付帅. 基于 ERNIE-RCNN 模型的电商评论情感分析[J]. 智能计算机与应用,2025,15(4):139-144. DOI:10.20169/j.issn.2095-2163.250419

基于 ERNIE-RCNN 模型的电商评论情感分析

付 帅
(南京邮电大学 管理学院, 南京 210003)

摘 要: 针对中文文本存在文本规范性差、一词多义和与上下文情境关联性大等特点,本研究融合 ERNIE 动态词向量模型与 RCNN 深度学习模型,提出了一种基于 ERNIE-RCNN 模型的电商评论情感分析模型。首先利用 ERNIE 动态词嵌入模型获得评论文本的动态表征,将文本转化为动态词向量,并将向量化后的文本输入 RCNN 模型中,通过 RCNN 模型中的 RNN 结构捕获广泛的上下文信息,更好地获取全局信息,随后使用最大池化获取文本的重要特征,突出文本的重要信息,最后通过 Softmax 进行分类。在京东电商评论数据集上的实验结果表明,该模型与其他深度学习模型相比表现出更高的准确性,在电商评论领域具有较强的适用性。

关键词: 情感分析; 深度学习; ERNIE; RCNN; 电商评论
中图分类号: TP391 **文献标志码**: A **文章编号**: 2095-2163(2025)04-0139-06

Sentiment analysis of e-commerce reviews based on ERNIE-RCNN model

FU Shuai
(School of Management, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

Abstract: Aiming at the characteristics of Chinese text, such as poor text normalization, polysemy and great relevance to context, this paper integrates ERNIE dynamic word vector model and RCNN deep learning model, and proposes an e-commerce review sentiment analysis model based on ERNIE-RCNN model. Firstly, the ERNIE dynamic word embedding model is used to obtain the dynamic representation of the comment text, and the text is transformed into a dynamic word vector. The vectorized text is input into the RCNN model, and a wide range of context information is captured through the RNN structure in the RCNN model to better obtain the global information. Then, the maximum pooling is used to obtain the important features of the text and highlight the important information of the text. Finally, the Softmax classification is used. The experimental results on the Jingdong e-commerce review data set show that the accuracy of the model is higher than other deep learning models, and has strong applicability in the field of e-commerce reviews.

Key words: sentiment analysis; deep learning; ERNIE; RCNN; e-commerce review

0 引 言

伴随着信息技术的快速发展,网络用户数量不断增加,电商平台的影响力日益增强,电子商务也随即得到了迅猛发展。据《中国电子商务报告(2021)》显示,2021 年全国电子商务交易额达 42.3 万亿元,其中网上零售额达 13.1 万亿元,电商平台已然成为了消费者们购买商品的重要渠道,并且网络购物也已逐步成为一种重要的消费方式[1]。电商平台上商品种类繁多,质量参差不齐,消费者面对这种情况时常会眼花缭乱,此时电商平台中的评论功能便能够记录下消费者对产品的意见与建议[2]。电商评论中包含着消费者对产品的情感表示,通过对电商评论的分析能够减少消费者由于信息不对称产生的购物风险[3]。在电商平台购物时所接触的信息都是由商家单方面填写的描述信息,此时通过分析用户电商评论的情感分布,就可在一定程度上有效辨别商品的真实品质[4],为其他消费者提供借鉴和参考[5]。因此,对电商评论进行情感分析具有重要意义。

针对中文文本存在文本规范性差、一词多义和与上下文情境关联性大等特点,本文提出了一种融合 ERNIE 动态词嵌入模型[6]和循环卷积神经网络(RCNN)[7]的电商评论情感分析模型,动态词嵌入

作者简介: 付 帅(1989—),男,硕士研究生,主要研究方向:用户行为。Email:1132898786@qq.com。

收稿日期: 2023-08-26

模型针对传统静态词嵌入模型无法解决一次多义的问题,在面对中文语料库时展现出了显著优越性。RCNN 模型融合了 RNN 模型与 CNN 模型的优点,能够有效改善 CNN 模型文本窗口大小不足的缺陷[8],并且 RCNN 使用循环结构捕获广泛的上下文信息,能够更好地提取文本特征。

1 相关研究

情感分析、又称为意见挖掘[9],是自然语言处理的重要组成部分,旨在挖掘文本中蕴涵的情感倾向和态度分类。根据技术路线不同,主要可以分为情感词典、机器学习和深度学习的方法。

1.1 基于情感词典的情感分析方法

首先就是构建情感词典,通常是在基础情感词典的基础上加入研究所需的新的情感词,常见的基础情感词典有大连理工大学情感词典、知网情感词典以及台湾大学情感词典等。随后将构建好的情感词典搭配对应的计算规则计算文本中的情感得分,并以此进行情感倾向的判定。丁美荣等学者[10]以基础情感词典为主题,通过加入与酒店评论相关的情感词来构建扩展的情感词典,并在酒店评论情感分析的实验中取得了良好的效果。但由于基础的情感词典在特定的情感分析领域未能取得满意效果,管雨翔等学者[11]使用 SO-PMI 算法,并结合 TF-IDF 和 TextRank 算法构建了一种应用于突发网络舆情时间领域的情感词典,并在相应的案例中进行验证,实验结果表明该方法有一定的准确性与适用性。

然而,基于基础情感词典的情感分析方法虽然运用简便,但其情感分析结果准确性较低,需要对词典进行拓展以提高准确率。但考虑到同一词语在不同的情境下所表达的情感态度可能会有所差异,因此针对特定领域进行拓展的情感词典很难迁移到其他领域[12]。

1.2 基于机器学习的情感分析方法

相比情感词典,机器学习能够有效地降低人工的工作量,可自动进行训练,面对大量数据时有很好的处理能力。传统的机器学习情感分析方法首先是对文本数据进行编码,随后构建机器学习分类器进行情感分析,传统的机器学习模型有:最大熵[13]、支持向量机[14]、朴素贝叶斯[15]、随机森林[16]等。机器学习在情感分析领域得到了广泛的运用:Pang 等学者[17]为了分析电影评论中的情感倾向,使用支持向量机、朴素贝叶斯等机器学习模型进行情感分析,实验结果表明该模型在情感分析领域具有较高的准确性。针对微博数据量大且冗余度高的特征,李首政等学者[18]结合 TF-IFD 算法和词袋模型进行文本特征提取,随后构建支持向量机分类器对微博数据进行情感分析,并在微博评论情感分析实验中得到了较高的准确率。

机器学习方法拓展性和可重复性好,准确度较情感词典有所提高,但该方法的准确率依赖于训练集的标注质量,大量的数据标注需要较高的人工成本,且容易受到个人主观意识的影响。

1.3 基于深度学习的情感分析方法

近年来,深度学习模型在情感分析领域取得可观成果,深度学习模型可以通过多层的神经网络进行多层次的学习以准确捕获文本中的情感特征,从而得到更好的分类效果。常用的深度学习模型包括卷积神经网络(Convolutional Neural Network,CNN)、循环神经网络(Recursive Neural Network,RNN)、长短时记忆网络(Long Short Term Memory,LSTM)和注意力机制(Attention,Att)[19]。

杨秀璋等学者[20]提出一种融合多头注意力机制和双向 LSTM 的情感分析模型用于电商评论情感分析研究,实验结果表明该方法优于现有的机器学习和深度学习模型,具有较好鲁棒性和较高的准确性。针对 CNN 只能提取文本中局部特征与 RNN 存在梯度爆炸的问题,吴贵珍等学者[21]将 CNN 与 BiGRU 模型相结合,增强了文本特征的提取能力,同时引入注意力机制,实验结果表明该模型在文本情感分析领域有较强的实用性。

此外,文本需要向量化表示后才能输入深度学习模型,因为文本向量化后的特征表示能力也将影响到深度学习分类的准确度。常用的文本向量化表示方法包括:Word2Vec、GloVe(Global Vector)、BERT(Bidirectional Encoder Representations from Transformers)、ERNIE 等[21]。Word2Vec 和 GloVe 都属于静态词向量表示模型,即一个向量对应一个词语,无法解决文本中存在着一次多义的问题,但动态词向量模型 BERT[22]和 ERNIE 却对此提出了有效解决方案。BERT 模型是 Devlin 等学者[22]提出的预训练语言模型,该模型基于 Transformer[23]框架,结合注意力机制以及注意力加权操作,能够从双向表示文本的语义信息,并且通过掩码和下一句预测两项训练任务进行训练,在多项 NLP 任务中取得最优性能。ERNIE 则是在 BERT 的基础上进行优化,在掩码任务上做进一步优化,并且增加了更多

中文语料库，在中文 NLP 任务中模型效果超越 BERT。

2　模型设计

为增强文本特征提取能力以及电商评论情感分析的准确性，本文融合 ERNIE 预训练语言模型和 RCNN 模型，提出 ERNIE-RCNN 电商评论情感分析模型，其结构如图 1 所示。首先将原始评论文本进行预处理，包括数据去重、去除无实际意义的杂乱符号及去掉停用词等，然后将文本送入 ERNIE 预训练语言模型得到文本的向量化表示。再将 ERNIE 层的输出送入 RCNN 层，接下来经过 RCNN 层中的卷积神经网络部分对向量化的文本进行卷积操作提取特征向量，随后送入循环神经网络中得到文本的全局表示，最后输入全连接层得到电商评论文本的分类结构。

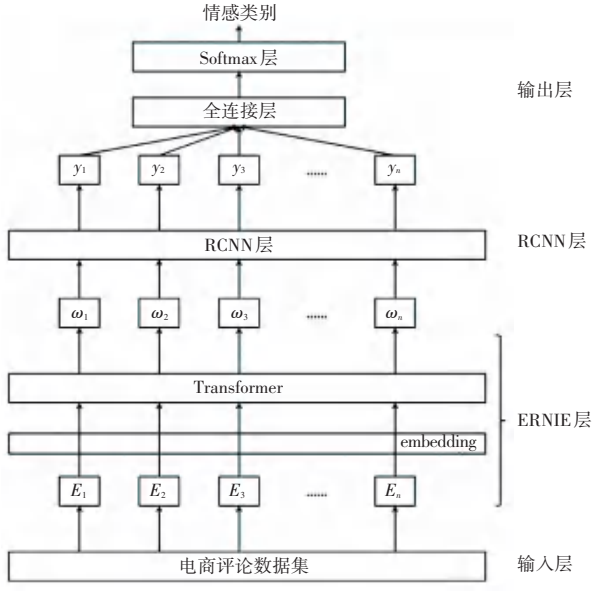

图 1　ERNIE-RCNN 结构图

Fig. 1　Structure of ERNIE-RCNN

2.1　ERNIE 模型

ERNIE(Enhanced Representation through Knowledge Integration)是百度推出的一种基于 BERT 模型的预训练语言模型，其结构如图 2 所示。ERNIE 改进了 BERT 的掩码策略，通过引入多粒度的语言表示来建模不同层次的语义信息，如果在掩码策略中加字级别、词语级别和句子级别的信息，就能更好地理解文本中不同粒度的信息。此外，ERNIE 还使用了更全面的预训练语料，其中包括百度百科、百度贴吧、百度知道等多种文本类型。这使得 ERNIE 能够更好地理解文本中的实体、关系、事件等知识。

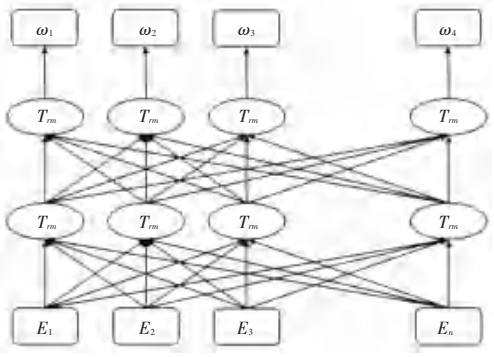

图 2　ERNIE 结构图

Fig. 2　Structure of ERNIE

ERNIE 的主要结构包括 12 层 Transformer 块，每个 Transformer 块包含了多头子注意力机制和前馈神经网络。Transformer 模型主要由 Encoder 和 Decoder 两部分组成，ERNIE 采用的是其 Encoder 部分，其结构如图 3 所示。

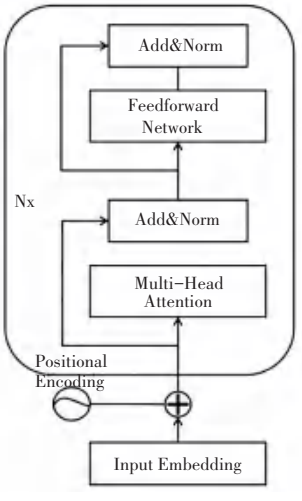

图 3　ERNIE 的 Transformer 模块

Fig. 3　Transformer module of ERNIE

首先输入的文本由输入嵌入层(Input Embedding Layer)层转化为词向量表示；然后经过位置编码层(Positional Encoding Layer)为每个输入的词向量加上一定的位置编码；随后对输入的带有位置编码的数据进行多头注意力计算(Multi-Head Attention Layer)，使其能同时关注不同位置的信息，更好地捕捉上下文信息；接下来会经过残差连接和归一化层(Add&Norm Layer)防止模型出现梯度爆炸、梯度消失和过拟合的问题。此后通过前馈网络层(Feedforward Network Layer)将上一层的输出转化为下一次的输入，最后对最后一层的输出进行分类。

2.2 RCNN 层

RCNN(Recurrent Convolutional Neural Network)模型是一种融合了卷积神经网络(CNN)和循环神经网络(RNN)的模型,RCNN 模型结合了 CNN 模型和 RNN 模型的优点。传统的 CNN 网络是都卷积层+池化层的形式,RCNN 模型可以看作是将卷积层替换成双向 RNN,利用双向 RNN 模型提取文本信息,比基于窗口大小捕获文本特征的卷积神经网络能更有效地减少噪声。此外,该模型使用最大池化获取文本的重要特征,能够自动判断哪部分文本特征对分类结果的影响更大。RCNN 结构如图 4 所示。

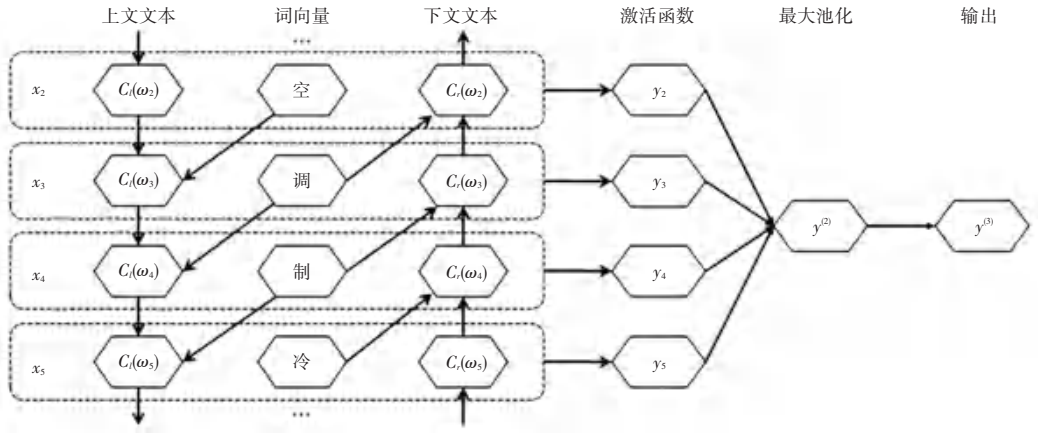

图 4 RCNN 结构图

Fig. 4 Structure of RCNN

首先采用双向 RNN 获得文本的上下文信息,并将双向 RNN 模型的隐层输出与输入的词向量进行拼接得到新的词向量表示,公式如下:

$$\boldsymbol{c}_l(\boldsymbol{\omega}_i)=f(\boldsymbol{W}^{(l)}\boldsymbol{c}_l(\boldsymbol{\omega}_{i-1})+\boldsymbol{W}^{(sl)}\boldsymbol{e}(\boldsymbol{\omega}_{i-1})) \quad (1)$$

$$\boldsymbol{c}_r(\boldsymbol{\omega}_i)=f(\boldsymbol{W}^{(r)}\boldsymbol{c}_r(\boldsymbol{\omega}_{i+1})+\boldsymbol{W}^{(sr)}\boldsymbol{e}(\boldsymbol{\omega}_{i+1})) \quad (2)$$

其中,$\boldsymbol{c}_l(\boldsymbol{\omega}_i)$ 表示第 i 个输入词向量上文信息;$\boldsymbol{c}_r(\boldsymbol{\omega}_i)$ 表示第 i 个输入词向量的下文信息;$\boldsymbol{e}(\boldsymbol{\omega}_{i-1})$ 与 $\boldsymbol{e}(\boldsymbol{\omega}_{i+1})$ 分别表示当前输入词向量的前一个和后一个词的词向量;$\boldsymbol{W}^{(l)}$ 与 $\boldsymbol{W}^{(r)}$ 表示权重矩阵,使向量从当前层转换至下一个隐藏层;$\boldsymbol{W}^{(sl)}$ 与 $\boldsymbol{W}^{(sr)}$ 表示语义结合权重矩阵,将当前语义和上下文语义相结合;f 表示非线性激活函数 tanh。

再将上下文向量表示与当前词向量表示进行拼接得到词 $\boldsymbol{\omega}_i$ 的表示 $\boldsymbol{x}_i$,公式如下:

$$\boldsymbol{x}_i=[\boldsymbol{c}_l(\boldsymbol{\omega}_i),\boldsymbol{e}(\boldsymbol{\omega}_i),\boldsymbol{c}_r(\boldsymbol{\omega}_i)] \quad (3)$$

然后,将 $\boldsymbol{x}_i$ 作为当前词向量 $\boldsymbol{\omega}_i$ 的嵌入表示,再输入激活函数得到 $\boldsymbol{\omega}_i$ 的潜在语义信息 $\boldsymbol{y}_i$,公式如下:

$$\boldsymbol{y}_i=\tanh(\boldsymbol{W}\boldsymbol{x}_i+\boldsymbol{b}) \quad (4)$$

随后,对该条评论文本的向量化表示进行最大池化提取文本中最重要的信息,寻找潜在语义因素,公式如下:

$$\boldsymbol{y}=\max_{i=1}\boldsymbol{y}_i \quad (5)$$

最后,将结果输入全连接层得到文本的最终表示,并通过 Softmax 层进行情感分类即可得到情感输出。

3 实验及结果分析

3.1 实验数据

本研究所采用的数据为利用 Python 的爬虫功能从京东电商网站上爬取的相关电器评论,共爬取了 7 000 条数据评论,预处理后剩余 6 000 条评论,包含 3 500 条好评、1 250 条中评和 1 250 条差评,按照 6∶2∶2 的比例划分验证集、测试集、训练集,实验数据信息见表 1。

表 1 文本数据信息

Table 1 Text data information

数据	好评	中评	差评	总计
训练集	2100	750	750	3 600
测试集	700	250	250	1 200
验证集	700	250	250	1 200
总计	3 500	1 250	1 250	6 000

3.2 实验环境及参数设置

本研究采用 GPU 类型为 GeForce RTX 3090,内存容量为 24 G。模型编程在 Windows 环境下使用 PyTorch 框架实现,Python 版本为 3.7。实验参数设

置见表 2。

表 2　实验模型参数设置

Table 2　Experimental model parameter settings

模型参数	总计
Batch_size	126
Pad_size	64
Epoch	10
Learning_rate	5e - 5
Dropout	0.5
Hidden_size	768
Rnn_hidden	256
Num_layers	2

3.3　评价指标

本研究采用的评价指标为精确率（*P*）、召回率（*R*）和 *F*1 值，计算公式具体如下：

$$P = \frac{TP}{TP + FP} \tag{6}$$

$$R = \frac{TP}{TP + FN} \tag{7}$$

$$F1 = \frac{2 \times P \times R}{P + R} \tag{8}$$

其中，*TP* 表示预测为真的值，实际也为真；*FP* 表示预测为真的值，实际不为真；*TN* 表示预测为假的值，实际也为假；*FN* 表示预测为假的值，实际为真。

3.4　实验结果分析

为验证 ERNIE-RCNN 模型性能，本研究分别开展 2 组实验：比较不同词向量模型的情感分析效果以及比较不同深度学习模型的情感分析效果。

（1）不同词向量模型的情感分析效果。为比较相同深度学习模型结合不同词向量对在线评论情感分析的效果，本研究选用 Word2Vec-RCNN、BERT-RCNN 与 ERNIE-RCNN 进行比较，实验结果见表 3。

表 3　不同词向量模型测试结果

Table 3　Test results of different word vector models　%

模型	*R*	*P*	*F*1
Word2Vec-RCNN	79.15	80.19	79.72
BERT-RCNN	84.07	84.21	83.70
ERNIE-RCNN	**84.83**	**85.65**	**85.17**

实验结果表明 ERNIE、BERT 作为词向量模型效果远远优于 Word2Vec 词向量模型，说明动态词向量模型在情感分类任务上的性能优于静态词向量模型，能够弥补静态词向量无法解决一词多义问题的不足。此外，ERNIE 模型在训练时采用了更全面的语料库，并且在掩码策略中加入字级别、词语级别和句子级别的信息对于中文这种以单个字为单位的语言则比 BERT 模型具有更大优势。

（2）不同深度学习模型的情感分析效果。为对比情感分析模型性能，验证 ERNIE-RCNN 模型的有效性，本研究将 ERNIE-RCNN 模型与 TextCNN、DPCNN、BiLSTM、BERT、ERNIE 模型进行比较，实验结果见表 4。

表 4　不同深度学习模型的情感分析效果

Table 4　Sentiment analysis effect of different deep learning models　%

模型	*R*	*P*	*F*1
DPCNN	74.66	75.67	72.02
BiLSTM	72.80	76.96	73.00
TextCNN	81.44	82.12	81.17
BERT	83.81	83.79	83.47
ERNIE	84.24	85.34	84.51
ERNIE-RCNN	**84.83**	**85.65**	**85.17**

从表 4 可以看出 ERNIE-RCNN 模型在精确率、召回率和 *F*1 值三个指标上均优于其他模型，在 *F*1 值上分别提升了 13.15%、12.17%、4.00%、1.70% 和 0.66%。并且可以看出 ERNIE、BERT 模型相较于传统的深度学习模型有了较大提升，这得益于 ERNIE 模型与 BERT 模型都是基于 Transformer 结构的原因，Transformer 结构中使用了自注意力机制，能够更好到捕捉文本中的全局信息，并且由于其结构问题，ERNIE 与 BERT 模型都包含多层 Transformer 块，每层都会对文本数据进行处理，从而提取出更高层次的特征表达，因此模型效果优于传统的深度学习模型。ERNIE-RCNN 模型结合了 ERNIE 预训练语言模型与 RCNN 模型，不仅能够解决上游任务中存在一次多义的问题，还融合了 CNN 模型和 RNN 模型的优点，利用双向 RNN 模型提取文本信息，减少噪声并通过 CNN 中的最大池化获取文本的重要特征，在电商评论情感分析领域具有良好的性能。

4　结束语

随着信息技术的发展，电商购物由于其方便快捷、选择多样、价格透明和利于比较等优点逐渐受到人们的青睐，越来越多的人选择在网络上进行购物。但网上购物存在的虚拟性、无法亲身体验产品等弊端也是不容忽视的，此时电商平台上的海量评论就能为其他消费者提供参考，而评论中所蕴含的情感倾向则表达了消费者对产品的态度，能够对其他消

费者的购买意愿产生影响。为此,本文研发提出了ERNIE-RCNN 情感分析模型,旨在提升电商评论情感分析的准确性。并在进行对比实验后可知,相比其他模型效果均有提升,仿真结果表明该模型在情感分析领域具有较好的性能。下一阶段的工作将致力于如何在提高模型准确率的同时,进一步减少模型的使用时间,从而有效提升模型效率。

参考文献

[1] 周瑛,张晓宇,虞小芳. 基于产品评论挖掘的消费者偏好分析[J]. 情报科学,2022,40(1):58-65.

[2] 李丹阳. 面向中文评论的情感分析方法研究[D]. 西安:西安工业大学,2019.

[3] HUANG W, LIN M, WANG Y. Sentiment analysis of Chinese e-commerce product reviews using ERNIE word embedding and attention mechanism[J]. Applied Sciences, 2022, 12:7182.

[4] HU Minqing, LIU Bing. Mining and summarizing customer reviews [C]//Proceedings of the Tenth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York:ACM,2004: 168-177.

[5] 郭博,李守光,王昊,等. 电商评论综合分析系统的设计与实现:情感分析与观点挖掘的研究与应用[J]. 数据分析与知识发现,2017,1(12):1-9.

[6] SUN Yu, WANG Shuohuan, LI Yukun, et al. Ernie: Enhanced representation through knowledge integration[J]. arXiv preprint arXiv,1904.09223,2019.

[7] LAI Siwei, XU Liheng, LIU Kang, et al. Recurrent convolutional neural networks for text classification[C]//Proceedings of the AAAI Conference on Artificial Intelligence. New York: ACM, 2015: 2267-2273.

[8] 王乾,曾诚,何鹏,等. 基于 RoBERTa-RCNN 和注意力池化的新闻主题文本分类[J]. 郑州大学学报(理学版), 2024,56(2):43-50.

[9] PANG Bo, LEE L. Opinion mining and sentiment analysis[J]. Foundations and Trends® in Information Retrieval, 2008, 2(1-2): 1-135.

[10] 丁美荣,冯伟森,黄荣翔,等. 基于预训练模型和基础词典扩展的酒店评论情感分析[J]. 计算机系统应用,2022,31(11):296-308.

[11] 管雨翔,王娟,刘静,等. 突发事件网络舆情领域情感词典构建[J]. 情报探索,2023 (2):1-8.

[12] 李杨,徐泽水,王新鑫. 基于在线评论的情感分析方法及应用[J]. 控制与决策,2023,38(2):304-317.

[13] 黄文明,孙艳秋. 基于最大熵的中文短文本情感分析[J]. 计算机工程与设计,2017,38(1):138-143.

[14] CORTES C, VAPNIK V. Support-vector networks[J]. Machine Learning, 1995, 20: 273-297.

[15] 苏莹,张勇,胡珀,等. 基于朴素贝叶斯与潜在狄利克雷分布相结合的情感分析[J]. 计算机应用,2016,36(6):1613-1618.

[16] 郑志伟,邱佳玲,阳庆玲,等. 随机森林对文本情感分析的应用与 R 软件实现[J]. 现代预防医学,2018,45(8):1345-1348.

[17] PANG Bo, LEE L, VAITHYANATHAN S. Thumbs up: sentiment classification using machine learning techniques[C]// Proceedings of the ACL-02 Conference on Empirical methods in Natural Language Processing. ACL, 2002: 79-86.

[18] 李首政,王琪,王力. 基于支持向量机的微博情感分析方法研究[J]. 现代计算机,2022,28(19):63-66.

[19] YADAV A, VISHWAKARMA D K. Sentiment analysis using deep learning architectures: A review[J]. Artificial Intelligence Review, 2020, 53(6): 4335-4385.

[20] 杨秀璋,武帅,任天舒,等. 融合多头注意力机制和 BiLSTM 的电商评论情感分析研究[J]. 信息技术与信息化,2022 (10):5-9.

[21] 吴贵珍,王芳,黄树成. 基于词向量与 CNN-BIGRU 的情感分析研究[J]. 软件导刊,2022,21(8):27-32.

[22] DEVLIN J, CHAMG Mingwei, LEE K, et al. Bert: Pre-training of deep bidirectional transformers for language understanding[J]. arXiv preprint arXiv,1810.04805, 2018.

[23] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. Advances in Neural Information Processing Systems, 2017, 30: 5998-6008.