

双向跨域推荐模型

郑键珑¹ 王丹阳^{2*}

1 中国民用航空飞行学院 理学院 2 自然资源部第三大地测量队

DOI:10.32629/acair.v3i4.17934

[摘要] 用户冷启动问题是推荐系统面临的一大挑战,而跨域推荐是解决用户冷启动问题的有效手段之一。以往的跨域推荐主要依赖于用户特征的单向映射,即从源推荐领域到目标推荐领域或从目标推荐领域到源推荐领域,没有有效地融合用户在两个推荐领域上的信息。为了解决上述问题,提出了一种双向跨域推荐模型(Bidirectional Cross Domain Recommendation Model, Bi-CDRM),该模型通过训练两个用户特征映射网络,分别实现用户特征从源域到目标域和从目标域到源域的映射,以得到粗粒度的用户映射特征;引入相关性计算单元,利用注意力机制对粗粒度的用户映射特征和交互物品特征进行加权,最后使用平均池化得到更细粒度的用户全局特征。这一过程不仅提升了跨域推荐模型的性能,也增强了用户特征映射的可解释性。在Amazon数据集的三个跨域推荐场景下,Bi-CDRM在评分预测任务中,效果相较于对比模型有显著的提升。

[关键词] 推荐系统; 跨域推荐; 用户冷启动; 数据挖掘; 深度学习

中图分类号: P413 **文献标识码:** A

Bidirectional Cross Domain Recommendation Model

Jianlong Zheng¹ Danyang Wang^{2*}

1 Civil Aviation Flight University of China

2 The Third Geodetic Surveying Team of the Ministry of Natural Resources

[Abstract] User cold start is a major challenge faced by recommendation systems. Cross domain recommendation is one of the effective methods to solve the problem of user cold start. Previous cross domain recommendations mainly relied on single direction mapping of user features, namely from the source recommendation domain to the target recommendation domain or from the target recommendation domain to the source recommendation domain, without effectively integrating user information in the two recommendation domains. To address the aforementioned issues, a Bidirectional Cross Domain Recommendation Model (Bi-CDRM) is proposed. This model trains two user feature mapping networks to map user features from the source domain to the target domain and from the target domain to the source domain, respectively, to obtain coarse grained user mapping features; Introducing correlation unit, utilizing attention mechanisms to weight coarse-grained user mapping features and interactive item features, and finally using average pooling to obtain finer grained global user features. This process not only improves the performance of cross domain recommendation models, but also enhances the interpretability of user feature mapping. In three cross domain recommendation scenarios on the Amazon dataset, Bi-CDRM showed significant improvement in rating prediction tasks compared to the comparison models.

[Key words] recommendation system; cross-domain recommendation; user cold-start; data mining; deep learning

引言

推荐系统(Recommendation System, RS)能有效缓解信息过载,帮助用户从海量数据中发现潜在兴趣内容。随着互联网发展,推荐系统已在电商^[1]、社交^[2]与新闻^[3]等多个领域广泛应用。其技术演进也从早期的协同过滤(Collaborative Filtering, CF)^[4]逐渐发

展至基于深度学习的模型^[5],后者能更有效地挖掘用户与物品特征,提升推荐性能。然而,这些算法通常依赖充足的数据支持,在用户交互行为稀疏甚至缺失的情况下,效果往往不佳,即“用户冷启动问题”,这仍是当前推荐系统的一大挑战。

针对用户冷启动,早期工业界常采用非个性化推荐(如热门

物品推荐)或基于人口统计信息(如性别、职业等)^[6]的泛个性化推荐。但前者易降低用户粘性,后者又因隐私保护^[7]限制而难以获取数据。

近年来,跨域推荐受到广泛关注。其基本思路是:若两个领域相似,用户兴趣偏好通常也相近^[8],因此可利用源域中的用户行为数据辅助目标域的推荐,缓解目标域中的冷启动问题。跨域推荐的核心在于实现源域与目标域间的用户偏好映射^[9-12],典型方法如DTCDR^[13]和EMCDR^[14],均通过将源域用户特征映射至目标域实现推荐。

然而,现有方法多依赖单向用户特征映射,未能充分融合两个领域的信息。为构建更细粒度、更具解释力的用户全局特征,本文提出双向跨域推荐模型(Bi-CDRM),通过双向融合不同领域用户信息,并引入相关性计算单元,自适应学习用户映射特征与交互物品间的相似性。

1 相关工作

跨域推荐的出现有助于缓解用户冷启动问题,目前研究主要集中在基于共享实体表示和基于域间映射的两类模型。

基于共享实体表示的模型适用于多目标域且域间存在高度相似重叠实体(通常为重叠用户)的场景。该类模型通过共享或组合重叠实体的跨域特征,融合多领域信息以建立域间关联,从而提升多领域推荐性能^[8]。典型模型包括: DTCDR^[13]通过结合层整合重叠用户信息,以保留多领域显著特征并共享至双域推荐模型; GA-DTCDR^[15]在DTCDR基础上引入图嵌入构建无向异构图表示域内实体,采用element-wise attention机制融合重叠实体表示; MV-DNN^[16]可视作DSSM^[17]双塔模型的扩展,将不同域物品作为多视图输入,用户作为主视图输入,各视图使用结构相同但参数独立的MLP获得表示向量,再与用户表示计算余弦相似度进行预测; DDTCDR^[18]则利用深度双向迁移学习机制学习重叠用户的兴趣迁移,并通过跨域隐式正交映射保持用户偏好的相似性,同时优化逆映射计算。

基于域间映射的模型适用于源域数据充足而目标域数据稀疏的场景。该类方法同样关注域间重叠实体^[8],但侧重于通过学习映射函数建立域间关联。当用户在源域活跃而在目标域处于冷启动状态时,可通过映射函数获得目标域中的用户特征表示。

EMCDR^[14]作为首个域间映射模型,通过对各域评分矩阵进行矩阵分解获取用户与物品表示,再利用重叠实体训练映射函数,使映射后用户表示接近目标域表示; TMCDD^[19]将跨域推荐分为Transfer阶段和Meta阶段,前者预训练所有实体获取双域特征表示,后者引入元学习思想,采用面向任务的优化方法直接利用任务标签优化元网络,并通过得分/排序方式训练; DCDCSR^[20]学习目标域到标准域的映射函数,该标准域为融合多领域信息的通用特征空间,通过重叠实体学习映射后将多域用户特征映射至标准域进行推荐; PTUPCDR^[21]学习一个元网络,以源域用户特征为输入,为每个用户生成个性化特征映射桥; DCDIR^[22]在知识图谱上设计基于元路径的方法,使用GRU建模源域用户动态兴趣,再利用MLP学习双域特征映射函数; SSCDR^[23]针对现实中重

叠实体比例低导致映射函数泛化能力弱的问题,设计了无监督损失函数,将模型转化为半监督学习过程,从而利用域内丰富非重叠实体提升映射函数的鲁棒性与推荐性能。

2 双向跨域推荐模型

2.1 用户特征表示。特征提取。使用TextCNN模型从每条评论中提取特征。TextCNN是一种适用于文本分类任务的卷积神经网络结构,能有效捕捉文本中的局部信息。

偏好预测任务。将TextCNN模型的输出输入到一个二分类器中,完成用户对物品的偏好预测任务。这一步的目标是训练模型,使其能准确预测用户对每个物品的偏好。

用户特征计算。利用训练好的TextCNN模型,计算用户对每个评论的特征。将TextCNN最后一层的输出进行平均池化,得到用户的最终特征表示,即 U_{si_emb} 或 U_{ti_emb} 。

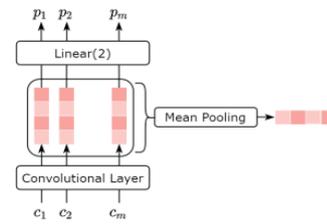


图1 用户特征表示

2.2 物品特征表示。特征提取。针对物品id,物品类别(cate),物品品牌(brand)三个特征,使用独热编码(one-hot)进行处理,每个特征的每个取值都被映射为一个唯一的整数索引,然后通过独热编码将这个索引表示为一个稀疏向量,其中只有一个元素为1,其余为0。这样,每个特征都被转化为一个高维稀疏向量。针对物品名称(title),物品描述(description)两个特征,使用谷歌预训练模型对分词后的物品名称和物品描述进行特征提取,生成针对语义信息更为丰富的词向量。

特征拼接。将上述得到的五个特征向量,即id embedding, cate embedding, brand embedding, title embedding, description embedding进行拼接,得到一个高维稀疏特征向量。

嵌入层。使用全连接神经网络将拼接得到的高维特征向量映射到一个更紧凑且表示丰富语义信息的低维向量空间。

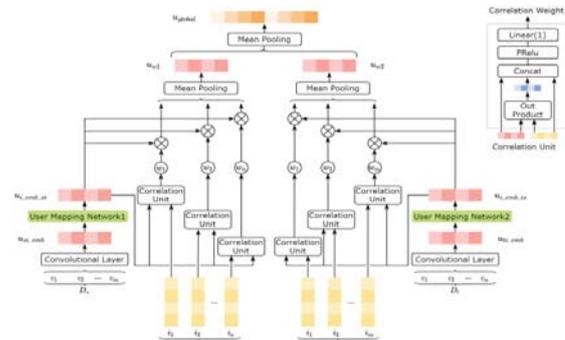


图2 双向跨域推荐模型

最终获得一个维度为的低维密集向量, 作为物品的特征表示, 即 i_{si_emb} 或 i_{ti_emb} 。

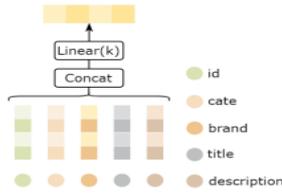


图3 物品特征表示

2.3用户特征映射网络。用户特征映射网络(User Mapping Network, UMN)使用MLP^[24-26]作为基本结构。采用MLP作为基本结构具有以下优点: 首先, 输入特征和输出特征的维度一致, MLP可以很好的捕获需要映射的特征; 其次, MLP是一种非线性的变换, 比一般的线性映射更灵活, 最后, MLP具有非常强的自适应学习能力。为了更好更快地学习输入到输出的映射关系, 加快网络训练速度, 提高网络的泛化能力, 使用了激活函数PReLU。PReLU激活函数可以自适应地学习矫正线性单元的参数, 提高模型准确率, 并且在训练过程中降低模型过拟合的风险, 具体如下:

PReLU激活函数

$$PReLU(x_i) = \begin{cases} x_i & \text{if } x_i > 0 \\ a_i x_i & \text{if } x_i \leq 0 \end{cases} \quad (1)$$

本文所提出的模型将分别训练两个用户特征映射网络:

User Mapping Network1 (UMN1): 完成用户特征从源域到目标域的映射:

$$u_{i_emb_st} = PReLU(u_{si_emb}W_1 + b_1) \quad (2)$$

其中, u_{si_emb} 为源域上的用户特征, $u_{i_emb_st}$ 为该用户映射后的特征。

User Mapping Network2 (UMN2): 完成用户特征从目标域到源域的映射:

$$u_{i_emb_ts} = PReLU(u_{ti_emb}W_2 + b_2) \quad (3)$$

其中, u_{ti_emb} 为目标域上的用户特征, $u_{i_emb_ts}$ 为该用户映射后的特征。

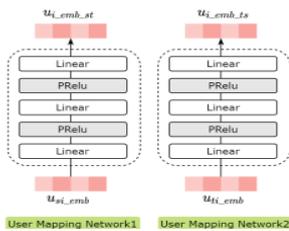


图4 用户特征映射网络

2.4相关性计算单元。为了融合用户在两个推荐领域上的信息, 从而更全面的捕获用户兴趣, 获得更加细粒度的用户全局特征, 提出相关性计算单元。如图2中所示。

仅使用用户特征映射网络得到的映射特征, 是粗粒度的, 因为并没有考虑映射之后的特征是否可以真正代表用户在另一个推荐领域的兴趣。并且在实际应用场景中, 两个相似推荐领域之间总会存在一定的差异性, 而在特征映射时, 考虑只对相似的部分做特征映射至关重要。在上述条件之下, 对于本研究中提出的模型而言, 期望最终得到的用户全局特征更能代表用户在两个领域之间的兴趣偏好。因此希望用户特征映射网络映射得到的用户特征能够尽可能与目标推荐领域中用户交互的物品存在一定的关联性, 这样也能使得用户特征映射这一过程更具有可解释性。

相关性计算单元用于计算映射特征与交互物品的相似性, 并把这种相似度作为一个权重, 最后进行加权平均得到最终的全局用户特征。

$$u_{w1} = \frac{1}{n} \sum_{j=1}^n a(u_{i_emb_st}, i_j) u_{i_emb_st}, i_j \in I_t \quad (4)$$

$$u_{w2} = \frac{1}{m} \sum_{j=1}^m a(u_{i_emb_ts}, i_j) u_{i_emb_ts}, i_j \in I_s \quad (5)$$

$$u_{global} = \text{meanPooling}(u_{w1}, u_{w2}) \quad (6)$$

其中 $a()$ 表示相关性计算单元。

3 实验

3.1数据集。本文选取了Amazon数据集中三个最大的推荐领域的的数据, 分别是Book域, Movie域和Music域来评估模型性能, 各个域统计信息如表1所示。构建了三个跨域推荐场景, 使用重叠用户数据进行训练, 目标推荐领域作为冷启动域, 如表2所示。

表1 实验数据集统计信息

Amazon 数据集			
域	Book	Movie	Music
#用户	126, 666	27, 822	11, 053
#物品	63, 202	12, 287	7, 710
#评论	3, 494, 976	779, 376	296, 185

表2 跨域推荐场景

数据集	场景	域	重叠用户
Amazon 数据集	场景 1	D_s	6, 074
		D_t	
	场景 2	D_s	2, 782
		D_t	
	场景 3	D_s	1, 705
		D_t	

3.2实验设置。本文对所有的用户数据和物品数据进行了预

处理: 过滤掉交互次数小于10次的用户和被交互次数小于30次的物品; 从用户评论信息中抽取用户特征时, 过滤掉了英文停用词, 为了提高抽取特征的准确性, 对一些错误的单词进行了纠正, 并且设置了评论信息的最大长度为500, 对长度大于500的评论信息进行了截断; 进行卷积操作时, 使用了50个卷积窗口大小为3的卷积滤波器来提取用户特征; 使用谷歌预训练词向量模型对物品特征进行编码。最后编码完成的用户特征和物品特征维度均为128; 整个模型训练优化过程中, 设置学习率为0.001, 每个跨域场景训练50个epoch。最后采用MSE来评估模型的性能, MSE被广泛用于推荐系统的评估。公式如下:

$$MSE = \frac{1}{|O|} \sum_{(u,i) \in O} (r_{u,i} - \hat{r}_{u,i})^2 \quad (7)$$

4 性能对比

本节汇总了各模型在Amazon数据集不同推荐场景下的性能(表3、图5), 并得出以下结论:

在Amazon数据集上, Bi-CDRM相较于最优基线ANR, 在三个场景中MSE分别降低0.01、0.015和0.004。尽管ANR本身为基于评论的单域推荐模型, 该结果仍验证了在跨域推荐中引入用户评论以建模用户特征的有效性; CMF在所有场景中表现最差, Bi-CDRM相较其MSE分别下降约0.054、0.032和0.048, 说明仅依赖联合矩阵分解构建共享实体表示难以有效提升性能; R-DFM融合评分与评论信息建模用户特征, 相较仅使用评分矩阵的EMCDR与DFM, MSE进一步降低。而Bi-CDRM相比R-DFM在三个场景中MSE分别下降0.019、0.021和0.02, 进一步证实结合评分与评论信息构建用户特征表示的有效性。

上述实验结果整体验证了本文所提Bi-CDRM模型的有效性。

表3 不同跨域场景下的对比结果

对比模型	场景1	场景2	场景3
CMF	1.167	1.139	0.939
EMCDR	1.129	1.116	0.924
CDLFM ^[27]	1.126	1.115	0.918
DFM ^[28]	1.141	1.136	0.923
R-DFM ^[26]	1.132	1.128	0.911
ANR ^[29]	1.123	1.122	0.895
Bi-CDRM	1.113	1.107	0.891

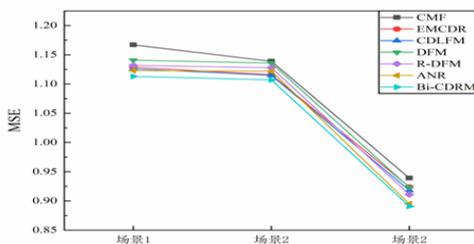


图5 不同跨域场景下的对比结果

5 总结与展望

本文提出了一种双向跨域推荐模型Bi-CDRM, 设计了基于MLP的用户特征映射网络将用户特征从一个推荐领域映射到另一个推荐领域, 从而得到粗粒度的用户映射特征; 引入相关性计算单元, 利用注意力机制对粗粒度的用户映射特征和交互物品特征进行加权, 再使用平均池化得到细粒度的用户全局特征。下一步将考虑在以下几个方面展开研究: (1) 用户偏好演化建模: 用户偏好是动态变化的, 跨域推荐需要能够及时捕捉用户偏好的演变。未来的研究可以探索更加精确的用户偏好动态建模方法, 以提高跨域推荐的准确性。(2) 多模态跨域推荐: 当前的跨域推荐主要是针对单一模态的数据进行的, 例如用户交互或物品信息。未来的研究中可以将多模态数据整合到跨域推荐中, 如图像、视频、语音等。

参考文献

- [1] LINDEN G, SMITH B, YORK J. Amazon.com recommendations: item-to-item collaborative filtering[J]. IEEE Internet Computing, 2003, 7(1): 76-80.
- [2] SU M K, LIM E P, ZHU F D. A survey of recommender systems in twitter[C]// Proceedings of the 4th International Conference on Social Informatics (SocInfo' 12). Berlin: Springer, 2012: 420-433. (Lecture Notes in Computer Science, Vol. 7710).
- [3] WANG H W, ZHANG F Z, XIE X, et al. DKN: Deep Knowledge-Aware Network for News Recommendation[C]// Proceedings of the 2018 World Wide Web Conference (WWW' 18). Geneva: ACM, 2018: 1835-1844.
- [4] CHEN C, ZHANG M, ZHANG Y, et al. Efficient heterogeneous collaborative filtering without negative sampling for recommendation[C]// Proceedings of the 34th AAAI Conference on Artificial Intelligence (AAAI 2020). Palo Alto: AAAI Press, 2020: 19-26.
- [5] TANG J, BELLETTI F, JAIN S, et al. Towards neural mixture recommender for long range dependent user sequences[C]// Proceedings of the 28th World Wide Web Conference (WWW 2019). Geneva: ACM, 2019: 1782-1793.
- [6] LOPS P, DE GEMMIS M, SEMERARO G. Content-based Recommender Systems: State of the Art and Trends[M]// LURIE N, SHAFER J. Recommender Systems Handbook. Boston: Springer, 2011: 73-105.
- [7] HUANG X W, SANG J T, YU J, et al. Learning to Learn a Cold-start Sequential Recommender[J]. ACM Transactions on Information Systems, 2021, 1(1): 1-26.
- [8] ZANG T Z, ZHU Y, LIU H B, et al. A Survey on Cross-domain Recommendation: Taxonomies, Methods, and Future Directions[J]. ACM Transactions on Information Systems, 2022, 41(2): 1-39.
- [9] 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: ACM, 2008: 650-658.
- [10] LONI B, SHI Y, LARSON M, et al. Cross-domain Collaborat

ive Filtering with Factorization Machines[C]//Proceedings of the 36th European Conference on IR Research (ECIR 2014). Berlin: Springer, 2014: 656–661. (Lecture Notes in Computer Science, Vol. 8416)

[11] CHEN C, ZHANG M, WANG C Y, et al. An Efficient Adaptive Transfer Neural Network for Social-aware Recommendation[C]//Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval (SIGIR 2019). Paris: ACM, 2019: 225–234.

[12] PERERA D, ZIMMERMANN R. Towards Comprehensive Recommender Systems: Time-aware Unified Recommendations Based on Listwise Ranking of Implicit Cross-network Data[C]//Proceedings of the 34th AAAI Conference on Artificial Intelligence (AAAI 2020). Palo Alto: AAAI Press, 2020: 189–197.

[13] ZHU F, CHEN C C, WANG Y, et al. DTCDR: A Framework for Dual-Target Cross-Domain Recommendation[C]//Proceedings of the 28th ACM International Conference on Information and Knowledge Management (CIKM 2019). Beijing: ACM, 2019: 1533–1542.

[14] MAN T, SHEN H W, JIN X L, et al. Cross-domain Recommendation: An Embedding and Mapping Approach[C]//Proceedings of the 26th International Joint Conference on Artificial Intelligence (IJCAI 2017). Melbourne: IJCAI, 2017: 2464–2470.

[15] ZHU F, WANG Y, CHEN C C, et al. A Graphical and Attentional Framework for Dual Target Cross-domain Recommendation[C]//Proceedings of the 29th International Joint Conference on Artificial Intelligence (IJCAI 2020). Yokohama: IJCAI, 2020: 3001–3008.

[16] ELKAHKY A M, SONG Y, HE X D. 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 (WWW 2015). Florence: ACM, 2015: 278–288.

[17] PO S H, HE X D, GAO J F, et al. Learning Deep Structured Semantic Models for Web Search Using Clickthrough Data[C]//Proceedings of the 22nd ACM International Conference on Information & Knowledge Management. San Francisco: ACM, 2013: 2333–2338.

[18] LI P, TUZHILIN A. DDTCDR: Deep Dual Transfer Cross Domain Recommendation[C]//Proceedings of the 19th ACM International Conference on Web Search and Data Mining (WSDM '20). Houston: ACM, 2020: 331–339.

[19] ZHU Y C, GE K K, ZHUANG F Z, 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 (SIGIR'21). Virtual Event: ACM, 2021: 1813–1817.

[20] ZHU F, CHEN C C, WANG Y, et al. A Deep Framework for Cross-domain and Cross-system Recommendations[C]//Proceedings of the 27th International Joint Conference on Artificial Intelligence (IJCAI 2018). Stockholm: IJCAI, 2018: 3711–3717.

[21] ZHU Y C, TANG Z W, LIU Y D, et al. Personalized Transfer of User Preferences for Cross-domain Recommendation[C]//Proceedings of the 15th ACM International Conference on Web Search and Data Mining (WSDM'22). Tempe: ACM, 2022: 1507–1515.

[22] BI Y, SONG L Q, YAO M Q, et al. DCDIR: A Deep Cross-domain Recommendation System for Cold Start Users in Insurance Domain[C]//Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval (SIGIR 2020). Virtual Event: ACM, 2020: 1661–1664.

[23] KANG S K, 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 (CIKM 2019). Beijing: ACM, 2019: 1563–1572.

[24] CHENG H, KOC L, HARMSSEN J, et al. Wide & deep learning for recommender systems[C]//Proceedings of the 1st Workshop on Deep Learning for Recommender Systems. Geneva: ACM, 2016.

[25] QU Y, CAO G, ZHOU C, et al. Product-Based Neural Networks for User Response Prediction[C]//Proceedings of the 16th International Conference on Data Mining (ICDM 2016). Barcelona: IEEE, 2016.

[26] GUO H F, TANG R M, YE Y, et al. DeepFM: A Factorization-Machine based Neural Network for CTR Prediction[C]//Proceedings of the 26th International Joint Conference on Artificial Intelligence (IJCAI 2017). Melbourne: IJCAI, 2017: 1725–1731.

[27] WANG X H, PENG Z H, WANG S Z, et al. Cross-domain Recommendation for Cold-Start Users via Neighborhood Based Feature Mapping[C]//Proceedings of the 23rd International Conference on Database Systems for Advanced Applications (DASFAA 2018). Gold Coast: Springer, 2018: 158–165.

[28] FU W J, PENG Z H, WANG S Z, et al. Deeply Fusing Reviews and Contents for Cold Start Users in Cross-domain Recommendation Systems[C]//Proceedings of the 33rd AAAI Conference on Artificial Intelligence (AAAI 2019). Honolulu: AAAI Press, 2019: 94–101.

[29] CHIN J Y, ZHAO K Q, JOTY S, et al. ANR: Aspect-based Neural Recommender[C]//Proceedings of the 27th ACM International Conference on Information & Knowledge Management. Torino: ACM, 2018: 147–156.

作者简介:

郑键珑(1999--),男,汉族,福建福州人,硕士研究生,助教,研究方向:自然语言处理。

*通讯作者:

王丹阳(1999--),女,汉族,四川南部县人,研究生,研究方向:推荐系统。