

基于 BERT 和双通道语义协同的在线医疗评论情感分析*

张雯 张建同 郭雨姗

(同济大学经济与管理学院 上海 200092)

〔摘要〕 目的/意义 利用人工智能技术从海量评论中迅速甄别负面评论,了解患者的需求与不满,推动远程医疗的可持续发展。方法/过程 以好大夫在线网站的评论数据为例,首先使用双向编码器表征(bidirectional encoder representations from transformers, BERT)模型生成词向量,随后将其输入卷积神经网络(convolutional neural network, CNN)与双向长短期记忆网络(bidirectional long short-term memory, BiLSTM)构成的双通道模型,最后通过特征融合策略获取文本情感信息,完成二分类任务。结果/结论 该双通道模型能够较好地融合 BiLSTM 与 CNN 的优势,与 BERT、BERT_BiLSTM、BERT_CNN 等 9 种模型相比,分类准确率、宏 F1 分数最高,在在线医疗评论文本情感分类任务中具有有效性。

〔关键词〕 双向编码器表征;卷积神经网络;长短期记忆网络;在线医疗评论;情感分类;双通道模型

〔中图分类号〕 R-058 〔文献标识码〕 A 〔DOI〕 10.3969/j.issn.1673-6036.2024.11.005

Sentiment Analysis of Online Medical Reviews Based on BERT and Semantics Collaboration through Dual-channel

ZHANG Wen, ZHANG Jiantong, GUO Yushan

School of Economics and Management, Tongji University, Shanghai 200092, China

〔Abstract〕 **Purpose/Significance** To use artificial intelligence (AI) technology to quickly screen negative comments from a large number of reviews, so as to understand the needs and grievances of patients, and promote the sustainable development of telemedicine. **Method/Process** Taking comments from Haodf.com as an example, the paper first uses bidirectional encoder representations from transformers (BERT) to generate word embeddings, which are then fed into a convolutional neural network (CNN) and a bidirectional long short-term memory (BiLSTM) network in a dual-channel manner. Finally, a feature fusion strategy is employed to obtain textual sentiment information to achieve a binary classification task. **Result/Conclusion** The proposed dual-channel model based on BERT can better integrate the advantages of CNN and BiLSTM. It achieves the highest classification accuracy and macro F1-score compared to other 9 models, including BERT, BERT_BiLSTM, BERT_CNN, etc., which is effective in sentiment classification tasks for online medical reviews.

〔Keywords〕 bidirectional encoder representations from transformers (BERT); convolutional neural network (CNN); bidirectional long short-term memory (BiLSTM); online medical reviews; sentiment classification; dual-channel model

〔修回日期〕 2024-06-17

〔作者简介〕 张雯,硕士研究生;通信作者:张建同,博士。

〔基金项目〕 国家自然科学基金面上项目(项目编号:72371188)。

1 引言

在互联网医院兴起之前,患者主要通过熟人推荐、院方推荐或随机选择等方式获取医生信息,并在就诊后通过社交媒体、医院意见簿或电话投诉等渠道分享就诊体验。随着互联网医院的发展,患者获取医生信息的途径与内容变得多元,医生的专业方向、接诊记录及诊后评价等信息变得公开透明,其他患者也能更便捷地获取并利用这些信息。

在医疗领域,患者的诊后评论可以在一定程度上缓解患者的感知风险、信息不对称和信任缺失问题^[1],成为其他患者重要的择医参考。对于医生和医院而言,这些评论是了解患者恢复状况和服务反馈的重要渠道。有研究^[2]表明,在线评论中的情感表达对用户感知和决策具有显著影响,且负面评论更具影响力,尤其在医疗领域,差评可能对医生声誉和平台治理产生负面影响,甚至可能演变为医患纠纷。然而,人工区分海量评论费时费力。利用深度学习等技术识别海量评论文本的情感倾向,并及时处理负面评论,有助于防范潜在纠纷,对在线医疗平台运营与医生管理至关重要。

2 相关研究

2.1 在线医疗情感分析研究现状

医患交互是在线医疗领域的重要课题。文本作为重要介质,蕴含大量信息。目前,有关在线医疗文本的研究主要包括实体识别^[3]、知识图谱构建^[4]、主题抽取^[5]、情感分析^[6]等方面。在情感分析领域,Zhao K 等^[7]将词汇特征(如帖子长度、关键词频率等)融入机器学习分类模型,对在线交互文本进行情感分类;向菲等^[8]采用特征规则方法,基于补充情感词典,对在线医疗社区用户就医评价进行观点挖掘与情感分析;高慧颖等^[6]则利用 Word2Vec 方法构建词向量模型,抽取情感词集合以完善医疗服务领域情感词典,并建立特征加权词向量模型分析在线医疗评论的情感倾向,模型 $F1$ 达到 88%。此外,叶艳等^[9]还通过双向长短期记忆网络(bidirectional long

short-term memory, BiLSTM)模型获取好大夫在线评论中的医疗服务质量主题情感倾向。

综上,尽管在线医疗情感分析已取得一定进展,但大多研究仍依赖基于情感词典^[6,8]和机器学习^[7,10]的方法。然而,基于情感词典的方法泛化能力有限,基于机器学习的方法对上下文的理解不足。此外,基于深度学习的研究多采用 Word2Vec^[9]进行文本编码,但这种方法主要获取文本的表层信息,导致分类准确率不高。因此,亟须引入更先进的模型以提高分类准确率,为在线医疗评论文本分类提供更可靠的基础。

2.2 基于 BERT 的情感分析研究现状

预训练模型通过大规模数据训练和深度神经网络架构,生成多层次词编码,具备强大的特征提取和迁移学习能力。双向编码器表征(bidirectional encoder representations from transformers, BERT)模型作为代表,采用双向编码架构,有效捕捉丰富的语义信息。Abdelgwad M 等^[11]在 3 个不同的阿拉伯语数据集上验证了 BERT 上下文嵌入的建模能力,展示了其词编码技术的优越性。鉴于此,众多学者探讨将 BERT 词编码技术与其他深度学习模型相结合,以进一步提升文本分类的准确率。在微博文本情感分类任务中,Jia K^[12]将 BERT 与卷积神经网络(convolutional neural networks, CNN)、注意力机制相结合,取得了 93.91% 的准确率;Jiang X^[13]等构建 BERT_BiLSTM_TextCNN 模型,宏 $F1$ 分数达到 90.52%。在 IMBD 电影数据分类任务中,Cupta B^[14]等将 BERT、BiLSTM 与双向门控循环单元(bidirectional gated recurrent unit, BiGRU)一维卷积相结合,准确率达到 93.89%;Jin Y 等^[15]则引入图神经网络,提出基于 BERT 的非链图网络模型,取得 88.81% 的 $F1$ 分数。

从以上研究可知,当前基于 BERT 的情感分析通常通过叠加其他深度学习模型以提升分类效果。然而,词编码在多重处理后可能会出现信息过度压缩或丢失的情况,尤其是在深度网络中,梯度消失或爆炸的问题会影响语义信息的保留。因此,为了在结合不同模型优点的同时减少信息损失,借鉴集

成学习思想,构建双通道模型,融合不同基学习器的特征,以降低单一网络结构对噪声数据的敏感性,提高模型的鲁棒性与稳定性,以提升在线医疗评论文本情感分类的准确率。

3 情感分析模型

3.1 基于 BERT 的双通道语义协同模型

设计双通道模型结构,见图 1,共分为 4 层,分别为输入层、特征提取层、特征融合层、输出层。




图 1 基于 BERT 的双通道语义协同模型

3.2 输入层

BERT 模型结构,见图 2。输入由字嵌入 token embedding、段嵌入 segment embedding 和位置嵌入 token embedding 部分相加组成,编码层由 12 层 Transformer 编码器堆叠而成,随后输出每个 token 的向量表示。即对于文本序列 S_i , 首先得到 $T_i = ([CLS], t_1, t_2, \dots, t_i, \dots, t_n, [SEP])$, 其中 $[CLS]$ 、 $[SEP]$ 分别为句首、句尾标志, t_i 为序列中的每个

字,随后将该矩阵输入 BERT 模型得到序列的词向量矩阵 $X_i = (x_1, x_2, \dots, x_j, \dots, x_L)$, 其中, $X_i \in R^{L \times M}$, x_j 为序列中单个汉字的特征表示, L 为句子截断长度, M 为向量维度。使用 HuggingFace 开发者社区发布的面向中文的 BERT - base - Chines 进行训练,并将生成的动态词嵌入 X_i 作为下游任务的输入。




图 2 BERT 模型结构

3.3 特征提取层

3.3.1 局部特征提取 为结合 CNN 提取局部特征的优点,设计一维卷积层,见图 3,即让卷积核在 BERT 的输出向量矩阵上沿文本方向滑动,并将卷积结果经 ReLU 去线性化处理。




图 3 一维卷积示意

$$c_j = f(W \otimes x_{j:j+h-1} + B) \quad (1)$$

$$C_i = (c_1, c_2, c_3, \dots, c_j, \dots, c_L) \quad (2)$$

其中, W 为卷积核参数, B 表示偏置矩阵, h 表示卷积核高度, $\otimes$ 表示卷积操作, $x_{j:j+h-1}$ 表示字向量 x_j 到字向量 x_{j+h-1} , c_j 表示字向量 x_j 到字向量 x_{j+h-1}

卷积后的结果，卷积核的宽度为文本词向量的维度 M 。由于设置了补零操作，最终得到维度为 $(L,1)$ 的矩阵 C_i 。 $f(*)$ 为激活函数，为了加快收敛速度，本文采用 ReLU 函数作为激活函数，其数学表达式为 $f(x) = \max(x,0)$ 。

3.3.2 上下文语义提取 长短期记忆网络 (long short-term memory, LSTM) 模型通过细胞状态和门机制，保留上一状态的记忆并融合当前信息传输到下一状态，能有效解决文本长距离依赖问题。BiLSTM 通过添加反向层实现双向读取，能更好地理解序列的上下文语义，见图 4。为结合这一优点，将其设计为另一通道。

$$H_t^l = \text{LSTM}_{\text{forward}}(x_t, H_{t-1}^l)$$

(3)

$$H_t^r = \text{LSTM}_{\text{backward}}(x_t, H_{t+1}^r)$$

(4)

$$H_t^{\text{BiLSTM}} = [H_t^l; H_t^r]$$

(5)

其中， H_t^l 、 H_t^r 分别表示前向与后向 LSTM 在时间步 t 的隐藏状态， $\text{LSTM}_{\text{forward}}$ 和 $\text{LSTM}_{\text{backward}}$ 分别为前向和后向 LSTM 的计算过程，“;” 表示向量的连接， H_t^{BiLSTM} 为 BiLSTM 的输出结果。




图 4 BiLSTM 示意

3.4 特征融合层

卷积得到结果向量长度为设定的截断长度 $\max_length$ ，BiLSTM 得到的结果向量长度为 $2 \times \text{hidden}$

$_dim$ 。在特征融合前，首先利用 Linear 线性层将这两个向量降至相同维度，得到 conv_output 和 BiLSTM_output ，分别表示文本的局部特征与上下文依赖，然后通过线性融合 $m \times \text{conv_output} + (1 - m) \times \text{BiLSTM_output}$ 进行特征融合。

3.5 输出层

使用 softmax 函数进行分类，其是一个非线性转换函数，能输出每条评论属于正面、负面的概率分布。

$$y_i = \frac{\exp(x_i)}{\sum_j \exp(x_j)}$$

(6)

4 实验与分析

4.1 实验数据

好大夫在线成立于 2006 年，是中国最大的在线医疗平台之一，致力于整合医疗资源，为患者提供远程医疗服务。患者可以在平台中选择医生咨询，并发表评论进行服务质量反馈，平台也会对评论内容进行审核。因此，好大夫在线积累了大量透明、真实的患者评论，为评论文本分析提供了优质的数据源。通过网络爬虫技术，收集 2022 年 1 月 1 日—2023 年 8 月 15 日期间内科、儿科、外科、皮肤美容等科室的患者评论，共计 16 320 条。首先，对数据进行预处理，删除段落标签与字数少于 5 字的低质量文本。由于平台已对患者隐私信息进行脱敏处理，以“*”代替，因此无法获取原始内容。为消除平台脱敏处理对模型分析的影响，删除这类词块，并通过人工复审确保文本的有效性。最终得到 12 700 条有效数据，好评 6 361 条，差评 6 339 条。情感标签标注以好大夫在线提供的标签为基础进行人工校对，其中，“0”表示差评，“1”表示好评。部分样例数据，见表 1。

表 1 样例数据

序号	评论内容	情感标签
0	态度恶劣，未解决问题，不耐烦态度，等待一大早，遇到这样医生真的很糟心，问什么都不给你解答，态度特别差，再也不会看这个医生了，对待患者就是不耐烦，推脱责任	0
1	母亲右侧腰腿痛麻半年多了，曹主任检查后发现有椎管内肿瘤，良性的，经手术完全摘除了，今天术后第 6 天了可以正常走路了，一点不痛不麻了，恢复特别好很感激	1
2	医术高，态度好，手术顺利，康复快	1
3	排队 1 小时，看病 3 分钟，话都没说完就让走	0
4	医生态度差，开药时也未告知药物副作用，回来吃完药一直吐一直吐！太难受了	0

4.2 参数设置

模型输入层采用 BERT – base – Chinese 模型进行编码，该模型含有 12 层 Transformer，隐藏维度为 768，Multi – Head_ Attention 参数为 12，激活函数为 ReLU。模型特征提取层由 CNN 和 BiLSTM 构成，具体参数，见表 2。

表 2 其他重要参数设置

名称	参数
batch_size	32
epochs	4
max_length	200
optimizer	optim. AdamW (model.parameters()), lr=5e-05
loss_function	nn.CrossEntropyLoss()
hidd_dim	384
num_layers	1
bidirectional	TRUE
dropout	0.1
kernel_size	3
padding	1
stride	1
m	0.5

4.3 评价指标

为衡量模型综合性能，选取准确率（accuracy）、宏精确率（macro_precision）、宏召回率（macro_recall）和宏 F1 分数（macro_F1_score）作为评价指标。准确率是正确预测的比例，而精确率和召回率之间通常存在权衡关系，单独使用可能会产生误导性结果，因此使用 F1 分数作为补充指标。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \tag{7}$$

$$Macro_Precision = \frac{1}{n} \sum_{i=1}^n Precision_i \tag{8}$$

$$Macro_Recall = \frac{1}{n} \sum_{i=1}^n Recall_i \tag{9}$$

$$Macro_F1_score = \frac{2 \times Macro_Precision \times Macro_Recall}{Macro_Precision + Macro_Recall} \tag{10}$$

其中，TP（true positive）是真正例，TN（true negative）是真负例，FP（false positive）是假正例，FN（false negative）是假负例，Precision_{*i*}、Recall_{*i*}代表每个类别的精确率和召回率。

4.4 实验结果分析

为对比双通道模型的性能表现，搭建 BERT_FC、BERT_BiLSTM、BERT_CNN、BERT_CNN_BiLSTM 以及以 Word2Vec 编码的 W2V_BiLSTM 等 9 个模型。实验数据按照 8:2 划分训练集、测试集，训练过程均使用五折交叉验证。模型性能，见表 3。结果显示，基于 Word2Vec 的方法通过结合不同的神经网络结构，如 CNN、BiLSTM，逐步提升了性能，但总体上仍逊色于基于 BERT 的方法。基于 BERT 的方法，即使是全连接层分类器，也能取得较高的准确率，显示了强大的特征表示能力。结合 CNN 与 BiLSTM 的双通道结构进一步提升模型性能，表明该结构能够充分利用语义信息，捕获更丰富的情感特征，尤其是本文提出的基于 BERT 的双通道模型，在所有模型中表现最佳，准确率与宏 F1 分数分别达到 96.86%、96.45%，分别超基线 BERT_FC 3.20、2.79 个百分点，也优于既有研究的 88%^[6]和 94%^[10]。

表 3 模型性能比较 (%)

模型	准确率	宏精确率	宏召回率	宏 F1 分数
W2V_FC	72.53	73.04	72.63	72.83
W2V_BiLSTM	75.77	76.01	75.82	75.92
W2V_CNN	79.22	80.82	80.70	80.76
W2V_CNN_BiLSTM	81.19	81.62	81.36	81.49
W2V_CNN + BiLSTM	87.55	87.59	87.35	87.47
BERT_FC	93.66	93.66	93.66	93.66
BERT_BiLSTM	94.99	95.07	94.99	95.03
BERT_CNN	92.17	92.56	86.72	89.54
BERT_CNN_BiLSTM	95.01	95.04	95.02	95.03
BERT_CNN + BiLSTM	96.86	96.88	96.02	96.45

为进一步评估模型性能，进行鲁棒性实验，见图 5。




图 5 测试结果

通过计算，在引入噪声的测试集上，模型准确率为 96.57%，宏精确率为 97.59%，宏召回率为 95.52%，宏 $F1$ 分数为 96.54%，各指标表现优秀，说明模型具有良好的稳健性与泛化能力。

5 结语

评论文本分类是了解用户反馈的重要途径。随着远程医疗和在线医疗平台的发展，在线医疗平台上积累了海量患者评论。准确识别评论文本的情感倾向，有助于了解患者的需求与不满，从而指导医生服务行为，帮助医疗从业者（如医生和医疗平台管理人员）更有效地回应患者需求，作出科学决策，推动远程医疗的可持续发展。

目前，针对在线医疗评论文本情感分析的研究相对较少，且主要聚焦于基于情感词典或 Word2Vec 的机器学习模型。然而，医疗评论文本含有医学专业词汇且表达口语化，这些模型在处理这类问题时表现欠佳，分类准确率不高。因此，亟须引入更先进的模型。鉴于此，本文提出基于 BERT 的双通道语义协同模型，用于在线医疗评论文本的情感分析。该模型首先利用 BERT 对评论文本进行编码，生成蕴含上下文语义的字向量。然后通过 CNN 及 BiLSTM 双通道分别捕获局部特征与上下文语义依赖关系，最后通过特征融合获取综合特征向量，以判断在线医疗评论文本的情感倾向。在好大夫在线数据集的对比实验结果显示，本文的双通道模型能更好地融合不同深度学习网络的优点，在获取语义信息方面具有优越性，有效适应在线医疗评论文本专业性强、表达不规范等特点，为在线医疗评论文本情感分析的研究提供了思路。

作者贡献：张雯负责数据采集、代码编写、论文撰写与修订；张建同负责研究设计与指导；郭雨珊负责论文修订。

利益声明：所有作者均声明不存在利益冲突。

参考文献

1 马骋宇. 在线医疗社区发展现状浅析 [J]. 中国医院管理, 2018, 38 (5): 58 – 60.

2 LEE M, JEONG M, LEE J. Roles of negative emotions in customers’ perceived helpfulness of hotel reviews on a user-generated review website: a text mining approach [J]. International journal of contemporary hospitality management, 2017, 29 (2): 762 – 783.

3 XU Q, ZHOU Y, LIAO B, et al. Named entity recognition of diabetes online health community data using multiple machine learning models [J]. Bioengineering, 2023, 10 (6): 659.

4 廖开际, 黄琼影, 席运江. 在线医疗社区问答文本的知识图谱构建研究 [J]. 情报科学, 2021, 39 (3): 51 – 59.

5 由丽萍, 王世钰. 基于框架语义的在线医生服务评价主题识别 [J]. 情报理论与实践, 2019, 42 (9): 166 – 170.

6 高慧颖, 公孟秋, 刘嘉唯. 基于特征加权词向量的在线医疗评论情感分析 [J]. 北京理工大学学报 (自然版), 2021, 41 (9): 999 – 1005.

7 ZHAO K, YEN J, GREER G, et al. Finding influential users of online health communities: a new metric based on sentiment influence [J]. Journal of the American medical informatics association, 2014, 21 (e2): e212 – e218.

8 向菲, 谢耀谈. 基于特征规则的在线医疗社区用户评论观点挖掘与情感分析方法 [J]. 医学信息学杂志, 2018, 39 (11): 9 – 14.

9 叶艳, 吴鹏, 周知, 等. 基于 LDA – BiLSTM 模型的在线医疗服务质量识别研究 [J]. 情报理论与实践, 2022, 45 (8): 178 – 183, 168.

10 柯洁, 杨婉, 黄桂玲, 等. 移动医疗 APP 在线评论维度挖掘与情感分析 [J]. 中华医学图书情报杂志, 2022, 31 (6): 20 – 29.

11 ABDELGWAD M M, SOLIMAN T H A, TALOBA A I. Arabic aspect sentiment polarity classification using BERT [J]. Journal of big data, 2022, 9 (1): 115.

12 JIA K. Sentiment classification of microblog: a framework based on BERT and CNN with attention mechanism [EB/OL]. [2023 – 12 – 23]. <https://doi.org/10.1016/j.compeleceng.2022.108032>.

13 JIANG X, SONG C, XU Y, et al. Research on sentiment classification for netizens based on the BERT – BiLSTM – TextCNN model [EB/OL]. [2023 – 12 – 25]. <https://doi.org/10.7717/peerj-cs.1005>.

14 GUPTA B, PRAKASAM P, VELMURIGAN T. Integrated BERT embeddings, BiLSTM – BiGRU and 1 – D CNN model for binary sentiment classification analysis of movie reviews [J]. Multimedia tools and applications, 2022, 81 (23): 33067 – 33086.

15 JIN Y, ZHAO A. Bert – based graph unlinked embedding for sentiment analysis [J]. Complex & intelligent systems, 2024, 10 (2): 2627 – 2638.