

张典秋, 夏莉. 结合双向循环神经网络和注意力机制的微博文本情感分析[J]. 智能计算机与应用, 2024, 14(7): 236-240.
DOI: 10.20169/j.issn.2095-2163.240738

结合双向循环神经网络和注意力机制的微博文本情感分析

张典秋, 夏莉

(广东财经大学 统计与数学学院, 广州 510320)

摘要: 情感分析作为自然语言处理的一个重要分支, 广泛应用于各个领域。针对 CNN 不能联系全文信息, RNN 模型存在时序依赖问题, 对特征信息提取不充分, 本文构建一种结合双向循环神经网络和注意力机制的情感分析模型。首先, 在文本表示部分使用 Word2Vec 模型获得词向量; 其次, 在训练模型部分构建双向循环神经网络连接注意力机制的组合模型, 把双向循环神经网络的输出做 3 种线性变化后输入 Attention 机制, 以此给隐层特征分配权重来整合文本信息; 最后, 在 simplifyweibo_2_polarities 数据集上验证模型的有效性。

关键词: 自然语言处理; 情感分析; 双向循环神经网络; 注意力机制

中图分类号: TP391

文献标志码: A

文章编号: 2095-2163(2024)07-0236-05

Sentiment analysis of weibo text by combining bidirectional recurrent neural network and attention mechanism

ZHANG Dianqiu, XIA Li

(School of Mathematics and Statistics, Guangdong University of Finance and Economics, Guangzhou 510320, China)

Abstract: As an important branch of natural language processing, sentiment analysis is widely used in various fields of society. In response to the shortcomings of CNN being unable to contact full-text information, RNN models having temporal dependencies, and insufficient feature information extraction, this paper constructs an sentiment analysis model based on combined NLP. First, we use Word2Vec model to obtain word vector in text representation. Then in the training model part, we build a combined model of bidirectional recurrent neural network connecting attention mechanism, input the output of bidirectional recurrent neural network into Attention mechanism after three linear changes, to assign weight to hidden layer features to integrate text information. Finally, validate the effectiveness of the model on the simplifyweibo_2_polarities dataset.

Key words: NLP; sentiment analysis; bidirectional recurrent neural network; attention mechanism

0 引言

自然语言处理 (Natural Language Processing, NLP) 是机器学习重要的研究方向之一, 情感分析成为自然语言处理领域的重要分支^[1-2]。自然语言处理是利用计算机技术研究和处理语言的一门学科, 随着处理数据的规模越来越大, 大部分的自然语言处理任务, 如文本分类、情感分析、中文分词、机器翻译都很难通过经典机器学习算法完成。针对现有模型的缺点本文提出一种结合双向循环神经网络 (Bi-directional Recurrent Neural Network, BiRNN) 和注意力机制 (Attention Mechanism) 组合的 NLP 模型, 与

现有模型相比, 该模型能更好地完成文本情感分析任务。

1 相关工作

情感分析可以按照实现方法分为基于规则法、基于机器学习和基于深度学习的情感分析。

基于规则法的情感分析是通过构建情感词典和匹配规则实现的, 不需要训练前标记数据^[3]。Taboada 等^[4]提出了一种利用词典实现的语义倾向计算模型, 通过增强的情感词典配合强化词规则与改进的否定词规则, 综合判定文本的情感极性; 王志涛等^[5]使用统计信息进行新词挖掘, 生成了新的情

基金项目: 国家自然科学基金资助项目 (11971200); 广东省教育厅委托项目 (0835-210Z33606691)。

作者简介: 张典秋 (1999-), 男, 硕士研究生, 主要研究方向: 机器学习。

通讯作者: 夏莉 (1980-), 女, 博士, 教授, 主要研究方向: 偏微分方程理论及其应用, 自然与语言处理。Email: xaleyserry@163.com

收稿日期: 2023-05-12

感词典;聂卉等^[6]改进了情感词典匹配算法和经典的互信息情感识别算法。规则词典法的主要缺点是对情感词典的质量过于依赖,且情感词典的构建费时费力,对语言特征的提取不充分。

基于机器学习的情感分析是通过特征工程对文本进行特征提取,再用机器学习模型作为分类器,完成文本情感分析任务。Pang等^[7]最先在情感分析任务中应用机器学习算法;谢丽星等^[8]提出基于支持线向量机(Support Vector Machine, SVM)的层次结构多策略方法;李婷婷等^[9]通过结合SVM和条件随机场来进行情感分析任务,获得更好的结果;王伟等^[10]基于潜在狄利克雷分布主题模型,结合情感词典获得了更高的分类准确率。基于机器学习的情感分析存在着特征提取不充分、维度灾难和泛化能力不足的问题。

基于深度学习的情感分析通过设计不同的网络结构从文本中提取高层语义特征,不需要大量的人工操作。Hinton等^[11]提出神经网络,成为主流的情感分析方法;Mikolov等^[12]提出Word2Vec工具中的CBOW(Continuous Bag-of-Words)与Skip-Gram模型,可以快速地单词映射到实数向量空间,为引入各种神经网络提供基础;Vaswani等^[13]提出Transformer模型,该模型完全基于注意力机制;刘龙飞等^[14]提出通过将字级别特征向量与词级别特征向量分别作为句子的原始特征,再利用卷积神经网络提取隐含的文本特征,从而实现情感分析任务;Sharaf等^[15]提出一种将深度神经网络与多头注意力机制相结合的混合模型,提取位置不变的局部特征;Li等^[16]提出一种双重图卷积网络模型,同时考虑句法结构的互补性和语义相关性;梁燕等^[17]将GRU(Gated Recurrent Unit)与3种注意力机制融合,提出了一种针对文本中不同目标的情感分析方法;刘思琴等^[18]提出了一种结合BERT(Bidirectional Encoder Representations from Transformers)模型、双向长短时记忆神经网络与注意力机制的情感分析模型;房京珂^[19]用两种递归神经网络结构与ALBERT(A Lite BERT)模型结合,在微博文本数据上的情感分析取得更好的效果;李亦然^[20]利用情感分析技术对三孩生育意愿进行研究,通过对比发现,ALBERT-BiLSTM模型表现最佳。

本文针对现有模型对文本高层特征提取不足的问题,提出了结合双向递归神经网络和注意力机制的情感分析模型(BRNN_Att),并在simplifyweibo_2_polarities数据集上验证了模型的有效性。

2 本文模型

本文提出的BRNN_Att模型结构如图1所示。BRNN_Att模型由预输入层、编码层、BiRNN层、Attention层和输出层组成。

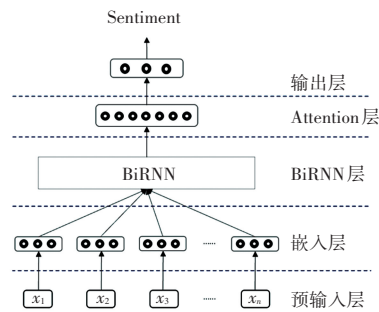


图1 BRNN_Att模型结构

Fig. 1 BRNN_Att model network structure

首先,在预输入层对得到的文本数据进行清洗,包括停用词去除、特殊字符去除和文本分词;其次,把数据输入到嵌入层,通过使用Word2Vec模型把所得数据转化为词向量;经过BiRNN层的训练,通过BiRNN层提取文字信息的深层特征;在得到BiRNN层的隐层输出,把该结果作为Attention层的输入;最后,在输出层归一化,使用softmax函数实现文本情感二分类任务。

2.1 预输入层

在预输入层对文本数据进行预清洗,处理步骤为:去除重复文本、去除特殊字符、去除停用词、文本分词。

停用词是指在文本中出现频率过高且信息密度低的词,如“着”、“向”等,停用词的存在会增加数据处理的复杂度,降低模型的效率,本文使用公开词表来去除停用词;在中文文本的自然语言处理中,文本分词是一个非常重要的步骤,文本分词的好坏直接影响后续文本表示和建模的效果。现阶段主要的分词技术有4种:基于字典匹配的分词、基于统计信息的分词、基于知识理解的分词和基于深度学习的分词,考虑到现阶段基于字典匹配的分词方法十分成熟,且实现简单高效,本文采用基于字典的分词。经过预输入层处理后得到文本数据表示为 $S = \{\omega_1, \omega_2, \dots, \omega_n\}$ 。

2.2 嵌入层

模型的嵌入层使用Word2Vec模型,该模型是目前被广泛使用的一款词向量训练工具包,其本质上是一种无监督学习,通过CBOW模型或Skip-Gram模型快速地将词映射到实数向量空间。基本

原理是构建一个神经网络模型,根据单词的所处语境,将每个单词的独热编码向量压缩成具有相同维度的低维实数向量,向量中的数值可以是任何数字,向量的维度在训练前人为指定。CBOW 模型利用语境上下文词来预测中心词,其目标函数如式(1)所示:

$$L = \prod_{t=1}^T P(\omega_t | w_{t-m}, \dots, w_{t-1}, w_{t+1}, \dots, w_{t+m}) \quad (1)$$

其中, T 为上下文窗口长度, ω_t 表示中心词向量。

CBOW 模型结构如图 2 所示。




图 2 CBOW 模型结构

Fig. 2 CBOW model structure

Skip-Gram 模型的基本思想是使用中心词分别预测其语境上下文出现的单词,通过训练得到输入层与隐藏层之间的权值矩阵 \mathbf{W} 作为词向量矩阵,其目标函数如式(2)所示:

$$L = \prod_{t=1}^T \prod_{-m \leq j \leq m, j \neq 0} P(w_{t+j} | w_t) \quad (2)$$

Skip-Gram 模型结构图如图 3 所示。




图 3 Skip-Gram 模型结构图

Fig. 3 Skip-Gram model structure diagram

使用 Word2Vec 模型将每个单词映射到一个高维的向量空间,设嵌入查找矩阵为 $\mathbf{E} \in \mathbb{R}^{D \times |V|}$,其中 D 是词向量维数, $|V|$ 是词汇表长度,经过编码层处理后得到的词向量为 $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$ 。

2.3 BiRNN 层

双向循环神经网络的结构如图 4 所示。

给定时间步长 t 、输入数据 $X_t \in \mathbb{R}^{n \times d}$,并令隐藏层的激活函数为 ϕ ,在双向架构中,前向和反向隐状态的更新如式(3)和式(4)所示:

$$\vec{H}_t = \phi(X_t W_{sh}^{(\vec{f})} + \vec{H}_{t-1} W_{hh}^{(\vec{f})} + b_h^{(\vec{f})}) \quad (3)$$

$$\overleftarrow{H}_t = \phi(X_t W_{sh}^{(\overleftarrow{f})} + \overleftarrow{H}_{t-1} W_{hh}^{(\overleftarrow{f})} + b_h^{(\overleftarrow{f})}) \quad (4)$$

其中, $W_{sh}^{(\vec{f})}$ 、 $W_{hh}^{(\vec{f})}$ 都是模型隐层状态量, $b_h^{(\vec{f})}$ 表示偏置项。




图 4 BiRNN 网络结构图

Fig. 4 BiRNN network structure diagram

将前向隐状态和反向隐状态连接起来获得送入输出层的隐状态 $H_t \in \mathbb{R}^{n \times 2h}$,最后输出层得到输出,如式(5)所示:

$$O_t = H_t W_{hq} + b_q \quad (5)$$

经过 BiRNN 层的处理后,得到词的特征表示为

$$O = \{o_1, o_2, \dots, o_n\}。$$

2.4 Attention 层

为了使模型在训练时更加关注中心词相关的情感信息,用注意力机制来捕捉中心词和上下文词之间的相互作用。在序列到序列模型中文本的所有信息被强制集中于一个语境向量中,而且循环神经网络存在梯度消失问题,导致语境向量难以保留所有的有效信息,编码器相当于对输入仅获取了大概信息。本文引入了 Attention 机制,使编码器的输入根据单词的不同赋予不同的权重,使目标词和上下文词充分学习对方信息来提高情感分析建模的准确率。注意力机制的计算过程:根据式(6)、式(7)计算注意力得分:

$$e_{ii} = f(s_{t-1} o_i) \quad (6)$$

$$a_{ii} = \frac{\exp(e_{ii})}{\sum_{k=1}^n \exp(e_{ik})} \quad (7)$$

其中, s_t 为解码器中第 t 步的隐藏单元状态, f 为校验模型,本文采用的校验模型如式(8)所示:

$$e_{ij} = \tanh(W_a \cdot o_i + U_a \cdot S_{t-1} + b_a) \quad (8)$$

其中, W_a 和 U_a 为权重矩阵, b_a 为偏置项。

综上可以计算出归一化的中心词注意力得分,如式(9)所示:

$$a_{ii} = \frac{\exp(\tanh(W_a \cdot o_i + U_a \cdot S_{t-1} + b_a))}{\sum_{k=1}^n \exp(\tanh(W_a \cdot o_i + U_a \cdot S_{t-1} + b_a))} \quad (9)$$

然后加权求和得到注意力层的输出,公式

(10):

$$h_i = \sum_{i=1}^T a_{ii} o_i \quad (10)$$

其中, $h_i = [\vec{h}_i, \overleftarrow{h}_i]$ 。

Attention 机制的本质思想如图 5 所示。




图 5 注意力机制

Fig. 5 Attention mechanism

Query 为查询向量, 将 *Source* 中的构成元素抽象为一系列键值对 <Key, Value>。首先选定查询向量, 使用相似度函数计算其与各个键之间的相似度, 从而可以得到每个值的对应权值, 最后进行加权求和, 得到注意力计算结果, 如式(11)所示:

$$\text{Attention}(\text{Query}, \text{Source}) = \sum_{j=1}^L \text{Similarity}(\text{Query}, \text{Key}_j) \times \text{Value}_j \quad (11)$$

其中, L 为 *Source* 的元素数。

键与值相同, 为输入句子中每个单词对应的特征编码, 查询向量为解码器中每一步的隐藏单元状态。经过 Attention 层处理后得到词汇的特征表示为 $H = \{h_1, h_2, \dots, h_n\}$ 。

2.5 输出层

在最后的输出层把经过 BiRNN 层和 Attention 层处理后的词向量作为最终的向量表示, 将其归一化, 用 softmax 函数得到每个情感类别的概率。取概率最高的情感类别作为本文预测的情感类别, softmax 函数的计算如公式(12)所示:

$$y = \text{softmax}(W_s h + b_s) \quad (12)$$

其中, W_s 和 $b_s \in \mathbb{R}^l$ 为权重参数和偏置项, l 为情感类别, 本文设置为 2。

3 实验与分析

3.1 数据集

本文所使用的数据集为 simplifyweibo_2_polarities 数据集, 该数据集含有从网络收集的 36 万多条已经进行情感标注的新浪微博文本数据, 初始数据集中包含喜悦、愤怒、厌恶和低落 4 种情感类别, 分别用标签 1、2、3、4 表示。首先对该数据集进行清洗, 用 Pkuseg 分词工具对文本进行分词, 最后把情感标签合并分为积极和消极两类, 分别用标签

1、2 表示。划分的训练集、验证集和测试集数据量见表 1。

表 1 数据集规模

Table 1 Dataset size

数据集	数据条数
训练集	244 684
验证集	30 481
测试集	30 481

3.2 数据集的文本表示

在文本表示阶段, 本文使用 Python 中的 Densim 包来实现预训练的 Word2Vec 模型。具体参数设置: 上下文窗口设置为 5, 词向量维度设置为 150, 最低词频数参数设置为 8, 负采样个数设置为 5, 学习率初始化为 0.02。通过该设置完成 Word2Vec 模型的训练, 即可获得每个单词的词向量。

3.3 评价指标

本文使用准确率 (Accuracy)、F1 值 (F1 - score) 作为模型的评价指标。准确率是指模型正确预测的样本数占总样本数的比例, 可以有效评估模型对分类任务的有效性, 公式(13):

$$\text{Accuracy} = \frac{T}{N} \quad (13)$$

其中, T 表示预测正确的样本数, N 为样本总数。

F1 值是精度 (Precision) 和召回率 (Recall) 的调和平均, 综合考虑了模型的准确率和召回率, 适用于评价模型在不同类别上的平衡性, 计算如公式(14) ~ 公式(16):

$$\text{Precision} = \frac{TP}{TP + FP} \quad (14)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (15)$$

$$F1 = \frac{2 \times \text{precision} \times \text{recall}}{\text{Precision} + \text{Recall}} \quad (16)$$

其中, TP 、 FN 、 FP 、 TN 见表 2。

表 2 混淆矩阵

Table 2 Confusion matrix

		真实值	
		正例	负例
预测	正例	TP	FP
	负例	FN	TN

3.4 实验结果

保持文本预处理、文本表示技术和模型参数一致, 以 Word2Vec + CNN、Word2Vec + RNN 和

Word2Vec+LSTM 为基线模型,与 BRNN_Att 模型在 simplifyweibo_2_polarities 数据集上做实验对比,其实验结果见表 3。

表 3 模型结果对比

Table 3 Comparison of model results

模型	准确率	F1 值
Word2Vec+CNN	0.713 8	0.804 9
Word2Vec+RNN	0.730 5	0.805 1
Word2Vec+LSTM	0.723 4	0.804 2
BRNN_Att	0.754 3	0.832 4

由表 3 可知,本文提出的 BRNN_Att 模型在处理情感分析任务上存在一定的优势,对比 Word2Vec+CNN、Word2Vec+RNN 和 Word2Vec+LSTM 在准确率上的提升分别是 0.040 5、0.023 8 和 0.030 9,在 F1 上的提升分别是 0.027 5、0.027 3 和 0.028 2,验证了模型的有效性。

4 结束语

本文针对 CNN 不能联系全文信息、RNN 模型存在时序依赖问题以及对特征信息提取不充分的缺点,构建一种结合双向循环神经网络和注意力机制的情感分析模型,并在 simplifyweibo_2_polarities 数据集上与 3 个基线模型进行对比实验,验证了本文模型的有效性。

由于计算设备、实验时间和自身水平的限制,本文的研究工作还存在着一些不足,未来可以从两点进一步优化:

(1) simplifyweibo_2_polarities 数据集可以进行细粒度分析,本文所用的数据集虽然经过清洗,但是在时效性、规模和分类准确度上还存在着提升空间;

(2) 本文构建的情感分析模型效果还不是很理想,未来可以尝试多种注意力机制组合设计模型,以提升模型精度。

参考文献

[1] 余凯,贾磊,陈雨强,等. 深度学习的昨天、今天和明天[J]. 计算机研究与发展, 2013, 50(9):1799-1804.
 [2] ZHANG W, LI X, DENG Y, et al. A survey on aspect-based sentiment analysis: tasks, methods, and challenges[J]. IEEE

Transactions on Knowledge and Data Engineering, 2023(11):35.
 [3] ROUHANI S, ABEDIN E. Crypto-currencies narrated on tweets: a sentiment analysis approach[J]. International Journal of Ethics and Systems, 2019, 36.
 [4] TABOADA M, BROOKE J, TOFILOSKI M, et al. Lexicon-based methods for sentiment analysis[J]. Computational linguistics, 2011, 37(2): 267-307.
 [5] 王志涛,於志文,郭斌,等. 基于词典和规则集的中文微博情感分析[J]. 计算机工程与应用,2015,51(8):218-225.
 [6] 聂卉,首欢容. 基于修正点互信息的特征级情感词极性自动研判[J]. 图书情报工作,2020,64(5):114-123.
 [7] PANG B, LEE L, VAITHYANATHAN S. Thumbs up? Sentiment classification using machine learning techniques[J]. arXiv preprint cs/0205070, 2002.
 [8] 谢丽星,周明,孙茂松. 基于层次结构的多策略中文微博情感分析和特征抽取[J]. 中文信息学报,2012,26(1):73-83.
 [9] 李婷婷,姬东鸿. 基于 SVM 和 CRF 多特征组合的微博情感分析[J]. 计算机应用研究,2015,32(4):978-981.
 [10] 王伟,周咏梅,阳爱民,等. 一种基于 LDA 主题模型的评论文本情感分类方法[J]. 数据采集与处理,2017,32(3):629-635.
 [11] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. science, 2006, 313(5786): 504-507.
 [12] MIKOLOV T, CHEN K, CORRADO G, et al. Efficient estimation of word representations in vector space[J]. arXiv preprint arXiv:1301.3781, 2013.
 [13] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. Advances in Neural Information Processing Systems, 2017, 30.
 [14] 刘龙飞,杨亮,张绍武,等. 基于卷积神经网络的微博情感倾向性分析[J]. 中文信息学报,2015,29(6):159-165.
 [15] SHARAF A L DEEN H S, ZENG Z, AL-SABRI R, et al. An improved model for analyzing textual sentiment based on a deep neural network using multi-head attention mechanism[J]. Applied System Innovation, 2021, 4(4): 85.
 [16] LI R, CHEN H, FENG F, et al. Dual graph convolutional networks for aspect-based sentiment analysis[C]//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing (Volume 1: Long Papers). 2021: 6319-6329.
 [17] 梁燕,刘超,梁仲雄,等. 融合多注意力神经网络的方面级情感分析[J]. 计算机工程与设计,2023,44(3):894-900.
 [18] 刘思琴,冯霄睿. 基于 BERT 的文本情感分析[J]. 信息安全研究,2020,6(3):220-227.
 [19] 房京珂. 基于 NLP 的微博情感分析研究[D]. 北京:中央民族大学,2021.
 [20] 李亦然. 基于深度学习的微博三孩生育意愿的文本情感分析[D]. 济南:山东大学,2023.