

基于BE-MCNN模型的新闻评论情感分析方法

李文书¹, 管平²

(1. 浙江理工大学人工智能学院; 2. 浙江理工大学信息学院, 浙江杭州 310018)

摘要: 实时新闻评论具有文本短、信息丰富、结构复杂等特点, 情感分析难以准确捕捉其真实的情感倾向。为增强语义的特征信息, 减少模型过拟合问题, 提高新闻评论情感分析的准确性, 提出一种融合BERT模型、Transformer Encoder与多尺度CNN模型的新闻评论情感分析算法。首先, 针对新闻评论长度较短、表达情绪观点内容较多的特点, 使用BERT模型对新闻评论文本进行预训练, 获得具有上下文信息的特征向量; 其次, 为解决模型过拟合问题, 在BERT模型下游添加一层Transformer编码器; 最后使用四通道双层CNN模型, 通过组合不同大小尺寸的卷积核来提升模型分析新闻评论情感的性能。实验结果表明, 该方法在两个新闻评论数据集上的准确率分别达到93.0%与96.4%; 与不同模型比较实验进一步证明了所提方法的有效性。

关键词: 情感分析; BERT模型; Transformer Encoder; 多尺度CNN; 新闻评论

DOI: 10.11907/rjdk.231176

开放科学(资源服务)标识码(OSID):



中图分类号: TP391

文献标识码: A

文章编号: 1672-7800(2024)003-0001-07

News Commentary Sentiment Analysis Method Based on BE-MCNN Model

LI Wenshu¹, GUAN Ping²

(1. College of Artificial Intelligence, Zhejiang Sci-Tech University;

2. College of Information Science and Technology, Zhejiang Sci-Tech University, Hangzhou 310018, China)

Abstract: Real time news comments have the characteristics of short text, rich information, and complex structure, making it difficult for sentiment analysis to accurately capture their true emotional tendencies. To enhance semantic feature information, reduce model overfitting problems, and improve the accuracy of news comment sentiment analysis, a news comment sentiment analysis algorithm is proposed that integrates BERT model, Transformer Encoder, and multi-scale CNN model. Firstly, in response to the short length of news comments and the high content of expressing emotional views, a BERT model is used to pre train news comment texts and obtain feature vectors with contextual information; Secondly, to solve the problem of model overfitting, a layer of Transformer encoder is added downstream of the BERT model; Finally, a four channel dual layer CNN model is used to improve the performance of analyzing news comment sentiment by combining convolutional kernels of different sizes. The experimental results show that the accuracy of this method on two news comment datasets reaches 93.0% and 96.4%, respectively; The comparative experiments with different models further demonstrate the effectiveness of the proposed method.

Key Words: sentiment analysis; BERT model; Transformer Encoder; multi-scale CNN; news commentary

0 引言

近年来,随着计算机网络的普及,各种网页和App成为人们浏览新闻的主要途径,与此同时新闻评论数量也呈指数增长。这些评论数据反映了人们对热点新闻事件的

看法,舆情监管部门等可以通过分析新闻评论的情感分布有效获取大众舆论情况。然而,越来越多的评论数据导致其文本情感分析变得十分困难。采用人工智能技术对网络新闻评论进行情感分析显得越来越有必要,不仅可以减少相关部门对新闻评论的审核与分类工作,而且可以帮助其从众多新闻评论中获取有价值的信息^[1]。

收稿日期: 2023-02-27

基金项目: 国家自然科学基金项目(31771224, 61603228); 国家重点研发计划项目(2018YFB1004901); 浙江省自然科学基金项目(LY17C090011, LGF19F020009)

作者简介: 李文书(1975-), 男, 浙江理工大学人工智能学院教授、硕士生导师, 研究方向为图像处理、虚拟现实、物联网集成开发; 管平(1998-), 女, 浙江理工大学信息学院硕士研究生, 研究方向为自然语言处理。

情感分析是一种文本分类方法,旨在识别文本数据的情感极性,属于自然语言处理研究领域,其中新闻评论情感分析侧重于用户对新闻事件表达的正面或负面情绪挖掘。

目前,很多学者对文本情感分析方法进行了研究。例如, Kim^[2]将TextCNN(Text Convolutional Neural Network)模型应用于句子级别的分类任务,通过不同大小的窗口获取文本的上下文信息。然而TextCNN的视野是固定的,且卷积池化等操作会使位置信息不再具有可参考性,使得一些变换顺序后就改变语义的句子的情感识别变得十分艰难。Transformer结构可改进这一缺陷,其在输入时加入位置向量这一信息,可以考虑到位置对语义的影响。Jin等^[3]将卷积神经网络(Convolutional Neural Network, CNN)、长短时记忆网络(Long Short Term Memory Network, LSTM)与BERT(Bidirectional Encoder Representations from Transformers)模型结合起来用于中文长文本分类。

然而,他们只是简单地堆叠了这些模型。由于BERT输出的文本特征向量不能表达最原始的文本特征,当将其其他模型与BERT模型结合时,应该将原始文本表示输入到CNN等模型中来提取特征。BERT模型是一种完全意义上的双向语言模型,能够捕捉整个句子中的字序列信息、上下文关系信息和语法语境信息等,进而解决一词多义的问题^[4]。BERT模型使用Transformer的Encoder代替BiLSTM(Bi-directional Long Short-Term Memory),使得运算可以并行执行且可以叠加多层,从而大大提高了对文本信息的表征能力。

情感分析方法发展到现在已经取得了一定成果,但在并行计算方面尚存在提升空间。为此,本文提出一种基于BE-MCNN(BERT and Encoder with Multi-scale CNN)的中文情感分析方法。该方法通过在BERT模型的下流添加一层Transformer Encoder来优化过拟合问题,并增加特征向量包含表征信息,然后通过一个组合不同尺度的CNN卷积模型提升处理不同长度文本的能力,降低词向量维度,从而提升算法的情感分析性能。

1 理论基础

基于深度学习的情感分析方法主要分为以下3个步骤:①数据预处理。将原始文本数据转化为计算机可以处理的格式,通常包括分词、去停用词、词向量化等步骤;②模型训练。选择合适的数据集训练模型;③模型微调与优化。通过评估结果对模型进行优化调整,如修改模型结构、改变实验参数等。

1.1 数据预处理

由于新闻评论内容具有多样性和复杂性,数据预处理是其情感分析的重要一步,主要包括文本清洗、分词、停用词去除和特征提取步骤。

文本清洗是指去除新闻评论中的无用信息,例如HTML标签、特殊字符、数字、标点符号和停用词等。分词是指将新闻评论分解为单独的字或词语的过程。停用词是指在文本中频繁出现但没有太大意义的词语,例如“的”“和”“是”等。在情感分析中,一些特殊字符、标点符号以及停用词可能会影响模型性能,需将其从文本中移除。特征提取是将文本转换为计算机可理解的数字特征向量信息的过程,可以更好地捕捉文本的上下文信息。

Word2Vec是一种典型的固定向量模型,考虑了句子的上下文关系,相较Embedding方法具有更低的维度、更快的速度以及更强的通用性,然而Word2Vec中的词和向量是一一对应的关系,无法处理词语的多义性^[5]。One-hot^[6]、TF-IDF(Term Frequency-Inverse Document Frequency)^[7]、SVD(Singular Value Decomposition)^[8]等均属于离散模型,生成的词向量具有很高的稀疏性,占用空间大。

Elmo是一个双层双向LSTM结构,可以更好地捕捉语法和语义的特征信息,且对词汇量没有限制,缺点为速度很慢,不能进行并行计算,提取特征的能力不及Transformer^[9]。BERT模型的出现几乎解决了以上所有缺陷,不仅考虑了上下文之间的关系,可进行并行计算,提取特征的能力也远超上述模型,同时解决了多义词的问题^[10]。

1.2 模型训练

选取合适的模型需要确定意图解决的问题以及想要达到的目标。每种模型都具有自己的优势与缺陷,需根据实际情况选择合适的模型进行训练与优化。在选择模型时需要充分考虑数据集大小、特征维度、噪声情况、标签数量以及目标任务的复杂程度等因素。

例如,在文本分类任务中,CNN模型可以通过设置不同大小的卷积核来处理不同长度的文本,使得模型更具灵活性^[11];循环神经网络(Recurrent Neural Network, RNN)可以处理任意长度的序列数据,适用于序列标注任务^[12];LSTM和BiLSTM可以有效解决RNN在长序列训练过程中的梯度消失和梯度爆炸等问题^[13-14];Attention机制可以提高模型对重要信息的关注程度^[15];Transformers模型可以将输入序列中的每个位置都与其他位置进行交互,从而更好地捕捉文本中的全局关系,在文本分类任务中具有更好的表现力和泛化能力^[16]。

1.3 模型微调与优化

除选择合适的模型外,还需要考虑模型的微调与优化方法。模型微调(Fine-tuning)是指在预先训练好的模型上通过调整参数,对某些层进行重新训练,以适应新的任务或数据集。

常用优化方法包括随机梯度下降(Stochastic Gradient Descent, SGD)、Adam、Adagrad等。不同优化方法对模型的收敛速度和性能有不同影响,需要在实验过程中进行比较与调整。

2 模型构建

本文提出基于 BE-MCNN 的情感分析模型,通过对新闻评论文本进行情感分析,得到其情感倾向。该模型采用 BERT 作为预训练模型,将新闻评论的文本信息转化为字向量,然后输入到 Transformer Encoder 中,优化模型的过拟合问题,最后输入到多尺度 CNN 中,从中获取更深层次的语义信息。模型结构见图 1。

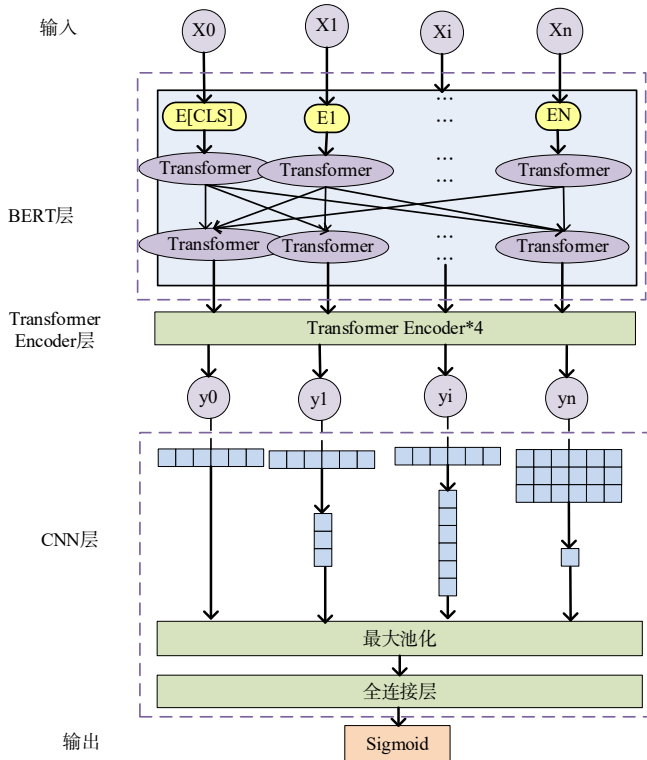


Fig. 1 Structure of sentiment analysis model based on BE-MCNN

图 1 基于 BE-MCNN 的情感分析模型结构

2.1 BERT 模块

BERT 模块采用 Transformer 双向编码器,通过词语或句子上下文之间的关联来预测句子分类,具有良好的语义多样性。BERT 模型还具备微调功能,可以直观展示模型根据参数改变所产生的结果变化。BERT 通过 masked 语言机制实现句子中字向量的深度双向表示,从输入中随机 mask 掉一些 token 向量,再对 mask 掉的字进行预测,同时联合上下文关系,获取句子的语义信息。

在本文模型中,BERT 作为预模型对长度为 128 的新闻评论句子进行处理,输出文本的字向量。首先在句子的开头加上“[CLS]”标志,句子末尾加上“[SEP]”标记,模型输入即为句子语义信息的向量表示,主要包含字向量、文本向量和位置向量,即 token 对应的表征信息,维度为 768;然后通过 12 层 Transformer 编码器结构将其转换为包含更多语义信息的词向量,输入到下层 Transformer Encoder 结构中。

2.2 Transformer Encoder 模块

在 BERT 模型下游增加 Transformer Encoder 主要是为了缓解过拟合问题,其是基于自注意力机制实现的特征提取器,可用于提取序列的特征信息。结构如图 2 所示。选择该模块的原因有以下 3 点:①使用多头注意力机制并行计算多个不同的注意力分布可以更好地捕捉不同角度的信息,从而有效减少过拟合问题,提高模型的鲁棒性和泛化能力;②使用 Dropout 技术在每一层中随机丢弃一些神经元,防止过度依赖某些特征,有效降低训练集与测试集之间的误差;③使用标签平滑技术在训练时给标签添加一些噪声,使模型不会对某些类别过于自信,有效缓解类别不平衡问题,提高模型的鲁棒性。

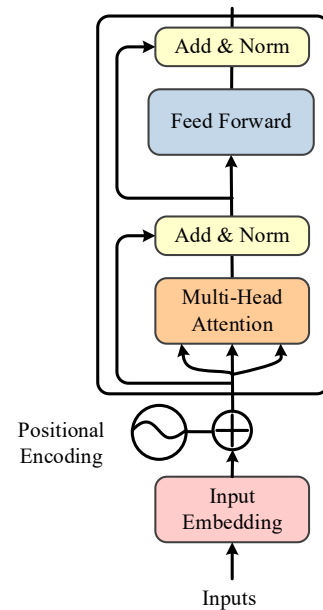


Fig. 2 Transformer Encoder structure

图 2 Transformer Encoder 结构

由于 Transformer 没有类似 RNN 的迭代操作,为识别字在句子中的顺序,必须提供句子的位置向量,与词嵌入向量相加后输入到自注意力机制中,以得到每个字与其他字的加权值向量。

将加权值向量与原始输入向量进行残差连接与标准化,进行两层线性映射并采用 GLU 激活函数激活^[17]。GLU 激活函数表示:

$$GLU(x) = \sigma(x * W_g) * x * W_h \quad (1)$$

式中: x 表示输入数据, W_g 和 W_h 为可训练的权重矩阵, σ 为 sigmoid 函数。

2.3 多尺度 CNN 模块

多尺度 CNN 模块可增强模型提取不同尺度文本特征的能力^[18],其使用并行的卷积分支提取不同尺度的特征,每个分支均包含不同大小的卷积核,以便提取不同尺度的信息。基于并行设计,多尺度 CNN 模块可同时处理不同尺度的输入,并将它们组合成一个具有更好表现力的表示。其结构如图 3 所示。

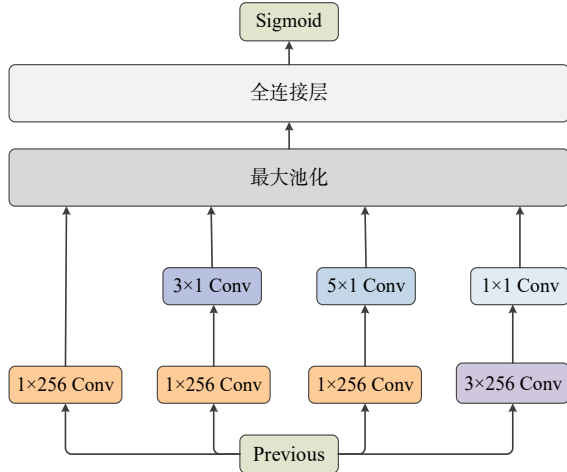


Fig. 3 Multi-scale CNN structure

图3 多尺度CNN结构

多尺度CNN模块通过多个卷积通道并行处理Transformer Encoder输出的特征向量,并在最后进行最大池化操作。模块使用4个卷积通道获取特征向量信息,其中第1个通道只有1层卷积,为 1×256 ,1表示卷积核尺寸,256表示卷积核数量。第2、3、4个通道均使用两层卷积,可以获得句子隐藏的文本信息。第2、3通道的第1层均为 1×256 尺寸的卷积核,第4通道的第1层为 3×256 尺寸的卷积核;第2通道的第2层为 3×1 尺寸的卷积核,第3通道的第2层为 5×1 尺寸的卷积核,第4通道的第2层为 1×1 尺寸的卷积核。对4个通道均进行最大池化,选取权重最大的几个特征信息进行拼接后输入全连接层,然后使用sigmoid函数获取分类结果。

3 实验方法与结果分析

3.1 实验环境

本文实验在Linux系统中完成,操作系统为Ubuntu 64位,CPU为Intel E5-2620,NVIDIA GTX2080Ti,显存容量为11 G。使用Pytorch 1.2.0框架平台,Python版本为3.7。

3.2 实验数据集

SMP2020 微博情绪分类技术评测(The Evaluation of Weibo Emotion Classification Technology, SMP2020-EWECT,以下简称SMP)包含通用数据集和疫情新闻数据集两种^[19],疫情新闻数据集数量较少,本文选用通用数据集。该数据集为多分类性质,对其标签进行处理得到一个二分类数据集。

weibo_senti_100k(以下简称WS)是网络公开的新浪微博评论数据集,内含大量新闻评论数据,是一个含有正负标签的数据集^[20]。该数据集含有一些标签错误或内容为空的数据,需先将其去除。处理后的两个数据集信息表1所示。

3.3 评价标准

采用准确率(Accuracy)、精准率(Precision)、召回率

Table 1 Datasets information

表1 数据集信息

数据集	总数量	训练集	测试集
SMP	21 986	17 985	4 001
WS	119 988	110 000	6 090

(Recall)、F1值4个指标判断模型优劣。计算这4个指标需要用到混淆矩阵。见表2。

Table 2 Confusion matrix

表2 混淆矩阵

	真实类别为正	真实类别为负
预测类别为正	TP	FP
预测类别为负	FN	TN

准确率、精准率、召回率、F1值的计算公式分别为:

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (2)$$

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

$$F1 = \frac{2PR}{P + R} \quad (5)$$

式中:F1中的P和R分别表示精准率和召回率。

3.4 实验参数选取与优化

采用Adam优化器进行模型训练,设置超过1 000 batch 损失还没有下降或效果没有提升便停止训练。学习率设为 $1E-5$,Dropout为0.4,Epoch为5,BERT隐藏层数量为768;多尺度CNN卷积分为两层,第1层尺寸分别为 1×256 、 1×256 、 1×256 、 3×256 ,第2层尺寸为 0 、 3×1 、 5×1 、 1×1 。

3.4.1 Maxlen长度选取

句子最大长度(Maxlen)对算法结果影响很大。最大长度过小会损失过多情感信息,导致模型性能下降;最大长度过大会使数据量增大,导致模型训练速度变慢^[21-22]。首先对新闻评论的长度进行统计,确定合适的句子长度。两个数据集的文本长度统计如图4所示。

在实验中,如果评论长度小于最大长度,使用0对向量进行填充;若大于最大长度,则对向量进行截断处理^[23]。通过对最大长度进行改变,观察模型性能的变化情况。实验结果如图5所示。

可以看出,在两个数据集中,当Maxlen为125时,性能最佳。当Maxlen小于125时,各项指标随着Maxlen的增加而增加,而当超过125时,各项指标呈现下降趋势,这是由于0向量的填充影响了测试结果。因此,句子最大长度设定为125。

3.4.2 Encoder层数考察

不同Encoder层数对本文模型性能的影响结果如图6所示。可以看出,在两个数据集上,Encoder层数从1增加至4时,模型准确率、精准率、召回率、F1值均逐渐上升;但在4层之后,随着层数的继续增加,模型各项指标逐渐降低。因此,本文将Transformer中的Encoder层数设置为4。

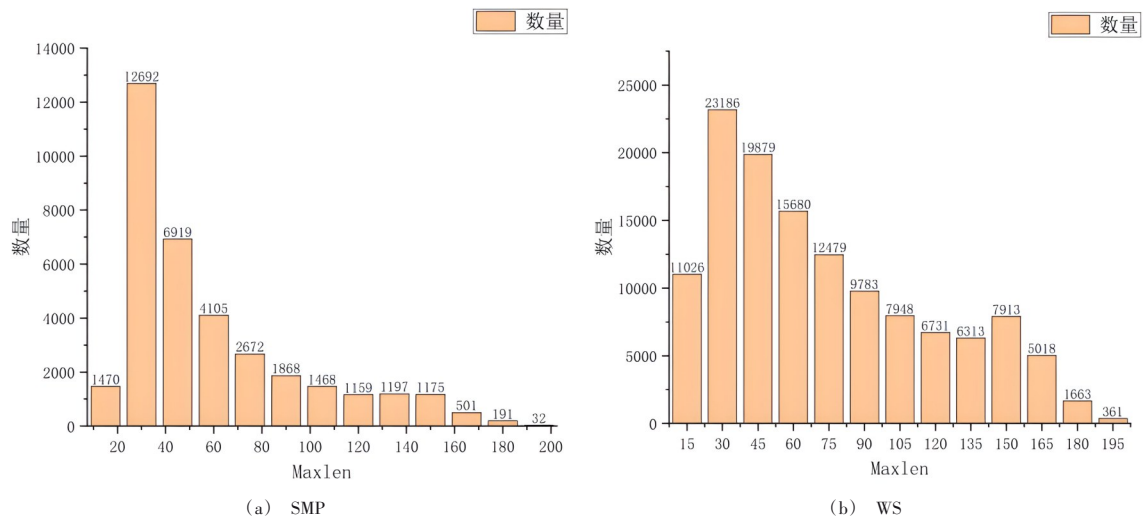


Fig. 4 SMP and WS dataset text length distribution

图4 SMP和WS数据集文本长度分布

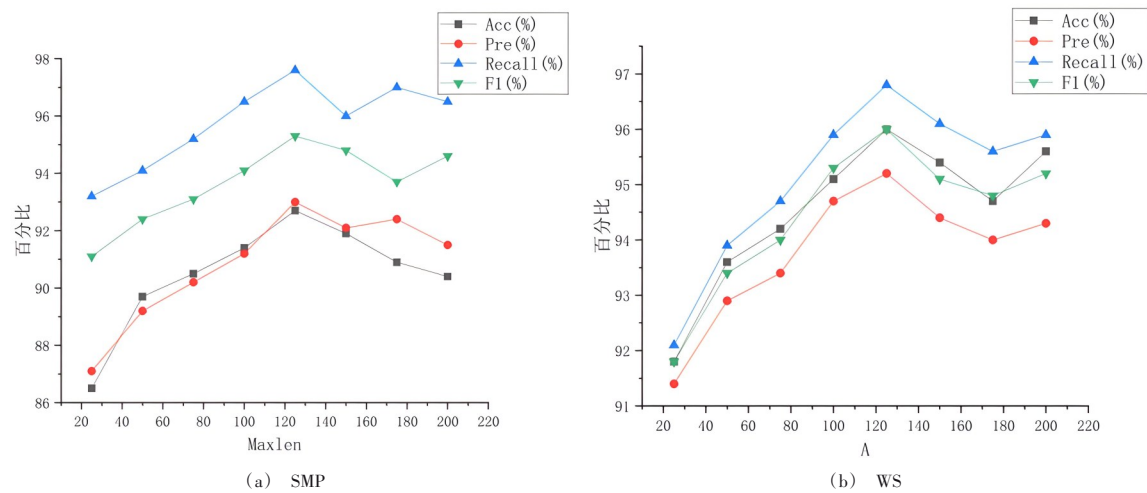


Fig. 5 The variation of model performance with Maxlen length

图5 模型性能随最大长度的变化结果

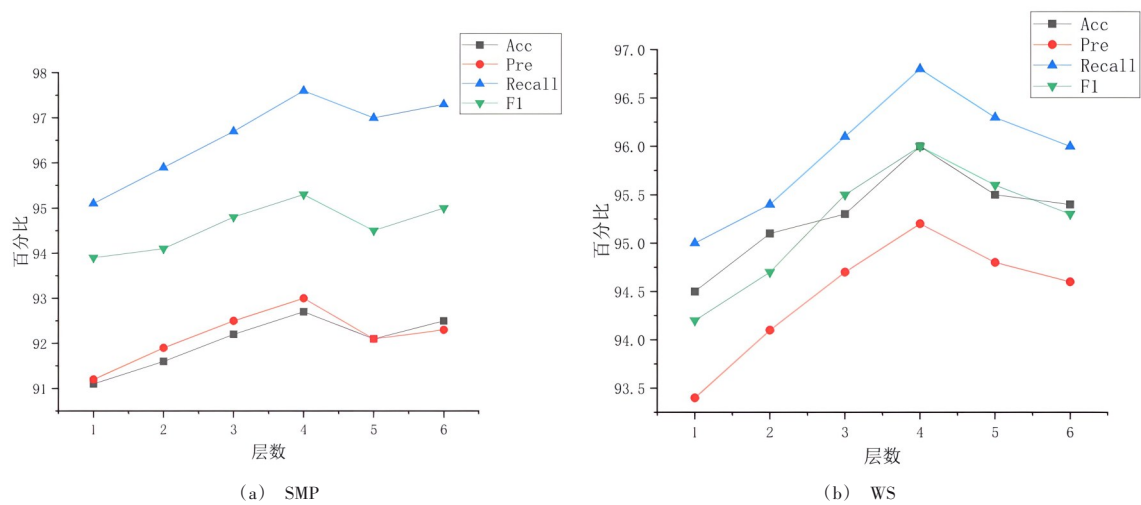


Fig. 6 The variation of model performance with the number of Encoder layers

图6 模型性能随Encoder层数的变化

3.5 比较实验

选择 TextCNN^[2]、BERT+TECNN^[4]、BERT^[10]、CNN-RNN^[24]、BiGRU-Attention^[25]作为对照模型,在两个数据集上与本文模型进行比较,结果如表3、表4所示。

Table 3 Comparison of different models on SMP dataset

表3 不同模型在SMP数据集上的比较 (%)

模型	Acc	Pre	Recall	F1
TextCNN	83.1	85.1	94.3	89.5
BERT	87.3	87.8	96.4	91.9
CNN-RNN	92.0	91.3	93.0	92.1
BiGRU-Attention	91.8	91.8	95.4	93.5
BERT+TECNN	91.4	91.6	97.4	94.4
本文模型	93.0	93.0	98.4	95.6

Table 4 Comparison of different models on WS dataset

表4 不同模型在WS数据集上的比较 (%)

模型	Acc	Pre	Recall	F1
TextCNN	89.5	93.4	85.5	89.3
BERT	91.3	89.6	93.1	91.3
CNN-RNN	93.0	92.6	95.0	93.8
BiGRU-Attention	93.3	93.9	93.6	93.7
BERT+TECNN	94.6	93.7	95.5	94.6
本文模型	96.4	95.5	97.2	96.4

可以看出,在相同的硬件条件和数据集下,本文模型性能相较5个对照模型均有不同程度的提升。且本文模型在WS数据集上的表现优于SMP数据集,这是由于WS数据集规模大,模型训练效果更好。

3.6 消融实验

为验证BE-MCNN模型各模块的有效性,设计了以下消融实验。BE-MCNN w/o Transformer指将BE-MCNN模型中的Transformer Encoder结构移除;BE-MCNN w/o Multi-scale指将BE-MCNN模型中的多尺度CNN改为textCNN。消融实验结果见表5、表6。

Table 5 Ablation experimental results of SMP dataset

表5 SMP数据集消融实验结果 (%)

模型	Acc	Pre	Recall	F1
BE-MCNN w/o Transformer	90.5	90.9	90.1	90.5
BE-MCNN w/o Multi-scale	90.7	91.6	97.4	94.4
本文模型	93.0	93.0	98.4	95.6

Table 6 Ablation experimental results of WS dataset

表6 WS数据集消融实验结果 (%)

模型	Acc	Pre	Recall	F1
BE-MCNN w/o Transformer	92.0	90.9	92.4	91.6
BE-MCNN w/o Multi-scale	91.0	91.8	90.4	91.1
本文模型	96.4	95.5	97.2	96.4

可以看出,引入Transformer Encoder或多尺度CNN结构后,两个数据集的准确率提升了2.3%~5.4%,表明Transformer Encoder结构与多尺度CNN结构均可有效提升模型性能。

4 结语

为帮助政府舆情监测部门和各公司公关部门等快速整理筛选新闻评论,从中获取公众对各个新闻的情感倾向,本文提出一种基于BE-MCNN的情感分析模型,其结合了BERT、transformer编码器与多尺度CNN的优点,可获取更加全面的特征信息;然后与不同尺度的特征进行融合,进一步丰富句子的语义信息,提升模型的分类性能。在2个微博数据集上的比较及消融实验表明,本文模型的情感分析效果更佳。

然而本文模型仍然存在一些局限性,例如规模较大,所需参数较多,导致模型训练速度较低,耗时长。下一步可以考虑通过添加注意力机制对向量进行加权^[26],提高情感词汇的权重,使模型对新闻评论情感分析更具有针对性。

参考文献:

- [1] LI Z J, FAN Y, WU X J. A review of pre-training techniques for natural language processing[J]. Computer Science, 2020, 47(3): 162-173. 李舟军, 范宇, 吴贤杰. 面向自然语言处理的预训练技术研究综述[J]. 计算机科学, 2020, 47(3): 162-173.
- [2] KIM Y. Convolutional neural networks for sentence classification[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing, 2014: 1746-1751.
- [3] JIN Y, ZHU Q, DENG X. Weighted hierarchy mechanism over BERT for long text classification[C]//International Conference on Artificial Intelligence and Security, 2021: 566-574.
- [4] LI T F, SHENG L, WU D. Research on text classification based on BERT-TECNN model [J]. Computer Engineering and Applications, 2021, 57(18): 186-193. 李铁飞, 生龙, 吴迪. BERT-TECNN模型的文本分类方法研究[J]. 计算机工程与应用, 2021, 57(18): 186-193.
- [5] JANG B, KIM I, KIM J W. Word2vec convolutional neural networks for classification of news articles and Tweets [J]. PloS One, 2019, 14(8): 1-20.
- [6] PHAM D H, LE A C. Exploiting multiple word embeddings and one-hot character vectors for aspect-based sentiment analysis [J]. International Journal of Approximate Reasoning, 2018, 103: 1-10.
- [7] MEE A, HOMAPOUR E, CHICLANA F, et al. Sentiment analysis using TF-IDF weighting of UK MPs' tweets on Brexit [J]. Knowledge-Based Systems, 2021, 228: 1-17.
- [8] THARA S, SIDHARTH S. Aspect based sentiment classification: SVD features [C]//2017 International Conference on Advances in Computing, Communications and Informatics, 2017: 2370-2374.
- [9] NURIFAN F, SARNO R, SUNGKONO K R. Aspect based sentiment

- analysis for restaurant reviews using hybrid elmo-wikipedia and hybrid expanded opinion lexicon-senticircle[J]. *International Journal of Intelligent Engineering and Systems*, 2019, 12(6): 47-58.
- [10] DEVLIN J, CHANG M W, LEE K, et al. BERT: pre-training of deep bidirectional transformers for language understanding [J]. *Association for Computational Linguistics*, 2019, 1: 4171-7186.
- [11] LIAO S, WANG J, YU R, et al. CNN for situations understanding based on sentiment analysis of Twitter data [J]. *Procedia Computer Science*, 2017, 111: 376-381.
- [12] CAN E F, EZEN C A, CAN F. Multilingual sentiment analysis: an RNN-based framework for limited data [DB/OL]. <https://arxiv.org/abs/1806.04511>.
- [13] WANG Y, HUANG M, ZHU X, et al. Attention-based LSTM for aspect-level sentiment classification [C]//*Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing*, 2016: 606-615.
- [14] BHUVANESHWARI P, RAO A N, ROBINSON Y H, et al. Sentiment analysis for user reviews using Bi-LSTM selfattention based CNN model [J]. *Multimedia Tools and Applications*, 2022, 81(9): 12405-12419.
- [15] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [DB/OL]. <https://arxiv.org/abs/1706.03762>.
- [16] WANG D, GUO X, TIAN Y, et al. TETFN: a text enhanced transformer fusion network for multimodal sentiment analysis [J]. *Pattern Recognition*, 2023, 136(C): 109259.
- [17] SUN C A, DING Y, TIAN G. Neural network analysis of affective tendency based on GLU-CNN and Attention-BiLSTM [J]. *Software*, 2019, 40(7): 62-66.
孙承爱,丁宇,田刚. 基于GLU-CNN和Attention-BiLSTM的神经网络情感倾向性分析[J]. *软件*, 2019, 40(7): 62-66.
- [18] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions [C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2015: 1-9.
- [19] The 9th National Social Media Processing Conference. SMP2020 Weibo sentiment classification technology evaluation (SMP2020 EWECT) [EB/OL]. <https://smp2020ewect.github.io/>.
第九届全国社交媒体处理大会. SMP2020微博情绪分类技术评测 (SMP2020-EWECT) [EB/OL]. <https://smp2020ewect.github.io/>.
- [20] Github. Weibo_senti_100k dataset [EB/OL]. https://link.csdn.net/?target=https%3A%2F%2Fgithub.com%2FSophonPlus%2FChineseNlpCorpus%2Fblob%2Fmaster%2Fdatasets%2Fweibo_senti_100k%2Fintro.ipynb.
- [21] XU P, LUO Z X, HUANG X K. Research on sentiment analysis of product reviews based on Bert BiLSTM [J]. *Intelligent Computer and Applications*, 2022, 12(11): 186-191.
徐鹏,罗梓汛,黄昕凯. 基于Bert-BiLSTM的商品评论情感分析研究 [J]. *智能计算机与应用*, 2022, 12(11): 186-191.
- [22] DONG J, FAN Q R, ZHANG S J. Emotional analysis of Weibo text in the context of sudden major public health incidents [J]. *Journal of Inner Mongolia Normal University (Natural Science Chinese Edition)*, 2022, 51(5): 489-493, 510.
董婧,范全润,张顺吉. 突发重大公共卫生事件情境下的微博文本情感分析 [J]. *内蒙古师范大学学报(自然科学汉文版)*, 2022, 51(5): 489-493, 510.
- [23] LYU M Y, ZHANG Y J, ZHANG Y Q, et al. A sentiment analysis method for comment texts incorporating sentiment information word vectors [J]. *Journal of Hebei University of Science and Technology*, 2021, 42(4): 380-388.
吕妹园,张永健,张永强,等. 融入情感信息词向量的评论文本情感分析方法 [J]. *河北科技大学学报*, 2021, 42(4): 380-388.
- [24] SOUMA W, VODENSKA I, AOYAMA H. Enhanced news sentiment analysis using deep learning methods [J]. *Journal of Computational Social Science*, 2019, 2(1): 33-46.
- [25] FU W, WANG Y X, WANG Y Q, et al. A novel approach to web text sentiment analysis based on Bi-GRU neural network and self-attention mechanism [P]. China, CN112527966B, 2022-09-20.
付蔚,王榆心,王彦青,等. 基于Bi-GRU神经网络和自注意力机制的网络文本情感分析方法 [P]. 中国, CN112527966B, 2022-09-20.
- [26] LI H, MA Y, MA Z, et al. Weibo text sentiment analysis based on BERT and deep learning [J]. *Applied Sciences*, 2021, 11(22): 10774.
(责任编辑:尹晨茹)