

文章编号:1674-2869(2019)04-0386-06

# 基于CNN-BiLSTM网络引入注意力模型的 文本情感分析

王丽亚,刘昌辉\*,蔡敦波,赵彤洲,王 梦

武汉工程大学计算机科学与工程学院,湖北 武汉 430205

**摘 要:**为了解决单一卷积神经网络(CNN)缺乏利用文本上下文信息的能力和简单循环神经网络(RNN)无法解决长时依赖的问题,提出CNN-BiLSTM网络引入注意力模型的文本情感分析方法。首先利用CNN的特征强学习能力提取局部特征,再利用双向长短期记忆网络(BiLSTM)提取上下文相关特征的能力进行深度学习,最后,增加注意力层获取重要特征,使模型提取到有效的特征。在IMDB数据集上Accuracy值和均方根误差(RMSE)值分别达到90.34%和0.296 7,在Twitter数据集上Accuracy值和RMSE值分别达到76.90%、0.417 4,且模型时间代价小。结果表明,本文提出的模型有效提升了文本分类的准确率。

**关键词:**卷积神经网络;CNN-BiLSTM;注意力机制;文本情感分析

**中图分类号:**TP391      **文献标识码:**A      **doi:**10.3969/j.issn.1674-2869.2019.04.016

## Text Sentiment Analysis Based on CNN-BiLSTM Network and Attention Model

WANG Liya, LIU Changhui\*, CAI Dunbo, ZHAO Tongzhou, WANG Meng

School of Computer Science and Engineering, Wuhan Institute of Technology, Wuhan 430205, China

**Abstract:** To solve the problems that single Convolutional Neural Network (CNN) lacks the ability to utilize text context information and simple Recurrent Neural Network (RNN) cannot deal with long-term dependence, we propose a text sentiment analysis method by introducing the attention model into a CNN-BiLSTM network. In the CNN-BiLSTM network, CNN model and Bidirectional Long Short-Term Memory (BiLSTM) model are used to extract local features and context-related features, respectively. After that, the attention layer is used to focus our attention on the most critical features. Experiments were performed on both IMDB and Twitter datasets. The accuracy and Root Mean Squared Error (RMSE) achieved on IMDB dataset are 90.34% and 0.296 7, respectively. As to dataset Twitter, 76.90% accuracy and 0.417 4 RMSE are achieved. The experimental results show that our technique is able to improve the accuracy of text classification effectively with little runtime overhead.

**Keywords:** convolutional neural network; CNN-BiLSTM; attention mechanism; text sentiment analysis

情感分析<sup>[1]</sup>是自然语言处理领域的一个重要研究方向,文本情感分析的主要目的是从原始文本中提取出说话人的主观情绪,包括其针对某个对象的立场是褒扬还是贬损,其对某事件的态度

是积极还是消极等等。

情感分析方法主要是基于有监督学习、基于语言学和基于深度学习的三类方法<sup>[2]</sup>。随着深度学习在图像处理和语音识别领域的成功应用,便

收稿日期:2019-04-24

基金项目:国家自然科学基金(61103136);武汉工程大学研究生教育创新计划项目(CX2018196)

作者简介:王丽亚,硕士研究生。E-mail:lia.w@qq.com

\*通讯作者:刘昌辉,博士,副教授。E-mail:lch52012@qq.com

引文格式:王丽亚,刘昌辉,蔡敦波,等. 基于CNN-BiLSTM网络引入注意力模型的文本情感分析[J]. 武汉工程大学学报,2019,41(4):386-391.

逐渐将其应用到自然语言处理领域,其中情感分析就是一个很重要的研究方向。Bengio等<sup>[3]</sup>最早使用神经网络构建语言模型。Mikolov等<sup>[4-5]</sup>于2013年提出了word2vec技术,推动了词向量的快速发展。Kim等<sup>[6]</sup>对比了不同词向量构造方法,利用提前训练的词向量作为输入,通过卷积神经网络(convolutional neural network, CNN)实现句子级的文本分类。Lee等<sup>[7]</sup>利用基于循环神经网络(recurrent neural network, RNN)和CNN训练文本的向量,通过普通人工神经网络(ANN)实现文本分类,证明了添加文本序列信息可以提高分类的准确率。普通RNN可以有效地利用近距离的语义信息<sup>[8-9]</sup>,RNN有多种变种循环神经网络模型,长短时记忆网络(long short-term memory, LSTM)<sup>[10-11]</sup>,可以捕捉较远距离的两个文本元素之间的相互关系,获取更多文本序列信息。双向长短时记忆网络(bidirectional long short-term memory, BiLSTM)<sup>[12]</sup>,由两个LSTM组合而成,一个前向传播、一个后向传播,可以有效地利用文本的上下文语义信息。Bahdanau等<sup>[13]</sup>最早提出了注意力机制理论,并将其应用到了机器翻译领域。Mnih等<sup>[14]</sup>在RNN模型上使用了注意力机制来进行图像分类,使得注意力机制真正意义上流行了起来。类似图片,文本中重点信息也会出现分布不均的情况,可以利用注意力机制(Attention)通过对文本向量的语义编码分配不同的注意力权重,以区分文本中信息的重要性大小,提高分类的准确率。

胡荣磊等<sup>[15]</sup>提出了LSTM添加注意力机制的方法,证明了添加注意力机制较传统的机器学习

方法和单纯的长短期记忆网络的方法有明显的优势。Zhou等<sup>[16]</sup>提出C-LSTM模型,将CNN与LSTM以链接的方式构建网络模型,增强了模型特征学习能力从而改进了模型分类效果。

但是单LSTM只能学习前向特征,忽略了后向特征的学习,不能很好的利用上下文语义特征,从而限制了文本分类性能。本文采用CNN基础上添加BiLSTM,并证明了BiLSTM的添加对模型的分

类效果起到正影响,而且弥补LSTM的不足,再在此网络基础上添加注意力机制,在丰富特征信息的同时减少了噪声干扰。通过实验证明了此网络模型对提高文本分类准确率的有效性和高效性。

### 1 CNN-BiLSTM网络引入注意力模型

通过学习已有的神经网络模型,为了提高文本情感分析的准确率,本文提出了CNN-BiLSTM网络引入注意力模型的文本情感分析方法。模型网络结构如图1所示。

其主要包括两个部分:一是CNN-BiLSTM网络构建,本文后面将进行CNN网络与BiLSTM网络连接方式的有效性分析。二是引入注意力模型。实验主要流程为:首先获取大规模语料训练而成的词向量矩阵,生成词索引,通过嵌入层,将其输出作为CNN-BiLSTM网络的输入,然后引入注意力模型,再添加全连接层,最后通过softmax分类器进行情感分类,其中采用dropout技术防止过拟合。




图1 模型的网络结构图

Fig. 1 Network structure diagram of model

1.1 模型表示

给定文本句子数据集  $D$ , 其中包含有文本  $X\{x_1, x_2, \cdots, x_m\}$  及每个句子所对应的情感标签  $Y\{y_1, y_2, \cdots, y_m\}$ , 其中每个文本句子  $x_i$  有  $n$  个词组成, 表示为  $\{x_{i1}, x_{i2}, \cdots, x_{in}\}$ , 最终目标函数为:

$$P(Y|X)=\arg \max _{\theta} f(Y|X ; \theta) \quad(1)$$

1.2 卷积神经网络模型

利用 CNN 提取局部特征。CNN 是一种前馈神经网络, 其模型结构主要包括输入层、卷积层、池化层、全连接层和输出层几部分。

将嵌入层的输出作为输入, 句子中每个词的词向量为  $x_i, x_i \in R^{n \times d}$ , 其中  $n$  是词数,  $d$  是向量维度, 本文定为 200 维。

卷积操作, 主要完成特征提取的工作, 通过设置好的滤波器来完成对输入文本句子特征的提取:

$$J_i=f\left(\omega \times x_{i:i+g-1}+b\right) \quad(2)$$

其中,  $\omega$  是卷积核,  $g$  是卷积核的尺寸,  $x_{i:i+g-1}$  是  $i$  到  $i+g-1$  个词组成的句子向量,  $b$  是偏置项, 通过卷积层后, 得到特征矩阵  $J$ ,  $J=\left[c_1, c_2, \cdots, c_{n-g+1}\right]$ 。

池化层, 通过对卷积层之后得到的句子局部特征矩阵  $C$  进行下采样, 求得局部值的最优解。这里采用 MaxPooling 技术, 如式 (3) 所示:

$$M=\max \left(c_1, c_2, \cdots, c_{n-g+1}\right)=\max \{J\} \quad(3)$$

由于 BiLSTM 输入必须是序列化结构, 池化将中断序列结构  $J$ , 所以需要添加全连接层, 将池化层后的  $M_i$  向量连接成向量  $Q$ :

$$Q=\left\{M_1, M_2, \cdots, M_n\right\} \quad(4)$$

将新的连续高阶窗口  $Q$  作为 BiLSTM 的输入。

1.3 BiLSTM 模型

LSTM 是 RNN 的一个变种, 它存在一个贯穿始终的记忆状态单元 (Memory Units), 该记忆单元遗忘、记忆、输出, 由通过上个时刻的隐藏状态  $h_{t-1}$  和当前输入  $x_t$  计算出来的遗忘门  $f_t$ 、记忆门  $i_t$ 、输出门  $o_t$  来控制, 保留重要的信息, 遗忘不重要的信息, 消除了循环神经网络存在的梯度爆炸 (Gradient Explosion) 或梯度消失问题。其原理图如图 2 所示。

计算遗忘门  $f_t$ , 根据  $h_{t-1}$  和  $x_t$  计算, 如式 (5) 所示:

$$f_t=\operatorname{logistic}\left(W_f x_t+U_f h_{t-1}+b_f\right) \quad(5)$$

根据  $h_{t-1}$  和  $x_t$  计算, 计算记忆门  $i_t$ :

$$i_t=\operatorname{logistic}\left(W_i x_t+U_i h_{t-1}+b_i\right) \quad(6)$$

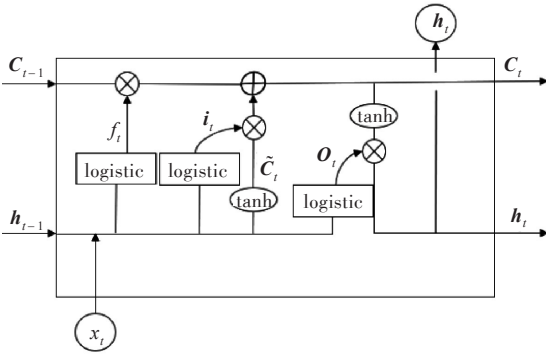


图 2 长短期记忆单元模型的网络结构图  
Fig. 2 Network structure of LSTM model

根据  $h_{t-1}$  和  $x_t$  计算, 计算临时记忆状态  $\tilde{C}_t$ :

$$\tilde{C}_t=\tanh \left(W_c x_t+U_c h_{t-1}+b_c\right) \quad(7)$$

计算当前记忆状态  $C_t$ , 根据  $f_t, i_t, \tilde{C}_t$  和上一时刻记忆  $C_{t-1}$  计算:

$$C_t=i_t \cdot \tilde{C}_t+f_t \cdot C_{t-1} \quad(8)$$

计算输出门  $o_t$ , 根据  $h_{t-1}$  和  $x_t$  计算, 如式 (9) 所示:

$$o_t=\operatorname{logistic}\left(W_o x_t+U_o h_{t-1}+b_o\right) \quad(9)$$

计算当前时刻隐藏状态  $h_t$ , 根据  $o_t$  和  $C_t$  计算, 如式 (10) 所示:

$$h_t=o_t \cdot \tanh \left(C_t\right) \quad(10)$$

其中  $W_f, U_f, W_i, U_i, W_c, U_c, W_o, U_o$  均为权值矩阵;  $b_f, b_i, b_c, b_o$  均为偏置向量;  $\tanh$ : 激活函数;  $\operatorname{logistic}$ : 激活函数。

BiLSTM 由正向 LSTM 与反向 LSTM 结合而成, 若记  $t$  时刻正向 LSTM 输出的隐藏状态为  $\bar{h}_t$ , 反向 LSTM 输出的隐藏状态为  $\overleftarrow{h}_t$ , 则 BiLSTM 输出的隐藏状态  $h_t$ :

$$h_t=\bar{h}_t \oplus \overleftarrow{h}_t \quad(11)$$

1.4 注意力模型

注意力模型是用来表示文本句子中的词与输出结果之间的相关性, 该模型最先被应用于机器翻译的任务中。注意力模型通过对文本向量的语义编码分配不同的注意力权重, 以区分文本中信息的重要性大小, 提高分类的准确率。本文使用前馈注意力模型。

生成目标注意力权重  $v_t, h_t$  是 CNN-BiLSTM 网络输出的隐藏状态:

$$v_t=\tanh \left(h_t\right) \quad(12)$$

注意力权重概率化, 通过 softmax 函数生成概率向量  $p_t$ , 如式 (13) 所示:

$$p_t = \frac{\exp(v_t)}{\sum_{t=1}^m \exp(v_t)}$$

(13)

注意力权重配置,将生成的注意力权重配置给对应的隐层状态语义编码  $h_t$ ,使模型生成的注意力权重发挥作用,  $a_t$  是  $h_t$  的加权平均值,权值是  $p_t$ ,如式(14)所示:

$$a_t = \sum_{t=1}^m p_t \cdot h_t$$

(14)

2 实验部分

实验针对带有情感标签的电影评论和推特评论对提出的情感分析方法进行有效性验证。其中,实验所用的嵌入矩阵是 glove 已训练好的词向量 glove.6B.200d。

2.1 实验数据

数据集来自 IMDB 电影评论和 Twitter 用户评论,IMDB 电影评论情感类别是类似豆瓣网站的星级评分制度,最差 1 分至最好 10 分,本文将其分为 2 类,即 1~5 分归为消极情感 0,6~10 归为积极情感 1。Twitter 用户评论情感标签直接为 2 类,消极为 0,积极为 1。实验所用数据集的设置如表 1 所示。

表 1 实验数据设置

Tab. 1 Experimental settings				条
数据集	训练集	验证集	测试集	总数
IMDB	22 500	2 500	5 000	30 000
Twitter	45 000	5 000	5 000	55 000

2.2 参数设置

实验所用的嵌入矩阵是 glove 已训练好的词向量 glove.6B.200d,词向量维度设置为 200,嵌入索引中找不到的单词将全部为零。卷积神经网络的滤波器窗口大小均分别为 3,4,5,激活函数选择 relu 函数。双向长短时记忆网络的隐藏状态向量维度设置均为 200,Dense 层,为 2 分类,激活函数为 softmax,Dropout 参数设置分别为 0.3,0.2,0.25。模型的优化器 optimizer='adam',采用 fit 函数进行训练,其中训练批次长度 batch-size=32。

2.3 有效性分析

本文提出的方法是在 CNN-BiLSTM 联合网络上引入注意力模型,所以在构建联合网络时会有 CNN、BiLSTM 网络联合次序的影响,这里针对实验数据集,设置对比实验,进行 CNN-BiLSTM 联合次序的有效性分析。

联合次序对比实验结果如表 2 所示。对表 2 中实验结果进行分析:在 Twitter 数据集上,

CNN-BiLSTM 的连接方式比 BiLSTM-CNN 的连接方式,Acc 指标高约 1.01%,RMSE 指标优化了约 0.32%。在 IMDB 数据集上,前者比后者 Acc 指标高约 0.18%,RMSE 指标优化了约 1.20%。说明了 CNN-BiLSTM 的连接方式比 BiLSTM-CNN 的连接方式,在引入注意力模型后,分类效果上有所提高。

表 2 联合次序对比实验结果

Tab. 2 comparison experimental results in different model-combining order				
模型	IMDB		Twitter	
	Acc / %	RMSE	Acc / %	RMSE
BiLSTM-CNN-Attention	90.16	0.308 7	75.89	0.420 6
CNN-BiLSTM-Attention	90.34	0.296 7	76.90	0.417 4

从验证集的准确率(val\_acc)上来看, Twitter 的 val\_acc 变化如图 3 所示,本文模型 val\_acc 值均在 BiLSTM-CNN-Attention 模型之上。IMDB 的 val\_acc 变化如图 4 所示,本文模型 val\_acc 本文模型多数高于对比模型,且波动性平稳,说明了 CNN-BiLSTM 的连接方式在模型分类效果上更具有优势,更加稳定。




图 3 Twitter 训练时 val\_acc 的变化图  
Fig. 3 val\_acc plots in Twitter training




图 4 IMDB 训练时 val\_acc 的变化图  
Fig. 4 val\_acc plots in IMDB training



整体上,针对 2 组数据集,训练中迭代次数均设置为 10 次,且模型训练结果均取得较好的分类效果,说明了本文模型在短时间有很好的收敛性,即能高效地提高文本分类准确率。

再从时间代价上来看,2 组模型的时间代价如图 5~图 6 所示,横坐标是模型训练的迭代次数,纵坐标是模型训练时每次迭代所用时间,时间单位均为 s。针对 Twitter 数据,BiLSTM-CNN-Attention 模型的训练速度都在 360 s 以上波动,本文模型的训练速度均在 20 s 左右波动,总体对比实验模型要比本文模型约慢 1 倍。即在时间代价上,CNN-BiLSTM 的连接方式耗时少,有利于加快模型的训练速度。




图 5 Twitter 的时间代价图  
Fig. 5 Epoch-time plots of Twitter




图 6 IMDB 的时间代价图  
Fig. 6 Epoch-time plots of IMDB

在 IMDB 数据上,BiLSTM-CNN-Attention 模型的训练速度均超过 1 800 s,而本文模型的训练速度均在 800 s 附近波动,总体本文模型要比对比实验模型快 1 倍多。说明了 CNN-BiLSTM 的连接方式在训练速度上保持了高效性。

由于 Twitter 数据集的最大文本长度为 40,且文本长度多数分布在 4 到 26 之间,而 IMDB 数据集的文本长度集中于长度为 400 以内,约是 Twitter 数

据集单句评论文本的 10 倍。可见,在短文本中相对较长的文本数据集上,CNN-BiLSTM-Attention 模型比 BiLSTM-CNN-Attention 模型的总体训练速度更有明显的优势。

综上所述,针对本文实验所用数据集,CNN-BiLSTM 的连接方式在文本分类上更具有高效性和有效性,所以本文选择在 CNN-BiLSTM 的连接方式上引入注意力模型。

2.4 实验结果分析

实验针对数据集 IMDB、Twitter 进行情感分析,并设置了以下多组对比试验,包括 SVM 与深度学习方法的比较,单一网络与 CNN-BiLSTM 联合网络的比较,及与引入注意力模型的网络对比。网络输入均是利用 word2vec 训练的词向量。

SVM<sup>[17]</sup>:采用传统机器学习算法 SVM 进行情感分析;

BiLSTM<sup>[18]</sup>:单一的 BiLSTM 网络

CNN<sup>[19]</sup>:单一的 CNN 网络。

CNN-BiLSTM:先添加一个 CNN 网络,再添加一个 BiLSTM 网络。

CNN-BiLSTM-Attention:先添加一个 CNN 网络,再添加一个 BiLSTM 网络,最后引入 Attention 机制。

表 3 对比实验结果  
Tab. 3 Comparison experimental results

模型	IMDB		Twitter	
	Acc / %	RMSE	Acc / %	RMSE
SVM	78.64	0.521 3	63.25	0.517 5
BiLSTM	84.29	0.413 7	71.24	0.435 1
CNN	85.94	0.351 0	72.08	0.457 2
CNN-BiLSTM	87.93	0.328 2	73.27	0.429 3
CNN-BiLSTM-Attention	90.34	0.296 7	76.90	0.417 4

多组对比实验结果如表 3 所示,从模型评价的结果上来看,深度学习模型结果明显优于传统 SVM 方法。在 Twitter 数据集上,CNN-BiLSTM 的联合网络比单 BiLSTM 网络,Acc 指标高约 2.03%,RMSE 指标优化了约 0.58%。CNN-BiLSTM 的联合网络比单 CNN 网络,Acc 指标高约 1.19%,在 RMSE 上优化了约 2.76%。在 IMDB 数据集上,联合网络比单 BiLSTM 网络,Acc 指标高约 3.64%,RMSE 指标优化了约 8.55%。联合网络比单 CNN 网络,Acc 指标高约 1.99%,在 RMSE 上优化了约 2.28%。综上,CNN-BiLSTM 的联合网络比单模型的效果要好,这是由于 CNN 在提取局部特征上更有优势,利用 CNN 可以很好的提取文本中局部重要信息,而

BiLSTM网络不但能捕捉上文长时间间隔的特征,也能很好的利用下文特征,从而利用文本的语序和语法信息,而文本语序不同,表达的含义就会相差甚远,从而影响文本情感分析的准确度,CNN-BiLSTM的联合网络综合了二者的优点。

在Twitter数据集上,CNN-BiLSTM网络引入注意力模型比CNN-BiLSTM的联合网络,Acc指标高约3.63%,RMSE指标优化了约1.19%。在IMDB数据集上,前者比后者,Acc指标高约2.41%,RMSE指标优化了约3.15%。这是由于注意力模型通过对输入的向量编码,分配不同的注意力权重,区分重要性大小,以获取重要的局部特征。即在提取文本特征时,加强了有关情感的语义特征权重,同时弱化了情感不相关的语义特征权重。结果表明,基于CNN-BiLSTM的联合网络,添加注意力模型,可以提高分类的准确率。

3 结 语

本文提出了一种CNN-BiLSTM网络引入注意力模型的文本情感分析方法。通过利用BiLSTM学习CNN池化后连接而成的特征,解决了单CNN缺乏利用文本上下文信息的问题,同时避免了简单RNN带来的梯度爆炸或梯度消失,最后引入注意力模型筛选特征,降低了噪声干扰,从而提高文本情感分类的准确率。实验结果证明了CNN-BiLSTM网络引入注意力模型的方法的有效性和CNN-BiLSTM网络联合次序的高效性。但联合网络中CNN网络的深度不够,今后研究如何利用深度更深的CNN网络来提高分类准确率,是下一步工作的目标。

参考文献

[1] PANG B, LEE L, VAITHYANATHAN S. Sentiment classification using machine learning techniques [C]// Proceedings of Cnference on Empirical Methods in Natural Language Processing Slrroudstarg. Associaton for Computation Linguisilics, Philadelphia;2002:79-86.

[2] 李松如.基于循环神经网络的网络輿情文本情感分析技术研究[D].泉州:华侨大学,2017.

[3] BENGIO Y, SCHWENK H, SENEAL J S, et al. A neural probabilistic language model [J]. Journal of Machine Learning Research, 2003, 3(6):1137-1155.

[4] MIKOLOV T, CHEN K, CORRADO G, et al. Efficient estimation of word representations in vector spac e[EB/OL]. [2017-08-04]. <http://www.surdeanu.info/mihai/teaching/ista555-spring15/readings/mikolov2013.pdf>.

[5] MIKOLOV T, SUTSKEVER I, CHEN K, et al. Distrib-

uted representations of words and phrases and their Compositionality [J]. Advances in Neural Information Processing Systems, 2013(26):3111-3119.

[6] KIM Y.Convolutional neural networks for sentence classification[C] //Proceedings of the EMNLP, 1746-1751.

[7] LEE J Y, DERNONCOURT F. Sequential short-text classification with recurrent and convolutional neural networks[J]. Eprint Arxiv: 2016,2(1):515-520.

[8] MERRIENBOER B V, GULCEHRE C. Learning phrase representations using RNN encoder decoder for statistical machine translation[J]. Computer Science,2014:1-12.

[9] EBRAHIMI J, DOU D. Chain based RNN for relation classification [C] //Conference of the North American Chapter of the Association for Computational Linguistics. Denver, colorado: Association tor Computational Linguistics,2015: 1244-1249.

[10] 孙晓,彭晓琪,胡敏,等.基于多维扩展特征与深度学习的微博短文本情感分析[J].电子与信息学报, 2017,39(9): 2048-2055.

[11] CHEN W , XU B. Semi-supervised Chinese word segmentation based on bilingual information[C]//Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing, Lisbon, Portugal: Association for Computational Linguistics, 2015: 1207-1216.

[12] ANDRIY M, GEOFFREY H. A scalable hierarchical distributed language model [C]// The Conference on Neural Information Processing Systems (NIPS) , 2008: 1081-1088

[13] BAHDANAU D, CHO K, BENGIO Y. Neural Machine translation by jointly learning to align and translate [EB/OL]. [2018-03-20].<https://arxiv.org/pdf/1409.0473v7.pdf>.

[14] MNIH V, HEES N, GRAVES A. Recurrent models of visual attention[J] Advances in Neural Information Processing Systems.2014,36(9): 2204-2212.

[15] 胡荣磊,芮璐,齐筱,等.基于循环神经网络和注意力模型的文本情感分析[J/OL].计算机应用研究,2019(11): 1-7[2019-04-19].<http://kns.cnki.net/kcms/detail/51.1196.TP.20180811.1330.064.html>.

[16] ZHOU C, SUN C, LIU Z, et al. A C-LSTM neural network for text classification [J]. Computer Science, 2015,1(4): 39-44.

[17] 常丹,王玉珍.基于SVM的用户评论情感分析方法研究[J].枣庄学院学报,2019,36(2):73-78.

[18] 任勉,甘刚.基于双向LSTM模型的文本情感分类[J].计算机工程与设计,2018,39(7):2064-2068.

[19] 王煜涵,张春云,赵宝林,等.卷积神经网络下的Twitter文本情感分析[J].数据采集与处理,2018,33(5):921-927.