

文章编号: 2096-1618(2025)02-0143-08

基于位置特征与语义分割的方面级情感三元组抽取方法

杨爱琳, 吴震, 王焱, 黄超, 杨渭平

(成都信息工程大学网络空间安全学院, 四川 成都 610225)

摘要:方面情感三元抽取任务定义为识别句子中的方面术语、情感极性和意见术语。近期一种端到端的网格标注方法有效缓解了流水线框架中误差传播的问题,却忽略了字符间的位置关系以及局部上下文信息,导致模型无法充分挖掘文本中的局部情感特征,影响性能的进一步提升。针对上述问题,提出一种融合位置特征与语义分割的方面情感三元抽取模型。该模型首先通过 BERT 编码层学习每个单词的上下文表达,同时加入位置编码丰富模型对位置信息的感知。在此基础上,使用语义分割网络捕获字符间的局部依赖,充分建模文本的上下文信息,加强模型的局部建模能力。在 Res14、Lap14、Res15 和 Res16 标准数据集上的实验结果表明,相较于基准模型,提出模型的 F1 指标分别提升2.82、3.8、3.59、3.77个百分点,均取得最优性能,有效证明了所提方法的优越性。

关键词:三元抽取;语义分割;位置编码;情感分析;网格标注

中图分类号:TP183

文献标志码:A

doi:10.16836/j.cnki.jcuit.2025.02.004

0 引言

随着科技的发展,互联网与人类的生活紧密相连,生活中的种种情感表达被映射到互联网文字里,其中包含大量发布者对于客观世界事物的观点态度。深入理解并分析文本中的情感信息对于产品优化与决策制定等具有显著助益^[1]。例如,对电商平台用户评价等相关的内容进行情感分析,分析用户对商品甚至单一商品属性的情感倾向,为商家制定精准营销策略提供有效支持。然而,文本内容的海量数据使得人工处理信息变得十分困难。因此,迫切需要设计一种自动化的计算框架,以便分析蕴含在非结构化文本之后的观点。基于这一需求,情感分析作为一个研究领域应运而生。

传统情感分析研究主要聚焦于文档或句子层面的情感预测,基于假设单一主题在给定文本中传达独立情感,从而对整体句子或文档情感进行判断。但在实际应用中,文档或句子往往涵盖多个主题,携带丰富多样的情感色彩,因而出现识别更细粒度的方面级意见和情感的需求。

方面级情感分析(aspect based sentiment analysis, ABSA)是一种细粒度的情感分析任务,旨在识别一条语句中某个特定方面的情感极性。值得注意的是,一个语句中可能包含多个不同的方面,而且每个方面的情感极性可能不同。该任务在实际应用中具有广泛的价值,例

如,针对商品评论的细粒度情感分析能够提取用户对商品不同部分或方面的评价,为制造商进一步改进商品提供更为细致的参考依据。方面级情感分析任务最早由 Thet 等^[2]于2010年提出。2012年,Liu 等^[3]进一步对该任务进行详细定义。随后,2014–2016年,国际语义评测大会 SemEva 将 ABSA 任务设为子任务之一,提供了一系列完成人工标注和校正的基准数据集^[4–6]。当前,方面级情感分析研究主要关注以下方向:方面词抽取^[5–7]、方面词的情感极性分类^[8–10]、观点词抽取^[11–12]、方面词和观点词的共同抽取等^[13–15]。然而,这些子任务只是针对细粒度情感分析任务的一个方面,并不完善。最近几年,研究者^[16–19]提出方面情感三元抽取(ASTE)任务,旨在从目标用户评论中抽取三元组集合,三元组分别是评论的目标(Aspect,方面项)、针对该目标的情感极性(Sentiment,情感项)以及体现该情感的原因(Opinion,观点项)。早期该任务主要采用流水线方法,但普遍存在传播误差问题,无法准确捕捉三元组,限制了性能的进一步提升。

文献[20]提出一种端到端的方法解决方面级三元情感抽取任务。该方法将 ASTE 任务转化成统一的标签标注任务,并提出一种新的序列标注模式,可以有效地完成目标–观点–情感极性的同步抽取。然而,该方法不能有效地建模词与词之间的局部依赖,忽略了词与词之间的位置关系与局部上下文信息。尤其是当模型进行标签识别时,往往只能捕捉到该标签相关的两个词的语义信息。但实际上,两个词在句子中的位置和词与词之间的位置关系往往扮演着重要的角色。此外,一个标签的周围有很大可能属于同类。所以,网

收稿日期:2023-10-15

基金项目:四川省科技计划资助项目(2023YFG0292, 2021ZYD0011);国家社会科学基金资助项目(23BSH061);四川省社会科学资助项目(SC21B034)

通信作者:吴震. E-mail:wzhen@cuit.edu.cn

格中的每个元素和上下左右等邻居元素之间的依赖关系也非常重要。

基于上述研究,本文对 Wu 等^[20]提出的 GTS 模型进行改进,利用位置编码和语义分割来加强模型对位置信息和上下文信息的建模能力,进而增强模型的位置感知能力和局部建模能力,更稳定地抽取方面词、观点词以及情感极性。

本文的贡献如下:

(1)在编码层融入位置特征,得到位置增强的词向量表示,加强模型在识别标签时对标签相关的两个词在句子中的位置和词与词之间的位置关系的关注,从而获得更丰富的文本语义表示。

(2)引入语义分割网络,通过语义分割网络捕捉网格点周围的信息,加强模型的局部建模能力,从而更好地学习单词间的局部上下文特征。

(3)在4个基准数据集进行大量的实验,实验结果表明本文提出的方法取得了最佳性能,充分证明了该方法的优越性。

1 相关工作

在 ASTE (aspect sentiment triplet extraction) 任务中,早期工作主要采用流水线方式。Peng 等^[16]在 2020 年提出 ASTE 任务,抽取句子中的方面-情感-观点三元组。采用流水线模型将任务分为两个阶段;第一个阶段抽取句子中的方面项、情感极性和潜在的观点项;第二个阶段则把相应的方面项与相应的观点项进行配对,完成完整的情感三元项抽取。Xu 等^[17]提出了 Span-Based ASTE 方法,直接捕捉方面-观点对之间的跨度关系,而不是词与词之间的交互关系。该方法采用神经网络生成所有可能方面项和观点项的跨度表示,并独立预测所有可能的方面-观点对的情感关系。Jian 等^[18]提出利用强化学习处理多个三元组和重叠的三元组。先抽取句子中的情感极性,然后利用强化学习捕捉相应的方面项和观点项。但是,这种流水线的方法通常存在误差传播问题,不能准确地捕获三元组之间的关系。

所以,近期学者们提出使用端到端模型来同时抽取三元组。Xu 等^[19]提出模型 JET,该模型基于位置感知的标注机制来捕捉情感三元组之间的信息,端到端地抽取情感三元组。但当句子中包含多个方面词和观点词时,JET 模型无法将其视为整体,忽略了方面项和观点项的整体信息。Wu 等^[20]在 2020 年提出一种新的端到端的方法,使用网格标记方案,把情感三元组抽取任务转换为统一的标注任务。首先通过编码层生

成字符对应的向量,再经过网格标记法对获得的向量进行编码,之后通过推理层来推测词与词之间的关系。但 GTS 模型忽略了字符之间的位置关系和局部上下文信息。

因此,本文对 Wu 等^[20]提出的 GTS 模型进行改进,提出一个新的端到端的方面级三元情感抽取模型。该模型通过在编码层融合位置特征,使其在识别标签时,捕捉到该标签相关的两个词向量的位置关系。不仅如此,本文还引入语义分割捕捉网格点周围的信息,加强对网格局部建模的能力。实验结果表明,本文提出的 PEunet 模型在准确率和有效性方面比基线模型有较大的提升。

2 基于位置特征与语义分割网络的方面情感三元抽取模型

本文设计了一个端到端的方面情感三元抽取,在 GTS 模型的基础上,加入位置编码模块和语义分割模块更完整地抽取情感三元组,模型结构如图 1 所示。

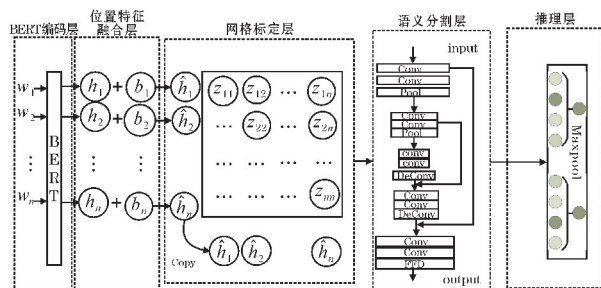


图 1 PEunet 模型框架

2.1 任务定义与准备

2.1.1 ASTE 任务

ASTE 任务是在一个包含 n 个单词的句子 $s = w_1, w_2, \dots, w_n$ 中抽取方面-情感-观点三元组。

$$T = \{ (a, o, c)_m \}_{m=1}^{|T|}$$

其中, a 表示方面项, o 表示观点项, c 表示与前面两项相关的情感极性, 3 种情感类型分别是 $\{ \text{NEG}, \text{NEU}, \text{POS} \}$, 代表消极、中性、积极。 $(a, o, c)_m$ 是 s 中的三元组, 而 $|T|$ 表示句子 s 中的三元组总数。

2.1.2 网格标记法

GTS 模型分为编码层、网格标记层、推理层等模块。其中,最重要的是网格标记层。本文将采用 Wu 等^[20]提出的网格标注方案,端到端地解决 ASTE 任务。该方法采用 6 个标签 $G = \{ A, O, \text{NEG}, \text{NEU}, \text{POS}, N \}$ 来表示网格中任意一个词对 (w_i, w_j) 的关系。6 个标签的含义如表 1 所示。

表 1 标签的含义

标签	含义
A	表示 (w_i, w_j) 对应的标签为方面项
O	表示 (w_i, w_j) 对应的标签为观点项
NEG	一个方面项和一个观点项对应的情感项,表现的情感是消极的
NEU	一个方面项和一个观点项对应的情感项,表现的情感是中性的
POS	一个方面项和一个观点项对应的情感项,表现的情感是积极的
N	表示 (w_i, w_j) 对应的两个单词不具备上述关系

图 2 为 GTS 网格标记法的示例。需要注意的是,根据对称关系,词对 (w_i, w_j) 和词对 (w_j, w_i) 表示的关系相同,并且具有相同的标签。因此,采用上三角网络进行编码。考虑输入句子“The hot dogs are top-notch but the coffee is average”。在这个句子中,“hot dogs”和“coffee”是方面项,而“top-notch”和“average”则是句子中的观点项。由于横、纵坐标相同,因此方面项和观点项通常被标记在对角线区域。方面项与观点项在网格中的交点区域则被标记为三元组中的情感项。例如,图 2 中,“hot dog”和“top-notch”对应于情感项“positive”。因此,这三个元素可以被抽取为句子的一个完整三元组,即 $\{\text{hot dog, top-notch, positive}\}$ 。

The	hot	dogs	are	top	notch	but	average	coffee	
N	N	N	N	N	N	N	N	N	The
	A	A	N	Pos	Pos	N	N	N	hot
		A	N	Pos	Pos	N	N	N	dogs
			N	N	N	N	N	N	are
				0	0	N	N	N	top
					0	N	N	N	notch
						N	N	N	but
							0	N	average
								A	coffee

图 2 网格标注法示例

由此,通过网格标注法成功地将方面级情感三元组抽取任务转化为一个更为统一的标注任务。在这个过程中,方面项和观点项主要位于标注表的上三角区域,这一区域用来映射句子中的方面项和观点项,并通过连续块状的区域来表示完整的方面项或观点项。随后,利用上三角矩阵中方面项和观点项相交的区域来识别情感项。

2.2 方面情感三元组抽取模型

本文提出一种名为 PEunet 的情感三元组抽取模型,融合位置特征与语义分割网络,可以有效地建模词

级序列特征和片段级局部特征,并具备端到端的情感三元组抽取功能。PEunet 模型的整体架构如图 1 所示,主要包括 BERT 编码层、位置特征融合层、网格标记层、语义分割层及推理层,并利用交叉熵损失预测标签。

2.2.1 BERT 编码

BERT (bidirectional encoder representations from transformers)^[21] 是一种基于 Transformer 架构的预训练语言模型,被广泛用于自然语言处理任务中。对于给定的语句 $s = \{w_1, w, \dots, w_n\}$,首先在语句的开头和结尾添加特殊标记 [CLS] 和 [SEP],然后将该序列完整地输入到 BERT 模型中进行编码。在编码层,输入序列首先使用词向量矩阵将每个字符映射为对应的向量表示。随后,分段嵌入被用于区分不同句子或文本片段,有助于模型理解句子级别的语义信息。同时,位置嵌入则用于标识每个标记在输入序列中的位置,进一步帮助模型理解上下文关系。通过多层的多头注意力机制和前馈神经网络进行迭代计算,最终,模型输出包含上下文信息的隐藏量 $E = \{h_{[\text{CLS}]}, h_1, h_2, \dots, h_n, h_{[\text{SEP}]}\}$ 。

2.2.2 位置特征融合层

GTS 模型着重设计一个统一的标注方法,信息聚焦于网格点 (w_i, w_j) 的横纵坐标对应的词 w_i, w_j ,但却忽略句子中词与词之间的关系,其中最重要的一个关系便是位置关系。针对这个问题,本文添加位置编码模块,加强模型的位置感知能力。利用正弦位置编码算法在编码层的输出 $E = \{h_{[\text{CLS}]}, h_1, h_2, \dots, h_n, h_{[\text{SEP}]}\}$ 中融合位置信息,有助于加强模型对不同位置之间相对距离和顺序的识别能力,从而更好地理解上下文内部的关系依赖。公式如下:

$$B_i = \begin{cases} \text{PE}(i, 2j) = \sin(i/10000^{2j/d_v}) \\ \text{PE}(i, 2j+1) = \cos(i/10000^{2j/d_v}) \end{cases}$$

其中: $B_i \in R^{d_v}$ 表示句子 S 中 w_i 对应的位置编码; i 表示词在句子序列中对应的位置; j 表示词嵌入编码中的维度索引; d_v 表示词嵌入的维度。

正弦这一类的参数式位置编码中主要涉及两个概念:一个是距离,另一个是维度。所以在涉及计算公式的时候,每个字之间按顺序给它分配距离,即参数 i ; 同一个字中不同维度的特征信息,即参数 j , 可以用 \sin 和 \cos 的方式计算。这种方法使用不同频率的正弦、余弦函数生成,然后再和对应位置的词向量相加得到

融合位置特征的向量 $\tilde{E} = \{\hat{h}_{[\text{CLS}]}, \hat{h}_1, \hat{h}_2, \dots, \hat{h}_n, \hat{h}_{[\text{SEP}]}\}$, 计算公式如下:

$$\hat{h}_i = h_i + b_i$$

2.2.3 语义分割层

在词对关系建模中,局部上下文信息对语义信息的理解有着至关重要的影响。为增强模型对局部信息的建模能力,本文进一步利用语义分割网络捕获词对间的片段级上下文特征。具体而言,在使用网格标注方法对特征编码后,可以获得一个矩阵 $\mathbf{Z} \in R^{L \times L \times D}$,即得到网格标记后得到其初始概率分布为 z_{ij} 。如图3所示,设计了一个类似的U形网络来处理该特征矩阵,将获得特征矩阵 $\mathbf{Z} \in R^{L \times L \times D}$ 。当D通道图像输入到U形网络中,该网络由两个独立的下采样模块和独立的上采样模块组成。每个下采样模块包括两个卷积层和一个最大池化层,每个模块都会使通道数翻倍,从而扩大感受野,有效地理解局部上下文信息并提取更高层次的语义特征。每个上采样模块包含两个卷积层和一个反卷积神经网络,每个模块都会减少通道数,并将前面的下采样模块的输出进行拼接。

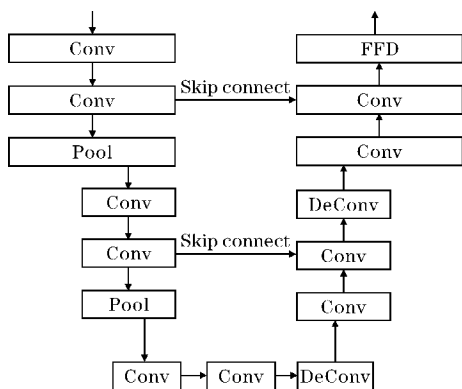


图3 语义分割层详解

此外,每一个上采样层和下采样层之间都有一个跳跃连接,每一层的特征融合后都会经过一系列的卷积层,以此来处理特征图中的细节,让模型学习这些信息来组装一个更精确的输出。最后,使用前馈神经网络将每个像素映射到6种标签,从而获得一个新的特征矩阵 $\mathbf{P} \in R^{L \times L \times D}$ 。语义分割层的引入,显著增强了模型对网格局部区域进行建模的能力。值得注意的是,整个Unet的设计中都没有使用padding。因为下采样维度越高,经过越多的卷积层,padding操作越多,越深层的特征图就越容易受到padding的影响,这就导致矩阵边缘的损失。然而,如果不使用padding,在层层卷积过程中,矩阵的分辨率会越来越小,导致最后上采样回去的特征图尺寸和原图不匹配。为了解决这个问题,Unet“粗暴”地将原图进行镜像扩充,这样上采样回去的图像就和原图具有相同的尺寸。

2.2.4 推理层

经过语义分割层处理过的网格,其初始概率分布为 p_{ij} 。因为三元组的位置存在一定的分布规律,例如:长度为 n 的一个句子,位置为(3,3)的词对被预测为方面项标签,则词对(3, i) ($i \in n$) 对应的标签不太可能是观点项标签。并且,如果某个标签被预测成情感项标签中的一个,那么它的相邻位置更有可能被预测为相同的情感标签。因此,加入推理策略模块,推理得新的特征 g_{ij} :

$$\begin{aligned} p_i &= \text{maxpooling}(p_{i,:}) \\ p_j &= \text{maxpooling}(p_{:,j}) \\ p'_{ij} &= [z_{ij}; p_i; p_j; p_{ij}] \\ g_{ij} &= W_g p'_{ij} + b_g \end{aligned}$$

其中, W_g 和 b_g 为可训练参数, $[\cdot; \cdot]$ 表示一个拼接操作, z_{ij} 为网格标记后的矩阵概率分布。

在上三角网格中, W_g 和 b_g 表示可以训练的参数。由于GTS为上三角网格,因此 $p_{i,:} = (p_{1:n,i}, p_{i,1:n})$, $p_{1:n,i}$ 表示词 w_i 位于网格中的第 i 列的特征。 $p_{i,1:n}$ 表示词 w_i 位于网格中第 i 行的特征。通过maxpooling捕捉 w_i 与其他词的关系。通过观察 w_i/w_j 与其他词之间的关系预测推断 (w_i, w_j) 可能的标记。

最后,再将结果送到softmax激活函数的线性层进行分类:

$$r_{ij} = \text{softmax}(W_r g_{ij} + b_r)$$

其中, W_r 和 b_r 表示可以训练的参数。

2.2.5 损失函数

交叉熵损失是一种常用的损失函数,特别适用于分类任务,用于衡量实际输出与期望输出之间的差异。在ASTE任务中,本文的训练目标是最小化所有词对的交叉熵误差。所以,统一将损失函数定义为

$$L = - \sum_{i=1}^n \sum_{j=i}^n \sum_{k \in G} I(y_{ij} = k) \lg(r_{i,j})$$

其中, G 为标签集, $G = \{A, O, NEG, NEU, POS, N\}$, 在得到预测结果时,对每一个位置的标签计算交叉熵。

3 实验及结果分析

3.1 实验设置

3.1.1 数据集

本文数据集使用SemEval竞赛的ASTE基准数据集,包括SemEval 2014的笔记本电脑数据集(Lap14)和SemEval 2014-2016的餐厅数据集(Res14、Res15、Res16)。沿用文献[20]的标签和数据集划分方式,将数据集按一定比例分为训练集、验证集和测试集,数据集统计信息如表2所示。

表 2 数据集的统计信息

数据集名称	训练集		验证集		测试集	
	句子数量	三元组数量	句子数量	三元组数量	句子数量	三元组数量
Res14	1259	2356	315	580	493	1008
Lap14	899	1452	225	383	335	547
Res15	603	1038	151	239	325	493
Res16	863	1421	216	348	328	525

3.1.2 实验环境与参数设置

实验环境:CPU 为 22 vCPU AMD EPYC 7T83 64-Core Processor,GPU 为 NVIDIA GeForce RTX 4090,显存为 24GB,开发环境为 linux64 位系统和pytorch1.7.1。采用 Adam 优化器来优化模型,BERT 采用 Google 的 BERT-Base-Uncased 预训练模型,字向量维度为 768,文本最大长度设置为 100,batch-size 为 32,BERT 的学习率为 2e-5,全局的学习率为 2e-3。

3.1.3 评估标准

为评价模型的性能与效果,使用精确率、召回率和 F1 值作为模型性能评价指标,公式如下:

$$P=\frac{TP}{TP+FP}$$
$$R=\frac{TP}{TP+FN}$$
$$F_1=\frac{2P\times R}{P+R}$$

只有当预测的三元组的方面项、观点项及其对应的情感极性与正确的三元组完全相同时,预测结果才会被认为完全正确。

3.2 基线模型

CMLA+^[16]:基于多层注意力机制的 CMLA (coupled multi-layer attention) 模型^[22]构造一个两段式流水线模型。第一阶段抽取方面项和情感项,第二阶段使用分类器来选择合适的方面词和观点词对。

RINANTE+^[16]:在模型 RINANTE (rule incorporate neural aspect and opinion term extraction)^[23]基础上构造一个流水线模型。分为两部分,首先使用基于依存关系挖掘方面词和观点词,然后使用关系分类器进行分类。

Li-unified-R+^[16]:基于 Li 等^[24]提出的模型构建的一个两段式模型。首先使用文献[24]模型提取观点项和方面-情感对,然后利用文献[12]模型的分类器进行匹配。

JET^[19]:基于位置感知的标注机制来分析情感三元组中各个元素之间的信息。通过端到端的方式从用户评论中抽取三元组。有两种方法:JET(t)+BERT 和 JET(O)+BERT。前者以目标词为中心,标注情感词和属性词之间的距离。后者以情感词为中心,计算属性词到情感词之间的距离。实验证明,JET(O)+BERT 的效果要好于 JET(t)+BERT。

GTS-BERT-REL^[25]:该模型在 GTS 的基础上,使用适配器来整合预训练模型中的结构偏差,并使用相对距离代替句法依赖结构提高计算效率。

PBF^[26]:Li 等^[26]提出基于位置感知的 BERT 框架,分为方向实体提取、目标导向的意见词提取、方向意见对情绪分类 3 步,完成三元情感抽取的任务。

GTS^[20]:Wu 等^[20]提出的网格标注方法,在 CNN、BiLSTM 及 BERT 的基础上设计的 3 个模型。其中 GTS-BERT 模型的效果要好于其他两种模型。

3.3 实验结果及分析

3.3.1 对比实验

本文提出的模型与上述的基线模型在基准数据集上进行对比实验,实验结果如表 3 所示。模型后加由对比实验结果可知,本文模型基本优于基准模型的实验效果。本文模型在 Res14、Lap14、Res15 和 Res16 数据集上的数值分别提高了2.82、3.8、3.59、3.77个百分点,证明了本模型的有效性。

表 3 不同模型对比实验结果

单位: %

方法	Res14			Lap14			Res15			Res16		
	精确率	召回率	F1	精确率	召回率	F1	精确率	召回率	F1	精确率	召回率	F1
CMLA+	40.11	46.63	43.12	31.40	34.60	32.90	34.40	37.60	35.90	43.60	39.80	41.60
RINANTE+	31.07	37.63	34.03	23.10	17.60	20.00	29.40	26.90	28.00	27.10	20.50	23.30
Li-unified-R+	41.44	68.79	51.68	42.25	42.78	42.47	43.34	50.73	46.69	38.19	53.47	44.51
JET(t)+BERT	70.39	51.86	59.72	57.98	36.33	44.67	61.99	43.74	51.29	68.99	51.18	58.77
JET(O)+BERT	67.97	60.32	63.92	58.47	43.67	50.00	58.35	51.43	54.67	64.77	61.29	62.98
GTS-BERT-REL	68.94	68.26	68.60	57.89	51.57	54.47	62.17	58.63	60.28	66.17	69.79	67.91
PBF	69.30	69.00	69.20	56.60	55.10	55.80	55.80	61.50	58.50	61.20	72.70	66.50
GTS-CNN *	67.20	63.13	65.10	56.98	45.69	50.71	61.05	52.56	56.48	64.89	63.51	64.20
GTS-BiLSTM *	66.43	64.75	65.58	56.00	46.24	50.65	59.09	55.83	57.41	68.61	63.71	66.07
GTS-BERT *	70.22	69.30	69.75	58.20	53.39	55.69	61.09	52.97	56.74	67.51	67.38	67.44
PEunet *	74.49	69.90	72.12	64.45	55.23	59.49	61.62	59.10	60.33	74.11	68.53	71.21

注: * 为本文训练得到的结果,其他引自原论文,加粗数值为最佳值。

由表 3 可知,CMLA+、RINANTE+、Li-unified-R、PBF 为流水线模型,JET(t)+BERT、JET(O)+BERT、GTS-CNN、GTS-BILSTM、GTS-BERT、GTS-BERT-REL 和本文模型 PEunet 为端到端模型。总体来看,端到端模型在基准数据集上的性能要明显好于流水线模型。

JET(t)+BERT、JET(O)+BERT、GTS-CNN、GTS-BILSTM、GTS-BERT、GTS-BERT-REL 和本文模型 PEunet 属于端到端模型。其中,采用 BERT 作为编码层的效果要明显高于其他同类型的模型。一方面,BERT 通过预训练模型获得的词向量,已经包含丰富的上下文信息和语义语境,使得模型更具有深层次的语义理解能力。另一方面,BERT 还通过掩码语言建模任务(Masked Language Modeling, MLM)的预训练过程,学会识别和填充句子中的缺失部分,强化了模型对文本信息的敏感性和全局上下文的把握。因此,BERT 词向量具备更加丰富的语义信息,使得模型在进行情感分类预测时能够捕获更为丰富的信息。

如图 4 所示,本文提出的 PEunet 模型与 GTS-CNN、GTS-BILSTM、GTS-BERT 模型进行比较。结果显示,PEunet 模型在数据集 Res14、Lap14、Res15 和 Res16 上均表现出显著的性能提升。与表现最佳的 GTS-BERT 相比,PEunet 平均在每个数据集上提高了近3.5个百分点。综合来看,本文提出的结合位置特征与语义分割的方面情感三元组抽取方法显著增强了模型对位置信息的敏感性,全面提升了模型的局部建模能力,使得该方法在情感三元抽取任务上实现了性能提升。




图 4 对比实验结果

3.3.2 消融实验

为验证模型中位置编码模块和语义分割模块对模型性能的影响,设计了以下消融实验,分别为不加入位置编码模块(w/o[PE])和不加入语义分割模块(w/o[U-net]),在 Res14、Lap14、Res15 和 Res16 数据集上进行实验,各项超参数均设置相同。实验的结果如表 4 所示,最优结果加粗标识。

表 4 消融实验的 F1 单位:%

方法	Res14	Lap14	Res15	Res16
PEunet	72.12	59.49	60.33	71.21
w/o[U-net]	71.66	57.48	59.71	69.47
w/o[PE]	71.29	57.31	59.92	70.60

由表 4 可以看出,U-net 和 PE 模块都有助于提高模块的最终性能。在不加入位置编码模块(w/o[PE])后,模型在数据集 Res14、Lap14、Res15 和 Res16 上实验,F1 值分别下降了0.46、2.01、0.62、1.74个百分点;在不加入语义分割模块(w/o[U-net])后,模型在数据集 Res14、Lap14、Res15 和 Res16 上实验,F1 分别下降了0.83、2.18、0.41、0.61个百分点。结果表明:位置编码和语义分割网络可以一定程度地提高模型的性能。

4 结束语

本文提出一种端到端的方面情感三元抽取模型,记为 PEunet。首先,采用 BERT 对输入的句子进行编码,以捕捉文本的语义信息。在此基础上,引入位置编码来更全面地感知词语的位置信息,并通过网格标定法实现对词与词之间关系的一致标注。进一步地,通过引入语义分割模块,模型可以更全面地考虑局部上下文的联系,以提高抽取模型的性能。最后,模型通过推理模块来得出最终的抽取结果。在公共数据集上的实验结果显示,本文提出的 PEunet 模型在性能上优于所有基线模型。但是,本文尚未深入探讨不同位置信息对实验结果的影响,也未充分探索更完善的位置信息融合方式。因此,未来将继续深入研究这一方面,以进一步提升抽取模型的性能和鲁棒性。

参考文献:

[1] Abdu S A, Yousef A H, Salem A. Multimodal Video Sentiment Analysis Using Deep Learning Approaches, a Survey [J]. Information Fusion, 2021, 76: 204–226.

[2] Thet T T, Na J C, Khoo C S G. Aspect-based sentiment analysis of movie reviews on discussion boards [J]. Journal of Information Science. 2010, 36(6): 823–848.

[3] Liu B, Zhang L. A survey of opinion mining and sentiment analysis [M]. Mining text data. Springer, Boston, MA, 2012: 415–463.

- [4] Pontiki M, Galanis D, Pavlopoulos J, et al. Semeval-2014 task 4: Aspect Based Sentiment Analysis [C]. Proceedings of the 8th International Workshop on Semantic Evaluation (SemEval 2014), Dublin, Ireland, 2014, 27–35.
- [5] Pontiki M, Galanis D, Papageorgiou H, et al. Semeval-2015 task 12: Aspect based sentiment analysis [C]. Proceedings of the 9th international workshop on semantic evaluation (SemEval 2015). 2015: 486–495.
- [6] Pontiki M, Galanis D, Papageorgiou H, et al. Semeval-2016 task 5: Aspect Based Sentiment Analysis [C]. Proceedings of the 10th International Workshop on Semantic Evaluation (SemEval 2016). 2016: 19–30.
- [7] Chen Z, Qian T. Bridge-based active domain adaptation for aspect term extraction [C]. Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing (Volume 1: Long Papers). 2021: 317–327.
- [8] Sun K, Zhang R, Mensah S, et al. Aspect-level sentiment analysis via convolution over dependency tree [C]. Proceedings of the 2019 conference on empirical methods in natural language processing and the 9th international joint conference on natural language processing (EMNLP-IJCNLP). 2019: 5679–5688.
- [9] Zhang C, Li Q, Song D. Aspect-based sentiment classification with aspect-specific graph convolutional networks [J]. arXiv preprint arXiv:1909.03477, 2019.
- [10] Tang H, Ji D, Li C, et al. Dependency graph enhanced dual-transformer structure for aspect-based sentiment classification [C]. Proceedings of the 58th annual meeting of the association for computational linguistics. 2020: 6578–6588.
- [11] Fan Z, Wu Z, Dai X, 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, Volume 1 (Long and Short Papers). 2019: 2509–2518.
- [12] Veyseh A P B, Nouri N, Deroncourt F, et al. Introducing syntactic structures into target opinion word extraction with deep learning [J]. arXiv preprint arXiv:2010.13378, 2020.
- [13] Wang W, Pan S J, Dahlmeier D, et al. Coupled multi-layer attentions for co-extraction of aspect and opinion terms [J]. Proceedings of the AAAI conference on artificial intelligence. 2017, 31(1).
- [14] Yu J, Jiang J, Xia R. Global inference for aspect and opinion terms co-extraction based on multi-task neural networks [J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2018, 27(1): 168–177.
- [15] Dai H, Song Y. Neural aspect and opinion term extraction with mined rules as weak supervision [J]. arXiv preprint arXiv:1907.03750, 2019.
- [16] Peng H, Xu L, Bing L, et al. Knowing what, how and why: A near complete solution for aspect-based sentiment analysis [J]. Proceedings of the AAAI conference on artificial intelligence. 2020, 34(5): 8600–8607.
- [17] Xu L, Chia Y K, Bing L. Learning span-level interactions for aspect sentiment triplet extraction [J]. arXiv preprint arXiv:2107.12214, 2021.
- [18] Yu Bai Jian S, Nayak T, Majumder N, et al. Aspect sentiment triplet extraction using reinforcement learning [C]. Proceedings of the 30th ACM International Conference on Information & Knowledge Management. 2021: 3603–3607.
- [19] Xu L, Li H, Lu W, et al. Position-aware tagging for aspect sentiment triplet extraction [J]. arXiv preprint arXiv:2010.02609, 2020.
- [20] Wu Z, Ying C, Zhao F, et al. Grid tagging scheme for aspect-oriented fine-grained opinion extraction [J]. arXiv preprint arXiv:2010.04640, 2020.
- [21] Kenton J D M W C, Toutanova L K. Bert: Pre-training of deep bidirectional transformers for language understanding [J]. Proceedings of naacL-HLT. 2019(1): 2.
- [22] Chen S, Wang Y, Liu J, et al. Bidirectional machine reading comprehension for aspect sentiment triplet extraction [J]. Proceedings of the AAAI conference on artificial intelligence. 2021, 35(14): 12666–12674.
- [23] Dai H, Song Y. Neural aspect and opinion term extraction with mined rules as weak supervision

[J]. arXiv preprint arXiv:1907.03750,2019.

[24] Li X,Bing L,Li P,et al. A unified model for opinion target extraction and target sentiment prediction[J]. Proceedings of the AAAI conference on artificial intelligence. 2019,33(1):6714–6721.

[25] Zhang C, Ren L, Ma F, et al. Structural bias for aspect sentiment triplet extraction[J]. arXiv preprint arXiv:2209.00820,2022.

[26] Li Y,Wang F,Zhong S. A More Fine-Grained Aspect-Sentiment-Opinion Triplet Extraction Task[J]. Mathematics,2023,11(14):3165.

Aspect-Level Sentiment Triple Extraction based on Location Features and Semantic Segmentation

YANG Ailin, WU Zhen, WANG Yi, HUANG Chao, YANG Weiping
(College of Cyberspace Security, Chengdu University of Information Technology , Chengdu 610225,China)

Abstract: Aspect-sentiment triple extraction task is defined as recognizing aspectual terms, sentiment polarity, and opinion terms in a sentence. Recently, researchers have proposed an end-to-end grid labeling method that effectively mitigates the problem of error propagation in pipelined approaches. However, the method ignores the positional relationship between characters and local contextual information, which results in the model not being able to fully mine the local sentiment features in the text, affecting the further improvement of performance. To address the above problems, this study proposes an aspectual sentiment Triple extraction model that fuses positional features with semantic segmentation. In this study, we first learn the contextual expression of each word through the BERT coding layer, and at the same time, we add location coding to enrich the model’s perception of location information. On this basis, the local dependencies between characters are captured using semantic segmentation network to fully model the contextual information of the text and strengthen the local modeling ability of the model. The experimental results on four standard datasets, Res14, Lap14, Res15 and Res16, show that compared with the benchmark model, the model proposed in this paper improves the F1 metrics by 2.82,3.8,3.59 and 3.77 percentage points, respectively, and all of them achieve optimal performance, which effectively proves the superiority of the method proposed in this paper.

Keywords: triple extraction;semantic segmentation;location coding;sentiment analysis;grid labeling