

# 基于知识迁移的情感-原因对抽取

赵凤园<sup>1,2</sup> , 刘德喜<sup>1,2</sup> , 万齐智<sup>1,2</sup> , 万常选<sup>1,2</sup> , 刘喜平<sup>1,2</sup> , 廖国琼<sup>1,2</sup>

<sup>1</sup> 江西财经大学信息管理学院/ 江西南昌

<sup>2</sup> 江西财经大学数据与知识工程江西省高校重点实验室/ 江西南昌

dexi.liu@163.com

## 摘要

现有的情感-原因对抽取模型均没有通过加入外部知识来提升情感-原因对的抽取效果。本文提出基于知识迁移的情感-原因对抽取模型(ECPE-KT), 采用知识库获取文本的显性知识编码; 随后引入外部情感分类语料库迁移得到子句的隐性知识编码; 最后拼接两个知识编码, 加入情感(原因)子句预测概率及相对位置, 搭配Transformer机制融合上下文, 并采用窗口机制优化计算压力, 实现情感-原因对抽取。在ECPE数据集上的实验结果显示, 本文提出的方法超过当前最先进的模型ECPE-2D。

**关键词:** 情感-原因对抽取; 知识辅助; 相对位置; 子句预测概率

## Emotion-Cause Pair Extraction Based on Knowledge-Transfer

Zhao Fengyuan<sup>1,2</sup> , Liu Dexi<sup>1,2</sup> , Wan Qizhi<sup>1,2</sup> , Wan Changxuan<sup>1,2</sup> , Liu Xiping<sup>1,2</sup> , Liao Guoqiong<sup>1,2</sup>

<sup>1</sup> School of Information Management, Jiangxi University of Finance and Economics / Jiangxi, Nanchang

<sup>2</sup> Jiangxi University of Finance and Economics, Key Laboratory of Data and Knowledge Engineering / Jiangxi, Nanchang

dexi.liu@163.com

## Abstract

The existing emotion cause pair extraction models do not improve the performance of emotion cause pair extraction by incorporating external knowledge. In this work, we propose an emotion-cause pair extraction model based on knowledge transfer (ECPE-KT), in which knowledge is utilized to obtain explicit knowledge encoding of text. Subsequently, the implicit knowledge encoding of clauses is obtained by the transfer of external sentiment classification corpus. Moreover, conduct filtering via adding the relative position and prediction probability to the representation of clause semantic features. Transformer with window mechanism is used to optimize the calculation pressure. Experimental results show that the proposed method outperforms the state-of-the-art method, i.e., ECPE-2D.

**Keywords:** Emotion-cause pair extraction , Knowledge-assisted , relative position , prediction probability

## 1 引言

©2022 中国计算语言学大会

根据《Creative Commons Attribution 4.0 International License》许可出版

基金项目: 国家自然科学基金项目(No.61972184,62076112)、江西省自然科学基金重点项目(No.20212ACB202002)、江西省主要学科学术和技术带头人培养计划领军人才项目(No.20213BCJL22041)

现有的情感原因抽取工作主要分为情感原因抽取(emotion cause extraction, ECE)(Lee et al., 2010)和情感-原因对抽取(emotion-cause pair extraction, ECPE)(Xia and Ding, 2019),前者是给定文本中的情感表达片段,抽取触发情感的原因片段,后者是同时抽取情感表达片段和情感原因片段。目前ECPE方法存在三方面的不足。首先,对于包含 $N$ 个子句的文本,候选情感-原因对共有 $N^2$ 对,因此识别的效率较低,不适合包含大量子句的长文本。其次,目前的模型尽管能通过候选情感子句和原因子句的相互作用,提升情感-原因对识别的效果,但也存在相互干扰的情况,并直接反映在实验结果上:在相同的ECPE数据集上,与单独抽取情感子句的模型相比,采用情感-原因联合抽取时,情感子句抽取的效果普遍明显下降;且在人工给定情感子句时,原因子句抽取的效果明显更优。第三,关于文本情感分析,目前有较多的人工知识(孙毅et al., 2021)可以帮助提升抽取效果,而触发情感的原因也多为事件(Turcan et al., 2021),情感的主体多为人、组织、机构等实体,如图1所示,这些特点还未见有模型充分利用。




Figure 1: 情感原因文本示例。文本包含7个子句,  $c_1$ 至 $c_7$ ,  $c_7$ 为情感子句,  $c_6$ 是情感子句 $c_7$ 对应的原因子句。其中, (1) 情感子句包含了较为明显的情感词“哭”, 以及表达情感的主体“我娘我嫂子”; (2) 触发情感的原因是一个事件, 如“我哥(主语)死(谓语)在朝鲜(状语)了(语气词)”。

基于以上分析, 本文提出了基于知识迁移的情感-原因对抽取模型(emotion-cause pair extraction model based on knowledge-transfer, ECPE-KT)。ECPE-KT首先引入知识库对文本进行显性知识的编码以加强心理特征、情感词、实体和事件的识别; 然后引入外部情感分类语料库, 构建简易情感分类器训练子句编码, 保存模型迁移得到ECPE数据集中子句的隐性知识编码; 最后结合两个知识编码, 加入情感(原因)子句预测概率及相对位置, 搭配Transformer机制融合子句上下文, 并采用窗口机制优化计算压力, 实现情感-原因对抽取果。

本文主要贡献: (1) 引入人工知识库, 辅助编码文本中的情感词、实体和事件以获取有利于情感抽取的显性知识; (2) 引入外部情感分类数据集, 获取文本中子句蕴含的隐性知识; (3) 在ECPE数据集上对模型进行了验证, 较当前最先进的模型ECPE-2D提升2.74%。

本文的结构如下: 第一节介绍情感-原因对抽取任务及其特点, 以及目前相关研究存在的不足。第二节详细介绍情感-原因对抽取任务的演化过程, 以及相关工作所提出的解决方案。第三节和第四节分别提出ECPE-KT模型并通过实验验证其性能。最后进行总结与展望。

## 2 相关工作

情感原因抽取任务(ECE)由Lee et al. (2010)提出, 给定文本中的情感词及其所属情感类别, 根据已知的情感词抽取原因事件。Chen et al. (2010)分析Lee构建的语料库后发现, 85.75%的情感原因事件均在同一子句中, 未曾跨越多个子句, 从而认为子句是ECE任务中较恰当的单元, 于是提出将情感原因抽取任务由词级别转换为子句级别。然而ECE任务需要标注出文本中的情感词或情感子句, 限制了实际应用场景; 先标注情感后抽取其原因的方法未考虑情感与原因之间的相互指示关系。因此, Xia and Ding (2019)将ECE任务扩展为ECPE任务, 研究方法可被总结为(邱祥庆 et al., 2022):

(1) 2阶段法。Xia and Ding (2019)提出两阶段框架, 先独立抽取情感和原因, 再将其配对过滤。Yu et al. (2021a)提出互助型多任务模型, 基于文献(Xia and Ding, 2019), 添加两个与原任务相同的辅助任务(情感子句和原因子句抽取), 建立情感与原因之间的双向关联, 再采取自蒸馏方法来训练以提高准确性, 降低误差传播。Sun et al. (2021)加入注意力网络分别独立询问上下文中的情感和原因以获得上下文语境语义, 同时讨论了损失函数对误差传播的影响。

(2) 一体化法(Wu et al., 2020)。由于阶段一的召回结果直接影响阶段二的性能, Ding et al.

(2020a)提出Transformer 一体化方法, 将文本中的所有子句都看作情感(原因)子句进行两两组合配对, 并搭配窗口限制(98%的情感-原因对的距离不大于3)和十字路口策略优化计算, 最终效果取得明显提升。Tang et al. (2020a)采用双仿射机制构建基于LSTM的分层网络, 一体化地建模情感抽取和情感-原因对抽取之间的关系, 并引入多注意力机制加强子句间的情感感知。

(3) 基于图的方法。Wei et al. (2020a)利用图注意力学习子句表示, 捕获子句间的潜在关系, 并对子句对进行排序以抽取情感-原因对。Fan et al. (2020a)提出了基于状态转移的联合学习模型, 将ECPE任务转换成一个类似解析的有向图构造过程, 对输入序列从左到右逐步构造和标记有向边, 并使用丰富的非局部特征对子句片段进行评估, 使得模型具备同时识别出文本中的情感及原因的能力, 有效缓解了误差传递问题。

(4) 局部搜索法(Wei et al., 2020b; Cheng et al., 2020a)。Ding et al. (2020b)提出基于滑动窗口的多标签联合学习模型。假设所有子句均为情感子句, 以其为中心句构建滑动窗口, 抽取中心句所对应的原因子句(CMLL)。同理, 假设所有子句均为原因子句, 抽取对应的情感子句(EMLL)。最后采用三种融合策略(平均概率, 逻辑与, 逻辑或)融合CMLL和EMLL的预测结果。Chen et al. (2022)采用多轮推理, 迭代地检测情感原因和情感-原因对。

尽管ECPE任务取得了丰富的成果, 但仍存在不足。端到端的方法大多采用一一配对的形式, 产生大量候选情感-原因对, 不适合包含大量子句的长文本; 大量外部知识被证实可以辅助情感分析(谭红叶 et al., 2020), 而深度学习模型中均未融入。

### 3 ECPE-KT模型

给定一个包含多个子句的文本  $d = \{c_1, c_2, \dots, c_{|d} \}$ , 自动抽取出文本中的情感-原因对:

$$P = \{ \dots, (c^{e1}, c^{c1}), (c^{e2}, c^{c2}), \dots \} \quad (1)$$

其中,  $(c^{e1}, c^{c1})$ 表示文本  $d$  中的第  $i$  个情感-原因对,  $c^{e1}$  表示情感子句,  $c^{c1}$  是原因子句。  $d$  中至少存在一个情感子句, 一个情感子句至少对应一个原因子句(目前已有的数据集基于该假设)。

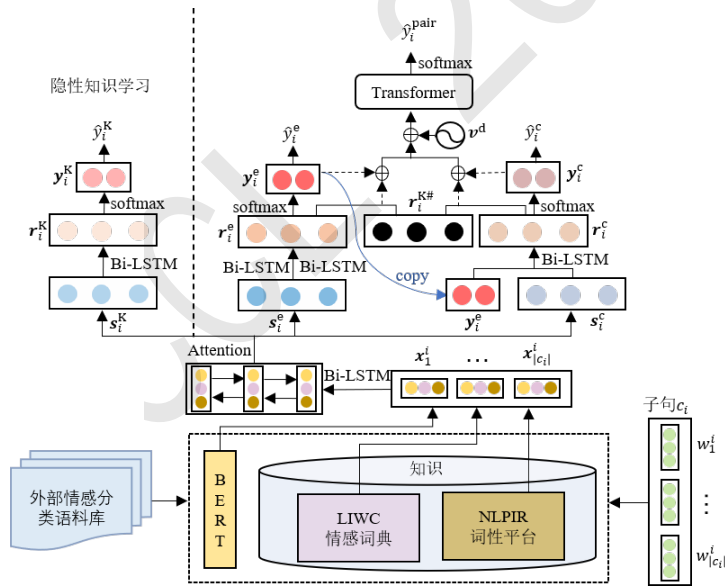


Figure 2: ECPE-KT模型结构图

本文基于Ding et al. (2020a)的ECPE-2D框架, 融入显式知识(LIWC和NLPir词性), 再结合同类语料库中包含的隐性知识, 提出基于知识迁移的情感-原因对抽取模型, 如图2所示。

#### 3.1 知识辅助的子句表示

知识辅助的子句表示如图3所示。给定一个包含  $d$  个子句的文本  $d = \{c_1, c_2, \dots, c_{|d} \}$ , 每一个子句  $c_i = (w_1^i, w_2^i, \dots, w_{|c_i}^i)$  分别包含  $|c_i|$  个词。每个词  $w_j$  的编码  $x_j$  由三部分组成, 分别是基于BERT的语义编码、基于LIWC语言心理特征知识库的词类编码和基于NLPir的词性编码。

<b>Input</b>	说	我	哥	死	在	朝鲜	了
BERT Embedding	$w_{说}^{BERT}$	$w_{我}^{BERT}$	$w_{哥}^{BERT}$	$w_{死}^{BERT}$	$w_{在}^{BERT}$	$w_{朝鲜}^{BERT}$	$w_{了}^{BERT}$
	+	+	+	+	+	+	+
LIWC Embedding	$w_{说}^{LIWC}$	$w_{我}^{LIWC}$	$w_{哥}^{LIWC}$	$w_{死}^{LIWC}$	$w_{在}^{LIWC}$	$w_{朝鲜}^{LIWC}$	$w_{了}^{LIWC}$
	+	+	+	+	+	+	+
NLPIR POS Embedding	$w_{说}^{NLPIR}$	$w_{我}^{NLPIR}$	$w_{哥}^{NLPIR}$	$w_{死}^{NLPIR}$	$w_{在}^{NLPIR}$	$w_{朝鲜}^{NLPIR}$	$w_{了}^{NLPIR}$
<b>Word Embedding</b>	$x_{说}$	$x_{我}$	$x_{哥}$	$x_{死}$	$x_{在}$	$x_{朝鲜}$	$x_{了}$

Figure 3: 知识辅助的子句表示

### 3.1.1 基于BERT的语义编码

BERT(Devlin et al., 2019)是一个强大的预训练模型，作为词嵌入效果显著，ECPE-KT采用BERT BASE对每个词 $w_j$ 进行编码，得到768维的词向量表示 $w_j^{BERT}$ 。

### 3.1.2 基于LIWC的词类编码

情感子句是用户所表达出来的带有情感色彩的子句，相较于非情感子句，其富含了表达用户情感或心理变化的词类。故此，ECPE-KT利用LIWC知识库对词语类别进行标注，便于侧重学习心理知识，从而辅助情感子句的抽取。本文利用黄金兰et al. (2012)构建的SC-LIWC词典，采用one-hot对词语 $w_j$ 进行编码，得到一个71维的向量 $w_j^{LIWC}$ 。如词语“不幸”在SC-LIWC词典中属于功能词、否定词、情感历程词、负向情绪词和悲伤词等5种词类，根据one-hot编码可得到“不幸”一词的词类编码结果为71维向量： $w_{不幸}^{LIWC}=[1,0,\dots,1,0,\dots,1,0,1,0,0,1,0,\dots,0]$ 。

### 3.1.3 基于NLPIR的词性编码

情感主体来自实体，识别子句中的人名、人称代词等特征有助于辅助情感子句的抽取。NLPIR 分析平台(张华平and 商建云, 2019)能够较为精准地识别出文本中的人名、机构名、地名和代词等，因此本文采用该平台对语料进行词性标注。

为避免过多的词性种类导致维度的稀疏，ECPE-KT保留{人名nr、地名ns、其他名词n、形容词a、副词d、动词v、人称代词rr、其他代词r}共8种词性，将其余词性统一合并为其他词性other。本文采用one-hot对子句中词语 $w_j$ 的词性进行编码，得到一个9维的向量表示 $w_j^{NLPIR}$ 。

ECPE-KT模型中候选子句的词语 $w_j$ 编码是 $w_j^{BERT}$ 、 $w_j^{LIWC}$ 和 $w_j^{NLPIR}$ 的拼接，表示为：

$$\mathbf{x}_j = [w_j^{BERT} \oplus w_j^{LIWC} \oplus w_j^{NLPIR}] \quad (2)$$

## 3.2 隐性知识学习

本文采用NLPCC2013中文微博情绪分析评测任务中的数据集中作为外部情感分类语料库，该数据集由姚源林et al. (2014)构建，其描述如表1所示。

Table 1: NLPCC2013数据集描述

统计粒度		有情绪	无情绪	总计	统计粒度		有情绪	无情绪	总计
微博级	数量	7407	6593	14000	句子级	数量	15688	29733	45421
	占比	52.91%	47.09%	100%		占比	34.54%	65.46%	100%

### 3.2.1 数据预处理

NLPCC2013数据集由微博组成，具有对话型回复、文本短、包含表情符等特点。微博在转发、回复等模式下会自动生成“//@微博昵称：”、“回复@微博昵称：”等与内容无关的格式化文本，这类文本不仅无益于语义理解，还可能造成歧义，如“回复@幸运的兰妹妹”，可能会使模型认为子句包含了情感——“幸运”。因此本文利用正则表达式删除了这类格式化文本。

除了格式化文本之外，微博用户常使用一些表情符，如：☺☺、T^T、^\_^。尽管表情符具有一定的情感表达作用，但是ECPE数据集中不存在这类符号，且其多为字符拼接而成，在进行分词操作时存在字符被逐一切分的情况。因此将NLPCC2013数据集中的表情符也统一删除。

### 3.2.2 情感识别的预热模型

给定情感分类语料库中的第 $k$ 个文本 $d^k$ ，它包含 $|d^k|$ 个子句， $d^k = \{c_1, c_2, \dots, c_{|d^k|}\}$ ，每一个子句 $c_i = (w_1^i, w_2^i, \dots, w_{|c_i|}^i)$ 分别包含 $|c_i|$ 个词， $d^k$ 中每个子句 $c_i$ 的情感标签为 $\mathbf{y}_i^{\text{kno}}$ 。根据3.1节获得每个词 $w_j$ 的编码表示 $\mathbf{x}_j$ 。

情感识别的预热模型采用词语层和子句层结合的双层Bi-LSTM(Graves et al., 2013):

#### (1) 词语层Bi-LSTM

将一个包含 $|c_i|$ 个词语的子句 $c_i = (w_1^i, w_2^i, \dots, w_{|c_i|}^i)$ 的编码表示 $(\mathbf{x}_1^i, \mathbf{x}_2^i, \dots, \mathbf{x}_{|c_i|}^i)$ 作为输入，送入Bi-LSTM中，得到子句 $c_i$ 中第 $j$ 个词语的隐层表示 $\mathbf{h}_j^i = \text{Bi-LSTM}(\mathbf{x}_1^i, \mathbf{x}_2^i, \dots, \mathbf{x}_{|c_i|}^i) \in \mathbb{R}^{2d_h}$ ，其中 $d_h$ 是Bi-LSTM的隐藏单元个数。

再对每个词语采用自注意力机制(Luong et al., 2015)得到子句 $c_i$ 的编码表示 $\mathbf{s}_i^K$ :

$$\alpha_{ij}^K = \mathbf{W}_\alpha^T \tanh(\mathbf{W}_h \mathbf{h}_j^i + \mathbf{b}_h); \quad \beta_{ij}^K = \exp(\alpha_{ij}^K) / \sum_{j=1}^{|c_i|} \exp(\alpha_{ij}^K); \quad \mathbf{s}_i^K = \sum_{j=1}^{|c_i|} \beta_{ij}^K \mathbf{h}_j^i \quad (3)$$

其中 $\mathbf{W}_\alpha \in \mathbb{R}^{2d_h}$ ， $\mathbf{W}_h \in \mathbb{R}^{2d_h \times 2d_h}$ 和 $\mathbf{b}_h \in \mathbb{R}^{2d_h}$ 可学习的参数。

#### (2) 子句层Bi-LSTM

子句层Bi-LSTM的目的是捕捉子句间的语义依赖。对于包含 $|d^k|$ 个子句的文本 $d^k = \{c_1, c_2, \dots, c_i, \dots, c_{|d^k|}\}$ ，将各个子句的编码 $(\mathbf{s}_1^K, \mathbf{s}_2^K, \dots, \mathbf{s}_i^K, \dots, \mathbf{s}_{|d^k|}^K) \in \mathbb{R}^{|d^k| \times 2d_h}$ 送入Bi-LSTM，得到Bi-LSTM的隐藏状态，即子句 $c_i$ 的上下文表示 $\mathbf{r}_i^K = \text{Bi-LSTM}(\mathbf{s}_1^K, \mathbf{s}_2^K, \dots, \mathbf{s}_i^K, \dots, \mathbf{s}_{|d^k|}^K) \in \mathbb{R}^{2d_h}$ 。

最后将 $\mathbf{r}_i^K$ 送入softmax函数，得到外部情感分类语料库子句 $c_i$ 是情感子句的概率 $\mathbf{y}_i^K = \text{softmax}(\mathbf{W}^K \mathbf{r}_i^K + \mathbf{b}^K)$ ，其中 $\mathbf{W}^K \in \mathbb{R}^{d_m \times 2d_h}$ ， $\mathbf{b}^K \in \mathbb{R}^{d_m}$ ， $d_m$ 表示类别数。

为了更好地学习子句的隐性知识表示，模型引入了损失函数 $L^K = -\sum_{i=1}^{|d^k|} \mathbf{y}_i^{\text{kno}} \cdot \log(\mathbf{y}_i^K)$ ，其中 $\mathbf{y}_i^{\text{kno}}$ 表示外部情感分类语料库子句 $c_i$ 作为情感子句的真实分布。

在NLPCC2013数据集上训练后得到情感识别的预热模型。对于ECPE数据集中给定的子句 $c_i$ ，可得到其隐状态，代表使用外部数据推断出来的情感隐性知识，记为 $\mathbf{r}_i^{K\#}$ 。

### 3.3 情感信息编码

对于ECPE数据集，给定一个包含 $|d|$ 个子句的文本 $d = \{c_1, c_2, \dots, c_{|d|}\}$ ，每一个子句 $c_i = (w_1^i, w_2^i, \dots, w_{|c_i|}^i)$ 分别包含 $|c_i|$ 个词。根据3.1节得到每个词 $w_j$ 的显性知识编码表示 $\mathbf{x}_j$ ，再将其送入3.2.2节的双层Bi-LSTM中，得到子句 $c_i$ 的上下文表示 $\mathbf{r}_i^e \in \mathbb{R}^{2d_h}$ ，最后将 $\mathbf{r}_i^e$ 送入softmax函数，得到子句 $c_i$ 是情感子句的概率 $\mathbf{y}_i^e = \text{softmax}(\mathbf{W}^e \mathbf{r}_i^e + \mathbf{b}^e)$ ，其中 $\mathbf{W}^e \in \mathbb{R}^{d_m \times 2d_h}$ ， $\mathbf{b}^e \in \mathbb{R}^{d_m}$ ， $d_m$ 表示类别数。

### 3.4 原因信息编码

原因信息的编码也采用词语层和子句层结合的双层Bi-LSTM，与3.1节和3.2.2节相同。将子句 $c_i$ 的编码表示 $\mathbf{s}_i^c$ 和情感信息编码阶段得到的情感预测概率值 $\mathbf{y}_i^e$ 进行拼接，得到子句 $c_i$ 的编码表示 $(\mathbf{s}_i^c \oplus \mathbf{y}_i^e)$ 。为捕捉上下文信息，将文本 $d$ 中 $|d|$ 个子句的向量表示 $(\mathbf{s}_1^c \oplus \mathbf{y}_1^e, \dots, \mathbf{s}_i^c \oplus \mathbf{y}_i^e, \dots, \mathbf{s}_{|d|}^c \oplus \mathbf{y}_{|d|}^e)$ 作为Bi-LSTM的输入，得到Bi-LSTM的隐藏状态，即子句 $c_i$ 的上下文表示 $\mathbf{r}_i^c \in \mathbb{R}^{2d_h}$ :

$$\mathbf{r}_i^c = \text{Bi-LSTM}(\mathbf{s}_1^c \oplus \mathbf{y}_1^e, \dots, \mathbf{s}_i^c \oplus \mathbf{y}_i^e, \dots, \mathbf{s}_{|d|}^c \oplus \mathbf{y}_{|d|}^e) \quad (4)$$

最后将 $\mathbf{r}_i^c$ 送入softmax函数中，得到子句 $c_i$ 的原因预测概率值 $\mathbf{y}_i^c = \text{softmax}(\mathbf{W}^c \mathbf{r}_i^c + \mathbf{b}^c)$ ，其中 $\mathbf{W}^c \in \mathbb{R}^{d_m \times 2d_h}$ ， $\mathbf{b}^c \in \mathbb{R}^{d_m}$ 。

### 3.5 情感-原因对抽取

#### 3.5.1 情感-原因配对

为避免误差传递，本文选择将所有子句进行一一配对。将文本 $d$ 中的子句配对后得到形如 $|d| * |d|$ 的矩阵 $\mathbf{M}$ ， $M_{i,j}$ 表示候选情感子句 $c_i$ 和候选原因子句 $c_j$ 的配对结果。融合情感子句上

下文表示 $r_i^e$ 和其隐性知识表示 $r_i^{K\#}$ , 得到候选情感子句 $c_i$ 的隐性知识表示 $r_i^{Ke} = r_i^e \oplus r_i^{K\#}$ ; 同理, 得到候选原因子句 $c_j$ 的隐性知识表示 $r_j^{Kc} = r_j^c \oplus r_j^{K\#}$ 。由此情感-原因配对被编码为 $M_{i,j}$ :

$$M_{i,j} = r_i^{Ke} \oplus y_i^e \oplus r_j^{Kc} \oplus y_j^c \oplus v^d \quad (5)$$

其中,  $y_i^e$  是情感预测概率,  $y_j^c$  是原因预测概率,  $v^d$ 为子句 $c_i$ 和子句 $c_j$ 的相对距离。

### 3.5.2 情感-原因交互

考虑到一个长度为 $|d|$ 的文本将会生成 $|d| * |d|$ 个可能的情感-原因对矩阵 $M$ , 然而其中仅有一小部分具有因果关系; 且当一个子句被认为是情感(原因)子句, 其上下文中的其他子句成为情感(原因)子句的概率将会减小。因此本文采用Transformer(Vaswani et al., 2017)对矩阵 $M$ 进行全局信息融合以实现情感和原因信息之间的有效交互。

(1) 标准的Transformer

标准的Transformer由 $N(N=6)$ 层encoding和decoding堆叠而成, 每层由多头自注意力机制和前馈网络两个组件组成。

多头自注意力机制首先计算文本 $d$ 中候选情感-原因对 $c_i^e - c_j^c$ 的查询向量 $q_{i,j}$ , 关键字向量 $k_{i,j}$ 和值向量 $v_{i,j}$ :

$$q_{i,j} = \text{Relu}(M_{i,j} W_Q); \quad k_{i,j} = \text{Relu}(M_{i,j} W_K); \quad v_{i,j} = \text{Relu}(M_{i,j} W_V) \quad (6)$$

其中 $W_Q \in \mathbb{R}^{n \times n}$ ,  $W_K \in \mathbb{R}^{n \times n}$ ,  $W_V \in \mathbb{R}^{n \times n}$ 分别是查询、关键字和值向量的可训练参数。

通过模型的学习优化, 可以得到矩阵 $M$ 中每个候选情感-原因对 $M_{i,j}$ 的新特征表示 $\hat{Z}_{i,j}$ :

$$\beta_{i,j,a,b} = \frac{\exp\left(\frac{q_{i,j} \cdot k_{a,b}}{\sqrt{n}}\right)}{\sum_{a'} \sum_{b'} \exp\left(\frac{q_{i,j} \cdot k_{a',b'}}{\sqrt{n}}\right)}; \quad \hat{z}_{i,j} = \sum_{a=1}^{|d|} \sum_{b=1}^{|d|} \beta_{i,j,a,b} \cdot v_{a,b} \quad (7)$$

在使用自注意力机制之后, 将前馈网络应用到每个候选配对上:

$$\hat{o}_{i,j} = \max(0, \hat{Z}_{i,j} W_1 + b_1) W_2 + b_2 \quad (8)$$

使用残差连接和归一化操作, 得到多头自注意力层输出 $z_{i,j}$ , 前馈网络层输出 $o_{i,j}$ :

$$z_{i,j} = \text{Normalize}(\hat{z}_{i,j} + M_{i,j}); \quad o_{i,j} = \text{Normalize}(\hat{o}_{i,j} + z_{i,j}) \quad (9)$$

记 $l$ 为每一层的索引, 上一层的输出将被作为下一层的输入, 由 $N$ 层堆叠的Transformer将被表示为:  $M_{i,j}^{(l+1)} = o_{i,j}^{(l)}$ 。

(2) 基于窗口的Transformer

由于配对矩阵 $M$ 中有 $|d| * |d|$ 个元素( $M_{i,j}$ ), 每个 $M_{i,j}$ 需要计算 $|d| * |d|$ 个注意力权重, 最终需要计算和保存 $(|d| * |d|) * (|d| * |d|)$ 个权重信息。为了减轻计算压力, 同时基于对数据集的统计, 仅1.85%的原因子句与情感子句之间的距离超过了4, 本文提出基于窗口的Transformer对子句进行交互优化计算。

基于窗口的Transformer是将配对矩阵 $M$ 中的候选情感-原因对 $c_i^e - c_j^c$ 限制在窗口内, 即只采用下标符合 $j-i \in [-window, window]$ 的候选情感-原因对作为Transformer的输入。值得一提的是, 基于窗口的Transformer不仅大大节省了计算资源, 还在一定程度上缓解了分类不均衡的问题, 减少了 $window$ 之外的负样本输入。

### 3.5.3 情感-原因对预测

将候选情感-原因对 $M_{i,j}$ 通过 $N$ 层堆叠的Transformer后, 得到每个候选情感-原因对的向量表示 $o_{i,j}^{(N)}$ , 将其送入softmax函数得到候选情感-原因对 $c_i^e - c_j^c$ 是情感-原因的概率分布 $y_i^{\text{pair}} = \text{softmax}(W^{\text{pair}} o_{i,j}^{(N)} + b^{\text{pair}})$ 。

文本 $d$ 中情感-原因对分类器的损失 $L^{\text{pair}} = -\sum_{i=1}^{|d|} \sum_{j=1}^{|d|} \mathbf{y}_i^{\text{pair}} \cdot \log(\mathbf{y}_i^{\text{pair}})$ , 其中 $\mathbf{y}_i^{\text{pair}}$ 是文本 $d$ 中候选情感-原因对 $c_i^e - c_j^c$ 的真实概率分布。

为了更好的学习情感信息编码和原因信息编码, 引入辅助任务的联合交叉熵损失 $L^{\text{ec}} = -\sum_{i=1}^{|d|} \mathbf{y}_i^{\text{emo}} \cdot \log(\mathbf{y}_i^e) - \sum_{i=1}^{|d|} \mathbf{y}_i^{\text{cau}} \cdot \log(\mathbf{y}_i^c)$ , 其中 $\mathbf{y}_i^{\text{emo}}$ 和 $\mathbf{y}_i^{\text{cau}}$ 分别表示子句 $c_i$ 作为情感子句和原因子句的真实概率分布。

ECPE-KT最终损失为情感-原因对抽取的损失 $L^{\text{pair}}$ 和辅助任务的损失 $L^{\text{ec}}$ 在L2正则化下的加权求和:  $L = \lambda_1 L^{\text{pair}} + \lambda_2 L^{\text{ec}} + \lambda_3 \|\theta\|^2$ , 其中 $\lambda_1, \lambda_2, \lambda_3 \in (0,1)$ 是权重,  $\theta$ 是模型的所有参数。

## 4 实验分析

### 4.1 数据集介绍

本文采用Xia and Ding (2019)提出ECPE任务时公开的情感原因数据集。其中, 1746个文本(占比89.77%)仅含有一个情感-原因对, 177个文本(占比9.10%)含有两个情感-原因对, 22个文本(占比1.13%)含有两个以上情感-原因对, 总计1945个文本。

### 4.2 实验设置

词向量为768维。词类编码向量为71维, 词性编码向量为9维。Bi-LSTM的隐藏单元为100, 注意力机制的查询、关键字和值向量设置为30维。所有的权重 $\mathbf{W}$ 和偏置 $\mathbf{b}$ 随机初始化为 $(-0.01, 0.01)$ 区间上的均匀分布。文本长度75, 子句长度45。采用十折交叉验证, 结合随机梯度下降SGD算法和Adam算法更新参数。样本批量大小和学习率分别为8和0.0005; 词语层Bi-LSTM的dropout均为0.5; L2正则化中的权重 $\lambda_1, \lambda_2, \lambda_3$ 分别设置为1, 1, 1e-5; 位置向量维度为50维<sup>0</sup>。

### 4.3 对比模型

**ECPE-2Steps**: Xia and Ding (2019)首次提出ECPE任务时采用的模型。该模型先抽取情感子句和原因子句, 再过滤情感-原因对。其中情感子句和原因子句的抽取分别采用了三种方法: (1) **Indep**: 独立抽取情感子句和原因子句。(2) **Inter-CE**: 将原因子句的预测分布作为特征, 辅助抽取情感子句。(3) **Inter-EC**: 将情感子句的预测分布作为特征, 辅助抽取原因子句。**ECPE-2D**(Ding et al., 2020a): 基于窗口化Transformer的一体化方法。**RANKCP**(Wei et al., 2020a): 图注意力模型。**TDGC**(Fan et al., 2020a): 基于状态转移的联合学习模型。**MTNECP**(Yu et al., 2021a): 多任务神经网络模型。**ECPE-MLL**(Ding et al., 2020b): 基于滑动窗口的多标签联合学习模型。**DQAN**(Sun et al., 2021): 注意力网络分别独立询问上下文中的情感和原因以获得上下文语境语义。**RSNLSTM**(Chen et al., 2022): 采用多轮推理, 迭代地检测情感原因和情感-原因对。**Inter-ECNC**(Shan and Zhu, 2020): 多头注意力网络模型。**MAM-SD**(Yu et al., 2021b): 相互辅助的多任务模型。**LAE-MANN**(Tang et al., 2020b): 基于双仿射机制的LSTM分层网络模型。**E2EECPE**(Song et al., 2020): 基于双向关注的定向预测模型。**SLSN-U**(Cheng et al., 2020b): 对称式局部搜索网络模型。**RHNSC**(Fan et al., 2020b): 端到端的分层神经网络模型。**IE-CNN+CRF**(Chen et al., 2020): 基于多类别情感标签的卷积神经网络模型。**ECPE-SL**(Yuan et al., 2020): 结合类型标签和距离标签的Bi-LSTM模型。**ECPE-KA**(刘德喜 et al., 2021): 外部人工知识(LIWC词典和词性)的2阶段抽取模型。

### 4.4 实验结果分析

ECPE-KT的评测结果如表2所示。由表2可知, 各个模型采用的方法主要分为“2阶段”法和端到端法, 后者的性能明显优于前者。值得一提的是, 综合使用了端到端模式和外部知识的ECPE-KT在ECPE任务上各个评测指标都达到最优, 相较其他模型, 分别在 $F1$ 值上提升2.74%~21.66%, 在精确率 $P$ 上提升2.03%~16.15%, 在召回率 $R$ 上提升2.34%~31.82%。

<sup>0</sup><https://github.com/Inkblue/ECPE-KT>

Table 2: 实验评测结果

模型名称	emotion extraction			cause extraction			ECPE			方法
	<i>P</i>	<i>R</i>	<i>F1</i>	<i>P</i>	<i>R</i>	<i>F1</i>	<i>P</i>	<i>R</i>	<i>F1</i>	
Indep	.8375	.8071	.8210	.6902	.5673	.6205	.6832	.5082	.5818	2阶段笛卡尔积
Inter-CE	.8494	.8122	.8300	.6809	.5634	.6151	.6902	.5135	.5901	2阶段笛卡尔积
Inter-EC	.8364	.8107	.8230	.7041	.6083	.6507	.6721	.5705	.6128	2阶段笛卡尔积
Inter-ECNC	/	/	/	.6863	.6254	.6544	.6601	.5734	.6138	2阶段笛卡尔积
MAM-SD	.8554	.8141	.8339	.7202	.6375	.6751	.6963	.5799	.6320	2阶段笛卡尔积
TDGC	.8716	.8244	.8474	<b>.7562</b>	.6471	.6974	.7374	.6307	.6799	解析式转移系统
E2EECP	.8595	.7915	.8238	.7062	.603	.6503	.6478	.6105	.6280	矩阵变换
MTNECP	.8662	.8393	.8520	.7400	.6378	.6844	.6828	.5894	.6321	矩阵变换
LAE-MANN	<b>.8990</b>	.8000	.8470	/	/	/	.7110	.6070	.6550	矩阵变换
ECPE-2D	.8627	<b>.9221</b>	<b>.8910</b>	.7336	.6934	<b>.7123</b>	.7292	.6544	.6889	矩阵变换
RHNSC	/	/	/	/	/	/	.6956	.5871	.6357	局部搜索
SLSN-U	.8406	.7980	.8181	.6992	.6588	.6778	.6836	.6291	.6545	局部搜索
RANKCP	.8703	.8406	.8548	.6927	.6743	.6824	.6698	.6546	.6610	局部搜索
ECPE-MLL	.8582	.8429	.8500	.7248	.6702	.6950	.7090	.6441	.6740	局部搜索
IE-CNN+CRF	.8614	.7811	.8188	.7348	.5841	.6496	.7149	.6279	.6686	序列标注
ECPE-SL	.8196	.7329	.7739	.7490	.6602	.7018	.7243	.6366	.6776	序列标注
ECPE-KA	.8549	.8958	.8746	.6760	<b>.7453</b>	.7083	.7354	.6531	.6914	外部知识
<b>ECPE-KT</b>	.8907	.8880	.8886	.7545	.6722	.7104	<b>.7524</b>	<b>.6699</b>	<b>.7078</b>	外部知识

相较于同样采用了外部知识的ECPE-KA模型，ECPE-KT在ECPE任务的*F1*上提升了2.37%；在精确率*P*上提升了2.31%；在召回率*R*上提升了2.57%。由此说明隐性知识的加入使得模型更充分地理解了语义，对子句的判断更为精准。

相较于ECPE-KT的基准模型ECPE-2D，在ECPE任务上，ECPE-KT( $F1=0.7078$ )取得优于ECPE-2D模型( $F1=0.6889$ )的效果，提升了2.74%；在精确率*P*上提升了3.18%；在召回率*R*上提升了2.37%。精确率*P*的大幅提升进一步佐证了隐性知识对子句语义的正向作用。

特别地，对于含有2个或2个以上情感-原因对的测试用例，ECPE-KT抽取完整的用例占9.375%，至少抽取出1对的用例占62.5%，而Inter-EC识别出的比例分别为6.25%和为56.52%。可见，两者在多情感-原因对文本上的正确率都有待提高，但是ECPE-KT依然有更好的表现。




Figure 4: ECPE方法评测

图4(Figure 4)更直观地展示了不同模型的评测结果。由图4可知，采用2阶段笛卡尔积的模型，精确率*P*和召回率*R*差距较大，模型提升空间大；随着方法的改进，评测指标均不断上升，且精确率*P*和召回率*R*不断趋近。融合了知识和端到端的ECPE-KT性能显著，仅在2阶段方法中加入外部知识的ECPE-KA也表现良好，可见外部知识对模型的辅助功能是不可或缺的。

## 4.5 消融实验

### 4.5.1 知识辅助的影响

表3展示了知识辅助的影响。BERT的影响。去掉BERT的ECPE-KT-BERT相较ECPE-KT在情感子句抽取上的*F1*值大幅降低，但在原因子句抽取上*F1*值有些许提升，最终



Table 3: 知识辅助和交互的影响

模型名称	emotion extraction			cause extraction			ECPE		
	<i>P</i>	<i>R</i>	<i>F1</i>	<i>P</i>	<i>R</i>	<i>F1</i>	<i>P</i>	<i>R</i>	<i>F1</i>
ECPE-2D#	.8511	.8237	.8365	.7133	.6285	.6672	.7118	.5984	.6494
ECPE-KT-BERT	.8684	.8683	.8679	.7526	.6821	<b>.7150</b>	.7481	.6539	.6959
ECPE-KT-know-70	.8730	.8808	.8766	.7388	.6434	.6852	.7192	.6500	.6814
ECPE-KT-know-50	.8799	.8793	.8794	.7318	.6601	.6925	.7164	.6622	.6869
ECPE-KT-inknow	.8867	.8725	.8793	.7513	.6800	.7121	<b>.7596</b>	.6434	.6950
ECPE-2D	.8627	<b>.9221</b>	<b>.8910</b>	.7336	<b>.6934</b>	.7123	.7292	.6544	.6889
ECPE-KT-Trans	.8896	0.8821	.8853	.7526	.6669	.7065	.7478	.6415	.6893
ECPE-KT	<b>.8907</b>	.8880	.8886	<b>.7545</b>	.6722	.7104	.7524	<b>.6699</b>	<b>.7078</b>

在ECPE上*F1*值仅存在1.71%的差距，甚至超越目前最优的ECPE-2D模型。由此说明BERT有利于模型对子句语义的理解，尤其是对事件的判定更为准确，最终使得子模型性能提升。

知识辅助的影响。去掉所有外部知识的ECPE-KT-know相较ECPE-KT在三个任务上的性能都有所下降，尤其是与ECPE-2D#采用相同参数的ECPE-KT-know-70模型，在ECPE上的*F1*值下降了3.87%。去掉隐性知识的ECPE-KT-inknow相较ECPE-KT在三个任务上同样都有所下降，在ECPE任务上的*F1*值存在1.84%的差距。将ECPE-KT-inknow与ECPE-KT-know-50进行比较，可发现在加入显性知识时，模型依旧能取得不错的性能( $F1=0.6950$ )，且优于先进的ECPE-2D模型。由此说明隐性知识和显性知识都能促进模型对子句的理解。

知识辅助与BERT的联合影响。加入了BERT和外部知识的ECPE-KT相较ECPE-2D#，各个指标都明显提升，且显著高于单独使用BERT或外部知识的模型。由此佐证，BERT和知识的相互作用能更有效地提取情感和原因的特征，增强情感-原因对的抽取效果。

#### 4.5.2 情感原因交互的影响

表3比较了使用交互的ECPE-KT和去掉交互的ECPE-KT-Trans的性能。加入交互组件Transformer后，情感-原因对抽取在各个指标上都有提升，精确率*P*提升0.62%，召回率*R*提升4.43%，*F1*值提升2.68%。由此可见，Transformer较好地对子句进行了交互，融合了子句间的信息。尤其是召回率*R*的大幅提升，意味着即使在正负样本不均衡的情况下，模型仍能较好地工作，抽取出尽可能多的正样本。

#### 4.6 ECE任务评测

表4在ECE任务上将ECPE-KT与一些已有的方法进行对比，值得注意的是，经典的ECE任务中，情感子句是人工标注的，而ECPE-KT在测试集中不要求对情感子句进行人工标注。

Table 4: 情感原因抽取任务的评测

Method	<i>P</i>	<i>R</i>	<i>F1</i>	Method	<i>P</i>	<i>R</i>	<i>F1</i>
RB	.6747	.4267	.5243	CANN	<b>.7721</b>	.6891	<b>.7266</b>
CB	.2672	<b>.7130</b>	.3887	CANN-E	.4826	.3160	.3797
ECPE-1C	.4516	.4732	.4618	PAE-DGL	.7619	.6908	.7242
Multi-kernel	.6588	.6927	.6752	ECPE-KT	.7545	.6722	.7104

**RB**(Chen et al., 2010): 自定义语言规则的情感原因抽取方法。**CB**(Russo et al., 2011): 基于知识的情感原因抽取方法。**ECPE-1C**: 已知情感子句，其前一句作为原因子句。**Multi-kernel**(Gui et al., 2016): 结合依存句法树的多核支持向量机模型。**CANN**(Li et al., 2018): 基于协同注意力的Bi-LST模型。**PAE-DGL**(Ding et al., 2019): 关注子句相对位置和全局标签(文本中其他子句的预测标签)的抽取模型。

表4显示，在未对测试数据集标注情感子句的情况下，ECPE-KT在精确率*P*上仅低于CANN和PAE-DGL，在*F1*值上仅与最好的结果(CANN)相差2%。这表明ECPE-KT可以克服ECE任务需要手工进行情感标注的应用限制，当然也存在改进的空间。特别地，基于知识的CB精确率*P*和*F1*值都特别低，但召回率*R*却仅次于ECPE-KT，与本文提出的知识辅助有异曲同工之意，它们都通过知识的引入提升了模型召回更多原因子句的能力。尽管已知情感子句，但ECPE-1C的性能不佳，由此说明很多情感原因并不恰好位于情感子句的前一个子句中。

为了在相同标注下比较各方法的性能，本文对比CANN-E模型(Li et al., 2018)，它将表现较好的CANN在测试时移除了数据集中情感子句的标签。由表4可见，移除了情感标注后CANN-E的性能直线下降，相较CANN在F1值上达到了47.74%的下降。而ECPE-KT同样在没有情感子句标签的情况下，F1值达到了0.7104，较CANN-E提升了87.1%。

#### 4.7 案例分析

图5示例1中，由于ECPE-KA对“依靠”一词的关注使得无任何情感表达的子句 $c_1$ 被抽取为情感子句，从而增加了模型中候选情感-原因对的数量和非必要的计算压力，而加入了外部数据集的ECPE-KT直接过滤了子句 $c_1$ 。同时在采用端到端抽取方法后，尽管ECPE-KT在辅助任务(原因子句)的抽取结果为空的情况下，却依旧能通过子句的信息融合得到正确的情感-原因对。由此可见，端到端的模型有效地克服了流水线模型的误差传导问题。

示例2中，两个模型均未能完整地抽取出情感-原因对。推测为，原因事件多由多个子句联合组成，单独一个子句可能不能完整的反映出整个原因事件。另外，ECPE-KT能够抽取出原因子句 $c_8$ 也从侧面反映出模型能够学习到“不行了”所包含的隐层含义，即表示人即将病逝。这印证了ECPE-KT引入外部情感分类语料库后学习到的隐性知识对模型是有正向作用的。

示例3中，两个模型均抽取错误。其原因可能是目前所采用的知识还未能很好地抽取隐晦的情感词，对于机器而言，子句 $c_6$ 中的“难堪”相较于子句 $c_9$ 中的“羡慕”更为隐晦。尽管ECPE-KT已经采用了外部情感分类语料库来加强隐性知识的学习，但是由于微博文本普遍偏口语化，与采用新闻构建而成的ECPE数据集具有些许差异，使得外部隐性知识未能完全适应数据集。因此加入多样化的外部知识是值得思考和优化的方向。

示例文本	示例1: 依靠父母支持和在学校打工积攒下来的钱( $c_1$ ), 两人共投资50多万元( $c_2$ ), 办起了养鸡场( $c_3$ )。去年11月开始售卖产品( $c_4$ ), 3个月的销售额已经达到了50多万元( $c_5$ )。有这样一个好的开头( $c_6$ ), 两人既是自豪也是对前景充满了信心( $c_7$ )。			示例2: 李芳抹着眼泪告诉小溪( $c_1$ ), 2002年( $c_2$ ), 她的儿子逝去了( $c_3$ )。儿子才17岁( $c_4$ ), 活泼好动( $c_5$ ), 热爱篮球( $c_6$ ), 但是高二体检查出脑瘤( $c_7$ ), 很快就受不了( $c_8$ ), 李芳痛不欲生( $c_9$ ), 捡起一把刀就想割脉自杀( $c_{10}$ )。			示例3: 韩小姐说( $c_1$ ), 不怪别人嘲笑她字体( $c_2$ ), 大学之后不管是学习工作大多都是用电脑和手机打字( $c_3$ )。手写字确实越写越丑( $c_4$ ), 一遇到要手写字的场合( $c_5$ ), 她就觉得有些难堪( $c_6$ ), 毕竟字如其人( $c_7$ )。有时候字体也会成为他人判断自己的标准( $c_8$ ), 看到字写得很好的人很羡慕( $c_9$ )。		
	模型	人工标注	ECPE-KA	ECPE-KT	人工标注	ECPE-KA	ECPE-KT	人工标注	ECPE-KA
情感子句抽取结果	$c_7$	$c_1, c_7$	$c_7$	$c_9$	$c_1, c_9$	$c_9$	$c_6$	$c_9$	$c_9$
原因子句抽取结果	$c_6$	$c_5, c_6$	Empty	$c_7, c_8$	$c_1, c_7$	$c_8$	$c_5$	$c_9$	$c_9$
配对结果	$(c_7, c_6)$	Empty	$(c_7, c_6)$	$(c_9, c_7), (c_9, c_8)$	Empty	$(c_9, c_8)$	$(c_6, c_5)$	$(c_9, c_9)$	$(c_9, c_9)$

Figure 5: ECPE-KT抽取的案例分析

## 5 总结与展望

本文提出基于知识迁移的抽取模型ECPE-KT。通过引入LIWC、词性等外部知识，显式地刻画人物和事件，以辅助学习子句的显性知识编码；引入外部情感分类语料库，构建分类器训练子句编码，保存模型迁移得到ECPE数据集中子句级隐性知识编码；最后将拼接两个知识编码，加入情感(原因)子句预测概率及相对位置信息，搭配Transformer机制融合子句上下文，并采用窗口机制优化计算压力，实现情感-原因对抽取。实验证明了ECPE-KT的有效性，F1值达到0.7078，较最先进的模型(ECPE-2D)提升了2.74%。究其性能提升的原因，可被归纳为两点：一是外部语料库覆盖了更多的情感表达方式，增强了数据量，克服了训练数据不足的问题；二是LIWC词典将词转换为词类，使模型能更好地归纳情感及其原因的表达式。

下一步工作：(1) 采用更新颖和有效的方式来融合显隐性知识。(2) 进一步探索可以利用的人工知识，从数据中挖掘知识，丰富知识库。(3) 目前ECPE任务大都基于文献(Xia and Ding, 2019)，领域有限，期望探索更多领域或者领域无关的模型，扩大应用场景。(4) 外部知识和语料库的加入虽然提升了模型性能，但其计算复杂性（在ECPE-2D的基础上需要进行外部语料库的预热训练、子句向量长度增加）、实现难度（外部语料库的数据清洗）也相应提升，知识蒸馏减少模型的方法将被纳入探索。

## 参考文献

- Ying Chen, Sophia Yat Mei Lee, Shoushan Li, and Chu-Ren Huang. 2010. Emotion cause detection with linguistic constructions. In Chu-Ren Huang and Dan Jurafsky, editors, *COLING 2010, 23rd International Conference on Computational Linguistics, Proceedings of the Conference, 23-27 August 2010, Beijing, China*, pages 179–187. Tsinghua University Press.
- Xinhong Chen, Qing Li, and Jianping Wang. 2020. A unified sequence labeling model for emotion cause pair extraction. In Donia Scott, Núria Bel, and Chengqing Zong, editors, *Proceedings of the 28th International Conference on Computational Linguistics, COLING 2020, Barcelona, Spain (Online), December 8-13, 2020*, pages 208–218. International Committee on Computational Linguistics.
- Fang Chen, Ziwei Shi, Zhongliang Yang, and Yongfeng Huang. 2022. Recurrent synchronization network for emotion-cause pair extraction. *Knowl. Based Syst.*, 238:107965.
- Zifeng Cheng, Zhiwei Jiang, Yafeng Yin, Hua Yu, and Qing Gu. 2020a. A symmetric local search network for emotion-cause pair extraction. In Donia Scott, Núria Bel, and Chengqing Zong, editors, *Proceedings of the 28th International Conference on Computational Linguistics, COLING 2020, Barcelona, Spain (Online), December 8-13, 2020*, pages 139–149. International Committee on Computational Linguistics.
- Zifeng Cheng, Zhiwei Jiang, Yafeng Yin, Hua Yu, and Qing Gu. 2020b. A symmetric local search network for emotion-cause pair extraction. In Donia Scott, Núria Bel, and Chengqing Zong, editors, *Proceedings of the 28th International Conference on Computational Linguistics, COLING 2020, Barcelona, Spain (Online), December 8-13, 2020*, pages 139–149. International Committee on Computational Linguistics.
- Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. 2019. BERT: pre-training of deep bidirectional transformers for language understanding. In Jill Burstein, Christy Doran, and Thamar Solorio, editors, *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, NAACL-HLT 2019, Minneapolis, MN, USA, June 2-7, 2019, Volume 1 (Long and Short Papers)*, pages 4171–4186. Association for Computational Linguistics.
- Zixiang Ding, Huihui He, Mengran Zhang, and Rui Xia. 2019. From independent prediction to re-ordered prediction: Integrating relative position and global label information to emotion cause identification. *CoRR*, abs/1906.01230.
- Zixiang Ding, Rui Xia, and Jianfei Yu. 2020a. ECPE-2D: emotion-cause pair extraction based on joint two-dimensional representation, interaction and prediction. In Dan Jurafsky, Joyce Chai, Natalie Schluter, and Joel R. Tetreault, editors, *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics, ACL 2020, Online, July 5-10, 2020*, pages 3161–3170. Association for Computational Linguistics.
- Zixiang Ding, Rui Xia, and Jianfei Yu. 2020b. End-to-end emotion-cause pair extraction based on sliding window multi-label learning. In Bonnie Webber, Trevor Cohn, Yulan He, and Yang Liu, editors, *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing, EMNLP 2020, Online, November 16-20, 2020*, pages 3574–3583. Association for Computational Linguistics.
- Chuang Fan, Chaofa Yuan, Jiachen Du, Lin Gui, Min Yang, and Ruifeng Xu. 2020a. Transition-based directed graph construction for emotion-cause pair extraction. In Dan Jurafsky, Joyce Chai, Natalie Schluter, and Joel R. Tetreault, editors, *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics, ACL 2020, Online, July 5-10, 2020*, pages 3707–3717. Association for Computational Linguistics.
- Rui Fan, Yufan Wang, and Tingting He. 2020b. An end-to-end multi-task learning network with scope controller for emotion-cause pair extraction. In Xiaodan Zhu, Min Zhang, Yu Hong, and Ruifang He, editors, *Natural Language Processing and Chinese Computing - 9th CCF International Conference, NLPCC 2020, Zhengzhou, China, October 14-18, 2020, Proceedings, Part I*, volume 12430 of *Lecture Notes in Computer Science*, pages 764–776. Springer.
- Alex Graves, Abdel-rahman Mohamed, and Geoffrey E. Hinton. 2013. Speech recognition with deep recurrent neural networks. In *IEEE International Conference on Acoustics, Speech and Signal Processing, ICASSP 2013, Vancouver, BC, Canada, May 26-31, 2013*, pages 6645–6649. IEEE.

- Lin Gui, Dongyin Wu, Ruifeng Xu, Qin Lu, and Yu Zhou. 2016. Event-driven emotion cause extraction with corpus construction. In Jian Su, Xavier Carreras, and Kevin Duh, editors, *Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing, EMNLP 2016, Austin, Texas, USA, November 1-4, 2016*, pages 1639–1649. The Association for Computational Linguistics.
- Sym Lee, C. Ying, and C. R. Huang. 2010. A text-driven rule-based system for emotion cause detection. *Association for Computational Linguistics*.
- Xiangju Li, Kaisong Song, Shi Feng, Daling Wang, and Yifei Zhang. 2018. A co-attention neural network model for emotion cause analysis with emotional context awareness. In Ellen Riloff, David Chiang, Julia Hockenmaier, and Jun'ichi Tsujii, editors, *Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing, Brussels, Belgium, October 31 - November 4, 2018*, pages 4752–4757. Association for Computational Linguistics.
- Thang Luong, Hieu Pham, and Christopher D. Manning. 2015. Effective approaches to attention-based neural machine translation. In Lluís Màrquez, Chris Callison-Burch, Jian Su, Daniele Pighin, and Yuval Marton, editors, *Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing, EMNLP 2015, Lisbon, Portugal, September 17-21, 2015*, pages 1412–1421. The Association for Computational Linguistics.
- Irene Russo, Tommaso Caselli, Francesco Rubino, Ester Boldrini, and Patricio Martínez-Barco. 2011. Emocause: An easy-adaptable approach to extract emotion cause contexts. In Alexandra Balahur, Ester Boldrini, Andrés Montoyo, and Patricio Martínez-Barco, editors, *Proceedings of the 2nd Workshop on Computational Approaches to Subjectivity and Sentiment Analysis, WASSA@ACL 2011, Portland, OR, USA, June 24, 2011*, pages 153–160. Association for Computational Linguistics.
- J. Shan and M. Zhu. 2020. A new component of interactive multi-task network model for emotion-cause pair extraction. *Journal of Physics Conference Series*, 1693:012022.
- Haolin Song, Chen Zhang, Qiuchi Li, and Dawei Song. 2020. End-to-end emotion-cause pair extraction via learning to link. *CoRR*, abs/2002.10710.
- Qixuan Sun, Yaqi Yin, and Hong Yu. 2021. A dual-questioning attention network for emotion-cause pair extraction with context awareness. In *International Joint Conference on Neural Networks, IJCNN 2021, Shenzhen, China, July 18-22, 2021*, pages 1–8. IEEE.
- Hao Tang, Donghong Ji, and Qiji Zhou. 2020a. Joint multi-level attentional model for emotion detection and emotion-cause pair extraction. *Neurocomputing*, 409:329–340.
- Hao Tang, Donghong Ji, and Qiji Zhou. 2020b. Joint multi-level attentional model for emotion detection and emotion-cause pair extraction. *Neurocomputing*, 409:329–340.
- Elsbeth Turcan, Shuai Wang, Rishita Anubhai, Kasturi Bhattacharjee, Yaser Al-Onaizan, and Smaranda Muresan. 2021. Multi-task learning and adapted knowledge models for emotion-cause extraction. In Chengqing Zong, Fei Xia, Wenjie Li, and Roberto Navigli, editors, *Findings of the Association for Computational Linguistics: ACL/IJCNLP 2021, Online Event, August 1-6, 2021*, volume ACL/IJCNLP 2021 of *Findings of ACL*, pages 3975–3989. Association for Computational Linguistics.
- Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Lukasz Kaiser, and Illia Polosukhin. 2017. Attention is all you need. In Isabelle Guyon, Ulrike von Luxburg, Samy Bengio, Hanna M. Wallach, Rob Fergus, S. V. N. Vishwanathan, and Roman Garnett, editors, *Advances in Neural Information Processing Systems 30: Annual Conference on Neural Information Processing Systems 2017, December 4-9, 2017, Long Beach, CA, USA*, pages 5998–6008.
- Penghui Wei, Jiahao Zhao, and Wenji Mao. 2020a. Effective inter-clause modeling for end-to-end emotion-cause pair extraction. In Dan Jurafsky, Joyce Chai, Natalie Schluter, and Joel R. Tetreault, editors, *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics, ACL 2020, Online, July 5-10, 2020*, pages 3171–3181. Association for Computational Linguistics.
- Penghui Wei, Jiahao Zhao, and Wenji Mao. 2020b. Effective inter-clause modeling for end-to-end emotion-cause pair extraction. In Dan Jurafsky, Joyce Chai, Natalie Schluter, and Joel R. Tetreault, editors, *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics, ACL 2020, Online, July 5-10, 2020*, pages 3171–3181. Association for Computational Linguistics.

- Sixing Wu, Fang Chen, Fangzhao Wu, Yongfeng Huang, and Xing Li. 2020. A multi-task learning neural network for emotion-cause pair extraction. In Giuseppe De Giacomo, Alejandro Catalá, Bistra Dilkina, Michela Milano, Senén Barro, Alberto Bugarín, and Jérôme Lang, editors, *ECAI 2020 - 24th European Conference on Artificial Intelligence, 29 August-8 September 2020, Santiago de Compostela, Spain, August 29 - September 8, 2020 - Including 10th Conference on Prestigious Applications of Artificial Intelligence (PAIS 2020)*, volume 325 of *Frontiers in Artificial Intelligence and Applications*, pages 2212–2219. IOS Press.
- Rui Xia and Zixiang Ding. 2019. Emotion-cause pair extraction: A new task to emotion analysis in texts. In Anna Korhonen, David R. Traum, and Lluís Màrquez, editors, *Proceedings of the 57th Conference of the Association for Computational Linguistics, ACL 2019, Florence, Italy, July 28- August 2, 2019, Volume 1: Long Papers*, pages 1003–1012. Association for Computational Linguistics.
- Jiaxin Yu, Wenyuan Liu, Yongjun He, and Chunyue Zhang. 2021a. A mutually auxiliary multitask model with self-distillation for emotion-cause pair extraction. *IEEE Access*, 9:26811–26821.
- Jiaxin Yu, Wenyuan Liu, Yongjun He, and Chunyue Zhang. 2021b. A mutually auxiliary multitask model with self-distillation for emotion-cause pair extraction. *IEEE Access*, 9:26811–26821.
- Chaofa Yuan, Chuang Fan, Jianzhu Bao, and Ruifeng Xu. 2020. Emotion-cause pair extraction as sequence labeling based on A novel tagging scheme. In Bonnie Webber, Trevor Cohn, Yulan He, and Yang Liu, editors, *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing, EMNLP 2020, Online, November 16-20, 2020*, pages 3568–3573. Association for Computational Linguistics.
- 刘德喜, 赵凤园, and 万常选. 2021. 一种基于知识辅助的情感-原因对抽取系统.
- 姚源林, 王树伟, 徐睿峰, 刘滨, 桂林, 陆勤, and 王晓龙. 2014. 面向微博文本的情绪标注语料库构建. *中文信息学报*, 28(5):83.
- 孙毅, 裘杭萍, 郑雨, 张超然, and 郝超. 2021. 自然语言预训练模型知识增强方法综述. *中文信息学报*, 35(7):20.
- 张华平 and 商建云. 2019. Nlpir-parser:大数据语义智能分析平台. *语料库语言学*, 2019(1):18.
- 谭红叶, 李宣影, and 刘蓓. 2020. 基于外部知识和层级篇章表示的阅读理解方法. *中文信息学报*, 34(4):7.
- 邱祥庆, 刘德喜, and 万常选. 2022. 文本情感原因自动识别综述. *计算机研究与发展*, 2022(2022):1–30.
- 黄金兰, Cindy K. Chung, Natalie Hui, 林以正, 谢亦泰, Ben C. P. Lam, 程威铨, Michael H. Bond, and James W. Pennebaker. 2012. 中文版「语文探索与字词计算」词典之建立. *中华心理学期刊*, 54(2):185–201.