

文章编号: 39

## 基于双重注意力模型的微博情感分析方法\*

郑佳, 张仰森, 黄改娟, 蒋玉茹

(北京信息科技大学 智能信息处理研究所, 北京市 100101)

**摘要:** 注意力模型在许多自然语言处理任务中都表现出了优秀的性能。该文针对现有大多数情感分析方法将深度学习模型与情感符号相剥离的现状, 提出了一种双重注意力模型的微博情感分析方法。该方法首先利用现有的情感知识库构建了一个包含情感词、程度副词、否定词、微博表情符号和常用网络用语的微博情感符号库; 然后, 采用双向长短记忆网络模型和全连接网络, 分别对微博文本和文本中包含的情感符号进行编码; 接着, 采用注意力模型分别构建微博文本和情感符号的语义表示, 并将两者的语义表示进行融合, 以构建微博文本的最终语义表示; 最后, 基于所构建的语义表示对情感分类模型进行训练。通过将注意力模型和情感符号相结合, 有效增强了对微博文本情感语义的捕获能力, 提高了微博情感分类的性能。基于 NLPCC 微博情感测评公共数据集, 对所提出的模型进行评测, 在多个情感分类任务中都取得了最佳的效果, 其中, 在 2013 和 2014 的数据集上, 相对于已知最好的模型, 宏平均和微平均的 F 值分别提升了 1.39%、1.26% 和 2.02%、2.21%。

**关键词:** 双重注意力模型, 微博文本, 情感分析, 语义表示, 情感符号

中图分类号: TP391

文献标识码: A

## A Microblog Sentiment Analysis Method Based on Double Attention Model

Zheng Jia, Zhang Yangsen, Huang Gaijuan, Jiang Yuru

(Institute of Intelligent Information Processing, Beijing Information Science and Technology University, Beijing 100101, China)

**Abstract:** Attention model shown excellent performance in many natural language processing tasks. In this paper, in view of the fact that most sentiment analysis methods based on deep learning model did not use the feature of emotion symbol, we proposed a double attention model for microblog sentiment analysis. First of all, we constructed a microblog emotion symbol knowledge base based on the existing emotional semantic resources which including emotion words, degree adverbs, negative words, microblog emoticons and common internet slang. Then, we used bidirectional long short-term memory and full connection network to encode the microblog text and the emotion symbols appeared in text. After that, we used the attention model to construct the semantic representation of microblog text and emotion symbols, and combined the semantic representation of them to construct the final semantic expression of microblog text. Finally, the emotion classification model was trained based on the constructed semantic representation. By combining the attention model and emotion symbol, the ability to capture the emotion and semantics of microblog text is effectively enhanced, and the performance of microblog sentiment classification is improved. The model proposed in this paper achieved the best effect in many sentiment classification task on the datasets of NLPCC microblog sentiment analysis task. Experiments on the 2013 and 2014 NLPCC datasets have been done and the F-Score of macro average and micro average raised by 1.39%、1.26% and 2.02%、2.21%, respectively, comparing to the known best model.

**Key words:** a double attention model; microblog text; sentiment analysis; semantic representation; emotion symbols

### 1 引言

以微博为代表的新兴社交媒体, 以其独特的开放性、实时性、互动性和低门槛性为人们

---

\* 基金项目: 国家自然科学基金 (61370139, 61602044)

进行意见表达和信息交流提供了新的媒介，人们通过微博平台发表观点，抒发情感，使其已超越传统媒体成为新的信息聚集地，以极快的速度影响着社会的信息传播格局<sup>[1]</sup>。对微博文本进行情感分析有助于了解公众的情感状态，及时获取公众的观点、态度，对于舆情控制、产品营销、民意调查等方面具有重要的意义。因此，开展以微博文本为代表的网络社交媒体文本的情感分析已经成国内外学者的研究热点。

情感分析是分析人们对于特定的评价对象所持有的观点、态度、意见等主观感受，评价对象包括：事件、个人、组织、服务、产品等实体及其相关属性<sup>[2]</sup>。人们对于情感的表达一般以文本、声音、图像为载体，并借助于一定的情感符号进行渲染与加强。微博文本短小、随意、主题鲜明的独特语言特性为情感的表达提供了便利，同时也为情感分析的研究带来了机遇与挑战。

国内外的相关学者已经对情感分析做了大量的研究，并取得了一些显著的成果。常见的情感分析研究主要包括情感识别、情感极性分析和细粒度的情感分析等。情感识别又称为主客观分类，主要是识别文本中的主观文本，为后续进一步的情感分析奠定基础。情感极性分析是情感分析的基础任务，主要是将情感分为正向和负向两类或者正向、负向和中性三类，最早进行情感分析研究的工作就是 Pang 等<sup>[3]</sup>对电影评论文本进行的正负情感的分类工作。情感极性分类任务虽然简单，但是可以满足很多现实的应用需求，如电商网站中评论的好评和差评的区分、舆情控制中公众对于某一政策的支持或反对的识别等。但是人们对于某一评价对象的情感倾向往往不只有正向和负向这么简单，还可能蕴含着更加复杂的情感成分，对于情感细粒度的类别暂时还没有统一的标准，有 6 类、12 类、18 类甚至 24 类等多种分类方法。目前在中文情感分析领域应用比较多的是大连理工大学信息检索研究室的 7 大类 20 小类的情感分类体系<sup>[4]</sup>（最新版已扩展至 21 小类），7 大类情感分别为乐（happiness）、好（like）、怒（anger）、哀（sadness）、惧（fear）、恶（disgust）、惊（surprise）。在该分类体系的基础上，文献[4]还构建了一个中文情感词汇本体，最新版的中文情感词汇本体已包含 27466 个情感词语。本文实验的情感分类体系也将采用该种分类方法。

现有的情感分析技术主要分为三种：基于情感知识的方法、基于特征分类的方法和基于深度学习的方法。基于情感知识的方法主要是构建一些情感词典，通过情感词典对文本中的情感词进行一定的组合计算，实现对文本情感的分析<sup>[5-6]</sup>。情感词是带有情感倾向的词语，是情感表现的主要载体之一，因此，情感词典的构建是情感分析的基础<sup>[7]</sup>，Chen 等<sup>[8]</sup>通过整合多种语言资源构建一个巨大的知识图，并进一步构建了 136 种主要语言的情感词典；李寿山等<sup>[9]</sup>在考虑到英文情感词典研究比较充分的基础上，借助机器翻译系统将中英文评论语料进行翻译，采用标签传播算法，将英文情感词的极性信息传播到中文词语上，从而实现中文情感词典的构建。

基于特征分类的方法主要是采用文本分析技术，提取文本中蕴含的相关语言特征，采用机器学习的方法将情感分析看作分类问题进行处理<sup>[10-11]</sup>，但是该方法对于情感特征提取方法的依赖性较大，提取情感特征的好坏将直接影响到最终的分类结果。

基于深度学习的方法主要是采用词向量表示技术，对文本中的词语进行表示，进而构建句子和篇章的语义表示。在句子和篇章的语义表示的基础上，采用深度学习模型对文本中蕴含的情感进行学习，从而实现文本情感的分析，常用的深度学习模型包括：卷积神经网络（CNN）<sup>[12]</sup>、循环神经网络（RNN）<sup>[13]</sup>、长短记忆网络（LSTM）<sup>[14]</sup>等。

人们在进行情感表达时，往往是采用某些特殊的情感符号实现情感的呈现，常用的情感符号主要为带有情感色彩的情感词，有时为了对情感进行更加深入的表达，人们往往会将情感词与程度副词或是否定词配合使用，起到情感加强或情感减弱的效果。微博作为新兴社交媒体，其中的情感表现形式除了基本的情感词外，还包含微博平台自身的表情符号和一些流行的网络用语，在本文中，我们将情感词、程度副词、否定词、微博表情符号、网络用语统

称为情感符号，将其作为评价微博文本情感倾向的一个重要组成部分。

现有的深度学习模型在进行情感分析时，大多是将文本看作一个整体进行编码，对于情感符号的作用体现不够，而传统的基于情感词典的方法则过分依赖于情感词典的作用，并没有考虑文本整体的语义关系。同时，微博文本的随意性和情感表示的多样性也为传统的情感分析带来了挑战。基于此，本文将在机器翻译任务中表现出优秀性能的注意力模型<sup>[15-16]</sup>引入到情感分析任务中，利用注意力模型对微博文本和情感符号进行双重编码，提出了一种基于双重注意力模型（Double Attention Model, DAM）的微博文本情感分析方法。本文的主要贡献有以下几点：

（1）通过利用现有的情感语义资源，对中文微博中经常使用的情感符号进行分类和统计，构建了一个微博情感符号库。

（2）提出了一种基于双重注意力模型的微博情感分类方法，将注意力模型引入微博文本的情感分析之中，通过设计相关实验验证了双重注意力模型在情感二分类和情感多分类任务中的先进性。

（3）通过设计相关实验，验证了在深度学习模型中引入注意力机制和情感符号，对情感分析性能的提升作用，实验表明，其性能超越了一般的深度学习模型。

本文剩余章节的安排如下：第2节介绍注意力模型的相关背景和微博情感分析的相关工作；第3节重点描述本文提出DAM模型；第4节介绍实验数据集和基本的实验流程，报告相关实验结果并进行分析；最后对本文的工作进行总结。

## 2 相关工作

### 2.1 注意力模型

最早将注意力模型引入自然语言处理领域的是Bahdanau等<sup>[15]</sup>人，Bahdanau等认为传统的Encoder-Decoder模型中Encoder生成的固定长度的中间语义向量是提升神经机器翻译模型性能的瓶颈，为此，Bahdanau等提出了一种预测输出单词与源句子中单词的自动对齐模型，应用到英语与法语的翻译系统中取得了不错的效果，该对齐模型就是现在大多数注意力模型的基础。随后，基于注意力机制的Encoder-Decoder模型在自然语言处理的很多领域得到了应用，如机器人的短文本对话<sup>[17]</sup>、文本摘要生成<sup>[18]</sup>、文本分类<sup>[19]</sup>、句法分析<sup>[20]</sup>等。

随着注意力模型在自然语言处理领域的广泛应用，各种改进模型也应运而生，如Luong等<sup>[16]</sup>针对注意力中全局对齐的模式，提出了一种局部注意力模型，首先确定对齐的大致位置，然后向左向右各拓展一定的窗口长度，在指定的窗口范围内计算每个单词的对齐概率；Karl等<sup>[21]</sup>根据人们在做阅读理解时，往往都是阅读完整个问题后再去文档中寻找答案，而不是每读完一个单词就去文档中寻找答案的实际情况，将逐个对齐的方式修改为将整个问题与文档中的单词进行对齐的模式；Raffel<sup>[22]</sup>等为了解决长距离的语义依赖问题，将注意力模型中的对齐模型进行改进，通过对当前输入的自适应加权，将原来前一时刻输出的隐含状态与当前时刻输入的隐含状态进行对齐的模式，修改为仅依赖当前时刻输入的隐含状态的对齐模式。

### 2.2 微博文本情感分析

自从微博出现以来，国内外对于微博文本的情感分析研究就从未间断过。多数的研究工作仍然是承袭了传统的基于情感知识的方法、基于特征分类的方法和基于深度学习的相关模型。如栗雨晴等<sup>[23]</sup>在大规模微博文本的基础上，利用相似度计算的方法对现有的情感词汇知识库进行扩展，构建了一个双语情感词典，采用半监督高斯混合模型和对称相对熵的K近邻算法实现对微博文本的情感分类计算；Barbosa等<sup>[24]</sup>在普通文本特征的基础上，提取了微博文本特有的一些特征包括：转发、回复、hashtag、URL、标点符号、表情符号以及以大写字母开头的单词数目，采用有监督的方法实现对Twitter文本的情感分类。由于微博文本中的表情符号具有较强的情感表现力，越来越多的研究将其引入到情感分析中，如Jiang等

[25]利用表情符号的词向量构建了表情符号向量空间 (Emoticon Space Model), 并将微博文本中所有的词映射到向量空间中, 采用 SVM 模型实现对微博文本的情感分类; 何炎祥等[26]为常见的表情符号构建情感空间的特征表示矩阵, 通过对文本词向量矩阵与表情符号的特征表示矩阵进行乘积运算, 实现词义到情感空间的映射, 从而构建微博文本的情感表示矩阵, 然后采用多通道的卷积神经网络对微博文本情感表示矩阵进行建模, 实现对微博文本的情感分类。虽然文献[25]和文献[26]都考虑了微博文本中表情符号对于情感表现的重要性, 但是都是采用全局的表情符号集实现对微博文本的情感加强, 并未考虑微博文本自身情感符号的意义以及文本自身的语义特征, 同时也未考虑微博文本的中常见的情感词以及常用的网络用语对于情感的表现能力。受文献[19]和文献[26]的启发, 本文将考察常见的情感符号, 包括情感词、程度副词、否定词、微博表情符号、网络用语对情感表现的作用, 采用注意力模型对微博文本和文本中包含的情感符号分别进行建模, 构建了一种双重注意力模型的微博文本情感分析方法, 并采用 NLPCC2013 和 NLPCC2014 的微博情感测评数据集, 构建了多个微博文本情感分类任务对本文提出的模型进行验证。

### 3 双重注意力模型

#### 3.1 情感符号库的构建

为了提取微博文本中的情感符号, 本文通过整理现有情感知识库, 构建了微博文本情感符号库, 库中各种情感符号的数目如表 1 所示。

表 1 微博情感符号库

情感符号	数目	举例
情感词	34606	高兴、绝望、恶心
表情符号	1866	[哈哈]、[伤心]、[失望]
程度副词	219	很、相当、着实
否定词	62	不、从未、绝非
网络用语	675	伤不起、羡慕嫉妒恨、你想多了

其中, 情感词主要基于大连理工大学的情感本体库和董振东老师构建的《HowNet》中的情感词典进行构建的; 表情符号采用新浪 API 从新浪微博开放平台上获得; 程度副词以《HowNet》中的程度副词列表为基础进行构建; 否定词和网络用语是以 Song 等[27]构建的否定词表 (negation words) 和网络用语词表 (NetLex) 为基础进行构建的。

#### 3.2 情感符号的提取

通过构建的情感符号库, 提取微博文本中包含的情感符号, 为每一条微博文本构建情感符号集合。对于情感符号的提取, 我们制定了如下提取规则。

**规则 1:** 若当前词语为情感词、表情符号和网络用语, 直接将当前词语加入到情感符号集合中。

**规则 2:** 若当前词语为程度副词, 且当前词语的下一个词语为情感词, 则将当前程度副词和情感词作为一个整体加入到情感符号集合中, 若情感词存在于情感符号集合中, 则将其删除。

**规则 3:** 若当前词语为否定词, 且当前词语的下一个词语为情感词, 则将当前否定词和情感词作为一个整体加入到情感符号集合中, 若情感词存在于情感符号集合中, 则将其删除; 或者当前词语的下一个词语为程度副词, 并且程度副词的下一个词语为情感词, 则将当前否定词和程度副词以及情感词作为一个整体加入到情感符号集合中, 若程度副词与情感词的整体存在于情感符号集合中, 则将其删除。

#### 3.3 双重注意力模型

我们在双向长短记忆网络 (Bidirectional Long Short-Term Memory, BLSTM) 深度学习模型中引入注意力机制和情感符号, 构建的双重注意力模型的整体架构如图 1 所示。

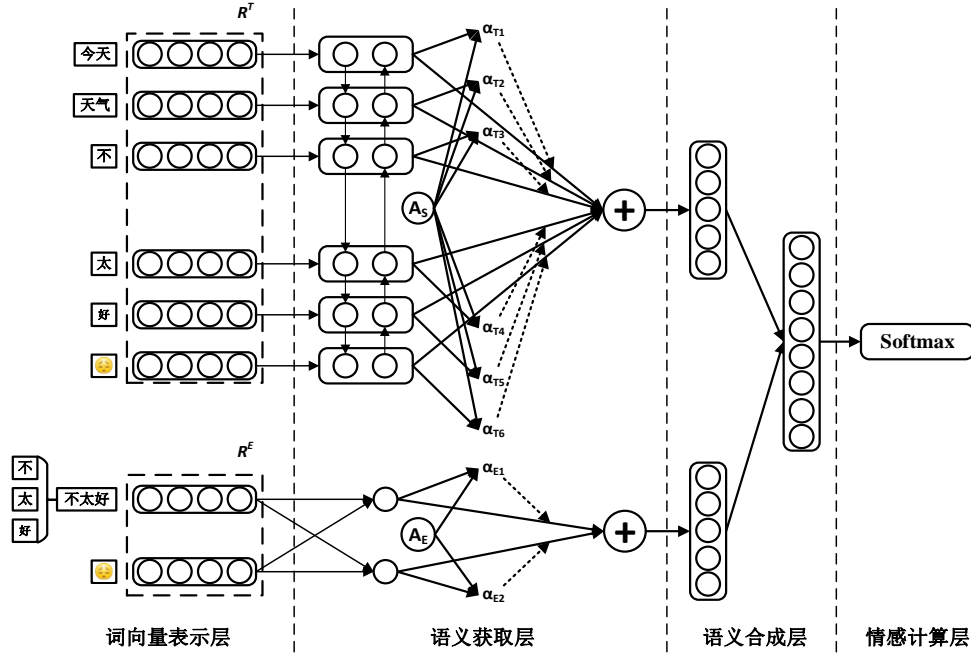


图 1 双重注意力模型架构

从图 1 可以看出，所提模型是一个自底向上的多层前向神经网络，按照其功能，可依次划分为词向量表示层、语义获取层、语义合成层、情感计算层四部分。各部分的结构介绍如下：

### 3.3.1 词向量表示层

词向量表示层为整个模型的输入，主要包括两部分：每一条微博文本词语的词向量矩阵  $R^T$  和情感符号集合的词向量矩阵  $R^E$ 。词语及情感符号词向量的获取可以看作是一个查词典的过程，词典  $\mathcal{I}^{d \times N}$  通过大规模语料，采用词向量训练模型<sup>[28-29]</sup>学习得到，其中  $d$  表示词向量的维数， $N$  表示词典中词语的个数。在词典中，每一个词语被表示为一个多维的、稠密的向量，可以映射为向量空间中的某一点，词意相近的词语在向量空间中具有较小的距离。对于一个文本序列  $T=\{w_1, w_2, \dots, w_n\}$ ，通过将文本中词语的词向量拼接起来，就可以得到整个文本序列的词向量表示如式 (1) 所示。

$$R^T = v_1 \oplus v_2 \oplus \dots \oplus v_n \quad (1)$$

其中， $v_i \in \mathcal{I}^{d \times N}$  表示  $w_i$  应于词典中的元素， $\oplus$  表示行向量的拼接操作。情感符号集合序列的词向量表示同样采用式 (1) 的方式进行拼接， $R^T$  和  $R^E$  矩阵的维数即为微博文本中词语的数目和情感符号的数目。

### 3.3.2 语义获取层

对于微博文本，除了需要考虑词语之间的语义依赖关系，还要体现出哪些词语对于情感的表现更加重要，对于情感表现重要的词语需要赋予更高的权重，因此，我们采用 BLSTM 和注意力模型对微博文本的语义信息进行编码；对于情感符号集合，为了找出集合中最重要的情感信号，我们采用全连接网络与注意力模型相结合的方式对情感符号进行编码。

由于 LSTM<sup>[30]</sup> 具有较强的长距离语义捕获能力，因此在文本处理中被广泛使用。但是普通的 LSTM 模型仅能捕获文本中的正向语义信息，缺乏对逆向语义信息的捕获，因此，本文在对文本的语义信息进行编码时采用 BLSTM 模型<sup>[31]</sup>，BLSTM 模型是正向的 LSTM 模型和逆向的 LSTM 模型的结合，能够同时捕获正向的语义信息和逆向的语义信息。LSTM 通过一个记忆单元  $c$ ，三个门结构（输入门  $x$ 、遗忘门  $f$  和输出门  $o$ ）来控制当前网络中信息的流量。具体来说，当前时刻记忆单元的信息含量  $c_t$  和输出的信息量  $o_t$  是由当前时刻的输入  $x_t$ 、当前时刻遗忘门的状态  $f_t$ 、前一时刻记忆单元的信息含量  $c_{t-1}$  以及前一时刻的输出  $o_{t-1}$  共同决定的，在 BLSTM 中，各个结构之间的关系可以简单的表示为式 (2)、式 (3)。

$$\begin{aligned} \overset{\mathbf{r}}{c}_t, \overset{\mathbf{r}}{o}_t &= G(\overset{\mathbf{r}}{c}_{t-1}, \overset{\mathbf{r}}{o}_{t-1}, \overset{\mathbf{r}}{f}_t, x_t) \\ \overset{\mathbf{s}}{c}_t, \overset{\mathbf{s}}{o}_t &= G(\overset{\mathbf{s}}{c}_{t-1}, \overset{\mathbf{s}}{o}_{t-1}, \overset{\mathbf{s}}{f}_t, x_t) \end{aligned} \quad (2)$$

其中,  $G$  表示 LSTM 模型中各个结构之间的关系。在 BLSTM 中, 某一时刻  $t$  的输出状态由当前时刻的正向 LSTM 和逆向 LSTM 的输出相连接组成, 可以表示为  $o_t = [\overset{\mathbf{r}}{o}_t, \overset{\mathbf{s}}{o}_t]$ , 这样, 正向的语义信息和逆向的语义信息以相同的地位被考虑。

由于每条微博文本中的每个情感符号之间只是具有情感加强和减弱的功能, 如相同极性的情感符号同时出现或是出现增强性的程度副词, 情感将会得到加强; 相反极性的情感符号同时出现或是出现减弱性的程度副词或者否定词, 情感将会得到减弱甚至反转, 情感符号相互之间并不存在较强的语义依赖关系, 因此, 采用全连接网络对情感符号集合进行非线性变换, 进行最初的语义编码。

为了捕获更直接的语义依赖关系, 我们将微博文本 BLSTM 模型的输出和情感符号集全连接的输出分别输入到注意力模型中, 采用双重注意力模型分别对微博文本和情感符号进行编码。注意力模型通过对每一个输入状态  $h_t$  进行加权, 从而实现为输入文本构造一个上下文相关的文本表示向量  $v$  如式 (4) 所示。

$$v = \sum_{t=1}^T \alpha_t h_t \quad (4)$$

其中,  $T$  为输入状态的数目,  $\alpha_t$  为输入状态  $h_t$  的权重, 与标准的注意力模型<sup>[15]</sup>不同的是, 本文注意力模型中的  $\alpha_t$  与每一时刻的输入状态和一个随机初始化的上下文向量  $A$  有关,  $A$  可以看作是对输入的一种表示。  $\alpha_t$  通过式 (5)、式 (6) 计算得到。

$$\alpha_t = \frac{\exp(e_t^T A)}{\sum_{k=1}^T \exp(e_k^T A)} \quad (5)$$

$$e_t = \text{Tanh}(Wh_t + b) \quad (6)$$

式 (5) 和式 (6) 中,  $W$  为模型中的权重,  $b$  为模型中的偏置, 两者和  $A$  一起作为模型训练过程中的参数, 通过不断训练学习得到。通过以上注意力模型, 可以为输入构造一个定长的上下文相关的文本表示向量, 向量中的信息包含各个输入状态的重要程度。

通过语义获取层, 分别为  $\mathbf{R}^T$  和  $\mathbf{R}^E$  进行语义编码, 构建其语义表示矩阵  $\mathbf{S}^T$  和  $\mathbf{S}^E$ 。  $\mathbf{S}^T$  和  $\mathbf{S}^E$  中包含了微博文本的重要情感语义信息。

### 3.3.3 语义合成层

语义合成层的主要任务是将  $\mathbf{S}^T$  和  $\mathbf{S}^E$  进行合并, 构建微博文本整体的语义表示向量。在本文中, 为了简化模型的计算量, 仅对  $\mathbf{S}^T$  和  $\mathbf{S}^E$  采用按行连接的方式进行语义合并, 构建一个  $(\text{rows}_T + \text{rows}_E) \times \text{cols}$  的矩阵  $\mathbf{S}$ , 对微博文本进行语义表示, 其中  $\text{rows}_T$  和  $\text{rows}_E$  表示  $\mathbf{S}^T$  和  $\mathbf{S}^E$  的行数,  $\text{cols}$  表示  $\mathbf{S}^T$  和  $\mathbf{S}^E$  的列数。

### 3.3.4 情感计算层

情感计算层的主要任务是构建情感分类器, 获取微博文本的语义表示  $\mathbf{S}$  对于每一个情感标签的得分向量, 并输出微博文本的最终情感标签。我们采用 *Softmax* 分类器构建每一个情感标签的得分向量, 并将其转化为条件概率分布如式 (7) 所示。

$$P_i(x) = \frac{\exp(x_i)}{\sum_{j=1}^C \exp(x_j)}, i = 1, 2, \dots, C \quad (7)$$

其中,  $C$  表示情感标签的数目。为了更好的训练模型, 我们采用对数损失函数来衡量情感标签的真实概率分布  $P_i^f(d)$  和预测的概率分布  $P_i^p(d)$  之间的差距如式 (8) 所示。

$$\text{loss} = -\sum_{d \in T} \sum_{i=1}^C P_i^f(d) \log(P_i^p(d)) \quad (8)$$

其中,  $T$  为训练数据集,  $d$  为  $T$  中的一篇微博文本。我们利用式 (8) 的损失函数, 采用反向传播机制对模型中的参数集合  $\theta$  进行训练和更新, 获取最优的参数集合  $\theta = \{\theta_{blstm}, \theta_{emlp}, \theta_{atten}\}$ ,  $\theta_{blstm}$  为微博文本的 BLSTM 语义编码网络的参数集合,  $\theta_{emlp}$  为情感符号集合的全连接语义编码网络的参数集合,  $\theta_{atten}$  为注意力模型的参数集合, 其中包含文本注意力模型和情感符号注意力模型的参数。

## 4 实验与分析

### 4.1 数据集

本文的实验数据采用 NLPCC 会议 2013 年和 2014 年中文微博情绪识别评测任务的公共数据集, 数据集中的微博文本全部来源于新浪微博平台, 每个数据集分为训练集和测试集两部分, 每一条微博文本标注为一个主要的情感标签和多个次要的情感标签。情感标签总共分为 8 种, 采用文献[4]的分类标准, 并将无情感的微博文本标注为情感标签 none, 各个类别作为主要情感标签的微博文本的数目如表 2 所示。

表 2 NLPCC2013 和 NLPCC2014 数据集

情感标签	2013-train	2013-test	2014-train	2014-test
happiness	370	1116	1459	441
like	595	1558	2204	1042
anger	235	436	669	128
sadness	385	744	1173	189
fear	49	102	148	46
disgust	425	935	1392	389
surprise	113	236	362	162
none	1828	4873	6591	3603
总计	4000	10000	13998	6000

其中, NLPCC2014 的训练数据中的 happiness 情感类别和 sadness 情感类别中各有一条微博内容为空, 我们选择将其删除。为了进一步验证本文提出的 DAM 模型的性能, 我们还设计了微博文本主客观分类任务和微博文本情感正负极性分类任务。在主客观分类任务中, 将情感标签 none 作为客观标签, 其它七类情感标签作为主观标签; 在正负极性分类任务中, 将 happiness、like 作为正向标签, 将 anger、sadness、fear、disgust、surprise 作为负向标签, 具体数据集大小如表 3 所示。

表 3 情感二分类数据集

	objective	subjective	positive	negative
2013	6701	7299	3639	3660
2014	10194	9804	5146	4658
总计	16895	17103	8785	8318

为了构建词语和表情符号的词向量, 我们采用开源的爬虫框架 WebCollector 实现了一个微博爬虫程序, 并采用 NLPPIR 工具对爬取的微博文本进行分词, 在分词的过程中, 将构建的微博情感符号库中的情感符号作为分词词典, 使其在分词后作为一个基本的语言单元而存在。此外, 我们还进行了一系列的微博文本预处理, 如繁简转换、url 替换、短小无意义微博的剔除等。最终, 构建了一个 Word2Vec 词向量训练语料, 包含微博 40 292 997 条, 包含词语 1 342 646 318 个。训练的过程中采用 Skip-gram 模型, 其它相关参数均采用默认设置, 经过训练, 得到了一个包含 850 599 个词的词向量, 每个词的词向量的维数为 200。

### 4.2 基准模型

**MNB 模型**<sup>[32]</sup>: 作为传统机器学习的代表, MNB (Multinomial Naïve Bayes) 在许多多

分类的情感分类任务中都取得了优秀的效果。

**MCNN 模型**<sup>[12]</sup>: 采用多通道的卷积神经网络对微博文本的词向量表示进行特征学习, 从而构建文本的语义表示, 实现文本的情感分类, 这是较早采用深度学习模型进行情感分析的模型之一。

**ESM 模型**<sup>[25]</sup>: 通过计算微博文本中词语的词向量与微博表情符号词向量的 cosine 值, 实现词语到情感空间的映射, 采用 SVM 模型进行情感分类。该模型分两种, 一种是对映射后的词语直接求和, 另一种是对映射后的词语采用求最大、最小和求和策略, 我们选择效果较好的第二种方法作为对照模型。

**EMCNN 模型**<sup>[26]</sup>: 为常见微博表情符号构建语义特征表示矩阵, 通过矩阵乘积运算, 使用表情符号的语义特征表示矩阵对微博文本进行语义增强, 采用多通道的卷积神经网络进行特征学习, 实现情感分类。

**BLSTM 模型**: 不引入注意力模型和情感符号, 直接采用 BLSTM 模型对微博文本建模, 并进行情感分析, 为本文模型的基准模型。

**SAMT 模型**: 是只考虑对微博文本  $R^T$  采用注意力模型进行相应编码的一个对照模型, 用于与本文提出 DAM 模型进行对比, 以体现出引入微博情感符号的 DAM 模型的优越性。

#### 4.3 实验参数设置

采用 Python 的 Hyperopt 库进行分布式调参, 获取模型的最优参数集合, 需要调节的参数如表 4 所示。

表 4 模型参数调节列表

参数	说明	取值范围	取值
optimizer	模型优化器	Adadelta, RMSprop	Adadelta
lstm_units	LSTM 输出维度	100, 150, 200, 250	200
batch_size	梯度下降时, 每个 batch 包含的样本数	8, 16, 32, 64	32
dropout	每次更新参数时随机断开输入神经元的比例, 用于防止过拟合	[0.05, 0.95]	在模型的输入层之后和最后的 Softmax 层之前分别使用了 dropout, 取值分别为: 0.30, 0.50

#### 4.4 实验结果分析

##### 4.4.1 NLPCC 微博情感测评任务

按照 NLPCC 的中文微博情绪识别评测任务的相关要求和评价指标, 本文分别对 NLPCC2013 和 NLPCC2014 公布的数据进行了实验, 实验结果如表 5、表 6 所示。

表 5 NLPCC2013 实验结果

模型	MicroF1	MacroF1
MNB	0.3208	0.3105
MCNN	0.4365	0.3462
ESM	0.4390	0.3500
EMCNN	0.4422	0.3517
BLSTM	0.4078	0.3151
SAM	0.4377	0.3570
<b>DAM</b>	<b>0.4548</b>	<b>0.3656</b>

表 6 NLPCC2014 实验结果

模型	MicroF1	MacroF1
MNB	0.3595	0.2783
MCNN	0.4534	0.3829
ESM	0.4425	0.3786
EMCNN	0.4723	0.3940
BLSTM	0.4456	0.3385
SAM	0.4779	0.3842
<b>DAM</b>	<b>0.4944</b>	<b>0.4142</b>

其中, DAM 模型在所有的指标上都取得了最好的结果, 相较于目前已知的最好模型 EMCNN, 在 2013 年的数据集上, MicroF1 和 MacroF1 分别提升了 1.26% 和 1.39%, 在 2014 年的数据集上, MicroF1 和 MacroF1 分别提升了 2.21% 和 2.02%, 体现了个性化的情感符号要好于全局化的情感符号, 这与文献[26]的结论是相一致的, 同时, 本文的 DAM 模型在 2014



年的数据集上的性能提升要好于 2013 年，是由于 2014 年的训练集要比 2013 年更大，模型得到了更加充分的训练。

SAM 模型在 2013 年的数据集上的 MicroF1 相对较低，排到了第四位，但是 MacroF1 指标却仅次于 DAM 模型，排在第二位；在 2014 年的数据集上 MicroF1 排第二位，MacroF1 排第三位，整体来说，SAM 模型的性能在 MCNN 模型之上，说明本文的注意力机制对微博文本的情感分类是有效的。DAM 模型的性能明显高于 SAM 模型，说明本文构建的情感符号对于微博文本的情感分类具有很大的帮助，同时，EMCNN 模型的性能稍好于 SAM，也验证了这一点。

#### 4.4.2 情感二分类任务

在 NLPCC 情感测评任务的基础上，我们还进行了情感正负极性分类任务和主客观分类任务。情感正负极性分类任务和主客观分类任务为情感二分类问题，我们对表 3 所示数据集，采用十折交叉验证的方法构建实验进行验证，实验的结果采用准确率作为指标进行评价，实验结果如图 2、图 3 所示。




图 2 正负极性分类结果对比图




图 3 主客观分类结果对比图

在情感正负极性分类任务中，本文的 DAM 模型相较于 EMCNN 模型有稍微的提高，但是 SAM 模型的性能要差于 EMCNN 模型，说明情感标签特别是微博中的表情符号对于情感正负分类任务具有较大的贡献。

在主客观分类任务中，本文的 DAM 模型仍然取得了最好的性能，并且 SAM 模型战胜了 EMCNN 模型取得了第二好的性能，说明注意力模型的引入对于主客观分类任务具有很大的帮助。虽然 2013 年的训练数据量要少于 2014 年（见表 3），但是所有模型 2013 年的性能要好于 2014 年，说明 2014 年的数据在主客观分类任务上要更加困难，这与文献[25]和文献[26]的结论基本一致。

#### 4.4.3 情感符号性能分析

为了验证各种情感符号对于微博文本情感分析的影响，我们在 SAM 模型的基础上，分别在 NLPCC2014 的数据集的测评任务和情感正负分类任务中添加各种情感符号及其组合，设置了 6 组对照试验，分别是 SAM+S（SAM+情感词）、SAM+E（SAM+表情符号）、SAM+N（SAM+网络用语）、SAM+EN（SAM+表情符号+网络用语）、SAM+SEN（SAM+情感词+表情符号+网络用语）和 SAM+SNA（SAM+情感词+否定词+程度副词），由于否定词和程度副词只有作用于情感词时，才会表现出其作用，且两者在数据集中较少，因此未单独与 SAM 模型进行组合，仅设置了与情感词搭配的对照。6 组对照试验与 SAM 和 DAM 的对比结果如图 4、图 5 所示。

从图 4、图 5 中我们可以看出，在 SAM 模型的基础上，单独添加情感词、表情符号以及网络用语时，其性能都有提升，但是在测评任务中单独添加表情符号和网络用语时性能提

升的不如情感正负分类任务中明显,在情感正负分类任务中单独添加表情符号性能提升的甚至要高于单独添加情感词,将表情符号和网络用语同时添加时,情感正负分类任务的性能提升也要好于测评任务。这说明了微博符号和网络用语对于正负情感的表现非常能力要较多种复杂情感的表达能力要强一些。同时,否定词和程度副词对于性能的提升不是那么明显,主要与数据集中否定词与程度副词出现的较少相关。




图 4 测评任务中情感符号性能对比




图 5 正负极性分类任务中情感符号性能对比

#### 4.4.4 微博文本语义表示的可视化分析

为了更清楚的展现本文模型对于微博文本的表现力,我们采用 PCA 降维技术对 DAM 模型中微博文本的语义表示进行降维处理,并将降维后的结果进行可视化。具体来说,我们对 NLPCCC2014 的数据集的测评任务、情感正负分类任务中的微博文本语义表示的维数降低为 2 维,在平面直角坐标中进行可视化展示,可视化后的结果如图 6、图 7 所示。




图 6 2014 年数据测评任务分析可视化结果




图 7 2014 年正负极性分类任务可视化结果

从图中可以看出,本文的 DAM 模型能够很好的将相同情感的语义表示聚集在一起,同时也能很好的区分不同情感的语义表示。在测评任务中,对于情感标签不同,但是情感极性相近的标签,在坐标系中具有较近的距离,而极性相反的标签具有较大的距离。在情感正负极性分类任务中,各个类别的聚类效果相较于测评任务各类别的聚类效果更好,是由于在情感正负极性分类任务中,训练数据比较充足,模型训练的比较充分,这与测评任务中训练数据比较充分的大类情感标签聚类效果较好,而训练数据比较少的小类情感标签聚类效果较差是相吻合的。同时情感正负极性分类任务中,其情感类别相对较少,也使得聚集的比较充分。

## 5 总结

本文提出了一种基于双重注意力模型的微博情感分析方法。通过利用现有的情感分析资源构建了一个包含情感词、程度副词、否定词、微博表情符号和常用网络用语的微博情感符号库,引入注意力模型对微博文本和文本中包含的情感符号分别进行编码,构建微博文本的

语义表示。通过将情感符号和注意力模型相结合,有效地增强了模型对于文本情感语义的捕获能力,进而提升了微博文本的情感分析性能。在 NLPCC 微博情感测评数据集上,本文提出的模型在多个任务上都表现了优越的性能,并在多个指标上超过了已知的最好结果。由于数据的限制,本文的情感符号库中收集的情感符号还不够全面,同时,模型对于各种情感符号语义的捕捉能力的度量方法还有待研究。因此,本文下一步的工作是进一步扩展情感符号库,并探究各种情感符号对于语义表示的影响。


## 参考文献

- [1] 丁兆云, 贾焰, 周斌. 微博数据挖掘研究综述[J]. 计算机研究与发展, 2014, 51(4): 691-706.
- [2] Liu B. Sentiment analysis and opinion mining[M]. Morgan & Claypool Publishers, 2012:1-167.
- [3] Pang B, Lee L. Seeing stars: exploiting class relationships for sentiment categorization with respect to rating scales[C]// Proceedings of the ACL. 2005:115-124.
- [4] 徐琳宏, 林鸿飞, 潘宇,等. 情感词汇本体的构造[J]. 情报学报, 2008, 27(2):180-185.
- [5] Taboada M, Brooke J, Tofiloski M, et al. Lexicon-based methods for sentiment analysis[J]. Computational Linguistics, 2011, 37(2):267-307.
- [6] Wiebe J, Wilson T, Cardie C. Annotating expressions of opinions and emotions in language[J]. Language Resources and Evaluation, 2005, 39(2):165-210.
- [7] Teng Z, Vo D T, Zhang Y. Context-Sensitive lexicon features for neural sentiment analysis[C]// Proceedings of the EMNLP. 2016:1629-1638.
- [8] Chen Y, Skiena S. Building sentiment lexicons for all major languages[C]// Proceedings of the ACL. 2014:383-389.
- [9] 李寿山, 李逸薇, 黄居仁等. 基于双语信息和标签传播算法的中文情感词典构建方法[J]. 中文信息学报, 2013, 27(6):75-81.
- [10] Pang B, Lee L. Opinion mining and sentiment analysis[J]. Foundations & Trends in Information Retrieval, 2008, 2(1-2):1-135.
- [11] Pang B, Lee L, Vaithyanathan S. Thumbs up? sentiment classification using machine learning techniques[C]//Proceedings of the EMNLP. 2002:79-86.
- [12] Kim Y. Convolutional neural networks for sentence classification[C]// Proceedings of the EMNLP. 2014:1746-1751.
- [13] Zhang Y S, Jiang Y R, Tong Y X. Study of sentiment classification for Chinese microblog based on recurrent neural network[J]. Chinese Journal of Electronics, 2016, 25(4):601-607.
- [14] Zhu X, Guo H, Mohammad S, et al. An empirical study on the effect of negation words on sentiment[C]// Proceedings of the ACL. 2014:304-313.
- [15] Bahdanau D, Cho K, Bengio Y. Neural Machine Translation by Jointly Learning to Align and Translate[C]// Proceedings of the ICLR. 2015.
- [16] Luong M T, Pham H, Manning C D. Effective approaches to attention-based neural machine translation[C]// Proceedings of the EMNLP. 2015:1412-1421.
- [17] Shang L, Lu Z, Li H. Neural responding machine for short-text conversation[C]// Proceedings of the ACL. 2015:1577-1586.
- [18] Alexander M R, Sumit C, Jason W. A neural attention model for sentence summarization[C]// Proceedings of

the EMNLP. 2015:379-389.

- [19] Yang Z, Yang D, Dyer C, et al. Hierarchical attention networks for document classification[C]// Proceedings of the NAACL-HLT. 2016:1480-1489.
- [20] Vinyals O, Kaiser L, Koo T, et al. Grammar as a Foreign Language[C]// Proceedings of the NIPS. 2015:2773-2781.
- [21] Hermann K M, Tomás K, Grefenstette E, et al. Teaching Machines to Read and Comprehend[C]// Proceedings of the NIPS. 2015: 1693-1701.
- [22] Raffel C, Ellis D P W. Feed-Forward Networks with Attention Can Solve Some Long-Term Memory Problems[C]// Proceedings of the ICLR. 2016.
- [23] 栗雨晴, 礼欣, 韩煦等. 基于双语词典的微博多类情感分析方法[J]. 电子学报, 2016, 44(9):2068-2073.
- [24] Barbosa L, Feng J. Robust sentiment detection on Twitter from biased and noisy data[C]// Proceedings of the COLING. 2010:36-44.
- [25] Jiang F, Liu Y Q, Luan H B, et al. Microblog Sentiment Analysis with Emoticon Space Model[J]. Journal of Computer Science and Technology, 2015, 30(5):1120-1129.
- [26] 何炎祥, 孙松涛, 牛菲菲等. 用于微博情感分析的一种情感语义增强的深度学习模型[J]. 计算机学报, 2017(4).
- [27] Song K, Feng S, Gao W, et al. Build emotion lexicon from microblogs by combining effects of seed words and emoticons in a heterogeneous graph[C]// Proceedings of the HT. 2015:283-292.
- [28] Mikolov T, Sutskever I, Chen K, et al. Distributed representations of words and phrases and their compositionality[J]. Advances in Neural Information Processing Systems, 2013, 26:3111-3119.
- [29] Pennington J, Socher R, Manning C. Glove: global vectors for word representation[C]// Proceedings of the EMNLP. 2014:1532-1543.
- [30] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 2012, 9(8):1735-1780.
- [31] Graves A, Jaitly N, Mohamed A R. Hybrid speech recognition with Deep Bidirectional LSTM[C]// Proceedings of the ASRU. 2013:273-278.
- [32] Bermingham A, Smeaton A F. Classifying sentiment in microblogs: is brevity an advantage?[C]// Proceedings of the CIKM. 2010:1833-1836.

## 作者简介



郑佳 (1991—), 男, 硕士研究生, 主要研究领域为自然语言处理、情感分析。  
E-mail:zhengjia0826@163.com。



黄改娟 (1964—), 女, 高级工程师, 主要研究领域为自然语言处理、人工智能。  
E-mail:huang\_gj@163.com。



张仰森 (1962—), 男, 博士后, 教授, 通讯作者, 主要研究领域为中文信息处理、人工智能。E-mail: zhangyangsen@163.com。



蒋玉茹 (1978—), 女, 博士, 副教授, 主要研究领域为自然语言处理、语义网。  
E-mail:jiangyuru\_modi@126.com。