

片段级别的双编码器方面情感三元组抽取模型

张韵琪¹, 李松达¹, 兰于权¹, 李东旭¹, 赵 慧^{1,2+}

1. 华东师范大学 软件工程学院, 上海 200062

2. 华东师范大学 上海市高可信计算重点实验室, 上海 200062

+ 通信作者 E-mail: hzhao@sei.ecnu.edu.cn

摘要: 方面情感三元组抽取(ASTE)是方面级情感分析的子任务之一,旨在识别出句子中所有的方面词及其对应的观点词和情感极性。目前,ASTE任务通过流水线模型或端到端模型完成,前者无法解决三元组方面词重叠问题,且忽视了观点词和情感极性之间的依赖关系;后者将ASTE任务分解为方面词和观点词抽取子任务以及情感极性分类子任务,通过共享编码器进行多任务学习,未区分两个子任务的特征差异,导致特征混淆问题。针对上述问题,提出了片段级别的双编码器方面情感三元组抽取模型(SD-ASTE)。该模型是流水线模型,分为两个模块。第一个模块基于片段抽取方面词和观点词,在片段特征表示中融入片段首尾和长度信息,关注方面词和观点词的边界信息;第二个模块判断方面词-观点词片段对表达的情感极性,采用基于悬浮标记的片段对特征表示方式,侧重于学习三元组各元素之间的依赖关系。模型利用两个独立编码器,分别为两模块提取不同的特征信息。多个数据集上的对比实验结果表明,该模型相较于目前最优的流水线模型和端到端模型具有更优的效果。通过有效性实验,验证了片段特征表示和片段对特征表示以及两个独立编码器的有效性。

关键词: 情感分析;方面情感三元组抽取(ASTE);流水线模型;片段;独立编码器

文献标志码: A **中图分类号:** TP391

Span-Level Dual-Encoder Model for Aspect Sentiment Triplet Extraction

ZHANG Yunqi¹, LI Songda¹, LAN Yuquan¹, LI Dongxu¹, ZHAO Hui^{1,2+}

1. School of Software Engineering, East China Normal University, Shanghai 200062, China

2. Shanghai Key Laboratory of Trustworthy Computing, East China Normal University, Shanghai 200062, China

Abstract: Aspect sentiment triplet extraction (ASTE) is one of the subtasks of aspect-based sentiment analysis, which aims to identify all aspect terms, their corresponding opinion terms and sentiment polarities in sentences. Currently, pipeline or end-to-end models are adopted to accomplish the ASTE task. The former cannot solve the overlapping problem of aspect terms in triplets and ignores the dependency between opinion terms and sentiment polarities. The latter divides the ASTE task into two subtasks of aspect-opinion-extraction and sentiment-polarity-classification, which applies multi-task learning through a shared encoder. However, this setting does not distinguish the differences between the features of the two subtasks, leading to the feature confusion problem. SD-ASTE (span-level dual-encoder model for ASTE), a pipeline model with two modules, is proposed to address the above problems. The first module extracts aspect terms and opinion terms based on spans. The span feature representation incorporates span head, tail and length information to focus on the boundary information of aspect terms and opinion terms. The second module judges the sentiment polarities expressed by aspect-opinion span pairs. The span-pair

基金项目: 国家重点研发计划(2019YFB2102600)。

This work was supported by the National Key Research and Development Program of China (2019YFB2102600).

收稿日期: 2022-08-03 **修回日期:** 2022-09-21

feature representation is based on levitated markers to focus on the dependency among triplet elements. The model utilizes two independent encoders to extract different features for each module. Comparative experimental results on multiple datasets show that the model is superior to the state-of-the-art pipeline and end-to-end models. Validity experiments show the effectiveness of the span feature representation, span-pair feature representation and the two independent encoders.

Key words: sentiment analysis; aspect sentiment triplet extraction (ASTE); pipeline model; span; independent encoders

对于商家而言,满足顾客日益增长的需求对抢占市场份额至关重要。随着线上信息交流平台的普及,顾客对于商品反馈的信息量大幅增加。同时,顾客往往会对商品多个方面进行评价。方面情感三元组抽取(aspect sentiment triplet extraction, ASTE)是方面级情感分析(aspect-based sentiment analysis, ABSA)的一项子任务^[1],实现对方面词-情感极性-观点词三元组的抽取,可以帮助商家从大量评论中挖掘顾客对商品不同方面的观点和情感极性,为商家改进商品提供具体思路,提高消费者满意度。

通过观察可以发现,真实的评论中往往存在以下两种情况:一种情况是顾客会针对同一商品的不同方面进行评价。以“电脑已收到,这价位非常给力,但客服态度不好”为例,顾客同时评价了“价位”和“客服态度”两个方面,并表达了不同的观点和情感。另一种情况是顾客针对同一方面可能存在多种情感极性。以“显示屏很不错,但是太贵了”为例,对于“显示屏”,分别通过“很不错”来表达正面的情感极性,通过“太贵”表达负面的情感极性。

目前,针对 ASTE 任务的模型主要可分为两类:流水线模型和端到端模型。

流水线模型^[2]将 ASTE 任务分为两阶段:第一阶段基于两个序列标注任务,分别预测方面词-情感极性对和观点词;第二阶段基于分类器,判断方面词-情感极性对和观点词是否匹配。在预测方面词-情感极性对的时候,模型采用了一种统一标注方式,把方面词的边界信息和情感极性融入一个标签。但是,该方式没有考虑观点词对判断情感极性的影响,而且无法解决三元组方面词重叠问题。以“显示屏不错,但是太贵了”为例,其中包含(“显示屏”,正面,“不错”)和(“显示屏”,负面,“太贵”)两个三元组。针对“显示屏”这一方面词,同时存在两种情感极性。但是,对于同一方面词,上述标注方式只能标注出一种情感极性。

端到端模型^[3-4]将 ASTE 任务分为方面词和观点词抽取以及情感极性分类两个子任务,在两项子任

务中共享编码器进行多任务学习。方面词和观点词抽取子任务的难点在于确定词的边界。以“耳机盒好看”为例,方面词应为“耳机盒”,如果方面词边界识别错误,可能得到结果“耳机”。情感极性分类子任务的难点在于正确配对方面词和观点词,并判断情感极性。以“物流很快,但质量很差”为例,“物流-很差”虽然语义合理,但不是对应关系。两项子任务难点不同,导致二者所需学习的特征信息之间存在差异。然而,共享编码器为两项子任务提取特征是相同的,导致模型在多任务学习过程中易出现特征混淆问题^[5-6],两项子任务无法同时达到最佳效果。

针对上述问题,本文提出了片段级别的双编码器方面情感三元组抽取模型(span-level dual-encoder model for ASTE, SD-ASTE)。该模型是一个由片段识别和情感分类两模块构成的流水线模型。两模块分别完成方面词和观点词抽取以及情感极性分类,采用相互独立的编码器学习各自所需的特征信息。片段识别模块侧重于学习方面词和观点词的边界信息,情感分类模块侧重于针对不同方面词-观点词对,学习三元组各元素之间的相互依赖关系。

1 相关研究

ASTE 任务由 Peng 等人^[2]提出, Peng 等人采用流水线模型将任务分成两阶段,第一阶段分别预测方面词-情感极性对和观点词,第二阶段将二者配对。该流水线模型判断情感极性时,没有考虑观点词,而且无法解决方面词重叠问题,加重了误差积累问题。

之后,开始有研究者采用端到端模型完成该任务。Xu 等人^[7]提出了一种采用位置感知标注方式的模型 JET(joint extraction of triplets),在 BIOES 序列标注方式中融入观点词和方面词之间的位置信息。为了更好地确定方面词和观点词的边界, Wu 等人^[8]提出了一种网格标注方式 GTS(grid tagging scheme),对句子中的单词两两进行标注,除了单词之间的情感极性之外,还标注出了两个单词是否属于同一个

方面词或同一个观点词。

上述模型在判断情感极性时都只利用了单词级别(word-level)的信息,没有充分利用方面词和观点词片段级别(span-level)的信息。

受到实体关系联合抽取相关工作的启发,Xu等人^[4]进一步优化JET模型,基于片段排列^[9-10]的思想,提出Span-ASTE(span-level model for ASTE)模型。该模型采用双通道片段修剪策略确定方面词和观点词,再从片段角度预测候选方面词-观点词对的情感极性。而Mukherjee等人^[3]基于指针网络^[11]的解码方式,提出PASTE(pointer networks for ASTE)模型,其核心是一个编码-解码框架。在编码阶段,基于预训练模型,获得片段特征表示。在解码阶段,在方面情感三元组中融入位置信息(方面词和观点词的起始位置),转换成五元组。该模型针对三元组重叠问题有了很大的提升。

机器阅读理解(machine reading comprehension, MRC)为ASTE任务提供了另一种思路。Chen等人^[12]提出模型BMRC(bidirectional machine reading comprehension),通过三轮MRC任务完成了ASTE任务。首先,分别查询全部方面词和观点词;随后,将方面词和观点词进行配对;最后,查询方面词-观点词对的情感极性。Mao等人^[13]通过两个BERT-MRC模型共享参数进行联合训练,先查询出句子中的方面词,然后根据方面词,查询其观点词-情感极性对。

也有学者将ASTE任务建模为生成任务。Yan等人^[14]引入了指针索引表示句子中方面词和观点词的起始和结束位置,采用生成式框架,利用预训练模型BART(bidirectional and auto-regressive transformers),生成由方面词指针索引、观点词指针索引和情感极性类别组成的序列。Lu等人^[15]提出了一个文本到结构的生成框架UIE(unified information extraction architecture),通过一种结构化抽取语言(structured extraction language, SEL)编码方面情感三元组,并设计了结构模式指导器(structural schema instructor, SSI)来控制UIE模型的生成。

2 方法和模型

2.1 问题定义

给定数据集 D ,输入序列为语句 $X=[w_1, w_2, \dots, w_n]$,ASTE任务的目标是抽取出 X 中所有方面情感三元组构成的集合 $T=\{t_1, t_2, \dots, t_k\}$, $t_i=(A_i, P_i, O_i)$,其中, A_i 和 O_i 分别表示方面词和观点词, $P_i \in \{Pos, Neg,$

$Neu\}$ 表示二者对应的情感极性, Pos 、 Neg 和 Neu 分别表示正面、负面和中性情感。

定义1(片段) 设 $s_{i,j}$ 为输入序列 X 的一个片段,表示 X 的子序列 $[w_i, w_{i+1}, \dots, w_j]$,其中 $1 \leq i \leq j \leq n$ 。

定义2(片段类别集合) 设片段类别集合为 $C=\{A, O, N_c\}$,其中, A 表示方面词片段, O 表示观点词片段, N_c 表示无意义片段。

给定片段 $s_{i,j}$,片段识别旨在预测其类别 $c \in C$ 的概率分布函数 $P(c|s_{i,j})$,最大化概率,得到最优类别 $L_c(i, j)$ 。输出为方面词集合 S_A 和观点词集合 S_O 。

定义3(片段对) 设片段对为 $(s_{i,j}, s_{p,q})$,其中, $s_{i,j} \in S_A$ 是方面词片段, $s_{p,q} \in S_O$ 是观点词片段。

定义4(情感极性集合) 设情感极性集合为 $V=\{Pos, Neg, Neu, N_v\}$,其中, N_v 表示无情感。

给定片段对 $(s_{i,j}, s_{p,q})$,情感分类旨在预测其情感极性 $v \in V$ 的概率分布函数 $P(v|s_{i,j}, s_{p,q})$,最大化概率,得到最优情感极性 $L_v(s_{i,j}, s_{p,q})$ 。输出为方面情感三元组集合 T 。

基于上述任务定义,本文提出了片段级别的双编码器方面情感三元组抽取模型SD-ASTE,图1示意了模型结构,包括片段识别模块和情感分类模块。

2.2 片段识别模块

该模块首先采用TPL(token pair linking)方式,标注所有片段的类别,构建词元之间的联系。其次,基于BERT(bidirectional encoder representations from transformers)模型^[16]得到输入序列的特征向量。然后,基于片段边界和长度信息,对片段进行特征表示。最后,通过前馈神经网络(feedforward neural network, FNN)学习片段特征信息,对片段进行分类,得到所有方面词片段和观点词片段。

2.2.1 TPL 标注层

TPL标注的标签集合为 $C \cup \{U\} = \{A, O, N_c, U\}$ 。设标注矩阵为 T_c 。若 $1 \leq j-i+1 \leq L$ 且 $i \leq j$,则标注 $T_c(i, j)$ 为 $s_{i,j}$ 片段类别;否则标注为 U 。其中 L 为超参数,是片段长度阈值。图2为 $L=5$ 的标注结果。

2.2.2 编码层

编码层基于BERT对输入序列编码。对于输入序列 $X=[w_1, w_2, \dots, w_n]$,先获取其字嵌入向量、段嵌入向量和位置嵌入向量,BERT将三种向量相加,再通过Transformer得到特征向量 $E=[e_1, e_2, \dots, e_n]$ 。

2.2.3 片段表示层

片段表示层对每个片段进行特征表示,由片段

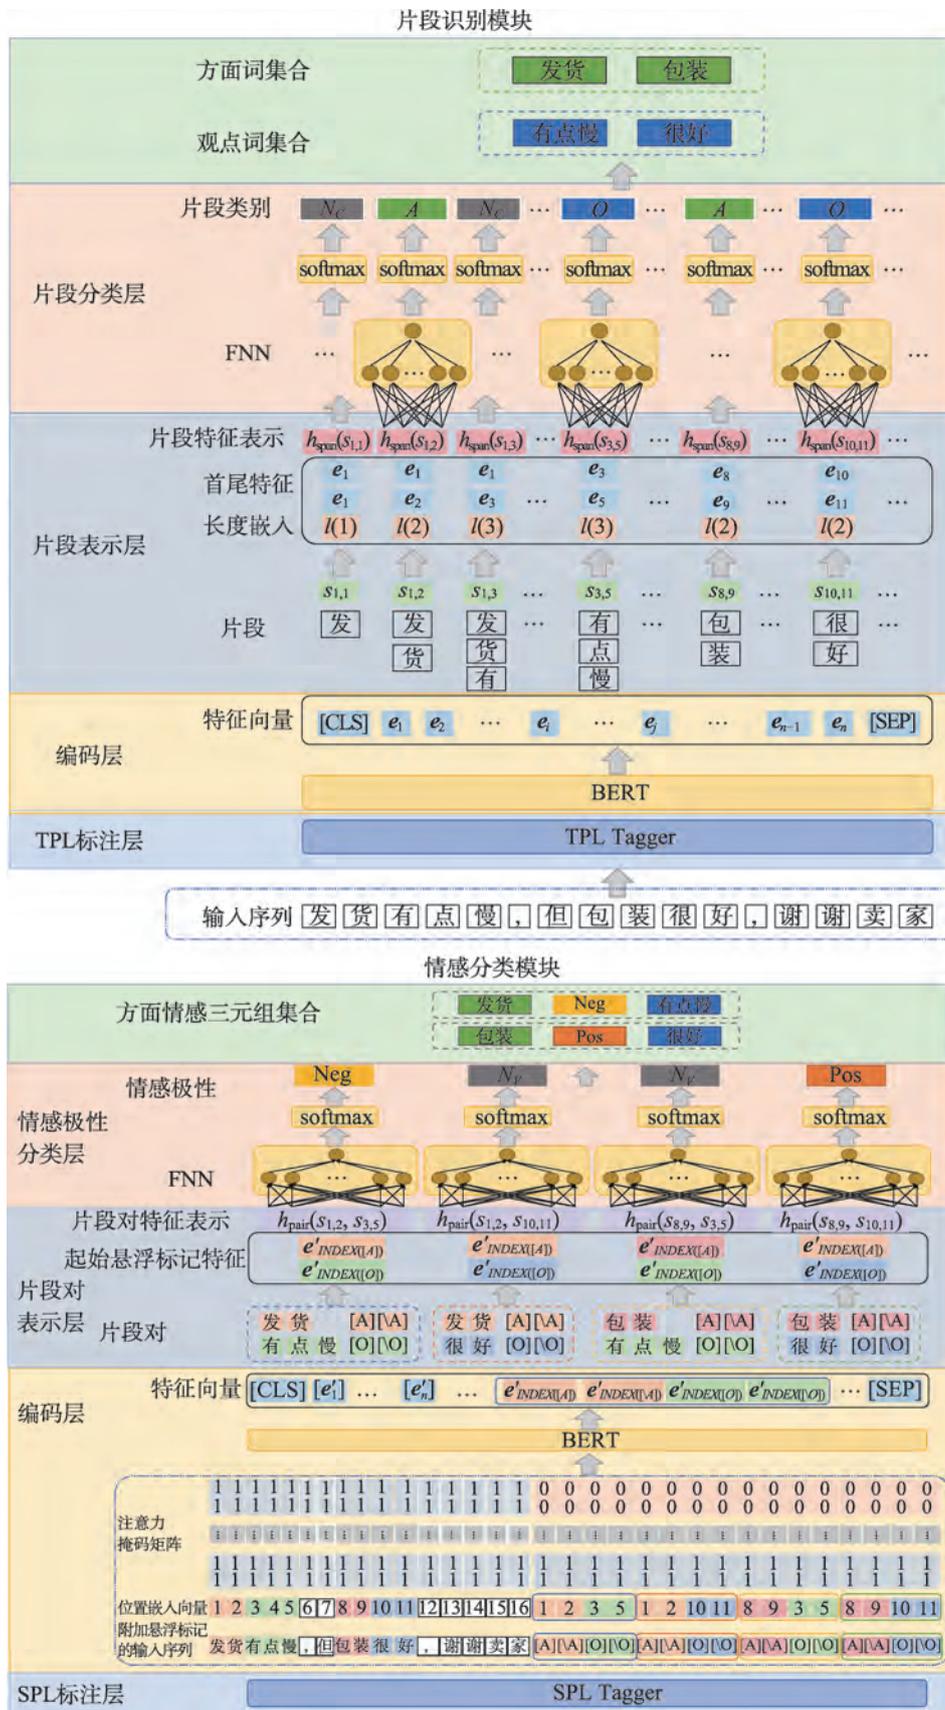


图1 SD-ASTE模型结构
Fig.1 Structure of SD-ASTE

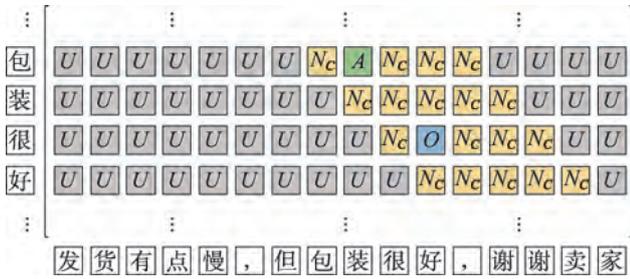


图2 TPL 标注方式

Fig.2 TPL tagging scheme

首尾特征表示和片段长度嵌入表示两部分构成。对于片段 $s_{i,j}$, 其首尾词元分别为 w_i 和 w_j , 那么在特征向量 E 中, 其首尾对应的特征表示分别为 e_i 和 e_j ; 其长度为 $j-i+1 \in [1, L]$, 对片段长度构造独热向量 $x=[x_1, x_2, \dots, x_L]$, 其中 $x_{j-i+1}=1$, 将 x 输入到一个全连接层, 得到长度 $j-i+1$ 的嵌入表示 $l(j-i+1)$:

$$l(j-i+1) = Wx + b \tag{1}$$

其中, W 和 b 是模型要学习的权重矩阵和偏置向量。

将片段首尾特征表示和长度嵌入表示拼接, 得到片段 $s_{i,j}$ 的特征表示 $h_{span}(s_{i,j})$, 具体如下:

$$h_{span}(s_{i,j}) = [e_i; e_j; l(j-i+1)] \tag{2}$$

2.2.4 片段分类层

对于片段表示层的输出 $h_{span}(s_{i,j})$, 将其输入到一个两层 FNN 中, 通过 softmax 函数归一化, 得到片段 $s_{i,j}$ 的类别 $c \in C$ 的概率分布:

$$P(c|s_{i,j}) = \text{softmax}(\text{FNN}(h_{span}(s_{i,j}))) \tag{3}$$

通过公式, 得到片段最优类别标签:

$$L_c(i,j) = \arg \max_{c \in C} P(c|s_{i,j}) \tag{4}$$

最终, 输出方面词集合 $S_A = \{s_{i,j} | L_c(i,j) = A\}$ 和观点词集合 $S_O = \{s_{i,j} | L_c(i,j) = O\}$ 。

模型训练过程中, 损失函数为交叉熵损失:

$$\mathcal{L}_1 = - \sum_{T_c(i,j) \neq U, 1 \leq i,j \leq n} \text{lb} P(T_c(i,j)|s_{i,j}) \tag{5}$$

其中, $T_c(i,j)$ 是片段 $s_{i,j}$ 的真实类别标注。

2.3 情感分类模块

基于片段识别模块的输出, 该模块首先通过 SPL (span pair linking) 方式, 标注所有片段对的情感极性, 构建片段之间的联系。其次, 在输入序列末尾插入悬浮标记^[17], 并针对附加悬浮标记的输入序列, 设计位置嵌入向量和注意力掩码矩阵, 通过 BERT 得到特征向量。然后, 基于悬浮标记对片段对进行特征表示。最后, 通过 FNN 学习片段对的特征信息, 分类片段对的情感极性, 得到所有方面情感三元组。

2.3.1 SPL 标注层

SPL 标注的标签集合为 $V = \{Pos, Neg, Neu, N_v\}$ 。设标注矩阵为 T_v 。将 $T_v(s_{i,j}, s_{p,q})$ 标注为片段对 $(s_{i,j}, s_{p,q})$ 的情感极性。图 3 为一个 SPL 标注的示例。

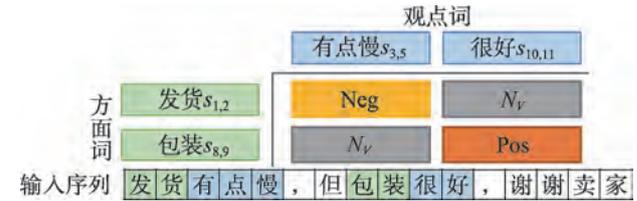


图3 SPL 标注方式

Fig.3 SPL tagging scheme

2.3.2 编码层

编码层在原始输入序列中插入悬浮标记, 通过 BERT, 对附加悬浮标记的输入序列进行编码。

第一步, 插入悬浮标记。对于输入序列 X 中所有可能的片段对, 在序列末尾插入悬浮标记 $[A]$ 和 $[\backslash A]$ 用于标记方面词, 插入悬浮标记 $[O]$ 和 $[\backslash O]$ 用于标记观点词, 得到附加悬浮标记的输入序列 $X' = [x_1', x_2', \dots, x_n', \dots, x_m']$ 。

第二步, 设计 BERT 输入中的位置嵌入向量。在附加悬浮标记的输入序列中, 同一片段的悬浮标记可能出现在多个不同的位置。以图 1 输入序列为例, 绿色 $[O]$ 均对应“有”, 但在 X' 中的位置索引不同。此外, 本文基于悬浮标记对片段对进行特征表示, 因此悬浮标记应该学习到其对应片段所在位置的上下文特征。因此, 需要把悬浮标记的位置嵌入与其对应片段的位置嵌入关联起来。对于片段 $s_{i,j} \in S_A$ 和 $s_{p,q} \in S_O$, 其悬浮标记的位置嵌入为:

$$\begin{cases} e_{INDEX([A:s_{i,j}])}^p = i, e_{INDEX([\backslash A:s_{i,j}])}^p = j \\ e_{INDEX([O:s_{p,q}])}^p = p, e_{INDEX([\backslash O:s_{p,q}])}^p = q \end{cases} \tag{6}$$

其中, $e_{INDEX(i)}$ 表示悬浮标记对应的位置嵌入, $[A:s_{i,j}]$ 和 $[\backslash A:s_{i,j}]$ 、 $[O:s_{p,q}]$ 和 $[\backslash O:s_{p,q}]$ 分别表示 $s_{i,j}$ 和 $s_{p,q}$ 的起始和终止悬浮标记。

第三步, 在 BERT 输入中设置注意力掩码矩阵。Transformer 通过自注意力机制计算序列中每个词元与所有词元的相互关系, 再利用这种关系调整词元的特征表示。而文本词元的含义与悬浮标记无关, 因此在编码过程中, 文本词元不需要考虑悬浮标记。本文通过设置注意力掩码矩阵来解决该问题。如果 w_i' 为文本词元, w_j' 为悬浮标记, 则令注意力掩码矩阵 M 的元素 $m_{ij} = 0$; 否则, 令 $m_{ij} = 1$ 。这样, 在

计算文本词元 w_i' 和其他词元的相互关系时, BERT 会对 w_j' 掩码, 从而不考虑 w_j' 对 w_i' 的影响。

第四步, 将上述位置嵌入向量、注意力掩码矩阵和 X' 输入 BERT, 得到 X' 特征向量 $E' = [e'_1, e'_2, \dots, e'_m]$ 。

2.3.3 片段对表示层

片段对表示层实现每组片段对的特征表示。对于片段对 $(s_{i,j}, s_{p,q})$, 其特征表示由两个片段的起始悬浮标记的特征表示拼接而成:

$$h_{\text{pair}}(s_{i,j}, s_{p,q}) = [e'_{\text{INDEX}([A:s_{i,j}])}; e'_{\text{INDEX}([O:s_{p,q}])}] \quad (7)$$

其中, $\text{INDEX}(\cdot)$ 表示悬浮标记在 X' 中的下标索引。

2.3.4 情感极性分类层

对于片段对表示层的输出 $h_{\text{pair}}(s_{i,j}, s_{p,q})$, 将其输入到两层 FNN 中。通过 softmax 函数归一化, 得到片段对 $(s_{i,j}, s_{p,q})$ 情感极性 $v \in V$ 的概率分布:

$$P(v|s_{i,j}, s_{p,q}) = \text{softmax}(\text{FNN}(h_{\text{pair}}(s_{i,j}, s_{p,q}))) \quad (8)$$

通过公式, 得到其最优情感极性标签:

$$L_V(s_{i,j}, s_{p,q}) = \arg \max_{v \in V} P(v|s_{i,j}, s_{p,q}) \quad (9)$$

最终, 得到方面情感三元组集合 $T = \{(s_{i,j}, L_V(s_{i,j}, s_{p,q}), s_{p,q}) | L_V(s_{i,j}, s_{p,q}) \neq N_V\}$ 。

模型训练过程中, 损失函数采用交叉熵损失:

$$\mathcal{L}_2 = - \sum_{s_{i,j} \in S_A, s_{p,q} \in S_O} \text{lb} P(T_V(s_{i,j}, s_{p,q}) | s_{i,j}, s_{p,q}) \quad (10)$$

其中, $T_V(s_{i,j}, s_{p,q})$ 是片段对 $(s_{i,j}, s_{p,q})$ 的真实情感极性标注。

3 实验设计及结果分析

3.1 实验数据集

本文在三个数据集上对模型进行了评估。数据集 1 (DS1) 来自《CCF-BDCI 2018 汽车行业用户观点主题及情感识别》, 是汽车论坛评论, 包含观点词、方面类别、情感极性三个字段。DS1 在原数据集的基础上标注了方面词^[18]。数据集 2 (DS2) 来自《之江杯电商评论观点挖掘大赛》, 包含观点词、方面词、情感极性三个字段, 是化妆品相关的商品评论。数据集 3 (DS3) 来自《基于主题的文本情感分析比赛》, 是电商评论, 包含观点词、方面词、情感极性三个字段, 其涉及的商品类别更加广泛。

过滤方面词或观点词为空的数据, 按 6:2:2 将其划分为训练集 (train)、验证集 (dev)、测试集 (test)。实验数据统计如表 1 所示。

3.2 实验设计

3.2.1 对比实验

该实验用于对比 SD-ASTE 模型和其他基线模型

表 1 实验数据统计

Table 1 Statistics of datasets

数据集	句子	三元组	正面	负面	中立	
DS1	train	960	1 134	524	487	123
	dev	322	366	152	180	34
	test	320	374	176	161	37
	总计	1 602	1 874	852	828	194
DS2	train	2 953	3 831	2 961	801	69
	dev	986	1 228	944	265	19
	test	984	1 302	1 012	265	25
	总计	4 923	6 361	4 917	1 331	113
DS3	train	11 092	16 976	9 556	6 502	918
	dev	3 699	5 651	3 178	2 165	308
	test	3 697	5 629	3 076	2 246	307
	总计	18 488	28 256	15 810	10 913	1 533

的效果。本文对比的模型包括以下方法:

PengTwoStage^[2]: 基于双向长短期记忆神经网络 (bi-directional long short-term memory, BiLSTM) 和图卷积网络 (graph convolutional networks, GCN) 的两阶段流水线模型。

BMRC^[12]: 通过三轮 MRC 任务, 分别实现方面词抽取、观点词抽取和情感极性判断。

BARTBSA^[14]: 基于 BART 完成序列生成任务, 再将其转换为方面情感三元组。

JET-BERT^[7]: 提出位置感知标注方式, 模型核心是条件随机场和半马尔科夫条件随机场。

GTS-BERT^[8]: 提出网格标注方式, 用于解决方面情感三元组重叠问题。

PASTE^[3]: 基于指针网络的解码思想, 考虑了方面词和观点词片段级别的信息。

Span-ASTE^[4]: 基于片段排列的思想, 并提出双通道片段修剪策略, 用于确定方面词和观点词。

3.2.2 有效性实验

该实验用于验证本文提出的片段特征表示、片段对特征表示和编码方式的有效性。表 2 示意了实验具体设计。

对于片段特征表示, 采用以下方式进行实验: 方式 1 将片段首尾特征和长度嵌入拼接, 即本文采用的方式; 方式 2 在方式 1 的基础上去除长度嵌入; 方式 3 从输入序列的特征向量中, 获取片段对应的特征向量, 对其进行最大池化; 方式 4 将方式 3 中的最大池化替换为平均池化。

对于片段对特征表示, 采用以下方式进行实验: 方式 1 将方面词和观点词对应的起始悬浮标记的特征表示拼接, 即本文采用的方式; 方式 2 参考 PASTE^[3]

表2 有效性实验设计

Table 2 Design of validity experiments

实验项目	对比方式	
片段 $s_{i,j}$ 特征表示	方式1	$[e_i; e_j; l(j-i+1)]$
	方式2	$[e_i; e_j]$
	方式3	$MaxPooling([e_i, e_{i+1}, \dots, e_j])$
	方式4	$MeanPooling([e_i, e_{i+1}, \dots, e_j])$
片段对 $(s_{i,j}, s_{p,q})$ 特征表示	方式1	$[e'_{INDEX([A_{s_{i,j}}])}; e'_{INDEX([O_{s_{p,q}}])}]$
	方式2	$[h_{span}(s_{i,j}); h_{span}(s_{p,q}); l(\min(p-j , q-i))]$
编码方式	方式1	两个独立编码器对两模块分别编码
	方式2	两模块共享编码,模型损失为两模块损失之和

和 Span-ASTE^[4]模型的方式,将片段特征表示和片段之间的距离嵌入拼接。

对于编码方式,端到端方法认为,在方面词和观点词识别子任务以及情感极性分类子任务中共享编码器,可以使两项子任务相互促进。而 SD-ASTE 模型通过两个独立编码器对两阶段分别编码。因此,本文在 SD-ASTE 模型的两个阶段中采用一个共享编码器,修改模型损失为两阶段损失之和,进行实验。

3.3 实验设置

对于 PengTwoStage,基于本文的数据集训练 300 维 GloVe^[19]向量,作为词嵌入模型。BARTABSAs 采用 bart-base-chinese^[20]作为预训练模型。其余模型均采用 bert-base-chinese^[16]作为预训练模型。

模型在单 Nvidia GeForce RTX-3090 Ti GPU 上训练。实验机器的操作系统为 Linux Ubuntu 20.04,内存为 32 GB,Python 版本为 3.8.0,深度学习框架为 PyTorch 1.10.2。表 3 示意了 SD-ASTE 模型的实验参数设置。

表3 实验参数设置

Table 3 Experimental parameter setting

参数名称	参数值	参数名称	参数值
批处理参数	32	失活率	0.2
最大句子长度	228	学习率	1.0×10^{-5}
最大片段长度	8	优化器	AdamW
最大迭代次数	50	长度嵌入维度	150

3.4 实验结果

本文采用精确率、召回率和 F1 值作为模型评估标准。实验重复三次,取结果的平均值。

3.4.1 对比实验

该实验对比了 SD-ASTE 模型和其他基线模型的效果,实验结果如表 4 所示。

结果表明,本文提出的 SD-ASTE 模型在三个数

表4 对比实验结果

Table 4 Results of comparative experiments 单位:%

数据集	模型	精确率	召回率	F1 值
DS1	PengTwoStage	45.74	63.89	53.31
	BMRC	60.05	66.97	63.32
	BARTABSAs	64.80	62.12	63.43
	JET-BERT	61.58	62.86	62.21
	GTS-BERT	60.62	67.46	63.86
	PASTE	63.76	69.95	66.71
	Span-ASTE	65.59	72.76	68.99
	SD-ASTE	68.21	75.94	71.87
	PengTwoStage	54.45	71.11	61.67
DS2	BMRC	76.31	73.46	74.86
	BARTABSAs	75.52	77.38	76.44
	JET-BERT	78.37	71.59	74.83
	GTS-BERT	75.08	73.84	74.45
	PASTE	81.15	80.47	80.81
	Span-ASTE	82.84	82.17	82.50
	SD-ASTE	85.37	84.12	84.74
	PengTwoStage	50.89	69.68	58.82
	BMRC	74.19	68.82	71.40
DS3	BARTABSAs	71.99	73.08	72.53
	JET-BERT	76.64	73.99	75.29
	GTS-BERT	75.94	74.16	75.04
	PASTE	76.20	72.71	74.41
	Span-ASTE	77.19	73.09	75.08
	SD-ASTE	78.21	76.14	77.16

据集上的效果都是最优的。

相较于流水线最优模型 PengTwoStage,SD-ASTE 模型在三个数据集上的 F1 值分别提高了 18.56 个百分点、23.07 个百分点、18.34 个百分点。这一显著提升是因为 SD-ASTE 采用 SPL 标注方式,避免了三元组重叠问题。同时,本文提出的基于悬浮标记的片段对特征表示方式,可以更好地学习三元组各元素之间的依赖关系,从而更准确地判断情感极性。

相较于端到端最优模型 Span-ASTE, SD-ASTE 模型在三个数据集上的 $F1$ 值分别提高了 2.88 个百分点、2.24 个百分点、2.08 个百分点。分析认为, SD-ASTE 模型在两模块采用独立编码器, 并针对两模块分别设计了特征表示方式, 可以更好地学习两模块

各自需要的特征。

3.4.2 有效性实验

该实验分别验证了片段特征表示方式、片段对特征表示方式和编码方式的有效性, 图 4(a)~(c) 示意了实验结果。

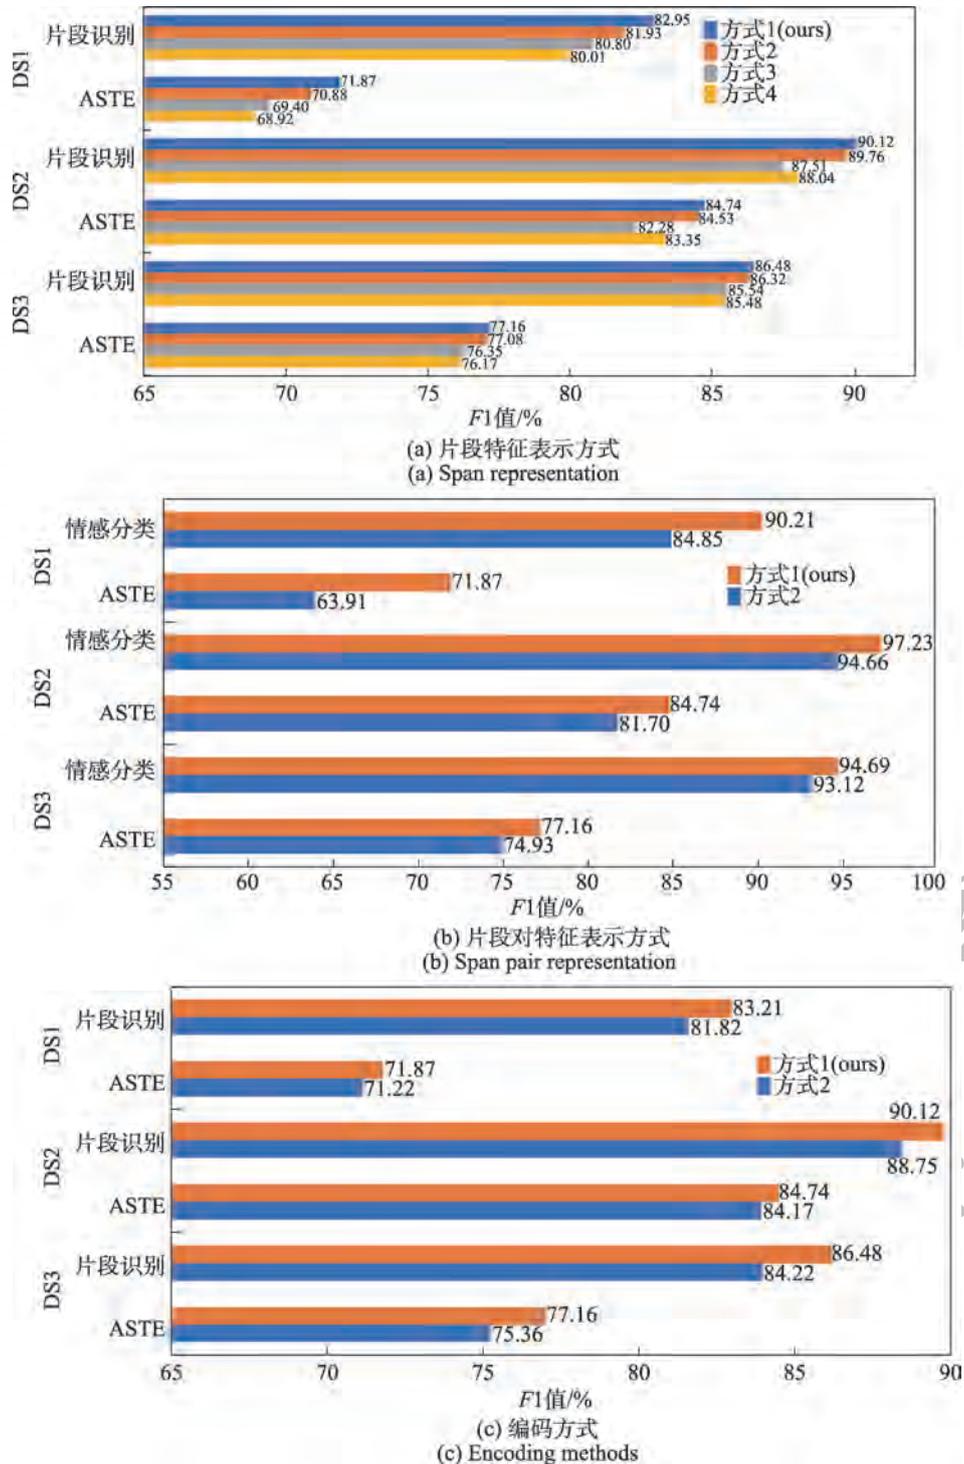


图4 有效性实验结果

Fig.4 Results of validity experiments

片段特征表示方式的实验结果表明,片段长度和首尾特征信息在片段识别过程中起到了重要作用,这两项信息可以帮助模型更好地确定片段边界。

片段对特征表示方式的实验结果表明,本文采用的方式对情感极性分类的效果有明显提升。这种特征表示方式可以针对不同片段对,更有效地学习方面词和观点词之间的依赖关系,从而提取更多有助于情感极性分类的特征信息。

编码方式的实验结果表明,共享编码不能帮助提高情感三元组抽取的结果,而采用两个独立的编码器可以更好地提取不同任务所需的特征,有效提升了模型整体的效果。

4 结束语

ASTE任务是细粒度的方面级情感分析任务,其目的是抽取句子中所有方面情感三元组。目前ASTE任务面临以下问题:流水线模型没有考虑观点词对判断情感极性的影响,且无法解决三元组重叠问题;而端到端模型采用共享编码器,存在特征混淆问题。

本文提出了片段级别的双编码器方面情感三元组抽取模型SD-ASTE。该模型分为片段识别和情感分类两模块,分别采用TPL和SPL标注方式,解决了三元组重叠问题。片段识别模块采用融入片段首尾和长度信息的片段特征表示方式,可以更好地确定方面词和观点词的边界。情感分类模块采用基于悬浮标记的片段对特征表示方式,可以更有效地针对不同片段对,学习三元组各元素之间的依赖关系。两模块各自通过一个独立编码器进行特征提取,避免了特征混淆问题。多个数据集上的对比实验验证了SD-ASTE相比其他主流模型具有更优效果,有效性实验验证了本文所采用的片段特征表示方式、片段对特征表示方式和编码方式的有效性。

目前,ASTE任务的数据集主要集中于商品评论这一场景,下一步工作将针对其他场景,探索基于迁移学习、半监督学习或无监督学习的方法。

参考文献:

- [1] ZHANG W, LI X, DENG Y, et al. A survey on aspect-based sentiment analysis: tasks, methods, and challenges[J]. arXiv: 2203.01054, 2022.
- [2] PENG H, XU L, BING L, et al. Knowing what, how and why: a near complete solution for aspect-based sentiment analysis[C]//Proceedings of the 34th AAAI Conference on Artificial Intelligence, the 32nd Innovative Applications of Artificial Intelligence Conference, the 10th AAAI Symposium on Educational Advances in Artificial Intelligence, New York, Feb 7-12, 2020. Menlo Park: AAAI, 2020: 8600-8607.
- [3] MUKHERJEE R, NAYAK T, BUTALA Y, et al. PASTE: a tagging-free decoding framework using pointer networks for aspect sentiment triplet extraction[C]//Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing, Punta Cana, Nov 7-11, 2021. Stroudsburg: ACL, 2021: 9279-9291.
- [4] XU L, CHIA Y K, BING L. Learning span-level interactions for aspect sentiment triplet extraction[C]//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics, Aug 1-6, 2021. Stroudsburg: ACL, 2021: 4755-4766.
- [5] WANG J, LU W. Two are better than one: joint entity and relation extraction with table- sequence encoders[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing, Nov 16-20, 2020. Stroudsburg: ACL, 2020: 1706-1721.
- [6] ZHANG Y, YANG Q. A survey on multi-task learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2021.
- [7] XU L, LI H, LU W, et al. Position-aware tagging for aspect sentiment triplet extraction[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing, Nov 16-20, 2020. Stroudsburg: ACL, 2020: 2339-2349.
- [8] WU Z, YING C, ZHAO F, et al. Grid tagging scheme for aspect-oriented fine-grained opinion extraction[C]//Findings of the Association for Computational Linguistics: EMNLP 2020, Nov 16-20, 2020. Stroudsburg: ACL, 2020: 2576-2585.
- [9] LUAN Y, WADDEN D, HE L, et al. A general framework for information extraction using dynamic span graphs[C]//Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics, Minneapolis, Jun 2-7, 2019. Stroudsburg: ACL, 2019: 3036-3046.
- [10] WADDEN D, WENBERG U, LUAN Y, et al. Entity, relation, and event extraction with contextualized span representations[C]//Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing, Hong Kong, China, Nov 3-7, 2019. Stroudsburg: ACL, 2019: 5784-5789.
- [11] CHEN Y, ZHANG Y, HU C, et al. Jointly extracting explicit and implicit relational triples with reasoning pattern enhanced binary pointer network[C]//Proceedings of the 2021

- Conference of the North American Chapter of the Association for Computational Linguistics, Jun 6-11, 2021. Stroudsburg: ACL, 2021: 5694-5703.
- [12] CHEN S, WANG Y, LIU J, et al. Bidirectional machine reading comprehension for aspect sentiment triplet extraction[C]//Proceedings of the 35th AAAI Conference on Artificial Intelligence, the 33rd Conference on Innovative Applications of Artificial Intelligence, the 11th Symposium on Educational Advances in Artificial Intelligence, Feb 2-9, 2021. Menlo Park: AAAI, 2021: 12666-12674.
- [13] MAO Y, SHEN Y, YU C, et al. A joint training Dual-MRC framework for aspect based sentiment analysis[C]//Proceedings of the 35th AAAI Conference on Artificial Intelligence, the 33rd Conference on Innovative Applications of Artificial Intelligence, the 11th Symposium on Educational Advances in Artificial Intelligence, Feb 2-9, 2021. Menlo Park: AAAI, 2021: 13543-13551.
- [14] YAN H, DAI J, JI T, et al. A unified generative framework for aspect-based sentiment analysis[C]//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics, Aug 1-6, 2021. Stroudsburg: ACL, 2021: 2416-2429.
- [15] LU Y, LIU Q, DAI D, et al. Unified structure generation for universal information extraction[C]//Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics, Dublin, May 22-27, 2022. Stroudsburg: ACL, 2022: 5755-5772.
- [16] 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, Minneapolis, Jun 2-7, 2019. Stroudsburg: ACL, 2019: 4171-4186.
- [17] ZHONG Z, CHEN D. A frustratingly easy approach for entity and relation extraction[C]//Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics, Jun 6-11, 2021. Stroudsburg: ACL, 2021: 50-61.
- [18] 姚婉薇. 基于 Target-Aspect-Opinion 联合抽取的汽车评论情感分析[D]. 上海: 华东师范大学, 2020.
YAO W W. Joint extraction of Target-Aspect-Opinion based sentiment analysis with automobile review data[D]. Shanghai: East China Normal University, 2020.
- [19] 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, Doha, Oct 25-29, 2014. Stroudsburg: ACL, 2014: 1532-1543.
- [20] SHAO Y, GENG Z, LIU Y, et al. CPT: a pre-trained unbalanced transformer for both Chinese language understanding and generation[J]. arXiv:2109.05729, 2021.



张韵琪(2000—),女,上海人,硕士研究生,主要研究方向为自然语言处理、情感分析等。

ZHANG Yunqi, born in 2000, M.S. candidate. Her research interests include natural language processing, sentiment analysis, etc.



李松达(2000—),女,黑龙江大庆人,硕士研究生,主要研究方向为自然语言处理、情感分析等。

LI Songda, born in 2000, M.S. candidate. Her research interests include natural language processing, sentiment analysis, etc.



兰于权(1999—),男,四川遂宁人,硕士研究生,主要研究方向为自然语言处理、关系抽取等。

LAN Yuquan, born in 1999, M.S. candidate. His research interests include natural language processing, relation extraction, etc.



李东旭(1999—),男,山东东营人,硕士研究生,主要研究方向为数据增强、小样本学习等。

LI Dongxu, born in 1999, M.S. candidate. His research interests include data augmentation, few-shot learning, etc.



赵慧(1968—),女,陕西西安人,博士,教授,主要研究方向为数据管理与分析、信息抽取、知识图谱等。

ZHAO Hui, born in 1968, Ph.D., professor. Her research interests include data management and analysis, information extraction, knowledge graph, etc.