



计算机科学

COMPUTER SCIENCE

基于注意力机制交互卷积神经网络的推荐方法

任胜兰, 郭慧娟, 黄文豪, 汤志宏, 亓慧

引用本文

任胜兰, 郭慧娟, 黄文豪, 汤志宏, 亓慧. [基于注意力机制交互卷积神经网络的推荐方法](#)[J]. 计算机科学, 2022, 49(10): 126-131.

REN Sheng-lan, GUO Hui-juan, HUANG Wen-hao, TANG Zhi-hong, Qi Hui. [Recommendation Method Based on Attention Mechanism Interactive Convolutional Neural Network](#)[J]. Computer Science, 2022, 49(10): 126-131.

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)

[基于图学习的推荐系统研究综述](#)

Survey of Recommender Systems Based on Graph Learning

计算机科学, 2022, 49(9): 1-13. <https://doi.org/10.11896/jsjcx.210900072>

[基于矢量量化编码的协同过滤推荐方法](#)

Collaborative Filtering Recommendation Method Based on Vector Quantization Coding

计算机科学, 2022, 49(9): 48-54. <https://doi.org/10.11896/jsjcx.210700109>

[多层注意力机制融合的序列到序列中国连续手语识别和翻译](#)

Sequence-to-Sequence Chinese Continuous Sign Language Recognition and Translation with Multi-layer Attention Mechanism Fusion

计算机科学, 2022, 49(9): 155-161. <https://doi.org/10.11896/jsjcx.210800026>

[基于可变形图卷积的点云表征学习](#)

Deformable Graph Convolutional Networks Based Point Cloud Representation Learning

计算机科学, 2022, 49(8): 273-278. <https://doi.org/10.11896/jsjcx.210900023>

[基于知识图谱的层次粒化推荐方法](#)

Hierarchical Granulation Recommendation Method Based on Knowledge Graph

计算机科学, 2022, 49(8): 64-69. <https://doi.org/10.11896/jsjcx.210600111>

基于注意力机制交互卷积神经网络的推荐方法

任胜兰¹ 郭慧娟² 黄文豪³ 汤志宏⁴ 齐 慧¹

1 太原师范学院计算机科学与技术学院 山西 晋中 030619

2 太原理工大学信息与计算机学院 太原 030600

3 华南理工大学软件学院 广州 510006

4 江西科技学院信息工程学院 南昌 330098

摘要 为了捕捉在线购物时用户与商品之间的动态交互关系,提高推荐系统(RS)的准确度,提出了结合用户倾向性和商品吸引力的用户评价预测方法。首先,将评论分为用户评论文本和商品评论文本,分别输入两个交互卷积神经网络(CNN),并结合注意力机制,动态捕捉文本中的语义信息和上下文信息,得到用户和商品的自适应特征;然后,利用交互注意力网络,分析商品特征和用户特征的动态交互关系,计算出用户对特定商品的倾向性和商品对特定用户的吸引力;最后,通过预测模块提供用户对商品的准确评价预测。在数据集上进行实验,结果表明,所提方法取得了最优性能,比其他方法的 MAE 和 RMSE 性能分别至少提升了 15.1% 和 13.6%。此外,基于 Top-K 的统计指标进一步验证了所提方法的商品推荐精准度。

关键词: 推荐系统; 用户倾向性; 卷积神经网络; 交互注意力机制; 上下文特征

中图法分类号 TP391.41

Recommendation Method Based on Attention Mechanism Interactive Convolutional Neural Network

REN Sheng-lan¹, GUO Hui-juan², HUANG Wen-hao³, TANG Zhi-hong⁴ and Qi Hui¹

1 College of Computer Science and Technology, Taiyuan Normal University, Jinzhong, Shanxi 030619, China

2 College of Information and Computer, Taiyuan University of Technology, Taiguang 030600, China

3 School of Software Engineering, South China University of Technology, Guangzhou 510006, China

4 Information Engineering College, Jiangxi University of Technology, Nanchang 330098, China

Abstract In order to capture the dynamic interaction between users and items during online shopping and improve the accuracy of recommendation systems(RS), a user rating prediction method combining user preference and item attractiveness is proposed. The reviews are divided into user review texts and product review texts, which are fed into two convolutional neural networks (CNN), and combined with an attention mechanism to dynamically capture semantic and contextual information in the texts, and obtain user and item adaptive representations. Subsequently, using the interactive attention network, the dynamic interaction between the item features and the user features is analyzed to calculate the user preference on specific items and the attractiveness of the items to a specific user. Finally, the prediction module is used to provide accurate predictions about user ratings to unseen items. Results on experimental datasets show that the proposed method achieves optimal performance, with at least 15.1% and 13.6% improvement in MAE and RMSE performance compared to other advanced methods. In addition, the statistical metrics based on Top-K further validate the accuracy of the proposed method for product recommendation.

Keywords Recommendation system, User preference, Convolutional neural network, Interactive-attention mechanism, Contextual features

到稿日期:2022-07-06 返修日期:2022-08-24

基金项目: 山西省自然科学基金(201801D121147); 山西省教育厅项目(2021YJJG269); 山西省科技厅基础研究项目(自由探索)(20210302123334); 江西省教育厅科学技术研究项目(GJJ191016)

This work was supported by the Natural Science Foundation of Shanxi Province, China(201801D121147), Project of Shanxi Provincial Department of Education(2021YJJG269), Basic Research Project of Shanxi Provincial Department of Science and Technology(Free Exploration)(20210302123334) and Science and Technology Research Project of Jiangxi Provincial Department of Education(GJJ191016).

通信作者: 任胜兰(250648099@qq.com)

1 引言

推荐系统(Recommendation System, RS)预测用户对特定商品或服务的喜好,并提前向用户推荐合适的商品或服务^[1]。随着亚马逊、淘宝等国内外在线购物网站的兴起,商品和服务推荐系统与每个人的日常生活密切相关。当前,各电商平台不断生成海量评论文本,这些评论文本反映了用户对购买商品和接收服务的正面评价和负面评价,以及与之相关的用户情感^[2]。情感分析已成为自然语言处理(Natural Language Processing, NLP)中的热门研究领域。情感分析技术有助于检测用户态度,预测用户需求,以改善用户的浏览和消费行为,帮助用户重点关注有用信息,减少大数据时代中的信息过载问题^[3]。

基于评论的评价预测是情感分析中的一个分支,其并非简单地正面和负面的二元情感分类,而是基于用户对商品的评论,预测出用户对商品的评价得分(例如1~5星)^[4]。传统推荐系统使用协同过滤(Collaborative Filtering, CF)方法,如矩阵分解(Matrix Factorization, MF)算法,仅依赖用户评价做出预测,但该方法存在严重的数据稀疏性和冷启动(Cold Start)问题^[5]。随着电子商务网站的兴起,用户评论文本被用于解决数据稀疏性问题,提高了推荐系统的准确度。文献[6]提出了多角度隐性因素感知的推荐系统ALFM,利用话题建模学习目标的多角度特征表示,并利用启发式方法对不同角度的重要性建模。但此类方法依赖于词袋(Bag-of-Words, BOW)方案,忽视了词语的上下文信息。

深度学习具有优秀的表征学习的能力,得到了许多先进推荐系统的使用。此类方法大多基于深度学习模型,将文本内容编码到相应的用户和对象嵌入向量,并使用MF或因式分解机(Factorization Machine, FM)进行评分预测,取得了优于传统方法的性能^[7]。文献[8]提出了评论文本和评分矩阵交互的深度模型,结合情感分析和注意力机制,从上下文语义层面对评论文本进行分析。文献[9]提出了基于全局和局部注意力机制的D-Attn方法,其中仅使用用户和商品特征的点积对评价预测进行估计。文献[10]提出了基于注意力的评价预测方法NARRE,在用户评论文本上使用评论扩展技术,以改善预测性能。文献[11]提出了基于深度学习的评价预测模型Deep-CoNN,其中使用两个交互的卷积神经网络(Convolutional Neural Network, CNN)来学习用户和商品特征表示,并在共享层利用MF技术进行评价预测。文献[12]提出了注意力机制的深度学习,用于自动关注数据辅助评论,并基于评论的推荐系统来表示用户和具有相关评论的项目。文献[13]提出了基于信息融合的深度神经矩阵分解推荐模型,该模型引入了属性信息,并在信息融合时采用不同信息域之间的元素乘积来学习交叉特征。但这些方法大多以静态方式从评论中获得用户和商品的隐性特征,忽视了用户特征和商品特征之间的相关性。

为了捕捉用户和商品之间的动态交互关系,改善评价预测和推荐系统的精度,本文提出了基于交互CNN和交互注意力机制的深度学习。所提方法的创新点主要有两点:1)将评论分为用户评论和商品评论,并在两个交互的CNN

中结合注意力机制,分别学习用户和商品的自适应特征表达,挖掘评论文本中的语义信息和上下文信息;2)利用交互注意力网络,联合抽取用户和商品评论中的语义信息,探索特定用户和特定商品之间的动态隐性交互关系,由此计算出用户倾向性和商品吸引力得分。最后融合用户和商品的多角度特征,得出准确的评价预测。

2 基于注意力机制交互CNN的推荐模型

所提方法包括特征表示模块、交互注意力模块以及预测模块,其架构如图1所示。首先,对数据集中的用户评论和商品评论进行分离;其次,通过两个交互的CNN网络,利用嵌入层和卷积层学习语义信息和局部特征;然后,应用注意力池化层分别学习用户和商品的自适应特征表示,并输入交互注意力模块,以得到用户倾向性和商品吸引力得分;最后,结合前两个模块的结果,在预测模块中计算用户对特定商品的评价预测。




图1 基于注意力机制交互CNN的推荐模型框架

Fig. 1 Recommendation model framework of attention mechanism based interactive CNN

2.1 问题定义

给定评论文本集合 D ,包含用户 $U = u_1, u_2, \dots, u_n$ 对商品 $I = i_1, i_2, \dots, i_n$ 的评论 $d_{u,i} \in D$ 以及用户对商品整体满意度的相应评分 $r_{u,i}$ 。将商品和用户之间的交互关系表示为元组 $(u, i, r_{u,i}, d_{u,i})$ 。所提方法旨在针对任何未给出的用户和商品对,估计出用户 u 对商品 i 的评分 $r'_{u,i}$ 。

2.2 建立用户和商品文档

首先从数据集中移除非语境词,如html标签、网址或符号等,然后将来自同一个用户 u 的所有评论串联到文档 D_u 中,同理将同一个商品 i 的所有评论串联到文档 D_i 中。在每个用户或每个商品的两条不同评论之间加入分隔符,以防止卷积过滤器将不包含上下文联系的词语混合在一起。由此,串联后评论文档的长度将遵循长尾分布^[14]。

特定用户文档和商品文档中的语义信息会存在较大差异,商品文档指不同用户从不同角度对同一个商品的评论,用户文档则体现了特定用户的个人倾向性。将用户文档和商品文档输入网络,学习用户和商品的隐性特征表达。设定每个文档的长度,使得至少70%的词语被保留下来。最后,将用户评论文档和商品评论文档分别输入两个CNN网络。

2.3 自适应特征表示

为了分别基于用户评论文本和商品评论文本学习用户和商品特征,本文使用了结合注意力机制的交互CNN网络。传统CNN模型使用最大池化操作,基于固定向量对用户和商品的隐性特征进行建模。与之相比,所提模型利用注意力

池化操作,实现用户和商品的自适应特征表示,通过重点关注评论文本中信息最丰富的部分,分别学习用户和商品的自适应特征。

通过嵌入层,将输入的每条评论的词语序列表示为独热编码向量,并将其映射到稠密矩阵 $X_i \in R^{n' \times d}$,其中 n' 为词语数量, d 为词嵌入维数。word2vec 是谷歌开发的词向量计算工具,通过词语上下文信息表示及其与目标词语的关系进行建模,将稀疏维度压缩嵌入到一个较小的维度空间,其中包含了 CBOW 模型和 Skip-gram 模型。文献[15]提出了改进的连续词袋(CBOW)方法,其中保留了词序位置信息,避免了维度灾难问题,并考虑到了词向量在文本全局信息中的重要程度。本文使用通过该方法训练的 Word2vec 对 CNN 网络的嵌入层进行初始化。

将嵌入层的结果输入卷积层,在大小为 s 的滑动窗口内,从输入的词嵌入向量序列的局部特征中抽取显著性特征。通过卷积操作生成上下文特征向量 c_i^j 。

$$c_i^j = f(W_j^i X_{i:i+s-1} + b) \quad (1)$$

其中, f 为非线性激活函数,本文使用 RELU 激活函数; W_j^i 为卷积层的过滤器 j 的权向量; $X_{i:i+s-1}$ 表示窗口内第 i 个位置的词嵌入向量的串联;ReLU 为激活函数; b 为偏置项。由此得到卷积过滤器 j 计算出的第 i 个词的上下文特征。为了基于词嵌入向量序列中的局部上下文抽取每个词的上下文信息,为每个过滤器赋予不同的权重。在编码输入上应用卷积操作,得到序列中第 i 个位置的词的上下文特征向量 c_i 。

$$c_i = [c_i^1, c_i^2, \dots, c_i^m] \quad (2)$$

利用交互 CNN 网络,从用户评论集中得到用户文档矩阵 P ,从商品评论集中得到商品文档矩阵 Q 。

$$P = [c_1^u, c_2^u, \dots, c_m^u] \quad (3)$$

$$Q = [c_1^g, c_2^g, \dots, c_n^g]$$

其中, c_j^u 表示用户文档中 j 个词的特征向量, c_k^g 表示商品文档中第 k 个词的特征向量, m 和 n 为相应的用户文档和商品文档大小。

传统 CNN 模型一般采用最大池化操作,生成固定的隐性特征向量,但在预测特定用户对特定商品的评价时,并非所有评论都是有价值的。所提方法利用注意力池化机制,捕捉评论文本最具信息量的特征,以分别学习用户和商品的自适应特征表示。注意力池化支持模型动态捕捉评论中信息量最大的相关语义特征,以学习自适应特征表示。从用户评论文档学习到的注意力得分的计算式为:

$$a_j^u = \text{softmax}(W_p (c_j^u)^T) \quad (4)$$

同理,从商品评论文档中学习到的注意力得分为:

$$a_k^g = \text{softmax}(W_q (c_k^g)^T) \quad (5)$$

其中, $\text{softmax}(x_i) = \exp(x_i) / \sum_k \exp(x_k)$; a_j^u 和 a_k^g 分别为用户和商品的注意力向量; W_p 和 W_q 分别为用户权重和商品权重。最后,用户自适应特征表示的计算式为:

$$P_u = \sum_{j=1}^m a_j^u c_j^u \quad (6)$$

商品自适应特征表示为:

$$Q_i = \sum_{k=1}^n a_k^g c_k^g \quad (7)$$

2.4 用户倾向性和商品吸引力

利用交互 CNN 网络计算出的用户和商品的自适应特征,学习特定用户和特定商品之间的隐藏相关性。为此,通过交互注意力模块,联合计算用户对特定商品的倾向性,以及商品对特定用户的吸引力。图 2 给出了基于关联矩阵的交互注意力结构。




图 2 交互注意力网络

Fig. 2 Interactive attention network

通过交互注意力机制,同时考虑商品特征和用户特征,在词语层面上计算每对用户特征和商品特征之间的相似性,从而构建用户特征和商品特征之间更紧密的联系。具体来说,结合用户和商品的自适应特征,分别估计出用户对特定商品的倾向性,以及商品对特定用户的吸引力。给定用户特征表示 $P_u \in R^{m \times \mu}$ 和商品特征表示 $Q_i \in R^{n \times \eta}$,则关联矩阵的计算式为:

$$C = \tanh(P_u W_{\bar{c}} Q_i) \quad (8)$$

其中, $W_{\bar{c}} \in R^{n \times \eta}$ 为权重矩阵; μ 和 η 分别决定了隐性的用户倾向性、商品吸引力的隐性因子数量和隐藏层大小;tanh 为非线性函数;关联矩阵 $C \in R^{m \times n}$ 中的每个元素代表相应的用户和商品特征在每个词语上的亲和度。利用单层感知机,将关联矩阵作为一个特征^[16],分别计算用户和商品的注意力得分。

$$a_u = \tanh(P_u W_y + C(Q_i W_z)) \quad (9)$$

$$a_i = \tanh(Q_i W_z + C(P_u W_y))$$

其中, $W_y, W_z \in R^{n \times \eta}$ 为权重参数。

关联矩阵 C 将用户特征空间映射到商品吸引力,并将商品特征空间映射到用户倾向性。由此,利用 softmax 函数将注意力得分归一化,得到用户对特定商品的倾向性评分。

$$\psi_u = \text{softmax}(a_u V_y) \quad (10)$$

同理,得到商品对特定用户的吸引力评分。

$$\xi_i = \text{softmax}(a_i V_z) \quad (11)$$

其中, $V_y, V_z \in R^{\eta}$ 为权重参数。

2.5 评价预测

将上文得出的用户和商品的自适应特征表示 (P_u, Q_i)、用户倾向性得分 ψ_u 和商品吸引力得分 ξ_i 输入最终预测模块,计算用户对商品的评价预测。

$$r'_{u,i} = \sum_{u,i} (\psi_u, \xi_i) \cdot (P_u (Q_i)^T) + r_o + b_u + b_i \quad (12)$$

其中, b_u 和 b_i 分别为用户评论和商品评论的偏置向量, r_o 为平均评价。评价预测可考虑为回归问题,通过反向传播技术对用户网络和商品网络中的所有参数进行联合训练,并使用

均方误差(MSE)作为损失函数进行模型优化,通过损失函数最小化学习模型参数。在训练过程中,将 D_u 和 D_i 分别输入两个网络。在测试过程中,将用户和商品对 (u, i) 及其相应的 D_u 和 D_i 输入到用户和商品网络中,并估计出用户对商品的评价 $r'_{u,i}$ 。

3 实验与分析

通过实验分析所提方法的评价预测性能,验证学习自适应用户和商品特征表示,并结合特定用户和特定商品的底层交互对推荐系统的准确度进行改进。

本文采用的对比方法为文献[6,9,11]中的方法。这些方法在用户特征和商品特征之间的相关性,以及获取用户和商品特征的方式方面有待进一步研究。

3.1 数据集

为了评估所提方法的性能,使用两个开源的大规模实验数据集:亚马逊商品评论数据集^[17]和 Yelp 2017 挑战数据集^[18]。亚马逊商品评论集分为 24 个子类,被广泛用于评价预测任务。原始数据集规模过大,本文实验中使用了 3 个子类,分别为汽车用品、宠物用品和食品子集。Yelp 2017 数据集包含 4 个国家 12 个城市的商品和服务的评论及用户评价。对数据集进行预处理,首先设最大评论长度为 300 个词,计算每个词的 TF-IDF 得分,移除频率大于 0.5 的停用词,并使用前 2 万个不同词语作为词库。从数据集中移除得到评价少于 5 个的商品和给出评价少于 5 个的用户。将每个数据集按 80:10:10 的比例分别用于训练、测试和验证。这两个数据集中均包含了表 1 列出的数据集统计信息。

表 1 实验数据集

Table 1 Experimental datasets

数据集	用户数	商品数	评论数
汽车用品子集	125 760	48 365	205 478
宠物用品子集	184 720	19 541	224 856
食品子集	104 527	26 324	145 788
Yelp	157 852	60 524	795 105

3.2 实验设置

为了得到最优结果,在验证集上基于网格搜索策略对模型超参数进行微调。为了防止过拟合,在特征向量上使用 L2 正则化,所有数据集上的正则化数值为 0.001。设词嵌入向量维数为 200,卷积过滤器数量为 64。应用随机梯度下降(SGD),批大小为 512,学习率为 0.0001,代数为 25。对于实验中的所有模型,取 10 轮运行的均值。

3.3 评价指标

通过实验,分别检验所提系统在评价预测和商品推荐任务中的性能。在评价预测实验中,采用均方根误差(RMSE)和平均绝对误差(MAE)指标^[19],计算式如下:

$$MAE = \frac{\sum_{u,i \in T} |r'_{u,i} - r_{u,i}|}{T} \quad (13)$$

$$RMSE = \sqrt{\frac{\sum_{u,i \in T} (r'_{u,i} - r_{u,i})^2}{T}} \quad (14)$$

其中, T 为测试数据集中的样本数, $r_{u,i}$ 和 $r'_{u,i}$ 分别为用户 u 对商品 i 的实际评价和预测评价。

为估计推荐商品的排名质量,采用归一化折扣累积增益(NDCG@N)^[20]:

$$NDCG@N = \frac{DCG@N}{IDCG@N} \quad (15)$$

其中, $DCG@N = \sum_{i=1}^N \frac{2^{rel(i)} - 1}{\log 2(i+1)}$ 为折扣累积增益, $rel(i)$ 表示

预测排名 i 的商品的相关性, $IDCG@N = \sum_{i=1}^C \frac{2^{rel(i)} - 1}{\log 2(i+1)}$ 为理想折扣累积增益, C 为前 N 个推荐中的相关商品数量。

采用精度($prec@N$)指标^[20],计算推荐的相关产品在实际推荐列表中前 N 名的比例。

$$prec@N = \frac{|L_N \cap B|}{N} \quad (16)$$

其中, L_N 为推荐的相关商品, B 为实际推荐列表中的前 N 个商品。

3.4 实验结果分析

表 2 列出了所提方法与其他比较方法在所有数据集上的 MAE 结果, MAE 数值越低,评价预测的性能就越好。

表 2 MAE 结果

Table 2 Results of MAE

方法	汽车用品	宠物用品	食品	Yelp
ALFM	0.972	0.929	1.004	0.925
D-Attn	0.685	0.694	0.599	0.799
Deep-CoNN	0.620	0.792	0.602	0.802
本文方法	0.525	0.554	0.547	0.729

表 3 列出了不同方法的 RMSE 结果,同样,数值越低,模型的性能越好。


表 3 RMSE 结果

Table 3 Results of RMSE


方法	汽车用品	宠物用品	食品	Yelp
ALFM	1.021	1.004	1.105	1.304
D-Attn	0.820	0.892	0.957	1.203
Deep-CoNN	0.885	0.994	1.025	1.158
本文方法	0.792	0.754	0.802	0.996

从表 2 和表 3 可以发现,ALFM 方法的评分预测误差最大,尽管该方法在评分预测中结合了用户评论和评价,并尝试发掘上下文感知的特征,但此类基于潜在狄利克雷分布(Latent Dirichlet Allocation, LDA)的方法无法捕捉词语级的上下文信息,导致评价预测准确度较低。尽管 D-Attn、Deep-CoNN 和本文方法均采用了注意力机制,并在特征学习过程中考虑到了用户评论和商品评论,但本文方法依然取得了优于其他两种深度学习方法的结果,在 4 个数据集上比 D-Attn 的 MAE 和 RMSE 结果平均改善了 15.1% 和 16.3%,比 Deep-CoNN 的 MAE 和 RMSE 结果平均改善了 13.6% 和 17.6%。这是因为 D-Attn 和 Deep-CoNN 仅在最终预测时结合了用户评论和商品评论中的不同特征表示,而所提方法则通过交互注意力网络,在整个训练过程中动态地捕捉用户和商品之间的隐藏交互关系,由此实现了更低的预测误差。

为了进一步验证所提方法的性能,本文给出了 Top-N 推荐的实验结果, Top-N 推荐旨在推导出用户最喜欢的前 N 个商品。图 3(a)和图 3(b)分别给出了本文方法与其他方法的 NDCG@10 结果和 Prec@10 结果,数值越高,代表性能越好。



(a) NDCG@10 性能比较



(b) Prec@10 性能比较

图 3 商品推荐实验结果

Fig. 3 Test results of product recommendation

由图 3 可知,ALFM 方法是基于 BoW 的主体建模方法,未能提供令人满意的推荐精度。所提方法在大部分情况下取得了最好的 $NDCG@10$ 和 $Prec@10$ 结果,但相比其他两种深度学习方法的性能优势并不明显,这表明相对于评价预测任务,商品推荐任务更加复杂,RMSE 和 MAE 中的性能并不一定能在 top-N 推荐中体现。

3.5 文档长度

为了分析文档信息长度对模型性能的影响,设置了不同的最大文档长度,并分析了其对所提方法在 Yelp 数据集上的性能影响。图 4 给出了 RMSE 和训练时间结果,从中可发现,文档长度为 200~250 时实现了时间与性能之间的最优权衡。本文方法旨在分析用户的评论文本,因此将最大文档长度设为 200。需要指出,文档长度增加会造成要处理的信息量变大,延长模型的训练时间,可根据任务需求在训练时间和文档长度之间进行权衡。




图 4 文档长度对模型性能的影响

Fig. 4 Effect of document length on model performance

3.6 Dropout 敏感性分析

深度学习通常应用 dropout 缓解训练样本数不足情况下的过拟合问题。为了分析所提方案中 dropout 的敏感度,保持其他常数不变,调整 dropout 率数值,以分析模型的性能。图 5 给出了在 Yelp 数据集上的实验结果。从中可发现,dropout 策略能够提升模型性能,当 dropout 率设为 0.5 时,所提模型能够取得最优的性能。




图 5 dropout 率对模型性能的影响

Fig. 5 Effect of dropout rate on model performance

3.7 消融实验

通过消融实验,分析所提模型中不同组件的影响。为此,设计移除所提模型的组件,并与默认模型进行比较。简化模型 1:在嵌入层中不使用预训练的词向量,即对所有词语特征表示进行随机初始化。简化模型 2:在 CNN 网络中移除注意力机制,取消自适应池化操作,并直接应用最大池化操作,在固定向量上直接学习用户和商品的特征表示。简化模型 3:移除交互注意力网络,对用户和商品的自适应表征进行直接级联,即不考虑用户倾向性和商品吸引力得分。表 4 列出了在 Yelp 数据集上执行消融实验的 RMSE 和 MAE 结果。从中可发现,完整模型取得了最优性能,且性能显著优于其他 3 个简化模型。简化模型 1 的性能最差,证明预训练的词嵌入向量较大程度地提升了评价预测性能。简化模型 2 和简化模型 3 忽略了用户和商品特征之间的动态性和交互性,因此性能显著低于完整模型。

表 4 消融实验结果

Table 4 Results of ablation experiment

模型	RMSE	MAE
简化模型 1	1.557	1.035
简化模型 2	1.139	0.975
简化模型 3	1.235	0.815
完整模型	0.996	0.729

结束语 本文提出了基于交互 CNN 网络的商品推荐系统,基于商品评论和用户评价提供评价预测和商品推荐。通过 CNN 网络捕捉用户评论和商品评论之间的自适应表征,并通过交互注意力网络得到用户倾向性和商品吸引力得分,以捕捉特征之间的高阶非线性交互。大规模数据集上的实验结果证明,所提方法的评价预测和商品推荐性能优于其他先进方法。实际上,本文系统所用的文本分类效率并不高,目前公认的高效率文本分类方法是图卷积神经网络,未来我们考虑采用先进的图卷积神经网络对语义信息进行分类,同时还要解决图卷积网络嵌入到系统等问题。

参考文献

- [1] HUANG L W,JIANG B T,LYU S Y,et al. Survey on deep learning based recommender systems [J]. Chinese Journal of Computers,2018,41(7):1619-1647.
- [2] KUMAR S,YADAVA M,ROY P P. Fusion of EEG response and sentiment analysis of products review to predict customer satisfaction[J]. Information Fusion,2019,52(1):41-52.
- [3] TANG L Y,XIONG C C,WANG Y,et al. Review of deep lear-

- ning for short text sentiment tendency analysis[J]. *Journal of Frontiers of Computer Science & Technology*, 2021, 15(5): 794-811.
- [4] MAHADEVAN A, AROCK M. Integrated topic modeling and sentiment analysis: a review rating prediction approach for recommender systems[J]. *Turkish Journal of Electrical Engineering & Computer Sciences*, 2020, 28(1): 107-123.
- [5] REN Y G, ZHANG Y P, ZHANG Z P. Collaborative filtering recommendation algorithm based on rough set rule extraction [J]. *Journal on Communications*, 2020, 41(1): 76-83.
- [6] CHENG Z, DING Y, ZHU L, et al. Aspect-aware latent factor model: Rating prediction with ratings and reviews[C]// *Proceedings of the 2018 World Wide Web Conference*. Lyon, France: IEEE press, 2018: 639-648.
- [7] DAU A, SALIM N. Recommendation system based on deep learning methods: a systematic review and new directions[J]. *Artificial Intelligence Review*, 2020, 53(4): 2709-2748.
- [8] LI S Z, YU L T, DENG X H. Recommendation model combining deep sentiment analysis and scoring matrix[J]. *Journal of Electronics & Information Technology*, 2022, 44(1): 245-253.
- [9] SEO S, HUANG J, YANG H, et al. Interpretable convolutional neural networks with dual local and global attention for review rating prediction[C]// *Proceedings of the Eleventh ACM Conference on Recommender Systems*. Como, Italy: IEEE, 2017: 297-305.
- [10] CHEN C, ZHANG M, LIU Y, et al. Neural attentional rating regression with review-level explanations [C] // *International World Wide Web Conferences Steering Committee*. Lyon, France: IEEE, 2018: 1583-1592.
- [11] ZHENG L, NOROOZI V, YU P S. Joint deep modeling of users and items using reviews for recommendation[C]// *Proceedings of the Tenth ACM International Conference on Web Search and Data Mining*. Cambridge, United Kingdom: IEEE, 2017: 425-434.
- [12] HYUN D, PARK C, CHO J, et al. Learning to utilize auxiliary reviews for recommendation [J]. *Information Sciences*, 2021, 45(3): 595-607.
- [13] WANG R. Information fusion-based deep neural attentive matrix factorization recommendation [J]. *Algorithms*, 2021, 14(10): 281-297.
- [14] WANG X L, YE D Y. Social media text classification method based on character-word feature self-attention learning[J]. *Pattern Recognition and Artificial Intelligence*, 2020, 33(4): 287-294.
- [15] YE X, CAO J B, XU F X, et al. Sentiment dictionary adaptive learning method in Chinese domain[J]. *Computer Engineering and Design*, 2020, 41(8): 2231-2237.
- [16] TU C, LIU H, LIU Z, et al. Cane: Context-aware network embedding for relation modeling[C]// *Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics*. Vancouver, Canada: IEEE, 2017: 1722-1731.
- [17] NORINDER U, NORINDER P. Predicting Amazon customer reviews with deep confidence using deep learning and conformal prediction[J]. *Journal of Management Analytics*, 2022, 47(1): 1-16.
- [18] BUDHI G S, CHIONG R, PRANATA I, et al. Using machine learning to predict the sentiment of online reviews: a new framework for comparative analysis[J]. *Archives of Computational Methods in Engineering*, 2021, 28(4): 2543-2566.
- [19] KUMAR A, DEEPIKA R, KUMAR S, et al. Recommender System: An Automated Movie Rating Prediction Using an Improved Timefly Algorithm (ITFA)[J]. *Annals of the Romanian Society for Cell Biology*, 2021, 39(2): 1967-1971.
- [20] HAN D, CHEN Y, ZHANG S. Implicit social recommendation algorithm based on multilayer fuzzy perception similarity[J]. *International Journal of Machine Learning and Cybernetics*, 2022, 13(2): 357-369.



REN Sheng-lan, born in 1962, undergraduate, associate professor. Her main research interests include artificial intelligence, big data and network security.

(责任编辑:喻黎)