

# 基於微調 BERT 模型之情緒與原因組合提取

郭維哲<sup>1</sup> 吳宜鴻<sup>2\*</sup>

中原大學資訊工程系

<sup>1</sup>E-mail: 10977001@cycu.org.tw

<sup>2</sup>E-mail: yhwu@cycu.edu.tw

## 摘要

情緒原因組合提取(ECPE)旨在從文本中同步提取情緒與其對應的原因，我們提出基於微調 BERT 模型的方法，先用 BERT 分類模型提取帶有情緒感受的字句，並判定情緒類型；然後將這些情緒子句轉為問句，以 BERT 問答模型提取原因子句。我們的方法達到 68.26% 的 F1 分數，先前研究分別只有 61.28% 和 65.50%。

**關鍵字：**自然語言理解、情緒分類、情緒原因組合提取、預訓練語言模型。

## Abstract

Emotion-cause pair extraction (ECPE) aims at extracting emotions and their causes simultaneously from text. We propose a method based on fine-tuned BERT model. At first, the BERT-based classification model is used to not only extract the clauses with emotions but also determine the emotion type of each clause. After that, we convert the emotion clauses into the forms of questions suitable for the BERT-based QA model, which is then used to extract the cause clauses. Our method achieves the F1-score of 68.26%, while previous studies gets 61.28% and 65.50%, respectively.

**Keywords:** *natural language understanding, emotion classification, emotion-cause pair extraction, pre-trained language model.*

## 1. 簡介

近年來，文本情感分析是自然語言處理(NLP)領域重要的研究方向，旨在從文本識別情感信息，從而理解作者的情感狀態和情感傾向。隨著情感分析技術不斷演進，研究者開始關注引發情緒的原因，因而形成情緒原因提取(Emotion Cause Extraction,

ECE)研究領域。目標是從文本識別給定情緒所涉及的原因，藉此深入瞭解情緒的形成過程。

情緒原因提取任務是先從文本中識別出情緒，然後將不同的情緒與文本一起輸入模型，以得到對應的原因。雖然[10]在 ECE 問題達到 76.77% 的 F1 分數，然而，ECE 問題假設在提取情緒涉及的原因前，須事先知道文本的情緒類別，這限制了實際生活中可應用的情境，近年來興起情緒原因組合提取(Emotion Cause Pair Extraction, ECPE)的研究方向。ECPE 問題由[11]提出，目標是同時提取文本中的情緒和原因的所有組合。與 ECE 不同的是，ECPE 不再需要情緒類別事先已知，而是在未知情緒類別的前提下從輸入的文本中直接提取情緒子句與對應的原因子句。

情緒原因組合提取的方法分為端到端與二步法，主要差異在於前者只建立單一模型，而後者採用多個模型合作完成。端到端的方法[3][9]使用單一模型進行建模，以多任務學習的方式訓練，先預測文本中的情緒子句與原因子句，然後將情緒子句與原因子句兩兩配對並篩選可能相互對應的組合。

相較於端對端，多個模型合作的二步法分開訓練不同階段的模型，容易達成各個模型的優化，也提供未來置入預訓練模型的可能。最早的二步法由[11]提出，第一步為分別提取情緒子句與原因子句，第二步將情緒與原因兩兩配對後找出真正的情緒原因組合(Emotion Cause Pair, ECP)。

Google 於 2019 年基於 Transformer 架構提出 BERT 模型[2]能在處理自然語言任務時更理解上下文，BERT 引入預訓練和微調階段。使用 BERT

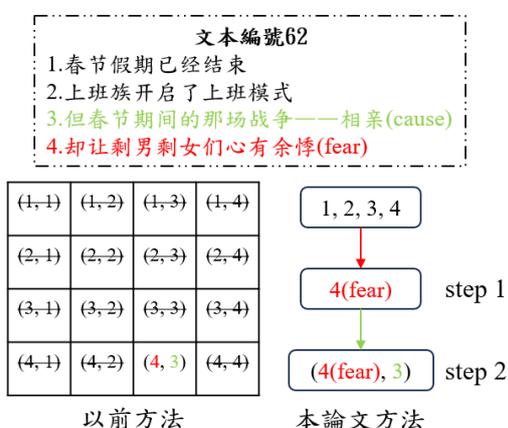
---

\* 通訊作者

模型針對 ECPE 問題的相關研究並不多，以[1]和[4]最具代表性，其中[1]將 ECPE 分兩階段進行，第一階段使用 BERT 問答任務分別提取情緒子句與原因子句，第二階段將情緒與原因使用 BERT 句子關係判斷任務篩選情緒原因組合；第一階段採用 BERT 問答模型只輸出一組最佳答案，每篇文本只能預測一組 ECP。本論文同樣採取二階段，只是採用不同 BERT 任務完成。

先前研究有二個不足之處：一、所找出的 ECP 欠缺情緒類別的資訊，限制了應用範疇，有效辨識 ECP 情緒類別的方法仍有待研究。二、判定組合是否 ECP 的模型需要準備負樣本，包括負樣本的定義、從資料集生成及正負樣本數量懸殊等難題。

圖一展示本論文與先前研究的方法差異，假設文本包含四個子句，第四句為情緒子句，第三句為原因子句，故正確情緒原因組合為(4, 3)。先前研究會先求出情緒與原因配對的候選集合，再將每個候選配對輸入模型，四個子句的文本可產生 16 組情緒原因候選的配對，最後的正確組合只有一組(4, 3)。



圖一、本論文方法與先前研究的差異

本論文使用 BERT 下游任務以兩階段的方法求出情緒原因組合，命名為 *BERT-Class2QA*。第一階段使用 BERT 分類模型實現情緒分類，除了可以知道哪些子句為情緒子句之外，也可以得知各子句的情緒分類，如圖一本論文方法在第一階段(step1)得知第四句為情緒子句且情緒分類為害怕(fear)。第二階段將原因提取轉為問答任務，將前面得到的情緒子句，透過問答模型找出對應的原因子句。

本論文採用[11]提供的資料集進行十折交叉驗證，在 ECPE 問題取得 F1 分數 68.26%，比[1]高

出 3 個百分點。第二階段方法相當於 ECE 問題，取得的 F1 分數為 80.94%，也比[10]高 4 個百分點。

## 2. 相關研究

ECE 問題在提取原因前，需事先標記好文本的情緒類別，限制可應用的情境，[11]改變既有形式，率先提出情緒原因組合提取(ECPE)問題；與前者不同的是不需要情緒類別作為輸入，改為直接產生情緒原因的組合(Emotion-Cause Pair)，該論文提出名為 Inter-EC 的二步法，先個別提取情緒子句與原因子句，然後篩選情緒子句與原因子句的配對。[12]在二步法加入自蒸餾(self-distillation)以提升模型效能，自蒸餾會透過一個大型而複雜的模型(稱為教師模型)訓練另一個小型而簡化的模型(常稱為學生模型)。目標是將教師模型的知識轉移到學生模型，以期壓縮模型和提高學生模型的性能。通過自蒸餾，學生模型從教師模型獲得更多知識，包括更準確的預測和表示能力，從而提高模型的性能。

端到端的方法旨從輸入到輸出的完整流程中使用單個模型進行建模學習和預測的方法，當中可能有多個不同的任務，以多任務學習的方式訓練。如[9]提出名為 RankCP 的方法，針對最後的篩選組合階段設計一套預測 ECP 可能性排序的模型，關鍵是使用兩個子句出現位置的遠近輔助判定是否 ECP。[3]將文本中所有句子兩兩配對，形成所有句子之間的二維配對矩陣，並篩選正確的 ECP。

BERT 是基於 Transformer 的自注意力模型，主要特點是能雙向參考前後文的所有單詞，更有效理解前後文的關聯性。BERT 在預訓練階段以大量未標記文本學習建立語言模型，然後利用標記數據微調到不同用途的任務中，先前研究也採用 BERT 嘗試實現情緒原因組合提取的任務。

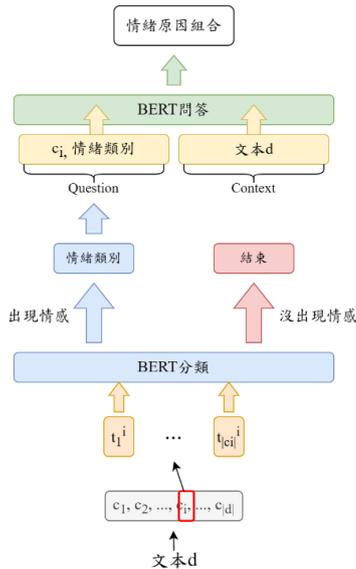
[1]先用 BERT 問答任務逐一提取情緒子句和原因子句的候選，例如對每篇文本提問“哪個句子表示情緒”與“哪個句子表示原因”；然後，將情緒與原因兩兩配對後丟入 BERT 句子關係判斷任務模型，通過即為情緒原因組合。

[4]採取將文本視為兩兩子句組合的模式，並忽略兩個子句相對距離大於特定門檻的組合以減

少處理資料量。該方法結合 BERT 模型的關係判斷任務與分類任務，以同時預測每個組合中的子句是否為情緒子句或原因子句，以及這些組合是否為正確的情緒原因組合；這種方法通過多任務學習來提高模型的整體性能，但是基於效率而忽略相對距離較遠的組合，不適用於完整提取所有的 ECP。

### 3. 主要方法

本論文提出的方法流程如圖二所示，分為兩階段，第一階段使用 BERT 分類任務實現情緒分類，第二階段使用 BERT 問答任務產生情緒原因組合。首先輸入一篇文本，第一階段先將文本斷句後得到  $[c_1, c_2, \dots, c_{|d|}]$ ，分別將每一句  $c_i$  輸入 BERT 分類模型，分類每個子句的情緒類別。若被判定為情緒子句，繼續進行第二階段。若無則結束。第二階段將先前得到的情緒子句轉為問句，用 BERT 問答模型詢問對應的原因子句，得到最終的情緒原因組合。



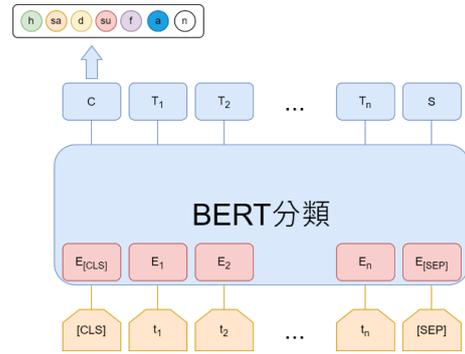
圖二、本論文方法的流程

#### 3.1 用 BERT 分類任務提取情緒子句與分類

分類任務先對 BERT 文本分類模型進行微調，目標是對文本逐句判定其情緒類別。在文本中存在具有情緒字詞的子句，也存在沒有任何情緒的子句，因此，在常見的 6 種情緒類別之外，加入代表沒有情緒的類別，表示為“Null”類別。

BERT 分類模型架構如圖三，輸入為一個句子，輸出為分類結果。每個句子在分詞與添加特殊標記 [CLS]與[SEP]後作為 BERT 的輸入。[CLS]為分類

的標記，固定加在序列開頭；[SEP]用於標示 BERT 模型不同輸入文本之間的邊界或表示結尾。



圖三、BERT-分類模型架構

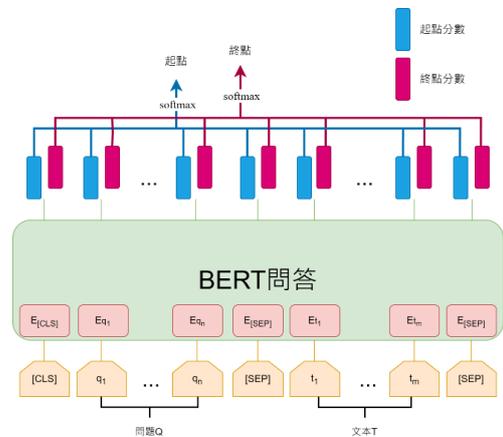
輸入句子  $c$  由數個分詞組成  $c = [t_1, t_2, \dots, t_{|c|}]$ ，輸入為  $x_i = ([CLS], t_1, t_2, \dots, t_{|c|}, [SEP])$ ，而輸出為每個分詞對應的編碼  $y_i = (C, T_1, T_2, \dots, T_{|c|}, S)$ ，其中 [CLS]學習到序列上下文關係以及代表分類的編碼  $C$ ，最後將  $C$  放入 softmax 層推算每個類別的分類機率，預測公式如下：

$$y_i^e = (C \cdot W_{cls} + b_{cls}) \quad (1)$$

其中  $W_{cls}$  與  $b_{cls}$  為模型訓練參數，其中  $C \in R^h$ ， $W_{cls} \in R^{h \times 7}$ ， $b_{cls} \in R^7$ ， $h$  為  $C$  的維度，7 為分類的數量，包括 6 種情緒類別與 Null。

#### 3.2 用 BERT 問答任務提取情緒原因組合

第二階段將前一階段的情緒子句轉為對應的問句，向模型提問以獲取對應的原因子句。微調後的 BERT 問答模型理解情緒子句的上下文，找出符合語意的情緒原因組合。語言模型擅長捕捉文本描述的關聯，得以有效推論情緒背後的原因。



圖四、BERT 問答模型架構

BERT 問答模型的輸入形式為提問加上文本

組合而成的序列，輸出為對應答案在文本中的起點與終點位置，如圖四所示。使用 BERT 問答模型時，輸入序列是將問題和文本結合後以分隔標記[SEP]予以區隔，在序列開頭加入特殊標記[CLS]，並在結尾加入[SEP]。若提問句子為  $Q = [q_1, q_2, \dots, q_n]$ ，文本為  $T = [t_1, t_2, \dots, t_m]$ ，輸入為  $x = ([CLS], q_1, q_2, \dots, q_n, [SEP], t_1, t_2, \dots, t_m, [SEP])$ 。

模型輸出每個字對應的編碼外，還會輸出每個字位置可能是起點的分數(start\_logit)與可能是終點的分數(end\_logit)，這二者可以通過 softmax 函數獲得每個位置為起點或終點的機率分佈。

#### 4. 實驗評估

本篇論文研究使用的硬體配置如下，CPU 為 13th Gen Intel(R) Core(TM) i7-13700F，GPU 為 NVIDIA GeForce RTX 3060 Ti，RAM 為 32GB。在軟體環境方面，我們使用 BERT<sub>base</sub> 在 PyTorch 環境下進行訓練，BERT<sub>base</sub> 的輸入序列最大值為 512。在第一階段 BERT 分類模型中，長度最大設定為 50。第二階段 BERT 問答模型設定為 512。

本論文採用[11]提供的資料集，該資料集基於[5]擷取新浪城市發布與中文情緒原因相關的新聞內容構建而成，包含 1945 篇文本，每篇文本包含一或多組的情緒原因組合。為了與先前研究比較，本研究採用與[11]相同的 10 折交叉驗證方法。本論文採取二階段分別進行訓練，皆採用正確率(p)、召回率(r)、與 F1-Score(F1)作為預評估指標。

##### 4.1 情緒子句提取的實驗結果

表一列出本論文方法和先前研究在情緒子句提取的實驗結果，其中 Inter-EC 是[11]提出的模型，先透過 LSTM 模型理解上下文建模，再訓練分類器來判別是否情緒子句；Emo2cause 則使用 BERT 問答任務提取情緒子句，其優勢在於訓練模型時能捕捉整篇文本的上下文關係，缺點則是一篇文本只能夠找出一個情緒子句。

先前研究提取情緒子句時均未判定情緒類別，因此，本論文方法採用 BERT 分類模型的結果可以分為兩種不同需求的效能評估：

1. BERT-Boolean (二元分類)：將分類簡化為判定

是否存在情緒，只考慮情緒子句是否被提取，忽略情緒類別的正確與否。

2. BERT-Emotion (多元情緒分類)：提取的情緒子句必須被判定為正確的情緒類別。

表一、情緒子句提取的實驗結果

	Precision	Recall	F1
Inter-EC [11]	83.64%	81.07%	82.30%
Emo2cause [1]	-	-	84.90%
BERT-Boolean	73.59%	88.22%	80.24%
BERT-Emotion	62.75%	76.62%	67.17%

與 Inter-EC 相比，雖然我們的 BERT-Boolean 的正確率相對較低，但是比較高的召回率達到 88.22%，能提取大多數的情緒子句。Emo2cause 的 F1 分數雖然最佳，不過其採用的 BERT 問答模型不適用於存在多個情緒子句的文本。我們的 BERT-Emotion 在各方面的分數都偏低，原因是必須成功判斷每個子句的情緒類別，提供比較完整的資訊。

由於情緒子句佔少數，因此存在資料不平衡的現象。表二是情緒子句在 10 折資料其中一折的情緒子句數量分布，其情緒子句數占比都低於 1/10。

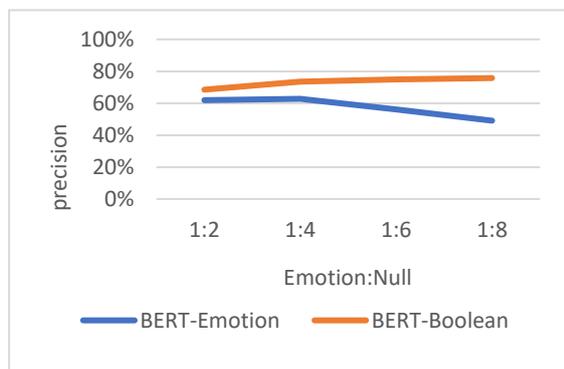
表二、其中一折的情緒子句數量分布

	訓練集	測試集	總數
非情緒子句數	24719	1923	26642
情緒子句數	1881	211	2092
情緒子句數占比	7.07%	9.89%	7.28%

我們隨機篩選一定數量的“Null”類別子句，與所有情緒子句合併成不同的訓練集，在不同的篩選比例下各進行了五次試驗，統計其平均值。我們以 Fold1\_train 中情緒子句的數量 1881 為基準，首先從“Null”類別隨機選取 1800 個非情緒子句與所有的情緒子句一起訓練，得到的 BERT-Boolean 的正確率與召回率分別為 60.36%和 94.83%，而 BERT-Emotion 的正確率與召回率分別為 55.49%和 83.17%。接下來，從“Null”類別以 1800 的 2 乘冪倍數作為非情緒子句數隨機選取，以觀察隨著非情緒子句數以倍數增加會造成什麼影響。

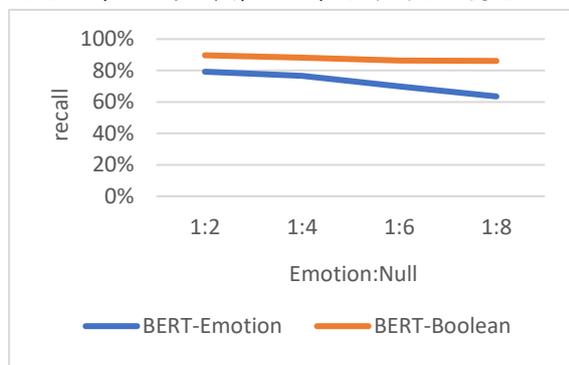
圖五展示不同“Null”類別比例的情緒分類正確率，隨著比例升高，BERT-Boolean 正確率也

漸增；推測可能是因為增加“Null”類別的樣本後，模型在訓練時學習到“Null”類別的特徵，更準確辨識非情緒子句，因此減少將非情緒子句錯誤標記為情緒子句的情況。另一方面，BERT-Emotion 的正確率卻在 1:4 後隨著比例增加反而下降；推論這是增加“Null”類別樣本到相當數量後，情緒類別在訓練資料的占比過低，使模型預測情緒類別出錯。



圖五、“Null”類別比例對情緒分類的正確率

圖六顯示的是不同“Null”類別比例對應的情緒分類召回率，隨著比例增加，BERT-Boolean 與 BERT-Emotion 的召回率都是遞減；可能是“Null”類別樣本比較多時，情緒子句在訓練集中所佔比例過低，導致模型對情緒子句的辨識能力變差。



圖六、“Null”類別比例對情緒分類的召回率

#### 4.2 原因子句提取的實驗結果

情緒原因提取原本可視為分類的問題，即預測每一句是否為原因的二元分類問題。本論文在第二階段將這個分類問題轉為問答形式，透過微調 BERT 問答模型來實現原因子句提取，第二階段可視為情緒原因提取(ECE)的類似方法。

表三為本論文與先前研究的實驗結果比較，可看出我們的 BERT 問答模型雖然侷限於同一情緒無法回答多個原因的假設，只能答出其中一個原因，

但是在 ECE 任務的 F1 分數高於先前研究最優的 RTHN 模型 [10]，提高了 4.17%。

表三、原因子句提取的實驗結果[10]

	Precision	Recall	F1
Multi-Kernel [5]	65.88%	69.27%	67.52%
Memnet [6]	70.76%	68.38%	69.55%
CANN [7]	77.21%	68.91%	72.66%
RTHN [10]	76.97%	76.62%	76.77%
BERT-QA	82.20%	79.74%	80.94%

在 BERT 問答模型的訓練過程中，作為問句的提示形式可能是影響模型表現的重要因素，因此，我們嘗試以三種不同形式的問句進行訓練。

Q1-自然問句：此問句合併第一階段提取的情緒子句與情緒類別，採取人類日常口述語言的問句。

Q2-制式問句：此問句同樣是合併情緒子句與情緒類別，但是改用特定格式來描述問句。

Q3-無情緒類別問句：此問句不使用第一階段得到的情緒類別，只有情緒子句。

透過這三種不同形式的問句，可觀察對 BERT 問答模型預測結果的影響，從表四列出的結果可見加入情緒類別的效果較優，符合本研究的預期。

表四、不同問題對問答結果影響

Question	F1
Q1-BERT-QA	80.94%
Q2-BERT-QA	78.26%
Q3-BERT-QA	78.10%

#### 4.3 情緒原因組合提取的實驗結果

整體表現的實驗比較對象包括 Inter-EC [11]、Emo2cause [1]與 ECRP-BERT [4]三種方法，本論文提出的方法則表示為 BERT-Class2QA，第一階段使用情緒與“Null”類別按 1:4 的比例訓練 BERT 分類模型，第二階段採用 Q1-自然問句訓練 BERT 問答模型，最後合併成兩階段模型。其中 Inter-EC 與 Emo2cause 皆使用[11]提出的 ECPE 資料集進行實驗，ECRP-BERT 則遵循其作法，排除資料集中情緒與原因相對距離大於 2 的組合[8]，以縮減後的資料集進行實驗。

由表五可見，我們的模型取得 F1 分數 68.26%。

相較於同樣使用 BERT 進行情緒原因組合提取的 Emo2cause 模型，高出了將近 3%。在正確率方面，我們的模型比 Inter-EC 低了將近 2%，但在召回率則高出 14.54%。

表五、情緒原因組合提取的實驗結果

	Precision	Recall	F1
Inter-EC [11]	67.21%	57.05%	61.28%
Emo2cause [1]	-	-	65.50%
<b>BERT-Class2QA</b>	65.69%	71.59%	68.26%
ECRP-BERT[4]	80.56%	73.21%	76.69%
<b>BERT-Class2QA</b>	64.01%	73.32%	67.95%

ECRP-BERT 忽略情緒與原因相對距離大於 2 的組合，因此無法預測距離較遠的組合，但提升了距離較近組合的預測正確率。我們採用類似資料集進行訓練與預測，從表中可看出我們的正確率因此降低了 1.68%，原本情緒與原因相對距離大於 2 的組合被視為錯誤，導致正確率降低；相對的，刪除一部分的組合也導致召回率升高。

## 5. 結論與未來展望

本論文使用 BERT 下游任務中的分類模型與問答模型實現二階段情緒原因組合提取，第一階段以 BERT 分類模型進行情緒分類與情緒子句提取，而第二階段將前述結果轉為問句形式，利用 BERT 問答模型提取原因子句。我們改善了先前研究並未同時獲取情緒類別的缺點，實驗結果顯示，找出的情緒類別也有助於第二階段提取原因子句。

我們在第二階段採用 BERT 問答模型時，只能找出一個原因子句，未來希望能讓這個階段同時找出多個原因子句，以滿足真實資料集的需求。

## 參考文獻

[1] T.W. Chang, Y.C. Fan, and A.L.P. Chen, “Emotion-cause pair extraction based on machine reading comprehension model,” MTAA, 81: 40653-40673, 2022.

[2] J. Devlin, M.W. Chang, K. Lee, and K. Toutanova, “BERT: pre-training of deep bidirectional transformers for language

understanding,” NAACL-HLT, 1: 4171-4186, 2019.

- [3] Z. Ding, R. Xia, and J. Yu, “ECEP-2D: emotion-cause pair extraction based on joint two-dimensional representation, interaction and prediction,” ACL, pp. 3161–3170, 2020.
- [4] R. Fan, T. He, Y. Wang, J. Hong, and X. Tu, “Emotion-cause relationship between clauses prediction: a novel method based on BERT for emotion-cause pair extraction,” IEEE Big Data, pp. 721-726, 2022.
- [5] L. Gui, D. Wu, R. Xu, Q. Lu, and Y. Zhou, “Event-driven emotion cause extraction with corpus construction,” EMNLP, pp. 1639-1649, 2016.
- [6] L. Gui, J. Hu, Y. He, R. Xu, Q. Lu, and J. Du, “A question answering approach to emotion cause extraction,” EMNLP, pp. 1593-1602, 2017.
- [7] X. Li, K. Song, S. Feng, D. Wang, and Y. Zhang, “A co-attention neural network model for emotion cause analysis with emotional context awareness,” EMNLP, pp. 4752–4757, 2018.
- [8] X. Su, Z. Huang, Y. Zhao, Y. Chen, Yong Dou and H. Pan, “Recent trends in deep learning based textual emotion cause extraction,” TASLP, pp. 2765-2786, 2023.
- [9] P. Wei, J. Zhao, and W. Mao, “Effective inter-clause modeling for end-to-end emotion-cause pair extraction,” ACL, pp. 3171-3181, 2020.
- [10] R. Xia, M. Zhang, and Z. Ding, “RTHN: a RNN-transformer hierarchical network for emotion cause extraction,” IJCAI, pp. 5285-5291, 2019.
- [11] R. Xia and Z. Ding, “Emotion-cause pair extraction: a new task to emotion analysis in texts,” ACL, pp. 1003-1012, 2019.
- [12] J. Yu, W. Liu, Y. He, and C. Zhang, “A mutually auxiliary multitask model with self-distillation for emotion-cause pair extraction,” IEEE Access, 9: 26811-26821, 2021.