

基于情感分布的 emoji 嵌入式表示

曾雪强, 孙雨, 刘烨, 万中英*, 左家莉, 王明文

(江西师范大学计算机信息工程学院, 江西 南昌 330022)

摘要:提出了一种基于情感分布的 emoji 嵌入式表示方法(emoji embedded representation based on emotion distribution, EDEER)。EDEER 方法采用基于 BERT 的情绪预测模型软标签,从真实数据中学习 emoji 嵌入式表示,通过情感分布直接建模 emoji 在各种情绪上的表达程度,使嵌入式表示中包含 emoji 的多种情感信息。在包含 emoji 的中文微博数据集上的多组对比实验表明,本文提出的方法可以有效地学习到与细粒度情绪直接关联的 emoji 嵌入式表示,构建具有较高情绪表达质量的 emoji 表示空间。

关键词: emoji; 情绪分析; 嵌入式表示; 情感分布

中图分类号: TP391 **文献标志码:** A

引用格式: 曾雪强, 孙雨, 刘烨, 等. 基于情感分布的 emoji 嵌入式表示[J]. 山东大学学报(理学版), 2024, 59(3): 81-94.

Emoji embedded representation based on emotion distribution

ZENG Xueqiang, SUN Yu, LIU Ye, WAN Zhongying*, ZUO Jiali, WANG Mingwen

(School of Computer & Information Engineering, Jiangxi Normal University, Nanchang 330022, Jiangxi, China)

Abstract: This paper proposes an emoji embedded representation based on emotion distribution (EDEER) method. The EDEER method adopts the soft label of BERT-based emotion prediction model to learn emoji embedded representation from real data, and directly models the expression degree of emoji on various sentiments through emotion distribution, so that the embedded representation contains various emotional information of emoji. Multiple sets of comparative experiments on the Chinese Weibo dataset containing emoji shows that the method proposed in this paper can effectively learn emoji embedded representations that are directly related to fine-grained sentiments, and build an emoji representation space with high emotional expression quality.

Key words: emoji; sentiment analysis; embedded representation; emotion distribution

0 引言

情感分析(sentiment analysis)又称为意见挖掘,旨在提取和分析人们对不同实体(如事件、产品和服务)的意见、评价和情绪等^[1]。emoji 表情符号是一种新兴的视觉情感符号,具有比普通文字更强的情绪表现力,在微博、推特等社交媒体软件上被广泛使用^[2-3]。

Emoji 是日语单词“絵(e = picture)文(mo = write)字(ji = character)”的音译,2010 年统一码联盟(Unicode Consortium)正式将 emoji 标准化,为每个 emoji 确定了相应的编码和文本描述。emoji 首次出现于 1999 年,最初包含 176 个简单的图形符号^①,目前 emoji 标准已更新至 15.1 版^②。在直白的普通文本之外,emoji 能够传递一些复杂或细微的情绪,对句子表达的实际情感具有重要影响。已有研究工作表明,在模型

收稿日期: 2023-05-04; 网络出版时间: 2023-12-05 16:51:54

网络出版地址: <https://link.cnki.net/urlid/37.1389.N.20231204.1422.006>

基金项目: 国家自然科学基金资助项目(62266021); 江西省教育厅科学技术研究项目(GJJ2200330)

第一作者: 曾雪强(1978—), 男, 教授, 博士, 研究方向为自然语言处理、情感分析、数据降维。E-mail: xqzeng@jxnu.edu.cn

* 通信作者: 万中英(1977—), 女, 副教授, 研究方向为自然语言处理。E-mail: libby@jxnu.edu.cn

① <https://edition.cnn.com/style/article/emoji-shigetaka-kurita-standards-manual/index.html>

② <https://emojipedia.org/emoji-15.1/>

中增加考虑 emoji 信息可以有效提升情感分析模型的性能^[4-5]。

在自然语言处理领域,对各种输入数据进行有效表示是一项传统的重要研究任务,emoji 作为一种视觉符号(特别是一些基于人脸图像的 emoji 符号)经常可以表达多种不同的情绪,与普通单词相比,emoji 包含更多的情感信息,相应的 emoji 有效表示更为复杂,目前构建有效且与情绪关联的 emoji 表示模型已成为情感分析领域的一个研究热点^[6]。

借鉴普通单词的向量化表示方法,目前主流的 emoji 表示方法是采用嵌入式表示(embedded representation)模型,将 emoji 映射到低维的语义空间^[7]。已有的 emoji 嵌入式表示方法主要分为两大类:第一类方法是基于描述文本的 emoji 嵌入式表示,例如 Eisner 等^[6]利用 emoji 的 Unicode 官方描述文本构建 Emoji2vec,将 emoji 映射为低维的向量表示;Wijeratne 等^[8]基于从 EmojiNet 提取的 emoji 语义描述文本,训练 emoji 嵌入式表示。这类表示方法采用描述文本代表 emoji,可以方便地利用丰富的文本预训练词嵌入资源;但由于 emoji 的具体含义在不同应用场景和文化背景下具有明显的不同,所以固定的描述文本一般难以对 emoji 的含义进行准确表达。第二类方法是基于模型训练的 emoji 嵌入式表示,例如 Barbieri 等^[9]在推特数据集上采用 skip-gram 模型对 emoji 符号和普通单词进行训练,得到 emoji 嵌入式表示;Li 等^[10]为了分析不同语言网络社交平台上用户的 emoji 使用习惯差异,分别在推特和微博 2 种语料上训练 fastText 模型以获得 emoji 嵌入式表示。基于模型训练的表示方法直接从目标任务的真实语料中学习嵌入式表示,可以避免描述文本不能准确表达 emoji 具体含义的问题,但是传统词嵌入模型一般只基于训练数据中符号的共现规律学习 emoji 嵌入式表示,没有考虑 emoji 表达的情感信息,所以得到的嵌入式语义空间缺乏与情绪的直接关联。

在 emoji 的研究工作中,emoji 情感词典是另一种可以为 emoji 和情绪建立关联的方法^[11-12]。emoji 情感词典为每个 emoji 关联一种或多种情绪标签或得分,用于记录 emoji 的情感极性或细粒度情绪信息^[11]。例如,Novak 等^[13]根据句子的情感极性为每个 emoji 计算情感极性分数,构建了一个 emoji 情感极性词典;Li 等^[14]将微博中的 emoji 转换成文本特征并进行情感极性标注,构建得到微博 emoji 情感极性词典;Shoeb 等^[11]为探索 emoji 与情绪的联系,对 150 个常用 emoji 与 8 种基本情绪的关联程度进行人工打分,获得 emoji 情感词典。emoji 情感词典存储 emoji 与情绪的直接关联信息,可以方便地使用在情感分析模型中,但 emoji 情感词典不是有效的 emoji 表示方法,我们一般无法在目标任务中对 emoji 与各种情绪的关联程度进行进一步训练。

针对上述问题,本文提出一种基于情感分布的 emoji 嵌入式表示方法(emoji embedded representation based on emotion distribution, EDEER),利用基于 BERT 的情绪预测模型软标签,在中文微博情感数据集上学习 emoji 嵌入式表示。不同于已有的 emoji 表示方法,EDEER 方法构建得到与细粒度情绪直接关联的 emoji 嵌入式表示,通过情感分布定量地表示出 emoji 在各种情绪上的表达程度。在中文微博数据上的多组对比实验的结果表明,相对于其他 emoji 表示方法,EDEER 方法可以有效地学习到与细粒度情绪直接关联的 emoji 嵌入式表示,构建出具有较高情绪表达质量的 emoji 表示空间。


1 相关工作

1.1 Emoji 情感信息

Emoji 是一种具有丰富情感意义的新型视觉语言,可以表达或增强情绪,已经成为互联网上进行互动和情感交流的重要媒介^[3]。emoji 的使用不受单词语法规则的约束,可以出现在语句中的不同位置,主要用来表现作者的主观情感。与普通单词相比,emoji 一般包含更多和更复杂的情感信息,在不同的句子中,同一个 emoji 经常表达出不同的情绪。以 Weibo Emotion Corpus (WEC)数据集^[15]为例,含有相同 emoji 的句子的情绪标注经常是不同的。如表 1 所示,包含❤️的例句 1 和 2 的标注情绪分别为乐(高兴)和悲(悲伤);含有😍的例句 3 和 4 的情绪标签分别是爱(喜欢)和恶(厌恶)。对表 1 中的例句进行仔细分析可以发现,emoji 的含义应该是一种与上下文相关的多种强度不同的情绪混合表达。如图 1 所示:❤️的主要情绪是乐(高兴),次要情绪为爱(喜欢),此外与悲(悲伤)也具有关联;😍的主要情绪为乐(高兴),次要情绪为悲(悲伤),此外也可以用于表达爱(喜欢)和恶(厌恶)等情绪。

表 1 WEC 微博数据集中的示例
Table 1 Examples of WEC Weibo dataset

序号	示例	情绪
1	感谢一切,爱你们❤️	乐
2	满满的正月味道,让我不禁思念远在故乡的亲人❤️	悲
3	奋斗的人生才有意义,充实才叫人生😁	爱
4	真不知道要怎么和敷衍对话的人继续聊下去😞	恶



注: 纵坐标左侧数字表示 emoji 在各情绪上的表达程度,数值越大表示 emoji 表达此情绪的程度越高。横坐标: 1.怒; 2.恶; 3.惧; 4.乐; 5.爱; 6.悲; 7.惊。

图 1 ❤️和😞在 7 种情绪上的情感分布
Fig.1 Emotional distribution of ❤️ and 😞 over 7 emotions

已有研究表明,在基于文本的情感分析模型中增加考虑 emoji 信息可以有效地提升模型性能^[16-17],例如, Felbo 等^[17]将 emoji 作为文本情感的代理,用于训练基于推文的情绪分类模型,取得了显著超越基线方法的情绪预测性能。

1.2 Emoji 的嵌入式表示

在自然语言处理领域中,对输入数据(字母、单词和句子等)进行有效的表示是一个经典的研究方法^[6]。作为在情感分析模型中考虑 emoji 信息的基础,构建有效的 emoji 的数值表示是一项重要的研究内容。与普通文本进行数值表示的做法类似,嵌入式表示方法是当前 emoji 表示的主流做法,目前已有的 emoji 嵌入式表示方法主要分为基于描述文本的 emoji 嵌入式表示和基于模型训练的 emoji 嵌入式表示。

基于描述文本的 emoji 嵌入式表示的一般做法是先将 emoji 表示为某些文本描述(如微博中 emoji 😁 表示为“可爱”),然后采用某种方法获得描述文本的嵌入式向量,最后将其直接或经过转换后作为 emoji 的嵌入式表示。例如, Singh 等^[18]将 emoji 替换为短文本描述,再使用描述词在预训练词典中的词嵌入向量作为 emoji 嵌入表示。基于描述文本构建 emoji 嵌入式表示,可以利用或借鉴基于大规模语料预训练的普通文本词嵌入资源,在 emoji 训练数据不足的任务中可以获得较好的性能,但是,普通文本一般很难准确地表达基于图像的 emoji 的视觉语义,而且同一个 emoji 在不同的应用场景和文化背景下很可能表达不同的具体含义(如😞在现实应用中可用于表达多种含义)。基于特定的情感分析任务进行针对性的训练,是构建鲁棒的 emoji 嵌入式表示的一个可行思路。

基于模型训练的 emoji 嵌入式表示是将 emoji 作为特殊单词与普通单词一起进行词嵌入模型的训练,以获得包括所有 emoji 和普通单词的嵌入式表示。例如, Dimson^[19]在整个 Instagram 语料库上训练 skip-gram 模型,生成包含 emoji 的嵌入式向量。基于模型训练获得的 emoji 嵌入式表示可以直接从目标任务的训练数据中学习 emoji 嵌入式表示,用于表达 emoji 在特定任务中的语义信息,可以避免描述文本不能准确表示 emoji 语义的问题。但是,传统的词嵌入模型(如 skip-gram、fastText 等)一般只基于单词的共现规律学习嵌入式语义表示,没有考虑文本中情感信息,所以得到的嵌入向量与句子表达出的情绪没有直接关联。基于 emoji 可以表达大量情感信息的特点,构建一种能够直接建模 emoji 在各个细粒度情绪上表达程度的嵌入式表示,是一个值得尝试的研究思路。

1.3 Emoji 情感词典

Emoji 情感词典是一种保存 emoji 与情绪关联信息的知识库^[13]。在 emoji 情感词典中,每个 emoji 对应

一种或多种情绪的标签或分数。构建 emoji 情感词典的最直接的方式是进行人工标注,例如 Shoeb 等^[11]对 150 个常用 emoji 与 8 种基本情绪的关联程度进行人工打分,构建 emoji 情感词典。另一种获得 emoji 情感词典的方式是基于已知的句子或情感词的情感信息,间接地构建 emoji 情感词典,例如 Novak 等^[13]基于推文的句子级情感极性(正面、负面和中性)计算 emoji 的情感极性分数,形成 emoji 情感极性词典;Kimura 等^[20]提取出语句中的情感词,再基于情感词与 emoji 的共现规律构建 emoji 情感极性词典;Shoeb 等^[11]在包含 2 千万条推文的数据集上学习情感词与 emoji 的共现规律,再基于情感词的情绪标注信息获得 emoji 与各个情绪的关联得分。基于 emoji 情感词典,我们可以方便地获得 emoji 与情绪的关联信息,然而情感词典不是一种有效的 emoji 表示方式,我们需要在目标任务上对 emoji 在各个情绪上的表达程度进行定制化的训练。

1.4 情感分布学习

情感分布学习(emotion distribution learning, EDL)是一种新型的情感分析范式^[21],通过为每个示例关联一个情感分布向量^[22],定量地记录示例在多种情绪上的表达程度,可以较好地处理具有情感模糊性的情绪分析任务。情感分布向量中每个数值代表给定示例在对应情绪上的表达程度,向量维数为情绪的种类数。情感分布学习最初由 Zhou 等^[21]于 2015 年在针对人脸情绪识别任务时提出,随后被应用于文本情绪识别等多种情绪分析任务,并在处理情感模糊性方面表现出了独特的优势^[23]。与人脸表情经常呈现复杂情感类似,emoji 所表达的情感可以认为是由多种强度不同的基本情绪所构成。借鉴 EDL 的研究思路,本文利用情感分布建模 emoji 在各种情绪上的表达程度,构建 emoji 与情绪直接关联的 emoji 嵌入式表示。

1.5 软标签

软标签(soft label)是一种将已训练的预测模型多标签输出作为目标变量,用于训练另一个预测模型的技术^[24]。已有一些研究表明,用软标签代替真实标签可以显著提高自然语言处理任务的性能^[25]。例如,Zhao 等^[26]提出了一种基于软标签的鲁棒的机器阅读理解方法;Fornaciari 等^[27]将软标签作为多任务神经网络的辅助任务,用于解决过拟合问题;Fayek 等^[25]采用软标签对情感的主观性进行建模,并将其应用到情绪识别任务中;Wang 等^[28]利用软标签构建细粒度情绪的分布式表示。本文采用基于 BERT 的情绪分类模型输出软标签,在目标任务的训练过程中构建基于情感分布的 emoji 嵌入式表示。与在输入层的嵌入式表示方法只能通过反向传播机制进行训练不同,在预测模型输出层的软标签直接包含了语句中多种情绪的表达强度信息,可以用于对 emoji 进行有效表示。

2 基于情感分布的 emoji 嵌入式表示

2.1 Emoji 嵌入式表示

构建有效的 emoji 表示是情感分析模型考虑 emoji 信息的基础^[16],但由于 emoji 表达情绪具有多义性,因此传统的基于描述词构建的 emoji 表示很难准确表达 emoji 含义。例如👊,描述词“奥特曼”较为中性,难以直接判断表达的情绪,但是从包含👊的语句“感觉充满了能量👊”中可以推断,👊主要表达积极的情感。

考虑到含有 emoji 语句的句子级情绪与 emoji 表达的情绪具有显著的关联性,我们认为可以在建立句子级情绪预测模型的同时,挖掘 emoji 表达的情绪信息。通过同一个 emoji 在不同句子中表达出的多种情绪信息,综合得到 emoji 的情绪表示。例如对于😭,在句子“造孽啊!😭”中表达悲伤情绪,而在句子“花了两小时终于成功了,感动得痛哭流涕😭”中表达了高兴的积极情感。在综合所有包含😭语句的情绪信息的基础上,可以得到😭的情绪表示。本文将利用语句的嵌入式表示,学习有效的 emoji 嵌入式表示。

对于 emoji^(m),即第 m 个 emoji,我们定义 E_m 为 emoji^(m) 的嵌入式表示, x 为含有 emoji^(m) 的句子样本。用 $V(x)$ 和 $p(x)$ 分别表示样本 x 的嵌入式表示和概率密度, Ω 为 x 的积分域。另外,使用 $L(E_m, V(x))$ 作为 E_m 和 $V(x)$ 之间的距离函数。为了获得 emoji^(m) 更好的嵌入式表示,我们希望在积分域 Ω 上最小化 L 的期望值,因此,得到的 emoji^(m) 嵌入式表示的计算公式如下:

$$E_m = \arg \min_E \int_{\Omega} L(E, V(x)) p(x) dx. \quad (1)$$

2.2 基于情感分布的 emoji 嵌入式表示

目前有许多可用的情感分析数据集,其中含有 emoji 的句子可以视为有效的样本。给定情感数据集 D

和 emoji^(m),我们使用数据集中含有 emoji^(m)的所有样本,估计 emoji^(m)的嵌入式表示,因此式(1)改写为

$$E_m = \arg \min_E \sum_{x \in T_m} L(E, V(x)), \tag{2}$$

其中 T_m 为数据集 D 中含 emoji^(m)的所有样本集合。

在本文中,我们采用欧氏距离作为 E 和 V(x)之间的距离度量,则式(2)可简写为

$$E_m = \arg \min_E \sum_{x \in T_m} \| E - V(x) \|_2^2. \tag{3}$$

对公式(3)进行求解得到

$$E_m = \frac{\sum_{x \in T_m} V(x)}{s_m}, \tag{4}$$

其中 s_m 为集合 T_m 的大小。

从式(4)可以看出,emoji^(m)的嵌入式表示其实是数据集 D 中所有包含 emoji^(m)的样本的嵌入式表示平均值。以下将讨论如何获得数据集中句子样本的嵌入式表示。BERT 作为一种语言表征双向编码模型,在许多自然语言处理任务(例如文本情感分类、机器阅读理解等)中表现出较出色的性能^[29]。图2所示为基于 BERT 的情绪预测模型架构。BERT 预训练上下文语言模型主要包括词向量编码层和 12 个多头自注意力机制与位置全连接前馈网络的组合层,其中词向量编码层由 3 个子层组成,分别为位置嵌入、分段嵌入和标记嵌入。在基础 BERT 模型上加一个全连接层用于情绪预测任务,其输出为软标签。

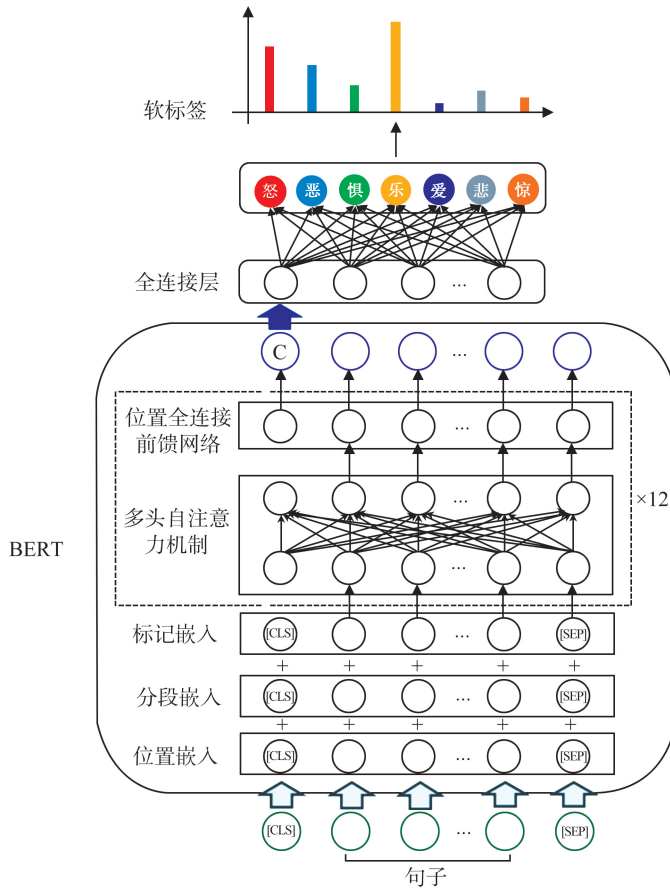


图2 基于 BERT 的情绪预测模型示意图

Fig.2 Schematic diagram of the BERT-based sentiment prediction model

受以往软标签研究工作的启发,我们直接将情绪预测模型的软标签作为输入样本的嵌入式表示, E_m 的维数等于数据集 D 中情绪标签的数量。最终,基于情感分布的 emoji^(m)的嵌入式表示 E_m 通过式(5)计算得到:

$$E_m = \frac{\sum_{x \in T_m} V_{\text{soft}}(x)}{s_m}. \tag{5}$$

其中 $V_{\text{soft}}(x)$ 是基于 BERT 情绪预测模型输出的样本 x 的软标签, E_m 中各元素表示 emoji^(m) 在各个情绪上的表达程度, 总和为 1。EDEER 方法的算法伪代码如算法 1 所示。

算法 1 EDEER 算法

```

输入:  $D = \{(x^{(n)})_{n=1}^N\}$ ,  $\text{EMOJI} = \{\text{emoji}^{(m)}\}_{m=1}^M$ 
//包含  $N$  个样本的训练数据集和  $M$  个 emoji。
输出:  $E = \{E_1, E_2, \dots, E_M\}$  //emoji 嵌入式表示。
1.  $f \leftarrow D$  //训练基于 BERT 的情绪预测模型;
2.  $E = \{0, 0, \dots, 0\}$ ;
3.  $\{s_1, s_2, \dots, s_M\} \leftarrow \{0, 0, \dots, 0\}$  //保存 emoji 的样本数;
4. for  $n=1$  to  $N$  do;
5.  $SL \leftarrow f(x^{(n)})$  // $SL$  是软标签, 维度为情绪数量;
6. for  $m=1$  to  $M$  do;
7. if emoji(m) in  $x^{(n)}$  do;
8.  $E_m \leftarrow E_m + SL$ ;
9.  $s_m \leftarrow s_m + 1$ ;
10. end for;
11. end for;
12. for  $m=1$  to  $M$  do;
13.  $E_m \leftarrow E_m / s_m$ ;
14. end for。

```

3 实验结果与分析

为了验证 EDEER 方法的有效性,我们在中文微博情感数据集上进行了 3 组对比实验:emoji 表示向量可视化实验,emoji 表示的情感极性一致性检测实验和 emoji 表示映射的细粒度情绪的对比实验。

3.1 实验数据集

本文采用 NLP&CC2013^[30]、NLP&CC2014^[30] 和 WEC^[15] 这 3 个中文微博情感数据集作为实验数据集。因为单个数据集包含 emoji 的句子相对较少,所以我们将 3 个微博数据集合并构成总的数据集进行实验,实验数据集的具体信息如表 2 所示。

表 2 实验数据集
Table 2 Experimental dataset

数据集	emoji 数量	含 emoji 的句子数	总句子数
NLP&CC2013	110	1 509	10 487
NLP&CC2014	28	637	5 918
WEC	191	8 961	39 660
总计	262	11 107	56 065

NLP&CC2013 数据集和 NLP&CC2014 数据集是自然语言处理与中文计算会议(CCF Conference on Natural Language Processing & Chinese Computing, NLP&CC)于 2013 年和 2014 年发布的情感评测任务中文单标签情感数据集,2 个数据集均包含怒(愤怒)、乐(高兴)、惧(恐惧)、惊(惊讶)、悲(悲伤)、恶(厌恶)和爱(喜欢)7 种情绪。NLP&CC2013 数据集包含从新浪微博中采集的 10 487 条情绪句和 21 633 条无情绪句。NLP&CC2014 数据集是 NLP&CC2013 数据集的扩充,共有 16 405 条情绪句和 29 731 条无情绪句,其中与 NLP&CC2013 数据集不重复的情绪句有 5 918 条。WEC 数据集是香港理工大学于 2016 年发布的中文微博情感语料库,包含怒(愤怒)、乐(高兴)、惧(恐惧)、惊(惊讶)、悲(悲伤)、恶(厌恶)和爱(喜欢)7 种情绪共 39 660 条语句。本文将 NLP&CC2013 和 NLP&CC2014 数据集的情绪句与 WEC 数据集合并,得到总计 56 065 条句子构成实验数据集,其中含 emoji 的句子 11 107 条,不同的 emoji 符号 262 个。

在数据预处理部分,我们去除了句子中的中英文标点符号等特殊字符和所有的英文字母,仅保留中文和

数字,使用 Jieba 分词工具进行分词后,采用中文预训练词向量模型(Chinese word vector, CWV)^[31]将单词表示为 300 维词向量。句子最大的单词数设为数据集中最长句子的单词数,不足则补 0。

中文微博数据集采用“[描述词]”的形式对 emoji 进行表示,例如😄在数据集中表示为“[哈哈]”,😱表示为“[抓狂]”。对于每个 emoji,我们统计出数据集中包含该 emoji 的句子数量,舍弃句子数量小于 30 的 emoji,保留了 64 个使用频率最高的 emoji。对包含 emoji 句子的标注情绪进行统计,得到最常用的 64 个 emoji 在 7 种情绪上的句子标注数量。我们将每个 emoji 在数据集中标注最多的句子情绪标签,标注为该 emoji 的主导情绪。64 个 emoji 在 7 种情绪上的句子标注信息如表 3 所示,其中每个 emoji 的主导情绪用粗体标出。

表 3 64 个 emoji 在 7 种情绪上的句子标注数量
Table 3 Number of sentences labeled with 64 emoji on 7 emotions

emoji	描述词	总句子数	7 种情绪的句子标注数量							emoji	描述词	总句子数	7 种情绪的句子标注数量						
			怒	恶	惧	乐	爱	悲	惊				怒	恶	惧	乐	爱	悲	惊
😭	泪	1 787	153	186	27	171	62	1 161	27	😨	吃惊	109	14	22	3	9	2	17	42
😄	哈哈	629	8	42	4	457	67	38	13	😏	鄙视	106	37	38	1	5	4	17	4
😱	抓狂	606	152	160	14	25	23	224	8	🤔	思考	105	8	30	2	20	15	19	11
❤️	心	539	6	8	5	273	168	74	5	😘	亲亲	104	1	6	0	57	27	12	1
😡	怒	459	273	80	3	9	4	82	8	😴	睡觉	103	8	34	3	21	7	28	2
😂	嘻嘻	401	7	19	3	303	45	22	2	👍	赞	98	4	2	0	20	70	2	0
😵	衰	352	53	80	10	13	3	168	25	☁️	浮云	96	8	17	0	21	9	39	2
😓	汗	309	53	108	6	25	8	80	29	🍷	笑哈哈	92	4	5	0	62	11	8	2
🙏	拜拜	295	30	15	1	15	6	222	6	👁️	花心	87	2	6	0	42	30	2	5
😞	悲伤	293	19	21	6	17	5	224	1	😋	馋嘴	85	3	14	0	49	9	9	1
😏	偷笑	276	8	28	2	172	33	26	7	👊	威武	78	3	5	0	34	22	9	5
💔	伤心	267	22	22	4	11	10	196	2	🌿	微风	71	1	8	1	35	12	12	2
😮	哼	263	74	84	5	15	3	77	5	👥	围观	64	3	8	0	28	9	14	2
🤒	生病	258	30	53	11	8	6	147	3	🤮	吐	62	14	28	0	2	1	16	1
😄	呵呵	239	8	20	2	84	44	78	3	😬	做鬼脸	61	2	8	1	32	10	7	1
😓	可怜	208	18	24	8	23	11	121	3	🐼	熊猫	61	4	4	1	12	14	21	5
😞	失望	206	12	27	8	6	11	139	3	🍰	蛋糕	57	0	0	0	28	24	4	1
😳	害羞	187	7	20	10	82	37	28	3	🐷	猪头	57	9	10	0	15	12	10	1
🕯️	蜡烛	185	20	12	1	20	16	114	2	🤪	崩溃	53	19	12	1	1	2	18	0
😍	可爱	179	1	10	2	82	49	30	5	🗣️	话筒	52	3	8	0	9	18	14	0
😵	晕	177	25	53	3	16	6	59	15	😡	愤怒	51	35	6	0	1	1	7	1
🌙	月亮	176	7	11	3	62	47	44	2	😕	疑问	51	8	10	0	6	4	20	3
👏	鼓掌	174	2	13	0	95	53	9	2	🌹	鲜花	49	1	0	0	22	16	9	1
😞	委屈	167	13	19	4	9	8	112	2	😬	闭嘴	46	7	7	1	2	2	23	4
🦸	奥特曼	158	9	21	1	49	45	28	5	🐎	神马	44	10	9	0	8	5	11	1
😓	黑线	145	29	52	1	10	3	38	12	😞	困	42	1	20	0	3	8	8	2
🐰	兔子	141	6	11	0	85	16	20	3	👎	弱	38	16	10	0	0	1	11	0
😎	酷	130	2	20	0	60	29	14	5	🌧️	下雨	37	3	6	1	4	4	18	1
😓	泪流满面	126	13	10	5	10	5	81	2	👤	悲催	36	0	7	1	1	1	26	0
😡	怒骂	119	51	28	0	3	2	32	3	🍷	干杯	35	1	0	0	21	8	5	0
☀️	太阳	112	6	2	0	67	17	17	3	🤗	抱抱	32	1	1	0	25	5	0	0
✌️	耶	110	2	2	3	65	30	5	3	👤	顶	30	5	7	2	0	4	12	0

在 emoji 的主导情绪的基础上,我们对各个 emoji 的情感极性进行标注。Demszky 等^[32]将 27 种细粒度情绪划分为 3 种情感极性,分别为积极、消极和模糊。依据此情感极性划分标准,7 种情绪的情感极性如表 4 所示。其中,乐和爱标记为积极的情感极性,怒、恶、悲和惧确定为消极情感,惊对应为模糊的情感极性。最常用的 64 个 emoji 的情感极性标注结果如图 3 所示。

表 4 7 种情绪的情感极性及其 emoji 数量
Table 4 The emotional polarity of 7 emotions and their emoji numbers

情绪	情感极性	emoji 数量
乐	积极	27
爱	积极	2
怒	消极	5
恶	消极	8
悲	消极	21
惧	消极	0
惊	模糊	1



图 3 64 个 emoji 的情感极性

Fig.3 The emotional polarity of 64 emoji

大多数 emoji 带有强烈的情感色彩,具有较为明确的情感极性。例如,😊常用于表示“乐”的积极情绪,在句子“好长时间没运动了,今天打了羽毛球😊”中可以明显看出😊表达出开心、幸福等情感;😡和😠常表示“怒”的消极情绪,从句子“恶心的人,有多远滚多远。😡影响网络环境”和“话不投机半句多😠”中可以看出,😡表达出的愤怒程度比😠更重。在现实使用场景中少部分 emoji 的情绪表达具有显著的模糊性,使用偏好受到用户特征的影响很大。例如,很多年轻用户常使用😁表达“恶”的消极情绪,而年长用户一般认为😁表示“乐”;对于表达思考状态的😏,不同用户也经常有不同的理解和使用偏好。另外,非面部 emoji 相比于面部 emoji,表达的情绪和含义具有更加明显的模糊性。例如,🍀和🐼等较少使用的非面部 emoji 表达的情绪,并不一定符合很多人的想法。🐼的标注结果为消极,但也有部分用户认为🐼也可用于表示可爱、喜欢等积极情感,不同的用户对非面部 emoji 的理解可能不同。

3.2 模型设置

本文采用基于 BERT^[29] 的情绪预测模型软标签进行 emoji 嵌入式表示,另外,输出为软标签的模型都可以用来学习 emoji 的嵌入式表示。为了对比不同的情绪预测软标签模型,我们在基于 BERT 的模型之外,分别使用基于 TextCNN^[33] 和基于 BiLSTM^[34] 的情绪预测模型软标签对 emoji 表示进行学习,3 种模型的详细设置如下。

(1) TextCNN 模型。该模型是用于文本分类的卷积神经网络模型,通过一维卷积来获取句子中的 n -gram 特征表示。模型由一层卷积、一层 max-pooling 组成,最后将输出外接 softmax 进行分类。本文采用 3 种过滤器,滑动窗口分别为 3、4 和 5;损失函数优化采用 SGD 算法,训练轮次为 5;批量大小和学习率设置为 50 和 0.01。

(2) BiLSTM 模型。该模型由前向 LSTM 与后向 LSTM 组合而成,将同一个序列分别输入向前和向后的 2 个 LSTM 中,再共同接入到输出层进行预测,可以同时捕捉正向信息和反向信息,使得对文本信息的利

用更全面。本文分别设置批量大小和学习率为 32 和 0.001,训练轮次为 2,优化器使用 Adam。

(3) BERT 模型。该模型是 Google AI 研究院于 2018 年提出的一种预训练语言表征模型,利用 masked language model(MLM)进行训练并且采用深层的双向 Transformer 编码器表示,是一个典型的双向编码模型。本文在 BERT 模型的顶部添加一个全连接层,采用 Adamw 优化器,设置批量大小和训练轮次为 32 和 2,学习率为 0.000 03。

3.3 Emoji 表示向量可视化

为了更好地理解 emoji 在空间中的排列情况,我们利用 *t*-SNE 算法^[35]将 64 个 emoji 嵌入式表示向量从高维空间投射到二维进行可视化。此外,本文使用 3 种常用的词嵌入模型作为基线模型,分别是 CWV 模型^[31]、Directional Skip-Gram(DSG)模型^[36]和 fastText 模型^[37]。

(1) CWV 模型^[31]:该模型是在一种基于汉语的类比推理任务中提出的中文词嵌入模型,该模型包括 85 万个词,所有词向量都使用 ngram2vec 工具包在不同的表征、上下文特征和语料库上进行训练,最终得到 300 维词向量表示。

(2) DSG 模型^[36]:DSG 模型是 Tencent AI Lab 于 2018 年发布的中文词嵌入算法,它通过明确区分单词的上下文来增强 Skip-Gram 模型,并为每个单词引入了一个方向向量。其嵌入表示不仅通过其上下文中的单词共现模式学习,还通过其上下文单词的方向学习。最新版本中包括超过 1 200 万个中文词,并分别提供了 100 维和 200 维向量表示,本文中使用了最新版中的 200 维词向量来加入比较。

(3) fastText 模型^[37]:fastText 是 Facebook 开源的一个文本分类与词向量训练工具,在文本分类任务中学习词嵌入表示。本文参考 Li 等^[10]的实验设置,在中文微博情感数据集上训练 fastText 模型,将 emoji 和单词映射到同一空间以获得 emoji 嵌入向量,设置 emoji 嵌入向量的维数为 100。

采用 6 种不同的 emoji 嵌入式表示方法对 64 个 emoji 进行表示,得到每个 emoji 相应的嵌入式向量,再通过 *t*-SNE 算法^[35]将 emoji 向量降到 2 维并进行可视化。为了直观地分析各种 emoji 嵌入式表示方法的情感极性区分能力,我们在 *t*-SNE 的 2 维空间中使用 kNN 算法得到各个 emoji 近邻区域的情感极性,其中 *k*=1。如图 4 所示,红色、绿色和蓝色区域分别对应积极、消极和模糊的情感区域。图 4(a)和(b)是 CWV 模型和 DSG 模型中对应 emoji 描述词嵌入表示的结果,图 4(c)为利用 fastText 模型得到的 emoji 嵌入表示的结果,图 4(d)一(f)分别显示了基于 TextCNN、BiLSTM 和 BERT 模型的 EDEER 方法生成的 emoji 嵌入式表示可视化结果。

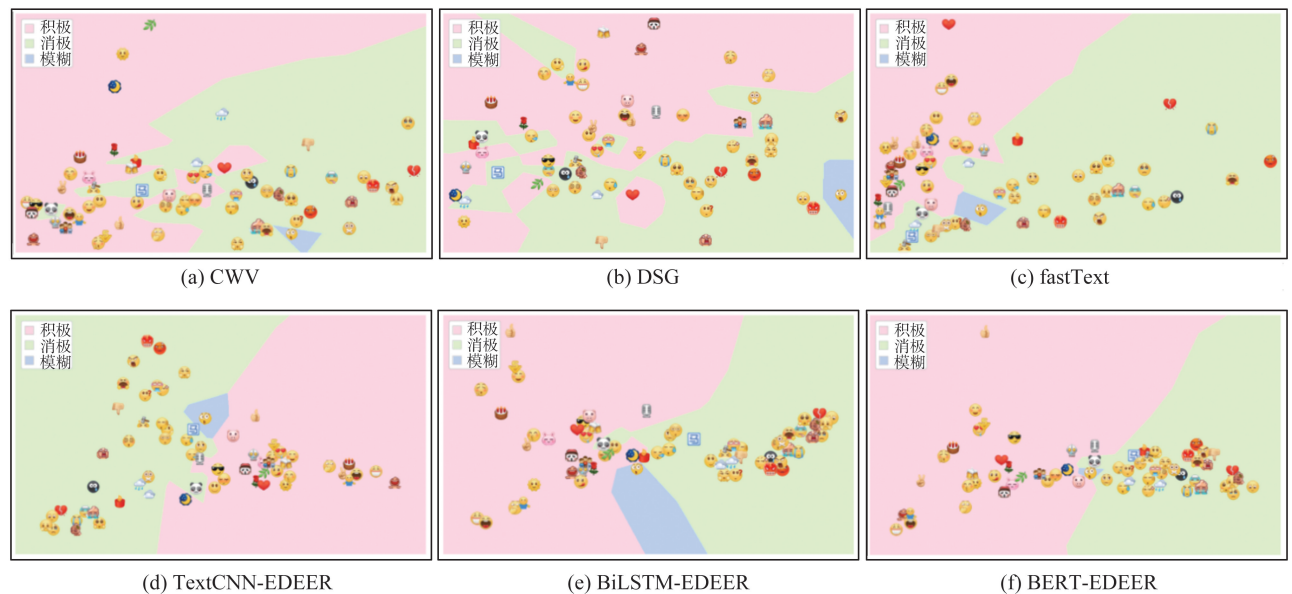


图 4 不同 emoji 表示方法下 64 个 emoji 向量的 *t*-SNE 可视化

Fig.4 *t*-SNE visualization of 64 emoji vectors under different emoji representation methods

如图 4(a)和(b)所示,CWV 模型和 DSG 模型学习到的 emoji 嵌入表示在空间中的排列没有明显规律,积极情绪和消极情绪之间没有明确的界限,利用 emoji 描述词的词向量作为 emoji 嵌入表示没有包含 emoji 情感信息,不能准确表达 emoji 的情绪。在图 4(c)中,fastText 模型学习到的 emoji 嵌入表示可以使不同情

感极性的 emoji 分布在不同区域,这是因为 fastText 是有监督学习模型,在情感分类任务中可以学习到对应的情感,但相似情绪 emoji 之间距离较远,例如表示消极情绪的 ☹️ 和 ☔️,被多个具有积极情绪的 emoji 分隔,同时也表明积极情绪和消极情绪之间的界限并不平滑。

从图 4(d) — (f) 中可以发现,使用 EDEER 方法学习到的 emoji 嵌入式表示可以使情感极性为积极的 emoji 与消极的 emoji 分布在空间的不同区域,具有明显的界限。其中图 4(f) 利用基于 BERT 的情绪预测模型的软标签使得相同极性的 emoji 更加聚集,且不同情感极性 emoji 间的界限较为平滑。相似情绪 emoji 之间距离较近,例如具有消极情绪的 ☹️ 和 ☔️ 在空间中排列紧密,但在 CWV 模型、DSG 模型和 fastText 模型的向量空间中距离较远。具有模糊情感极性的 emoji 正好位于积极和消极 emoji 之间,表明利用本文方法学习到的 emoji 表示能够更好地描述具有模糊情绪的 emoji 与其他不同情感极性的 emoji 之间的关系。

总体而言,使用软标签得到的 emoji 嵌入式表示比词嵌入方法更容易使具有相似情感的 emoji 聚集在一起,进一步表明使用 EDEER 方法学习到的 emoji 嵌入式表示包含准确的情感,并可以描述具有不同极性的 emoji 间的情感关系。

3.4 Emoji 表示的情感极性一致性检测

情感极性一致性检测^[38]是一种评估嵌入式表示情绪表达质量的方法,本实验通过对相似 emoji 嵌入向量之间的 emoji 情感极性一致性进行检测,进一步评估不同 emoji 嵌入式表示方法的情绪表达质量。根据图 3 中显示的 64 个 emoji 的情感极性,确定不同 emoji 的情感极性是否一致。

按照 Tang 等^[38]衡量情感极性一致性的实验设置,计算每个 emoji 与其最邻近的前 k 个 emoji 之间情感极性一致的准确率 A ,

$$A = \frac{\sum_{m=1}^M \sum_{j=1}^k \alpha(\text{emoji}^{(m)}, e_{mj})}{M \times k}, \quad (6)$$

其中: M 是 emoji 个数; $\text{emoji}^{(m)}$ 为第 m 个 emoji; e_{mj} 是 emoji 中第 j 个与 $\text{emoji}^{(m)}$ 余弦相似度最高的 emoji; $\alpha(\text{emoji}^{(m)}, e_{mj})$ 是一个指示函数,如果 $\text{emoji}^{(m)}$ 和 e_{mj} 情感极性相同,则 $\alpha = 1$, 否则 $\alpha = 0$ 。准确率越高,嵌入空间中相近 emoji 的情感一致性越好。

图 5 显示了 $k = \{10, 15, 20, 25, 30, 35, 40\}$ 时的不同 emoji 表示方法的结果。从图中可以看出,CWV 模型、DSG 模型和 fastText 模型的准确率较低,当 $k = 10$ 时结果最好,准确率分别为 70.16%、63.28% 和 88.44%,随着 k 的增大,准确率降低。本文 EDEER 方法的准确率普遍较高,最高为 94.22%,使用基于 BERT 的情绪预测模型的软标签学习的 emoji 嵌入式表示向量比使用其他模型的软标签情感一致性准确率更高,这是因为 BERT 提取情感关系的能力更强。实验结果进一步证明,本文提出的 EDEER 方法能构建出具有较高情绪表达质量的 emoji 表示空间,可以使相近 emoji 之间具有较好的情感一致性。




图 5 不同 emoji 表示方法的情感一致性准确率

Fig.5 Emotional consistency accuracy of different emoji representation methods

3.5 Emoji 表示映射的细粒度情绪的对比实验

为了验证 EDEER 方法生成的 emoji 嵌入式表示向量包含较准确的 emoji 情感信息,我们将不同方法生成的 emoji 表示映射的细粒度情绪进行对比。将每个 emoji 的嵌入表示分别与 7 种情绪类别的嵌入表示进行相似度计算,对于利用基于 BERT 的情绪预测模型的软标签学习到的 emoji 嵌入式表示,我们将 7 种情绪类别(怒、乐、惧、惊、悲、恶和爱)进行 one-hot 表示作为其嵌入表示(例如“怒”的嵌入表示为[1, 0, 0, 0, 0, 0, 0]);对于其他 3 种词嵌入模型(CWV 模型、DSG 模型和 fastText 模型),使用每个模型中 7 种情绪类别的词嵌入向量作为对应的情绪类别嵌入表示。与 emoji 相似度最大的情绪类别作为 emoji 表示的映射结果,主导情绪标签为正确答案。emoji 表示映射的细粒度情绪计算公式如下:

$$\text{emo} = \arg \max \text{sim}_{\text{emo}_c}(\text{emoji}^{(m)}, \text{emo}_c), \tag{7}$$

其中:emoji^(m)是第 m 个 emoji;emo_c为 7 种情绪类别的嵌入向量;emo 是 emoji^(m)的映射结果;sim 为相似度函数,这里选择余弦相似度。表 5 所示为不同方法生成的 emoji 嵌入式表示在各类情绪上映射正确的准确率和在总体上映射正确的准确率,加粗部分为最优结果。


表 5 64 个 emoji 的情绪映射结果
Table 5 Emotion mapping results for 64 emoji

模型	准确率/%						平均准确率/%
	怒	恶	乐	爱	悲	惊	
CWV	0.00	1.67	11.11	0.00	9.52	0.00	9.38
DSG	80.00	8.89	37.04	50.00	42.86	100.00	43.75
fastText	60.00	6.67	3.70	0.00	0.00	100.00	7.81
BERT-EDEER	80.00	8.89	96.30	50.00	90.48	100.00	82.81

从表 5 的实验结果可以发现,CWV 模型和 fastText 模型的准确率较低,平均准确率分别仅有 9.38% 和 7.81%,fastText 模型生成的 emoji 嵌入表示可以表示出 emoji 的情感极性,但不能准确表示出 emoji 的细粒度情绪。DSG 模型的平均准确率为 43.75%,该模型使用的中文嵌入语料库具有高覆盖率、高新鲜度和高准确性的优势^[38],训练数据不仅由新闻、维基百科和百度百科组成,还包括小说等普通文本,使得 DSG 的映射结果比 CWV 模型和 fastText 模型更准确。

EDEER 方法的映射结果比词嵌入模型的结果更准确,使用基于 BERT 的情绪预测模型的软标签学习的 emoji 嵌入式表示总体准确率高达 82.81%,对于各类情绪的映射结果基本上比其他方法更准确,表明 EDEER 方法可以获得具有准确情感信息的 emoji 嵌入式表示向量。


另外,使用 EDEER 方法学习到的 emoji 嵌入式表示可以与多种情绪相关联。图 6 所示是利用基于 BERT 的情绪预测模型的软标签生成的 64 个 emoji 嵌入表示与 7 种情绪之间的关联热图,颜色深浅代表 emoji 在每种情绪上表达程度的高低。从图 6 中可以看出,😄、😁和😂等与“乐”具有很强的联系,与“悲”等消极情绪相关值很低。😡和😠等与多种消极情绪相关联,例如“怒”、“悲”和“恶”,这些 emoji 可以表示多种消极情绪。而一些非面部表情,例如🌿和🍷与多种不同极性的情绪相关,表明 emoji 本身也具有情绪表达的模糊性。图 7 是通过 64 个 emoji 嵌入向量得到的 7 种情绪之间的热力图,从图中可以很清楚看到,相同情感极性之间的情绪类别密切相关,例如“怒”与“恶”这 2 种消极情绪的关联度较高,积极情绪“乐”与“爱”之间的关系也很密切。使用本文方法学习到的 emoji 嵌入式表示可以很好地捕捉不同情绪之间以及 emoji 与每种情绪之间的关系,同时可以表示出 emoji 与每种情绪的关联程度。



注:右侧数值表示每个 emoji 与各类情绪的关联强度,颜色越深代表关联强度越高。

图 6 64 个 emoji 和 7 种情绪之间的关联热图

Fig.6 Heat map of the association between 64 emoji and 7 emotions



注:右侧数值表示各类情绪与情绪间的关联强度,颜色越深代表关联强度越高。

图7 7种情绪之间的关联热图

Fig.7 Heat map of the association between 7 emotions

4 结束语

本文提出了EDEER,利用基于BERT的情绪预测模型的软标签从真实数据中学习emoji嵌入式表示,通过情感分布直接建模emoji在各种情绪上的表达程度。在中文微博情感数据集上通过3组对比实验来验证emoji嵌入式表示的有效性,实验结果表明,EDEER方法生成的emoji嵌入式表示可以将emoji与情绪建立直接联系,并具有显著优于对比方法的情绪表达质量。

在未来的工作中,我们将考虑以更加有效的方式利用软标签来生成emoji嵌入式表示,并将其应用到情绪分析任务中提升模型性能。

参考文献:

- [1] BIRJALI M, KASRI M, HSSANE A B. A comprehensive survey on sentiment analysis: approaches, challenges and trends [J]. Knowledge-Based Systems, 2021, 226:107134.
- [2] GUPTA S, SINGH A, RANJAN J. Sentiment analysis: usage of text and emoji for expressing sentiments[C]//Advances in Data and Information Sciences; Proceedings of ICDIS 2019. Singapore: Springer, 2020:477-486.
- [3] LEE S, JEONG D, PARK E. MultiEmo: multi-task framework for emoji prediction[J]. Knowledge-Based Systems, 2022, 242:108437.
- [4] 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(9):2647-2650.
TAN Hao, DENG Shuwen, QIAN Tao, et al. A microblog sentiment analysis model based on emoji attention mechanism[J]. Application Research of Computers, 2019, 36(9):2647-2650.
- [5] 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):73-84.
XIE Lixing, ZHOU Ming, SUN Maosong. Hierarchical structure based hybrid approach to sentiment analysis of Chinese microblog and its feature extraction[J]. Journal of Chinese Information Processing, 2012, 26(1):73-84.
- [6] EISNER B, ROCKTÄ 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. Stroudsburg: ACL, 2016: 48-54.
- [7] GROVER V. Exploiting emojis in sentiment analysis: a survey[J]. Journal of the Institution of Engineers (India): Series B, 2021, 103(1):1-14.
- [8] WIJERATNE S, BALASURIYA L, SHETH A, et al. A semantics-based measure of emoji similarity[C]//Proceedings of the International Conference on Web Intelligence. New York: ACM, 2017:646-653.
- [9] BARBIERI F, RONZANO F, SAGGION H. What does this emoji mean? a vector space skip-gram model for Twitter emojis

- [C]//Proceedings of the Tenth International Conference on Language Resources and Evaluation (LREC 2016). Slovenia: ELRA, 2016:3967-3972.
- [10] LI M, GUNTUKU S, JAKHETIYA V, et al. Exploring (dis-) similarities in emoji-emotion association on Twitter and Weibo [C]//Companion proceedings of the 2019 world wide web conference. New York: ACM, 2019:461-467.
- [11] SHOEB A A M, DE MELO G. Emotag1200: understanding the association between emojis and emotions[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2020:8957-8967.
- [12] 王文远,王大玲,冯时,等. 一种面向情感分析的微博表情情感词典构建及应用[J]. 计算机与数字工程, 2012, 40(11):6-9.
WANG Wenyu, WANG Daling, FENG Shi, et al. A sentiment dictionary construction and application of microblog emoji sentiment dictionary for sentiment analysis[J]. Computer and Digital Engineering, 2012, 40(11):6-9.
- [13] NOVAK P K, SMAILOVIĆ J, SLUBAN B, et al. Sentiment of emojis[J]. PLoS One, 2015, 10(12):e0144296.
- [14] LI D, RZEPKA R, PTASZYNSKI M, et al. HEMOS: a novel deep learning-based fine-grained humor detecting method for sentiment analysis of social media[J]. Information Processing & Management, 2020, 57(6):102290.
- [15] LI M, LONG Y, QIN L, et al. Emotion corpus construction based on selection from hashtags[C]//Proceedings of the Tenth International Conference on Language Resources and Evaluation. Slovenia: ELRA, 2016:1845-1849.
- [16] 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(4):18.
HE Yanxiang, SUN Songtao, NIU Feifei, et al. A deep learning model enhanced with emotion semantics for microblog sentiment analysis[J]. Chinese Journal of Computers, 2017, 40(4):18.
- [17] FELBO B, MISLOVE A, SØGAARD A, et al. Using millions of emoji occurrences to learn any-domain representations for detecting sentiment, emotion and sarcasm[C]//Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2017:1615-1625.
- [18] SINGH A, BLANCO E, JIN W. Incorporating emoji descriptions improves tweet classification[C]//Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Stroudsburg: ACL, 2019:2096-2101.
- [19] DIMSON T. Emojineering part 1: machine learning for emoji trends[J]. Instagram Engineering Blog, 2015, 30:1-10.
- [20] KIMURA M, KATSURAI M. Automatic construction of an emoji sentiment lexicon[C]//Proceedings of the 2017 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining. New York: ACM, 2017:1033-1036.
- [21] ZHOU Y, XUE H, GENG X. Emotion distribution recognition from facial expressions[C]//Proceedings of the 23rd ACM International Conference on Multimedia. New York: ACM, 2015:1247-1250.
- [22] 曾雪强,罗明珠,陈素芬,等. 基于自适应多重多元回归的人脸年龄估计[J]. 江西师范大学学报(自然科学版), 2019, 43(1):68-75.
ZENG Xueqiang, LUO Mingzhu, CHEN Sufen, et al. The facial age estimation based on adaptive multivariate multiple regression[J]. Journal of Jiangxi Normal University(Natural Sciences Edition), 2019, 43(1):68-75.
- [23] ZHAO Z, MA X. Text emotion distribution learning from small sample: a meta-learning approach[C]//Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing. Stroudsburg: ACL, 2019:3955-3965.
- [24] ZHOU D, QUOST B, FRÉMONT V. Soft label based semi-supervised boosting for classification and object recognition [C]//2014 13th International Conference on Control Automation Robotics & Vision. Piscataway: IEEE, 2014:1062-1067.
- [25] FAYEK H M, LECH M, CAVEDON L. Modeling subjectiveness in emotion recognition with deep neural networks: ensembles vs soft labels[C]//2016 International Joint Conference on Neural Networks. Piscataway: IEEE, 2016:566-570.
- [26] ZHAO Z, WU S, YANG M, et al. Robust machine reading comprehension by learning soft labels[C]//Proceedings of the 28th International Conference on Computational Linguistics. Berlin: ICCL, 2020:2754-2759.
- [27] FORNACIARI T, UMA A, PAUN S, et al. Beyond black & white: leveraging annotator disagreement via soft-label multi-task learning[C]//Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Stroudsburg: ACL, 2021:2591-2597.
- [28] WANG X, ZONG C. Distributed representations of emotion categories in emotion space[C]//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. Stroudsburg: ACL, 2021:2364-2375.
- [29] DEVLIN J, CHANG M W, LEE K, et al. BERT: pre-training of deep bidirectional transformers for language understanding [C]//Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics;

- Human Language Technologies. Stroudsburg: ACL, 2019:4171-4186.
- [30] 姚源林,王树伟,徐睿峰,等. 面向微博文本的情绪标注语料库构建[J]. 中文信息学报, 2014, 28(5):83-91.
YAO Yuanlin, WANG Shuwei, XU Ruifeng, et al. The construction of an emotion annotated corpus on microblog text[J]. Journal of Chinese Information Processing, 2014, 28(5):83-91.
- [31] LI S, ZHAO Z, HU R, et al. Analogical reasoning on Chinese morphological and semantic relations[C]//Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics. Stroudsburg: ACL, 2018:138-143.
- [32] DEMSZKY D, MOVSHOVITZ-ATTIAS D, KO J, et al. GoEmotions: a dataset of fine-grained emotions[C]//Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. Stroudsburg: ACL, 2020:4040-4054.
- [33] KIM Y. Convolutional neural networks for sentence classification[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2014:1746-1751.
- [34] SCHUSTER M, PALIWAL K K. Bidirectional recurrent neural networks[J]. IEEE Transactions on Signal Processing, 1997, 45(11):2673-2681.
- [35] VAN DER MAATEN L, HINTON G. Visualizing data using t-SNE[J]. Journal of Machine Learning Research, 2008, 9(11):2579-2605.
- [36] SONG Y, SHI S, LI J, et al. Directional skip-gram: explicitly distinguishing left and right context for word embeddings [C]//Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics. Stroudsburg: ACL, 2018:175-180.
- [37] JOULIN A, GRAVE E, BOJANOWSKI P, et al. Bag of tricks for efficient text classification[C]//Proceedings of the 15th Conference of the European Chapter of the Association for Computational Linguistics. Stroudsburg: ACL, 2017:427-431.
- [38] TANG D, WEI F, YANG N, et al. Learning sentiment-specific word embedding for Twitter sentiment classification[C]//Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics. Stroudsburg: ACL, 2014:1555-1565.

(编辑:于善清)

(上接第80页)

- [27] VELIČKOVIĆ P, CUCURULL G, CASANOVA A, et al. Graph attention networks[J]. arXiv, 2017. <https://arxiv.org/abs/1710.10903>.
- [28] 张玉帅,赵欢,李博. 基于 BERT 和 BiLSTM 的语义槽填充[J]. 计算机科学, 2021, 48(1):247-252.
ZHANG Yushuai, ZHAO Huan, LI Bo. Semantic slot filling based on BERT and BiLSTM[J]. Computer Science, 2021, 48(1):247-252.
- [29] DEVLIN J, CHANG M W, LEE K, et al. Bert: pre-training of deep bidirectional transformers for language understanding[J/OL]. arXiv, 2018. <https://arxiv.org/abs/1810.04805v2>.
- [30] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J/OL]. arXiv, 2017. <https://arxiv.org/abs/1706.03762v3>.
- [31] 金燕,黄杰. 基于信息熵与词长信息改进的 TFIDF 算法[J]. 浙江工业大学学报, 2021, 49(2):203-209.
JIN Yan, HUANG Jie. Improved TFIDF algorithm based on information entropy and word length information[J]. Journal of Zhejiang University of Technology, 2021, 49(2):203-209.
- [32] 张晟旗,王元龙,李茹,等. 基于局部注意力机制的中文短文本实体链接[J]. 计算机工程, 2021, 47(11):77-83.
ZHANG Shengqi, WANG Yuanlong, LI Ru, et al. Chinese short text entity link based on local attention mechanism[J]. Computer Engineering, 2021, 47(11):77-83.

(编辑:于善清)