

基于评论方面级用户偏好迁移的跨领域推荐算法

张佳, 董守斌

引用本文

张佳, 董守斌. [基于评论方面级用户偏好迁移的跨领域推荐算法](#)[J]. 计算机科学, 2022, 49(9): 41-47.

ZHANG Jia, DONG Shou-bin. [Cross-domain Recommendation Based on Review Aspect-level User Preference Transfer](#)[J]. Computer Science, 2022, 49(9): 41-47.

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)

[基于非局部注意力生成对抗网络的视频异常事件检测方法](#)

Non-local Attention Based Generative Adversarial Network for Video Abnormal Event Detection

计算机科学, 2022, 49(8): 172-177. <https://doi.org/10.11896/jsjcx.210600061>

[基于 DNGAN 的磁共振图像超分辨率重建算法](#)

Super-resolution Reconstruction of MRI Based on DNGAN

计算机科学, 2022, 49(7): 113-119. <https://doi.org/10.11896/jsjcx.210600105>

[基于时频域生成对抗网络的语音增强算法](#)

Speech Enhancement Based on Time-Frequency Domain GAN

计算机科学, 2022, 49(6): 187-192. <https://doi.org/10.11896/jsjcx.210500114>

[基于特征感知的数字壁画复原方法](#)

Digital Mural Inpainting Method Based on Feature Perception

计算机科学, 2022, 49(6): 217-223. <https://doi.org/10.11896/jsjcx.210500105>

[基于生成对抗网络的 5G 网络流量预测方法](#)

Traffic Prediction Method for 5G Network Based on Generative Adversarial Network

计算机科学, 2022, 49(4): 321-328. <https://doi.org/10.11896/jsjcx.210300240>

基于评论方面级用户偏好迁移的跨领域推荐算法

张 佳 董守斌

华南理工大学计算机科学与工程学院 广州 510006

中山市华南理工大学现代产业技术研究院 广东 中山 528437

(cszhangjia@mail.scut.edu.cn)

摘 要 为解决推荐系统中数据稀疏造成的用户冷启动问题,文中提出了一种基于方面级用户偏好迁移的跨领域推荐算法(Cross-Domain Recommendation via Review Aspect-Level User Preference Transfer, CAUT),设计了基于两阶段生成对抗网络的用户方面级偏好跨领域迁移结构,通过用户历史评论挖掘用户细粒度方面级偏好。CAUT 利用预训练源领域编码器参数对目标领域编码器进行参数初始化,在固定源领域编码器参数的同时引入领域鉴别器,以解决源领域与目标领域数据分布差异的问题,进而可以有效利用源领域的丰富数据,缓解目标领域数据稀疏造成的用户冷启动问题。在亚马逊电商平台真实数据集上进行了实验,结果表明,与最新算法相比,CAUT 在用户对商品的评分预测均方根误差(RMSE)指标上有明显的提升,说明 CAUT 可有效缓解用户冷启动问题。

关键词: 跨领域推荐;方面级用户偏好;用户冷启动;生成对抗网络

中图法分类号 TP391

Cross-domain Recommendation Based on Review Aspect-level User Preference Transfer

ZHANG Jia and DONG Shou-bin

School of Computer Science and Engineering, South China University of Technology, Guangzhou 510006, China

Zhongshan Institute of Modern Industrial Technology of SCUT, Zhongshan, Guangdong 528437, China

Abstract In order to solve the user cold-start problem caused by data-sparse in recommender system, this paper proposes a cross-domain recommendation algorithm based on aspect-level user preference transfer, named CAUT. CAUT is devised to learn aspect transfer across domains from a two-stage generative adversarial network and extract aspect-level user fine-grained preference from reviews. The data distribution misalignment between source and target domains is eliminated by fixing source domain encoder parameters and designing a domain discriminator. Then the user cold-start problem caused by data-sparse in the target domain could be alleviated by utilizing source domain data via CAUT. Experiments on real-world datasets show that the proposed CAUT outperforms SOTA models significantly in rating prediction RMSE indicator, suggesting that CAUT can effectively solve the user cold-start problem.

Keywords Cross-domain recommendation, Aspect-level user preference, Cold-start user, Generative adversarial network

1 引言

推荐系统作为有效的过滤手段,在电商平台为用户从海量信息中筛选其感兴趣的商品。传统推荐算法可以分为协同过滤、基于内容或混合推荐的方法,然而这些方法的有效性通常依赖于用户与商品丰富的历史交互。当用户在平台中只拥有非常少的交互记录时,少量的用户交互数据产生的数据稀疏问题会使得传统推荐算法失效,导致冷启动问题。

跨领域推荐旨在使用源领域的丰富知识作为辅助信息缓解目标领域的数据稀疏问题,提升目标领域的个性化推荐效果^[1-5]。已有的研究通过构建联合协同过滤矩阵^[5]、共享参数^[3]或共享数据^[6]等方法实现信息的跨域流动。但跨领域

推荐仍然存在巨大挑战,这是因为源领域与目标领域间的数据分布存在巨大差异,导致信息迁移并不总是有效的。

用户评论作为隐式反馈反映了用户对商品的主观评价与描述,是推荐系统中重要的辅助信息。基于评论进行用户偏好建模是近年来个性化推荐的研究热点^[7-12]。区别于直接将评论编码为简单特征向量的方法,方面级用户偏好建模方法 ANR^[7]通过提取细粒度的方面级知识对用户进行偏好建模。基于不同领域的方面级用户建模,有望实现细粒度的用户偏好迁移。但源领域和目标领域的用户方面级特性差异较大,如何挖掘具有较大共性的方面级特性并进行迁移是一项很大的挑战。为解决上述问题,本文提出了基于评论方面级用户偏好迁移的跨领域推荐算法 CAUT 模型,设计了基于迁移

学习的知识跨领域迁移结构,利用评论文本挖掘用户潜在的方面级偏好,将数据丰富的源领域方面级用户偏好迁移到数据稀疏的目标领域,从而缓解目标领域用户冷启动问题,提升目标领域个性化推荐效果。本文的主要贡献如下:

- (1)设计了基于迁移学习的用户偏好迁移算法,在迁移学习中通过固定源领域编码器参数、引入领域鉴别器等策略来解决源领域与目标领域数据分布差异的问题,从而有效地利用源领域的丰富数据来缓解目标领域数据稀疏带来的用户冷启动问题。
- (2)通过卷积神经网络捕获词在评论中的上下文相关性,结合注意力机制和方面级表示,学习方面级用户偏好,捕获用户细粒度高级的方面级知识特征。
- (3)探索了不同方面个数对用户偏好挖掘的影响,选择最优的方面数组组合进行充分实验,在大型公开的亚马逊数据集中取得了具有竞争力的实验结果。

2 相关工作

2.1 跨领域推荐

传统跨领域推荐方法从知识聚合、知识迁移两种角度利用评分矩阵完成冷启动用户的信息传递^[4]。已有工作把源领域和目标领域用户对商品的评分矩阵整合为统一的联合矩阵来共享用户因子,从而实现知识的跨领域集成^[13]。但当不同领域被作为一个整体考虑时,这些基于协同过滤的工作会受到严重的数据稀疏问题的困扰^[14-15]。本文从基于映射和基于共享的角度介绍了近年来跨领域推荐的相关工作。

Man 等最早提出基于映射的 EMC^{DR}^[1]方法,学习从源领域到目标领域的用户表示映射函数,预测时通过映射源领域的用户表示得到目标领域的用户表示,奠定了基于映射方法的框架基础。在后续的工作中,CDLF^M^[2]等结合协同过滤的方法被陆续提出。

基于共享的跨领域推荐方法可以分为参数共享和数据共享。CoNet^[3],DDTC^{DR}^[16]等基于参数共享的方法在目标领域共享源领域的部分参数,并共同学习更新这些参数。其中,CoNet 的核心为隐藏层的交叉连接单元,通过交叉连接单元来学习两个领域不同层的权重以实现参数共享。此外,基于数据共享的 CD-DNN^[17],DTC^{DR}^[6]等方法直接将源领域数据与目标领域进行共享,从而丰富目标领域数据。PPGN^[18],DMGE^[19]等方法从图的角度实现跨领域推荐,通过构建两个领域的交互异构图,结合图卷积神经网络将推荐任务转换为图链接预测任务。Zhao 等在 CATN^[14]方法中利用辅助信息增强用户表示,在评分预测时进行跨领域方面级特征匹配,从而取得了目前最好的结果。

然而,上述方法大多忽略了评论等丰富的相关内容,只考虑基于评分矩阵的协同过滤方法,部分使用评论文本的方法直接对原始数据进行内容拼接融合,忽略了不同领域数据分布差异的问题。

2.2 基于评论的用户偏好挖掘

用户画像是实现个性化推荐的基础,为了更加精准地

刻画消费者的用户画像,电商平台为用户提供了多种评价反馈的渠道。评分是用户结合多方面评估后给出的一定数值范围内综合评价的显式反馈,具有简单、高效且易于处理等特征。评论是用户对商品的隐式反馈,从更加细致的角度来表达用户对商品的评价和偏好,能在一定程度上缓解推荐系统中的数据稀疏问题。挖掘评论中隐含的用户偏好,可以更加精准地进行用户画像,促进电商平台的用户个性化推荐。

评论文本是隐式反馈式用户对商品的主观评价与描述。以往大量的工作表明^[20],评论文本能有效地缓解基于协同过滤推荐方法中数据稀疏的问题。随着深度学习技术的快速发展,结合深度神经网络的自然语言处理方法也在推荐系统的应用中被广泛关注,DeepCoNN^[8],D-ATTN^[9],HACN^[21]等方法对由用户历史评论组成的用户文档进行知识挖掘,建模用户画像特征。然而,在电商平台中,不是所有评论都是同等重要的,无关评论会影响模型对用户偏好的准确挖掘,基于这一出发点,NARRE^[10],MPCN^[11],HUITA^[12]等评论级方法利用注意力机制对不同的评论赋予不同的重要性,筛选具有代表性的相关评论进行用户画像挖掘。

用户给出的评论包含了用户的多种偏好以及商品的各种特点,只关注单一角度直接将评论文本编码为特征向量的方法忽略了用户偏好和商品特征的多样性^[22]。Chin 等提出方面级用户偏好建模方法 ANR^[7],利用评论文本挖掘用户文档中个性化的方面级偏好,区别于只关注单一角度的方法,方面级用户兴趣偏好是一种细粒度的知识表示,能够从不同的方面对用户进行刻画。然而,ANR 也是一种文档级方法,未区分不同评论的信息,同时也受限于静态词向量带来的语义问题。因此,为了进行更准确的用户方面级兴趣偏好建模,本文设计了 CAUT-Aspect 模块,利用评论中每个词的上下文信息,动态挖掘每一条评论的方面级特征。

3 模型描述

本文使用跨领域推荐来解决个性化推荐中的用户冷启动问题。首先对问题进行符号化描述,相关符号如表 1 所列,然后概述本文提出的基于评论方面级用户偏好迁移的跨领域推荐算法 CAUT,并对每个模块进行详细的介绍。

表 1 相关符号说明
Table 1 Notations and their definitions

符号	说明
$\mathbf{G}$	方面级词表示映射矩阵
D_s	源领域
D_t	目标领域
$\mathbf{M}_u$	用户嵌入矩阵
U^c	冷启动用户集合
P_u	用户方面级偏好
A	领域全局方面表示

3.1 问题描述

D_s 和 D_t 分别表示源领域和目标领域,共享用户为在 D_s 和 D_t 两个领域都有历史交互记录的用户集合, U^c 为冷启动用户集合。其中,冷启动用户指只在源领域有商品交互而在

目标领域中没有交互的用户。对于给定的冷启动用户 $u \in U^c$, 本文的目标是预测其在目标领域对应商品的评分。




图 1 CAUT 跨领域推荐模型框架

Fig. 1 Cross-domain recommendation via aspect-level user preference transfer model

CAUT 的总体结构如图 1 所示, 包含方面级用户偏好提取模块 CAUT-Aspect 和用户方面级偏好跨领域迁移模块。本文使用 D_u 表示用户 u 给出的评论集合, D_i 表示商品 i 收到的评论集合, 使用上标“s”和“t”分别表示源领域和目标领域, 即 D_u^s 表示用户在源领域的评论集合。类似地可以对源领域、目标领域的用户和商品进行表示。在模型的训练中, 利用共享用户作为连接源领域和目标领域的桥梁, 对给定的共享用户 u , 其拥有两个用户文档, 分别为 D_u^s 和 D_u^t 。本文提出的跨领域推荐算法的过程如下:

(1) 使用 D_u^s 和 D_u^t 评论集合作为输入挖掘用户方面级偏好, 得到 P_u^s 和 P_u^t 分别作为用户在源领域和目标领域的方面级偏好; 类似地, 得到两个领域相关的商品特征。

(2) 使用 P_u^s 和 P_u^t 训练跨领域迁移模块, 使得 P_u^s 在迁移后能学习表示用户在目标领域的方面级偏好 P_u^t 。

(3) 对于目标领域的冷启动用户, 使用该用户的源领域方面级偏好 P_u^s 得到目标领域用户方面级偏好 P_u^t , 预测其与目标领域对应商品的评分。

3.2 方面级用户偏好建模

为了更好地理解“方面”, 参考文献[7], 本文对方面做如下定义: 方面是领域细粒度的高级语义知识, 包含领域的特有属性, 例如, 在电子产品领域, 方面可以包含产品功能、电池性能、品牌等信息。

方面级用户偏好建模(CAUT-Aspect)方法如图 2 所示, 包含提取上下文特征的卷积模块、方面级词表示映射模块以及方面级注意力模块。源领域和目标领域中的用户、商品使用相同的过程提取方面级特征, 下文以使用 D_u 挖掘用户方面级偏好为例。




图 2 方面级用户偏好提取模型(CAUT-Aspect)

Fig. 2 Aspect-level user preference extract model

3.2.1 文本输入及卷积层

$D_u = [review_1, review_2, \dots, review_L]$ 是用户文档, 其中每条 $review$ 是用户在当前领域对商品给出的评论, 每条评论有 n 个词, 具体表示为 $review_i = [w_1, w_2, \dots, w_n]$ 。对于用户文档 D_u , 通过预训练的嵌入式词矩阵学习每条评论中词的嵌入式表达 M_u 并将其作为模型的输入, 其中:

$$M_u = [M_{u,1}, M_{u,2}, \dots, M_{u,L}], M_{u,l} \in \mathbf{R}^{n \times d}$$

$$M_{u,l} = [e_1, e_2, \dots, e_n], e_n \in \mathbf{R}^d$$

其中, $M_{u,l}$ 表示用户文档的输入为 l 条评论, 每条评论包含 n 个 d 维的嵌入式词向量。

为了解决静态词向量带来的歧义问题, 本文通过挖掘每个词在句子中的上下文信息来获得更加准确的动态语义表达。使用一维卷积网络, 对矩阵 $M_{u,j}$ 进行卷积计算, 采用窗口大小为 ω 的卷积核提取上下文特征, 得到包含上下文信息的动态词表示特征矩阵。

$$C_j = [c_1, c_2, \dots, c_n], c_i \in \mathbf{R}^d$$

其中, $c_i \in \mathbf{R}^d$ 是评论 j 中第 i 个词结合上下文局部特征得到的词向量, 其计算过程为:

$$c_i = \text{conv}_s(e_{i+\frac{-\omega+1}{2}}, e_{i+\frac{-\omega+3}{2}}, \dots, e_{i+\frac{\omega-1}{2}})^T \quad (1)$$

3.2.2 基于方面的表示学习

对于给定用户的第 j 条评论 $C_{u,j}$, 为了挖掘该评论的方面级特征 $P_{u,j}$, 本文设计方面级词表示映射矩阵, 用于学习每个词在不同方面的特征表示。

$$G = [g_1, g_2, \dots, g_K], g_k \in \mathbf{R}^{d \times d}$$

其中, K 为领域中方面的个数, d^a 是每个方面的潜在特征维度。紧接着, 评论中词 i 在方面 k 下的方面级词特征 $v_{i,k}$ 的计算过程为:

$$v_{i,k} = c_i \times g_k^T \quad (2)$$

对于评论 j 与方面 k , 通过连结方面 k 下该评论所有的方面级词特征可以获得初步的评论 j 基于方面 k 的方面级特征, 即:

$$V'_{j,k} = [v_{1,k}, v_{2,k}, \dots, v_{n,k}]$$

3.2.3 方面级注意力学习

通过式(2)可以学习到评论中每个词的方面级表示, 然而, 在同一个方面中不是所有的词都是同等重要的, 例如评论“虽然苹果手机好看、系统流畅, 但价格太贵了”中, 在价格相关方面, “价格、贵”等词的重要性比其他如“流畅、好看”等词更高。因此, 学习方面级词注意力以更准确地表达评论的方面级特征是必要的。此外, 由于不同领域关注的方面不同, 例如护肤品领域侧重于品牌、效果以及价格等方面, 而电子游戏领域则更加侧重于角色、情节以及类型等方面。为学习方面级注意力, 本文引入领域全局方面表示用于指导方面级词注意力的学习, 领域全局方面特征如下:

$$A = [a_1, a_2, \dots, a_K], a_k \in \mathbf{R}^d$$

领域在 K 个方面下的不同特征分别结合方面级词表示通过式(3)计算方面级词注意力。

$$attn_{k,j} = \text{softmax}(a_k (V'_{j,k})^T) \tag{3}$$

紧接着, 评论 j 的方面 k 的特征 $V_{j,k}$ 的计算式如下:

$$V_{j,k} = \sum_{i=1}^a attn_{k,j,i} v_{i,k} \tag{4}$$

对评论词分配不同的注意力后, 将用户评论在所有方面下的特征连结, 得到用户 u 在评论 j 中的方面级表示。

$$P_{u,j} = [V_{j,1}, V_{j,2}, \dots, V_{j,K}]$$

最后, 将用户 u 的评论文档 D_u 中所有评论的方面级特征进行连结, 得到用户在该领域的方面级偏好特征。

$$P_u = [P_{u,1}, P_{u,2}, \dots, P_{u,j}]$$

通过上述步骤, 可以分别得到源领域与目标领域用户和商品的方面级表示。其中, 源领域中用户 u 的方面级偏好为 P_u^s , 商品 i 的方面级特征为 P_i^s , 同理 P_u^t 和 P_i^t 分别表示目标领域的用户与商品的方面级特征。

3.3 方面级用户偏好跨领域迁移

本文设计了基于两阶段生成对抗网络的用户偏好迁移模型, 将交互数据丰富的源领域用户方面级兴趣偏好迁移到数据稀疏的目标领域, 可以有效缓解在目标领域缺少交互历史的用户冷启动问题。受到生成对抗网络 ADDA^[23]方法的启发, 在数据丰富的源领域训练方面级特征编码器 E_s 并将其作为生成器, 结合领域鉴别器 D_c 的约束, 通过将源领域与目标领域的特征映射到相近的特征空间, 来解决不同领域数据分布差异的问题, 以实现知识的跨域迁移。

在预训练阶段, 使用 P_u^s 和 P_i^s 作为 E_s 的输入, 结合多层感知机预测用户对商品的评分 r' , 利用平方损失函数进行优化。

$$loss_r = \frac{1}{|O|} \sum_{(u,i)} (r_{u,i} - r'_{u,i})^2 + \lambda_\theta \| \theta \|^2 \tag{5}$$

在迁移学习阶段, 目标是将用户源领域的方面级特征迁移到目标领域。首先利用预训练的源领域特征编码器 E_s 对目标领域特征编码器 E_t 进行参数初始化, 并且在训练过程中固定 E_s 的参数, 更新 E_t 的参数, 使得经过 E_t 编码的方面级特征在编码后不断向源领域的特征分布靠近, 同时又保留目标领域数据分布的特性。

为了约束两个编码器编码后的特征分布相近, 本文采取了

两个策略: 首先固定源领域编码器的参数不参加训练; 与此同时, 设计领域鉴别器用于区分编码后的特征是来自于源领域还是目标领域, 当编码后的特征分布足够相似时, 领域鉴别器将无法正确判断特征数据的所属领域。一方面特征编码器能挖掘足够有效的领域相关特征, 实现更加准确的评分预测; 另一方面领域相关特征使得领域鉴别器能准确判断数据来源, 只有当源领域与目标领域编码后的数据特征分布足够相似时, 领域鉴别器才无法准确判断。因此, 在迁移学习阶段, 领域鉴别器与特征编码器的训练过程是相互对抗。

领域鉴别器 D_c 的优化目标是分类任务, 本文设定源领域是正类, 标签为 1, 目标领域是负类, 标签为 0。目标领域特征编码器 E_t 的优化目标为评分预测的回归任务。在对抗学习中, 目标领域编码器 E_t 的优化方法如式(5)所示, 领域鉴别器 D_c 的优化为交叉熵损失函数。

$$loss_{D_c} = -y \log D_c(x) - (1-y) \log (1-D_c(x)) \tag{6}$$

4 实验及分析

4.1 实验数据及参数设置

本文使用推荐领域广泛使用的亚马逊公开数据集^[24]进行实验。亚马逊拥有丰富的商品评论数据, 该公开数据集包含 25 个不同领域的用户商品交互记录子数据集, 每个子数据集中都包含用户、商品、评分和评论等信息。本文提出的 CAUT 使用用户评论文本进行商品评分预测。

用户信息在所有子数据集中共享, 在实验中利用源领域和目标领域的共享用户历史交互作为实验数据, 按照 7:1:2 的比例划分训练集、验证集和测试集。测试集为目标领域冷启动用户 U^c , U^c 在目标领域中没有交互记录。

考虑到跨领域推荐中知识迁移的可跨性问题, 本文提出了如下 3 个假设: 源领域的数据应该足够丰富、源领域与目标领域应该有足够多的共享用户、共享用户在源领域和目标领域的占比应该足够大。基于上述假设, 实验中选择以 electronic 数据集为源领域, 同时选定共享用户数量在源领域中占比高于 2% 且在目标领域中占比高于 20% 的子数据集作为目标领域进行跨领域推荐实验。

CAUT 以共享用户为桥梁, 源领域与目标领域间的共享用户数量是实验的基础。如表 2 所列, 以 electronic 数据集为源领域, 目标领域包括 video 等 8 个子数据集, 统计筛选评论后的源领域与目标领域的共享用户数据。为了消除无效评论以及用户评论量较少的影响, 将评论字数少于 10 的评论视为无效评论, 将有效评论数少于 10 的用户视为无效用户。

表 2 实验数据统计

Table 2 Statistics of Amazon datasets

目标领域	共享用户	源领域的共享用户 / %	目标领域的共享用户 / %
video	1 203	3.322	24.041
sport	1 460	4.031	28.910
cell	1 251	3.454	62.833
health	2 914	8.046	47.983
office	1 313	3.625	82.165
pet	756	2.087	29.055
home	3 494	9.648	36.166
beauty	1 054	2.910	31.406

参考文献[11]中的预处理方法, 首先去除停用词并根据

词频逆文档频率选择词表,对每条有效评论进行截长补短至150字,使用基于 Glove 在 Google News 中预训练的 300 维词向量。方面的个数设置为 5,每个方面的维度为 100 维,使用 3 个窗口大小为 3 的卷积核,批量大小为 64。

CAUT 由方面级用户偏好建模(CAUT-aspect)和方面级用户偏好迁移(CAUT-transfer)两部分组成,其中 CAUT-aspect 在每个领域数据集中独立进行,迁移过程中使用已训练好的离线模型来获取用户偏好。为了分析卷积神经网络在方面级用户偏好建模中的复杂度,以 sport,cell,health 为例,表 3 列出了 CAUT-aspect 模型的参数统计结果,其中卷积神经网络的参数量约为 0.27×10^6 ,而每个数据集词表不同,导致模型输入的 embedding 层参数不一致。同时,对于卷积神经网络在 CAUT-aspect 中的时间复杂度,由于 CAUT-aspect 使用一维卷积并在评论中以窗口的形式线性滑动,因此卷积神经网络的时间复杂度为 $O(N)$ 。

表 3 模型参数统计

Table 3 Model parameter statistics

Dataset	sport	cell	health
卷积参数量	0.27×10^6	0.27×10^6	0.27×10^6
词向量参数量	13.82×10^6	9.73×10^6	16.29×10^6
其他参数	0.77×10^6	0.77×10^6	0.77×10^6
总参数量	14.86×10^6	10.77×10^6	17.33×10^6
磁盘占用大小/MB	57.6	41.4	66.2

实验中,本文使用均方根误差(RMSE)作为评估指标,所有的实验数据取 5 次实验的平均值, RMSE 的计算过程如下:

$$RMSE = \frac{\sqrt{\sum_{i=1}^N (r - r')^2}}{N}$$

(7)

4.2 实验结果及讨论分析

本文提出的 CAUT 算法设计了基于生成对抗网络的跨领域迁移结构来对用户的方面级偏好进行迁移。为了验证 CAUT 的有效性,需要探究以下两个问题。

问题 1 CAUT 中用户方面级偏好建模是否有效,与单领域推荐方法相比,其在评分预测指标上是否有优势。

问题 2 CAUT 提取的方面级偏好在跨领域迁移模块上能否进行有效的知识迁移?即 CAUT 能否将源领域知识有效地应用于目标领域,缓解目标领域用户的冷启动问题,并在评分预测指标 RMSE 上有足够的竞争力。

本文选择以下方法作为对比的基线方法,包括基于评论用户建模单领域推荐方法、经典的跨领域推荐方法。基于评论用户建模单领域推荐的对比方法如下。

(1)DeepCoNN^[8](2017)。是单领域推荐中应用得较广且性能优越的方法,基于卷积神经网络从评论中获取潜在的用户、商品表示。大量的实验证明,DeepCoNN 方法远优于经典的矩阵分解、主题模型等方法^[14]。

(2)ANR^[7](2018)。该方法是最先进的单领域推荐方法之一,通过对用户、商品的方面级信息匹配进行评分预测。与基于注意力的方法不同,该方法基于深度神经网络挖掘用户细粒度的方面级信息。

跨领域推荐的对比方法如下。

(1)EMCDR^[1](2017)。首次提出利用多层感知机学习用户潜在特征从源领域到目标领域的映射,该映射思想被广泛地

运用于后续的工作中,是跨领域推荐的经典方法之一。

(2)PPGN^[18](2019)。该方法构建用户和商品的交互图,挖掘结构化信息,将跨领域推荐任务转换为链接预测任务,基于图卷积神经网络充分利用了图信息,但未使用文本信息。

(3)CATN^[14](2020)。目前领先的方面级跨领域推荐方法,使用辅助信息增强用户文档,挖掘用户方面级特征,并在跨领域推荐中利用方面级特征的匹配程度进行评分预测。

(4)PTUPCDR^[25](2022)。该方法首次提出用户特征个性化迁移理念,在基于映射方法的基础上,利用元学习为每个用户设计生成不同的个性化映射参数,其效果优于 EMCDR 等全部用户共享同一个映射模型的方法。

在实验对比中,本文对最优的实验数据加粗标注,对次优的实验结果使用下划线进行标注。与此同时,对于实验的提升比例,效果优于对比方法的正向提升使用“+”进行标注,效果差于对比方法的负面提升使用“-”进行标注。

4.2.1 单领域实验

对于问题 1,本文在单领域进行评分预测实验并与 ANR,DeepCoNN 两种方法进行非冷启动实验对比。实验设置参考文献[6],如表 4 所列,提升百分比为本文提出的用户方面级偏好建模(CAUT-aspect)与 ANR 方法对比计算。

表 4 单领域评分预测实验结果

Table 4 Single domain ratings prediction results

Dataset	DeepCoNN	ANR	CAUT-Aspect	Improve /%
video	1.2239	<u>1.0361</u>	0.9951	+3.95
sport	1.1402	<u>0.9519</u>	0.8589	+9.76
tool	1.1954	<u>1.0064</u>	0.8969	+10.88
cell	1.4282	<u>1.1705</u>	0.9595	+18.02
pet	1.5651	<u>1.1443</u>	1.0846	+5.21
office	1.2429	<u>0.8782</u>	0.7429	+15.41
health	1.1493	<u>1.0484</u>	0.9869	+5.86
beauty	1.2513	<u>1.1137</u>	0.9736	+12.57
home	1.2281	<u>1.0689</u>	0.9593	+10.25
electronic	1.2880	<u>1.1360</u>	1.0889	+4.14

由表 4 可知,在单领域非冷启动实验中,本文提出的方面级用户偏好建模方法 CAUT-Aspect 在 RMSE 指标上优于经典的 ANR,DeepCoNN 方法,这说明本文方法能够提取有效的用户方面级特征,从而进行准确的用户偏好建模。

DeepCoNN 和 ANR 在进行用户偏好建模时,直接使用用户文档进行建模,DeepCoNN 利用卷积神经网络直接将用户文档编码为单个的特征向量,ANR 则更加深入地挖掘细粒度方面级知识并取得了优于 DeepCoNN 的结果。DeepCoNN 实验的效果较差,这是因为只关注单一特征表示方法无法挖掘数据集中多样化细粒度的用户偏好和商品特征。

ANR 和 CAUT-Aspect 都是基于方面级用户偏好建模的方法,CAUT-Aspect 的效果优于 ANR,可能的原因如下。首先,CAUT-aspect 在处理用户文档时对每一条评论分别进行方面级知识的提取,然后融合所有评论的方面级特征,而 ANR 不对评论做区分,直接将所有评论拼接成一个文档,没有进行重点评论筛选。其次,在提取方面级特征时,CAUT-Aspect 利用卷积神经网络学习评论中包含每个词上下文信息的动态词向量,解决静态词向量表示能力不足的问题。而 ANR 直接使用预训练的静态词向量,忽略了同一词在不同语境中的歧义问题。因此,CAUT-Aspect 通过挖掘动态词向量并对

不同评论赋予不同的注意力能通过评论文本更准确地挖掘用户的方面级偏好特征,从而在单领域实验中取得更好的效果。

4.2.2 跨领域实验

对于问题 2,本文使用 electronic 数据集作为源领域,并选定 8 个有足够共享用户的数据集作为目标领域,分别与 EMCDR,PPGN,CATN 以及 PTUPCDR 等方法在 RMSE

指标上进行对比。其中,提升百分比由 CAUT 与目前领先的跨领域推荐算法 CATN 以及最新的个性化迁移方法 PTUPCDR 对比计算所得。从表 5 中可以得到以下结论与分析:本文提出的 CAUT 方法在 6 个数据集中能取得当前最优的跨领域推荐效果,且相对次优的方法有显著的提升,这说明 CAUT 对用户方面级偏好进行知识迁移能够有效缓解目标领域用户的冷启动问题。

表 5 跨领域用户冷启动评分预测实验结果
Table 5 Cross-domain cold-start user ratings prediction experiments

method target domain							Improve/%	
	EMCDR	PPGN	PTUPCDR	CATN	CAUT(Ours)		CAUT vs.	CAUT vs.
							PTUPCDR	CATN
sport	1.0997	1.4804	1.0073	1.0235	0.8864±0.0006		+12.00	+13.39
video	1.4682	1.6331	1.1175	1.0433	1.0635±0.0027		+4.83	-1.93
cell	1.2374	1.6224	1.1625	1.1241	1.0235±0.0033		+11.96	+8.94
health	1.3957	1.5485	1.0818	1.1096	1.0286±0.0008		+4.92	+7.29
office	1.1032	1.6920	0.9138	0.9191	0.8599±0.0038		+5.90	+6.44
pet	1.3816	1.8154	1.1571	1.1837	1.0988±0.0023		+5.04	+7.17
home	1.2355	1.4616	1.0864	1.1576	0.9762±0.0007		+10.14	+15.67
beauty	1.3351	1.4805	1.1135	1.0422	1.0502±0.0012		+5.68	-0.76

此外,虽然 CAUT 在 video,beauty 两个数据集上取得了略差于 CATN 的次优结果,但实验结果相差不大,与最优方法非常接近,且与其他方法相比均有较大的提升。分析其可能的原因是,源领域 electronic 数据集和目标领域 video, beauty 数据集之间用户偏好的相关性难以挖掘。研究源领域与目标领域的相关性、探索不同方面级特征在知识迁移中的作用亦是进一步研究的方向。

可以观察到,CAUT 在 sport 等其他 6 个领域的效果均优于 CATN,这是因为 CAUT 使用生成对抗网络进行知识迁移,以尽可能地消除不同领域数据分布差异带来的问题。然而,对比方法 CATN 基于源领域用户与目标领域商品方面级特征的相关度进行知识匹配,忽略了领域间数据分布差异的问题,推荐效果受领域间方面级特征匹配程度的影响较大,因此本文提出的 CAUT 方法在准确性上比 CATN 更加稳定。

PTUPCDR 方法在 5 个目标领域数据集中取得了仅次于 CAUT 的次优效果,这说明在用户偏好知识的迁移过程中“个性化”迁移策略是有效的。然而,虽然源领域与目标领域间不同用户偏好的迁移关系有差异,但领域内的知识存在共性,因此共性迁移应该是个性化迁移的基础,个性化迁移应在共性迁移之上进行微调。

EMCDR 和 PPGN 方法表现较差,这是因为这两种方法都只使用了评分数据,并未使用蕴含丰富语义特征的评论信息。CAUT 和 CATN 的性能优于 EMCDR 和 PPGN,也进一步说明了方面级知识的提取在跨领域推荐中的有效性。

4.3 方面个数分析

方面的个数会影响用户方面级兴趣偏好特征的粒度,本文在多个领域中分别选取 3~10 共 8 个不同的方面个数,展开方面个数对用户偏好挖掘影响的实验探究,并使用 RMSE 指标进行实验评估。

通过图 3 可以观察到,不同的数据集取得最优的方面个数不是完全一致的,这是因为各个领域数据集中评论的内容不同,导致其所包含的方面级特征也是有差异的。与此同时,可以观察到 cell,health,video,home 这 4 个数据集的最优

方面个数是 5,pet,office 的最优方面个数是 4,sports 和 tool 的最优方面个数分别是 3 和 7。总体而言,大部分数据集的最优方面个数在 4~6 之间。随着方面个数的增加,RMSE 指标在后期呈现明显的增长趋势,这意味着推荐效果下降。




图 3 方面个数对 RMSE 指标的影响
Fig. 3 Effect of number of aspects on RMSE

对于上述现象,本文分析可能的原因是方面的个数会通过改变领域中每个方面知识的粒度来影响推荐效果。方面个数过少会导致方面级特征粒度较大,表达不够具体,而过多的方面个数会导致方面级特征粒度过细,难以表达领域的共性特征。此外,虽然不同的方面个数对个性化推荐的效果有影响,但整体波动不大,这进一步说明本文提出的用户方面级兴趣偏好挖掘方法具有鲁棒性。

结束语 本文提出了一种基于方面级用户偏好迁移的跨领域推荐算法 CAUT,用于解决数据稀疏场景下的用户冷启动问题。CAUT 使用基于两阶段生成对抗网络的迁移结构实现源领域到目标领域的知识迁移,利用评论挖掘用户的方面级兴趣偏好,缓解电商平台用户冷启动带来的数据稀疏问题,在

大型公开的亚马逊数据集中取得了具有竞争力的结果。

方面级知识的跨领域迁移,为跨领域推荐的可解释性工作提供了新的思路,通过对方面级特征的分析,可以更好地挖掘领域间的相关性。在接下来的工作中,我们将进一步探索跨领域推荐中方面级知识的有效性,研究不同方面在知识迁移中发挥的作用。然后,继续深入研究领域之间的可跨性问题,挖掘源领域与目标领域之间知识迁移的内在联系,从而进行更准确的跨领域推荐。

参 考 文 献

- [1] MAN T, SHEN H, JIN X, et al. Cross-Domain Recommendation: An Embedding and Mapping Approach[C]// Proceedings of IJCAI. Morgan Kaufmann, 2017: 2464-2470.
- [2] WANG X, PENG Z, WANG S, et al. CDLFM: cross-domain recommendation for cold-start users via latent feature mapping[J]. Knowledge and Information Systems, 2019, 62(5): 1-28.
- [3] HU G, ZHANG Y, YANG Q. CoNet: Collaborative Cross Networks for Cross-Domain Recommendation[C]// Proceedings of CIKM. ACM, 2018: 667-676.
- [4] JIN Y, DONG S, CAI Y. RACRec: Review Aware Cross-Domain Recommendation for Fully-Cold-Start User[J]. IEEE Access, 2020, 8(3): 55032-55041.
- [5] WANG C, NIEPERT M, LI H. Recsys-dan: discriminative adversarial networks for cross-domain recommender systems[J]. IEEE Trans. Neural Netw. Learn. Syst., 2019, 31(8): 2731-2740.
- [6] ZHU F, CHEN C, WANG Y, et al. DTCDR: A Framework for Dual-Target Cross-Domain Recommendation[C]// Proceedings of CIKM. ACM, 2019: 1533-1542.
- [7] CHIN J Y, ZHAO K, JOTY S, et al. ANR: Aspect-based neural recommender[C]// Proceedings of CIKM. ACM, 2018: 147-156.
- [8] ZHENG L, NOROOZI V, YU P S. Joint deep modeling of users and items using reviews for recommendation[C]// Proceedings of WSDM. ACM, 2017: 425-434.
- [9] SEO S Y, JING H, HAO Y, et al. Interpretable convolutional neural networks with dual local and global attention for review rating prediction[C]// Proceedings of RecSys. ACM, 2017: 297-305.
- [10] CHEN C, ZHANG M, LIU Y, et al. Neural attentional rating regression with review-level explanations[C]// Proceedings of the 2018 World Wide Web Conference. ACM, 2018: 1583-1592.
- [11] TAY LUU A, HUI S. Multi-pointer co-attention networks for recommendation[C]// Proceedings of SIGKDD. ACM, 2018: 2309-2318.
- [12] WU C, WU F, LIU J, et al. Hierarchical user and item representation with three-tier attention for recommendation[C]// Proceedings of ACL. ACL, 2019: 1818-1826.
- [13] SAH A, DWIVEDI P. Knowledge transfer by domain-independent user latent factor for cross-domain recommender systems[J]. FGCS, 2020, 108(7): 320-333.
- [14] ZHAO C, LI C, XIAO R, et al. CATN: Cross-Domain Recommendation for Cold-Start Users via Aspect Transfer Network

[C]// Proceedings of SIGIR. ACM, 2020: 229-238.

- [15] KANG Y, GAI S, ZHAO F, et al. Deep Transfer Collaborative Filtering with Geometric Structure Preservation for Cross-Domain Recommendation[C]// IJCNN. IEEE, 2020: 1-8.
- [16] LI P, TUZHILIN A. DDTCDR: Deep Dual Transfer Cross Domain Recommendation[C]// Proceedings of WSDM. ACM, 2020: 331-339.
- [17] HONG W, ZHENG N, XIONG Z, et al. A Parallel Deep Neural Network Using Reviews and Item Metadata for Cross-Domain Recommendation[J]. IEEE Access, 2020, 8(2): 41774-41783.
- [18] ZHAO C, LI C, FU C. Cross-Domain Recommendation via Preference Propagation Graph-Net[C]// Proceedings of CIKM. ACM, 2019: 2165-2168.
- [19] YANG O, GUO B, TANG X, et al. Mobile App Cross-Domain Recommendation with Multi-Graph Neural Network[J]. Trans. Knowl. Discov. Data. ACM, 2021, 15(4): 1-21.
- [20] CHAHAL D, GUPTA P. Implementation and comparison of topic modeling techniques based on user reviews in e-commerce recommendations[J]. Journal of Ambient Intelligence and Humanized Computing, 2021, 12(5): 5055-5070.
- [21] DU Y, WANG L, PENG Z, et al. review-based Hierarchical Attention Cooperative Neural Networks for Recommendation[J]. Neurocomputing, 2021, 447(4): 38-47.
- [22] LIU H, WANG W, CHEN H, et al. Hierarchical Multi-view Attention for Neural Review Based Recommendation[C]// NLPC. Cham: Springer, 2020: 267-278.
- [23] TZENG E, HOFFMAN J, SAENKO K, et al. Adversarial Discriminative Domain Adaptation[C]// Proceedings of CVPR. IEEE, 2017: 7167-7176.
- [24] HE R, MCAULEY J. Ups and Downs: Modeling the Visual Evolution of Fashion Trends with One-Class Collaborative Filtering[C]// WWW. ACM, 2016: 507-517.
- [25] ZHU Y, TANG Z, LIU Y, et al. Personalized Transfer of User Preferences for Cross-domain Recommendation[C]// Proceedings of WSDM. ACM, 2022: 1507-1515.



ZHANG Jia, born in 1996, postgraduate. Her main research interests include recommendation systems and natural language processing.



DONG Shou-bin, born in 1967, Ph.D., professor, Ph.D supervisor. Her main research interests include information retrieval, natural language processing and high-performance computing.

(责任编辑:喻黎)