

文章编号：

面向中文微博的情绪-原因对抽取数据集构建及分析研究

陈仲豪^{1,2} 朱军楠^{2,1,2} 向露^{3,1,2} 周玉^{4,1,2,3} 宗成庆^{5,1,2}

(1. 中国科学院自动化研究所 模式识别国家重点实验室, 北京 100190;
2. 中国科学院大学 人工智能学院, 北京 100049;
3. 凡语 AI 研究院 北京中科凡语科技有限公司, 北京 100190)

摘要: 情绪-原因对抽取 (ECPE) 任务旨在从给定文档中同步抽取情绪子句及其对应的原因子句, 该任务在新闻领域得到了广泛研究。然而, 社交媒体领域 ECPE 任务的研究相对较少, 主要原因在于缺少适用的数据集。与新闻领域相比, 该领域更具挑战性和实用性: (a) 在社交媒体领域, 情绪表达更加多样化、非规范化; (b) 以往的研究忽略了情绪造成的主观意图, 它对于决策分析有很重要的价值。针对以上问题, 该文首先构建了一个面向中文微博的情绪原因抽取数据集, 并对其中 5 009 条数据进行了人工标注。该数据集具备以下特点: (1) 收录了隐喻、反讽等形式的情绪表达, 标注了细粒度的情绪类别; (2) 定义了三种类型的意图, 并标注了意图子句; (3) 当前规模最大的中文情绪-原因对抽取数据集。结合数据集特点, 该文提出一种融合情绪类别和意图信息的情绪-原因对抽取方法, 并将该方法与多个 ECPE 主流方法进行了比较分析。实验结果表明, 该文所提方法可以更有效地提升社交媒体领域情绪-原因对抽取的效果。

关键词: 情绪-原因对抽取; 中文社交媒体; 微博数据集

中图分类号: TP391

文献标识码: A

Construction and Analysis of Chinese Microblog Emotion-Cause Pair Extraction Dataset

CHEN Zhonghao^{1,2}, ZHU Junnan^{1,2}, XIANG Lu^{1,2}, ZHOU Yu^{1,2,3}, and ZONG Chengqing^{1,2}

(1. National Laboratory of Pattern Recognition, Institute of Automation, Chinese Academy of Sciences, Beijing 100190, China;
2. School of Artificial Intelligence, University of China Academy of Sciences, Beijing 100049, China;
3. Fanyu AI Lab, Zhongke Fanyu Technology Co., Ltd, Beijing 100190, China)

Abstract : Emotion-cause pair extraction (ECPE) is to extract emotion clauses and corresponding cause clauses simultaneously, which has been widely studied in the news domain. However, there are few studies on ECPE task in the social media domain, mainly due to the lack of available datasets. Compared to the news domain, it is more challenging and practical in the social media domain: (a) the emotion expression in the social media texts is more diverging or even ill-formed; (b) the human's subjective intentions have been widely ignored in the prior studies, which are significant for decision analysis. To alleviate these problems, this paper constructs a Chinese Microblog dataset **WeiboEmotion** for ECPE. It is the largest dataset containing 5 009 samples manually annotated. This dataset includes emotional expressions in the form of metaphor and irony, and defines fine-grained emotional categories. Meanwhile, the intentions annotated in the dataset are divided into three types. Considering the features of this dataset, this paper proposes an ECPE method integrating emotion category and intention information and conducts experiments to compare this method to the mainstream ones. Experiments results have shown the effectiveness of this method in the social media domain.

Key words: emotion-cause pair extraction; Chinese social media; weibo dataset

0 引言

作为情绪分析中的一个子任务，情绪-原因对抽取(emotion-cause pair extraction)近年来吸引了许多学者的关注。情绪-原因对抽取任务旨在从给定的文本中同步抽取出情绪和及其对应的原因子句，其难点在于缺少情绪的标注信息。尽管在新闻领域已经出现了大量的研究工作，但是仍然存在以下问题：(1) 目前大多数工作聚焦于新闻领域，忽略了具有丰富舆论倾向的社交媒体领域；(2) 目前大多数工作较少地考虑了细粒度的情绪类别信息对“情绪-原因对”抽取的影响。另外，社交媒体领域的情绪表达方式呈现多样化、非规范化的特点，更具挑战性；(3) 由于社交媒体文本均以第一人称发布，除了情绪和原因以外，往往还会包含由此情绪造成的后果，即用户的意图，这是新闻文本所不具备的。

本文研究聚焦于现今最大的中文社交媒体平台微博，图 1 是取自微博的一个样本。用户在跟帖中表达了他对韵达快递生气的情绪。情绪-原因对抽取任务的目标仅抽取情绪子句 c_3 及对应的原因 c_2 ，但是忽略了情绪类别和用户意图。由于 c_3 “你能信”这类隐喻情绪表达需要通过上下文语境才能判断具体类别，对于情绪子句仅定位而不分类将会影响下游任务的使用。除了了解造成用户情绪的原因外，由情绪引发的意图也是很重要的信息，如 c_4 中用户明确表示放弃韵达快递服务，此类信息可以帮助企业及时制定应对措施。针对上述问题分析发现，若能在抽取“情绪-原因对”的同时，进行情绪分类和意图识别，不仅能够更加满足实际场景的需要，还能够为模型的训练引入更多的信息，增强监督信号，从而达到改善情绪-原因对抽取的效果。

情绪-原因对抽取	情绪-类别-原因-意图抽取
[你能信(c_3), 结果搞丢了(c_2)]	[(你能信(c_3), 生气, 结果搞丢了(c_2)), 再也不会主动用韵达快递了(c_4)]

图 1 两种任务的对比示例

综上，本文聚焦于以下两个问题：(1) 构建一个社交媒体领域的情绪-原因对抽取数据集；(2) 将情绪类别和意图信息在情绪-原因对抽取任务中进行充分利用。

针对第一个问题，本文通过收集微博每日热点话题的跟帖并进行标注，构建了一个全新的数据集(WeiboEmotion)。在 WeiboEmotion 中标注了情绪-类别-原因三元组及意图四种成分，从而构成了更加完整的情绪事件。WeiboEmotion 共包含 5 009 条样本，是目前最大的情绪-原因对抽取数据集。

针对第二个问题，本文提出一种融合情绪类别与意图信息的情绪-原因对抽取方法。通过多任务学习框架引入情绪分类和意图识别两个子任务，用以辅助“情绪-原因对”的抽取，从而增强监督信息。

综上所述，本文构建了一个当前规模最大的中文社交媒体领域的情绪-原因对抽取数据集 WeiboEmotion，包含情绪、原因、情绪类别及意图等多种成分，能够体现微博数据的特点。另外，提出一种融合情绪类别与意图信息的情绪-原因对抽取方法，为模型提供更多的监督信号，改善情绪-原因对抽取效果，并使用多任务学习框架解决了这一任务。实验表明，融合情绪类别与意图信息的情绪-原因对抽取方法能够有效改善“情绪-原因对”的抽取效果。

1 数据集构建

1.1 数据收集和标注

1.1.1 数据收集

本文收集了自 2020 年 9 月至 12 月期间微博每日热点话题下的跟帖，组成生语料库。与以往选择样本的方式不一样，为了保证情绪表达多样性，本文通过人工方式筛选包含情绪表达的样本，而非利用情感词典筛选包含情绪关键词的样本。本文的情绪划分基于 Ekman^[1]的 6 大情绪类别（高兴、伤心、害怕、厌恶、生气、惊讶），通过分析中文微博样本的特点，发现“高兴”这一类样本占比非常高。通过参考徐琳宏等人^[2]对“高兴”的情绪划分方法并结合微博特点，将“高兴”进一步分为“快乐”、“喜欢”、“羡慕”、“感动”四类情绪，分别刻画不同方面的“高兴”情绪，从而组成了细粒度情绪类别（快乐、喜欢、羡慕、感动、伤心、害怕、厌恶、生气、惊讶）。依照同时包含情绪、原因子句的样本将被保留的原则，共筛选出 5 009 条数据。

1.1.2 数据预处理

为保证连贯性，删除了样本中的话题标签。此外，所有表情均被转换为字符串。

1.1.3 标注规范

在数据集构建阶段，由三名硕士生担任标注员。初始筛选包含情绪表达的句子阶段，由三名标注人员进行人工筛选样本，保留依据为样本中同时包含情绪表达及其对应原因。将两名以上人员认为需要保留的样本作为待标注样本。然后，利用一部分筛选出的样本进行一轮试标注，通过讨论总结出初始标注规范。其次，根据初始标注规范由两名标注人员分别对样本进行标注，并在标注过程中不断迭代、完善标注规范。最终，由另一名标注人员对以上两名人员标注不一致的情况进行统一。

根据以往研究^[3]的结论，数据的标注粒度设置为子句。根据预先定义好的情绪类别在样本中定位情绪子句的 ID 及类别。此外，当某种情绪在样本中多次出现如表 1 (a)，或多种情绪在样本中出现时表 1 (b)，则应看作多个情绪。当同一个样本中包含两个或多个相同情绪的子句，则应均被标出，并分别标注其对应的原因。

表 1 多个情绪出现在同一个样本中的示例

(a) 李雪琴可真是一个人才 (c ₁)，她这口才真的是太让人 佩服了(c ₂)，我瑞思拜了(c ₃)	(2, 羡慕, 2) (3, 羡慕, 2)
(b) 看着太生气了吧(c ₁)，这 么大的活动说取消就取消 (c ₂)，那些贷款的商家也太惨 了吧(c ₃)，听月小筑掌柜小姐 姐哭的我好心疼(c ₄)。	(1, 生气, 2) (4, 伤心, 4)

原因在样本中以三种形式出现：

(1) 指代型原因，其定义为：在某种情绪所对应的原因子句中，仅出现了以代词指代的原因事件。例如，在“大晚上看到这个新闻 (c₁)，好心酸 (c₂)”中，“这个新闻”是用户“心酸”的原因，而对于新闻的具体内容并未详细阐述；

(2) 细节型原因，其定义为：在某种情绪所对应的原因子句中，包含原因事件的详细描述。例如，在“好心酸 (c₁)，一家四口人就这么一天死亡 (c₂)”中，“好心酸”的原因是“一家四口人就这么一天死亡”，用户对原因事件的细节进行了阐述。

(3) 用户在阐述原因时还可能将以上两种原因结合起来，例如“大晚上看到这个新闻 (c₁)，好心酸 (c₂)，一家四口人就这么一天死亡 (c₃)”。

由于原因分类是以用户的阐述方式来划分的，因此，以上三种情况可以覆盖全部情况。

在意图方面，主要标注以下三种情况，分别定义如下：

(1) 未来行动：用户明确阐述的由于某种情绪所导致的未来可能采取的行动。在表 2 (a) 中由于对于某电商服务不满，用户在 c₆ 中表示今后可能会选择京东。该类意图针对的对象通常为用户自身；

(2) 期望：用户对引发自身情绪变化的人或事物所提出的希望、期待等。在表 2 (b) 中用户表示了对黄鸿升女友的同情，并在 c₅ 中表达了积极的期望。该类意图针对的对象通常为事物的发展趋势；

(3) 建议：用户由于某些情绪及原因对组织、部门或个人提出的针对性意见。在表 2 (c) 中用户提出了对监管部门的建议 c₅，这种建议对于政府部门掌握舆论倾向非常重要。该类意图针对的对象通常为可以执行用户意图的第三方客观主体。

表 2 数据集中不同类型的意图

(a) 今年是真的恶心(c ₁)，一个凑单的一个买错了 (c ₂)，跟客服说先别发货的时候都不理人(c ₃)，然后火速填了单号(c ₄)，客服再回一句不好意思已经发货了拦截不了了呢(c ₅)？真就是赶人去京东 呗(c ₆)！
(b) 黄鸿升因意外不幸离世(c ₁)，女友发文悼念 (c ₂)，文字看的让人心痛(c ₃)，明天和意外哪个先 来真的很难预料(c ₄)，希望姐姐能早点走出来 (c ₅)。
(c) 从监控看(c ₁)，那牵引车都没减速(c ₂)，加速 碾过去了(c ₃)，太可怕了(c ₄)，一定要严查(c ₅)。

1.2 数据集统计信息

表 3 数据集统计信息

样本总数	5 009
带有一个情绪的样本数	4 757
带有两个情绪的样本数	238
带有三个及更多情绪的样本数	14
带有意图的样本数	1 422
平均子句数量	5.4
最大子句数量	30

WeiboEmotion 共包含 5 009 条标注样本，本文将 F1 值^[4]作为一致性评估指标，在情绪类别、情绪-原因对和意图上的一致率分别为 86.1%，79.4%，75.5%，表 3 是数据集的统计信息。从表 3 中可以看出，大多数样本仅包含 1 种情绪。但

由于存在一个样本包含多种情绪的情况，因此如何为情绪和原因正确配对成为了一个非常关键的问题。另外，包含意图的样本仅占总样本数的 28.4%，样本稀疏将给后续意图识别任务增加难度。在样本长度方面，由于微博热点跟帖具有字数限制，样本相对较短，平均子句数量为 5.4，其中最长样本包含子句数量为 30。

表 4 情绪原因相对位置距离分布

相对位置距离	数量	百分比/%
0	953	13.4
1	3 564	50.2
2	1 551	21.8
3	625	8.9
≥ 4	410	5.8

表 4 统计了情绪子句和原因子句相对位置的信息。其中情绪原因子句相对位置距离不大于 3 的情况占比 94.2%，由此可见，相对位置对于“情绪-原因对”的抽取是非常重要的特征。

表 5 情绪类别分布

情绪类别	数量	百分比/%
快乐	1 112	21.1
生气	749	14.2
伤心	987	18.7
害怕	363	6.9
厌恶	555	10.5
惊讶	391	7.4
羡慕	582	11.0
感动	193	3.7
喜欢	343	6.5

此外，本文还统计了情绪类别的分布情况，

如表 5 所示。本文以情绪子句中是否包含情感词典^[2]中的情感词，将情绪表达划分为显式表达和隐式表达，两种情况分别占比 64% 和 36%。由于隐式情绪表达的存在，微博文本情绪表达方式更加多样化，其中的反讽、隐喻等问题需要构建具有推理能力的模型才能有效解决。此外，情绪类别分布并不均匀，标签为“快乐”的样本数达到“喜欢”的三倍多，不平衡的类别分布也会给情绪分类任务带来影响。

2 融合情绪类别与意图信息的情绪-原因对抽取方法

本文旨在通过引入情绪分类和意图识别两个任务，来改善“情绪-原因对”的抽取效果。具体而言，首先在编码阶段利用 BERT^[5]获得子句的向量表示，为了增强子句之间的交互，引入了图注注意力神经网络^[6]在子句级别进行文本信息交互建模。然后利用基于滑动窗口的多标签学习方法^[7]进行“情绪-原因对”的抽取，并将情绪子句抽取、原因子句抽取、情绪分类和意图识别作为辅助子任务来增强监督信息。模型的整体结构如图 2 所示。

2.1 模型结构

2.1.1 子句编码层

对于一篇文档 $D = [c_1, c_2, \dots, c_d]$ ，本文通过 BERT 获取子句向量表示。在输入 BERT 之前，每个子句 $c_i = (w_{i1}, w_{i2}, \dots, w_{id})$ 将被处理为以下形式： $c'_i = ([CLS], w_{i1}, w_{i2}, \dots, w_{id}, [SEP])$ ，其中 [CLS] 为子句的开始符，用其表示子句向量，[SEP] 为句子的

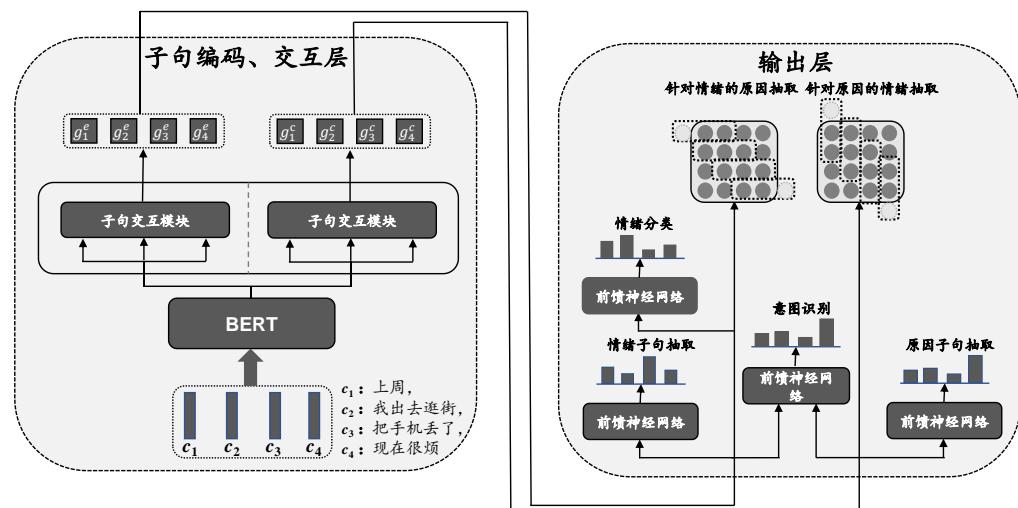


图 2 模型整体结构图

结束符。文本经过 BERT 编码后可以获得子句向量：

$$\mathbf{h}_{c_i} = \text{BERT}(c'_i) \quad (1)$$

2.1.2 子句交互层

借鉴 Wei 等人^[8]的句子交互方法，本文采用了两个图注意力神经网络^[6]进行子句间的交互建模，分别得到针对情绪和原因的子句向量：

$$\mathbf{g}_{c_i}^e = \text{GAT}(\mathbf{h}_{c_i}) \quad (2)$$

$$\mathbf{g}_{c_i}^c = \text{GAT}(\mathbf{h}_{c_i}) \quad (3)$$

2.1.3 输出层

输出层采用了多种任务联合训练的框架，其中主任务为“情绪-原因对”的抽取，辅助子任务分别为情绪子句抽取、原因子句抽取、情绪分类和意图识别。本文采用基于滑动窗口的多标签学习方法抽取“情绪-原因对”。假定 c_i 是一个情绪子句，目标是检测其对应的原因子句。通过设定一个窗口将可能存在的原因限定在距离为 w 的范围内，使用一个多标签二分类器在窗口 $[c_{i-w}, \dots, c_{i-1}, c_i, c_{i+1}, \dots, c_{i+w}]$ 内进行原因检测：

$$\mathbf{y}_i^c = \text{softmax}(\text{res}(\mathbf{W}^c \mathbf{g}_{c_i}^c) + \mathbf{b}^c) \quad (4)$$

其中， $\text{res}(x)$ 的作用是将 x 转化为一个 $(2 * w + 1, 2)$ 形状的矩阵。本文通过同样的计算方式，通过假定 c_j 为一个原因子句，检测其对应的情绪子句：

$$\mathbf{y}_j^e = \text{softmax}(\text{res}(\mathbf{W}^e \mathbf{g}_{c_j}^e) + \mathbf{b}^e) \quad (5)$$

在推理阶段，当且仅当 $(\mathbf{y}_m^{c_{m-n}} + \mathbf{y}_n^{e_{n-m}}) / 2 > 1/2$ 且 $|m - n| \leq w$ 时，子句对 $c_m - c_n$ 将被预测为“情绪-原因对”。

4 个辅助子任务分别使用 4 个前馈神经网络进行训练。对于情绪子句抽取和原因子句抽取，分别将针对情绪和原因的子句向量输入对应的网络中：

$$\mathbf{y}^{emo} = \text{sigmoid}(\mathbf{W}^{emo} \mathbf{g}^e + \mathbf{b}^{emo}) \quad (6)$$

$$\mathbf{y}^{cau} = \text{sigmoid}(\mathbf{W}^{cau} \mathbf{g}^c + \mathbf{b}^{cau}) \quad (7)$$

其中， $\mathbf{g}^e = [\mathbf{g}_{c_1}^e, \mathbf{g}_{c_2}^e, \dots, \mathbf{g}_{c_d}^e]$ ， $\mathbf{g}^c = [\mathbf{g}_{c_1}^c, \mathbf{g}_{c_2}^c, \dots, \mathbf{g}_{c_d}^c]$ 。

情绪分类利用针对情绪的子句向量进行分类：

$$\mathbf{y}^{cat} = \text{softmax}(\mathbf{W}^{cat} \mathbf{g}^e + \mathbf{b}^{cat}) \quad (8)$$

表 6 模型在 WeiboEmotion 上情绪-原因对抽取的实验结果

意图识别时，将针对情绪和原因的向量相加后输入到一层前馈神经网络中进行学习：

$$\mathbf{y}^{int} = \text{sigmoid}(\mathbf{W}^{int} (\mathbf{g}^e + \mathbf{g}^c) + \mathbf{b}^{int}) \quad (9)$$

2.2 模型训练

模型采用反向传播算法进行训练，全部任务损失函数均为交叉熵，最终损失为它们的加和形式。具体计算如下式所示。

$$L = L^{pair_emo} + L^{pair_cau} + L^{cat} + L^{int} + L^{emo} + L^{cau} \quad (10)$$

其中 L^{pair_emo} 、 L^{pair_cau} 、 L^{emo} 、 L^{cau} 、 L^{cat} 和 L^{int} 分别对应上述各任务。

3 实验

3.1 实验数据和评价指标

本文采用 **WeiboEmotion** 作为实验数据集，并将数据集以 8:1:1 的比例进行划分训练集、验证集和测试集。为避免结果的随机性，采用 10 折交叉验证，每次划分都以随机采样的形式进行，共采样 10 次。评价指标选择精确率 (P)、召回率 (R) 和 F1 值。

3.2 实验设置

本文将 BERT-Base, Chinese^[9] 用于 BERT 的初始化，其余参数使用 Xavier 方法^[10] 进行初始化。在对模型进行训练时，本文采用 Adam 算法^[11] 进行参数优化，初始学习率设置为 2e-5，并采用线性 warmup 机制自动调整学习率。图注意力神经网络设置 4 个注意力头，每个头的隐层向量维度为 192。本文将批大小设置为 8，总训练轮数为 30，约束窗口尺寸 w 设置为 3。为了避免过拟合，本文采用了 dropout 机制，并将比率设置为 0.1。另外还加入了早停机制，轮数为 5。本文以情绪-原因抽取对在验证集上的 F1 值为标准挑选最终模型，在测试集上利用选出的模型进行最终预测。

模型	情绪-原因对抽取			情绪子句抽取			原因子句抽取		
	P	R	F1	P	R	F1	P	R	F1
Trans-ECPE	64.61	56.45	60.12	86.05	85.03	85.53	70.80	63.45	66.87
RANKCP	67.35	62.19	64.61	88.77	86.91	87.83	74.45	68.06	71.11
ECPE-MLL	73.01	60.98	66.41	89.01	81.43	85.02	77.05	66.66	71.48
所提方法	73.15	62.95	67.63	90.52	82.47	86.29	78.17	67.89	72.63

3.3 结果分析

本文选择了 3 个解决情绪-原因对抽取的主流方法在 **WeiboEmotion** 进行实验, 来探索和分析社交媒体文本风格对模型的影响。

(1) **Trans-ECPE**: Fan 等人^[12]提出一个基于转移的有向图构建模型, 该模型将情绪、原因配对过程转化为图中边的生成过程, 边的起点为原因子句, 终点为情绪子句。利用基于转移的神经网络模型学习每个时刻所生成边的种类。

(2) **RANKCP**: Wei 等人^[8]首先利用图注意力网络进行句间交互建模, 然后从排序角度给符合相对位置距离约束的句对打分, 从中选出得分最高的句对作为“情绪-原因对”。对于多个对的情况, 则依靠外部词典进行抽取。

(3) **ECPE-MLL**: Ding 等人^[7]提出一个基于滑动窗口的多标签学习模型, 该模型通过假定某个子句为情绪子句, 在以该句为中心的窗口内判断情绪子句对应的原因子句。同理可在以某个假定原因子句为中心的窗口内判断对应的情绪子句。最后将两种结果集成起来, 作为模型的输出。

表 6 展示了基线模型及本文所提方法在 **WeiEmotion** 数据集上的实验结果。在 4 个模型中, 本文所提方法在情绪-原因对抽取任务上获得了最好的效果。本文通过引入情绪分类和意图识别任务有效提高了“情绪-原因对”的抽取效果, 但在情绪子句抽取任务上表现差于 RANKCP, 主要原因在于 RANKCP 通过模型抽取首个情绪原因对后, 利用情感词典关键词匹配进行其它对的抽取, 从而提高了情绪子句的召回率, 因此 RANKCP 的情绪子句抽取 R 值明显优于其他几个模型。Trans-ECPE 在进行基于转移的有向图构建时定义了 6 种动作, 将任务看作 6 分类问题, 而其它三种方法本质上均为二分类问题, 即 Trans-ECPE 相对其他方法建模了更加复杂的情况, 所以取得了最差的表现。RANKCP 在处理多“情绪-原因对”情况时采取的基于词典匹配的方法并完全不适用于社交媒体文本, 原因在于隐喻、反讽等表达方式的存在, 使得利用情绪关键词召回的方法在新闻文本领域的优势不再明显。本文所提方法集成了 RANKCP 和 ECPE-MLL 的优点, 同时融合了情绪类别和意图信息, 因此效果好于这两种方法。

表 7 展示了本文所提模型在情绪分类、意图识别及情绪-类别-原因三元组检测任务上的效果。由于情绪分类任务包含 9 种不同情绪, 相比于情绪子句抽取任务更难, 因此其分类效果也较差。意图识别的效果非常差, 主要原因在于数据集中

包含意图的样本仅占 28.4%。本文将抽取出来的“情绪-原因对”和对应子句的情绪分类结果进行组合, 构成情绪-类别-原因三元组。统计结果显示其 F1 值为 59.24, 尽管表现较差, 但是三元组形式的输出更有利下游任务的使用, 因此有必要进一步探索更加有效的方法。

表 7 所提方法在辅助子任务上的结果

任务	P	R	F1
情绪分类	76.97	79.78	78.30
意图识别	54.21	48.09	50.78
三元组检测	64.07	55.15	59.24

3.4 模型分析

3.4.1 子句交互层对抽取性能的影响

本文为探究子句交互层的作用进行了消融实验, 表 8 展示了子句交互层对情绪-原因对抽取的影响, -GAT 指将图注意力网络从所提方法中移除, FFW 指将子句交互层中的图注意力网络替换为前馈神经网络。

从表 8 中可以看出, 采用子句交互层可以有效提升情绪-原因对的抽取效果。通过比较-GAT 和 FFW 的结果可以看出, 使用前馈神经网络的子句交互层对于模型的抽取性能也有帮助, 但效果略低于图注意力网络, 因此本文选择了图注意力网络来实现子句交互层。

表 8 子句交互层对抽取性能的影响

方法	P	R	F1
所提方法	73.15	62.95	67.63
-GAT	72.79	62.26	67.07
FFW	73.26	62.51	67.43

3.4.2 情绪-原因对数目对抽取性能的影响

本文分别分析了样本中含有多个情绪与一个情绪的对比结果和样本中含有多个情绪-原因对与一个情绪-原因对的对比结果。

表 9 含有多个情绪与一个情绪的对比结果

情绪数目	P	R	F1
多个情绪	81.87	45.82	58.64
一个情绪	71.95	64.73	68.12

表 10 含有多个与一个情绪-原因对的对比结果

情绪-原因对数目	P	R	F1
多个情绪-原因对	79.89	50.73	62.03
一个情绪-原因对	68.00	76.35	71.90

从表 9 中可以看出，当样本中含有多个情绪时比仅含有一个情绪的情绪-原因对抽取结果下降了大约 10 个点。从表 10 中可以看出，样本中含有多个情绪-原因对时比仅含有一个情绪-原因对的抽取结果同样下降了大约 10 个点，这表明含有多个情绪-原因对的抽取更加困难。造成这种情况的主要原因是训练集中大量样本仅包含一个情绪-原因对，这种数据偏置造成模型倾向于输出更少的情绪-原因对。

3.4.3 情绪类别与意图信息对抽取性能的影响

为了分析融合情绪类别与意图信息对情绪-原因对抽取的作用，本文进行了以下消融实验：

(1) -IE：在本文所提方法中将意图识别任务删除；

(2) -EC：在本文所提方法中将情绪分类任务删除；

(3) -IE-EC：删除所提方法中的意图识别和情绪分类任务；

表 11 删除情绪类别、意图信息对情绪-原因对抽取的影响

方法	情绪-原因对抽取			情绪子句抽取			原因子句抽取		
	P	R	F1	P	R	F1	P	R	F1
所提方法	73.15	62.95	67.63	90.52	82.47	86.29	78.17	67.89	72.63
-IE	72.74	62.73	67.33	90.11	82.21	85.96	78.02	67.78	72.50
-EC	72.18	62.26	66.80	89.76	82.58	86.01	77.48	67.31	71.98
-IE-EC	70.97	62.88	66.62	88.88	83.17	85.91	76.76	68.21	72.16

表 11 展示了删除情绪类别、意图信息对情绪-原因对抽取的影响。当把意图识别和情绪分类任务全部删除后，情绪-原因对抽取的 F1 值下降了 1 个点。这与本文所提观点一致，融合情绪类别和意图信息对于抽取“情绪-原因对”是有帮助的。当仅删除意图识别任务时，情绪-原因对抽取 F1 值下降幅度小于删除情绪类别识别任务，说明情绪类别比意图信息可以更好地指导抽取“情绪-原因对”。这种现象也与人们的直觉相符，因为情绪类别与情绪原因直接相关，细粒度的情绪能够指导模型寻找更加准确的原因。从情绪子句抽取的 R 值中也能看出，当去掉情绪类别任务的约束后，模型倾向于召回更多的情绪子句，导致-IE-EC 的召回率最高，准确率却有所下降。因此，在后续研究中应重点关注如何充分利用情绪类别的信息。

4 相关工作

情绪-原因对抽取任务是由情绪原因抽取任务发展而来的^[13-14]。Lee 等人^[15]首次提出给定情绪从文本中抽取出情绪对应的词级别原因。Chen 等人^[3]指出对于情绪原因抽取而言，子句是更加合理的粒度。依据这个设定，后续有一些学者进行了深入研究^[16-17]。Gui 等人^[18]在 2016 年发布了第一套公开的中文新闻领域情绪原因抽取数据集，共包含 2 105 条样本。刁宇峰等人^[19]利用情绪词和情绪类别中的情绪信息，通过引入基于位置信息的注意力机制模型，构建情绪原因识别模型。此外，由于公开数据的出现和深度学习方法的兴起，后续出现了一系列基于神经网络的方法来解决这个问题^[20-24]。

以上研究都是在给定文本情绪的条件下从文本中抽取原因，Xia 和 Ding^[25]提出这种模式并不符合实际场景的需要，并提出了一个新任务：情绪-原因对抽取。他们利用级联式系统，分别抽取情绪和原因子句，再将句子配对后进行分类，解决这个任务。但是，级联式系统会造成误差传播，

同时不利于情绪与原因子句间交互建模。针对这一问题，Ding 等人^[26]提出一种 2D-Transformer 联合框架将“情绪-原因对”的表示学习和预测整合在一个联合框架中，进行端到端的抽取。Fan 等人^[12]提出基于转移的有向图构建方法，将情绪-原因对抽取转化为类似句法解析的过程。Wei 等人从排序角度出发为所有候选句对打分，并提出利用情感词典关键词匹配解决多对问题。Yuan 等人^[27]和 Chen 等人^[28]分别提出两种标签方案将情绪-原因对抽取任务转化为序列标注任务。Chen 等人^[29]则利用情绪原因的相对位置关系来构建邻接矩阵，提出基于图卷积网络^[30]的情绪-原因对抽取方法。上述方法大多是通过两个子句的向量通过拼接等手段，在句对层面进行分类。而 Ding 等人^[7]则提出一种基于滑动窗口的方法，在窗口内进行了多标签分类，为中心假定情绪句子检测原因，实现“情绪-原因对”的抽取。

上述工作聚焦于新闻领域，在社交媒体领域情绪原因抽取任务近年来也有一些进展。Gui 等人^[17]通过标注全部情绪关键词、情绪类别和原因，构建了一个包含 1 333 条样本的小规模微博数据集。Gao 等人^[31]在其数据集中仅标注了文本中的主导情绪及其原因。Cheng 等人^[32]发布了一套公

开的多用户结构微博情绪原因抽取数据集，并提出两种任务：当前子推中的情绪原因检测和原始子推中的情绪原因检测。

5 结论

本文针对中文社交媒体领域情绪-原因对抽取的问题构建了一个微博数据集，该数据集同时包含显式和隐式情绪表达及用户意图，是当前规模最大的数据集。通过分析微博数据的特点，本文还提出了一种融合情绪类别与意图信息的情绪-原因对抽取方法，并将其与主流方法进行了对比。该方法通过将情绪分类和意图识别引入模型训练的过程，增强了监督信号。实验结果表明，该方法能够有效改善“情绪-原因对”的抽取。同时，还分析了情绪类别与意图信息分别对情绪-原因对抽取的影响。在未来工作中，将会重点关注如何设计更加合理的模型结构来融合情绪类别和意图信息。

参考文献

- [1] Ekman P. Expression and the nature of emotion[J]. *Approaches to emotion*, 1984, 3(19): 344.
- [2] 徐琳宏, 林鸿飞, 潘宇, 等. 情感词汇本体的构造[J]. *情报学报*, 2008, 27(2): 180–185.
- [3] Chen Y, Lee S Y M, Li S, et al. Emotion cause detection with linguistic constructions[C]//Coling 2010 - 23rd International Conference on Computational Linguistics, Proceedings of the Conference. 2010, 2(August): 179–187.
- [4] Hripcsak G, Rothschild A S. Agreement, the F-measure, and reliability in information retrieval[J]. *Journal of the American Medical Informatics Association*, 2005, 12(3): 296–298.
- [5] 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, Volume 1 (Long and Short Papers). 2019: 4171–4186.
- [6] Huang J, Shen H, Hou L, et al. Graph Attention Networks[C]//ICLR. 2018.
- [7] Ding Z, Xia R, Yu J. End-to-End Emotion-Cause Pair Extraction based on Sliding Window Multi-Label Learning[C]//EMNLP 2020 - Conference on Empirical Methods in Natural Language Processing, Proceedings. 2020, 3: 3574–3583.
- [8] Wei P, Zhao J, Mao W. Effective Inter-Clause Modeling for End-to-End Emotion-Cause Pair Extraction[C]//ACL 2020 - 58th Annual Meeting of the Association for Computational Linguistics, Proceedings of the Conference. 2020: 3171–3181.
- [9] Goole. BERT-Base, Chinese[EB/OL]. (2018). <https://github.com/google-research/bert>.
- [10] Glorot X, Bengio Y. Understanding the difficulty of training deep feedforward neural networks[C]//Proceedings of the 13th International Conference on Artificial Intelligence and Statistics (AISTATS) 2010. 2010, 9: 1074–1078.
- [11] Kingma D P, Ba J L. Adam: A method for stochastic optimization[C]//3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings. 2015: 1–15.
- [12] Fan C, Yuan C, Du J, et al. Transition-based Directed Graph Construction for Emotion-Cause Pair Extraction[C]//ACL 2020 - 58th Annual Meeting of the Association for Computational Linguistics, Proceedings of the Conference. 2020: 3707–3717.
- [13] 宗成庆, 夏睿, 张家俊. 文本数据挖掘[M]. 清华大学出版社, 2019.
- [14] Zong C, Xia R, Zhang J. Text Data Mining[M]. Springer, 2021.
- [15] Lee S Y M, Chen Y, Huang C-R. 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(June): 45–53.
- [16] Rubino F, Cnr I L C A Z, Moruzzi V G, et al. EMOCause : An Easy-adaptable Approach to Emotion Cause Contexts[C]//Proceedings of the 2nd Workshop on Computational Approaches to Subjectivity and Sentiment Analysis, ACL-HLT 2011,. 2011: 153–160.
- [17] Gui L, Yuan L, Xu R, et al. Emotion Cause Detection with Linguistic Construction in Chinese Weibo Text[C]//Natural Language Processing and Chinese Computing. 2014: 457–464.
- [18] Gui L, Wu D, Xu R, et al. Event-driven emotion cause extraction with corpus construction[C]//EMNLP 2016 - Conference on Empirical Methods in Natural Language Processing, Proceedings. 2016: 1639–1649.
- [19] 刁宇峰, 亮杨, 林鸿飞, 等. 基于ECPA神经网络的情绪原因识别方法[J]. 中文信息学报, 2021, 35(6): 85–92.
- [20] 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.
- [21] Li X, Song K, Feng S, et al. A Co-Attention Neural Network Model for Emotion Cause Analysis with Emotional Context Awareness[C]//EMNLP 2018 - Conference on Empirical Methods in Natural Language Processing, Proceedings. 2018: 4752–4757.
- [22] Fan C, Yan H, Du J, et al. A knowledge regularized hierarchical approach for emotion cause analysis[C]//EMNLP-IJCNLP 2019 - 2019 Conference on Empirical Methods in Natural Language Processing and 9th International Joint Conference on Natural Language Processing, Proceedings of the Conference. 2019: 5614–5624.
- [23] Ding Z, He H, Zhang M, et al. From independent prediction to reordered prediction: Integrating relative position and global label information to emotion cause identification[C]//33rd AAAI Conference on Artificial Intelligence, AAAI 2019.

- 2019: 6343–6350.
- [24] Xia R, Mengran Z, Zixiang D. RTHN:ARNN-Transformer Hierarchical Network for Emotion Cause Extraction[C]//Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence, IJCAI-19. 2019: 5285–5291.
- [25] Xia R, Ding Z. Emotion-cause pair extraction: A new task to emotion analysis in texts[C]//ACL 2019 - 57th Annual Meeting of the Association for Computational Linguistics, Proceedings of the Conference. 2019: 1003–1012.
- [26] Ding Z, Xia R, Yu J. ECPE-2D: Emotion-Cause Pair Extraction based on Joint Two-Dimensional Representation, Interaction and Prediction[C]//ACL 2020 - 58th Annual Meeting of the Association for Computational Linguistics, Proceedings of the Conference. 2020, 1: 3161–3170.
- [27] Yuan C, Fan C, Bao J, et al. Emotion-Cause Pair Extraction as Sequence Labeling Based on A Novel Tagging Scheme[C]//EMNLP 2020 - Conference on Empirical Methods in Natural Language Processing, Proceedings. 2020: 3568–3573.
- [28] Chen X, Li Q, Wang J. A Unified Sequence Labeling Model for Emotion Cause Pair Extraction[C]//COLING 2020 - Proceedings of the 28th International Conference on Computational Linguistics. 2020: 208–218.
- [29] Chen Y, Hou W, Li S, et al. End-to-End Emotion-Cause Pair Extraction with Graph Convolutional Network[C]//COLING 2020 - Proceedings of the 28th International Conference on Computational Linguistics. 2020: 198–207.
- [30] Santerne A, Moutou C, Tsantaki M, et al. Semi-Supervised Classification with Graph Convolutional Networks[C]//ICLR 2017. 2017.
- [31] Gao K, Xu H, Wang J. A rule-based approach to emotion cause detection for Chinese micro-blogs[J]. Expert Systems with Applications, Elsevier Ltd, 2015, 42(9): 4517–4528.
- [32] Cheng X, Chen Y, Cheng B, et al. An emotion cause corpus for Chinese Microblogs with multiple-user structures[J]. ACM Transactions on Asian and Low-Resource Language Information Processing, 2017, 17(1): 1–19.



周玉（1976—），通信作者，博士，研究员，主要研究领域为自然语言处理和机器翻译。
E-mail: yzhou@nlpr.ia.ac.cn



陈仲豪（1994—），硕士研究生，主要研究领域为自然语言处理和情感分析。
E-mail: zhonghao.chen@nlpr.ia.ac.cn



朱军楠（1993—），博士，助理研究员，主要研究领域为自然语言处理和自动摘要。
E-mail: junnan.zhu@nlpr.ia.ac.cn