

融合表情符号图像特征学习的微博情感分类

陈 黎¹, 刘雨欣², 周耘立¹, 吴妍秀¹, 于中华¹

(1. 四川大学计算机学院, 成都 610065; 2. 四川大学软件学院, 成都 610065)

摘 要: 表情符号作为一种新兴的网络图形化语言, 由于能够直观地表达用户的情感和态度, 因此在社交平台被广泛使用. 现有的利用表情符号进行微博情感分类的研究主要考虑表情符号的文本特征, 这样的做法不能很好的捕捉表情符号之间更细粒度的联系, 并无法适应表情的不断发展与变化. 针对现有研究存在的问题, 本文提出了一种基于卷积自编码器的表情图像特征学习的微博情感分类模型. 该模型通过卷积自编码器捕捉的表情符号的图像特征, 然后将图像的嵌入表达融入到微博的文本特征中, 再利用多层感知机进行情感分类. 该模型分别在中文和英文微博的数据集上和现有的方法进行了对比, 实验证明, 本文的方法优于现有的方法, 并且在新表情和跨语言环境下的泛化能力更强.

关键词: 表情符号; 情感分类; 卷积自编码; 微博

中图分类号: TP391 **文献标识码:** A **DOI:** 10.19907/j.0490-6756.2021.012005

Incorporating image features of emoticons into microblog sentiment classification

CHEN Li¹, LIU Yu-Xin², ZHOU Yun-Li¹, WU Yan-Xiu¹, YU Zhong-Hua¹

(1. College of Computer Science, Sichuan University, Chengdu 610065, China;

2. College of Software, Sichuan University, Chengdu 610065, China)

Abstract: Emoticon, as an emerging network graphic language, is widely used on the social platform due to its ability to express the sentiment and attitude of users intuitively. The current studies take emoticons as text features so that they can neither capture more fine-grained correlations between emoticons, nor can they adapt to the development and change of emoticons. In order to overcome the above difficulties, we propose an emoticon-image-feature learning method based on Convolutional Auto Encoder (CAE) for microblog sentiment classification. Our model can learn image features of emoticons by CAE automatically, and such features are incorporated into the embedding representations of microblogs for sentiment classification. We verify the effectiveness of our proposed model on Chinese microblog and twitter datasets, respectively. The experimental results demonstrate that our model outperforms the state-of-art methods, and the image features learned by our proposed model have stronger generalization ability even with new emoticons in cross-language environment.

Keywords: Emoticon; Sentiment classification; Convolutional auto encoder; Microblog

收稿日期: 2020-07-12

基金项目: 四川省重点研发项目(2019YFG0521)

作者简介: 陈黎(1977-), 女, 讲师, 研究方向为自然语言处理.

通讯作者: 刘雨欣. E-mail: 583946482@qq.com

1 引言

随着移动互联网的普及与发展,微博逐渐成为人们分享观点和表达情感的主要平台,其内容有传播范围广、更新速度快、话题聚集度高等特点。近年来,微博平台在各类公共事件中起到越来越大的影响,微博的情感分析对于舆情的监控有着重要的研究意义。与传统新闻、博客相比,微博内容短小,语言不规范,并且混合了多种非文字类信息,给情感分类任务带来了巨大的挑战^[1]。

在微博的非文字类信息中,表情符号已成为其重要的组成部分,同时也是分析社交媒体情感的重要特征之一。例如:“跑了十公里😊”,用户使用表情“😊”来增强感染力并表达了喜悦这一积极的情感。现有的研究已经认识到微博的表情符号对情感是有重要的预示作用,因此,文献^[2]定义表情符号的情感类型,并通过表情作为远距离监督信号,自动标注 Twitter 的情感类别,以此来构建情感分类数据集。

在微博文本中,每个表情符号都有对应的文本标签,如表情😊对应[馋嘴]。现有利用表情符号作为特征进行微博情感分类的研究中,主要将表情看成是普通词,将表情对应的文本标签^[3]或者表情的情感信息^[4-5]融入到微博的特征表达中,再利用机器学习方法进行微博的情感识别。

然而,现有的研究主要是利用表情的文本标签,将不同的表情看成是普通词,这样的做法无论是使用词袋模型还是词向量都只能表示表情的离散信息,而无法表达表情图像中更细粒度的连续信息。表情作为一种象形符号,其表达情感的方式是跨文化、跨语言的,比如👍和👏就不存在“好”和“good”的交流壁垒。一些表情符号虽然表示不同的情感,但是它们的上下文非常相似,例如:😋(馋嘴)和🤢(恶心)都和食物有关,但是表达的情感却不同。如果基于前后文来学习表情的嵌入表达,可能学习到的词向量是相似的。而从图像上来看,这两个表情是存在明显的差异,而作为图形化的语言,表情的图像包含了比文字更加丰富,更细粒度的特征信息。此外,表情符号作为一种网络语言,随着时间的变化,新表情不断出现,这将对现有的表情符号的使用产生很大的影响,旧表情的使用比例将会下降。而现有的研究只能将新表情作为未登录词来处理,不能适应表情符号的不断变化和

发展。

就我们所知,现有的研究工作还未将表情作为图像融入到微博的情感分类中,因此,为了解决现有研究存在的问题,本文提出了一种融合表情图像特征来实现微博情感分类的方法。首先,通过卷积自编码器自动学习表情符号的图像特征,再利用深度模型将图像特征以及微博的文本特征结合起来,进行情感分类。

2 相关工作

情感分析(Sentiment Analysis, SA)是对带有感情色彩的主观性文本进行分析、处理、归纳和推理的过程^[5]。微博内容主题涉及面广,其中包含大量有价值的用户情感信息,对其进行情感分析具有广阔的应用前景,例如股票预测^[6]、话题检测^[7]和疫情分析^[8]等。相比于传统的新闻、博客、评论,微博文本内容短小包含大量的表情符号和网络词汇,同时具有稀疏性、实时性和不规范性等特点,形成一种特有的语言风格。表情符号作为一种新兴的网络图形化语言,在微博上深受用户青睐,直观形象的表情符号在很大程度上反映了用户的情感。文献^[2]认识到表情符号对情感分类是有重要的预示作用,而手工标注语料耗时耗力,因此首次将表情符号作为远监督信号,自动标注微博数据的情感标签。

在微博情感分类研究中,表情符号主要是应用在如下两方面:(1)是利用表情符号的情感极性作为监督信号,通过远距离方法构建语料集^[2,9-12];(2)是将表情符号作为特征和微博的文本信息联合进行情感分类^[4-5,13-16]。

在将表情符号作为分类特征的研究中,主要是利用表情的文本标签,将每个表情看成是普通词,然后利用不同的特征表示方法得到表情的特征表达。文献^[4]提出一种情感语义增强的多通道卷积神经网络,把表情符号看作情感词,使用表情符号的词向量来增强情感语义。文献^[5]根据表情符号的感情类别和强度构建了表情词典,提出了一种级联式的情感分类模型。文献^[6]提出了一种基于双重注意力模型的微博情感分析方法,将表情作为一种情感符号和其他情感词组合,使用 word2vec 训练得出词向量。而文献^[13]借助词向量技术为常用的表情符号构建了情感空间的特征表示矩阵,并将矩阵和文本的词向量进行乘积实现词义到情感空间的映射,再输入多通道的卷积神经网络。文献

[14-15]都利用了文献[13]所提出的 emoji2word 将表情转换为表情嵌入,再结合文本信息进行情感分类. 其中,文献[15]不仅考虑了表情,还考虑了微博中出现的颜文字,将颜文字的嵌入、表情的嵌入和词嵌入共同作为微博的表达,使用基于上下文的双向长短记忆网络进行微博的情感预测. 文献[16]收集并处理了一个由 2 000 万条包含有表情符号的 tweet,通过研究各表情之间以及表情与词汇之间的共现关系,生成了具有可解释性的单词嵌入,并用于预测文本的情感强度.

现有的研究只是将表情符号看成是普通词,利用词的语义信息或者表情的情感信息,将这些特征融入到微博的特征表达中,这样的做法不能很好地捕捉表情图像中包含的更细粒度的表情之间的联系. 同时,现有研究通过语料学习的表情嵌入表达都不能适应表情符号的不断发展与变化,当新表情出现以后必须更新词典以及重新训练表情的嵌入表达.

为此,本文提出了一种将表情的图像特征和微博的文本信息融合来增加微博情感分类的效果. 模型利用卷积自编码器自动提取表情特征,这种无监督的方法不需要标注数据能够很好地适应表情的发展变化.

3 融合表情图像的微博情感分类模型

为了更好地捕捉表情之间的细粒度联系以及适应表情符号的发展变化,本文提出了一种基于表情图像进行微博情感分类的模型,模型框架如图 1 所示.

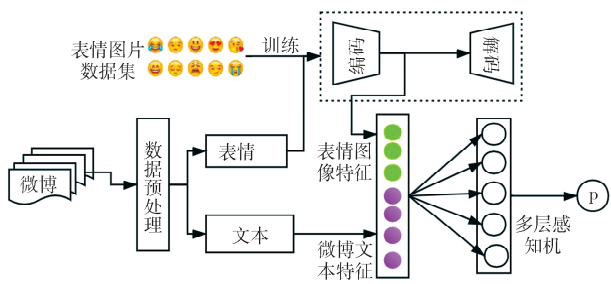


图 1 基于表情图像的微博情感分类框架
Fig. 1 The framework of Microblog sentiment classification based on emoticon image features

给定一个微博 W , W 可能包含表情图像,也可能没有包含表情图像. 通过数据预处理模块,去除微博中的噪声(如超链接、用户名等). 如果微博

中包含表情图像,则将微博中的表情图片送入到已经训练的自编码器,得到表情的特征向量 $E \in \mathbb{R}^{d^p}$, 其中, d^p 为表情特征向量的维数. 如果微博中未包含表情图标,则表情向量 E 的各维为 0. 将微博的文本 $W = \{w_1, w_2, \dots, w_n\}$, 由 n 个词对应的词向量构成,将每个词的词向量取平均,得到微博文本的特征向量 $T_T \in \mathbb{R}^{d^w}$, d^w 为词向量的维数. 包含有表情符号的微博特征表达由文本特征向量和表情特征向量拼接而成,如式(1)所示.

$$T_W = [E; T_T] \tag{1}$$

其中, $T_W \in \mathbb{R}^{d^{p+w}}$. 将 T_W 喂入到一个全连接层进行非线性变化,如式(2)所示.

$$W_q = \text{ReLU}(W_{i1} T_W + b_{i1}) \tag{2}$$

其中, W_{i1} 和 b_{i1} 表示第 i 个全连接层的参数. 最后通过 sigmoid 函数得到微博的情感类别概率,如式(3)所示.

$$p = \text{sigmoid}(W_1 W_q + b_1) \tag{3}$$

其中, W_q 为全连接的输出; W_1 和 b_1 为输出层的参数. 分类模型的目标优化函数 L 使用交叉熵损失,如式(4)所示.

$$L = -\sum y \lg(p) + (1-y) \lg(1-p) + \lambda \|\bar{\omega}\|_2 \tag{4}$$

其中, $y \in \{0, 1\}$ 是微博的情感标签,若 y 取值为 1,表示微博为正向情感; y 为 0,表示负向情感; $\bar{\omega}$ 表示模型中所有的参数的集合.

4 基于卷积自编码器的表情图像特征学习

卷积神经网络在图像特征学习方面具有很大优势,但是通常需要大量标注数据进行模型的学习^[17]. 自编码器是一种无监督的深度神经网络学习算法,它将输入的信息通过编码器编码成低维信息,再利用解码器输出能够实现对输入数据的复现^[18]. 变分自编码器(VAE)是目前应用非常广泛的一种模型,它能够学习隐编码空间与数据生成空间的特征映射,是无监督学习的重要工具,在图像生成的多样性方面取得了进步^[19]. 然而本文的目的是通过自编码器捕捉表情图像的特征,而不是生成多样性的表情,因此 VAE 不适用于本文的工作,我们选择一般的自编码器来捕获表情图像的特征信息.

为了适应表情图像的不断变化发展,减少人工标注的工作量,本文提出了基于卷积自编码器的表情图像特征学习模型(Convolutional Auto En-

coder, CAE),对表情图像进行特征编码和解码,模型结构如图 2 所示.卷积自编码主要包含卷积编码和反卷积解码两个部分,其中卷积编码的作用是对标签图像进行特征编码,通过非线性的变换将图片转变成更为高层次的,更加抽象的表达,并且在

隐藏层得到表情图片定长的连续的稠密向量.反卷积解码部分从隐藏层的低维表示逐层地进行解码重构,最后在输出层输出重构之后的数据.如果卷积编码学习到有效的特征表示,那么通过反卷积解码之后能够得到与原始数据尽可能相似的表达.

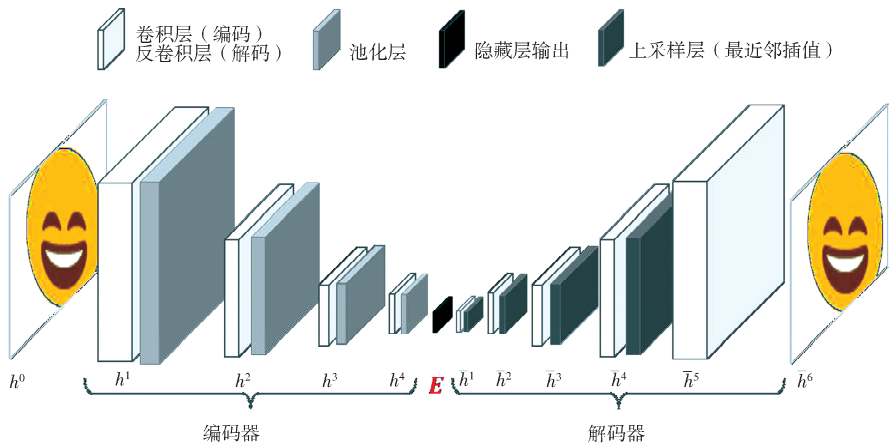


图 2 基于卷积自编码器的标签图像特征学习
Fig. 2 Emoticon image feature learning based on convolutional auto encoder

从图 2 可知,编码器包括 4 个卷积层和相应的 4 个池化层,解码器由 5 个反卷积层和相应的 4 个上采样层构成.模型利用重构数据和原始数据进行无监督的特征学习,优化目标就是最小化原始数据和输出数据的重构误差.

4.1 编码器

编码器包含四个卷积层以及对应的池化层.其输入是 $32\times32\times3$ 的 png 格式表情图像,编码器四个卷积层的参数如表 1 所示.

表 1 编码器的参数
Tab. 1 Parameters of the encoder

层名	卷积核大小	步长	卷积核个数
h^1	3×3	1	16
h^2	3×3	1	8
h^3	3×3	1	8
h^4	3×3	1	8

卷积层是用于提取图像的局部特征,每个卷积层的神经元通过一组权值给连接到了上一层的局部区域,然后将其局部加权和传递给一个非线性函数,获得卷积层中每个神经元的输出.

池化层起到二次提取特征的作用,它紧挨着卷积层,是将卷积层作为其输入,它的每个神经元对局部区域进行池化操作.文本最大池化选择局部区域中的最大点.下采样的池化窗口为 2×2 .

最后编码器输出为 8 个 2×2 的特征图,得到

了 32 维的表情图像的特征向量 E .

4.2 解码器

解码器包含了 5 个反卷积层和 4 个池化层,解码器各层参数如表 2 所示.

表 2 解码器的参数
Tab. 2 Parameters of the decoder

层名	卷积核大小	步长	卷积核个数
\bar{h}^1	3×3	1	8
\bar{h}^2	3×3	1	8
\bar{h}^3	3×3	1	8
\bar{h}^4	3×3	1	16
\bar{h}^5	3×3	1	3

CAE 是一个具有对称结构的卷积网络,在卷积解码过程中需要进行反卷积.在卷积编码过程中所产生的低维编码特征,将被用作卷积解码过程的输入,以便从该编码表示的信息中重建原始输入数据.每次反卷积操作后使用最近邻插值算法进行上采样.上采样层对上一层的输出的局部特征值进行重复采样,并作为当前层的局部特征值,其窗口大小为 2×2 .通过卷积层和上采样层不断地操作之后可以重构出与原始数据相同的维度.最后解码器的输出为 $32\times32\times3$ 的三通道 png 格式图片.

4.3 训练过程

卷积自编码是一种特殊的自编码器,编码器将

原始表示编码成隐藏层表示,编码器将隐藏层表示解码重构成原始表达,训练目标是 최소화 输出的重构误差,自编码器的目的是为了捕捉输入数据最有代表性的特征表示.

卷积编码过程对应于输入层到隐藏层,从 h^{k-1} 层到 h^k 层的特征图 h^k 如式(5)所示.

$$h^k = \text{ReLU}(h^{k-1} * W^k + b^k)$$

(5)

其中, W^k 和 b^k 表示该卷积层第 k 层卷积核的参数矩阵和偏置; h^k 表示上一层结构的输出; $*$ 表示卷积运算.CAE的输入为 h^0 即为原始的表情图像.

反卷积解码过程从隐藏层 \bar{h}^k 到 \bar{h}^{k+1} 的特征图 \bar{h}^{k+1} ,如式(6)所示.

$$\bar{h}^{k+1} = g(\bar{h}^k * \hat{W}^{k+1} + c)$$

(6)

其中, \hat{W}^{k+1} 表示反卷积参数矩阵; c 表示偏置参数.第一至四个反卷积层使用 ReLU 为激活函数,第五个反卷积层使用 Sigmoid 激活函数.对数据进行重构的输出为 \bar{h}^6 ,计算 h^0 与 \bar{h}^6 的重构误差为训练的优化目标.本文选取交叉熵(cross entropy)函数作为损失函数,如式(7)所示.

$$J = -\sum_{i=1}^m h_i^0 \log(\bar{h}_i^6) + (1 - h_i^0) \log(1 - \bar{h}_i^6)$$

(7)

其中, h_i^0 表示第 i 个表情原始图像; \bar{h}_i^6 表示第 i 个表情图像的重构图像; m 表示训练集中样例个数.

5 实验与结果

5.1 实验数据

本文的实验数据包括了表情数据集以及中、英文微博数据集.

5.1.1 表情数据集 本文中的 CAE 使用的数据来自 Unicode 表情符号图表 V13.0. 该数据集包含来自 Facebook、Twitter 等多个平台的表情图标.实验排除了中性含义的图标(如动物、水果等),选取了具有情感表达意义的 873 个表情符号(包括脸部表情,手势等)用于训练,表情实例如图 3 所示.




图 3 表情数据示例

Fig. 3 The emoticon examples

5.1.2 中文微博数据集 从网络收集了 101 577

条带有情感倾向的微博,其中负例 50 829 条,正例 50 748 条.对收集的数据中的表情使用情况进行统计,其中 70% 微博中只使用了一种表情,10% 微博中不含表情,其余的使用了多种表情.在实验过程中,使用留出法将数据按 7 : 3 分为训练集和测试集,分别为 71 103 条和 30 474 条,其中选取训练集数据的 10% 作为验证集.

5.1.3 英文 Twitter 数据集 英文 twitter 数据集来自从网络收集的 13 922 条带有情感倾向的微博,其中消极分类 6 991 条,积极分类 6 931 条.在实验过程中,使用留出法将数据按 7 : 3 分为训练集和测试集,分别为 9 745 条和 4177 条.训练模型时,选取训练集数据的 10% 作为验证集.

我们对中英文数据集中表情图像在微博中的分布进行了统计,结果如表 3 所示.

表 3 表情数据在两个数据集的分布
Tab. 3 The distribution of emoticons in two datasets

表情个数	中文微博数据集		Twitter 数据集	
	正例	负例	正例	负例
0 个	5 190	5 015	1 079	1 520
1 个	37 334	40 936	4 878	5 130
多个	8 224	4 878	974	341
总计	50 748	50 829	6 931	6 991
	101 577		13 922	

5.2 实现细节

本文使用 gensim 库训练 word2vec 词嵌入模型,词向量的维度 $k=300$. 当一个词在整个数据集的出现次数小于 5 则被舍弃.每条微博所有词向量的加权平均值作为微博文本特征向量 T_T .

如果微博中不包含任何表情符号,则将表情的特征向量为 0;如果微博中包含多个表情符号,则表情图像的特征向量为多个图像向量的平均值.模型中的超参数如表 4 所示.

表 4 超参数设置
Tab. 4 The hyperparameters setting

超参数描述	超参数值
CAE 优化器	Adagrad
CAE 学习率 η	0.01
CAE 的 batch_size	16
2 层隐藏层隐藏单元个数	(200,100)
MLP 优化器	adam
MLP 学习率	0.001
L_2 正则化项参数	1e-4
优化的容忍误差	1e-5

5.3 实验模型

使用如下的模型进行了实验对比如下.

(1) No-Emo:去除微博中的表情符号,只使用微博的文本信息进行情感预测,通过词向量得到微博的文本表达,再通过多层感知机进行情感预测.

(2) Emoji2vec:基于 Eisner^[13] 提出的 emoji2vec 模型,将表情符号的描述语句转化为词向量,与文本向量融合. 本文的表情符号使用 Eisner 得出的预训练结果(<https://github.com/uclnlp/emoji2vec>).

(3) Emo-As-Word:将表情作为普通词,将表情符号对应的文本标签的词向量作为表情的特征向量和微博文本向量进行情感预测.

(4) CAE-Emo:本文的方法,将表情的图像特征融入到微博的特征学习中,进行情感分类.

5.4 结果分析

在实验中,我们使用精确率(Precision)、召回率(Recall)和 F 值作为评估指标,来度量不同模型的性能. 我们分别在中文微博和英文 Twitter 语料上实验了 5.3 节的 4 个模型,实验结果如表 5 和表 6 所示.

表 5 在中文微博数据集的实验对比结果

Tab. 5 Comparison results in Chinese microblog dataset

模型	$P/\%$	$R/\%$	$F/\%$
No-Emo	75.53	69.47	72.37
Emoji2vec	75.46	77.62	76.53
Emo-As-Word	95.22	90.87	93.00
CAE-Emo(ours)	94.84	94.06	94.45

从表 5 可知,Emoji2vec 模型的性能优于 No-Emo,说明表情符号在情感的分类中是有重要预示作用. 而 Emoji2vec 相比 Emo-As-Word 和 CAE-Emo 性能差很多,因为我们使用了 Eisner 预训练的表情向量,而且这些表情的向量是基于英文得到的,所以在中文语料中的性能比较差. Emo-As-Word 和 CAE-Emo 相比前两个模型性能显著提高,并且 P 、 R 和 F 都达到 90% 以上. 而在 R 和 F 上,CAE-Emo 模型的性能显著高于 Emo-As-Word. Emo-As-Word 对于未登录词不能很好处理,而我们的 CAE 是一种无监督方法学习图像特征,出现的新表情不会作为未登录词.

为了进一步验证我们模型的有效性,我们将四个模型分别在英文 Twitter 语料上进行了实验,结果如表 6 所示.

表 6 在 Twitter 数据集的实验对比结果

Tab. 6 Comparison results in Twitter dataset

模型	$P/\%$	$R/\%$	$F/\%$
No-Emo	73.72	68.66	71.10
Emoji2vec	83.08	81.62	82.34
Emo-As-Word	80.59	79.64	80.11
CAE-Emo(ours)	84.74	85.70	85.22

从表 6 可以看出,Emoji2vec 的性能相比中文微博数据集显著提高,可以达到 82.34% 的 F 值,同时也可以看出 Emoji2vec 模型是基于表情的英文描述训练得出的,在其他语言环境下的泛用性较差. 在英文环境下,CAE-Emo 的性能高于 Emoji2vec,验证了我们提出的模型在跨平台和跨语言的情况下,依然能够提高微博的情感分类,具有很好的泛化能力. 图 4 是 4 个模型在不同的迭代次数的准确率和损失情况.

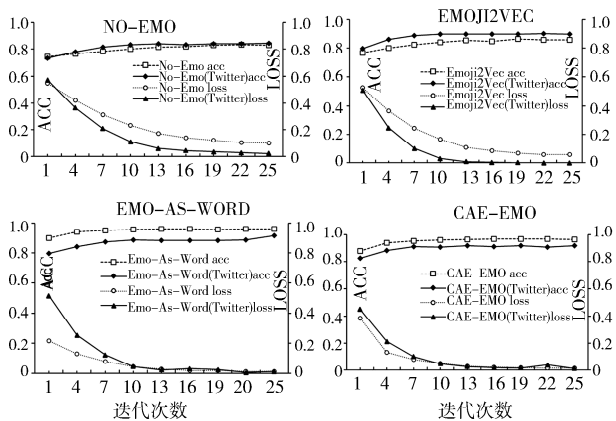


图 4 模型在两个数据集下的准确率以及损失
Fig. 4 The accuracies and losses of four models

从图 4 中可以看到,随着迭代次数的增加,损失在下降并趋于稳定,而准确率在不断上升也趋于稳定,说明模型在迭代 25 次时,4 个模型处于收敛状态,各种的性能都达到最好.

6 结 论

本文提出了一种基于卷积自编码的融合表情的图像特征的微博情感分类方法. 通过 CAE 网络对表情图像进行特征学习,再将图像的特征与微博文本的特征向量融合,进行微博的情感预测. 模型在不同的数据集上与现有的方法进行了对比,实验结果证明,表情的图像特征能够更好地捕捉表情之间更细粒度的关联信息,同时能够更好地适应表情符号的发展变化,提高微博的情感分类性能.

参考文献:

- [1] 庄传志, 靳小龙, 朱伟建, 等. 基于深度学习的关系抽取研究综述[J]. 中文信息学报, 2019, 33: 1.
- [2] Go A, Bhayani R, Huang L. Twitter sentiment classification using distant supervision: CS224N project report [R]. Stanford: [s. n.], 2009.
- [3] 谭皓, 邓树文, 钱涛, 等. 基于表情符注意力机制的微博情感分析模型[J]. 计算机应用研究, 2019, 36: 2647.
- [4] 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, 40: 773.
- [5] 张仰森, 孙旷怡, 杜翠兰, 等. 一种级联式微博情感分类器的构建方法[J]. 中文信息学报, 2017, 31: 178.
- [6] 张仰森, 郑佳, 黄改娟, 等. 基于双重注意力模型的微博情感分析方法[J]. 清华大学学报: 自然科学版, 2018, 58: 122.
- [7] 赵妍妍, 秦兵, 刘挺. 文本情感分析[J]. 软件学报, 2010, 21: 1834.
- [8] Ruan Y, Durrezi A, Alfantoukh L. Using Twitter trust network for stock market analysis[J]. Knowl-Based Syst, 2018, 145: 207.
- [9] Davidov D, Tsur O, Rappoport A. Enhanced sentiment learning using twitter hashtags and smileys [C]//Proceedings of the 23rd International Conference on Computational Linguistics: Posters. Beijing: Association for Computational Linguistics, 2010.
- [10] 张珊, 于留宝, 胡长军. 基于表情图片与情感词的中文微博情感分析[J]. 计算机科学, 2012, 39(S3): 146.
- [11] Jiang F, Liu Y Q, Luan H B, *et al.* Microblog sentiment analysis with emoticon space model[J]. J Comput Sci Tech-Ch, 2015, 30: 1120.
- [12] 王伟, 周咏梅, 阳爱民, 等. 基于种子词的微博表情符情感倾向判定方法[J]. 数据采集与处理, 2017, 32: 198.
- [13] Eisner B, Rocktäschel T, Augenstein I, *et al.* Emoji2vec: Learning emoji representations from their description [C]//Proceedings of the Fourth International Workshop on Natural Language Processing for Social Media. Texas, USA: Association for Computational Linguistics: Austin, 2016.
- [14] Subramanian J, Sridharan V, Shu K, *et al.* Exploiting emojis for sarcasm detection [C] // Proceedings of the International Conference on Social Computing, Behavioral-Cultural Modeling and Prediction and Behavior Representation in Modeling and Simulation. Washington: Springer, 2019.
- [15] 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: 113.
- [16] Shueb A A M, Raji S, De Melo G. Emotag - towards an emotion-based analysis of emojis [C]//Proceedings of the International Conference on Recent Advances in Natural Language Processing (RANLP 2019). Bulgaria: Incoma Ltd., 2019.
- [17] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40: 1229.
- [18] 贾文娟, 张煜东. 自编码器理论与方法综述[J]. 计算机系统应用, 2018, 27: 1.
- [19] 翟正利, 梁振明, 周炜, 等. 变分自编码器模型综述[J]. 计算机工程与应用, 2019, 55: 6.

引用本文格式:

中 文: 陈黎, 刘雨欣, 周耘立, 等. 融合表情符号图像特征学习的微博情感分类[J]. 四川大学学报: 自然科学版, 2021, 58: 012005.

英 文: Chen L, Liu Y X, Zhou Y L, *et al.* Incorporating image features of emoticons into microblog sentiment classification [J]. J Sichuan Univ: Nat Sci Ed, 2021, 58: 012005.