 模型和 NFM 模型进行对比, 可以发现 NFM 模型在特征提取的能力比 FM 强。将 FM 模型和 RSCDR 模型进行比较, 可以观察到 RSCDR 的性能提升不少。

RSCDR 模型基于 NFM 模型, 通过进行对比, RSCDR 在三个数据组中取得最优结果, 在“Movie-Book”实验组中, RSCDR 模型和 NFM 模型在 Movie 数据集结果相差很小, 但在同组的 Book 数据集中, RSCDR 模型比 NFM 提高了 2.1%。同时, 在“Movie-Music”数据组中, RSCDR 分别提高 0.64%和 1.48%, 在“Book-Music”和“Android-Toy”数据组中, RSCDR 比 NFM 模型分别提高了 2.33%、2.61%、0.74%和 2.16%, 由此可见, 利用潜在正交矩阵进行跨域推荐 RSCDR 模型能够有效解决推荐系统中数据稀疏的问题。

DDTCDR 模型与本文模型最为相似, 都是利用了潜在正交矩阵进行跨域映射, 进行双向推荐。但从本文实验结果上看, 只有在“Android-Toy”数据组的 Toy 数据集中, RSCDR 模型的性能比不上 DDTCDR 模型, 但在其余三组数据组中, DDTCDR 模型取得的效果并不明显, RSCDR 的 MSE 值均能比 DDTCDR 要低。因此, 在本实验中, 从总体上说明基于 NFM 的 RSCDR 模型能有效挖掘出交互特征的深层含义, 能够提高跨域推荐的性能。

5. 结束语

本文利用情感分类器对不同领域的评论文本中的情感进行分类, 将评论进行情感向量化, 并从中计算出用户偏好特征和商品特征, 并在 NFM 模型上利用潜在正交函数进行双向迁移, 实现双向跨域推荐。通过实验证明该模型的在跨域推荐上具有较好的效果。因此, 在下一步工作中, 可以深入研究, 不同特

征提取方式对潜在正交映射的影响。

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] Cantador, I., Fernández-Tobías, I., Berkovsky, S. and Cremonesi, P. (2015) Cross-Domain Recommender Systems. In: *Recommender Systems Handbook*, Springer, Berlin, 919-959. https://doi.org/10.1007/978-1-4899-7637-6_27
- [2] Xu, Y., Peng, Z., Hu, Y., et al. (2018) SARMF: A Sentiment-Aware Review Feature Mapping Approach for Cross-Domain Recommendation. *International Conference on Web Information Systems Engineering*, Dubai, 12-15 November 2018, 3-18. https://doi.org/10.1007/978-3-030-02925-8_1
- [3] Fu, W.J., Peng, Z.H., Wang, S.Z., et al. (2019) Deeply Fusing Reviews and Contents for Cold Start Users in Cross-Domain Recommendation Systems. *Proceedings of the AAAI Conference on Artificial Intelligence*, **33**, 94-101. <https://doi.org/10.1609/aaai.v33i01.330194>
- [4] Wang, X.H., Peng, Z.H., Wang, S.Z., et al. (2020) CDLMF: Cross-Domain Recommendation for Cold-Start Users via Latent Feature Mapping. *Knowledge and Information Systems*, **62**, 1723-1750.
- [5] Devlin, J., Chang, M.W., Lee, K., et al. (2018) BERT: Pre-Training of Deep Bidirectional Transformers for Language Understanding.
- [6] Vaswani, A., Shazeer, N., Parmar, N., et al. (2017) Attention Is All You Need. *Proceedings of Conference of Neural Information Processing Systems*, Long Beach, 2017, 6000-6010.
- [7] He, X.G. and Chua, T.S. (2017) Neural Factorization Machines for Sparse Predictive Analytics. <https://doi.org/10.1145/3077136.3080777>
- [8] 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. <https://doi.org/10.1109/72.80266>
- [9] Vinceny, 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.
- [10] 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.
- [11] Zheng, L., Noroozi, V. and Yu, P.S. (2017) Joint Deep Modeling of Users and Items Using Reviews for Recommendation. *Proceedings of the Tenth ACM International Conference on Web Search and Data Mining*, Cambridge, 6-10 February 2017, 425-434. <https://doi.org/10.1145/3018661.3018665>
- [12] Kim, Y. (2014) Convolutional Neural Networks for Sentence Classification. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing*, Doha, 25-29 October 2014, 1746-1751. <https://doi.org/10.3115/v1/D14-1181>
- [13] Caruana, R. (1997) Multitask Learning. *Machine Learning*, **28**, 41-75. <https://doi.org/10.1023/A:1007379606734>
- [14] Rendle, S. (2010) Factorization Machines. *IEEE International Conference on Data Mining*, Sydney, 13-17 December 2010, 995-1000. <https://doi.org/10.1109/ICDM.2010.127>
- [15] Zhu, F., Chen, C., Wang, Y., et al. (2019) DTCDDR: A Framework for Dual-Target Cross-Domain Recommendation. *The 28th ACM International Conference*, Huntsville, 27-30 October 2019, 1533-1542. <https://doi.org/10.1145/3357384.3357992>
- [16] He, X.N., Liao, L.Z., Zhang, H.W., Nie, L.Q., Hu, X. and Chua, T.-S. (2017) Neural Collaborative Filtering. In: *Proceedings of the 26th International Conference on World Wide Web (WWW = 17)*, International World Wide Web Conferences Steering Committee, Geneva, 173-182.
- [17] Li, P. and Tuzhilin, A. (2019) DDTCDDR: Deep Dual Transfer Cross Domain Recommendation. <https://doi.org/10.1145/3336191.3371793>
- [18] Hyun, D., Park, C., Yang, M.C., Song, I., Lee, J.T. and Yu, H. (2018) Review Sentiment-Guided Scalable Deep Recommender System. <https://doi.org/10.1145/3209978.3210111>
- [19] Mikolov, T., Chen, K., Corrado, G., et al. (2013) Efficient Estimation of Word Representations in Vector Space.
- [20] McAuley, J., Pandey, R. and Leskovec, J. (2015) Inferring Networks of Substitutable and Complementary Products.

Proceedings of the 21st ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Sydney, 10-13 August 2015, 785-794. <https://doi.org/10.1145/2783258.2783381>

- [21] Sun, Z., Yu, D., Fang, H., Qu, X., Zhang, J. and Geng, C. (2020) Are We Evaluating Rigorously? Benchmarking Recommendation for Reproducible Evaluation and Fair Comparison. *RecSys'20: Fourteenth ACM Conference on Recommender Systems*, New York, 23-32. <https://doi.org/10.1145/3383313.3412489>