

文章编号: 1003-0077(2021)06-0085-08

基于 ECPA 神经网络的情绪原因识别方法

刁宇峰^{1,2}, 杨亮¹, 林鸿飞¹, 樊小超^{1,3}, 吴迪¹, 任璐¹, 张冬瑜¹, 许侃¹

(1. 大连理工大学 计算机科学与技术学院, 辽宁 大连 116024;

2. 内蒙古民族大学 计算机科学与技术学院, 内蒙古 通辽 028043;

3. 新疆师范大学 计算机科学与技术学院, 新疆 乌鲁木齐 830054)

摘要: 情绪原因识别是文本情绪分析领域中的一个前沿研究方向。传统情绪原因识别方法需要进行规则制定、抽取特征,而该文从情绪原因的语言特点出发,结合 Bi-LSTM 模型和注意力机制,提出一种基于情绪上下文位置注意力神经网络的情绪原因识别方法(ECPA)。该方法考虑了情绪词和情绪类别中的情绪信息,学习了 Bi-LSTM 模型建模后的上下文语义信息,引入了基于位置信息的注意力机制模型,进而构建情绪原因识别模型。实验结果证明,该方法在情绪原因识别任务中的有效性,并取得了目前最优的性能,同时对情绪归因方法具有一定的指导作用。

关键词: 情绪原因识别; Bi-LSTM; 注意力机制; 情绪信息; 位置信息

中图分类号: TP391

文献标识码: A

Emotion Cause Recognition Based on Emotion Context Position Attention(ECPA) Neural Network

DIAO Yufeng^{1,2}, YANG Liang¹, LIN Hongfei¹, FAN Xiaochao^{1,3},
WU Di¹, REN Lu¹, ZHANG Dongyu¹, XU Kan¹

(1. School of Computer Science and Technology, Dalian University of Technology, Dalian,

Liaoning 116024, China;

2. School of Computer Science and Technology, Inner Mongolia University for Nationalities, Tongliao,

Inner Mongolia 028043, China;

3. School of Computer Science and Technology, Xinjiang Normal University, Urumqi, Xinjiang 830054, China)

Abstract: Emotion cause recognition is a new research issue in the field of text emotion analysis. Based on linguistic characteristic of emotion cause, we propose an emotion cause recognition method by emotion context position attention neural network(ECPA). This method considers emotion information such as emotion and category embedding, applies Bi-LSTM to capture context semantic information, and imports a position-based attention mechanism to recognize emotion cause. The experimental results demonstrate the effectiveness of our proposed model, which achieves better performance than state-of-the-art models.

Keywords: emotion cause recognition; Bi-LSTM; attention mechanism; emotion; position

0 引言

文本情绪分析是近几年自然语言处理领域非常重要的研究方向之一,主要研究文本所蕴含的情绪以及情绪有关的深层语义信息。王蓉等人^[1]采用词

袋模型表示文本特征,使用联合学习的方法进行文本情绪分类。使用深度学习的情绪分类方法也有很多,如张志华^[2]、Yaqi Wang^[3]等,均采用卷积神经网络进行句子级的建模,取得了较好的性能。对于文本的情绪分析任务,需要更深层次地挖掘语义信息,用以提升分析的性能。情绪原因识别任务作为

收稿日期: 2019-08-01 定稿日期: 2019-09-15

基金项目: 国家自然科学基金(61632011,62006130,61702080,61602079,61602078);中央高校基本科研业务费专项资金(DUT18ZD102);中国博士后科学基金(2018M631788)

文本情绪分析领域的一个前沿研究方向,越来越受到学者们的关注。

情绪原因识别是指给定一个文本中出现的特定人物的情绪,通过有效技术手段抽取出特定人物情绪产生的原因。众所周知,互联网是一个方便创建信息和传播观点的在线交流平台,人们可以踊跃地分享其观点和情绪。伴随着网络平台的广泛应用,人们越来越关注情绪产生的动机和根源,例如,苹果公司对其旗下产品口碑好坏与否的原因格外关注,以便更好地理解用户的需求和完善产品的性能;又如心理医生对病人产生各种情绪的原因格外关心,这样可以方便医生更好地了解病人的病情和制定治疗方案。因此,情绪原因识别任务在现实中有着广泛的应用场景。

早期关于情绪原因识别的研究主要采用基于规则和统计的方法^[4-6]。随着深度学习在自然语言处理中的广泛应用,有许多学者将深度学习应用在识别情绪原因的任务上。慕永利等人^[7]通过融合多个 CNN 的方法来识别情绪原因任务,Gui 等人^[8]提出一种改进的深度记忆网络模型 ConvMS-Memnet,用它来抽取情绪原因,取得了较好的分类性能。由此可见,神经网络模型可以有效地帮助识别情绪原因。

本文针对文本情绪原因识别任务,在 Bi-LSTM^[9]和 Attention^[10]注意力机制的基础之上,提出一种 ECPA 神经网络的情绪原因识别方法。该模型考虑情绪词和情绪类别对识别情绪原因的影响,利用 Bi-LSTM 对句子的上下文进行建模,同时引入结合相对位置和绝对位置的注意力机制,识别文本中的情绪原因。实验结果表明,本文提出的 ECPA(emotion context position attention Bi-LSTM neural network)方法取得了最佳的分类性能。

1 相关工作

针对文本情绪分析,首先需要了解情绪的分类体系。目前有很多文本情绪分类体系,如 Ekman^[11]、Linhong Xu 等^[12]均提出了不同的情绪分类框架。在本文的情绪原因识别任务上,采用 Ekman 在 1984 年提出的情绪分类体系,该体系在 W3C 的情绪标记语言的基础上,设置了六大类情绪,如 sadness、anger、fear、disgust、surprise 和 happiness。目前大多数的中文情绪分析都使用上述的情绪分类体系。而对于文本情绪分类任务大多使用深度学习方法进

行处理,如张志华^[2]、Yaqi Wang^[3]等,采用卷积神经网络进行建模,取得了较好的效果。目前 Bi-LSTM 模型^[9]、Attention 模型^[10]、CNN 模型^[13]等神经网络模型在自然语言处理的各项任务中均取得了不错的分类性能。

针对情绪原因识别任务,研究者主要采用基于规则、基于统计和基于深度学习的方法。对于基于规则的情绪原因识别方法,例如, Sophia Yat Mei Lee 等人^[4]建立了一个情绪归因语料库,同时根据规则来识别情绪原因句子; Kai Gao 等人^[5]提出的基于规则的情绪原因识别模型主要基于对微博数据抽取情绪原因; Weiyuan Li 等人^[6]使用基于规则的情绪原因特征进行情绪分类。然而这些方法制定的规则难以覆盖所有的语言现象,容易造成规则冲突。对于基于统计的情绪原因识别方法,例如,李逸薇等人^[14]将情绪原因识别任务看作序列标注问题,着重考虑上下文特征,标记出哪些句子是情绪原因句; Gui 等人^[15]通过建立规则和分类两种不同的方式来预测文本的情绪原因; Gui 等人^[16]在构建的情绪原因语料库上,考虑多核函数、词性等信息训练情绪原因分类器;但是统计方法难以挖掘到更深层的潜在语义信息。对于基于深度学习的情绪原因识别方法,例如,慕永利等人^[7]提出一种 E-CNN 的方法来识别情绪原因,同时结合了语言结构; Gui 等人^[8]提出一种改进的深度记忆网络模型 ConvMS-Memnet,着重考虑了深层的记忆网络,并利用了上下文卷积的思想。

综上所述,针对基于规则、基于统计和基于深度学习的方法,三者均利用语言现象有效地识别情绪原因。基于此,本文提出一种基于 ECPA 神经网络的端到端情绪原因识别模型,它主要利用 Bi-LSTM 和注意力机制,同时融合了情绪、上下文、位置等语义信息,进行情绪原因识别。

2 基于 ECPA 的情绪原因识别方法

本文首先对情绪原因识别任务进行了相关的介绍,然后介绍本文提出的情绪原因识别神经网络模型 ECPA,最后介绍本模型的训练方式。

2.1 情绪原因识别任务介绍

Gui 等人^[16]首次提出了情绪原因识别的任务,本文将该任务形式化地描述为:给定一个包含情绪的文档 D ,包括情绪词 E 和该情绪产生的原因。该

文档 D 被手动分割成多个子句 $c, D = \{c_{-3}, \dots, c_{-1}, c_0, c_1, c_2, \dots, c_m\}$, 子句由逗号、问号、感叹号、句号进行分割。对于任一子句 $c = \{w_1, w_2, \dots, w_n\}$ 包含 n 个词, 情绪原因识别任务主要在于识别哪个子句中包含情绪原因。子句示例信息如表 1 所示, 同时, 本文给出数据集中关于情绪子句的情绪分布和位置分布的统计信息, 具体如表 2 和表 3 所示。

表 1 情绪原因识别示例表

子句位置	子句信息	标签
c_{-3}	当日的见面中,	0
c_{-2}	跟中新社记者谈起建言献策的初衷,	1
c_{-1}	白金跃陷入回忆,	0
c_0	并略显激动。	0
c_1	那天的采访,	0
c_2	进行了很久很久,	0
c_3	结束的时候已经天黑了。	0

表 2 情绪类别信息分布表

情绪类别	数量	比例/%
Happiness (高兴)	544	25.83
Sadness (悲伤)	546	26.94
Fear (恐惧)	379	18.00
Anger (愤怒)	302	14.35
Disgust (厌恶)	225	10.69
Surprise (惊奇)	88	4.18

表 3 情绪原因与情绪表达相对位置信息分布表

位置	数量	比例/%
前三个子句	37	1.71
前两个子句	167	7.71
前一个子句	1 180	54.45
同一个子句	511	23.58
后一个子句	162	7.47
后两个子句	48	2.22
后三个子句	11	0.51
其他	42	1.94

其中, 表 1 为情绪原因的具体示例。该文档包

含 7 个子句, 子句 c_0 是情绪表达句, 其情绪表达为“激动”, 属于 Happiness (高兴) 情感类别。 c_{-3}, c_{-2}, c_{-1} 表示情绪表达句的前三个子句, c_{-1}, c_{-2}, c_{-3} 表示情绪表达句的后三个子句。子句 c_{-2} 为情绪原因句, 情绪原因与情感表达的相对位置为 -2, 其标签为 1, 其余标签为 0。本文的目的在于识别情绪原因子句。

(1) 从表 1 可知, 该示例共有 7 个子句, 情绪表达子句有 1 个, 情绪原因子句有 1 个, 非情绪原因子句有 6 个, 即标签为 1 的子句仅有 1 个。由此看出, 情绪原因子句与非情绪原因子句的数量比重处于不平衡状态, 在识别分析时可以利用的信息也较少, 需要着重挖掘能够发现情绪原因子句的本质特征。

(2) 从表 2 可知, 整个数据库的情感类别分布共有 6 大类, 分别为 Fear、Surprise、Disgust、Sadness、Anger 和 Happiness, 其中 Sadness 和 Happiness 的情绪分布比重最大, 符合日常人们情绪表达的现状^[17]。同时, 情绪词和情绪类别能够极大地影响情绪原因识别的性能, 是本文需要着重考虑的关键因素。

(3) 从表 3 可知, 情绪原因与情绪表达是同一个子句的比例, 以及情绪原因在情绪表达的前一个子句的比例均比较高, 这表明绝大多数情绪原因子句都位于紧邻情绪表达子句的上下文信息中, 与文献^[18]的结论相同。因此, 情绪原因与情绪表达子句的位置信息也是情绪原因识别的关键。

2.2 ECPA 模型

通过上述的讨论分析, 本文发现提升情绪原因识别任务性能主要依赖于情绪词、情绪类别和位置信息。因此, 本文提出一种 ECPA 模型, 具体框架如图 1 所示。该模型主要由四部分组成: ①Embedding 层: 该层由两部分组成。首先, 利用 Word2Vec^[19] 工具进行词向量表示, 将句子中的词向量组合成一个词向量矩阵 Word Embedding。然后, 将与情绪信息相关的情绪词、情绪类别映射为词向量矩阵。最后, 将三者进行拼接作为下一层的输入。②Bi-LSTM 层: 通过 Bi-LSTM 模型, 充分学习词与词之间的语义信息, 获得句子的上下文信息。③Position Attention 层: 将子句与情绪表达子句的相对位置、绝对位置映射为词向量矩阵 R-Position Embedding 和 A-Position Embedding, 使用基于位

置的注意力机制来挖掘能够影响情绪原因识别的语义信息；④**Output 层**：通过 sigmoid 分类函数得到

该文档中任意子句作为情绪原因子句的概率值，选取概率最大的子句作为最终的情绪原因子句。




图1 ECPA(Emotion Context Position Attention Bi-LSTM)模型框架图

(1) Embedding 层

该层主要用于初始化输入的子句数据，通过 Word2Vec 将子句中的词语表示成词向量 (word embedding)，得到每个词语的低维稠密向量，能够更充分地表达词汇丰富的语义信息，挖掘词语间的语义关联，解决词袋模型中的向量稀疏问题。其中， $w_i \in R^k$ 表示 k 维词向量， $k=300$ ， W 表示 $n \times k$ 维的词向量矩阵。对于未登录词，需要使用 $\langle \text{unk} \rangle$ 进行替代，随机初始化 k 维的词向量。

同时，在 Embedding 层，需要学习到情绪相关的深层次的语义信息，本文主要从情绪词 E 和情绪类别 EC 两个角度对情绪原因识别任务的影响。对于情绪词 E ，其中， $E_i \in R^k$ 表示 k 维词向量， $k=300$ 。若情绪词为未登录词，则需要随机初始化词向量；否则在对应词向量矩阵中查找相应的词向量映射，得到情绪向量 Emotion Embedding。对于情绪类别，数据集有 {Fear, Surprise, Disgust, Sadness, Anger, Happiness} 总共 6 个类别，对应生成一个 $6 \times c_d$ 的向量矩阵 Category Embedding， $c_i \in R^{c_d}$ 表示 c_d 维词向量，这里的维度 c_d 选择 10 维。

最后，将上述的 Word Embedding、Emotion Embedding 和 Category Embedding 三者进行拼接操作，得到最终的输入词向量矩阵 $X = \{x_1, x_2, \dots, x_n\}$ ，具体如式(1)所示。

$$x_i = w_i \oplus E_i \oplus ec_i \quad (1)$$

其中， x_i 是一维行向量， \oplus 表示矩阵的连接操作， x_i 的维度为 $(k+k+c_d)$ 。

(2) Bi-LSTM 层

Hochreiter 等人^[20]提出的 LSTM(long short term memory)记忆单元主要在 RNN 模型的基础

上加入了门限制机制。LSTM 主要由细胞状态和门结构组成，细胞状态主要用于存储历史的信息，门结构主要负责保护和控制记忆细胞的状态。一个记忆单元一般有三个门结构：输入门、输出门和遗忘门。这里的遗忘门主要用于舍弃细胞状态中的信息，过滤部分传送的历史信息，从而解决梯度消失的问题。具体计算如式(2)~式(6)所示。

$$i_t = \sigma(W_i x_i + U_i h_{t-1} + V_i c_{t-1}) \quad (2)$$

$$f_t = \sigma(W_f x_f + U_f h_{t-1} + V_f c_{t-1}) \quad (3)$$

$$o_t = \sigma(W_o x_o + U_o h_{t-1} + V_o c_{t-1}) \quad (4)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tanh(W_c x_c + U_c h_{t-1}) \quad (5)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (6)$$

其中， x_t 为当前时刻的由上一层得到的输入向量， σ 为 sigmoid 激活函数， \cdot 为 element-wise 点乘操作， h_t 为当前时刻的隐层状态单元， i, f 和 o 分别表示输入门、遗忘门和输出门， $W_{\{i,f,o,c\}}$ ， $U_{\{i,f,o,c\}}$ ， $V_{\{i,f,o,c\}}$ 为训练学习到的参数。

在 LSTM 模型中，若按照正向的输入序列，则仅利用了上文的历史信息，但没有考虑到未来的下文信息。Graves 等人^[9]提出的 Bi-LSTM 模型可以充分考虑上下文的语境信息。本文将 Bi-LSTM 应用在情绪原因识别任务上，对于每一个子句，都有一个前向的 LSTM(\vec{h})和后向的 LSTM(\bar{h})，最终将两者的隐层状态进行拼接得到相应的表示，具体计算如式(7)~式(9)所示。

$$\vec{h}_t = H(W_{x\vec{h}} x_t + W_{\vec{h}\vec{h}} \vec{h}_{t-1} + b_{\vec{h}}) \quad (7)$$

$$\bar{h}_t = H(W_{x\bar{h}} x_t + W_{\bar{h}\bar{h}} \bar{h}_{t-1} + b_{\bar{h}}) \quad (8)$$

$$h_{out} = W_{\vec{h}} \vec{h}_t + W_{\bar{h}} \bar{h}_t + b \quad (9)$$

其中， \vec{h} 为一个前向的 LSTM， \bar{h}_t 为一个后向

的 LSTM, h_{out} 为 Bi-LSTM 模型的输出。

(3) Position Attention 层

由 2.1 节得知, 子句与情绪表达子句的位置信息能够影响情绪原因识别任务的性能。这里, 本文主要考虑任一子句与情绪表达子句的相对位置和绝对位置, 而情绪原因子句位于情绪表达子句在内的上下文 7 个子句的比例为 98.06%, 因此, 绝对位置设置为 $A_Position = \{1, 2, 3, 4, 5, 6, 7\}$, 对应生成一个 $7 * a_d$ 的向量矩阵 $A_Position$ Embedding (简称 AP), $ap_i \in R^{a_d}$ 表示 a_d 维的词向量, 这里的维度 a_d 选择 10 维。同时, 对于相对位置可以设置为 $R_Position = \{-3, -2, -1, 0, 1, 2, 3\}$, 对应生成一个 $7 * r_d$ 的向量矩阵 $R_Position$ Embedding (简称 RP), $rp_i \in R^{r_d}$ 表示 r_d 维词向量, 这里的维度 r_d 选择 10 维。

Attention 机制^[10]实际上是一种神经网络中计算权重的方法, 针对情绪原因子句与情绪表达子句特殊的位置结构信息, 本文通过在 Bi-LSTM 层后添加 Attention 层来增强情绪原因子句的语言现象对情绪原因子句识别任务的影响。这里, 本文会得到一个在位置结构信息影响下的隐层状态向量表示 r , 具体如式(10)~式(12)所示。

$$M = \tanh \left(\begin{bmatrix} W_h H_{out} \\ W_a AP_a \otimes ap_a \\ W_r RPr \otimes rp_r \end{bmatrix} \right) \quad (10)$$

$$\alpha = softmax(w^T M) \quad (11)$$

$$r = H_{out} \alpha^T \quad (12)$$

其中, H_{out} 为 Bi-LSTM 层的隐层状态输出, AP_a 、 RP_r 分别为绝对位置词向量矩阵和相对位置词向量矩阵, ap_a 与 rp_r 为词向量矩阵中的一维词向量, $AP_a \otimes ap_a$ 表示向量 AP 重复 N 次后进行拼接的操作, $RP_r \otimes rp_r$ 表示向量 RP 重复 N 次后进行拼接的操作, W_h 、 W_a 、 W_r 、 w 均为训练后可学习到的参数。

(4) Output 层

本层主要用于预测一个文档中所有子句中成为情绪原因子句的概率, 是一个二分类问题。这里, 本文使用 sigmoid 函数对结果进行预测, 具体如式(13)所示。

$$y = \text{sigmoid}(W_y r + b_y) \quad (13)$$

其中, r 为上一层输出得到的结果, W_y 、 b_y 为可训练学习到的参数。

2.3 模型训练

在模型训练阶段, 本文采用一种端到端的反向

传播的方式进行训练, 损失函数采用交叉熵, 同时使用 L_2 正则进行规范化。其中, y 为文本的真实分布, \hat{y} 为模型的预测分布, 模型训练的目标在于最小化所有子句的真实分布 y 与预测分布 \hat{y} 之间的交叉熵。具体如式(14)所示。

$$\text{loss} = - \sum_i \sum_j y_i^j \log \hat{y}_i^j + \lambda \| \theta \|^2 \quad (14)$$

其中, i 表示子句的索引号, j 表示类别的索引号, 本文的分类任务是二分类, λ 是 L_2 的正则项, θ 是参数。

3 实验与分析

本书首先介绍实验的设置和数据集, 然后与一些基线方法进行性能上的对比与分析, 最后列出一些可视化的结果, 并对其进行分析。

3.1 实验设置

在本部分, 本文首先分析实验室使用的数据集, 然后介绍具体的评价指标和基线方法, 最后给出在模型训练过程中的实现细节。

(1) 数据集

为了验证方法的有效性, 本文使用 Gui 等人^[16]标注的情绪原因数据集。这是一个公开可下载的中情绪原因数据集^①, 该数据集有 2 105 篇文档, 主要来自新浪城市新闻^②。每个文档都被手动分割成若干个子句, 这里的子句以逗号、句号、感叹号和问号为结尾。每个文档都包含一个情绪词, 以及一个或一个以上的情绪原因。该任务的目标在于识别每个文档中哪个子句是情绪原因子句, 具体的数据集统计信息如表 4 所示。

表 4 数据集统计信息

项目	数量
文档数	2 105
子句数	11 799
情绪原因子句	2 167
包含单一情绪的文档数	2 046
包含两个情绪的文档数	56
包含三个情绪的文档数	3

① http://hlt.hitsz.edu.cn/?page_id=694

② <http://news.sina.com.cn/society>

(2) 评价指标

对于情绪原因的识别任务,本文的评价指标与 Gui 等人^[16]、慕永利等人^[7]的评价方法一致,均采用准确率、召回率和 F_1 值这三个指标。对于数据集的训练和测试的比例划分,也采用相同的策略。在实验过程中,本文随机将数据集的 90% 作为训练集,10% 作为测试集,反复重复实验 10 次,即采用 10 倍交叉验证,求取各个衡量指标的平均值。

(3) 基线方法

对于情绪原因的识别任务,本文设置了如下的基线方法。

- **RB**: 基于规则的方法^[4]。
- **CB**: 基于常识的方法^[21]。
- **ML**: 用基于规则的方法进行特征抽取,然后利用机器学习方法进行分类^[22]。
- **SVM**: 该方法以 SVM 为分类器,采用许多有效的特征,如 1-gram、2-gram 和 3-gram 等,由 Li 和 Xu 提出^[23]。
- **Word2Vec**: 该方法使用 SVM 的分类器,其词向量由 Word2Vec^[18]学习得到。
- **Multi-kernel**: 该方法使用一种多核的方法来识别情绪原因^[16]。
- **Memnet**: 该深度记忆网络由 Gui 等人在 2017 年提出^[8],其词向量由 skip-gram 模型提前预训练得到,网络为 3 层结构。
- **ConvMS-Memnet**: 该网络同样由 Gui 等人在 2017 年提出^[8],是目前情绪原因识别任务中性能最佳的模型。本文列举该网络的最佳结果,使用预训练好的词向量,层数为 3。
- **CNN**: 该方法由慕永利等人^[7]在 2017 年提出,使用卷积神经网络结构识别情绪原因句。
- **E-CNN**: 该方法由慕永利等人^[7]在 2017 年提出,使用融合多个的卷积神经网络结构识别情绪原因子句,该结果为论文中的最佳结果。
- **Bi-LSTM**: 采用双向 LSTM 模型进行情绪原因识别^[9]。
- **ECPA**: 该方法为在 2.2 节提出的本文方法,首先考虑了情绪词向量和情绪类别向量,在 Bi-LSTM 模型的基础上,使用了基于相对位置和绝对位置的注意力增强机制。

(4) 实验细节

对于情绪原因的识别任务,本文采用 10 倍交叉验证来进行实验。本文使用 Word2Vec 词向量^[18],使用 twitter 和新浪微博的未标注数据进行预训练,其中对比了词向量维度分别为 100、200、300 时的分类性能,最终选取词向量维度为 300。Bi-LSTM 的神经元个数为 100,其他参数均采用均匀分布 $U(-0.01, 0.01)$ 进行初始化。为防止过拟合,本文采用 dropout 策略,值为 0.5。使用 AdaGrad 作为优化方法,学习率为 0.01,mini-batch 为 32。

3.2 实验性能对比

首先,本文将提出的 ECAP 方法与基线方法进行对比,结果如表 5 所示。

表 5 情绪原因识别任务中不同方法的结果对比

方法	准确率/%	召回率/%	F_1 值/%
RB	67.47	42.87	52.43
RB+CB	54.35	53.07	53.70
RB+CB+ML	59.21	53.07	55.97
SVM	42.00	43.75	42.85
Word2Vec	43.01	42.33	41.36
Multi-kernel	65.88	69.27	67.52
CNN	34.53	35.76	35.13
E-CNN	57.14	54.37	55.69
Memnet	59.22	63.54	61.31
ConvMS-Memnet	70.76	68.38	69.55
Bi-LSTM	59.54	46.28	52.08
ECPA	70.96	70.32	70.64

(1) 对于基于规则的方法, RB 取得了较高的准确率和较低的召回率,而基于常识的方法 CB 则相反,取得了较高的召回率和较低的准确率, CB 的召回率为目前方法的最高值 71.30%,说明基于常识的方法是比较全面的一种方法,而两者的融合方法 RB+CB 的 F_1 值取得了较大的性能提升,相比于 RB 方法提升了 1.27%。

(2) 对于机器学习方法, RB+CB+ML 的 F_1 值要高于 RB+CB,说明使用规则和常识作为特征,机器学习方法作为分类器是更有效的;而 SVM 和 Word2Vec 方法都设计了词级别的特征,取得了相似的性能; Multi-kernel 方法取得了较高的性能,原因在于通过句法分析树引入了上下文信息,同时使用了一个情感词典。

(3) 对于深度学习方法, CNN 和 E-CNN 均采用了卷积神经网络, 其中 E-CNN 能够识别不包含情绪原因的子句以及各种类型语言结构的情绪原因子句; Memnet 和 ConvMS-Memnet 采用了深度记忆网络, 这种多层网络结构能够更深层次地挖掘语义信息, 其中 ConvMS-Memnet 在该任务上取得了当前最佳的 F_1 值。

(4) 本文提出的 ECPA 模型能够充分学习到文本的上下文信息, 其结果明显高于 CNN 和 E-CNN; 而本文的 ECPA 模型的准确率和 F_1 值明显高于 ConvMS-Memnet 模型, 说明本文的模型充分地考虑到了情绪词和情绪类别对识别情绪原因的影响, 也学习了表达子句之间的位置结构信息。

3.3 ECPA 模型的分析

本节列出了一系列的模型来验证我们提出的 ECPA 模型的有效性。首先, 本文只使用 Bi-LSTM 模型识别情绪原因; 然后, 依次加入注意力机制、情绪词向量 (Emotion Embedding)、情绪类别词向量 (Category Embedding)、基于绝对位置 (A-Position) 的 Attention 机制和基于相对位置 (R-Position) 的 Attention 机制, 验证对情绪原因识别任务的影响; 最后, 对 ECPA 模型进行分析。具体的结果如表 6 所示。

表 6 ECPA 模型的性能分析

方法	准确率 /%	召回率 /%	F_1 值 /%
Bi-LSTM	59.54	46.28	52.08
Bi-LSTM+Attention	59.97	49.07	53.98
Bi-LSTM+Emotion Embedding+Attention	62.16	58.97	60.53
Bi-LSTM+Emotion Embedding+Category Embedding+Attention	63.83	60.47	62.10
Bi-LSTM+Emotion Embedding+Category Embedding+Attention+A-Position	66.89	65.34	66.11
Bi-LSTM+Emotion Embedding+Category Embedding+Attention+A-Position+R-Position	70.96	70.32	70.64

(1) 本模型使用 Bi-LSTM 来挖掘情绪原因的上下文信息, 能够从前向和后向两个角度充分地学习潜在语义信息, 与 CNN 模型相比取得了更好的结果; 在此模型的基础上, 引入注意力机制, 在该任

务上其 F_1 值提升了 1.9%, 表明使用注意力机制能更有效地挖掘到情绪原因的本质特点并赋予更多的关注。

(2) 在 Bi-LSTM 和注意力机制的基础上, 本文尝试先加入情绪词向量, 结果提升了近 6%, 说明情绪词能够深刻地影响着情绪原因的发现, 体现出因与果的语义关联性, 在加入情绪类别词向量后, 性能提升了 1.5%, 这表明情绪词所属的情绪类别信息能够从更高维的语义空间上影响情绪原因的识别。

(3) 对于注意力机制, 本文首先引入基于绝对位置的 Attention 模型, 结果提升了 4%, 然后在此基础上, 引入基于相对位置的 Attention 模型, 结果提升了 4.5%, 达到了 ECPA 模型的最佳结果, 高于其他基线方法。这表明 Attention 机制与位置信息的结合是有效的, 同时位置结构信息能够极大地影响情绪原因识别任务的性能。

4 结论与未来工作

本文重点在于识别情绪原因。为此, 本文提出了一种有效的情绪原因识别模型 ECPA, 从情绪原因的语言学特点出发, 首先考虑情绪信息, 如情绪词、情绪类别的影响力, 然后通过 Bi-LSTM 模型理解句子的上下文信息, 同时学习在相对位置和绝对位置信息作用下的注意力分配机制, 最终有效地识别情绪原因句子。实验结果表明, 本文的 ECPA 模型具有足够的识别情绪原因句的能力, 已达到国内外先进水平。对于未来的工作, 我们需要找到更高效的特征和手段来识别和理解情绪原因句, 也可以精确定位情绪原因子句的位置, 同时可以尝试开展情绪原因生成的工作。这些都是将来可探索的方向。

参考文献

[1] Wang R, Li S, Zhou G, et al. Joint sentiment and emotion classification with integer linear programming [C]//Proceedings of International Conference on Database Systems for Advanced Applications. Springer International Publishing, 2015: 259-265.

[2] 张志华. 基于深度学习的情感词向量及文本情感分析的研究[D]. 上海: 华东师范大学硕士学位论文, 2016.

[3] Wang Y, Feng S, Wang D, et al. Multi-label Chinese microblog emotion classification via convolutional neural network [C]//Proceedings of Asia-Pacific Web Conference. Springer International Publishing, 2016:

- 567-580.
- [4] Sophia Yat Mei Lee, Ying Chen, et al. A text-driven rule-based system for emotion cause detection[C]//Proceedings of the NAACL HLT 2010 Workshop on Computational Approaches to Analysis and Generation of Emotion in Text, 2010: 45-53.
- [5] Kai Gao, Hua Xu, Jiushuo Wang. A rule-based approach to emotion cause detection for Chinese micro-blogs[J]. Expert Systems with Applications, 2015, 42(9): 4517-4528.
- [6] Weiyuan Li, Hua Xu. Text-based emotion classification using emotion cause extraction[J]. Expert Systems with Applications, 2014, 41(4): 1742-1749.
- [7] 慕永利, 李旻, 王素格. 基于 E-CNN 的情绪原因识别方法[J]. 中文信息学报, 2018, 32(2): 120-128.
- [8] Gui L, Hu J, He Y, et al. A Question Answering Approach to Emotion Cause Extraction[C]//Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing, 2017: 1593-1602.
- [9] Graves A, Jaitly N, Mohamed A. Hybrid speech recognition with deep bidirectional LSTM[C]//Proceedings of the 2013 IEEE Workshop on Automatic Speech Recognition and Understanding, 2013: 273-278.
- [10] Bahdanau D, Cho K, Bengio Y. Neural machine translation by jointly learning to align and translate[C]//Proceedings of the 3rd International Conference on Learning Representations, 2015.
- [11] Paul Ekman. Expression and the nature of emotion[M]. Approaches to Emotion, LON: Psychology Press, 1984.
- [12] Linhong XU, Lin H F, Yang Z H. Text Orientation identification based on semantic comprehension[J]. Journal of Chinese Information Processing, 2007, 21(1): 96-100.
- [13] Yoon Kim. Convolutional neural networks for sentence classification[C]//Proceedings of the EMNLP 2014, 2014: 1746-1751.
- [14] 李逸薇, 李寿山, 黄居仁, 等. 基于序列标注模型的情绪原因识别方法[J]. 中文信息学报, 2013, 27(5): 93-99.
- [15] Lin Gui, Li Yuan, Ruifeng Xu, et al. Emotion cause detection with linguistic construction in Chinese weibo text[J]. Communications in Computer & Information Science, 2014, 496(s 3-4): 457-464.
- [16] Lin Gui, Dongyin Wu, Ruifeng Xu, et al. Event-driven emotion cause extraction with corpus construction[C]//Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing, 2016: 1639-1649.
- [17] Gao Q, Hu J, Xu R. Overview of NTCIR-13 ECA task[C]//Proceedings of the 13th NTCIR Conference. Tokyo, Japan, 2017: 361-366.
- [18] Ying Chen, Sophia Yat Mei Lee, Shoushan Li, et al. Emotion cause detection with linguistic constructions[C]//Proceedings of the 23rd International Conference on Computational Linguistics, 2010: 179-187.
- [19] Mikolov T, Chen K, Corrado G, et al. Efficient estimation of word representations in vector space[C]//Proceedings of the 1st International Conference on Learning Representations, 2013: 1-12.
- [20] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [21] Irene Russo, Tommaso Caselli, Francesco Rubino, et al. EMO-cause: An easy-adaptable approach to emotion cause contexts[C]//Proceedings of the 2nd Workshop on Computational Approaches to Subjectivity and Sentiment Analysis, 2011: 153-160.
- [22] Y. Chen, S Y M Lee, S Li, et al. Emotion cause detection with linguistic constructions[C]//Proceedings of the 23rd International Conference on Computational Linguistics, 2010: 179-187.
- [23] Weiyuan Li, Hua Xu. Text-based emotion classification using emotion cause extraction[J]. Expert Systems with Applications, 2014, 41(4): 1742-1749.



刁宇峰(1987—), 博士, 讲师, 主要研究领域为文本挖掘、情感计算。

E-mail: diaoyufeng@mail.dlut.edu.cn



林鸿飞(1962—), 通信作者, 博士, 教授, 博士生导师, 主要研究领域为信息检索、社会计算、情感分析、文本挖掘等。

E-mail: hflin@dlut.edu.cn



杨亮(1986—), 博士, 讲师, 主要研究领域为文本挖掘、文本情感分析。

E-mail: liang@dlut.edu.cn