

# 基于情感轮和情感词典的文本情感分布标记增强方法

曾雪强 华鑫 刘平生 左家莉 王明文

(江西师范大学计算机信息工程学院 南昌 330022)

**摘要** 情感分布学习是一种近年提出的用于处理存在情绪模糊性的多情绪分析模型,其核心思路是通过情感分布记录示例在各个情绪上的表达程度.不同于传统的单标记或多标记学习,情感分布学习可以定量地对多个情绪同时建模.目前,情感分布学习面临的一个重要困难是缺乏已标注情感分布的文本数据集.为了利用大量已有的单标记情感数据集,情感分布标记增强方法可以将示例的情绪标签增强为情感分布.基于文本中的情感词蕴含着大量情感信息的特点,本文在引入普鲁契克情感轮心理学模型的基础上,提出基于情感轮和情感词典的情感分布标记增强方法(Emotion Wheel and Lexicon based emotion distribution Label Enhancement,EWLLE).EWLLE方法基于情绪的心理距离为句子的真实情绪标签和情感词的情绪标签分别生成离散高斯分布,然后通过分布的叠加将两种信息综合为统一的情感分布.在7个常用的中英文文本情感数据集上的对比实验表明,EWLLE方法在情绪识别任务上的性能优于已有的情感分布标记增强方法.

**关键词** 标记增强;情感轮;情感词典;情感分布学习;情感分析

**中图法分类号** TP391 **DOI号** 10.11897/SP.J.1016.2021.01080

## Emotion Wheel and Lexicon based Text Emotion Distribution Label Enhancement Method

ZENG Xue-Qiang HUA Xin LIU Ping-Sheng ZUO Jia-Li WANG Ming-Wen

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

**Abstract** Emotion Distribution Learning (EDL) is a recently proposed effective multi-emotion analysis model, whose key idea is to handle the emotion fuzziness by associating each instance with an emotion distribution. Each component in an emotion distribution is the expression degree of the corresponding emotion on the given instance. Different from the traditional Single Label Learning or Multi Label Learning, EDL can quantitatively model multiple emotions simultaneously. Nowadays, one of the most critical difficulties of EDL is the lack of emotion distribution marked text datasets. Utilizing the existed single-label emotion datasets in EDL is a possible way to solve this problem, where emotion distribution label enhancement methods can be applied to convert the instances' emotion label to emotion distribution. This paper proposes an Emotion Wheel and Lexicon based emotion distribution Label Enhancement (EWLLE) method by extracting the affective words' emotional information and introducing the prior knowledge of the Plutchik's emotion wheel psychological model. Based on the psychological emotion distances, the EWLLE method generates the discrete Gaussian distributions for the emotion label of the sentence and the emotion labels of affective words respectively. Then, the two kinds of distribution are superposed

收稿日期:2020-08-06;在线出版日期:2021-01-15. 本课题得到国家自然科学基金(61866017,61866018,61876074,61966019)、江西省杰出青年人才资助计划(20171BCB23013)和江西省自然科学基金(20192BAB207027)资助. 曾雪强,博士,教授,博士生导师,中国计算机学会(CCF)高级会员,主要研究领域为标记分布学习、自然语言处理、数据降维. E-mail: xqzeng@jxnu.edu.cn. 华鑫,硕士研究生,主要研究方向为自然语言处理、情感分析. 刘平生,本科生,主要研究方向为中文信息处理. 左家莉,博士,副教授,主要研究方向为信息检索、文本挖掘. 王明文(通信作者),博士,教授,博士生导师,中国计算机学会(CCF)高级会员,主要研究领域为自然语言处理、信息检索. E-mail: mwwang@jxnu.edu.cn.

into a unified emotion distribution. Extensive comparative experiments on 7 commonly used Chinese and English text emotion datasets show that the proposed EWLLE method is superior to the existed emotion distribution label enhancement methods in the emotion recognition task.

**Keywords** label enhancement; emotion wheel; affective lexicon; emotion distribution learning; sentiment analysis

## 1 引言

在机器学习领域中,情感分析是一个应用场景非常广泛的重要研究课题<sup>[1]</sup>,在智能人机交互<sup>[2]</sup>、客户售后服务<sup>[3]</sup>、用户产品推荐<sup>[4]</sup>和在线商品评论分析<sup>[5]</sup>等新兴的人工智能应用中具有良好的运用前景.作为情感分析的子任务,文本情绪识别的任务目标是识别出文本中包含的作者的情绪状态.近几十年来,学者们在文本情绪识别领域做出了大量卓有成效的研究工作<sup>[1,6]</sup>.

文本表达的情感通常是由多种基本情绪(如愤怒、悲伤、恐惧和高兴等)构成的混合表达,各个相关的基本情绪在总的情感表达中都具有一定的贡献<sup>[7]</sup>.传统的文本情绪识别模型经常采用的单标记学习(single label learning),假定每个句子只有一个关联的情绪标签<sup>[8]</sup>.为了解决一个句子同时包含多种情绪的建模任务,基于多标记学习(multi label learning)的情绪识别模型为每个句子关联多个情绪标签<sup>[9]</sup>.但对于情绪标签具有模糊性的多情绪分析任务,多标记学习的建模能力具有明显的不足.在多情绪分析任务中,多标记学习模型可以识别目标句子中包含哪几种情绪,但无法定量地回答各个相关情绪的表达程度分别具体是多少<sup>[10]</sup>.

为了解决这一问题,借鉴标记分布学习(Label Distribution Learning, LDL)<sup>[11]</sup>的研究思路,Zhou 等人于 2015 年针对人脸情绪识别任务提出情感分布学习(Emotion Distribution Learning, EDL)<sup>[7]</sup>.随后,EDL 被应用于文本情绪识别<sup>[12]</sup>.EDL 为每个示例(人脸或句子)关联一个情感分布向量,情感分布的各分量是给定示例在对应情绪上的表达程度(分布中各分量的分值和为 1).EDL 可以定量地处理一个句子同时具有多种情绪的情况,在解决具有情绪标签模糊性的任务时具有明显的优势<sup>[7]</sup>.近年来,学者们提出了多个有效的 EDL 研究工作.例如,Zhou 等人提出一种考虑情绪间约束关系的 EDL 模型<sup>[12]</sup>;Jia 等人提出一种考虑情绪标记局部相关性

的 EDL 方法<sup>[13]</sup>;Zhao 等人提出一种针对小样本基于元学习的 EDL 模型<sup>[14]</sup>;He 等人提出将图卷积神经网络应用于 EDL,并在模型中考虑情绪间的相关性<sup>[15]</sup>;Xiong 等人提出考虑情感极性和情绪标签稀疏性的基于卷积神经网络的 EDL 方法<sup>[16]</sup>;Xu 等人提出一种通过图卷积神经网络和对抗学习策略在特征和标签级别上应用情感标签的分布信息的 EDL 方法<sup>[17]</sup>.这些 EDL 研究工作,表现出了优于传统情绪识别模型的性能.

已有的 EDL 研究工作大部分关注于提出新的预测模型,以提高情绪识别的准确率.但在预测模型的构建之外,EDL 研究工作面临的一个重要困难是缺乏已标注情感分布的文本情感数据集.我们认为出现这个困难主要有两个原因:首先,EDL 被提出的时间还较短,目前专门为 EDL 任务采集的数据集仍然不足;其次,为样本标注情感分布(对所有情绪标签定量打分)的人工成本明显大于传统的情绪标注(标注若干个相关的情绪标签).已有的多情绪定量打分的数据集,可以通过简单的标记归一化转换为 EDL 数据集,但这样的文本情感数据集只有 SemEval<sup>[18]</sup>等少数几个.如果要在 EDL 中利用大量已有的单标记情感数据集,我们需要进行情感分布标记增强(label enhancement).与 LDL 中的情况类似<sup>[19]</sup>,EDL 中标记增强的任务目标是将示例标注的情绪标签增强为情感分布.

目前学者们已提出的有效的情感分布标记增强方法只有两种<sup>[20-21]</sup>,且均存在一定的不足.Yang 等人于 2017 年提出基于 Mikels 情感轮<sup>[22]</sup>的情感分布标记增强方法(Mikels' emotion Wheel based emotion distribution Label Enhancement, MWLE)<sup>[20]</sup>.基于将先验知识引入机器学习模型的研究思路,MWLE 方法利用 Mikels 情感轮模型将情绪标签转换为情感分布.但是,MWLE 是针对人脸情绪识别提出的方法,没有考虑在文本分析中非常重要的情感词(affective words)信息.情感词是带有不同强度情感倾向性的词语<sup>[23]</sup>,一般已基于语言学知识进行了标注.情感词包含大量的情感信息,对文本的情绪识别

非常有效<sup>[23]</sup>. Zhang 等人于 2018 年提出一种基于情感词典的情感分布标记增强方法 (Lexicon based emotion distribution Label Enhancement, LLE)<sup>[21]</sup>. LLE 方法在示例的情绪标签的基础上, 引入情感词信息生成情感分布. 实验结果表明 LLE 方法的性能优于 MWLE 方法<sup>[21]</sup>, 但 LLE 方法的缺点是未考虑情绪间普遍存在的心理学相关性.

针对上述问题, 本研究采用普鲁契克情感轮 (Plutchik's wheel of emotions)<sup>[24]</sup> 计算情绪间的心理学距离, 提出基于情感轮和情感词典的情感分布标记增强方法 (Emotion Wheel and Lexicon based emotion distribution Label Enhancement, EWLLE). 普鲁契克情感轮是罗伯特·普鲁契克于 1980 年提出的一种经典的描述人类情绪之间关系的心理学模型<sup>[24]</sup>. EWLLE 方法基于普鲁契克情感轮为句子情绪标签和情感词的情绪标签分别生成离散高斯分布, 然后通过分布的叠加将它们综合成统一的情感分布. 不同于已有的 EDL 标记增强方法, EWLLE 方法在传统的有监督信息 (句子的情绪标签) 之外, 同时考虑了情绪的心理学知识和情感词的语言学信息. 在 7 个中英文文本情感数据集上的对比实验结果表明, EWLLE 方法在情绪识别任务中的性能优于已有的情感分布标记增强方法. 本文的主要贡献包括以下两点:

(1) 首次同时将心理学和语言学两种先验知识引入情感分布标记增强, 提出一种基于情感轮和情感词典的 EWLLE 方法. EWLLE 方法将单标记文本情感数据集中的情绪标签增强为情感分布, 可以有效地缓解 EDL 任务面临的标注情感分布的数据集不足的问题.

(2) 在 4 个英文文本情感数据集和 3 个中文文本情感数据集上, 将本文提出的 EWLLE 方法与其他情感分布标记增强方法进行充分的对比实验. 实验结果表明 EWLLE 方法在情绪识别任务中的性能优于已有的情感分布标记增强方法.

本文第 2 节介绍情感分布学习和基于情感词典的情感分布标记增强方法; 第 3 节详细描述基于情感轮和情感词典的情感分布标记增强方法; 实验设置、实验结果与分析在第 4 节中说明; 最后第 5 节总结全文, 并对未来工作进行展望.

## 2 相关工作

### 2.1 情感分布学习和情感分布标记增强

与人表情经常呈现复杂情感类似, 文本句子

所表达的情感一般是由多种基本情绪构成的混合表达, 每个相关的基本情绪都在总的情感表达中扮演一定的角色, 所有表达程度不同的基本情绪共同构成情感分布 (emotion distribution)<sup>[7]</sup>. 如图 1 所示, SemEval 文本情感数据集<sup>[18]</sup> 对采集的句子在 6 种基本情绪上的表达程度给出了具体评分. 例如, 悲伤 (Sadness) 是句子 (a) 的主要情绪, 表达程度 39.4%; 同时, 次要情绪恐惧 (Fear) 和愤怒 (Anger) 的表达程度也比较高, 分别为 30.9% 和 16%. 所有的主要情绪和次要情绪共同构成了句子 (a) 的情感表达. 句子 (b) 的多情绪标注情况与句子 (a) 类似.

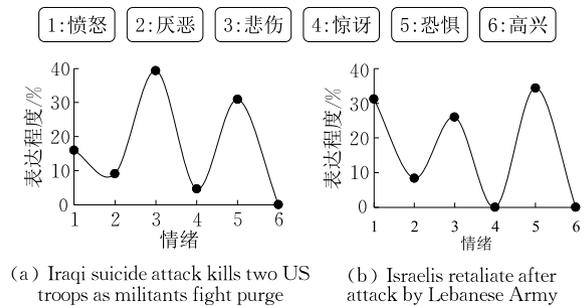


图 1 SemEval 数据集的两个例句及其在 6 种基本情绪上的表达程度

传统的单标记文本情绪识别任务中, 每个句子  $s_i$  有一个对应的情绪标签  $y_i$ ,  $y_i \in \{1, 2, \dots, C\}$ , 其中  $C$  是所有可能的情绪数量. 情感分布学习 (Emotion Distribution Learning, EDL)<sup>[7]</sup> 的建模目标是学习到一个函数将句子  $s_i$  映射为情感分布  $\mathbf{d}_i = \{d_i^j\}_{j=1}^C$ , 其中  $d_i^j$  表示句子  $s_i$  的在第  $j$  种情绪上的表达程度,  $d_i^j \in [0, 1]$  且  $\sum_j d_i^j = 1$ . 与概率分布中假定只有一个标签是正确的条件不同, 情感分布允许一个示例同时具有多个情绪标签. 任意表达程度大于零的情绪对于示例来说都是有效的标签, 只是其重要程度不同.

情感分布学习可以较好地解决具有情绪模糊性的多情绪识别问题<sup>[7]</sup>, 近年来学者们提出了多个有效的 EDL 模型<sup>[13-16, 21]</sup>. 但是在实际应用中, EDL 面临着情感分布的人工标注成本高、训练数据难以获得的问题<sup>[20-21]</sup>. 已有的情感数据集中, 只有少量已进行多情绪定量打分的数据集 (如 SemEval<sup>[18]</sup>) 能通过简单的标记归一化得到 EDL 需要的情感分布. 为了利用大量已有的单标记情感数据集, 我们需要进行情感分布标记增强 (label enhancement).

在 EDL 中, 标记增强的目标是将示例的情绪标签增强为情感分布, 即将训练数据集中句子  $s_i$  的情绪标签  $y_i$  扩展为情感分布  $\mathbf{d}_i = \{d_i^j\}_{j=1}^C$ . 示例的原始情绪标签在生成的情感分布中被称为真实情绪标

签,其表达程度一般是情感分布中的最高值. 如果假设存在一个初始的情感分布,其中真实标签的得分是 1,其他标签的得分是 0;那么,标记增强可以看作是一种对初始情感分布进行各标签间分值调整的方法. 大部分现有标记增强方法的基本思路是,适当降低真实标签的得分并同时提升某些其他标签的表达程度. 不同的标记增强方法的主要区别是标签间的分值调整策略不同<sup>[19]</sup>.

## 2.2 基于情感词典的情感分布标记增强

与一般的 EDL 任务不同,基于文本的 EDL 任务在示例标注的监督信息之外,还可以利用句子文本中包含的情感词信息. 情感词是带有不同强度情感倾向性的词语,通常是基于语言学知识关联到某些情绪标签<sup>[23]</sup>. 一个句子中可以含有若干个情感词,一个情感词可以对应多个情绪标签. 已有研究工作表明情感词包含大量的情绪信息,对句子的情绪识别非常有效<sup>[23]</sup>. 学者们已经提出了多种基于情感词典的情绪识别方法,基本思路是先从句子文本中提取出情感词,再利用情感词的情绪标签对句子的情绪进行预测. 例如, Agrawal 等人使用构造的情感词典对情绪句和非情绪句进行分类<sup>[25]</sup>, Wang 等人提出一种基于情感词典的多约束情绪分类模型<sup>[26]</sup>, Liu 等人提出了基于分类思想的微博新情感词抽取方法<sup>[27]</sup>. 以上基于情感词典的研究工作都取得了不错的效果.

根据文本分析任务的特点,在基于文本的情感分布标记增强模型中引入情感词信息是一种可行的做法. 基于此研究思路, Zhang 等人于 2018 年提出一种基于情感词典的情感分布标记增强方法 (Lexicon based emotion distribution Label Enhancement, LLE)<sup>[21]</sup>. 如图 2 所示,例句的原始情绪标签是愤怒, LLE 方法将愤怒作为主要情绪在生成的情感分布中赋予最高的得分. 同时, LLE 方法通过提取句子文本中的情感词的情绪标签,在情感分布中增加了厌恶、悲伤和恐惧三个次要情绪,它们在情感分布中的得分较低.

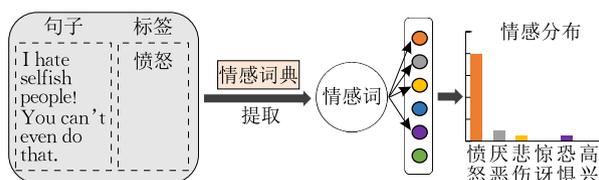


图 2 基于情感词典的情感分布标记增强方法

给定句子  $s_i$  和真实情绪标签  $y_i$ , LLE 方法的具体做法是,首先基于情感词典提取出句子  $s_i$  中的所

有情感词并得到对应的情绪标签集合  $D$ . 然后分为两种情况:如果句子  $s_i$  中没有情感词,情感分布就直接采用 one-hot 向量表示标签  $y_i$ ;否则, LLE 方法先在情感分布中赋予真实情绪标签  $y_i$  某个分值(例如 0.8),再将剩余分数(分值总和为 1)分配给其他有情感词的情绪标签<sup>[21]</sup>.

对于第  $j$  种情绪,当  $j = y_i$  时,按式(1)计算真实情绪标签的分值:

$$d_i^{j=y_i} = \begin{cases} \epsilon, & D/y_i \neq \emptyset \\ 1, & \text{其他} \end{cases} \quad (1)$$

当  $j \neq y_i$  时,按式(2)计算第  $j$  种情绪标签的分值:

$$d_i^{j \neq y_i} = \begin{cases} (1-\epsilon) \frac{|y_j|}{D/y_i}, & D/y_i \neq \emptyset \\ 0, & \text{其他} \end{cases} \quad (2)$$

式中,  $|y_j|$  表示句子中第  $j$  种情绪的情感词数量,  $\epsilon$  是真实情绪标签分值的权重参数. 在计算完所有情绪标签的分值后,通过归一化保证  $\sum_j d_i^j = 1$ .

LLE 标记增强方法在句子的真实情绪标签之外,引入情感词信息生成情感分布. 相对于只考虑句子情绪标签的标记增强方法<sup>[20]</sup>, LLE 方法生成的情感分布具有更好的性能<sup>[21]</sup>. 但是,简单的基于情感词典的方法,并未考虑人类情绪的心理先验知识,即没有利用情绪间存在的高度相关性.

## 2.3 基于多任务卷积神经网络的情感分布学习

情感分布学习通过为每个示例关联一个情感分布,对具有不同表达强度的多个情绪同时进行建模,可以较好地处理具有情绪模糊性的多情绪识别任务<sup>[7,12]</sup>. 在近年来提出的多个有效的 EDL 模型中, Zhang 等人于 2018 年提出的多任务卷积神经网络 (Multi-Task Convolutional Neural Network, MTCNN) 模型<sup>[21]</sup> 是其中性能较好的一种. 与传统的卷积神经网络不同, MTCNN 模型将情感分布预测和情绪标签分类两个学习任务整合在一起,同时进行端到端的优化训练,在实验中表现出了不错的效果.

给定训练数据集  $S = \{(s_i, d_i)\}_{i=1}^N$ , 其中  $N$  是样本数量,  $C$  是情绪数量,  $d_i = \{d_i^1, d_i^2, \dots, d_i^C\}$  是句子  $s_i$  对应的情感分布,  $d_i$  中表达程度最高的情绪是句子  $s_i$  的真实情绪标签. MTCNN 模型的两个任务目标是在预测情感分布  $d_i$  的同时,对句子的真实情绪标签进行分类.

MTCNN 模型采用 4 层神经网络结构,包括输入层、卷积层、最大池化层和损失层. 下面分别加以介绍.

**输入层.** 模型的输入文本是一个由  $M$  个单词构成的句子  $s = \langle w_1, w_2, \dots, w_M \rangle$ , 其中  $w_i$  是第  $i$  个单词,  $i \in \{1, 2, \dots, M\}$ . MTCNN 模型采用较为常用的 word2vec 词嵌入模型<sup>[28]</sup> 将单词  $w_i$  表示为  $\kappa$  维的词嵌入向量  $\mathbf{x}_i \in \mathbb{R}^\kappa$ . 然后, 一个句子的所有词向量被连接起来, 得到一个  $\kappa \times M$  的词嵌入向量矩阵作为模型的输入:

$$\mathbf{x} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_M] \quad (3)$$

其中, 如果句子的长度小于  $M$ , 词嵌入向量矩阵的最后部分填充 0.

**卷积层.** 在词嵌入向量矩阵上, 采用高度为  $h$  的滑动窗口滤波器  $\omega \in \mathbb{R}^{h \times \kappa}$  进行卷积操作, 产生新特征. 例如, 将滤波器  $\omega$  应用于单词窗口  $\mathbf{x}_{p:p+h-1}$  可以生成特征  $v_p$ :

$$v_p = f(\omega \cdot \mathbf{x}_{p:p+h-1} + b) \quad (4)$$

其中,  $f(\cdot)$  是激活函数 (如 sigmoid 或 ReLU 函数),  $b \in \mathbb{R}$  是偏置值,  $\mathbf{x}_{p:p+h-1}$  是由  $h$  个单词  $\mathbf{x}_p, \mathbf{x}_{p+1}, \dots, \mathbf{x}_{p+h-1}$  构成的单词窗口. 那么, 将滤波器  $\omega$  应用于输入句子的所有可能的单词窗口  $\mathbf{x}_{1:h}, \mathbf{x}_{2:h+1}, \dots, \mathbf{x}_{M-h+1:M}$ , 可以得到特征集合  $\mathbf{v}$ :

$$\mathbf{v} = [v_1, v_2, \dots, v_{M-h+1}] \quad (5)$$

**最大池化层.** 在特征集合  $\mathbf{v}$  上应用标准的 max-over-time 池化操作<sup>[29]</sup>, 用于获取其中最重要的特征:

$$\hat{v} = \max(\mathbf{v}) \quad (6)$$

其中,  $\hat{v}$  可以认为是输入样本使用某个滤波器在最大池化操作后的输出特征.

**损失层.** 通过一个包括  $C$  个神经元的全连接层, MTCNN 模型最后会输出一个在所有情绪标签上的概率分布. 基于这个概率分布, MTCNN 模型的目标函数是情绪分类损失  $E_{\text{cls}}$  和情绪分布预测损失  $E_{\text{edl}}$  的加权和.

$$E = (1 - \lambda)E_{\text{cls}}(s, y) + \lambda E_{\text{edl}}(s, \mathbf{d}) \quad (7)$$

其中,  $E_{\text{cls}}$  代表情绪分类效果的交叉熵损失,  $E_{\text{edl}}$  是度量情绪分布预测性能的 KL 损失,  $\lambda$  是控制两种损失的相对权重的参数, 原文中  $\lambda = 0.7$ <sup>[21]</sup>.

MTCNN 模型采用基于交叉熵的  $E_{\text{cls}}(s, y)$  度量情绪分类任务的损失, 具体计算公式如下:

$$E_{\text{cls}}(s, y) = -\frac{1}{N} \left[ \sum_i \sum_j 1(y_i = j) \ln \frac{e^{a_j^{(i)}}}{\sum_l e^{a_l^{(i)}}} \right] \quad (8)$$

其中,  $y_i$  是句子  $s_i$  的真实情绪标签,  $1(\delta)$  是指标函数, 当  $\delta$  为真时  $1(\delta) = 1$ , 否则为 0.  $\{a_j^{(i)} | j = 1, 2, \dots, C\}$  是句子  $s_i$  在最后的连接层的各个单元的激活

值.  $E_{\text{cls}}(s, y)$  是所有训练句子的真实情绪标签的对数似然之和.

对于情感分布预测任务, MTCNN 模型使用 KL 损失 (Kullback-Leibler loss) 度量预测分布和真实分布之间的距离, 具体计算公式如下:

$$E_{\text{edl}}(s, \mathbf{d}) = -\frac{1}{N} \left[ \sum_i \sum_j d_{s_i}^j \ln \frac{e^{a_j^{(i)}}}{\sum_l e^{a_l^{(i)}}} \right] \quad (9)$$

其中,  $d_{s_i}^j$  是句子  $s_i$  的每个标签的损失的和.

MTCNN 模型采用随机梯度下降 (Stochastic Gradient Descent, SGD) 算法进行模型的优化训练. 当预测任务是情绪分类时, MTCNN 模型将最后的全连接层输出的情感分布中表达程度最高的情绪作为预测的句子真实情绪.

### 3 基于情感轮和情感词典的情感分布标记增强

#### 3.1 普鲁契克情感轮

人类的情感是一个复杂的现象, 情绪之间具有明显的相关性. 某些情绪经常会同时出现, 即表现出很高的正相关性; 而另外一些情绪则相反. 罗伯特·普鲁契克于 1980 年提出的情感轮理论, 是一种从心理学角度描述人类情绪间相互关系的经典模型<sup>[24]</sup>. 普鲁契克情感轮 (Plutchik's wheel of emotions) 包含愤怒 (Anger)、厌恶 (Disgust)、悲伤 (Sadness)、惊讶 (Surprise)、恐惧 (Fear)、信任 (Trust)、高兴 (Joy) 和期待 (Expect) 8 种基本情绪. 如图 3 所示, 这 8 种情绪在情感轮中分为 4 组对立的情绪, 对角位置的情绪表现出对立性 (负相关性), 位置相邻的情绪具有相似性 (正相关性).

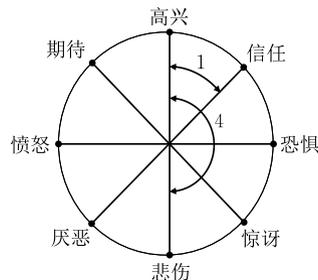


图 3 普鲁契克情感轮

依据普鲁契克情感轮中相邻的情绪具有相似性的特点, 我们定义两种情绪间的距离为其对应的在情感轮中的间隔角度. 间隔角度越小的情绪距离越近, 情绪每间隔  $45^\circ$  距离定义为 1. 例如, 高兴与信

任是两个相邻情绪, 间隔  $45^\circ$ , 对应的距离为 1; 高兴和悲伤是对立情绪, 间隔  $180^\circ$ , 对应的距离为 4. 根据这一距离定义方式, 任意两种不同情绪之间的距离是一个 1 到 4 之间的整数, 同一种情绪之间的距离是 0.

在 EDL 研究领域, 已有一些有效的工作将情感轮作为先验知识使用<sup>[12,20,22]</sup>. Zhou 等人在基于最大熵的 EDL 模型的优化目标中引入基于普鲁契克情感轮的情绪关系约束条件, 取得了不错的效果<sup>[12]</sup>. He 和 Jin 提出一种基于图卷积神经网络和 Mikels 情感轮<sup>[22]</sup> (一种包含 8 种情绪的心理模型, 与普鲁契克情感轮的主要区别是考虑的具体情绪不同) 的 EDL 方法<sup>[15]</sup>.

在情感分布标记增强方面, Yang 等人于 2017 年提出基于 Mikels 情感轮的情感分布标记增强方法 (Mikels' emotion Wheel based emotion distribution Label Enhancement, MWLE)<sup>[20]</sup>. MWLE 方法基于 Mikels 情感轮计算情绪之间的距离, 再采用高斯分布将情绪标签变换为情感分布. 但是, 由于没有利用句子文本中的情感词信息, MWLE 方法的性能劣于 LLE 方法<sup>[21]</sup>. 到目前为止, 还没有研究者提出同时考虑情感心理学先验知识与情感词语言学信息的情感分布标记增强工作.

### 3.2 基于普鲁契克情感轮和情感词典的情感分布标记增强方法

情感分布标记增强的任务目标是, 将句子  $s_i$  的真实情绪标签  $y_i$  扩展为情感分布向量  $\mathbf{d}_i = \{d_i^a\}_{a=1}^C$ . 在情绪标签  $y_i$  之外, 句子文本中包含的情感词也是非常重要的信息<sup>[23]</sup>. 本研究通过引入普鲁契克情感轮中的心理学知识和情感词包含的语言学信息, 提出基于情感轮和情感词典的情感分布标记增强方法 (Emotion Wheel and Lexicon based emotion distribution Label Enhancement, EWLLE). EWLLE 方法基于普鲁契克情感轮上的间隔角度定义情绪间的心理学距离, 并基于此距离为真实情绪标签和情感词的情绪标签分别生成离散高斯分布, 最后将两种标签的分布叠加为统一的情感分布. 不同于已有的标记增强方法, EWLLE 方法综合考虑了情绪的心理和语言学知识, 生成的情感分布包含更多的信息量.

EWLLE 方法通过查找情感词典提取出给定句子  $s_i$  中的所有情感词, 并得到对应的情感词集合  $\mathbf{w}_i = \{\omega_{i,k}\}_{k=1}^{n_i}$ , 其中  $n_i$  是  $s_i$  中情感词的数量. 同时,

每个情感词  $\omega_{i,k}$  有若干个关联的情绪标签  $\{p_{i,k}^t\}_{t=1}^{m_k}$ , 其中  $m_k$  是  $\omega_{i,k}$  的情绪标签数量. 一个句子的文本中可以包含一个或多个情感词, 也可能没有情感词; 每个情感词至少关联一个情绪标签.

给定某个情绪标签  $\alpha, \alpha \in \{1, 2, \dots, C\}$ , 我们认为应该按照以下两个准则生成其对应的情感分布: (1) 情绪标签  $\alpha$  的得分应该是情感分布中的最大值, 以确保真实情绪在分布中的主导地位; (2) 其他情绪的得分应随着离  $\alpha$  的心理学距离的增大而减小, 以使得和真实情绪越相似的情绪在分布中的得分越高. 因为所有的基本情绪在情感轮上构成环状关系, 生成的情感分布应该是一个以真实情绪标签  $\alpha$  为中心并左右对称递减的分布.

基于上述两个准则, EWLLE 方法假设从情绪标签生成的情感分布服从正态分布, 并采用离散高斯分布将情绪标签  $\alpha$  扩展为分布  $f_a = \{f_a^c\}_{c=1}^C$ . 具体而言, 以真实情绪标签  $\alpha$  为中心的离散高斯分布  $f_a$  的计算公式如下:

$$f_a^c = \frac{1}{\sigma \sqrt{2\pi} Z} \exp\left(-\frac{|a-c|^2}{2\sigma^2}\right) \quad (10)$$

$$Z = \frac{1}{\sigma \sqrt{2\pi}} \sum_a \exp\left(-\frac{|a-\alpha|^2}{2\sigma^2}\right) \quad (11)$$

式中,  $\sigma$  是离散高斯分布的标准差,  $Z$  是归一化因子, 使得  $\sum_a f_a^c = 1$ ,  $|a-\alpha|$  是情绪  $a$  与真实情绪  $\alpha$  之间的情感轮距离, 采用 3.1 节介绍的基于普鲁契克情感轮的方式计算. 标准差  $\sigma$  越大, 情绪高斯分布越平坦, 考虑的情绪范围越大; 反之, 考虑的情绪范围越小. 本文实验中离散高斯分布的标准差  $\sigma$  设为 1.

基于式 (10), EWLLE 方法为句子  $s_i$  的真实情绪标签  $y_i$  生成高斯分布  $f_{y_i}$ , 并为每个情感词的情绪标签  $p_{i,k}^t$  生成高斯分布  $f_{p_{i,k}^t}$ . 在此基础上, EWLLE 方法采用式 (12) 将代表两种信息的离散高斯分布  $f_{y_i}$  和  $f_{p_{i,k}^t}$  叠加, 得到综合的情感分布  $\mathbf{d}_i$ .

$$\mathbf{d}_i = \frac{1-\lambda}{n_i} \cdot \sum_{k=1}^{n_i} \sum_{t=1}^{m_k} f_{p_{i,k}^t} + \lambda \cdot f_{y_i} \quad (12)$$

式中,  $n_i$  是句子  $s_i$  的情感词数量,  $m_k$  是句子  $s_i$  的第  $k$  个情感词  $\omega_{i,k}$  的情绪标签数量,  $f_{p_{i,k}^t}$  是情感词  $\omega_{i,k}$  的第  $t$  个情绪标签  $p_{i,k}^t$  的高斯分布,  $f_{y_i}$  是句子情绪标签  $y_i$  的高斯分布, 句子情绪标签  $y_i$  的权重系数  $\lambda$  用于控制分布  $f_{y_i}$  在情感分布  $\mathbf{d}_i$  中的比例. EWLLE 算法的具体步骤如算法 1 所示.

### 算法 1. EWLLE 算法.

输入: training sentence  $s_i$  and its emotion label  $y_i$ ,  
weighting parameter  $\lambda$ , emotion lexicon  $L$

输出: emotion distribution  $d_i$  of  $s_i$

1. Extract all affective words  $\{\omega_{i,k}\}_{k=1}^{n_i}$  from  $s_i$  by looking up  $L$ ;
2. FOR EACH  $\omega_{i,k}$  DO
3. Obtain all emotion labels  $\{p'_{i,k}\}_{t=1}^{m_k}$  of  $\omega_{i,k}$  by looking up  $L$ ;
4. Generate discrete Gaussian distribution  $f_{p'_{i,k}}$  for each  $p'_{i,k}$  by Equation (10);
5. END FOR
6. Generate discrete Gaussian distribution  $f_{y_i}$  for  $y_i$  by Equation (10);

$$7. d_i = \frac{1-\lambda}{\sum_{k=1}^{n_i} m_k} \cdot \sum_{k=1}^{n_i} \sum_{t=1}^{m_k} f_{p'_{i,k}} + \lambda \cdot f_{y_i}$$

句子情绪标签权重系数  $\lambda$  的取值范围是  $[0, 1]$ . 当  $\lambda=1$  时, 代表 EWLLE 方法生成的情感分布只考虑句子的真实情绪标签, 没有利用句子文本中的情感词信息; 与之相反, 当  $\lambda=0$  时, 表示 EWLLE 方法只基于情感词和情感词典生成情感分布, 而没有考虑句子的情绪标签. 本研究将在实验部分进一步讨论参数  $\lambda$  的取值对 EWLLE 方法性能的影响.

## 4 实验结果与分析

### 4.1 实验设置

本文实验采用文本情绪识别任务中常用的 4 个单标记英文集 (TEC、Fairy Tales、CBET 和 ISEAR) 和 3 个单标记中文数据集 (NLP&CC 2013、NLP&CC 2014 和 WEC) 作为实验数据集. TEC 数据集<sup>[30]</sup> 包含 21051 条推文和 6 种情绪标签 (愤怒、厌恶、悲伤、惊

讶、恐惧和高兴). Fairy Tales 数据集<sup>[31]</sup> 包括从儿童故事中摘取的 1204 条英文句子, 每条句子标注 5 种情绪 (愤怒、悲伤、惊讶、恐惧和高兴) 中的 1 种. CBET 数据集<sup>[32]</sup> 采集了包含 9 种情绪共 76860 条推文 (每种情绪采集 8540 条推文). 因有些情绪没有出现在普鲁契克情感轮中, 我们选用了其中 6 种情绪 (愤怒、厌恶、悲伤、惊讶、恐惧和高兴) 共 51240 条推文. ISEAR 数据集<sup>[33]</sup> 包含 7 种情绪和 7666 条句子, 句子的内容是描述不同人在产生某种情绪时的外部环境或个人经历. 本文选用 ISEAR 数据集中的 5 种情绪 (愤怒、厌恶、悲伤、恐惧和高兴) 共 5431 条句子进行实验. 中文数据集 NLP&CC 2013 和 NLP&CC 2014<sup>[34]</sup> 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的公开数据集, 两个数据集均包含 7 种情绪, 即喜爱、愤怒、厌恶、悲伤、惊讶、恐惧和高兴. 因喜爱不在普鲁契克情感轮中, 本文实验没有将其纳入. NLP&CC 2013 和 NLP&CC 2014 数据集分别包含从新浪微博采集的 32185 条句子 (10552 条情绪句和 21633 条无情绪句) 和 45421 条句子 (15690 条情绪句和 29731 条无情绪句). 本文从 NLP&CC 2013 和 NLP&CC 2014 数据集分别选用了 7581 和 11431 条情绪句. WEC (Weibo Emotion Corpus) 数据集<sup>[35]</sup> 是香港理工大学于 2016 年构建的微博情感语料库, 包含 7 种情绪 (喜爱、愤怒、厌恶、悲伤、惊讶、恐惧和高兴). 本文选用 WEC 数据集中的 6 种情绪共 35121 条句子进行实验. 我们在表 1 中列出了所有中英文实验数据集的详细信息, 包括各个情绪的句子数量、全部句子数量和平均每个句子的单词数量.

表 1 中英文实验数据集

数据集	愤怒句子数	厌恶句子数	悲伤句子数	惊讶句子数	恐惧句子数	高兴句子数	全部句子数	平均单词数/句
TEC	1555	761	3830	3849	2816	8240	21051	15.3
Fairy Tales	216	—	264	114	166	444	1204	24.0
CBET	8540	8540	8540	8540	8540	8540	51240	15.0
ISEAR	1087	1081	1083	—	1090	1090	5431	21.7
NLP&CC 2013	1146	2075	1562	472	186	2140	7581	22.9
NLP&CC 2014	1899	3130	2478	820	299	2805	11431	23.3
WEC	4562	4876	14052	1011	661	9959	35121	39.7

英文数据集的文本预处理步骤如下. 首先, 去除标点符号等特殊字符, 仅保留英文字母和数字. 然后, 将所有英文字母转为小写, 并对单词做词干化处理. 最后, 采用开源的预训练 word2vec 词嵌入模

型<sup>[28]</sup> 将单词表示为 300 维的向量. word2vec 模型在 Google News 数据集的大约 1000 亿个词上训练得到, 词典包含大约 300 万个词. 对于中文文本的预处理, 我们首先去除标点符号等特殊字符, 仅保留中文

和数字. 然后, 采用 Jieba 分词工具<sup>①</sup>进行中文分词. 最后, 采用中文预训练词向量模型 Chinese Word Vectors<sup>[36]</sup>将单词表示为 300 维的向量. Chinese Word Vectors 模型包括 85 万个词, 通过在百度百科等中文语料库上的大约 1 亿 3600 万个词上训练得到. 对于词嵌入模型的未登录词, 采用均匀分布  $U^{-1.0, 1.0}$  对其随机初始化. 单词的词嵌入向量在神经网络的训练过程中保持固定. 作为神经网络预测模型的输入, 每个句子均通过预处理转换为一个 300 维的词嵌入矩阵. 句子的最大的单词数设为每个数据集中最长句子的单词数.

实验用的英文情感词典由 NRC<sup>[37]</sup> 和 Emosen-ticnet<sup>[38]</sup> 合并而成. NRC 情感词典包含 14 182 个情感词和 10 种情绪标签. Emosenticnet 词典包含 13 189 个情感词和 6 种情绪标签. 情感词典中的每个情感词标记有 1 个或多个情绪标签. 情感词典合并时, 我们保留了情绪标签交集的 6 种情绪(分别是愤怒、厌恶、悲伤、惊讶、恐惧和高兴), 并将没有标注这 6 种情绪的情感词删除. 对于两个词典共有的情感词, 其对应的情绪标签取为原有标签的并集. 最终, 我们得到 15 603 个英文情感词, 每个情感词平均标注 1.31 个情绪标签. 中文情感词典采用大连理工大学情感词汇文本库<sup>[39]</sup>, 该词典含 27 466 个情感词和 7 种情绪标签. 本文保留了愤怒、厌恶、悲伤、惊讶、恐惧和高兴 6 种情绪, 删除没有这 6 种情绪的情感词, 最终保留 16 358 个中文情感词, 每个情感词标注 1 个情绪标签.

实验设置采用标准的分层十折交叉验证 (stratified 10-fold cross-validation). 具体的实验步骤是将数据集在保持类别比例的前提下平均分成十份, 每一份用作测试集一次, 对应的剩余数据合并作为训练集使用; 如此重复十次. 交叉验证中的每一折都是一次单独的 EDL 情绪识别任务, 其中每一折实验均随机划出训练集的十分之一作为验证集. 为了使实验结果具有可比性, 参与对比的模型采用一致的数据划分. 十次交叉验证的评价指标的平均得分, 用于评价情绪识别模型的最终性能.

情绪识别的评价指标采用 4 种自然语言处理领域的常用指标, 分别是精确率 (precision)、召回率 (recall)、F1 分数 (F1-score) 和准确率 (accuracy). 4 种评价指标的计算公式如下:

$$precision = \frac{TP}{TP + FP} \quad (13)$$

$$recall = \frac{TP}{TP + FN} \quad (14)$$

$$F1 = \frac{2 \times precision \times recall}{precision + recall} \quad (15)$$

$$accuracy = \frac{TP + TN}{A} \quad (16)$$

其中,  $TP$  表示实际标签为真且预测为真的样例数,  $FP$  表示实际标签为假但预测为真的样例数,  $FN$  表示实际标签为真但预测为假的样例数,  $TN$  表示实际标签为假且为假的样例数,  $A$  表示所有样例的总数. 我们对每个情绪标签分别计算以上 4 种评价指标的得分, 然后取各指标在所有情绪标签上的平均值作为最分.

EDL 情绪识别模型, 采用被证明具有较好性能的多任务卷积神经网络 (MTCNN) 模型<sup>[21]</sup>. 在单标记数据集上, 标记增强方法生成的情感分布作为训练样本的监督信息, 与对应的词嵌入矩阵共同用于神经网络的训练. MTCNN 模型预测的情感分布中得分最高的情绪作为情绪识别的预测结果. MTCNN 模型的参数与原文<sup>[21]</sup>一致, 具体设置包括: 采用 3 种窗口大小 (3、4 和 5) 的过滤器, 每种过滤器各 100 个, dropout rate 设为 0.5, batch size 的取值为 50, 损失函数优化采用 SGD 算法, 迭代次数和学习率分别设置为 200 和 0.02.

实验在 1 台联想 PC 上运行, 主要硬件配置为 Intel 酷睿 i7-6700 3.4 GHz 4 核 CPU 和 32 GB 内存. 实验程序采用 Python 语言编码实现, 代码中使用了开源的 Python 机器学习库 Pytorch 1.3.1.

为了考察本文提出的 EWLLE 标记增强方法的性能, 我们进行了三组对比实验, 分别是 4 种标记增强方法在中英文实验数据集上的情绪识别性能对比实验, 句子情绪标签权重系数  $\lambda$  对 EWLLE 方法性能的影响分析实验和 4 种标记增强方法为 10 条具体的中英文例句生成情感分布的比较实验.

#### 4.2 多种情感分布标记增强方法的情绪识别性能对比

为了验证 EWLLE 方法的有效性, 我们对以下 4 种情感分布标记增强方法在中英文文本数据集上进行了对比实验.

(1) One-hot. 对单标记情绪标签直接编码的方法. 将句子的情绪标签编码为 One-hot 向量, 向量长度为所有可能的情绪标签数量. 在 One-hot 向量

① <https://github.com/fxsjy/jieba>

中,真实情绪对应的分量的值为 1,其他分量取值 0.

(2) MWLE. 基于 Mikels 情感轮的标记增强方法. Yang 等人提出的 MWLE 情感分布标记增强方法<sup>[20]</sup>,基于 Mikels 情感轮度量情绪间的心理学距离,再采用高斯分布将句子的情绪标签转换为情感分布. MWLE 方法使用情感心理学先验知识对情绪标签进行变换,但没有利用句子文本中的情感词信息. Yang 等人提出的 MWLE 方法有两个版本,本文选用了其中性能较好的 Implication Constraint 版本. 另外,由于 Mikels 情感轮包含的 8 种情绪与实验数据集标注的情绪差异较大,本文采用普鲁契克情感轮计算 MWLE 方法中情绪间的心理学距离. MWLE 方法中的参数  $\epsilon$  取值 0,高斯分布标准差设为 1.

(3) LLE. 基于情感词典的标记增强方法. Zhang 等人提出的 LLE 标记增强方法<sup>[21]</sup>,同时考虑了句子情绪标签和情感词包含的情绪信息. LLE 方法的主要流程是:在生成的情感分布中先赋予句子情绪标签一定的得分,再对所有其他情绪标签的情感词进行计数并据此进行剩余得分的分配. LLE 可以自动抽取文本中的情感词的语言学知识,但其缺点是没有利用情感词的心理学先验知识. LLE 方法的参数设置与原文一致.

(4) EWLLE. 本文提出的基于普鲁契克情感轮和情感词典的标记增强方法. EWLLE 方法在引入情感心理学先验知识的基础上,从句子的真实情绪标签和情感词的情绪信息生成情感分布. 句子情绪标签权重系数  $\lambda$  在英文和中文数据集上分别设置为 0.8 和 0.3.

参与对比的 4 种情感分布标记增强方法在中英文数据集上的详细实验结果在表 2 中给出. 表 2 记录了采用 MTCNN 作为预测模型,4 种标记增强方法在十折交叉验证实验设置下的情绪识别的精确率 ( $Pre(\%)$ )、召回率 ( $Rec(\%)$ )、F1 分数 ( $F1(\%)$ ) 和准确率 ( $Acc(\%)$ ). 各个数据集上的最好实验结果在表 2 中用粗体标出.

从表 2 的结果可以看出,本文提出的 EWLLE 方法在所有 7 个数据集上取得了比其它标记增强方法总体上更好的结果. 以 ISEAR 英文数据集上的准确率为例,EWLLE 方法的准确率比 LLE 方法高出 2.57%,比 MWLE 方法高出 3.78%,比 One-hot 方法高 5.25%. 以 WEC 中文数据集上的准确率为例,EWLLE 方法的准确率比 LLE 方法高出 2.53%,

表 2 基于 MTCNN 预测模型的 4 种情感分布标记增强方法的情绪识别的精确率、召回率、F1 分数和准确率

数据集	标记增强方法	$Pre/\%$	$Rec/\%$	$F1/\%$	$Acc/\%$
TEC	One-hot	52.32	41.96	43.77	56.74
	MWLE	55.19	42.03	44.16	57.89
	LLE	55.56	42.89	45.85	59.23
	EWLLE	<b>57.33</b>	<b>43.08</b>	<b>47.77</b>	<b>60.76</b>
Fairy Tales	One-hot	72.53	62.01	65.19	69.16
	MWLE	73.25	63.51	65.54	70.83
	LLE	75.45	<b>64.27</b>	66.33	71.51
	EWLLE	<b>77.98</b>	63.56	<b>67.72</b>	<b>73.33</b>
CBET	One-hot	61.33	56.77	57.98	56.74
	MWLE	62.56	58.71	58.19	58.80
	LLE	63.17	58.69	58.28	59.71
	EWLLE	<b>63.72</b>	<b>59.44</b>	<b>59.06</b>	<b>60.38</b>
ISEAR	One-hot	66.78	65.21	64.49	65.46
	MWLE	68.32	66.59	65.84	66.93
	LLE	70.21	67.86	67.78	68.14
	EWLLE	<b>72.89</b>	<b>69.03</b>	<b>68.17</b>	<b>70.71</b>
NLP&CC 2013	One-hot	49.13	41.92	42.59	58.07
	MWLE	59.41	<b>46.68</b>	48.28	60.50
	LLE	58.31	46.36	48.16	61.14
	EWLLE	<b>59.80</b>	46.59	<b>49.09</b>	<b>62.51</b>
NLP&CC 2014	One-hot	53.60	43.21	44.23	58.19
	MWLE	53.12	<b>48.61</b>	50.52	60.03
	LLE	61.45	48.28	50.60	61.61
	EWLLE	<b>61.88</b>	47.40	<b>51.05</b>	<b>62.76</b>
WEC	One-hot	61.28	39.24	42.17	60.55
	MWLE	58.39	42.37	48.13	61.21
	LLE	55.41	42.87	47.16	61.71
	EWLLE	<b>62.45</b>	<b>48.41</b>	<b>52.20</b>	<b>64.24</b>

比 MWLE 方法高出 3.03%,比 One-hot 方法高 3.69%. 相对于 3 种对比模型,除了在 Fairy Tales、NLP&CC 2013 和 NLP&CC 2014 数据集上的召回率指标外,EWLLE 方法在所有 7 个数据集上的 4 个性能指标上均有不同程度的提升. 这一实验结果说明,在使用句子情绪标签和情感词信息生成情感分布之外,引入情感的心理学先验知识有益于显著提高情绪识别性能.

另外,与 Zhang 等人的实验结果一致<sup>[21]</sup>,LLE 方法的性能优于没有利用情感词信息的 MWLE 方法. 这说明在情绪识别任务中,句子文本中的情感词信息具有很高的情绪信息量. 从具体的句子文本中挖掘出的情感词信息的情绪区分度大于从通用的情感心理学模型获得的先验知识. 最后不出意外,由于情感心理学知识和情感词的情绪信息都没有被使用,对句子情绪标签直接编码的 One-hot 方法在实验中表现出了最差的性能.

#### 4.3 句子情绪标签的权重系数 $\lambda$ 对 EWLLE 方法性能的影响

句子情绪标签的权重系数  $\lambda$  是 EWLLE 方法的一个重要参数,用于控制在生成的情感分布中句子

情绪标签相对于情感词的情绪信息的重要程度. 当参数  $\lambda=0$  时,EWLLE 方法只包含情感词信息而不纳入句子情绪标签;而当  $\lambda=1$  时,EWLLE 方法生成的情感分布只包含句子情绪标签信息. 为了分析系数  $\lambda$  对 EWLLE 方法性能的影响,我们将  $\lambda$  的取值从 0 变化到 1(每隔 0.1 取值一次),记录对应的 MTCNN 模型的情绪识别准确率. 在 4 个英文数据集和 3 个中文数据集上具体的实验结果分别如图 4 和图 5 所示.

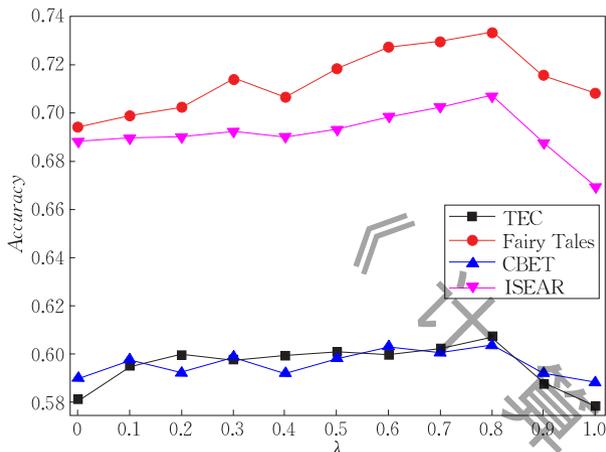


图 4 基于 MTCNN 预测模型,标签权重系数  $\lambda$  变化情况下 EWLLE 方法在 4 个英文数据集上的情绪识别准确率

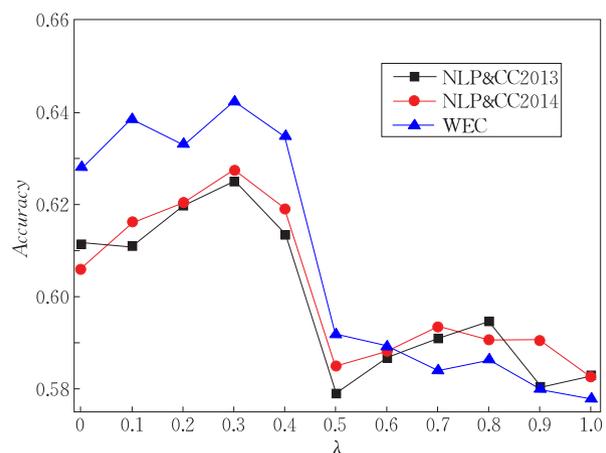


图 5 基于 MTCNN 预测模型,权重系数  $\lambda$  变化情况下 EWLLE 方法在 3 个中文数据集上的情绪识别准确率

从图 4 可以看出,4 个英文数据集表现出了相似的准确率变化趋势. 虽然不同数据集上的情绪识别准确率绝对得分有较大的差异,但都是当  $\lambda=0.8$  时准确率达到最优. $\lambda$  取值在 0 到 0.7 之间时,情绪识别的准确率逐步上升;说明此时增加句子情绪标签的权重是有益的. 当  $\lambda=0.8$  时,情感词和句子情

绪标签的信息量达到平衡,情绪识别准确率获得最优值. 当  $\lambda$  大于 0.8 时,准确率随着  $\lambda$  增大而快速下降;表明当情感词信息不足时标记增强方法的性能会显著降低,句子文本中的情感词信息对情绪识别非常重要.

在中文数据集上,除了参数  $\lambda$  的最优阈值与英文数据集不同,图 5 中的 3 条准确率曲线表现出了相似的变化趋势. 当  $\lambda$  取值在 0 到 0.3 之间时,情绪识别的准确率逐步上升,并当  $\lambda=0.3$  时达到最优值. 当  $\lambda$  取值在 0.3 到 0.5 之间时,识别准确率快速下降;说明此时增加句子情绪标签的权重显著不利于模型性能的提升. 当  $\lambda$  取值大于 0.5 时,3 个数据集的情绪识别准确率曲线都在较低的水平波动. 也就是说,当句子情感标签的权重大于情感词信息的权重时,EWLLE 方法在 3 个中文数据集上都表现较差. 我们认为这可能是因为中文数据集上的句子情绪标签的标注质量较差,单标记情绪标签不能很好地描述中文句子中蕴含的情感.

另外从图 4 和图 5 可以发现,所有 7 个实验数据集上的最优情绪识别准确率( $\lambda=0.8$  或  $\lambda=0.3$ ) 都显著高于当  $\lambda=0$ (只考虑情感词信息)或  $\lambda=1$ (只考虑句子的情绪标签)时的情况. 这说明,为了提升对文本的情绪预测准确率,EDL 标记增强方法在生成情感分布的过程中同时考虑句子级和单词级的情感词的情绪标签信息是有必要的.

#### 4.4 多种标记增强方法为中英文例句生成的情感分布对比

为了详细比较 4 种情感分布标记增强方法生成的情感分布的具体区别,我们从中英文实验数据集中选出 10 条有代表性的例句进行情感分布的对比实验. 选出的例句分别用 One-hot、MWLE、LLE 和 EWLLE 标记增强方法生成情感分布,具体的对比结果如表 3 所示. 表 3 的左侧列出中英文例句的原始文本及其情绪标签和所有情感词及其情绪标签,4 种标记增强方法为该例句生成的情感分布在表 3 的右侧给出. 例句中的情感词用粗体标出,情感分布中的真实情绪标签用蓝色标出.

如表 3 所示,One-hot 方法生成的情感分布是单标记标签的简单转换,只包含句子情绪标签的信息. 根据 4.2 节的实验结果,One-hot 生成的情感分布在情绪识别任务中表现出了较差的性能.

表 3 4 种情感分布标记分布方法对中英文例句生成的情感分布对比(句子文本中的情感词用粗体标出,情感分布中的真实情绪标签用蓝色标出,情绪标签 1:愤怒,2:厌恶,3:悲伤,4:惊讶,5:恐惧,6:高兴)

序号	句子文本及其标签	情感词及其标签	生成的情感分布			
			One-hot	MWLE	LLE	EWLLE
1	I <b>just</b> <b>absolutely</b> <b>lost</b> my <b>mind</b> . 标签: 1	just: 6 absolutely: 6 lost: 3 mind: 6				
2	<b>People</b> are more likely to <b>die</b> in <b>hospital</b> at <b>the weekend</b> . 标签: 5	people: 6 die: 3, 5 hospital: 3, 5 the: 6 weekend: 6				
3	I'm <b>exhausted</b> <b>but</b> can't sleep, I <b>just</b> <b>want</b> my <b>nap</b> . 标签: 3	exhausted: 3 but: 6 just: 6 want: 6 nap: 6				
4	Packing to <b>leave</b> tomorrow. 标签: 3	leave: 3, 4				
5	4 of 6 speedways in Midland don't <b>have</b> pizza. 标签: 1	have: 6				
6	Arabic coursework <b>deadline</b> extended by a week. 标签: 4	deadline: 5				
7	我总让那些 爱我的人生 气,对不起 标签: 3	生气: 2 对不起: 3				
8	没人会干涉 你的选择,但 活得 <b>坦然</b> 点不好吗? 标签: 2	干涉: 2 坦然: 6				
9	I don't want to walk 2 km everyday especially in the winter 标签: 1	want: 6, everyday: 3, 4 the: 6 winter: 6				
10	你总问我为 什么不 <b>高兴</b> , 是的就是这 句弄得我更 不 <b>高兴</b> 标签: 2	高兴: 6				

MWLE 方法生成的情感分布在句子的真实情绪之外, 添加了多个与真实情绪心理学距离较近的次要情绪. 在情感分布中, 最主要的句子真实情绪的分值最高, 其他次要情绪的分值随着其与真实情绪的距离递减. 通过引入基于情感轮的心理学知识, MWLE 可以补充原始单标记情绪标签的信息量的不足. 但是, 通用的心理学模型缺乏针对性, MWLE 难以考虑各个句子的具体情况. 例如, MWLE 为例句 4 生成的情感分布中两个与真实情绪悲伤最近的次要情绪厌恶和惊讶的分值相同; 但是通过人工分析句子文本, 惊讶的表达程度应该大于厌恶. 另外, MWLE 不能处理句子中包含与真实情绪距离较远的次要情绪的情况. 例如, 例句 3 的真实情绪是悲伤, 但也包含与悲伤对立的次要情绪高兴; 此时, MWLE 为例句 3 生成的情感分布中基本不包含高兴情绪. 中文数据集也存在类似的情况, 例如, MWLE 不能为例句 8 引入与真实情绪距离较远的次要情绪高兴.

LLE 方法通过提取句子文本中的情感词, 在以真实情绪标签为主要情绪的情感分布中增加情感词对应的情绪标签. 从句子文本中自动提取的基于情感词的语言学信息, 是句子情绪标签很好的补充. 但是 LLE 不能考虑与句子真实情绪心理上相近的次要情绪. 例如, 例句 1 的真实情绪是愤怒, LLE 为其补充了次要情绪高兴和悲伤, 但是没有引入与愤怒相近的次要情绪厌恶. 从 4.2 节的实验结果看, LLE 基于给定句子文本提取的个性化的情感词信息比 MWLE 采用的基于通用心理学模型的先验知识对情绪识别任务更为有效.

另外从表 3 可以看出, 与 MWLE 中次要情绪的分值总和一般是 0.5 左右不同, LLE 中次要情绪的分值和只有 0.2 左右. 这是因为 LLE 方法通过句子真实情绪权重参数  $\epsilon$  (原文中  $\epsilon = 0.8^{[21]}$ ), 控制次要情绪的分值总和. 我们认为 LLE 赋予次要情绪较低分值的主要原因, 是通过情感词自动抽取的情绪标签有时会有明显的偏差. 例如, 例句 5 的真实情绪是愤怒, LLE 通过情感词 have 引入了次要情绪高兴; 但是通过对句子文本的人工分析, 该句不应该包含高兴情绪. 与 LLE 方法不同, MWLE 方法通过心理学模型引入的次要情绪虽然也可能存在偏差, 但其与真实情绪的心理学距离较近. 人们对句子文本表达的情绪的解读存在一定的模糊性, 引入与真实情绪心理学距离较近的次要情绪较为符合人们的实际感受.

本文提出的 EWLLE 方法同时考虑了基于情感轮的心理学知识和通过情感词抽取的语言学信息, 生成的情感分布更为合理. 例如, 英文例句 1 的真实情绪是愤怒, EWLLE 既为其引入了心理学距离较近的次要情绪厌恶、悲伤和高兴, 同时基于抽取的情感词信息调高了次要情绪高兴的分值. 中文例句 7 的情况与例句 1 类似, EWLLE 在句子真实情绪悲伤之外适当引入了厌恶、惊讶和愤怒等次要情绪. 总体而言, EWLLE 生成的情感分布具有比 MWLE 和 LLE 更好的合理性, 本文 4.2 节的实验结果也说明 EWLLE 方法在情绪识别实验中具有更优的性能.

但是, EWLLE 方法也存在一定的局限性, 无法在生成的情感分布中考虑否定词问题. 例如, 例句 9 的真实情绪标签是愤怒, 由情感词引入的次要情绪包括高兴、悲伤和惊讶, 其中高兴的分值最高. 但是由于例句 9 中存在否定词 don't, 我们实际上应该将情感词包含的高兴情绪, 转换为与之相反的愤怒情绪后再引入. 因为 EWLLE 不能识别否定词 don't, 也就不可能基于否定词对情感词的情绪进行反向变换. 与例句 9 类似, EWLLE 在中文例句 10 上也不能识别带有否定词的高兴情绪. 由于 EWLLE 在中文数据集上赋予情感词信息的权重较高, 例句 10 的情感分布中高兴情绪的分值比真实情绪厌恶更高, 即由否定词带来的错误情绪问题更为明显.

目前, 学者们已提出的几种情感分布标记增强方法均不能正确识别否定词或处理否定情绪. 在下一步的研究中, 我们将尝试在标记增强方法中增加否定词的识别功能, 在引入情感轮和情感词的情绪信息时解决由否定词带来的否定情绪问题.

## 5 结束语

作为一种新兴的解决情绪模糊性的多情绪分析模型, 情感分布学习面临着标注情感分布的训练数据集严重不足的问题. 情感分布标记增强是解决这个问题的一种有效方法, 但现有的标记增强方法的性能仍有待提高. 本文提出了一种基于情感轮和情感词典的情感分布标记增强方法 (Emotion Wheel and Lexicon based emotion distribution Label Enhancement, EWLLE), 用于将单标记文本情感数据集中的情绪标签增强为情感分布. EWLLE 方法基于普鲁契克情感轮心理学模型为句子的真实情绪标签和情感词的情绪标签分别生成离散高斯分布,

然后将两种高斯分布叠加为统一的情感分布. 不同于已有的标记增强模型, EWLLE 方法综合考虑了情感心理学知识和情感词的语言学信息. 实验结果表明, EWLLE 方法在情绪识别任务上的性能优于已有的情感分布标记增强方法.

在下一步的工作中, 我们将考虑在情感分布标记增强方法中引入其他的情感先验知识, 并尝试多种不同的情感建模方式以更有效地利用先验知识. 另外, 在标记增强方法中识别否定词并合理引入相应的否定情绪, 也是我们在未来工作中需要研究的问题.

### 参 考 文 献

- [1] Yadollahi A, Shahraki A G, Zaiane O R. Current state of text sentiment analysis from opinion to emotion mining. *ACM Computing Surveys*, 2017, 50(2): 1-33
- [2] Zhou H, Huang M, Zhang T, et al. Emotional chatting machine: Emotional conversation generation with internal and external memory//*Proceedings of the 32nd AAAI Conference on Artificial Intelligence*. New Orleans, USA, 2018: 730-739
- [3] Jain M C, Kulkarni V Y. TexEmo: Conveying emotion from text—The study. *International Journal of Computer Applications*, 2014, 86(4): 43-49
- [4] Zhang Yi-Hao, Zhu Xiao-Fei, Xu Chuan-Yun, Dong Shi-Du. Hybrid recommendation approach based on deep sentiment analysis of user reviews and multi-view collaborative fusion. *Chinese Journal of Computers*, 2019, 42(6): 1316-1333 (in Chinese)  
(张宜浩, 朱小飞, 徐传运, 董世都. 基于用户评论的深度情感分析和多视图协同融合的混合推荐方法. *计算机学报*, 2019, 42(6): 1316-1333)
- [5] Rao Y, Xie H, Li J, et al. Social emotion classification of short text via topic-level maximum entropy model. *Information and Management*, 2016, 53(8): 978-986
- [6] He Yan-Xiang, Sun Song-Tao, Niu Fei-Fei, Li Fei. A deep learning model enhanced with emotion semantics for microblog sentiment analysis. *Chinese Journal of Computers*, 2017, 40(4): 773-790 (in Chinese)  
(何炎祥, 孙松涛, 牛菲菲, 李飞. 用于微博情感分析的一种情感语义增强的深度学习模型. *计算机学报*, 2017, 40(4): 773-790)
- [7] Zhou Y, Xue H, Geng X. Emotion distribution recognition from facial expressions//*Proceedings of the 23rd ACM International Conference on Multimedia*. Seattle, USA, 2015: 1247-1250
- [8] Abdul-Mageed M, Ungar L. EmoNet: Fine-grained emotion detection with gated recurrent neural networks//*Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics*. Vancouver, Canada, 2017: 718-728
- [9] Yu J, Marujo L, Jiang J, et al. Improving multi-label emotion classification via sentiment classification with dual attention transfer network//*Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing*. Brussels, Belgium, 2018: 1097-1102
- [10] Gao B B, Xing C, Xie C W, et al. Deep label distribution learning with label ambiguity. *IEEE Transactions on Image Processing*, 2017, 26(6): 2825-2838
- [11] Geng X. Label distribution learning. *IEEE Transactions on Knowledge and Data Engineering*, 2016, 28(7): 1734-1748
- [12] Zhou D, Zhang X, Zhou Y, et al. Emotion distribution learning from texts//*Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing*. Austin, USA, 2016: 638-647
- [13] Jia X, Zheng X, Li W, et al. Facial emotion distribution learning by exploiting low-rank label correlations locally//*Proceedings of the 2019 IEEE Conference on Computer Vision and Pattern Recognition*. Long Beach, USA, 2019: 9833-9842
- [14] Zhao Z, Ma X. Text emotion distribution learning from small sample: A meta-learning approach//*Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing*. Hong Kong, China, 2019: 3957-3967
- [15] He T, Jin X. Image emotion distribution learning with graph convolutional networks//*Proceedings of the 2019 on International Conference on Multimedia Retrieval*. Ottawa, Canada, 2019: 382-390
- [16] Xiong H, Liu H, Zhong B, Fu Y. Structured and sparse annotations for image emotion distribution learning//*Proceedings of the 33rd AAAI Conference on Artificial Intelligence*. Honolulu, USA, 2019: 363-370
- [17] Xu Z, Wang S, Wang C. Exploiting multi-emotion relations at feature and label levels for emotion tagging//*Proceedings of the 28th ACM International Conference on Multimedia*. Seattle, USA, 2020: 2955-2963
- [18] Strapparava C, Mihalcea R. Semeval-2007 task 14: Affective text//*Proceedings of the 4th International Workshop on Semantic Evaluations*. Prague, Czech Republic, 2007: 70-74
- [19] Xu N, Liu Y, Geng X. Label enhancement for label distribution learning. *IEEE Transactions on Knowledge and Data Engineering*, 2019, on-line published
- [20] Yang J, She D, Sun M. Joint image emotion classification and distribution learning via deep convolutional neural network//*Proceedings of the 26th International Joint Conference on Artificial Intelligence*. Melbourne, Australia, 2017: 3266-3272
- [21] Zhang Y, Fu J, She D, et al. Text emotion distribution learning via multi-task convolutional neural network//*Proceedings of the 27th International Joint Conference on Artificial Intelligence*. Stockholm, Sweden, 2018: 4595-4601
- [22] Mikels J A, Fredrickson B L, Larkin G R, et al. Emotional category data on images from the international affective picture system. *Behavior Research Methods*, 2005, 37(4): 626-630

- [23] Teng Z, Vo D T, Zhang Y. Context-sensitive lexicon features for neural sentiment analysis//Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing. Austin, USA, 2016: 1629-1638
- [24] Plutchik R. A General Psychoevolutionary Theory of Emotion. New York: Academic Press, 1980
- [25] Agrawal A, An A. Unsupervised emotion detection from text using semantic and syntactic relations//Proceedings of the 2012 IEEE/WIC/ACM International Conferences on Web Intelligence and Intelligent Agent Technology. Washington, USA, 2012: 346-353
- [26] Wang Y, Pal A. Detecting emotions in social media: A constrained optimization approach//Proceedings of the 24th International Conference on Artificial Intelligence. Buenos Aires, Argentina, 2015: 996-1002
- [27] Liu De-Xi, Nie Jian-Yun, Wan Chang-Xuan, et al. A classification based sentiment words extracting method from microblogs and its feature engineering. Chinese Journal of Computers, 2018, 41(7): 1574-1597(in Chinese)  
(刘德喜, 聂建云, 万常选等. 基于分类的微博新情感词抽取方法和特征分析. 计算机学报, 2018, 41(7): 1574-1597)
- [28] Mikolov T, Sutskever I, Chen K, et al. Distributed representations of words and phrases and their compositionality//Proceedings of the 26th International Conference on Neural Information Processing Systems. Lake Tahoe, USA, 2013: 3111-3119
- [29] Kim Y. Convolutional neural networks for sentence classification//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing. Doha, Qatar, 2014: 1746-1751
- [30] Mohammad S M. # Emotional tweets//Proceedings of the 1st Joint Conference on Lexical and Computational Semantics. Montreal, Canada, 2012: 246-255
- [31] Alm C O, Sproat R. Emotional sequencing and development in fairy tales//Proceedings of the 1st International Conference on Affective Computing and Intelligent Interaction. Beijing, China, 2005: 668-674
- [32] Shahraiki A G. Emotion Mining from Text[M. S. dissertation]. University of Alberta, Alberta, 2015
- [33] Scherer K R, Wallbott H G. Evidence for universality and cultural variation of differential emotion response patterning. Journal of Personality and Social Psychology, 1994, 66(2): 310-328
- [34] Yao Yuan-Lin, Wang Shu-Wei, Xu Rui-Feng, et al. The construction of an emotion annotated corpus on microblog text. Journal of Chinese Information Processing, 2014, 28(5): 83-91(in Chinese)  
(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. 中文信息学报, 2014, 28(5): 83-91)
- [35] Li M, Long Y, Qin L, Li W. Emotion corpus construction based on selection from hashtags//Proceedings of the 10th International Conference on Language Resources and Evaluation. Portoro, Slovenia, 2016: 1845-1849
- [36] Li S, Zhao Z, Hu R, et al. Analogical reasoning on Chinese morphological and semantic relations//Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics. Melbourne, Australia, 2018: 138-143
- [37] Mohammad S M, Turney P D. NRC emotion lexicon. National Research Council Canada, Ottawa: Technical Report; 2009-94, 2013
- [38] Poria S, Gelbukh A, Cambria E, et al. EmoSentSpace: A novel framework for affective common-sense reasoning. Knowledge-Based Systems, 2014, 69(1): 108-123
- [39] Xu Lin-Hong, Lin Hong-Fei, Pan Yu, et al. Constructing the affective lexicon ontology. Journal of the China Society for Scientific and Technical Information, 2008, 27(2): 180-185(in Chinese)  
(徐琳宏, 林鸿飞, 潘宇等. 情感词汇本体的构造. 情报学报, 2008, 27(2): 180-185)



**ZENG Xue-Qiang**, Ph. D. , professor, Ph. D. supervisor. His research interests include label distribution learning, natural language processing and dimension reduction.

**HUA Xin**, M. S. candidate. His research interests include natural language processing and emotion analysis.

**LIU Ping-Sheng**, B. E. His research interest is Chinese information processing.

**ZUO Jia-Li**, Ph. D. , associate professor. Her research interests include information retrieval and text mining.

**WANG Ming-Wen**, Ph.D. , professor, Ph.D. supervisor. His research interests include natural language processing and information retrieval.

## Background

Emotion Distribution Learning (EDL) is a recently proposed multi-emotion analysis task, which aims to determine

an emotion distribution for a sentence rather than a single label. However, emotion labels are crisp in most existing

emotion datasets. Label enhancement aims to convert traditional emotion labels into emotion distributions.

In this paper, we propose a novel Emotion Wheel and Lexicon based emotion distribution Label Enhancement (EWLLE) method, which calculates the psychological distances between emotions according to the Plutchik's emotion wheel and utilizes the linguistic information of affective words from some classical lexicons. The Plutchik's wheel of emotions is a well-known psychological model proposed by Robert Plutchik in 1980 to describe human emotional relationships. EWLLE exploit the Plutchik's wheel of emotions to determine similarities between different emotions through Gaussian distribution. For a given sentence, based on psychological emotion distances, EWLLE generates discrete Gaussian distribution of the sentence emotion label and the affective words' emotion labels, and then superposes them into a unified emotion distribution. Different from

existing EDL label enhancement methods, EWLLE takes into consideration the psychological and linguistic emotional knowledge at the same time during the label enhancement procedure. Extensive experiments on text emotion datasets demonstrate that EWLLE performs favorably against the state-of-the-art approaches to text emotion recognition. Our research belongs to the project of the National Natural Science Foundation of China (No. 61866018), whose name is "Text Mining Method for Difangzhi Combing External Resources". Text emotion analysis is one of research contents of this project. Besides, this work is partially supported by the National Natural Science Foundation of China (Nos. 61866017, 61876074, 61966019), the Support Program for Outstanding Youth Talents in Jiangxi Province (No. 20171BCB23013) and the Natural Science Foundation of Jiangxi Province (No. 20192BAB207027).

计算机学报