

[文章编号] 1003-4684(2021)06-0056-06

弹幕文本情感分类模型研究

——基于中文预训练模型与双向长短期记忆网络

陈志刚¹, 岳 倩¹, 赵 威²

(1 湖北工业大学经济与管理学院, 湖北 武汉 430068; 2 华中科技大学武汉光电国家研究中心, 湖北 武汉 430074)

[摘 要] 针对弹幕文本的口语化、网络化、一词多义等特点,提出 BERT-wwm-BiLSTM 模型以提升情感分类准确率。该模型引入 BERT-wwm 预训练模型,得到有关上下文信息的动态词向量,采用 BiLSTM 对特征进行提取,最后使用 softmax 进行情感分类。在自建的 bilibili 和腾讯视频两个弹幕数据集上进行实验,Acc、 p 、 R 、 F_1 值等 4 个指标均优于其他模型,且在一词多义弹幕文本中有突出表现,证明该模型在弹幕文本情感分类中的有效性。

[关键词] 弹幕文本情感分类; 中文预训练模型; 双向长短期记忆网络

[中图分类号] TP391 **[文献标识码]** A

以视频为媒介,观众可以针对视频内容发送弹幕,以表达自己的观点及情绪。通过对弹幕进行情感分析,一方面可以对视频内容进行信息挖掘,提取精彩视频^[1-2];另一方面可以获取用户的真实情感倾向,如通过对短视频平台弹幕文本进行情感分析^[3],快速获得网民在疫情期间的情感倾向,为有关部门治理及改善网络舆情提供参考。

弹幕文本情感分析离不开情感分类研究。传统的弹幕文本情感分类方法,多为通过构建情感词典将文本内容与情感词典匹配,从而得到情感极性。如:邱全磊等^[4]构建基于表情和语气词的情感词典;洪庆等^[5]构建了网络弹幕常用词词典;王文韬等^[6]构建了弹幕文本的积极词云和消极词云;司峥鸣等^[7]构建了多维情感词典,完成了弹幕文本的情感分类。情感词典法虽能完成弹幕文本的情感分类任务,但其构建需要耗费大量的人力,不能满足效率和准确率的要求,同时对数据集的泛化能力和迁移能力较差。随着深度学习在自然语言处理领域的发展,越来越多的学者将深度学习技术用于文本情感分类任务中,取得了优于情感词典法、机器学习法的分类结果。因此,针对弹幕文本的情感分类,庄须强等^[8]提出基于注意力机制的 LSTM 模型(AT-LSTM),并基于此完成精彩视频的提取;叶健等^[9]利用卷积神经网络(CNN)完成情感倾向弹幕的分类,均取得了优于传统方法的准确率和效率;李稚等^[10]构建 CNN-LSTM 模型完成弹幕文本情感分

析,并结合心理学、市场营销等知识,提出网络视频平台营销策略。

上述深度学习的方法虽基于不同方面完成了弹幕文本的情感分类任务,但多数研究并未考虑弹幕文本特点,如弹幕文本内容简短,内容口语化、网络化,存在一词多义的现象。这些为弹幕文本的情感分类任务带来极大挑战。

针对上述问题,本文提出一种结合中文预训练模型(BERT-wwm)和双向长短期记忆网络(BiLSTM)的模型来完成弹幕文本的情感分类。首先,引入 BERT-wwm 替代现有研究中词向量提取方法 Word2Vec,得到具有丰富语境信息的动态词向量。动态词向量能更好地适应上下文信息,解决弹幕文本的口语化、网络化及一词多义问题。其次,结合双向长短期记忆网络,通过前向和后向结合起来同时捕获整体文本的信息,可以对简短的弹幕文本内容获取更多的特征信息。最后,运用 softmax 函数得到分类结果。

1 BERT-wwm BiLSTM 模型

1.1 相关技术

1.1.1 预训练模型 BERT-wwm 传统的词向量表示是采用 Word2Vec^[11-12]、GloVe^[13] 等模型通过训练将词组表示为一系列静态词向量。这类词向量可以得到词语间的语义关系,但其得到的词向量是固定的,不会随上下文变化而改变。因此,这些静态词

[收稿日期] 2021-07-22

[第一作者] 陈志刚(1970—),男,湖北汉川人,湖北工业大学副教授,研究方向为电商理论与实务,数字经济,高新企业管理

[通信作者] 岳 倩(1996—),女,四川巴中人,湖北工业大学硕士研究生,研究方向为情报分析

向量技术无法表征上下文,同时无法解决一词多义问题。虽然有学者对 Word2vec 进行改进、优化^[14],解决了词向量特征稀疏性,但 Word2vec 得到的仍然是静态词向量,影响了文本情感分类的准确率。直至 2018 年,谷歌提出的预训练模型 BERT 可以结合上下文信息产生动态词向量^[15]。BERT 在 EMLo^[16]和 GPT^[17]的研究基础上,采用双向多层 Transformer 模型作为基础单元,通过 Encoder 特征抽取器对文本信息进行双向编码,得到的词向量不仅包含该词本身,还包含了该词与其他词的关系以及句子间的上下文信息^[18]。在实际运用中,对 BERT 进行微调^[19-23],使其更适用于具体的文本分类任务。2019 年,哈工大 Y Cui 等人^[24]提出用全词遮掩(Whole Word Masking)替代 BERT 中的 mask 任务,在机器阅读理解、自然语言推理、情绪分类、句子匹配、文档分类等数据集上有着更优秀的表现,并采用中文语料进行训练,据此提出了中文预训练 BERT-wwm 模型。

1.1.2 长短时记忆网络 LSTM 作为 RNN 的变体,LSTM 保留了 RNN 可以处理序列数据的优点,同时可以解决梯度消失的问题,非常适合时序数据(文本数据)的建模。Zhu 等^[25]利用 LSTM 完成评论文本的情感分类,Ren 等^[26]结合主题特征与 LSTM 对 Twitter 短文本进行情感分类。

LSTM 能解决 RNN 梯度消失的问题,仰仗其门控机制。LSTM 模型主要由当前记忆单元、遗忘门、输入门、输出门等 4 个元素组成。遗忘门 f_t 控制前一步记忆单元中的信息有多大程度被遗忘掉;输入门 i_t 控制当前时刻的输入以多大程度更新到记忆单元中;输出门 o_t 控制当前的输出有多大程度上取决于当前的记忆单元。

遗忘门是把 $t-1$ 时的长期记忆输入 C_{t-1} 乘以一个遗忘因子 f_t 。遗忘因子是由短期记忆 h_{t-1} 以及 x_t 来计算:

$$f_t = \sigma(W_f \times [h_{t-1}, x_t] + b_f) \tag{1}$$

其中, σ 表示 sigmoid 函数, W 表示矩阵乘法操作, h_{t-1} 表示上一时刻的记忆状态, x_t 表示此时刻的输入, b 为函数的偏置。

输入门针对遗忘门中丢弃的属性信息,在本单元模块找到相应的新的属性信息,并添加进去,以补充丢弃的属性信息。计算原理是接受从遗忘门输出的长期记忆 i_t , 以及从学习门输出的短期记忆 \tilde{C}_t , 然后直接把两者合并起来,更新 C_{t-1} , 得到 C_t 。计算公式如下:

$$i_t = \sigma(W_i \times [h_{t-1}, x_t] + b_i) \tag{2}$$

$$\tilde{C}_t = \tanh(W_C \times [h_{t-1}, x_t] + b_C) \tag{3}$$

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \tag{4}$$

其中, i_t 表示输入门的输出值, \tilde{C}_t 表示此时刻的记忆单元的输入单元, \tanh 为函数, C_t 表示此时刻记忆单元的内部状态。

输出门先通过一个 sigmoid 函数计算出 h_{t-1} 、 x_t 中哪些部分需要被输出,再将输入门中得到的 C_t 经 \tanh 函数处理,再将两者相乘得到:

$$o_t = \sigma(W_o \times [h_{t-1}, x_t] + b_o) \tag{5}$$

$$h_t = o_t \times \tanh(C_t) \tag{6}$$

1.1.3 双向长短时记忆网络 BiLSTM 单向的 LSTM 模型信息是从前往后传输,容易丢失上下文信息。双向长短时记忆模型(Bidirectional Long Short-Term Memory, BiLSTM)增加了一个从后往前传递信息的隐藏层,通过正向和负向结合同时捕获整体文本的信息,可以利用上下文信息。Yao^[27]提出了 BiLSTM 模型在中文分词方面是专家。Bailikas^[28]利用 Word2Vec 和 BiLSTM 模型完成文本的三元及五元情感分类任务,吴鹏^[29]利用 BiLSTM 模型用于识别网民的负面情绪,在舆情领域有着重要的意义。Baziotis 等^[30]结合注意力机制,将 BiLSTM 模型用于基于主题的情感分类任务中。BiLSTM 可分为 3 个步骤:1)前向的 LSTM 网络计算从左到右的隐特征;2)后向的 LSTM 网络计算从右到左的隐特征;3)将两个 LSTM 输出的结果进行拼接,得到 BiLSTM,提取文本特征。

1.2 模型构建

本文提出的弹幕文本情感分类模型 BERT-wwm-BiLSTM 主要由输入层、隐含层和分类层组成(图 1)。

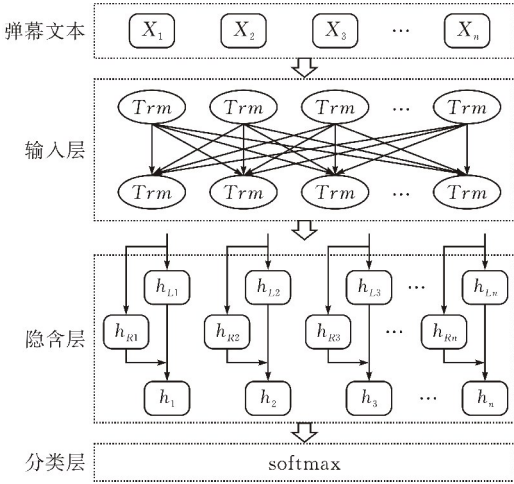


图 1 BERT-wwm-BiLSTM 模型结构

首先,输入层是通过 BERT-wwm 预训练模型将输入的文本向量化,获取包含具有上下文语义的动态词向量;其次,采用 BiLSTM 作为隐含层,将 BERT 预训练得到的词向量作为 BiLSTM 网络的

输入,经过神经网络的处理得到特征向量;最后,将隐含层的输出作为分类层的输入,利用 softmax 函数进行回归处理进而得到文本情感分类。

2 实验设置

2.1 实验环境

本操作系统为 Ubuntu 18.04.5 LTS,服务器 CPU 为 Intel(R) Xeon(R) Gold 5218,64 核,CPU 频率为 2.30 GHz。服务器内存为 188G,显卡为 Tesla V100,显存为 32 G。深度学习网络代码通过 Pytorch 1.7 实现,采用 Python3.6 进行代码编写。

2.2 数据集获取及处理

2.2.1 数据集的获取 采用 Python 脚本爬取视频弹幕信息,视频来自 bilibili 和腾讯视频网站。图 2 展示了数据爬取的流程,爬取的部分弹幕如表 1 所示。




图 2 数据爬取流程

表 1 部分弹幕情感标签

| 弹幕文本 | 标签 |
|------------------------------|----|
| 新会柑为武汉热干面加油 | 1 |
| 刚看完第二遍,感谢那些为祖国流血牺牲的先辈! | 1 |
| 我们不像别的国家的人爱说谎 | 1 |
| 不是靠良心,是靠法律! 只可惜没法律! | 0 |
| 爱因斯坦支持科学无国界的 | 1 |
| 说科学无国界的,先近领域的科学水平也没见美国和我们共享啊 | 0 |
| 中医牛皮!! 国土无双!!! | 1 |
| 司机师傅太不容易了! 感谢! | 1 |
| 能用普通话说吗? 中国都不用普通话说你怕是不尊重哦 | 0 |
| 大家以后捐物不要捐红会 | 0 |

0 表示消极情感,1 表示积极情感

2.2.2 数据预处理 爬取的数据需要进行预处理,以保证数据集的高效性,从而训练得到有效的模型:1)去除重复数据防止重复数据造成模型过拟合;2)删除没有明显情感极性的弹幕;3)将表情转换为对应中文,颜文字转换为对应的情感词,辅助弹幕情感分类。经过上述处理之后,腾讯数据集共有 21 532 条,bilibili 数据集有 24 492 条。之后进行人工标注数据集,标签‘0’表示消极情感,标签‘1’表示积极情感。表 1 展示了部分弹幕的情感标签。

2.3 评价指标

本文选取准确率 (Accuracy)、精确率 (Precision)、召回率 (Recall) 和 F_1 值作为评价指标。

2.4 参数设置

因为不同的参数会导致模型的学习能力不同,所以实验的结果很大程度依赖于模型的参数设置。本文所提出的模型实验参数主要包括 BERT-wwm 预训练模型参数以及 BiLSTM 网络参数。首先,对于 BERT-wwm 预训练模型,其参数已经定义好,不需要进行更改。BERT-wwm 是由 12 层 transformer 组成,隐藏层维度为 768,attention 多头个数为 12,总共参数量多达 110M。其次,在 BERT 对训练预料进行了学习之后,BiLSTM 则接着对数据进行特征提取,提升学习能力。在实验过程中,设置其网络层数为 6 层,隐藏层维度为 384。

深度学习模型还需要设置合适的超参数,使得其学习能力最好。本文涉及的超参数包括学习率、训练周期数、批处理大小等。实验中的详细参数设置见表 2。


表 2 模型参数设置

| 参数 | 参数含义 | 值 |
|------------|----------------------------|--------------------|
| lr | 学习率 | 2×10^{-5} |
| epoch | 训练周期数 | 10 |
| batch_size | 批处理大小 | 32 |
| max_length | 文本数据的最大长度 | 100 |
| padding | 是否对不足 max_length 的文本进行填补操作 | Ture |
| Lstm_layer | BiLSTM 网络的层数 | 6 |


3 实验结果及分析

3.1 实验一:学习能力测试

为了有效说明模型的学习能力,图 3、图 4 展示了模型训练过程中训练集和验证集的损失及准确率随训练周期的变化。在深度学习训练中,训练集的作用是进行模型学习,验证集则是在每个周期学习之后检验学习的成果,再根据验证集的准确率来调整后续的学习。对于验证集而言,验证集损失值先下降,之后小幅度波动上升,这是由于部分学习错误的文本主导了验证集的损失值,在深度学习训练过程中属于正常现象。验证集的准确率则是相对平稳的小幅上升,说明模型学习的效果不错。




(a) bilibili 数据集准确率变化曲线




(b)腾讯视频数据集准确率变化曲线

图 3 准确率随训练周期的变化



(a)bilibili 数据集损失值变化曲线




(b)腾讯视频数据集损失值变化曲线

图 4 损失值随训练周期的变化


3.2 实验二:模型指标测试

模型经过 10 个周期的学习之后,即可通过测试集来评估模型的能力。表 3 及图 5 展示了 BERT-wwm-BiLSTM 模型在 bilibili 和腾讯视频数据集中的表现。在 bilibili 数据集中,准确率为 90.55%, F_1

值为 90.59%, p 值为 90.33%, R 值为 90.85%。在腾讯视频数据集中,准确率为 90.81%, F_1 值为 88.82%, p 值为 90.82%, R 值为 86.90%。



(a)bilibili 数据集



(b)腾讯视频数据集

图 5 各模型评价指标对比

3.3 实验三:对比方案测试

选取机器学习算法 SVM,双向长短时记忆网络 BiLSTM,以及双向长短时记忆网络加注意力机制 BiLSTM-Attention 作为对比模型。由图 3 实验结果可知,本文模型 BERT-wwm-BiLSTM 在 bilibili 和腾讯视频数据集上的各个指标均显著优于对比模型。表 3 展示了不同模型的评价指标。相较于 BiLSTM 模型,本文模型准确率在 bilibili 和腾讯视频两个数据集上分别高出 9.01%和 8.88%,同时本文模型比 BiLSTM-Attention 模型准确率高出 8.42%和 9.07%。

表 3 不同模型在两个数据集上的精确率、召回率和 F_1 值 %

| 模型 | | bilibili 数据集 | | | | 腾讯视频数据集 | | | |
|------|------------------|--------------|-------|-------|-------|---------|-------|-------|-------|
| | | Acc | p | R | F_1 | Acc | p | R | F_1 |
| 对比模型 | SVM | 69.51 | 70.18 | 70.63 | 69.82 | 69.08 | 69.05 | 69.76 | 68.74 |
| | BiLSTM | 81.54 | 80.69 | 82.75 | 81.70 | 81.93 | 77.96 | 78.87 | 78.41 |
| | BiLSTM-Attention | 82.13 | 82.00 | 82.17 | 82.08 | 81.74 | 78.52 | 77.23 | 77.87 |
| 本文模型 | BERT-wwm BiLSTM | 90.55 | 90.33 | 90.85 | 90.59 | 90.81 | 90.82 | 86.90 | 88.82 |

除此之外,本文模型 BERT-wwm BiLSTM 对比模型在精确率、召回率和 F_1 值 3 个指标上也有较大的提升。不同模型在 bilibili 数据集和腾讯视频数据集上的 p 、 R 、 F_1 值结果如表 3 所示。由表格不难发现,本文模型 BERT-wwm BiLSTM 相较于其他对比模型, p 、 R 和 F_1 值均为所有模型中的最高值。 F_1 值是 p 值和 R 值的调和平均数,可以综合考虑到精确率和召回率。相较于其他三个模型,本文模型 BERT-wwm BiLSTM 在 F_1 值方面在两个数据集上分别高出 19.80%、7.92%、7.54% 以及 20.08%、10.41%、10.95%,再一次证明了本文模型

在弹幕文本情感分类任务中确实有效。

3.4 实验四:一词多义语句测试

预训练模型 BERT-wwm 得到动态词向量对一词多义的弹幕文本情感倾向的判断更加准确。表 4 展示了爬取的弹幕文本数据中部分一词多义的文本文本,以及本文模型和对比模型的分类结果。由表 4 可见,SVM 对 10 句语料的判断无规律可循,对“异想天开”判断为消极情感,但对明显含有积极情绪的“聪明、无微不至”也都判断为消极情感。BiLSTM、BiLSTM Attention 对“现在很多人办事都想靠关系走捷径”以及“专门钻法律漏洞,可真聪明”都

做出了错误的判断。“捷径”一词情感倾向性不明显,在不同的语境中表现出不同的情感,“聪明”含有明显的褒义,对比模型因此做出积极情感的判断,这与语境不符。由此可见,基于 Word2Vec 提取词向量的深度学习模型在一词多义语句上的表现差强人

意。因此,本文模型对一词多义弹幕情感判断明显优于其他对比模型,对于语句“up 主有点骄傲啊”判断失误,一方面由于该语句较短,上下文信息较少,另一方面也说明了模型还有改进的空间。

表 4 部分一词多义弹幕文本情感分类结果对比

| 一词多义弹幕 | SVM | BiLSTM | BiLSTM Attention | BERT-wwm BiLSTM | 正确情感 |
|-----------------------|-----|--------|---------------------|--------------------|------|
| 我发现了一条致富捷径! | 0 | 1 | 1 | 1 | 1 |
| 现在很多人办事都想靠关系走捷径 | 0 | 1 | 1 | 0 | 0 |
| 科学家就是需要这种异想天开又实事求是的精神 | 0 | 1 | 0 | 1 | 1 |
| 竟想在短时间达成成效,真是异想天开! | 0 | 0 | 0 | 0 | 0 |
| 这种时候我真为我是一个中国人而骄傲 | 1 | 1 | 1 | 1 | 1 |
| up 主有点骄傲啊! | 0 | 0 | 0 | 1 | 0 |
| 感谢医生和护士对患者无微不至的照顾 | 0 | 1 | 1 | 1 | 1 |
| 骗子才会无微不至的关心你,以及你的钱 | 0 | 0 | 0 | 0 | 0 |
| 他爸早知道了,是个聪明人 | 0 | 0 | 1 | 1 | 1 |
| 专门钻法律漏洞,可真聪明 | 0 | 1 | 1 | 0 | 0 |
| 准确率/% | 60 | 70 | 70 | 90 | 100 |

0 表示消极情感,1 表示积极情感

4 结束语

本文提出的 BERT-wwmBiLSTM 模型。引入 BERT-wwm 中文预训练模型得到有关上下文信息的动态词向量,用于解决弹幕文本口语化、网络化及一词多义的问题。之后将动态词向量传入 BiLSTM 网络中进行特征提取,双向的长短时记忆网络能更好地提取简短的弹幕文本特征。最后结合 softmax 分类层得到最终情感分类结果。数据集方面,通过爬虫技术在 bilibili 视频网站和腾讯视频网站得到弹幕数据集,并利用 pytorch 编程框架实现了提出的模型。试验评估方面,进行了模型的学习能力测试、模型的指标测试、对比试验测试以及文本实例预测测试。实验结果表明,本文提出的模型在文本预测中展现出优异的性能,可为弹幕文本分析提供较大帮助。

本文模型只适用于弹幕文本二分类情况,不能处理复杂的情感多分类。今后将改进模型,使其能够适应更复杂的情感分类任务。

[参 考 文 献]

[1] 邓扬,张晨曦,李江峰.基于弹幕情感分析的视频片段推荐模型[J].计算机应用,2017,37(4):1065-1070+1134.

[2] 朱思淼,魏世伟,魏思恒,等.基于弹幕情感分析和主题模型的视频推荐算法[J].计算机应用,[2021-11-15]:1-9.

[3] 刘琼,马文婷,范一欣.短视频平台突发公共事件的网络情绪呈现及舆情治理——以 Bilibili 网站“新冠疫

情”议题为例[J/OL].电子政务;1-14[2021-04-12].<http://kns.cnki.net/kcms/detail/11.5181.TP.20210409.0848.012.html>.

[4] 邱全磊,崔宗敏,喻静.基于表情和语气的情感词典用于弹幕情感分析[J].计算机技术与发展,2020,30(8):178-182.

[5] 洪庆,王思尧,赵钦佩,等.基于弹幕情感分析和聚类算法的视频用户群体分类[J].计算机工程与科学,2018,40(6):1125-1139.

[6] 王文韬,陈千,张肖,等.弹幕视角下的网络热搜健康视频关注度与情感分析[J].图书馆论坛,:1-11.

[7] 司峥鸣,谭天.弹幕评论情感分析的交互设计及舆论引导[J].青年记者,2021,702(10):35-37.

[8] 庄须强.基于深度学习的弹幕评论情感分析研究[D].山东师范大学,2018.

[9] 叶健,赵慧.基于大规模弹幕数据监听和情感分类的舆情分析模型[J].华东师范大学学报(自然科学版),2019(3):86-100.

[10] 李稚,朱春红.双模态情感分析的弹幕网络视频平台营销策略[J].心理科学进展,2021,29(9):1561-1575.

[11] MIKOLOV T, SUTSKEVER I, CHEN K, et al. Distributed representations of words and phrases and their compositionality[EB/OL].(2021-07-22). <https://arxiv.org/pdf/1310.4546.pdf>

[12] MIKOLOV T, CHEN K, CORRADO G, et al. Efficient estimation of word representations in vector space [EB/OL]. (2021-07-22) <https://arxiv.org/pdf/1301.3781.pdf>

[13] PENNINGTON J, SOCHER R, MANNING C D. Glove: Global vectors for word representation[C]//Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP). 2014:1532-1543.

[14] 张群,王红军,王伦文.词向量与 LDA 相融合的短文本分类方法[J].现代图书情报技术,2016,(12):27-35.

[15] DEVLIN J, CHANG M W, LEE K, et al. Bert: Pre-training of deep bidirectional transformers for language understanding [EB/OL]. (2021-07-22). <https://arxiv.org/pdf/1810.04805.pdf>

[16] PETERS M, NEUMANN M, IYYER M, et al. Deep Contextualized Word Representations [C]//Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long Papers), 2018: 2227-2237.

[17] RADFORD A, NARASIMHAN K, Salimans T, et al. Improving Language Understanding by Generative Pre [EB/OL]. (2021-07-22). https://s3-us-west-2.amazonaws.com/openai-assets/research-covers/language-unsupervised/language_understanding_paper.pdf

[18] 唐晓波,刘江南.基于 BERT 和 TF-IDF 的问答社区问句自动标引研究——以金投网问答社区为例[J].情报科学,2021,39(3):3-10.

[19] SHI KAIZE, GONG CHANGJIN, LU HAO, et al. Wide-grained capsule network with sentence-level feature to detect meteorological event in social network [J].Future Generation Computer Systems,2020(102): 323-332.

[20] CHEN F, YUAN Z, HUANG Y. Multi-source data fusion for as-pect-level sentiment classification [J]. Knowledge-Based Systems, 2020(187): 104831.

[21] ZHANG X, ZHANG Y, ZHANG Q, et al. Extracting comprehensive clinical information for breast cancer using deep learning methods[J]. International Journal of Medical Informat-ics, 2019(132): 103985.

[22] DU Y, PEI B, ZHAO X, et al. Deep scaled dot-product attention based domain adaptation model for bio-medical question answering - ScienceDirect[J]. Methods, 2020, 173:69-74.

[23] MORADI M, DORFFNER G, SAMWALD M. Deep contextualized embeddings for quantifying the informative content in bio-medical text summarization [J]. Computer Methods and Pro-grams in Biomedicine, 2020 (184): 105117.

[24] CUI Y, CHE W, LIU T, et al. Pre-training with whole word masking for chinesebert[J]. arXiv preprint arXiv:1906.08101, 2019.

[25] ZHU X, SOBIHANI P, GUO H. Long short-term memory over recursive structures [C]//International Conference on Machine Learning. PMLR, 2015: 1604-1612.

[26] REN Y, WANG R, JI D. A topic-enhanced word embedding for Twitter sentiment classification[J]. Information Sciences, 2016, 369: 188-198.

[27] YAO Y, HUANG Z. Bi-directional LSTM recurrent neural network for Chinese word segmentation[C]// International Conference on Neural Information Processing. Springer, Cham, 2016: 345-353.

[28] BALIKAS G, MOURA S, AMINI M R. Multitask learning for fine-grained twitter sentiment analysis [C]//Proceedings of the 40th international ACM SIGIR conference on research and development in information retrieval. 2017: 1005-1008.

[29] 吴鹏,应杨,沈思.基于双向长短期记忆模型的网民负面情感分类研究[J].情报学报,2018,37(8):845-853.

[30] BAZIOTIS C, PELEKIS N, DOULKERIDIS C. Datastories at semeval-2017 task 4: Deep lstm with attention for message-level and topic-based sentiment analysis [C]//Proceedings of the 11th international workshop on semantic evaluation (SemEval-2017), 2017: 747-754.

Research on Sentiment Classification of Barrage Text Based on BERT-wwm and BiLSTM

CHEN Zhigang¹, YUE Qian¹, ZHAO Wei²

(1 School of Economics and Management, Hubei Univ. of Tech., Wuhan 430068, China;

2 Wuhan National Laboratory for Optoelectronics,

Huazhong Univ. of Sci. and Tech., Wuhan 430074,China)

Abstract: Aiming at the colloquial, networked, and polysemous features of the barrage text, the BERT wwm BiLSTM model is proposed to improve the accuracy of sentiment classification and provide a reference for subsequent video content mining and network public opinion governance. The model introduces the BERT wwm pre-training model to obtain dynamic word vectors related to context information, then uses BiLSTM to extract features, and finally uses softmax to perform sentiment classification. Experiments were conducted on the self-built two barrage data sets of bilibili and Tencent video. The four indicators of Acc, P , R , and F_1 are better than other models, and they have outstanding performance in the one-word polysemous barrage text. It proves the effectiveness of the model in the sentiment classification of barrage text.

Keywords: barrage text; sentiment classification; BERT wwm BiLSTM

[责任编辑: 张 众]