

利用关系抽取技术联合识别文本中的方面-极性对

卜令梅, 陈黎, 卢永美, 于中华

(四川大学计算机学院, 成都 610065)

摘要: 方面级情感分析旨在识别出句子中显式提及的方面及其情感极性, 是细粒度情感分析中的重要任务。现有使用序列标注进行方面级情感分析的方法存在当方面(aspect)由多个单词构成时, 每个单词的情感极性可能不一致, 而基于跨度(span)的方法存在因方面标签和情感标签混合而导致的标签异质问题, 同时现有的研究忽略了文本中方面-情感极性对之间的相互关联。为了解决上述问题, 受关系抽取技术的启发, 本文将方面-情感极性对抽取视作一元关系抽取问题, 其中方面看成论元, 其对应的情感极性作为关系, 通过序列解码捕捉方面-情感极性对之间的关联。本文在3个数据集上进行了一系列实验来验证模型的有效性, 实验结果表明, 其性能超过了现有的最佳模型。

关键词: 方面级情感分析; 方面-情感极性对; 关系抽取

中图分类号: TP391 文献标识码: A DOI: 10.19907/j.0490-6756.2022.012002

Employing relation extraction technology to jointly recognize aspect-polarity pairs in a text

BULing-Mei, CHEN Li, LU Yong-Mei, YU Zhong-Hua

(College of Computer Science, Sichuan University, Chengdu 610065, China)

Abstract: Aspect-based sentiment analysis aims to identify the aspects mentioned in sentences and their sentiment polarity, which is an important task in fine-grained sentiment analysis. The existing studies use sequence labeling or span-based classification methods, having their own defects such as polarity inconsistency resulted from separately tagging tokens in the former and the heterogeneous categorization in the latter where aspect-related and polarity-related labels are mixed. At the same time, the existing methods ignore the correlation between aspect-polarity pairs in sentences. In order to remedy the above defects, inspiring from the recent advancements in relation extraction, we propose to generate aspect-polarity pairs directly from a text with relation extraction technology, regarding aspect-pairs as unary relations where aspects are entities and the corresponding polarities are relations and utilize sequence decoding to capture the correlation between aspect-polar pairs. The experiments performed on three benchmark datasets demonstrate that our model outperforms the existing state-of-the-art approaches.

Keywords: Aspect-based sentiment analysis; Aspect-sentiment pair; Relation extraction

收稿日期: 2021-08-06

基金项目: 国家重点研发项目(2020YFB0704502)

作者简介: 卜令梅(1997—), 女, 山东泰安人, 硕士研究生, 主要研究领域为自然语言处理。

通讯作者: 于中华. E-mail:yuzhonghua@scu.edu.cn

1 引言

情感分析的目的是识别人们在文本中表达的态度。随着互联网的快速发展,从网络海量的评论信息中获取用户的情感倾向^[1,2],有很大的商业价值和研究价值。早期的情感分析研究主要聚焦于文档级和句子级,通常假设一段文本只针对一个方面(aspect),并对给定的文本整体判断其情感极性。事实上,一段文本中经常包含多个不同方面,每个方面的情感倾向可能不相同,因此,情感分析的研究热点逐渐由粗粒度转向细粒度,其中方面级情感分析(Aspect-Based Sentiment Analysis, ABSA)是细粒度情感分析的一项重要研究任务。

早期的 ABSA 被视作方面抽取^[3-6]和极性分类^[7-11]两个独立的子任务,并采用流水线的方法将两个子任务结合起来获取方面-情感极性对,但是存在错误传播问题。此外,在进行方面抽取时,无法利用极性信息,影响抽取效果。为了克服上述缺点,最新的解决方案是使用单词级(token)序列标注和基于跨度(span, 是句子的一个片段,由起始词和结尾词标记。)的联合分类方法。文献[12-14]分别针对方面抽取和极性分类使用不同的标注体系,利用序列标注模型进行 ABSA 任务,这种方法可以捕捉方面和情感之间的相互作用,然而此方法对那些由多个单词构成的方面,要为每个单词分别进行极性标注,所以面临情感不一致问题。如图 1 所示的实例中,针对包含两个单词的方面 garlic knots,极性分类器可能会将 garlic 标注为积极(positive),而 knots 标注为消极(negative),从而导致整个 garlic knots 的情感极性有歧义。基于 span 的方法^[15-17]通过预测整个方面的极性避免了情感不一致问题。然而在针对候选 span 使用的 { TPOS, TNEG, TNEU, O } 标签体系中, TPOS、TNEG 和 TNEU 分别表示候选跨度是具有积极、消极和中性的方面,而 O 表示候选 span 不是一个有效的方面,这使得标签体系存在异质问题,导致模型难以将两个相关但不同的子任务捕捉相应的信息。此外,虽然上述方法捕捉了一个句子中各个方面之间的相互作用,但它们忽略了不同方面极性对之间的相互关联,这种关联对一个句子中所有方面的极性判断至关重要。

为了捕捉一个句子中所有方面极性对之间的相关性,本文受关系抽取技术^[18-20]的启发,将 ABSA 任务视为一元关系抽取,其中方面看成实体,

其对应的极性作为关系,利用关系抽取技术生成方面-情感极性对,提出利用关系抽取技术联合识别文本中方面-情感极性对(Employing Relation Extraction to Aspect-Polarity Pairs Generation, RE-APP)的模型。本文在 3 个公开的基准数据集进行了一系列实验。结果表明,本文的模型提高了方面级情感分析任务的性能,同时也验证了利用方面极性对之间的关联能够提高 ABSA 任务的性能。

<p>Sentence1: Pizza and garlic knots are great as well. APPs: (Pizza, positive) (garlic knots, positive)</p>
<p>Sentence2: I love Windows 7 which is a vast improvement over Vista. APPs: (Windows 7, positive) (Vista, negative)</p>

图 1 方面级情感分析实例
Fig. 1 An example of ABSA

本文的贡献主要有两方面:(1) 将 ABSA 任务归结为一元关系抽取问题,捕捉文本中不同方面极性对之间的相互作用,克服了现有方法中存在的情感不一致和标签异质问题;(2) 在 3 个数据集上进行了实验,验证了本文模型的性能。

2 相关工作

早期的 ABSA 先进行方面抽取再为给定的方面进行情感极性分类,这种分离模型的做法应用受限,目前联合两个子任务已经成为研究热点。2013 年,Mitchell 等^[12]首先尝试使用条件随机场(Conditional Random Fields, CRF)为联合标签进行序列标注,同时与流水线方法进行了对比,但实验表明联合标签并没有比流水线方法效果更佳。2015 年,Zhang 等^[13]在 Mitchell 等^[12]的基础上,进一步引入神经网络模型,然而也没能验证端到端方法比流水线方法更具优越性。此后,Li 等^[14]意识到之前的做法面对由多个单词构成的方面时,由于为每个单词预测的情感极性可能不一致而导致该方面的情感歧义问题,于是在为当前单词进行标注时利用了之前单词的嵌入信息进行缓解,然而这种方法并不能完全避免情感不一致问题。所以在 2019 年,研究者开始将方面看成一个 span,用基于 span 的方法避免上述情感不一致问题。Hu 等^[15]提出使用两个基于 span 的分类器识别 span 的起始位置和结束位置,然后针对整个 span 进行极性分类。但该工作对 span 起始位置和结束位置的识别是独立进行

的, 只能通过启发式算法为二者进行配对. Lin 等^[17]为了避免丢失正确的方面, 改进了 Hu 等^[15]的启发式算法, 首先通过匹配预测结果中最接近的起始和结束位置获取候选 span, 然后通过拓展策略确定正确 span, 虽然进行了更有效的开始和结束位置配对, 但仍旧独立进行起始位置和结束位置的识别工作, 没有从根本上解决二者的配对问题. Zhou 等^[16]枚举候选 span 并调用多分类器从 {TPOS, TNEG, TNEU, O} 中确定候选 span 的类别, 显然该集合包含的异质分类标签会影响分类性能.

3 任务与模型

为了解决现有的 ABSA 研究存在的问题, 本文提出将 ABSA 任务视为一元关系抽取的过程, 将方面视为实体, 使用 span 的方式进行表示, 其对应的极性视为关系, 方面-情感极性对则表示为(方面起始位置, 方面结束位置, 情感极性)三元组.

3.1 任务定义

给定一个句子 $S = \{w_1, w_2, \dots, w_n\}$, 每个句子由 n 个单词组成, 本文的任务是根据输入的句子自动识别 S 中所有的评价对象以及情感极性, 即输出集合 $Y = \{\langle s, e, r \rangle \mid 0 \leq s \leq e < n, r \in R\}$, 其中,

s 和 e 表示方面中的单词起始位置和结束位置; r 表示方面的感情极性. $R = \{POS, NEG, NEU\}$ 是情感极性集合, POS 、 NEG 和 NEU 分别表示积极、消极和中性情感. 当句子中的有效三元组都被全部识别出来时, 解码器将生成 NA 三元组, 意味着解码停止. 注意, NA 三元组由起始位置、结束位置和 NA 极性组成. 模型的输入输出实例如表 1.

3.2 提出的模型

本文提出的 REAPP 模型由三层组成, 如图 2 所示. 第一层为嵌入层, 负责利用词嵌入初始化句子中的所有单词; 第二层为编码层, 根据词嵌入进行句子分析, 捕捉句子中所有单词之间的相互作用, 生成单词的上下文表达; 最后一层是解码层, 注意力机制为解码层提供上下文表达, 解码层在每个时序步中生成三元组.

表 1 REAPP 的输入输出例子

Tab. 1 An example for input and output of REAPP

Term	Content
Input	I_0 love ₁ Windows ₂ 7 ₃ which ₄ is ₅ a ₆ vast ₇ improvement ₈ over ₉ Vista _{10, 11}
Output	(2, 3, POS) (10, 10, NEG) (12, 12, NA)
Aspect-polarity pair	(Windows 7, positive) (Vista, negative)

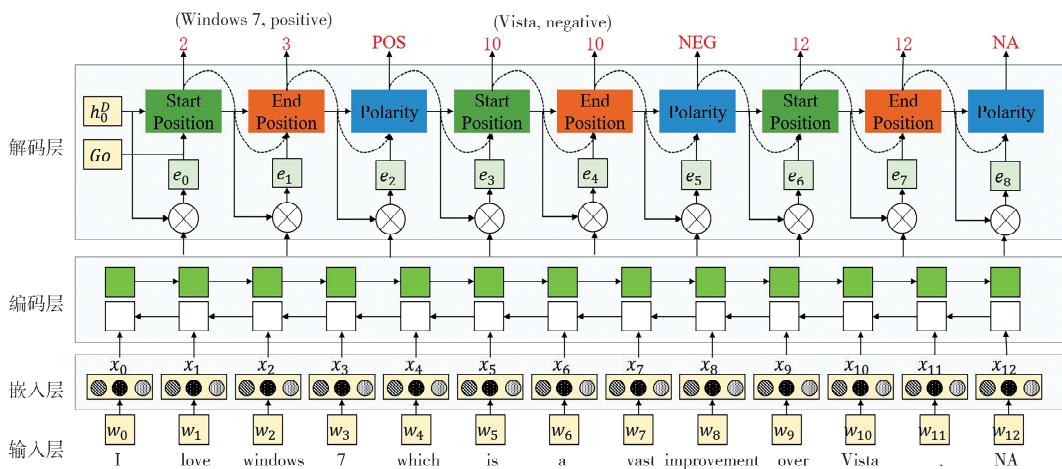


图 2 REAPP 模型结构图
Fig. 2 The architecture of REAPP model

3.3 嵌入层

本文使用预训练的 Glove^[21]向量初始化单词表达, 为了应对未登录词(Out of Vocabulary, OOV)问题并考虑词性(Part of Speech, POS)在确定方面和极性时的作用, 本文还在嵌入层加入了字符嵌入和 POS 嵌入. 具体来说, 对于一个单词, 本文使用卷积操作编码其字符序列并进行最大池

化得到字符编码 $e_i^c \in R^{d_f}$, 与 Glove 向量 $e_i^w \in R^{d_w}$ 以及 POS 嵌入 $e_i^p \in R^{d_p}$ 拼接得到单词的嵌入表达 $x_i = [e_i^w; e_i^c; e_i^p]$.

3.4 编码层

本文使用 Bi-LSTM 分析整个句子, 通过拼接每个时刻前向和后向的隐藏表达获取每个单词的上下文信息 h_i^E , 如式(1)所示.

$$h_i^E = [\overrightarrow{LSTM}(x_i, h_{i-1}^E); \overleftarrow{LSTM}(x_i, h_{i+1}^E)] \quad (1)$$

3.5 解码层

本层使用 LSTM 生成输入句子的三元组序列,为此,对于时间步 t ,LSTM 首先将句子的上下文表达与 $t-1$ 步传输的信息融合得到当前状态 h_t^D 和 c_t^D ,如式(2)所示.

$$h_t^D, c_t^D = LSTM([v_{t-1}; e_t] \cdot W^u, c_{t-1}^D) \quad (2)$$

其中, W^u 为待学习的参数; e_t 为当前时刻通过注意力计算得到的上下文向量,计算如式(3)~(6)所示.

$$m_t = W^P c_{t-1}^D + b^P, n_{t,i} = W^Q h_i^E \quad (3)$$

$$\beta_{t,i} = v^P \tan h(m_t + n_{t,i}) \quad (4)$$

$$\alpha_t^P = \text{softmax}(\beta_t) \quad (5)$$

$$e_t = \sum_{i=0}^{n-1} \alpha_{t,i}^P \times h_i^E \quad (6)$$

其中, W^P, b^P, W^Q 和 v^P 均为待学习的参数. 在得到解码器 t 时刻的状态后, 模型开始解码, 解码过程主要包含 3 个步骤: $t \% 3 = 1$ 时开始解码新的三元组, 生成评价对象的起始位置; $t \% 3 = 2$ 时生成评价对象的结束位置; $t \% 3 = 0$ 时预测情感极性, 一个完整的三元组总是需要经历这 3 个时刻, 具体进行哪个操作由 t 对 3 取余的结果确定, 模型会循环执行这一系列操作, 直到生成表示结束的三元组.

生成起始位置时($t \% 3 = 1$), 需考虑生成 NA 三元组的可能, 且在 ABSA 任务中每个方面只需要生成一次, 所以本文引入向量 $M \in R^n$ 来屏蔽已经拷贝过的方面, 计算起始位置概率分布的过程如图 3 和式(7)~(10)所示.

$$q_i^s = \text{selu}([h_t^D; h_i^E] \cdot W^s + b^s) \quad (7)$$

$$q^{\text{NA}} = \text{selu}(h_t^D \cdot W^{\text{NA}} + b^{\text{NA}}) \quad (8)$$

$$M_i = \begin{cases} 0, & i \in E \\ 1, & i \notin E \end{cases} \quad (9)$$

$$p^s = \text{softmax}([M \otimes q^s; q^{\text{NA}}]) \quad (10)$$

其中, W^s, b^s, W^{NA} 和 b^{NA} 均为待学习的参数.

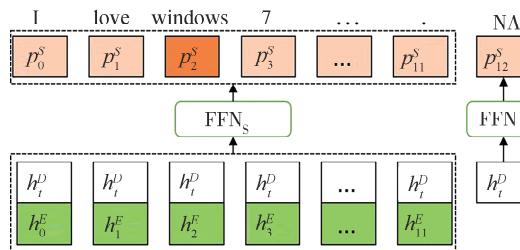


图 3 方面起始位置识别

Fig. 3 Start position identification of an aspect

生成结束位置时($t \% 3 = 2$), 其起始位置已经

明确, 本文引入另一个向量 $M^e \in R^n$ 确保结束位置在起始位置之后, 其他操作与 $t \% 3 = 1$ 类似, 计算结束位置概率分布的过程如图 4 和式(11)~(13)所示.

$$M_i^e = \begin{cases} 1, & i \geq s \\ 0, & i < s \end{cases} \quad (11)$$

$$q_i^e = \text{selu}([h_t^D; h_i^E] \cdot W^e + b^e) \quad (12)$$

$$p^e = \text{softmax}([M^e \otimes q^e \otimes M^e; q^{\text{NA}}]) \quad (13)$$

其中, W^e, b^e 均为待学习的参数.

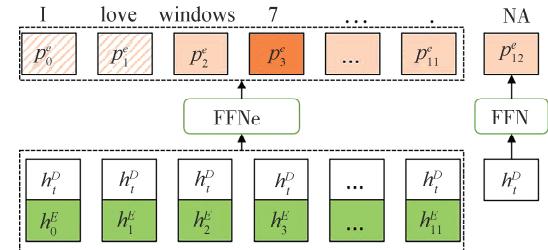


图 4 方面结束位置识别

Fig. 4 End position identification of an aspect

生成情感极性时($t \% 3 = 0$), 解码器的任务是预测前两步确定方面的情感极性, 除了该方面的上下文, 方面内部的信息也是决定极性的重要线索. 因此, 本文在方面内部($h_s^E, h_{s+1}^E, \dots, h_e^E$)使用 Bi-LSTM, 使用 $h_a = [h_s^E; h_{\text{sec}}^E; h_e^E]$ 作为当前方面的表达, 其中, h_{sec} 是 Bi-LSTM 前向和后向最后一个时刻隐藏向量的拼接. 然后, 采用类似前两步的处理, 计算情感极性概率分布的过程如图 5 和式(14)~(16)所示.

$$q_j^r = \text{selu}([h_a; h_t^D] \cdot W^r + b^r), j \in [1, 3] \quad (14)$$

$$q^{\text{SNA}} = \text{selu}(h_t^D \cdot W^{\text{SNA}} + b^{\text{SNA}}) \quad (15)$$

$$p^r = \text{softmax}([q^r; q^{\text{SNA}}]) \quad (16)$$

其中, W^r, b^r, W^{SNA} 和 b^{SNA} 均为待学习的参数.

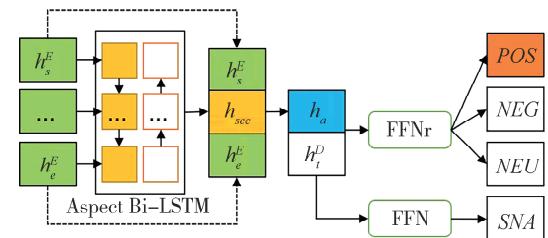


图 5 方面极性分类

Fig. 5 Polarity classification of an aspect

本文通过最小化负的 log 似然损失训练 REAPP 模型. 假设训练集为 $X = \{<S_1, Y_1>, <S_2, Y_2>, \dots, <S_B, Y_B>\}$, 其中, S_i 是一个句子, $Y_i = \{y_i^1, y_i^2, \dots, y_i^T\}$ 是对应的黄金标注, 损失计算如式

(17)所示.

$$L_{\text{loss}} = -\frac{1}{B \times T} \sum_{i=1}^B \sum_{t=1}^T \log(p(y_i^t | y_i^{<t}, x_i)) \quad (17)$$

4 实验与结果

4.1 实验数据

本文在 3 个 ABSA 任务公开的数据集 LAP-

表 2 实验数据统计
Tab. 2 Statistics of the datasets

Datasets	LAPTOP			REST			TWITTER		
	pos	neg	neu	pos	neg	neu	pos	neg	neu
training	883	754	404	2337	942	614	—	—	—
dev	104	106	46	270	93	50	—	—	—
testing	339	130	165	1524	500	263	—	—	—
total	1326	990	615	4131	1535	927	692	263	2244

4.2 实验设置

本文使用 glove.840B.300d 初始化词嵌入(nlp.stanford.edu/projects/glove/),而解码器使用的词嵌入是随机初始化的,此外,本文使用 Stanford CoreNLP toolkit 对句子中的单词进行 POS 标注(stanfordnlp.github.io/CoreNLP/),POS 嵌入的维度是 50. 本文使用 50 个大小为 3 的滤波器,字符级编码维度为 50. 输入句子的上下文编码是通过两个堆叠的 Bi-LSTM 学习的,正向和反向的维度都是 150 维,解码端的 LSTM 维度设置为 300. 本文的学习率设置为 0.001,batch 大小为 32,dropout 设置为 0.5,使用 Adam 优化器.

4.3 基线模型

本文对比的模型包括以下较先进的方法:

(1) CRF-pipelined,joint,collapsed(2013)^[12]:一种基于情感词典和手工构建特征的 CRF 序列标记方法;

(2) NN-CRF-pipelined,joint,collapsed(2015)^[13]:一种顶层使用 CRF 序列标注捕捉标签相关性的浅层网络模型;

(3) UNIFIED(2019)^[14]:一种使用联合标签的基于 Bi-LSTM 进行序列标注的方法;

(4) TAG-pipelined, joint, collapsed (2019)^[15]:一种以 BERT 为编码器,基于 CRF 进行序列标注的模型;

(5) Zhou-SPAN(2019)^[16]:集中基于 span 的

TOP、REST 和 TWITTER^[12] 上验证了 REAPP 模型的有效性. 为了便于比较,本文采用与 Zhou 等^[16] 相同的数据划分,其中 TWITTER 使用十折交叉验证,实验数据统计如表 2 所示. 本文使用的评价指标包括精确率、召回率、 F_1 得分和准确率. 此外,只有当预测的方面与黄金标注完全一致才认为是正确的方面.

联合方法,使用 span 制导的注意力机制获取每个 span 的情感信息;

(6) Hu-SPAN-pipelined, joint, collapsed (2019)^[15]:一种以 BERT 为编码器的基于 span 的方法,提出将起始位置和结束位置配对的启发式算法;

(7) SPRM(2020)^[17]:对 Hu-SPAN-joint^[15] 的改进,为每个子任务设计私有编码器以及联合编码器,以捕获两个任务之间的关联信息.

4.4 结果分析

在 3 个基准数据集上,方面-情感极性对抽取的实验结果如表 3 所示,从表 3 可看出,无论是与序列标注的方法相比,还是与基于 span 的方法相比,本文模型都表现最佳. SPAN-pipeline (2019) 的 F_1 值比 TAG-pipeline (2019) 在 3 个数据集上分别提升了 1.55%、0.94% 和 3.43%,可以看出基于 span 的方法比序列标注方法更有优势,因为其针对整个 span 进行情感分类,有效避免了序列标注方法给多个单词构成的方面所带来的语义歧义问题. 而本文方法除了针对整个 span 进行极性分类,还使用序列模型捕捉文本中不同方面-情感极性对之间的相互作用,提出的 REAPP 模型比效果最好的序列标注模型 TAG-pipeline (2019) 在 3 个数据集上的 F_1 值分别提高了 2.79%、6.09% 和 6.26%,而和基于 span 的模型 SPRM (2020) 相比,虽然在 REST 数据集上,本文的召回率较低,

但精确率比 SPRM 高出了 3.21%, 在 3 个数据集

上的 F_1 值分别超出 0.58%、0.90% 和 1.07%.

表 3 方面-极性对抽取实验结果

Tab. 3 Comparison of different methods' results on three datasets

Model	LAPTOP			REST			TWITTER		
	P/%	R/%	F_1 /%	P/%	R/%	F_1 /%	P/%	R/%	F_1 /%
CRF-pipeline (2013)	59.69	47.54	52.93	52.28	51.01	51.64	42.97	25.21	31.73
CRF-joint (2013)	57.38	35.76	44.06	60.00	48.57	53.68	43.09	24.67	31.35
CRF-collapsed (2013)	59.27	41.86	49.06	63.39	57.74	60.43	48.35	19.64	27.86
NN-CRF-pipeline (2015)	57.72	49.32	53.19	60.09	61.93	61.00	43.71	37.12	40.06
sequence labeling methods	NN-CRF-joint (2015)	55.64	34.48	45.49	61.56	50.00	55.18	44.62	35.84
	NN-CRF-collapsed (2015)	58.72	45.96	51.56	62.61	60.53	61.56	46.32	32.84
	UNIFIED (2019)	61.27	54.89	57.90	68.64	71.01	69.80	53.08	43.56
	TAG-pipeline (2019)	65.84	67.19	66.51	71.66	76.45	73.98	54.24	54.37
	TAG-joint (2019)	65.43	66.56	65.99	71.47	75.62	73.49	54.18	54.29
	TAG-collapsed (2019)	63.71	66.83	65.23	71.05	75.84	73.35	54.05	54.25
	Ours (REAPP)	69.82	68.78	69.30	80.99	79.18	80.07	61.72	59.37
<hr/>									

4.5 方面抽取结果分析

为了分析模型在方面抽取的性能,本文计算了 REAPP 在 3 个数据集上方面抽取的 F_1 得分,和序列标注以及基于 span 的方法进行对比,如图 6.

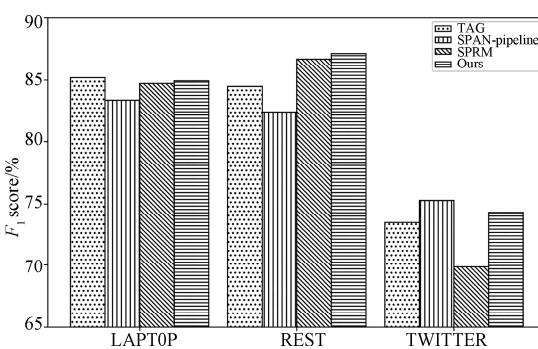


图 6 方面抽取对比结果

Fig. 6 The results of aspect extraction

从图 6 的实验结果可以看出,本文的模型在 LAPTOP、REST 和 TWITTER 数据集上的 F_1 值分别为 84.93%、87.16% 和 74.31%, 比 SPRM (2020) 的 F_1 值提高了 0.21%、0.45%、4.46%, 这证明本文模型对方面的识别是有效的. 此外还可以发现, SPRM 虽然在 LAPTOP 和 REST 上表现较

好,但是在 TWITTER 上表现较 SPAN-pipeline 模型和本文的模型差很多,这说明 SPRM 和 SPAN-pipeline 二者采用的启发式规则不能自适应所有的数据集,而本文的模型可以适应句子长度的变化,在识别评价对象时受其影响较小.

4.6 极性分类结果分析

对于 REAPP 模型在情感极性分类上的性能,本文针对所有被正确识别出的方面,计算情感极性分类的准确率(Acc),在 3 个数据集上和效果最好的情感分类器进行对比,结果如图 7 所示.

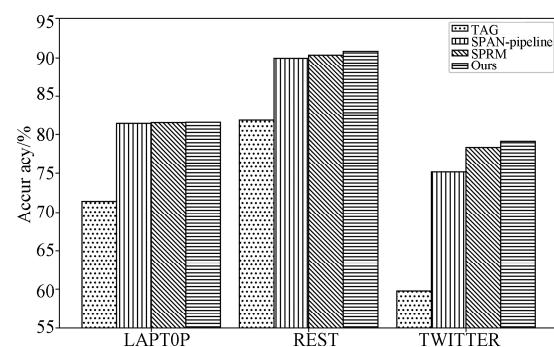


图 7 情感极性分类对比结果

Fig. 7 The results of polarity classification

由实验结果可知,本文的模型在 LAPTOP、

REST 和 TWITTER 数据集上的准确率分别是 81.52%、90.82% 和 79.12%，是目前在 3 个数据集上极性分类效果最好的模型。

5 结 论

本文提出了 REAPP 模型,与当前序列标注方法和基于 span 的模型不同,利用了句子中方面-情感极性对之间的关系,捕捉方面抽取和极性分类两个子任务之间的相互作用。此外极性预测针对整个方面,从而避免了现有单词级序列标注方法存在的情感极性不一致问题和基于 span 方法中标签体系的异质问题。在 3 个数据集上的实验表明,本文模型优于现有的最好方法。

目前本文在进行情感极性预测时,计算注意力的方式和位置识别相同,接下来,本文考虑在预测情感极性时,使用方面制导的注意力机制以更好的捕捉特定方面的情感信息。此外,通过表 3 还可以看出,不论是 REAPP 模型还是其他两类模型,召回率相对精确率都较低,这说明预测的方面数量较少,后续本文会尝试解决这个问题。

参 考 文 献:

- [1] 赵容梅, 熊熙, 瞿生根, 等. 基于混合神经网络的中文隐式情感分析[J]. 四川大学学报: 自然科学版, 2020, 57: 264.
- [2] 唐晓波, 刘广超. 细粒度情感分析研究综述[J]. 图书情报工作, 2017, 61: 132.
- [3] He R, Lee W S, Ng H T, et al. An unsupervised neural attention model for aspect extraction[C]// Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics, Vancouver, Canada: Association for Computational Linguistics, 2017.
- [4] Li X, Bing L, Li P, et al. Aspect term extraction with history attention and selective transformation [C]// Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence. Stockholm, Sweden: International Joint Conferences on Artificial Intelligence Organization, 2018.
- [5] Xu H, Liu B, Shu L, et al. Double embeddings and cnn-based sequence labeling for aspect extraction [C]// Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics. Melbourne, Australia: Association for Computational Linguistics, 2018.
- [6] Wang W, Pan S J, Dahlmeier D, et al. Recursive neural conditional random fields for aspect-based sentiment analysis[C]// Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing. Austin, Texas: Association for Computational Linguistics, 2016.
- [7] Fan F, Feng Y, Zhao D. Multi-grained attention network for aspect-level sentiment classification [C]// Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. Brussels, Belgium: Association for Computational Linguistics, 2018.
- [8] Chen P, Sun Z, Bing L, et al. Recurrent attention network on memory for aspect sentiment analysis [C]// Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing. Copenhagen, Denmark: Association for Computational Linguistics, 2017.
- [9] Fan Z, Wu Z, Dai X Y, et al. Target-oriented opinion words extraction with target-fused neural sequence labeling [C]// Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Minneapolis, Minnesota: Association for Computational Linguistics, 2019.
- [10] Li X, Bing L, Lam W, et al. Transformation networks for target-oriented sentiment classification [C]// Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics. Melbourne, Australia: Association for Computational Linguistics, 2018.
- [11] 杜成玉, 刘鹏远. 基于螺旋注意力网络的方面级别情感分析模型[J]. 中文信息学报, 2020, 34: 70.
- [12] Mitchell M, Aguilar J, Wilson T, et al. Open domain targeted sentiment [C]// Proceedings of the 2013 Conference on Empirical Methods in Natural Language Processing. Seattle, Washington, USA: Association for Computational Linguistics, 2013.
- [13] Zhang M, Zhang Y, Vo D T. Neural networks for open domain targeted sentiment [C]// Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing. Lisbon, Portugal: Association for Computational Linguistics, 2015.
- [14] Li X, Bing L, Li P, et al. A unified model for opinion target extraction and target sentiment prediction [C]// Proceedings of the AAAI Conference on Artificial Intelligence. Hawaii, USA: AAAI, 2019, 33: 6714.
- [15] Hu M, Peng Y, Huang Z, et al. Open-domain tar-

- geted sentiment analysis via span-based extraction and classification [C]//Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. Florence, Italy: Association for Computational Linguistics, 2019.
- [16] Zhou Y, Huang L, Guo T, et al. A span-based joint model for opinion target extraction and target sentiment classification [C]//Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence. Macao, China: International Joint Conferences on Artificial Intelligence Organization, 2019.
- [17] Lin P, Yang M. A shared-private representation model with coarse-to-fine extraction for target sentiment analysis [C]//Findings of the Association for Computational Linguistics: EMNLP 2020. Online: Association for Computational Linguistics, 2020: 4280.
- [18] Zeng X, Zeng D, He S, et al. Extracting relational facts by an end-to-end neural model with copy mech-
- anism [C]//Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics. Melbourne, Australia: Association for Computational Linguistics, 2018.
- [19] Zeng D, Zhang H, Liu Q. CopyMTL: copy mechanism for joint extraction of entities and relations with multi-task learning [C]//Proceedings of the AAAI Conference on Artificial Intelligence. New York, USA: AAAI, 2020, 34: 9507.
- [20] Nayak T, Ng H T. Effective modeling of encoder-decoder architecture for joint entity and relation extraction [C]//Proceedings of the AAAI Conference on Artificial Intelligence. New York, USA: AAAI, 2020.
- [21] Pennington J, Socher R, Manning C. GloVe: global vectors for word representation [C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). Doha, Qatar: Association for Computational Linguistics, 2014.

引用本文格式:

中 文: 卜令梅, 陈黎, 卢永美, 等. 利用关系抽取技术联合识别文本中的方面—极性对[J]. 四川大学学报: 自然科学版, 2022, 59: 012002.

英 文: Bu L M, Chen L, Lu Y M, et al. Employing relation extraction technology to jointly recognize aspect-polarity pairs in a text [J]. J Sichuan Univ: Nat Sci Ed, 2022, 59: 012002.