

# 一种基于情感计算与层次化多头注意力机制的负面新闻识别方法

张仰森<sup>1,3</sup>, 周炜翔<sup>1</sup>, 张禹尧<sup>1</sup>, 吴云芳<sup>2</sup>

(1. 北京信息科技大学智能信息处理研究所, 北京 100101; 2. 北京大学计算语言学研究所, 北京 100871;  
3. 国家经济安全预警工程北京实验室, 北京 100044)

**摘要:** 网络负面新闻识别在网络舆情监测中具有重要的研究意义. 针对当前海量数据下负面新闻难以检测的问题, 提出了一种基于情感计算与层次化多头注意力机制相结合的负面新闻识别方法. 首先, 从新闻文本中采用 TF-IDF (Term Frequency-Inverse Document Frequency) 和语义相似度算法构建负面新闻情感词库; 其次, 采用情感倾向计算方法计算负面新闻情感词的情感倾向度; 最后, 将词语和词语的情感倾向度进行向量化表示, 并采用层次化多头注意力机制进行正负面新闻的判定. 情感计算和多头注意力机制的引入, 对于捕获文本中的情感词语提供了很大帮助. 最终本文基于真实的网络新闻文本数据与现有的多种算法进行对比, 证明了该模型具有较好的识别效果, 相比于 Han 模型和 LSTM 模型分别提高了 0.67% 和 3.29%.

**关键词:** 语义相似度, 情感计算, 多头注意力模型, 情感倾向

**中图分类号:** TP391.1

**文献标识码:** A

**文章编号:** 0372-2112 (2020)09-1720-09

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.3969/j.issn.0372-2112.2020.09.008

## A Negative News Recognition Method Based on Emotional Computing and Hierarchical Multi-head Attention Mechanism

ZHANG Yang-sen<sup>1,3</sup>, ZHOU Wei-xiang<sup>1</sup>, ZHANG Yu-yao<sup>1</sup>, WU Yun-fang<sup>2</sup>

(1. Institute of Intelligent Information Processing, Beijing Information Science and Technology University, Beijing 100101, China;

2. Institute of Computational Linguistics, Peking University, Beijing 100871, China;

3. Beijing Laboratory of National Economic Security Early-Warning Engineering, Beijing 100044, China)

**Abstract:** Identification of network negative news has important research significance in network public opinion monitoring. Aiming at the problem that negative news is difficult to detect under the current mass data, this paper proposes a method of negative news recognition based on emotional computing and hierarchical multi-head attention mechanism. Firstly, this paper uses TFIDF (Term Frequency-Inverse Document Frequency) and emotional similarity algorithm to construct negative news emotional lexicon from news texts. Secondly, this paper uses the method of emotional tendency calculation to calculate the degree of emotional tendency of negative news affective words. Finally, the model vectorizes the emotional tendencies of words and expressions, and use hierarchical multi-attention model to judge the positive and negative emotions of news. The introduction of emotional computing and multi-attention mechanism is of great help in capturing emotional words in texts. Finally, this paper compares the real network news text data with many existing algorithms, and proves that the model has a good recognition effect. Compared with the Han model and LSTM model, it is increased by 0.67% and 3.29% respectively.

**Key words:** semantic similarity; emotional computing; multi-head attention mechanism; emotional tendency

### 1 引言

随着自媒体时代的到来, 网络新闻成为信息传递的一种重要载体, 具有传播速度快、影响面广、渠道多等

特点. 网络新闻来源于多个门户网站, 海内外每天产生的新闻量巨大. 网络新闻犹如一把双刃剑, 好的新闻能够使人们快速了解当前发生的热点事件, 坏的新闻会直接影响国家的安全稳定. 网络新闻平台是一个错综

收稿日期: 2019-08-26; 修稿日期: 2019-10-31; 责任编辑: 梅志强

基金项目: 国家自然科学基金 (No. 61772081); 科技创新服务能力建设-科研基地建设-北京实验室-国家经济安全预警工程北京实验室项目 (No. PXM2018\_014224\_000010); 促进高校内涵发展——研究生科技创新项目 (No. 5121911044)

复杂的社会环境,不同的新闻工作者对于同一事件的报道有着自己独特的见解,很容易产生一些片面的理解,导致报道的内容出现危害国家和社会的行为.本文定义的负面新闻是指报道的新闻内容违反社会公德、道德标准以及危害国家的不正当言论,例如辱骂领导人、批判中国各项政策、国家分裂、宗教、恐怖活动、群体性事件、周边关系等.此类负面新闻一旦进行传播,严重影响社会健康有序的发展.当前,负面新闻主要通过人工构建规则模板,采用匹配的方式进行筛选.由于新闻时效性强,这种方式不能满足业务系统的相关要求.因此,从海量网络新闻文本中识别出负面新闻,及时遏制负面新闻的传播具有较高的研究意义.

## 2 研究现状分析

负面新闻是一种具有情感倾向性的文本,是一种客观性的情感,与主观评价性的文本不同,不具备较强的情感倾向,因此新闻的倾向性判定问题难度较大,情感区分度不高.目前,对于网络新闻情感的分析研究较少,大多数的研究者都集中在主观评价的情感判别方面,其主要判别的方法有两种:基于情感词典与语义规则结合的方法、基于机器学习的判别方法.

基于情感词典与语义规则结合的方法.该方法首先判断词语的情感倾向,再通过对篇章中极性词语或词组计数、或对其褒贬程度值求和或求均值、或结合句法分析等方法获得篇章的总体情感倾向. Turney 等<sup>[1]</sup>提出了基于情感词组的 SO-PMI 的语义分类方法,提取符合规则的形容词或副词词组作为情感词词组,利用点互信息计算抽取的词语与情感词词组的语义相关性得到总体的情感极性;王兰成等<sup>[2]</sup>提出了基于情感本体的主题网络舆情倾向性分析方法,利用情感本体抽取特征词并判断其情感倾向,结合句法规则判断网络文本的情感倾向;周文等<sup>[3]</sup>提出了基于依存句法“动词配价”原理与组块的概念,对句子进行句法分析,在句法树和依赖关系中按规则提取情感依存元组,建立简单句情感依存元组判别模型,来计算句子的情感倾向性;陈涛等<sup>[4]</sup>提出了一种基于依存特征、句法特征和同义词特征的句模获取方法,从标注情感句中半自动地获取情感句模,通过对输入句进行情感句模分类实现文本情感分类;周邦定等<sup>[5]</sup>提出给单个倾向词分配倾向性、强度、极性和标志 4 个属性,通过依存句法找出倾向词之间的依存关系,再通过所提出的情感识别算法结合倾向词词典得出整个句子的情感值,最后将整篇新闻中关键句的情感值叠加,得到整篇新闻的情感值;曹欢欢等<sup>[6]</sup>提出了一种融合依存语法和简化的格语法框架理论,结合情感词典对关键句子集进行主题相关的语义倾向性分析,进而判定负面新闻的方法.

基于机器学习的方法.该方法通过统计正面或负面词语出现的频率或 TFIDF 值作为特征,采用机器学习的算法进行文本分类. Pang Bo 等<sup>[7]</sup>最早利用机器学习方法来解决基于情感的文本分类问题,应用朴素贝叶斯、最大熵、SVM 对电影评论进行分类.然而,机器学习需要人工选择特征,特征选择的好坏直接影响分类结果的准确性.相比于传统机器学习方法,深度神经网络的表达能力有了质的飞跃,并摆脱了特征工程的束缚.利用语义合成性原理通过不同深度模型将低层词向量合成高层文本情感语义特征向量,从而得到文本的深层次情感语义表达. Tang 等<sup>[8]</sup>采用 3 种神经网络来构建学习特殊情感词的嵌入方式(SSWE),将情感信息编码为词的连续表示,并实现了区分“好”和“坏”两个极性相反的情感在词向量空间中的表示;Ren 等<sup>[9]</sup>构建了两个神经网络模型分别处理当前 Tweet 的特征,用神经网络的池化方法自动抽取有效的特征以实现两种神经网络的非线性融合,从而获得最终的情感分类结果;以上方法都是用来解决带有主观性情感的分类问题,但对于新闻类的客观性情感判定则研究的较少.在客观性情感的识别方面,2007 年徐军等<sup>[10]</sup>提出了机器学习方法进行新闻的情感自动分类,选择具有语义倾向的词汇作为特征项,采用贝叶斯算法进行分类;何志勇<sup>[11]</sup>提出了一种基于 LSTM 的新疆暴恐事件新闻情感倾向性分析方法,该方法运用 LSTM 模型进行文本分类,判断新闻的情感倾向.但该方法主要针对暴恐事件相关的文本,泛化性不强,不适合处理海量新闻文本的情感极性判定问题.注意力机制的出现极大提高了传统编码方式捕获特征的能力,注意力机制更擅长捕获在语义表示中重要的部分<sup>[12]</sup>.关鹏飞等<sup>[13]</sup>提出了一种注意力增强的双向 LSTM 情感分析方法,该方法通过注意力机制从词向量层面学习词语对句子情感倾向的权重分布,从而提高了双向 LSTM 的分类效果;李丽双等<sup>[14]</sup>提出了一种基于动态注意力 GRU 的特定目标情感分类方法,利用动态注意力机制提取上下文单词的重要程度,提高了识别不同实体情感类别的能力.

本文充分研究了以上两种情感分类的方法,针对客观性负面新闻难以识别的问题,提出了一种基于情感计算与层次化多头注意力机制的负面新闻判别模型(Emotional Computing and Hierarchical Multi-head Attention Networks mode, EC-HMAN),具体来说,首先对网络新闻文本数据进行采集和预处理,从预处理后的海量文本中提取新闻情感词,然后对提取到的新闻情感词语进行筛选得到负向情感种子词库,采用词语语义相似度计算方法对负向情感种子词库进行扩充,并计算词语的情感倾向度.将词语和词语的情感倾向度进行向量化表示作为负面新闻判别模型的输入.在负面新

闻判别模型中采用层次化多头注意力机制,实现对网络新闻文本的负面新闻识别.情感计算能够有效增强模型对词语情感极性的判别能力,多头注意也能够有效提升自注意力的性能.其流程如图1所示.




图1 负面新闻识别流程图

### 3 词语情感倾向性的计算方法

情感词语主要包含褒义词、贬义词以及中性词,文本中的情感极性主要通过褒义词或贬义词所体现出来,情感词语及其情感极性是情感分析的基础,因此,构建基于情感词语及情感倾向性的本体知识库至关重要.本文将针对现有情感本体库在负向情感词方面的欠缺进行补充,并给出情感极性的自动计算方法.

#### 3.1 负向情感词的遴选与情感本体库的扩充

目前正向情感词库的建设较为完善,负向情感词库仍需要进行扩充,尤其是面向不同领域的负向情感词较为匮乏,本部分将对面向新闻类的负向情感词进行遴选来扩充情感词语库.负向新闻情感词库是指包含危害国家、社会安全稳定的情感词语库.比较规范的情感词语库主要有大连理工大学的《情感本体库》以及《HowNet》的情感词典,这两种较大情感词语库主要面向带有情感色彩较强的主观性文本,例如:电商用户评论、电影评论以及社交媒体用户发表的情绪等.然而,针对负向新闻类的情感词语库,至今没有权威的、公开的语料库资源.本文通过对现有的情感词语库构建方法进行研究,提出了一种基于语义相似度的负向情感词遴选方法,用于构建面向新闻文本的负向词语库,其构建流程如图2所示.




图2 负向情感词的遴选流程图

其负向情感词的遴选步骤如下所示:

Step1:将输入的网络新闻文本数据进行预处理(分词和停用词过滤),生成处理后的词语集合.

Step2:计算预处理后的词语集合中每个词语的TFIDF,并按TFIDF值进行倒序排序.

Step3:选取TFIDF值的Top1000个词语进行人工筛

选,筛选出带有负面情感的词语作为负向种子词集L1.

Step4:将词语集中的每个词语以及负向种子词集L1中的每个词语分别采用预训练好的n维词向量进行表示,然后利用余弦相似度计算词语集中每个词语与L1中每个词语的相似度,其相似度计算公式如式(1)所示.

$$\text{similarity} = \frac{\mathbf{A} \cdot \mathbf{B}}{\|\mathbf{A}\| \|\mathbf{B}\|} = \frac{\sum_{i=1}^n A_i \times B_i}{\sqrt{\sum_{i=1}^n (A_i)^2} \times \sqrt{\sum_{i=1}^n (B_i)^2}} \quad (1)$$

其中 $\mathbf{A}, \mathbf{B}$ 表示采用Word2Vec预训练好的n维词向量.

Step5:若相似度超过0.95,则将该词语加入到负向情感词语库L2中.

通过以上步骤,本文构建的负向情感词语库如表1所示.

表1 负向情感库

词性	数量	举例
动词	508	爆炸、裁决、致癌
名动词	47	突发、威胁、审判
名词	289	违纪、整治
形容词	26	暴戾、奸邪
成语	29	黑恶势力、大祸临头
副词	10	恨死、恐为
习用语	29	下落不明、一查到底

从表1中可以看出,大多数的新闻负向词语为动词或名词形式,成语、副词、习用语的数量偏少,这与实际用语的情况相符.可以证明本文提出的基于语义相似度的情感库扩增方法能够筛选出负向情感词语,并且筛选的情感词语具有较强的政治性负向情感色彩.为避免本文构建的情感词库出现局限性和词语覆盖度过小等问题,将《情感本体库》中的词语和本文构建的新闻负向情感词库进行融合,得到最终的情感词库.

#### 3.2 词语情感极性倾向度的计算

情感倾向是主体对客体内在评价的倾向,在新闻文本的情感判定中,可以理解为新闻发布者对某一事件表达自身观点所持有的一种态度以及报道的事件是否会危害社会的安全与稳定.情感倾向度是指主体对客体持有正面情感或负面情感的强弱程度,强弱程度主要通过词语的情感程度和说话的语气所体现.

词语情感倾向度的计算是对单个词语的情感极性、情感强度进行分析,目的是为文本情感倾向分析提供依据.常用的词语倾向性计算的方法主要基于SO-PMI,实验中发现SO-PMI算法受共现窗口大小和语料库的规模影响较大.因此,本文参考大连理工大学林鸿飞教授带领团队整理的《情感本体库》,将词语的情感强度分为1,3,5,7,9五个层级,9表示强度最大,1表示强度最小.同时,根据词语之间的相似度和情感度成正

比的关系,采用式(2)计算每个词语的情感倾向度.

$$E_{w_i} = \max_{i=1}^N \left\{ \frac{V_{w_i} \cdot V_{w_i}}{\|V_{w_i}\| \|V_{w_i}\|} \right\} E_{w_i} \quad (2)$$

其中,  $E_{w_i}$  表示词语  $A$  的情感倾向度,  $N$  表示《情感本体库》中情感词的数量,  $V_{w_i}$  表示词语  $A$  的词向量,  $V_{w_i}$  表示词语  $i$  的词向量,  $\max_{i=1}^N \left\{ \frac{V_{w_i} \cdot V_{w_i}}{\|V_{w_i}\| \|V_{w_i}\|} \right\}$  表示词语  $A$  与情感词典中词语  $i$  相似度的最大值,  $E_{w_i}$  表示词语  $i$  的情感倾向度, 负向情感词取值为负数, 正向情感词取值为正数.

通过以上方法对词语进行情感计算, 构建了包含 30737 个情感词语库, 其中正向情感词语 12270 个, 负向情感词语 12434 个, 其情感词倾向度如表 2 所示.

表 2 情感词倾向度表

序号	情感词	情感倾向度	最相似词
1	爆炸	-2.91	爆裂
2	冲击	-0.96	冲撞
3	制裁	-6.65	挟制
4	造假	-2.91	作假
5	撞伤	-4.85	撞车
...	...	...	...

从表 2 中可以看出, 采用式(2)计算的词语情感倾向度与种子《情感本体库》中的情感倾向度较为相近, 同时能够明显区分出词语的情感倾向强弱程度, 从而说明本文提出的词语情感倾向度计算方法的合理性.

## 4 新闻情感判定模型的构建

### 4.1 多头注意力模型

2017 年 google 机器翻译团队提出了多头注意力模型 (multi-head attention model)<sup>[15]</sup>, 多头注意力模型是由多个放缩点积注意力 (scaled dot-product attention) 的基础单元堆叠起来, 其模型如图 3 所示. 其中输入矩阵为  $Q \in \mathbb{R}^{n \times d}$ ,  $K \in \mathbb{R}^{n \times d}$ ,  $V \in \mathbb{R}^{n \times d}$  三个值, Scaled Dot-Product Attention 部分有  $h$  层, 每一层的注意力计算如式(3)所示.

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (3)$$

其中  $d$  为神经网络隐藏单元的个数, 因为多头注意力采用的自注意力机制, 所以输入的  $Q = K = V$ . 在多头注意力模型中, 首先将  $Q, K, V$  向量进行线性变换; 其次  $Q$  和每个  $K$  采用点积相似度函数计算其权重, 通过除以一个  $K$  的维度进行放缩, 避免内积值太大, 采用 softmax 函数对这些权重进行归一化处理; 最后将权重和相应的键值进行加权求和得到 Attention. 经过  $h$  次放缩注意力计算后, 得到多个 head, 将每一次的 head 进行拼接, 经过线性变换得到最后的结果, 计算公式如式(4)、(5)所示.

$$\text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V) \quad (4)$$

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \dots, \text{head}_h)W^O \quad (5)$$

其中  $W^O$  表示线性变换的权重,  $\text{MultiHead}(Q, K, V)$  表示最后计算的结果. 通过多次 Attention 的计算, 模型能够从不同空间中学习到更多的特征信息.

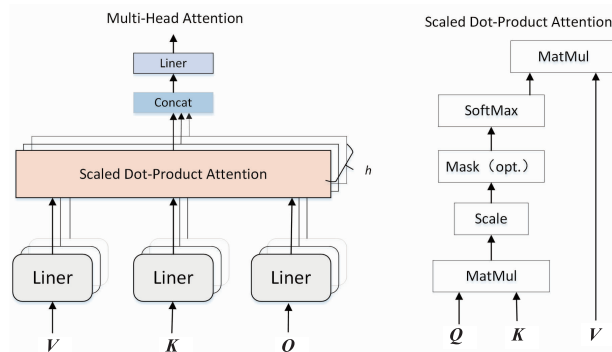


图3 多头注意力结构图

### 4.2 层次化多头注意力模型

新闻文本的情感为客观性情感, 文本中的主观性情感的词语较少, 由于新闻文本数据长度较长, 很难识别出某句话在新闻中的情感色彩. 然而, 层次化注意力模型从词语级别到句子级别进行编码, 在多个分类任务上已取得了较好的效果<sup>[16]</sup>. 本文在层次化注意力模型 (HAN) 的基础上, 引入了负向新闻情感知识库和多头注意力机制, 构建了基于负向新闻情感计算和层次化多头注意力相结合的负面新闻识别模型, 模型的整体架构如图 4 所示.

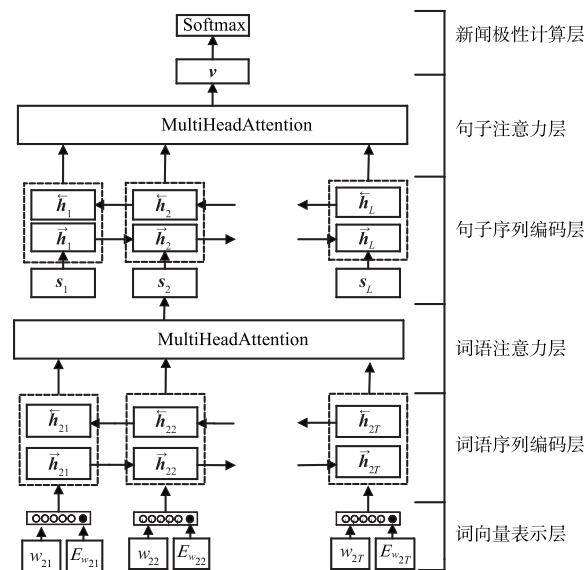


图4 新闻情感判别模型

根据各个层次的不同功能, 本文将该模型自下而上分为六部分, 分别为: 词向量表示层、词语序列编码层、词语注意力层、句子序列编码层、句子注意力层、新闻极性计算层.

### (1) 词向量表示层

词向量用于表示词语的语义信息,词向量表示层作为模型的输入,词向量表示的好坏直接影响文本的语义信息<sup>[17]</sup>.本文考虑到词语情感倾向的强弱,将情感词的情感倾向度引入词向量表示层,其输入的词向量主要包括两部分:词语的向量和词语的情感倾向度.图4中○表示词语的向量,●表示词语的情感倾向度.其计算公式如式(6)所示.

$$\mathbf{x}_{it} = \mathbf{W}_e w_{it} \oplus E_{w_{it}}, t \in [1, T] \quad (6)$$

其中  $\mathbf{W}_e w_{it}$  表示词语  $w_{it}$  的词向量,  $E_{w_{it}}$  表示词语  $w_{it}$  的情感倾向度,  $\mathbf{x}_{it}$  表示第  $i$  个句子的第  $t$  个词语的输入向量,  $\oplus$  表示在行方向上进行拼接,  $T$  表示每个句子的长度,  $\mathbf{W}_e$  是采用 Word2Vec 工具预训练得到的 200 维词向量.

### (2) 词语序列编码层

LSTM 能够捕获文本中较长距离的语义信息<sup>[18]</sup>, LSTM 包含记忆单元、输入门( $i_t$ )、遗忘门( $f_t$ )和输出门( $o_t$ ),用于记录和更新记忆单元的信息.其中,遗忘门决定记忆单元前一状态信息是否保留,输入门控制记忆单元当前时刻信息的输入,记忆单元根据当前输入信息更新记忆状态,通过输出门判断记忆单元对下一状态的输出结果.

新闻文本词语之间具有前后的连续关系,除了正向要考虑词语的词义信息,还要考虑词语之间前后的依赖关系.因此,本文采用 BiLSTM 对新闻词语信息进行编码, BiLSTM 模型不仅能够捕获句子的正向词语关系信息,还能够捕获前后的词语关系信息,其模型结构如图5所示.其中,  $x$  表示输入的词语,  $e$  表示对应输入词语的词向量,  $\vec{h}$  表示前向 LSTM 网络的输出值,  $\overleftarrow{h}$  表示后向 LSTM 网络的输出值,  $h$  表示 BiLSTM 的输出值.本文对于词语级序列编码计算公式如式(7)~(9)所示.

$$\vec{h}_{it} = \overrightarrow{\text{LSTM}}(\mathbf{x}_{it}) \quad (7)$$

$$\overleftarrow{h}_{it} = \overleftarrow{\text{LSTM}}(\mathbf{x}_{it}) \quad (8)$$

$$h_{it} = [\vec{h}_{it}, \overleftarrow{h}_{it}] \quad (9)$$

其中  $\vec{h}_{it}$  表示第  $i$  句第  $t$  个词语前向 LSTM 网络的输出值,  $\overleftarrow{h}_{it}$  表示第  $i$  句第  $t$  个词语后向 LSTM 网络的输出值,  $h_{it}$  表示第  $i$  句第  $t$  个词语 BiLSTM 网络的输出值.




图5 BiLSTM结构图

### (3) 词汇注意力层

新闻文本中不是每个词语都对句子有重要意义,一句话中往往只有少数的词语影响句子的含义,将每个词语赋予不同的权重来表示对句子的贡献程度.注意力机制能够学习句子中词语的依赖关系,从而捕获句子的内部结构,找出对输入的文本句子含义价值最大的词语或字,本文采用4.1节多头注意力机制计算词语编码序列的词语权重,其输入为词语编码层的输出  $h_{it}$ ,多头注意力计算后的结果通过 max pooling 进行压缩变换,最终得到单个序列的表示  $S_i, i \in [1, L], L$  表示句子的个数.

### (4) 句子序列编码层

在新闻负面文本的判定中,每个句子的情感极性影响着整篇文章的情感极性,通过神经网络能够挖掘出句子隐含的信息,同时句子与句子之间又存在着前后依赖关系.因此,本文采用 BiLSTM 对整个句子进行编码,寻找句子中的隐性特征并进行表示.其计算公式如式(10)~(12)所示.

$$\vec{h}_i = \overrightarrow{\text{LSTM}}(s_i) \quad (10)$$

$$\overleftarrow{h}_i = \overleftarrow{\text{LSTM}}(s_i) \quad (11)$$

$$h_i = [\vec{h}_i, \overleftarrow{h}_i] \quad (12)$$

其中  $\vec{h}_i$  表示第  $i$  句前向 LSTM 网络的输出值,  $\overleftarrow{h}_i$  表示第  $i$  句后向 LSTM 网络的输出值,  $h_i$  表示第  $i$  句 BiLSTM 网络的输出值.

### (5) 句子注意力层

新闻文本作为一种长文本,每句话对整个文本都有不同的影响程度,句子注意力层的目的是找出每句话对整篇文本情感分类的不同贡献程度.同样,本文采用4.1节的多头注意力机制来衡量每个句子对文本的重要性,其输入为句子序列编码层的输出值  $h_i$ ,多头注意力计算后的结果采用 max pooling 进行压缩变换得到句子的表示  $v$ .

### (6) 情感判定层

情感判定层主要是构建新闻文本的情感二分类判定器,对深层学习的特征信息进行情感倾向判定,输出最终新闻文本的情感标签.本文采用 softmax 分类器构建新闻文本情感标签的分类,计算公式如式(13)所示.

$$p = \text{softmax}(Wv + b) \quad (13)$$

其中,  $p$  表示每一个倾向类别的概率值.本文目标函数采用负对数似然函数作为训练的损失函数,其计算公式如式(14)所示.

$$L = - \sum_d \log p_d \quad (14)$$

其中  $j$  表示文档  $d$  的标签.

## 5 实验与结果分析

### 5.1 实验数据

当前针对负面新闻倾向性分类没有公开的评测数

数据集,本文采用分布式网络爬虫技术采集了多个 App 新闻数据源,包含:百度新闻、搜狐新闻、澎湃新闻等.为了保证实验数据与真实情况的吻合,从经济、政治、体育等多种类别爬取了 30 多万条新闻文本数据.采用人工筛选的方式构建了 25000 条正向新闻数据和 25000 条负向新闻数据,将数据按照训练集与验证集 3:1 的比例随机进行了 10 次划分,用于后续实验的验证,多次随机划分数据保证了本文实验结果的稳定性.

## 5.2 数据预处理

本文通过分析发现,新闻数据主要有以下特点:①数据内容杂乱:网络新闻存在大量的图片信息,导致采集的数据存在大量 URL;②数据繁体字较多:尤其海外新闻存在大量的繁体字;③数据较长:新闻主要倾向于注重对事件的描述,信息内容较长.本文针对以上几种情况进行数据预处理,处理方法如下:

(1) 利用正则表达式识别数据中的 URL 脚本内容,并将其进行删除;

(2) 采用 Hanlp 工具包提供的繁简体转换功能,将繁体字转换成简体字;

(3) 统计文本的长度分布,其结果如图 6 所示.




图6 数据长度分布图

由图 6 可以看出,新闻文本的数据长度大多在 1000 字以内,本文对长度超过 1000 字的部分内容进行截断,同时对长度小于 50 字的内容进行了过滤.

本文利用爬取的 30 万新闻语料和百度百科语料库构建了一个 Word2Vec 词向量训练语料,采用 Skip-gram 模型进行词向量训练,训练参数为默认值,输出词向量维度为 200 维.经过训练,得到了包含 2009501 个词的词向量,该词向量包含所有常用词语与专业名词.

## 5.3 实验参数设置

本文实验中前端采用 keras 深度学习框架进行搭建,后端采用 tensorflow 作为计算框架,模型参数设置如表 3 所示.

表 3 参数设置表

参数	说明	取值
Learning_rate	学习率	0.001
Optimizer	模型优化函数	Adam
Bach_size	每次迭代输入的数据个数	64
Dropout	防止过拟合	0.3
$h$	多头注意力的层数	8

## 5.4 实验评价指标

本文采用精准率  $P$ 、召回率  $R$ 、 $F1$  值以及正确率 Accuracy 作为模型的评价指标,其计算公式如式(15)~(18)所示.

$$P = \frac{TP}{TP + FP} \quad (15)$$

$$R = \frac{TP}{TP + FN} \quad (16)$$

$$F1 = \frac{2 \cdot P \cdot R}{P + R} \quad (17)$$

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (18)$$

其中,TP 表示真正属于负向的新闻数量,FP 表示将正向的新闻判定为负向的新闻数量,TN 表示真正属于正向的新闻数量,FN 表示将负向的新闻判定为正向的新闻数量.

## 5.5 实验对比模型

LSTM 模型:文献[11]采用 LSTM 模型对新疆暴恐事件新闻情感倾向进行分析,取得了不错的效果.

CNN 模型<sup>[19]</sup>:该模型自 2013 年 kim 提出以来,在多种数据集的分类任务上都取得了较好的效果.

RCNN 模型<sup>[20]</sup>:该模型首先使用循环神经网络捕获上下文信息,其次采用最大池化法判断哪些词语在文本分类中起关键作用,实现对文本的分类任务.

BiLSTM 模型:该模型直接通过双向 LSTM 对文本进行建模,采用 softmax 进行文本分类.

BiLSTM-Att 模型:该模型在 BiLSTM 模型的基础上,采用自注意力机制学习词语的权重信息,实现文本分类.

Han 模型:该模型采用层次化的注意力机制,分别从词语级到句子级对文本进行建模,保留了文本的原始结构信息,为本文模型的基准模型.

EC-Han 模型:该模型是在 Han 模型的基础上,引入情感计算的结果,实现对负面新闻的判别.

Hman 模型:该模型是在 Han 模型的基础上,采用多头注意力模型实现对负面新闻的判别.

## 5.6 实验结果与分析

本文在上述构建的新闻数据集上进行对比试验,来验证本文提出方法的有效性.其实验结果表 4 所示.

表 4 实验结果表

模型	$P$	$R$	$F1$
LSTM	0.8082	0.8691	0.8373
CNN	0.7629	0.9021	0.8260
RCNN	0.8061	0.8938	0.8475
BiLSTM	0.8118	0.8663	0.8378
BiLSTM-Att	0.8238	0.8776	0.8498
Han	0.8368	0.8650	0.8506

从表 4 中可以看出, CNN 模型的召回率最高, 然而精准率很低, 说明 CNN 模型能够筛选出更多的负面新闻, 但是误将正面新闻识别为负面新闻的情况较多, 其主要原因可与能 CNN 模型在卷积池化的过程中, 更能识别出负面的词语有关. RCNN 模型较 CNN 和 LSTM 模型在  $F1$  值方面提升 1% 左右, 说明利用 RNN 和 CNN 模型的叠加能够提升分类的效果. BiLSTM-Att 模型在整体上比 BiLSTM 和 LSTM 模型效果好, 说明增加的注意力机制能够更好的捕获重要的信息. Han 模型的  $F1$  值高于其他五种模型, 说明 Han 模型通过层级注意力能够更好的识别新闻的情感倾向, 同时也证明了本文选取的基准模型具有较高的研究价值.

表 5 模型实验结果对比表

模型	$P$	$R$	$F1$
Han	0.8368	0.8650	0.8506
EC-Han	<b>0.8474</b>	0.8681	0.8570
Hman	0.8324	<b>0.8802</b>	0.8556
EC-Hman	0.8471	0.8791	<b>0.8628</b>

从表 5 中可以看出, EC-Han 模型较 Han 模型在  $P$ 、 $R$ 、 $F1$  三个评价指标上均有所提高, 说明词语情感度的引入能够提升模型的效果; Hman 模型较 Han 模型在召回率上提高较大, 说明多头注意力模型在不同子空间中学习到的更多特征, 能有效提升识别出负向的新闻文本的性能. EC-Hman 在精准率、召回率以及  $F1$  值方面都高于 Han 模型, 说明本文提出的新闻情感词和层次化多头注意力能够提升 Han 模型的识别效果, 所以能够验证本文提出的方法合理性.

从图 7 中可以看出, Han 模型作为本文的基准模型, 与其他模型相比有较高的正确率, 说明 Han 模型保留的文本层级结构和注意力机制能够对文本有更好的分类效果. 本文提出的 EC-Hman 模型在负面新闻文本的识别上取得了最好的效果, 正确率达到 0.8402, 相比 Han 模型和 LSTM 模型分别提升了 0.67% 和 3.29%, 能够验证本文提出方法在网络负面新闻识别中的有效性.

### 5.7 可视化分析

为了进一步验证本文提出模型在词语注意力方面的有效性, 本文选取了两篇负向新闻文本段落进行可视化展示, 在图 8 中用加粗字体标出了词语注意力层计算后权重较大的词语.




图 7 实验结果正确率对比图

持续打压校园左派势力北大学生遭退学。来源德国之声作者根据住士建会标签工人下的日志工人声援团官网的消息, 两名长期关注底层工运的标签左派下的日志左派学生过去一周内陆续遭警方逮捕。此外, 北京语言大学的左派学生团体新青年, 也在月日遭无预警注销。一连串事件显示, 政府对标签校园下的日志校园左派势力的打压仍在持续。中国标签共产党下的日志共产党对大学校园左派势力的打压持续发酵。根据住士工人声援团官网的消息, 两名左派学生在过去一周内陆续遭警方强制拘捕。

美大学警告学生在中国别用微信防任意拘捕。数名在华加拿大标签公民下的日志公民遭中共抓捕, 被视为是中国当局的眼线。美国国务院日前对标签中国下的日志中国发布第二级旅行警告, 加州大学戴维斯分校则在近日向部份学生示警, 不要在中国境内使用标签下的日志或标签微信下的日志微信等通讯软件, 暗示中国当局可能会对美国公民随意标签拘捕下的日志拘捕或限制出境。据南华早报月日报道, 加州大学戴维斯分校一位负责人伦纳德在周一通过电子邮件向该校电子与计算机工程系学生发送赴中旅游警告。中国当局因标签孟晚舟事件下的日志孟晚舟事件而高调抓捕加拿大公民, 美国国务院月日更新中国旅行警告, 敦促前往中国旅行和在华美国公民提高警惕, 小心中共的任意执法与以出境禁令理由禁止美国公民出境。

图 8 词语注意力权重可视化图

从图 8 中可以看出, 本文提出的方法能够选出带有负向较强情感词语, 如: 拘捕、抓捕、示警等. 也能够选出一些在文中占用较大权重的名词, 如中国、中共、美国国务院等. 情感词库的引入为模型增加了人工构建的外部知识, 同时多头注意力模型通过多次的注意力求得的词语权重效果更好. 从而更能够证明本文提出的基于情感词库和层次化多头注意力模型具有较好的负面新闻识别效果.

为了直观的展示出模型在句子级注意力层的效果, 本文选取一段负面新闻文本进行实验.

**新闻文本:** 中纪委网站 6 月 24 日发文《@ 党员干部: “股事” 有风险, 这些红线莫触犯》, 提醒党员干部“股事” 红线. 文中点名了六名省部级官员涉及内幕交易或泄露内幕信息. 这 6 名炒股的省部级官员中, 最早落马的是国家安全部原副部长马建. 2015 年 1 月 16 日, 中央纪委监察部网站发布消息, 称马建涉嫌严重违纪违法, 接受组织调查. 马建通过内幕消息炒股, 获利 4929 万余元. 这个“战绩” 在六名炒股官员中, 只能排在三名之外. 姚刚与马建同一年落马. 作为证监会原副主席, 姚刚内幕信息应该最多, 炒股可谓近水楼台. 不过他利用内幕信息炒股, 只赚了 210 万余元. 是六名官员中炒股“成绩” 最差的. 除了姚刚, 六人中算得上有炒股专长的, 还有安徽省原副省长的陈树隆. 陈树隆安徽财贸学院会计专业毕业. 从政后, 他通过内幕交易, 非法获利 1.37 亿元.

对新闻文本按句号进行分割, 共分为 12 个句子, 绘制句子级注意力权重分配图, 如图 9 所示.




图9 句子级注意力权重分配图

从图9中可以看出,第四个句子分配的权重最高,表明该句话对整篇文本的影响最大,句子中出现的“涉嫌、违纪、违法”等词语负向情感倾向较强,更能代表整篇新闻的情感倾向。第九句话分配的权重最小,虽然在句子中出现了“最差”这样的负向词语,但本文更为关注的是具有较强政治色彩的句子,这与本文所定义的负面新闻的完全吻合。

## 6 结束语

本文在分析了现有负面新闻识别方法的基础上,针对负面新闻难以识别的问题,提出了一种基于情感计算与层次化多头注意力模型的负面新闻识别方法。首先,采用TFIDF和词语语义相似度算法构建了新闻类负向情感词库;其次,基于情感词库计算了词语的情感倾向度;最后,构建了基于情感计算与层次化多头注意力的新闻判别模型,对新闻中不同情感倾向的文本进行识别。通过多组对比实验表明,本文提出的模型在处理新闻正负向类别方面有较高的正确率。同时,对模型捕获负向词语的结果进行了可视化展示,能够证明本文提出方法在识别负向词语方面有较强的识别能力。在下一步研究工作中,将对情感库进行实时动态扩展,增加更多的新词,以提高新闻判别的准确性。

## 参考文献

[1] Turney Peter, Littman Michael. Measuring praise and criticism: inference of semantic orientation from association [J]. ACM Transaction on Information Systems, 2003, 21 (4): 315 - 346.

[2] 王兰成,徐震. 基于情感本体的主题网络舆情倾向性分析 [J]. 信息与控制, 2013, 42(01): 46 - 52.  
WANG L C, XU Z. Tendency analysis of thematic networks public opinion based on sentiment ontology [J]. Information and Control, 2013, 42 (01): 46 - 52. (in Chinese)

[3] 周文,欧阳纯萍,阳小华,等. 一种基于情感依存元组的简单句情感判别方法 [J]. 中文信息学报, 2017, 31 (03): 177 - 183.  
ZHOU W, OUYANG C P, YANG X H, et al. A simple-sentence sentiment classification method based on emotional dependency tuples [J]. Journal of Chinese Information Processing, 2017, 31 (03): 177 - 183. (in Chinese)

[4] 陈涛,徐睿峰,吴明芬,等. 一种基于情感句模的文本情感分类方法 [J]. 中文信息学报, 2013, 27(05): 67 - 74.  
CHEN T, XU R F, WU M F, et al. A sentiment classification approach based on sentiment sentence framework [J]. Journal of Chinese Information Processing, 2013, 27(05): 67 - 74. (in Chinese)

[5] 周邦定,曹海鹏,张彦. 新闻情感倾向性识别算法的研究与应用 [J]. 微型机与应用, 2015, 34(14): 58 - 60 + 67.  
ZHOU B D, CAO H P, ZHANG Y. Research and application of an algorithm about news' emotional tendency recognition [J]. Microcomputer and Applications, 2015, 34(14): 58 - 60, 67. (in Chinese)

[6] 曹欢欢,谢兴生. 负面新闻判定算法的研究与应用 [J]. 小型微型计算机系统, 2015, 36(05): 1047 - 1051.  
CAO HH, XIE X S. Research and application of an algorithm about negative news judgment [J]. Journal of Chinese Mini-micro Computer Systems, 2015, 36 (05): 1047 - 1051. (in Chinese)

[7] Bo Pang, Lillian Lee, Shivakumar Vaithyanathan. Thumbs up? Sentiment classification using machine learning techniques [A]. Proceedings of the 2002 Conference on Empirical Methods in Natural Language Processing [C]. Philadelphia, PA: EMNLP, 2002. 79 - 86.

[8] Tang DY, Wei FR, Yang N, et al. Learning sentiment-specific word embedding for twitter sentiment classification [A]. Proceedings of the Meeting of the Association for Computational Linguistics [C]. Baltimore, Maryland: ACL, 2014. 1555 - 1565.

[9] Ren Y, Zhang Y, Zhang M, Ji D. Context-Sensitive Twitter sentiment classification using neural network [A]. 30th AAAI Conf on Artificial Intelligence (AAAI 2016) [C]. Phoenix, Arizona, USA: AAAI, 2016. 215 - 221.

[10] 徐军,丁宇新,王晓龙. 使用机器学习方法进行新闻的情感自动分类 [J]. 中文信息学报, 2007(06): 95 - 100.  
XU J, DING Y X, WANG X L. Sentiment classification for chinese news using machine learning methods [J].

- Journal of Chinese Information Processing, 2007 (06) : 95 – 100. (in Chinese)
- [11] 何志勇. 基于 LSTM 新疆暴恐事件新闻情感倾向性分析[D]. 大连:大连理工大学, 2017.  
HE Z Y. Analysis of Emotional Tendency of News in Xinjiang Violent Based on LSTM[D]. Dalian: Dalian University of Technology, 2017. (in Chinese)
- [12] ZHANG Yangsen, ZHENG Jia, JIANG Yuru, et al. A text sentiment classification modeling method based on coordinated cnn-lstm-attention model[J]. Chinese Journal of Electronics, 2019, 28(01) : 120 – 126.
- [13] 关鹏飞, 李宝安, 吕学强, 等. 注意力增强的双向 LSTM 情感分析[J]. 中文信息学报, 2019, 33(02) : 105 – 111.  
GUAN P F, LI B A, LV X Q, et al. Attentionenhanced bi-directional LSTM for sentiment analysis [J]. Journal of Chinese Information Processing, 2019, 33(02) : 105 – 111. (in Chinese)
- [14] 李丽双, 周安桥, 刘阳, 等. 基于动态注意力 GRU 的特定目标情感分类[J]. 中国科学: 信息科学, 2019, 49(08) : 1019 – 1030.  
LI S L, ZHOU A Q, LIU Y, et al. Aspect-based sentiment analysis based on dynamic attention GRU [J]. Scientia Sinica Informationis, 2019, 49(08) : 1019 – 1030. (in Chinese)
- [15] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[A]. 31st International Conference on Neural Information Processing Systems [C]. Long Beach, California, USA; NIPS, 2017. 5998 – 6008.
- [16] Yang Z, Yang D, Dyer C, et al. Hierarchical attention networks for document classification[A]. Proceedings of the 2016 Conference of the North American Chapter of The Association for Computational Linguistics; Human Language Technologies [C]. San Diego, California, USA; NAACL HLT, 2016, 1480 – 1489.
- [17] 梁斌, 刘全, 徐进, 等. 基于多注意力卷积神经网络的特定目标情感分析[J]. 计算机研究与发展, 2017, 54(08) : 1724 – 1735.  
LIANG B, LIU Q, XU J, et al. Aspect-based sentiment analysis based on multi-attention CNN[J]. Journal of Computer Research and Development, 2017, 54(08) : 1724 – 1735. (in Chinese)
- [18] 王青. 基于强化学习的层次化注意力网络模型及文本情感分类研究[D]. 广州: 华南理工大学, 2018.  
WANG Q. Study on Hierarchical Attention Network Model Based on Reinforcement Learning and Text Sentiment Classification[D]. Guangzhou: South China University of Technology, 2018. (in Chinese)
- [19] Kim Y. Convolutional neural networks for sentence classification[A]. Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing [C]. Doha, Qatar; EMNLP, 2014. 1746 – 1751.
- [20] Lai S, Xu L, Liu K, et al. Recurrent convolutional neural networks for text classification[A]. Twenty-Ninth AAAI Conference on Artificial Intelligence [C]. Austin, Texas, USA; AAAI, 2015. 2267 – 2273.

### 作者简介



张仰森 男, 1962 年 6 月出生于山西临猗, 博士后, 教授, 研究方向为中文信息处理、人工智能.  
E-mail: zhangyangsen@163.com



周炜翔 男, 1993 年 5 月出生于河北唐山, 硕士研究生, 研究方向中文信息处理.  
E-mail: zwx0286@163.com



张禹尧 男, 1996 年 9 月出生于北京密云, 硕士研究生, 研究方向为中文信息处理.  
E-mail: 13716580192@163.com



吴云芳 女, 1973 年 3 月生于山西, 博士, 副教授, 研究方向为语义计算, 智能问答.  
E-mail: wuyf@pku.edu.cn