

陆雨嘉, 钱钢. 基于 ERNIE 和注意力机制的情感分析法[J]. 智能计算机与应用, 2025, 15(3): 181-185. DOI: 10.20169/j.issn.2095-2163.24042201

基于 ERNIE 和注意力机制的情感分析法

陆雨嘉, 钱 钢

(南京审计大学 计算机学院, 南京 210000)

摘要: 针对传统情感分析方法中, 词嵌入不准确和特征提取不充分的问题, 提出了一种基于 ERNIE 和注意力机制的情感分析方法。该方法首先利用预训练模型 ERNIE 获取文本的动态词嵌入表示; 其次, 分别使用注意力机制和长短期记忆网络对文本进行编码, 提取文本的全局特征和上下文特征, 然后将 2 种特征进行拼接融合, 输入到卷积神经网络中再提取文本的局部特征; 最后, 将 3 种特征进行拼接融合, 输入到全连接神经网络中输出分类结果。在公开的情感分析数据集上的实验结果表明, 该方法在准确率、召回率和 F1 值等评价指标上均优于其他对比方法, 证明了方法的有效性和优越性。

关键词: 情感分析; ERNIE; 注意力机制; 训练模型; 数据集

中图分类号: TP391

文献标志码: A

文章编号: 2095-2163(2025)03-0181-05

Emotional analysis method based on ERNIE and attention mechanism

LU Yujia, QIAN Gang

(School of Computing Science, Nanjing Audit University, Nanjing 210000, China)

Abstract: To address the issues of inaccurate word embeddings and insufficient feature extraction in traditional sentiment analysis methods, a sentiment analysis approach based on ERNIE and attention mechanism is proposed. This method firstly utilizes the pre-trained model ERNIE to obtain dynamic word embedding representations of the text; secondly, it employs the attention mechanism and Long Short-Term Memory networks (LSTM) to encode the text, extracting the global features and contextual features of the text; then, these two types of features are concatenated and fused, and input into a Convolutional Neural Network (CNN) to extract the local features of the text; finally, the three types of features are concatenated and fused, and input into a fully connected neural network to output the classification results. Experiments on public sentiment analysis datasets have been conducted, and the results show that this method outperforms other comparative methods in terms of accuracy, recall, and F1 score, proving its effectiveness and superiority.

Key words: sentiment analysis; ERNIE; attention mechanism; training model; data set

0 引言

情感分析是自然语言处理的一个重要分支, 旨在通过文本分析来检测和评估人们的心理状态和情感倾向^[1]。情感分析在各个领域都有广泛应用, 例如产品评论、社交媒体、舆情监测等^[2]。情感分析对于理解人们的需求、偏好、情绪和态度, 提供更好的服务、产品和体验, 具有重要的意义^[3]。

常用的情感分析方法可分为 3 类: 基于词典的方法、基于机器学习的方法和基于深度学习^[4]的方法。基于词典的方法是根据预先定义的情感词典, 来判断文本中情感词的极性和强度, 从而得到文本

的情感倾向。这种方法的优点是简单易实现, 不需要标注数据, 但是缺点是忽略了文本中的上下文关系和语义依赖, 无法处理情感词的多义性、否定词和程度副词的影响等, 容易出现误判和漏判。

基于机器学习的方法是利用标注好的文本数据, 来训练不同的分类器, 如朴素贝叶斯、支持向量机、神经网络等, 从而实现文本的情感分类或者情感得分^[5]。其优点是可以利用文本的特征和结构, 提高情感分析的准确性, 缺点是需要大量的标注数据, 而且对于不同的领域和语言, 可能需要不同的模型和特征, 缺乏通用性和可扩展性。

基于深度学习的方法是利用标注好的文本数据,

作者简介: 陆雨嘉(1998—), 男, 硕士研究生, 主要研究方向: 自然语言处理。

通信作者: 钱 钢(1965—), 男, 博士, 教授, 博士生导师, 主要研究方向: 大数据审计, 现代审计技术与方法。Email: lyj40acc@sina.com。

收稿日期: 2024-04-22

训练不同的神经网络模型,如循环神经网络、卷积神经网络、变换器等,从而实现文本的情感分类或者情感得分^[6]。这种方法的优点是可以利用神经网络的强大表达能力,提高情感分析的效果,但存在词嵌入模块无法准确表示文本和无法充分提取文本特征等问题,这可能影响模型的情感理解和判断能力^[7-8]。

本文提出了一种基于 ERNIE 和注意力机制 (ERNIE-ALC) 的情感分析方法,该方法主要包括以下几个步骤:利用 ERNIE 作为词嵌入,获取文本的动态特征表示;分别使用注意力机制和长短期记忆网络 (LSTM) 对文本和文本中包含的情感信息进行编码,提取文本的上下文关系特征和情感特征;将两种特征进行拼接融合,输入到卷积神经网络 (CNN) 中,输出预测结果。

1 相关工作

随着深度学习的发展,近年来已相继提出了一些基于神经网络的情感分析方法,如 CNN、循环神经网络 (RNN)、LSTM、注意力机制 (Attention) 等。这些方法可以有效地提取文本的特征和情感信息,提高情感分析的性能。例如,Moens 等学者^[9]提出了一种基于 CNN 的句子分类方法,可以用于情感分析任务。Hendri 等学者^[10]提出了一种基于递归神经网络的方法,可以对情感树进行语义组合和情感分类。Ren 等学者^[11]提出了一种基于注意力机制的神经机器翻译方法,可以根据输入的不同部分的重要性,来分配不同的权重,从而提取更有用的信息。

近年来,预训练模型在自然语言处理领域取得了可观研究成果,可以利用大规模的无标注文本来学习通用的语言表示,然后在下游任务中进行微调,以适应不同的场景和需求。其中,ERNIE^[12]是一种基于 BERT 的预训练模型,通过引入实体、短语、句子等多粒度的知识,来增强文本的语义理解能力。针对情感分析任务,也随即提出了一些基于 ERNIE 和注意力机制的方法。Huang 等学者提出了一种基于 ERNIE 和注意力机制的中文电商产品评论情感分析方法^[13],该方法有效地利用多维度的知识,增强文本的语义理解能力,提高情感分析的准确性。Hsieh 等学者^[14]提出了一种基于 ERNIE 和双向 LSTM 的弹幕评论情感分析方法,可以有效地捕捉文本中的上下文关系和情感倾向,提高情感分析的效率。Li 等学者^[15]提出了一种基于 ERNIE 和双重注意力机制的微博情感分析方法,该方法有效地提取文本的局部特

征和情感特征,提高情感分析的鲁棒性。Bashynska 学者^[16]提出了一种利用机器学习对文本信息进行情感分析的方法,训练了一个基于 BERT 编码器的分类器,该分类器识别以聊天方式书写的英文文本信息中的情感。Yang^[17]提出了一种基于深度学习的消费者评论文本情感分析方法,使用一个名为 ALBERT 的预训练语言模型获得语境化的词向量。

2 基于 ERNIE 和注意力机制的情感分析法

本文提出了一种基于 ERNIE 和注意力机制的情感分析方法 (ERNIE-ALC)。图 1 展示了 ERNIE-ALC 的结构,该模型由输入层、特征提取层和输出层组成。

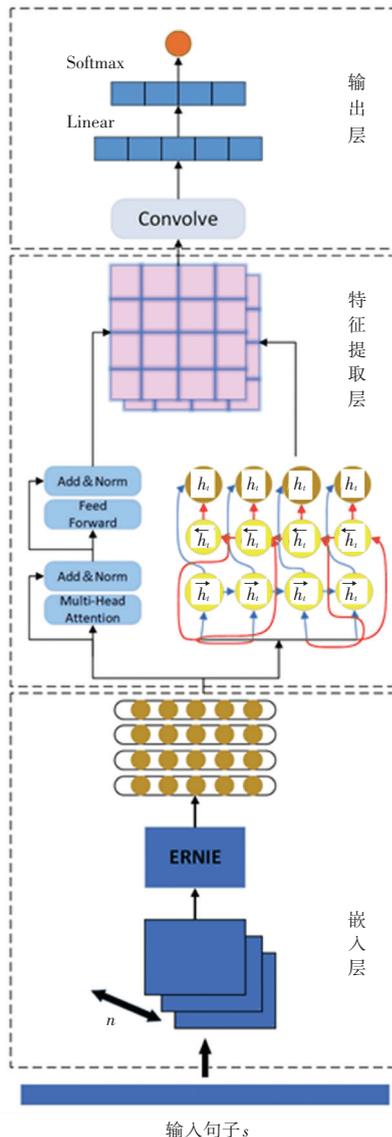


图 1 模型结构图

Fig. 1 Model structure diagram

2.1 输入层

对于一条文本 S , 将其划分为序列 $S_w = \{w_1, w_2, \dots, w_n\}$, 其中 n 为序列划分所得到的长度。微博数据大部分为中文数据, 因此本文采用 ERNIE 将文本序列转化为文本向量。ERNIE 是一个基于飞桨开源持续学习的语义理解框架, 利用不同的预训练任务来学习词法结构、语法结构和语义信息, 从而提高自然语言处理的效果。ERNIE 的结构主要由 Transformer Encoder 和 Task Embedding 两部分组成。其中, Transformer Encoder 是一个多层的自注意力机制, 用于编码输入文本的词法、语法和语义信息; Task Embedding 是一个额外的向量, 用于表示不同的预训练任务, 例如词法级别、语法级别和语义级别的任务。Task Embedding 可以让模型在不同的任务之间进行连续学习, 从而提高模型的泛化能力。将文本序列 S_w 输入到 ERNIE 中, 得到文本的向量化表示: $e_w = \{e_1, e_2, \dots, e_n\}$ 。

2.2 特征提取层

特征提取层的基本思想是依次提取文本的局部特征和全局特征, 从而捕捉文本的语义和形式信息。主要由 LSTM 层、注意力层和 CNN 层构成。

(1) LSTM 层。由于 RNN 在现有模型中被认为是解决序列问题的最佳模型, 因此在特征层选择 RNN 来获得更深层的语义特征。为了解决梯度消失或爆炸的问题, 并捕获过去和未来的上下文信息, 本文选择了 BiLSTM, 通过引入第二个隐藏层来扩展单向 LSTM 网络, 其中隐藏到隐藏之间的连接以相反的时间顺序流动。结合前向 LSTM 和后向 LSTM 的输出, 计算步长为 t 的 BLSTM 预测。在此, 分别用 \vec{h}_t 和 \overleftarrow{h}_t 来表示, 计算方法公式如下:

$$h_t = [\vec{h}_t \oplus \overleftarrow{h}_t] \quad (1)$$

其中, t 为序列位置, 而“ \oplus ”是串联操作。

在该模型中, 本文将嵌入向量馈送到隐藏层, 该隐藏层由 2 个独立的 LSTM 组成, 以获得 2 个特征级表示。BLSTM 的输出称为 $H \in R^{n \times d}$, 其中 d 为隐藏层单元数。

(2) 注意力层。本文采用多头注意力机制来提高模型对序列中远距离依赖关系的捕捉能力, 可以根据当前的上下文, 自适应地给不同的输入分配不同的权重, 从而突出重要的信息, 忽略无关的信息。其计算公式如下:

$$MultiHead(Q, K, V) = \text{concat}(head_1, head_2, \dots, head_h)W^O \quad (2)$$

其中, $head_i$ 表示第 i 个注意力头, 是对输入的 Q, K, V 进行线性变换后, 再应用缩放点积注意力的结果。由此推得的公式为:

$$head_i = Attention(QW_i^Q, KW_i^K, VW_i^V) \quad (3)$$

其中, W_i^Q, W_i^K, W_i^V 是可学习的权重矩阵, 用于将 Q, K, V 投影到不同的子空间。Attention 表示缩放点积注意力, 其计算公式为:

$$Attention(Q, K, V) = Softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (4)$$

其中, d_k 表示 k 的维度; $\sqrt{d_k}$ 是一个缩放因子, 用于防止点积的值过大导致梯度消失; Softmax 函数表示对每一行进行归一化, 得到一个概率分布。

(3) CNN 层。本文使用不同尺寸的卷积核对短文本进行局部特征提取, 卷积层的输出由下式计算:

$$V_{ci} = f(w \times c_{i:i+h-1} + b) \quad (5)$$

其中, V_{ci} 表示第 i 个特征向量; c_i 表示第 i 个输入数据; f 表示激活函数; w 表示卷积核权重; b 表示偏置参数。

将文本向量表示输入到特征层, 经过 LSTM 层和 CNN 层提取后, 得到文本的特征向量 V 。

2.3 输出层

本文使用 Softmax 层得到文本的预测概率 P , 最高概率对应的类别为最终的预测类别, P 的计算公式具体如下:

$$P = Softmax[W_{fc} \times V + b_{fc}] \quad (6)$$

其中, W_{fc} 和 b_{fc} 分别表示全连接层的参数矩阵和偏置量, “ \oplus ”表示拼接操作。

3 实验

3.1 实验环境与参数配置

本文采用实验方式, 检验了算法的可行性和有效性, 实验环境的配置信息见表 1。

表 1 实验环境的配置

Table 1 Configuration of experimental environment

实验环境	具体信息
Operating System	Windows 11
CPU	酷睿 i5-12500H
GPU	NVIDIA 3050ti
Development Language	Python 3.7
Development Platform	Pytorch 2.7

本实验的主要参数设置见表 2, 在 微博情感分析数据集上, pad_size 值为 32; 为了降低模型过拟合的风险, 当模型经历 1 000 个 batch 后, 模型的训练效

果没有提升时,结束训练。

表2 主要参数

Table 2 Main parameters

参数	值
batch_size	64
learning_rate	5×10^{-5}
filter_num	256
hidden_size	756
epochs	10
CNN_filter_sizes	2,3,4
Attention_heads	6

3.2 数据集

为了验证本文算法的性能,采用一个微博情感分类数据集与 ChnSentiCorp 中文情感分析数据集作为实验数据。其中,微博情感分类数据集由新微博言论和标签构成,包含了积极和消极两个类别。数据集共有 10 000 条数据,选取 8 000 条用作训练集,1 000 条用作验证集,1 000 条用作测试集。ChnSentiCorp 是一个中文情感分析数据集,包含酒店、笔记本电脑和书籍的网购评论。测试数据共 4 000 条,包含正、负类各 2 000 条。每条数据中包括一句消费评价,以及一个标识,表明这条评价是一条好评、还是差评。

3.3 基线方法

为了验证所提算法与传统分类方法的性能优劣,进行了对照实验,选用的对比模型简介如下。

(1)TextCNN^[18]。预训练词向量,然后将词向量作为 LSTM 的输入,通过 LSTM 的隐藏状态获取文本的深度表示,最后用一个全连接层或者其他分类器对文本进行分类。

(2)BiLSTM^[19]。首先用 Word2Vec 模型或其他方法得到词向量,然后将词向量作为双向 LSTM 的输入,通过双向 LSTM 的前向和后向隐藏状态获取文本的深度表示,最后用一个全连接层或者其他分类器对文本进行分类。

(3)TextRCNN^[20]。首先用 Word2Vec 模型或其他方法得到词向量,然后将词向量拼接成文本矩阵,通过不同大小的卷积核对文本矩阵进行卷积操作,提取文本的局部特征,再通过最大池化层得到全局特征,最后用一个全连接层或者其他分类器对文本进行分类。

(4)ERNIE^[21]。是一种基于预训练语言模型的文本分类模型,可以利用大规模的知识图谱和实体链接等先验知识,提高文本的表示能力。

3.4 评价指标

实验采用精确率 (Precision, P)、召回率

(Recall, R) 和 $F1$ 值来衡量分类模型的性能,并给出了相应计算方式。其中,精确率是指预测为正的样本中实际为正的样本比例,召回率是指实际为正的样本中预测为正的样本的比例, $F1$ 值是精确率和召回率的调和平均数,综合反映了模型对正样本的识别能力。各指标计算公式如下:

$$\begin{cases} P = \frac{TP}{TP + FP} \cdot 100\% \\ R = \frac{TP}{TP + FN} \cdot 100\% \\ F1 = \frac{2 \cdot P \cdot R}{P + R} \cdot 100\% \end{cases} \quad (7)$$

其中, TP 表示真正例,即实际为正且预测为正的样本数; FP 表示假正例,即实际为负且预测为正的样本数; FN 表示假反例,即实际为正且预测为负的样本数。通过这些指标,可以评价分类模型在不同类别上的表现,以及模型在样本不平衡情况下的鲁棒性。

3.5 实验结果分析

为了综合评估本文算法的性能和有效性,与常用算法在微博情感分类数据集及 ChnSentiCorp 中文情感分析数据集上进行了实验,同时选用精确率、召回率和 $F1$ 值作为评价指标。

表 3 显示了各个模型在微博情感分类数据集上的精确率、召回率和 $F1$ 值。

表3 在微博情感分类数据集上的实验结果

Table 3 Experimental results on Weibo sentiment classification dataset

Model	P	R	$F1$
TextCNN	92.88	92.80	92.82
LSTM	92.49	92.41	92.45
RCNN	93.24	93.15	93.21
ERNIE	96.78	96.45	96.57
OURS	98.46	98.35	98.41

表 4 显示了各个模型在 ChnSentiCorp 中文情感分析数据集上的精确率、召回率和 $F1$ 值。

表4 在 ChnSentiCorp 中文情感分析数据集上的实验结果

Table 4 Experimental results on the ChnSentiCorp Chinese sentiment analysis dataset

Model	P	R	$F1$
TextCNN	90.48	89.80	90.13
LSTM	91.27	91.16	91.21
RCNN	92.65	92.61	92.63
ERNIE	92.07	91.98	92.02
OURS	94.58	94.43	94.50

从实验结果中可以看出,本文算法在 3 个评价指标上都优于对比模型,尤其是在综合性评价指标

$F1$ 值上,本文模型相比 TextCNN、LSTM、RCNN 和 ERNIE 模型都要高出一定的百分比。这说明本文提出的算法 ERNIE-ALC 能够更好地识别数据集文本中的情感倾向。

ERNIE-ALC 的优势主要来源于 2 方面。一是使用预训练模型 ERNIE 作为输入模型,二是结合 CNN 和注意力机制的网络结构。预训练模型 ERNIE 是基于大规模语料库进行预训练的模型,能够捕捉文本中的语义信息和语境信息,从而提高文本表示的能力。相比之下,传统的词嵌入模型 Word2Vec 只能学习词语的静态表示,忽略了词语在不同语境中的多义性和关联性。因此,预训练模型 ERNIE 的文本表示能力优于传统的词嵌入模型 Word2Vec。CNN 和注意力机制是 2 种常用的神经网络结构,分别具有提取局部特征和捕捉长期依赖的能力。本文算法将两者结合起来,形成一个双层网络结构,能够充分利用各自的优点,提升了文本特征提取的能力。

4 结束语

本文针对传统词向量无法区分多义词、基础深度学习模型特征提取能力不足的问题,提出一种基于 ERNIE 和注意力机制的情感分析方法。实验结果表明,该模型在公开数据集上优于其他模型,具有较高的分类准确率和稳定性。

但是,该模型也存在一些不足,需做进一步改进。一方面,该模型的 CNN 网络结构过于简单,没有充分利用文本的语义和结构信息,下一步将探索更深、更复杂的 CNN 网络结构,以提取文本的更高层次的特征;另一方面,该模型的泛化能力还需要在更多的数据集上进行验证,以评估模型的有效性和适应性。

参考文献

- [1] 郭续,买日旦·吾守尔,古兰拜尔·吐尔洪. 基于多模态融合的情感分析算法研究综述[J]. 计算机工程与应用,2024,60(2):1-18.
- [2] 涂亚婷,安建业,徐雪. 基于深度学习的短文本分类方法研究综述[J]. 计算机工程与应用,2023,59(4):43-53.
- [3] BU Kun, LIU Yuanhao, JU Xiaolong. Efficient utilization of pre-trained models: A review of sentiment analysis via prompt learning [J]. Knowledge-Based Systems, 2024,283: 111148.
- [4] LI Songbin, WANG Jingang, LIU Peng. Detection of generative linguistic steganography based on explicit and latent text word relation mining using deep learning [J]. IEEE Transactions on Dependable and Secure Computing, 2023,20(2):1476-1487.
- [5] HSIEH Y H, ZENG X P. Sentiment analysis: An ERNIE-BiLSTM approach to bullet screen comments[J]. Sensors, 2022, 22(14): 5223.
- [6] LIU Jingyi, LI Sheng. A dependency-based hybrid deep learning framework for target-dependent sentiment classification [J]. Pattern Recognition Letters, 2023,176: 160-166.
- [7] ZHU Z, MAO K. Knowledge-based BERT word embedding fine-tuning for emotion recognition [J]. Neurocomputing, 2023, 552: 126488.
- [8] WANG J, MAEDA A, KAWAGOE K. MultArtRec: A multimodal neural topic modeling for integrating image and text features in artwork recommendation[J]. Electronics, 2024, 13(2): 302.
- [9] MOEN H, HAKALA K, PELTONEN L, et al. Assisting nurses in care documentation: from automated sentence classification to coherent document structures with subject headings[J]. Journal of Biomedical Semantics, 2020, 11(1): 10.
- [10] HENDRI M, GOWANDI T, ARDANESWARI G, et al. BERT-based combination of convolutional and recurrent neural network for Indonesian sentiment analysis [J]. Applied Soft Computing, 2024,151: 111112.
- [11] REN Q D E J, PANG Ziyu, LANG Jiajun. A Mongolian-Chinese neural machine translation model based on soft target templates and contextual knowledge[J]. Applied Sciences, 2023, 13(21): 11845.
- [12] WEN Yu, LIANG Yezhang, ZHU Xinhua. Sentiment analysis of hotel online reviews using the BERT model and ERNIE model: Data from China[J]. Plos One, 2023, 18(3): e0275382.
- [13] XIAO Dongling, ZHANG Han, LI Yukun, et al. Ernie-gen: An enhanced multi-flow pre-training and fine-tuning framework for natural language generation [J]. arXiv preprint arXiv, 2001. 11314, 2020.
- [14] HSIEH Y H, ZENG X P. Sentiment analysis: An ERNIE-BiLSTM approach to bullet screen comments[J]. Sensors, 2022, 22(14): 5223.
- [15] LI Aichuan, LI Tian. Fusion of XLNet and BiLSTM-TextCNN for Weibo sentiment analysis in Spark big data environment[J]. International Journal of Ambient Computing and Intelligence (IJACI), 2023, 14(1): 1-18.
- [16] BASHYNSKA I, SARAFANOV M, MANIKAEVA O. Research and development of a modern deep learning model for emotional analysis management of text data[J]. Applied Sciences, 2024, 14(5): 1952.
- [17] YANG Mei. An Effective emotional analysis method of consumer comment text based on ALBERT-ATBiFRU-CNN [J]. International Journal of Information Technologies and Systems Approach (IJITSA), 2023,16(2):1-12.
- [18] ZHANG Tianyu, YOU Fucheng. Research on short text classification based on TextCNN [J]. Journal of Physics: Conference Series, 2021, 1757(1): 012092.
- [19] QIN H. BiLSTM text classification incorporating attentional mechanisms[J]. Academic Journal of Computing & Information Science, 2023, 6(13): 92-98.
- [20] ZHOU Chuanhua, ZHOU Jiayi, YU Cai, et al. Multi-channel sliced deep RCNN with residual network for text classification[J]. Chinese Journal of Electronics, 2020,29(5):880-886.
- [21] WANG Yu, WANG Yuan, PENG Zhenwan, et al. A concise relation extraction method based on the fusion of sequential and structural features using ERNIE[J]. Mathematics, 2023, 11(6): 1439.