

王海涛, 何鑫, 施屹然, 等. 基于结构性符号文本的多通道情感分类模型构建[J]. 智能计算机与应用, 2024, 14(10): 164-169. DOI: 10.20169/j.issn.2095-2163.241023

# 基于结构性符号文本的多通道情感分类模型构建

王海涛<sup>1</sup>, 何鑫<sup>2</sup>, 施屹然<sup>3</sup>, 纪明宇<sup>2</sup>

(1 黑龙江财经学院 财经信息工程学院, 哈尔滨 150025; 2 东北林业大学 计算机与控制工程学院, 哈尔滨 150036;

3 苏州大学 计算机科学与技术学院, 江苏 苏州 215000)

**摘要:** 本文提出了一种改进的用于处理包含颜文字的结构性和文字混合文本的新的情感分类模型。模型综合包括多层感知机、统计情感缩放、预构建词典、多通道处理和自注意力机制在内的多种技术, 具有较高的可扩展性和可解释性。同现有的情感分类模型相比, 本模型能更好地感知颜文字对文本语义的影响, 并在此基础上实现文本情感分类。实验结果表明, 该模型在融合颜文字的文本情感分类任务中表现出更好的性能。此外, 模型可用于解决其他混合结构符号和文本的自然语言处理问题, 为情感分类领域的发展提供了新思路和新方法。

**关键词:** 深度学习; 结构性符号; 文本分类; 情感分类模型

中图分类号: TP391.1

文献标志码: A

文章编号: 2095-2163(2024)10-0164-06

## A multi-channel sentiment classification model construction based on structural symbolic text

WANG Haitao<sup>1</sup>, HE Xin<sup>2</sup>, SHI Yiran<sup>3</sup>, JI Mingyu<sup>2</sup>

(1 College of Finance and Information Engineering, Heilongjiang University of Finance and Economic, Harbin 150025, China;

2 College of Computer and Control Engineering, Northeast Forestry University, Harbin 150036, China;

3 School of Computer Science and Technology, Soochow University, Suzhou 215000, Jiangsu, China)

**Abstract:** This paper proposes a new and improved sentiment classification model for processing mixed structural symbol and textual texts containing face characters. The model integrates various techniques including multi-layer perceptron, statistical sentiment scaling, pre-constructed dictionary, multi-channel processing and self-attentive mechanism, with high scalability and interpretability. Compared with existing sentiment classification models, this model can better perceive the influence of face text on text semantics and achieve text sentiment classification on this basis. Experimental results show that the model shows better performance in text sentiment classification tasks incorporating face characters. In addition, the model can be used to solve other natural language processing problems with mixed structured symbols and texts, providing new ideas and methods for the development of the field of sentiment classification.

**Key words:** deep learning; structural symbol; text classification; sentiment classification model

## 0 引言

社交网络用户量的持续增长给随即涌现的大量情感文本信息分类带来了挑战。本文旨在解决混合符号与文字的文本分类问题, 以挖掘隐藏的信息和情感表示, 具有重要实际意义<sup>[1-3]</sup>。在实际应用场景中, 比如社交媒体和直播平台等, 存在大量混合

符号与文字的文本信息。这些符号是遵循一定规则组成的具象表达, 能够反映与影响整个文本信息的情感表示。整体来看, 这种混合符号与文字的文本信息存在着口语化、内容不纯粹等特点。传统的特征工程方法难以全面感知文本的整体情感, 因此本文提出一种基于符号文本特征分离、多通道处理的方法。

**基金项目:** 黑龙江财经学院 2024 年校级科研课题 (XJYB2024031); 黑龙江省重点研发计划项目 (2022ZX01A35)。

**作者简介:** 王海涛 (1975-), 女, 副教授, 主要研究方向: 机器学习, 人工智能; 何鑫 (1998-), 男, 硕士研究生, 主要研究方向: 自然语言处理; 施屹然 (2003-), 男, 本科生, 主要研究方向: 多模态信息处理。

**通讯作者:** 纪明宇 (1980-), 男, 博士, 副教授, 主要研究方向: 自然语言处理, 系统仿真建模。Email: 50117019@qq.com

收稿日期: 2023-06-13

结构性符号颜文字是由特定字符编排组合形成的表情符号,其核心在于外化情绪与表情的呈现。其中,颜文字符号更具有代表性,因其使用方便,不需要使用额外的表情系统而被大量使用。在颜文字与普通文字混合的文本中,如果只是对文字特征进行提取,则模型会忽略颜文字对文本的影响,容易导致分类结果与作者的情感产生偏差,比如“你可真棒”本身表达正向的情感,但加上颜文字符号后,如“你可真棒(-\_-|||)”,使得文本整体呈现负向情感。同样文字信息也可以影响颜文字信息的表达,有“(^v^)”表示微笑,其本身表达出正向的情感,但在特定的情境下,比如在“放弃吧(^v^)”语句中,微笑表情具有嘲讽意思,使得整个文本呈现负向的情感。因此,这些符号信息受语境与背景等方面的影响,其整体语义具有复杂多变的特点。

针对该情况,本文提出符号文本特征分离、多通道处理的方式,具体来说,研究基于 MLP 和统计缩放的形式单独构建符号向量词典,将结构性符号信息转化为向量表示。同时,使用 BERT 预训练模型处理普通文字,将其转化为向量表示。然后,将不同通道输出的特征使用自注意力机制进行特征融合,增强结构性符号的特征表示能力。最后,将融合后的特征向量输入到基于双向简单循环网络(BiSRU)构建的情感分类网络中,输出文本情感分类结果。

本次研究进行了大量实验比较,结果表明本文提出的方法在情感分类效果上具有显著的优势,分类准确率和召回率均超过了传统方法和其他对比方法。此外,本文所提出的方法训练效率也更高,具有较好的实用性和推广价值。

## 1 相关工作

在短文本分类中,为提升短文本分类的准确率,Bao 等学者<sup>[4]</sup>结合 BERT、CNN 和 BiGRU 对短文本特征进行捕捉和融合。Yu 等学者<sup>[5]</sup>使用并行的 LSTM 网络和 GRU 网络对文本语义进行捕捉和分类。Li 等学者<sup>[6]</sup>使用狄利克雷分布(LDA)的主题模型,调整并使用主题向量空间对短文本进行分类。Zhou 等学者<sup>[7]</sup>采用混合注意力网络,使用 RNN 和 CNN 进行文本特征提取并融合注意力机制对文本进行分类。陈亚茹等学者<sup>[8]</sup>对短文本词嵌入阶段加入噪声进行训练,提升模型特征提取效果,再使用 BiLSTM 网络结合注意力机制对短文本进行分类。

对于表情符号文本的处理,Mohank 等学者<sup>[9]</sup>使用带自注意力层的噪声正则化双向门控循环单元

(Bi-GRU)对含有表情符号和文字的文本信息进行分类。邱全磊等学者<sup>[10]</sup>通过构建情感词典对文字和颜文字的情感值进行累加。赵晓芳等学者<sup>[11]</sup>使用表情符号词典,将文本信息进行拼接,使用 CNN 和 LSTM 网络对文本进行分类。李楠等学者<sup>[12]</sup>提出表情稳定度的概念,基于概率统计计算表情符号在不同语境下的情感稳定性。龚路<sup>[13]</sup>使用 Word2Vec 的 Skip-gram 方法对表情符号进行词嵌入训练。以上模型能够对颜文字信息的特征进行提取,但是通过直接训练的方式得到的颜文字特征未考虑颜文字与文字、颜文字与数据集主题之间的相互影响。

## 2 多通道融合训练模型

为使模型能够区分结构性符号和普通文字,实现融合符号文本的情感分类,本文设计先构建结构性符号情感词典,再根据该词典对数据集中的文本进行特征分离处理再融合,并进一步将融合后的特征信息传入 BiSRU 网络中实现文本的情感分类,具体结构如图 1 所示。




图 1 模型结构图

Fig. 1 Model structure diagram

在文本特征的处理阶段,其基本思想是根据训练集数据训练出的情感词典,先对文本数据进行字符匹配,然后对普通文字和结构性符号文本进行拆分,将拆分后的数据分别传输到不同的通道中加以处理,同时进行特征融合,对融合后的特征采用自注意力机制提升特征提取的效果。

## 2.1 结构性符号特征工程

以颜文字符号为线索,颜文字等结构性符号与文字语法关联性不强,如果采用基于上下文的词嵌入训练的符号向量,会使训练的结果存在一定的局限性。因此本文使用多层训练的方式,以符号映射再训练缩放的方式,训练颜文字向量并构建结构化符号向量词典。

本文根据人体运动学模型<sup>[11]</sup>,将颜文字划分为如下9个部分,并按照该规则进行颜文字的匹配提取: {S1} {B1} {S2} {EL} {M} {ER} {S3} {B2} {S4},对颜文字中每一个字符进行唯一的ID编码的映射,由此可将颜文字映射为一个固定长度为9的向量。基于符号词典映射后,即可将获得的颜文字的固长符号向量传入神经网络中进行训练,为使得颜文字特征向量能够感知特征本身与样本之间的联系,以减少歧义与语义误差,因此计算当前颜文字的情感缩放系数,对向量进行缩放。颜文字特征训练结构如图2所示。




图2 颜文字特征训练结构图

Fig. 2 Structural diagram of face character training

将颜文字映射为9位标识向量后,使用全连接神经网络训练,获取颜文字特征向量表示,其计算过程计算公式如下所示:

$$A_1 = \text{ReLU}(W_1 D_n + b_1) \quad (1)$$

$$d = \text{Softmax}(W_2 A_1 + b_2) \quad (2)$$

$$\alpha = \frac{p}{p+n} + 0.5 \quad (3)$$

$$V = W_1 \times \alpha \quad (4)$$

其中,  $A_1$ 、 $A_2$  分别表示网络第一层与第二层输

出;  $W_1$ 、 $W_2$  分别表示网络第一层与第二层权重参数;  $b_1$ 、 $b_2$  分别表示网络第一层与第二层的偏置;  $d$  表示预测标签的分布。根据预测标签分布的效果,选择  $W_1$  作为待缩放的特征向量。研究可知,  $p$  表示颜文字在情感标签为积极的样本中所出现的次数;  $n$  表示颜文字在情感标签为消极的样本中所出现的次数;  $\alpha$  表示当前颜文字的情感缩放系数,由此得出代表颜文字本身的向量  $V$ 。

情感系数的计算,对于在积极样本出现次数更多的颜文字,其情感缩放因子会被映射到 1.0~1.5 之间,向量乘以该量后,会通过广播机制对向量整体数值进行放大,反之消极的颜文字的情感缩放因子会被映射到 0.5~1.0 之间,对向量数值具有缩小的作用,以此方式增强了颜文字向量,提升其对整个文本特征的感知能力。

颜文字在文本中出现的位置与数量也可能对文本情感的表示产生影响,在某些情况下表示不开心等反向情绪时会把表情符号放在前半部分,反之会放在文本后部;表情符号在一段文本中多次出现表示强调,可使原本所表达的情感更为强烈。颜文字位置与数量的特征表示采用索引记录与计数的方法,将二者组合为一个向量形成一组特征表示。由于短文本存在含有多个颜文字且颜文字不同的情况,针对该情况,本文采用选取文本中主颜文字的方法,根据文本的时间顺序提取主颜文字的信息,并作为短文本的主颜文字来代表整个文本的颜文字信息。颜文字位置与数量信息使用一个长度为3的向量表示,向量记录颜文字的起始索引以及出现次数,接下来使用此向量与颜文字词典映射向量进行拼接,得到完整的文本中颜文字的特征向量,其计算过程具体如下:

$$T = [S, E, C] \quad (5)$$

$$V_i = V \oplus T \quad (6)$$

其中,  $S$  表示颜文字的第一个字符在短文本的索引位置;  $E$  表示颜文字的最后一个字符在短文本中的索引位置;  $C$  表示颜文字在短文本中的出现次数,由这些信息共同组成颜文字的位置与数量信息特征向量  $T$ ;  $V$  表示上一层计算的颜文字向量;  $V_i$  表示该段文本的颜文字信息特征表示;“ $\oplus$ ”表示向量的拼接操作。

## 2.2 文本融合特征工程

在文字文本的特征提取方面,本文采用双向表征编码器 BERT 预训练模型来训练文本的特征向量, BERT 是谷歌在 2018 年提出的开源预训练模型<sup>[14]</sup>、是一种多层双向的编码器,同时也是

Transformer 结构中的 Encoder 部分。BERT 在对文本特征提取上表现优异,故本文将 BERT 作为模型文字文本向量的基础编码器。本文对 BERT 进行微调,输出的第一个 [CLS] 隐藏状态不作直接映射输出,而是在融合颜文字特征向量后输入到解码器中进行映射输出。

颜文字与文本融合特征向量的拼接算法公式见如下:

$$\mathbf{M}_i = \mathbf{V}_i \oplus \mathbf{W}_i \quad (7)$$

其中,  $\mathbf{M}_i$  表示第  $i$  段文本生成的融合向量;  $\mathbf{V}_i$  表示第  $i$  段文本的颜文字向量;  $\mathbf{W}_i$  表示第  $i$  段文本由 BERT 预训练模型所训练的文字文本向量表示。

为了挖掘特征向量内部不同位置信息之间的关联关系,在将向量进行拼接后,需要对特征向量进行优化,来提升特征向量的融合效果,基于此,本文在对颜文字与文字融合的向量中引入自注意力算法。

自注意力机制是注意力机制的一种特殊情况,其本质上是对输入的参数进行了加权平均的操作,使得短文本稀疏向量加强内部联系,以及使得不同部分能够感知结构性符号带来的影响。其计算过程可描述为:

$$s_{i,j} = \frac{\mathbf{q}_i \times \mathbf{k}_j}{\sqrt{d_k}} \quad (8)$$

$$\bar{s}_{i,j} = \frac{\exp(s_{i,j})}{\sum_j \exp(s_{i,j})} \quad (9)$$

$$\mathbf{z}_i = \sum_j \bar{s}_{i,j} \times \mathbf{v}_j \quad (10)$$

其中,  $\mathbf{q}_i$  表示文本中第  $i$  个词的 Query 向量;  $\mathbf{k}_j$  表示同一文本中第  $j$  个词的 Key 向量;  $d_k$  表示缩放因子,其值为  $k_j$  的维度;  $s_{i,j}$  表示  $\mathbf{q}_i$  与  $\mathbf{k}_j$  点积运算后并进行缩放的结果;  $\bar{s}_{i,j}$  为  $s_{i,j}$  经过 *Softmax* 函数映射后的结果;  $\mathbf{v}_j$  为同一文本中第  $j$  个词的 Value 向量。最终将  $\bar{s}_{i,j}$  与  $\mathbf{v}_j$  做点积运算并求和后,得到表达第  $i$  个词与同文本其他位置的词之间关系的向量  $\mathbf{z}_i$ ,再将  $\mathbf{z}_i$  与原文本特征向量进行拼接,得到融合自注意力机制的文本特征。

### 2.3 文本融合特征工程

情感分类模型是将特征输入到网络中进行训练,以得出适应的权重,使其能够对结果进行分类输出。循环神经网络(RNN)结构对序列数据具有良好的处理效果。在深度学习领域,RNN 常用于处理文本、语音等序列数据,但 RNN 存在梯度消失和梯度爆炸问题,为此通常对 RNN 单元进行调整与改进,比如常见的 LSTM 和 GRU 等<sup>[15]</sup>。

本文采用了前期研发提出的简单循环单元(SRU)。SRU 对比 LSTM 和 GRU 网络的优势在于,在保证一定准确率的前提下,实现了并行化运算,提升了训练效率。情感分类模型是将特征输入到循环神经网络中,再传入全连接网络中进行训练,训练出适应的权重能够对结果进行分类输出。本文基于双向的简单循环神经网络构建分类器,主要由简单神经元(SRU)构成,特征经由循环网络与全连接网络进行训练,将模型输出的结果传入 *Softmax* 函数中进行映射,得出分类结果。文本情感分类网络结构如图 3 所示。




图 3 情感分类网络结构图

Fig. 3 Affective categorization network structure diagram

其中,  $S_{q_1} \sim S_{q_n}$  分别表示不同时间部的序列输入,将其按照时间顺序输入到简单循环单元(SRU)中。简单循环单元(SRU)结构如图 4 所示。




图 4 简单循环单元结构图

Fig. 4 Structure diagram of simple cyclic unit

输入序列  $X_t (t = 1, 2, 3, \dots, T)$  先经过遗忘门,在通过遗忘门时计算隐藏状态  $C_t$ ,再继续计算得到隐藏层输出  $h_t$ 。SRU 计算过程可由如下公式来表示:

$$\bar{X}_t = \mathbf{W}X_t \quad (11)$$

$$\mathbf{f}_t = \tanh(\mathbf{W}_f X_t + \mathbf{b}_f) \quad (12)$$

$$\mathbf{r}_t = \tanh(\mathbf{W}_r X_t + \mathbf{b}_r) \quad (13)$$

$$C_t = f_t \otimes C_{t-1} + (1 - f_t) \otimes \bar{X}_t \quad (14)$$

$$h_t = r_t \otimes g(C_{t-1}) + (1 - r_t) \otimes \bar{X}_t \quad (15)$$

其中,  $W, W_f, W_r$  分别表示参数矩阵;  $b_f, b_r$  分别表示网络中的偏置值。由此进行循环训练, 得到输出与隐藏层输出  $C_t$  和  $h_t$ 。双向简单循环单元 (BiSRU) 是由 2 层 SRU 堆叠而成, 2 层 SRU 从不同方向对序列特征进行计算, 达到贯穿序列文本的上下文语义的效果, 再将双向拼接的隐藏层向量输入到全连接网络中进行分类训练得到分类结果。其计算过程的数学公式可写为:

$$H_t = \vec{h}_t \oplus \overleftarrow{h}_t \quad (16)$$

$$L = \text{Softmax}(W_t H_t + b_r) \quad (17)$$

其中,  $\vec{h}_t$  表示 SRU 网络正向输出结果,  $\overleftarrow{h}_t$  表示反向输出结果。对 2 个方向的时间输出结果进行拼接, 得到当前时间的输出向量  $H_t$ 。L 为预测输出的标签分布概率, 取其中最大值为当前样本的预测标签。

### 3 仿真结果实验

实验部分基于 Pytorch 框架开发, 开发工具为 Jupyter notebook, 开发语言为 Python, 使用 CPU 运行程序。

为验证模型对短文本分类的综合处理能力, 实验数据集为含颜文字的 B 站弹幕数据集, 旨在验证模型对颜文字与文字文本情感分类效果。其中, 训练集包含积极情感句子 8 600 个, 消极句子 8 300 个, 测试集有 4 111 条语料。样本内容示例见表 1。

表 1 样本示例表

Table 1 Sample example table

序号	内容	标签
1	还是可以的	1
2	是要跟男性推理小说家叫板吗? \ ( / _ \ ) /	0
3	(→_→) 请注意你的言语	0
4	等哈尔滨开店了, 你就有口福了^▽^	1

在样本示例表 1 中, 序号 1 的样本可体现模型在对无颜文字符号的文本进行情感分类时的效果; 序号 2 的样本可体现模型在对颜文字靠近文本中部时的情感分类效果; 序号 3 与序号 4 的样本体现模型在颜文字处于文本前、后时的情感分类效果。

由于样本的不平衡可能导致模型的泛化性能下降, 因此, 本文在训练分类器时会尽量确保不同位置的颜文字与不同情感标签的样本的平衡性。

为验证分类模型的有效性, 本文采用精准率 (Precision)、召回率 (Recall) 和 F1 作为模型的评价标准。其计算过程具体如下:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (18)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (19)$$

$$F1 = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (20)$$

其中, TP 表示样本为正向情感且预测为正向情感样本数; FP 表示样本为负向情感且预测为正向情感; FN 表示样本为正向情感且预测为负向情感的样本数。

在本次测试中, 采用随机抽样的方法, 将数据集 70% 的样本作为训练集, 30% 的样本作为测试集, 测试集在不同模型的测试结果见表 2。

表 2 对比实验结果表

Table 2 Comparative experimental results table

序号	模型	Precision/%	Recall/%	F1/%
1	BERT (baseline)	82.1	79.0	80.5
2	BERT-BiRNN	81.0	79.6	80.2
3	BERT-BiGRU	83.0	87.9	85.3
4	BERT-BiLSTM	87.7	86.6	87.1
5	Word2Vec(颜文字)-BERT-BiLSTM	88.9	86.5	87.5
6	本文模型	89.2	88.1	88.6

表 2 中, 序号 1 模型, 将 BERT 预训练模型的输出结果输出到 Softmax 函数中, 直接获得分类结果; 序号 2 模型通过 Word2Vec 训练出文本词嵌入向量后, 将其输入到 BiLSTM 网络中; 序号 3 模型在 BERT 训练文本向量后, 将其输入到 BiGRU 网络中; 序号 4 模型使用 BERT 训练文本向量, 将其输入到 BiLSTM 网络中; 序号 5 使用词嵌入的方法训练颜文字向量并构建颜文字向量词典; 序号 6 为本文所使用模型。

由表 2 可知, 本文模型含颜文字的数据集中具有更好的效果, 与序号 1、序号 2、序号 3、序号 4 和序号 5 的模型相比, 精确率分别提高 8.6%、10.1%、7.4%、1.7% 与 0.3%; 召回率分别提高 11.5%、9.6%、0.2%、1.7% 与 1.8%; F1 值分别提升 10.6%、10.4%、3.8%、1.7% 与 1.1%。SRU 自身可实现并行化运算, 在训练速度上较 LSTM 与 GRU 有一定的提升, 将分类模型的循环单元网络替换为不同的网络进行对比, 其训练速度对比结果如图 5 所示。




图 5 训练时长对比图

Fig. 5 Comparison chart of training duration

在对模型的单元网络进行替换后,分析可知在本实验环境下以及当前数据集中,使用 SRU 进行训练,每轮所消耗时间在整体上都小于 LSTM 与 GRU。

## 4 结束语

本文提出了一种新的多通道处理方式,能够更全面地感知混合符号与文字的文本信息,实现更准确的情感分类。该方法通过符号向量词典的预构建、MLP 和统计缩放的形式对结构性符号信息进行处理,并使用 BERT 预训练模型处理普通文字,最终使用自注意力机制进行特征融合,大幅提升了模型的性能。

本文通过仿真对比实验,充分证明了该模型的有效性。相较于其他常见的文本分类模型,该模型在融合颜文字符号的情感分类任务中取得了更好的效果,这一发现有助于更好地挖掘社交网络中隐藏的情感信息。

随着社交网络的不断发展,混合符号与文字的文本信息将会频繁出现。该方法为处理这类文本信息提供了一种有效的方式,可应用于电商评论、在线游戏聊天室、营销直播弹幕分析、信息推荐等领域,同时可以结合其他领域的知识和技术,如图像处理和声音识别等,探索更加全面和深入的情感分类方法,提高情感分类的准确度和可信度。

## 参考文献

- [1] LIU S, WANG G, LI Y, et al. A review of Chinese short text classification techniques [J]. Journal of Information Engineering University, 2021, 22(3): 304-312.
- [2] JIA Pengtao. A survey of text classification based on deep learning [J]. Computer and Modernization, 2021(7): 29-37.
- [3] 张明书, 葛晓义, 魏彬. 基于情感特征和谣言种类的谣言检测 [J]. 计算机仿真, 2023, 40(6): 21-25, 60.
- [4] BAO Tong, REN Ni, LUO Ruiwang, et al. A BERT-based hybrid short text classification model incorporating CNN and Attention-Based BiGRU [J]. Journal of Organizational and End User Computing, 2021, 33(6): 1485-1505.
- [5] YU Shujuan, LIU Danlei, ZHU Wenfeng, et al. Attention-based LSTM, GRU and CNN for short text classification [J]. Journal of Intelligent & Fuzzy Systems, 2020, 39(1): 1-8.
- [6] LI Yangyang, LIU Bo. A new vector representation of short texts for classification [J]. The International Arab Journal of Information Technology, 2020, 17(2): 241-249.
- [7] ZHOU Yujun, XU Jiaming, CAO Jie, et al. Hybrid attention networks for Chinese short text classification [J]. Computación y Sistemas, 2018, 21(4): 759-769.
- [8] 陈亚茹, 陈世平. 融合自注意力机制和 BiGRU 网络的微博情感分析模型 [J]. 小型微型计算机系统, 2020, 41(8): 1590-1595.
- [9] MOHANK A V, NANDAKUMAR A N. Noise-regularized bidirectional gated recurrent unit with self-attention layer for text and emoticon classification [J]. International Journal of E-Collaboration, 2022, 18(1): 102-123.
- [10] 邱全磊, 崔宗敏, 喻静. 基于表情和语气的情感词典用于弹幕情感分析 [J]. 计算机技术与发展, 2020, 30(8): 178-182.
- [11] 赵晓芳, 金志刚. 融合表情符号与短文本的微博多维情感分类 [J]. 哈尔滨工业大学学报, 2020, 52(5): 113-120.
- [12] 李楠, 张羽卉. 融合表情符号动态特征的舆情分析研究 [J]. 现代情报, 2021, 41(8): 98-108.
- [13] 龚路. 融合表情符号的中文短文本情感分析研究 [D]. 重庆: 重庆大学, 2021.
- [14] SATAPATHY R, PARDESHI S, CAMBRIA E. Polarity and subjectivity detection with multitask learning and BERT embedding [J]. Future Internet, 2022, 14(7): 191-200.
- [15] 刘建伟, 宋志妍. 循环神经网络研究综述 [J]. 控制与决策, 2022, 37(11): 2753-2768.