

深度融合句法和语义特征的情感三元组片段级抽取方法

常轩伟, 段利国, 陈嘉昊, 崔娟娟, 李爱萍

引用本文

常轩伟, 段利国, 陈嘉昊, 崔娟娟, 李爱萍. 深度融合句法和语义特征的情感三元组片段级抽取方法[J]. 计算机科学, 2026, 53(2): 322-330.

CHANG Xuanwei, DUAN Ligu, CHEN Jiahao, CUI Juanjuan, LI Aiping. [Method for Span-level Sentiment Triplet Extraction by Deeply Integrating Syntactic and Semantic Features](#) [J]. Computer Science, 2026, 53(2): 322-330.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于多模态体育教育数据的图空间融合动作识别方法](#)

Multimodal Physical Education Data Fusion via Graph Alignment for Action Recognition
计算机科学, 2026, 53(2): 89-98. <https://doi.org/10.11896/jsjcx.250800007>

[ZHA_TGCN:面向低资源壮文的主题分类方法](#)

ZHA_TGCN:A Topic Classification Method for Low-resource Sawcuengh Language
计算机科学, 2025, 52(11A): 250100059-8. <https://doi.org/10.11896/jsjcx.250100059>

[基于多语言嵌入图卷积网络的仇恨言论检测方法](#)

Multi-language Embedding Graph Convolutional Network for Hate Speech Detection
计算机科学, 2025, 52(11A): 241200023-8. <https://doi.org/10.11896/jsjcx.241200023>

[基于自注意力机制的图对比学习推荐算法](#)

Self-attention-based Graph Contrastive Learning for Recommendation
计算机科学, 2025, 52(11): 82-89. <https://doi.org/10.11896/jsjcx.240900134>

[基于大批次对抗策略和强化特征提取的文本情感分类方法](#)

Text Sentiment Classification Method Based on Large-batch Adversarial Strategy and Enhanced Feature Extraction
计算机科学, 2025, 52(10): 247-257. <https://doi.org/10.11896/jsjcx.240800061>

深度融合句法和语义特征的情感三元组片段级抽取方法

常轩伟¹ 段利国^{1,2} 陈嘉昊¹ 崔娟娟¹ 李爱萍¹

1 太原理工大学计算机科学与技术学院(大数据学院) 山西 晋中 030600

2 山西电子科技学院 山西 临汾 041000

(3137400769@qq.com)

摘要 方面情感三元组抽取旨在以三元组的形式抽取句子中包含的方面词及其对应的观点词和情感极性。现有的抽取模型存在未能充分挖掘句子中包含的句法和语义信息、多词实体边界识别错误等问题。对此,提出了一种深度融合句法信息和语义信息的片段抽取模型(Span Extractor Incorporating Semantic and Syntax Features,SESS)。SESS通过结合自注意力机制和多通道图卷积网络,深度挖掘句法与语义特征之间的关联,提升了模型对复杂句式和多词实体的处理能力。同时,模型采用基于片段的抽取方法抽取方面词和观点词,捕捉长实体的整体语义,减少情感不一致性的问题。在标准数据集 ASTE-Data-V2上进行的实验表明,SESS在F1值上优于绝大多数对比模型,尤其在复杂语句和多对一、一对多情感关系的处理上表现出色。此外,消融实验和案例分析验证了模型各个模块的有效性及其对任务性能的贡献,进一步证明了所提方法的先进性和鲁棒性。

关键词: 方面情感三元组抽取;图卷积网络;自注意力机制;依存句法关系

中图分类号 TP391

Method for Span-level Sentiment Triplet Extraction by Deeply Integrating Syntactic and Semantic Features

CHANG Xuanwei¹, DUAN Ligu^{1,2}, CHEN Jiahao¹, CUI Juanjuan¹ and LI Aiping¹

1 College of Computer Science and Technology(College of Data Science), Taiyuan University of Technology, Jinzhong, Shanxi 030600, China

2 Shanxi University of Electronic Science and Technology, Linfen, Shanxi 041000, China

Abstract Aspect sentiment triple extraction aims to extract aspects and their corresponding opinion words and sentiment polarities in the form of triples from sentences. Existing extraction models suffer from issues such as insufficient exploitation of syntactic and semantic information in sentences and incorrect identification of multi-word entity boundaries. To address these issues, this paper proposes a span extraction model that deeply integrates syntactic and semantic features(Span Extractor Incorporating Semantic and Syntax Features,SESS). SESS combines self-attention mechanisms with multi-channel graph convolutional networks to deeply explore the associations between syntactic and semantic features, enhancing the model's ability to handle complex sentence structures and multi-word entities. Additionally, the model employs a span-based extraction method to extract aspect and opinion words, capturing the overall semantics of long entities and reducing sentiment inconsistency issues. The experiments conducted on the standard dataset ASTE-Data-V2 demonstrate that SESS outperforms the vast majority of comparison models in terms of F1 score, particularly in processing complex sentences and one-to-many, many-to-one sentiment relationships. Furthermore, ablation experiments and case analysis validate the effectiveness of each module of the model and its contribution to task performance, further proving the advancement and robustness of the proposed method.

Keywords Aspect sentiment triplet extraction, Graph convolutional network, Self-attention mechanism, Dependency syntactic relationship

1 引言

情感分析(Sentiment Analysis)是自然语言处理领域中的一个重要研究方向,旨在从自然语言文本中识别和理解人们对不同对象或事件所表达的情感倾向、态度和评价,在商业

决策、舆情分析监控和社会管理等方面都具有重要价值。根据目标粒度范围的不同,情感分析任务可以分为文档级、语句级和方面级3类^[1]。方面级情感分析(Aspect-Based Sentiment Analysis, ABSA)是一项细粒度情感分析任务,能够对文本中的目标对象进行建模,从而挖掘更加细致的情感信息,

到稿日期:2025-01-09 返修日期:2025-04-29

基金项目:山西省自然科学基金(202203021221234, 202303021211052)

This work was supported by the Natural Science Foundation of Shanxi Province, China(202203021221234, 202303021211052).

通信作者:段利国(463035793@qq.com)

是当下研究的热点方向。然而传统的 ABSA 任务通常只聚焦于方面词与情感极性的关联上,难以全面揭示情感表达的细节。

在此背景下,方面情感三元组抽取(Asspect Sentiment Triplet Extraction,ASTE)任务被提出,它是 ABSA 的一个扩展且更加综合的子任务。ASTE 任务旨在从文本中同时识别 3 种关键要素,即方面词(Asspect Term)、观点词(Opinion Term)以及情感极性(Sentiment Polarity)。方面词是文本中被评论的对象或实体,观点词是表达用户态度的词汇,而情感极性则标明用户的具体情感倾向(通常为积极、消极或中立)。例如在句子“The price is reasonable although the service is poor”中:方面词“price”与观点词“reasonable”相关联,情感极性为积极;方面词“service”与观点词“poor”相关联,情感极性为消极。相比传统的 ABSA 任务,ASTE 任务引入观点词(证据),不仅可以细化情感极性的判定,还能揭示情感形成的具体原因,为情感分析提供了更加全面的视角。

目前,以端到端的方式完成 ASTE 任务的方法主要分为基于表格标注的方法、基于文本片段的方法,以及基于文本生成和阅读理解的方法。其中,基于表格标注的方法对每个词对之间的关系进行标注,并根据对应的迭代策略生成三元组。但在处理多词实体时,容易出现情感不一致性问题。例如,在处理如图 1 所示的句子时,多词实体“traditional Italian items”需要被拆分为多个词汇并逐词判断其与观点词之间的情感极性,导致情感判断的不一致性。



图 1 方面情感三元组提取实例

Fig. 1 Example of aspect sentiment triplet extraction

基于文本生成与阅读理解的方法则需要设计模板以生成相应问题和答案。显然,这在提高灵活性的同时,也增加了任务的复杂性。相比之下,基于文本片段的方法能够结合长实体的整体语义,达到较为理想的抽取精度。但当前的片段级抽取模型在复杂句子中仍存在局限性。常规方法未能充分挖掘句法和语义信息的深层含义,导致多词实体“traditional Italian items”的边界识别出现错误。

为了克服多词实体边界模糊问题并降低方面词与观点词之间复杂关系对 ASTE 任务造成的影响,本文提出了一种名为 SESS(Span Extractor Incorporating Semantic and Syntax Features)的情感三元组抽取模型。SESS 以 SpanBert^[2] 为主干特征提取器,利用交互注意力机制将双通道图卷积网络挖掘到的深层次语法和语义信息充分融合。此外,SESS 采用了一种低时间复杂度的词性片段生成策略,减少了无关片段造成的噪声干扰。

本文的贡献如下:

- 1)设计了一种结合语义和句法信息的双通道图卷积网络模型,该模型能够充分挖掘句子中包含的句法依赖关系和语义特征;
- 2)针对下游基于片段的抽取方法,使用预训练模型 SpanBert 对句子进行编码,同时引入基于词性的片段生成策略对搜索空间进行剪裁,生成富含更多语义信息的片段集合;
- 3)在 ASTE 任务的 4 个标准数据集上进行了充分的对比和消融实验,结果表明,SESS 模型显著优于现有方法,证明了所设计模块的有效性。

2 相关工作

方面情感三元组抽取任务旨在以三元组的形式抽取句子中包含的方面词、对应的观点词及情感极性,是方面级情感分析中较为复杂且完整的子任务。该任务的挑战在于,如何准确地处理多词实体以及捕捉其间复杂的关系。

Peng 等^[3]首次提出 ASTE 任务,并采用流水线的方式将其拆分为提取和匹配两个阶段。他们首先将情感标签加入到 BIOES 标签中,提取出方面-情感对和观点词,然后将两者进行配对。然而,这种抽取方式忽略了观点词对情感极性的影响,并导致误差从第一阶段累积至第二阶段。为了避免误差传播,研究者开始采用端到端的模型。Xu 等^[4]提出了一种基于位置感知的标注方式,通过在 BIOES 标注中加入关键词的位置信息,加强三元组元素间的信息交互。Wu 等^[5]提出的 GTS 模型将三元组抽取任务转换为表格标记任务,采用标签集对任意两个词对进行标注,实现一步提取三元组。

在较为复杂的句子中,多词实体的情感一致性问题一直都是序列标注和表格标注方法的难点。Xu 等^[6]提出了 Span-ASTE 模型,通过双通道片段剪裁策略生成方面词和观点词,并基于片段预测情感极性。Zhang 等^[7]提出的表格填充模型(BDTF)则是利用关系区域的检测和分类的思路,将三元组抽取转换为二维表边界识别任务。尽管 BDTF 模型在情感一致性方面有所改进,但它极大地增加了时间复杂度和空间复杂度,导致性能衰减。Chen 等^[8-9]提出了基于片段的联合训练框架以及片段级别的双向网络模型(SBN),利用 Transformer^[10] 技术将语义关系添加到特征提取部分,并引入 KL 散度损失和推理策略用于进一步优化性能。

近年来,基于文本生成和阅读理解的方法也被用于解决 ASTE 任务。例如:Mao 等^[11]将三元组抽取任务转换为多轮问答和理解任务;Chen 等^[12]提出的双向阅读理解模型将方面词和观点词进行交互式抽取;Mukherjee 等^[13]提出了一种基于指针网络的无标记解码框架,将方面词和观点词之间的语义关联性融入端到端的编解码架构中;Zhang 等^[14]将方面级情感分析任务转换为文本生成问题;Yan 等^[15]将三元组抽取任务转换为序列索引生成任务。此类方法通过生成自然语言的方式处理方面词与观点词的配对及情感极性预测任务。

知识增强和语法信息的利用亦是近年来的重要研究方向。Li 等^[16]提出了 SSJE 模型,利用图卷积网络^[17]学习句法依存信息。Chen 等^[18]通过设计多通道图卷积网络来高效整

合语法特征以提升模型效果。Shi 等^[19]通过迭代交互方式融合句法以及上下文特征,增强模型抽取能力。Li 等^[20]在双通道图卷积网络中融入情感词典知识。Li 等^[21]设计了一种词性片段过滤策略。而 Li 等^[22]将句法依赖关系和词性特征生成候选片段的方式融合,以强化文本表征能力以及文本片段之间的信息交互。Zhang 等^[23]利用适配器方法将结构偏置整合到预训练语言模型中,以提高模型的推理能力。Peng 等^[24]将关系表转换为图来探索更全面的关系信息,利用提示注意力分数计算模块来确定边的权重,并构建目标感知的网格图以增强三元组抽取过程。

与此同时,研究者还探索了多种 ASTE 框架与技术。Jiang 等^[25]设计了语义增强的双编码器框架,通过结合 Bert^[26]编码器与包含 BiLSTM 和图卷积网络的特定编码器,分别捕获表层语义与深层语义特征。Dai 等^[27]提出了双重嵌入机制和双向情感依赖检测器,通过将字符和词向量嵌入结合双向长短期记忆网络(BiLSTM)实现对不同粒度语义特征的捕获。Sun 等^[28]将 SenticNet 和抽象意义表示(AMR)驱动的门控注意力语义融合,提出一种能够增强语义理解以及词对表示能力的框架。Wang 等^[29]提出基于知识补全的双表填充方法,通过构建两个互补表来捕获不同粒度的知识,以解决单表方法的知识损失与冲突问题,并引入句法增强编码器(SEE)学习句子结构与词间依赖关系。Liu 等^[30]提出了基于外部知识和字词双通道的短文本语义匹配策略,其中的双通道思想给予了本文一定的启发。

尽管现有研究取得了显著的进展,但 ASTE 任务仍面临

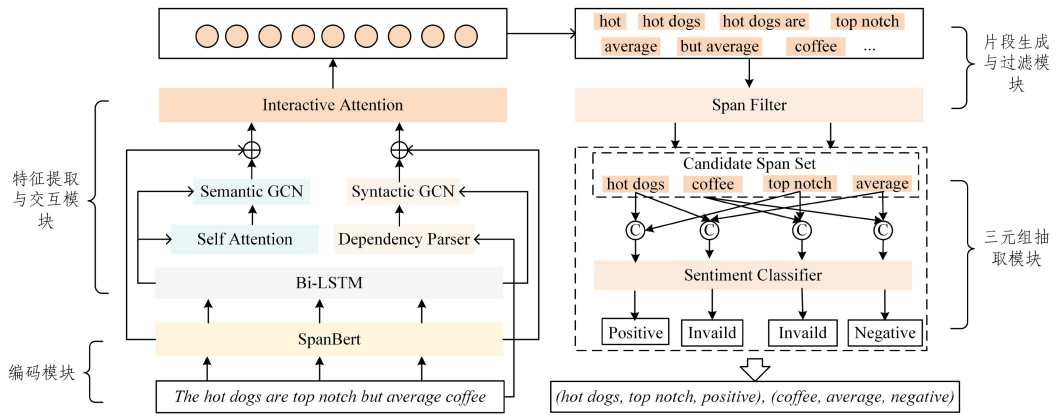


图2 本文模型结构图

Fig. 2 Structure diagram of the proposed model

3.1 编码模块

目前,大多数模型采用预训练模型 Bert 对句子的上下文信息进行编码。然而,Bert 是对输入序列中单个词或其子词进行随机掩码训练。这种训练方式在处理语义上紧密相关的多个词时,可能会造成语义割裂问题,进而无法充分捕捉片段级别的语义信息。与 Bert 的词级掩码策略不同,SpanBert 在训练时对一定长度的文本片段(Span)而非单个词添加掩码,并通过分词边界表示预测被掩码的片段内容。这种训练方式能够使模型更有效地学习和表示文本片段的整体语义特征,从而在片段级别任务上表现出更好的效果。

因此,本文的编码层采用预训练模型 SpanBert 作为基础编码器,对输入句子进行编码以更好地保持上下游任务之间

许多挑战。尤其是处理复杂句子时,仍存在方面词和观点词边界模糊或匹配错误等问题。因此,本文提出了一种基于双通道图卷积网络的模型结构来挖掘深层次文本信息,以提高模型在复杂句式中文本三元组抽取的准确率。

3 SESS 模型

本文 SESS 模型整体框架如图 2 所示,其中,⊕代表求和操作,⊙符号代表候选方面词和观点词片段特征及其局部上下文特征的拼接操作。模型主要分为四大模块:编码模块、特征提取与交互模块、片段生成与过滤模块、三元组抽取模块。编码模块负责对输入句子进行基础特征提取,生成初步的语义表示,为后续处理提供基础支持。特征提取与交互模块通过双通道图卷积网络结构分别深度挖掘语义信息和语法信息,并通过融合机制进一步增强文本的表征能力,从而捕获更加全面的上下文和结构化特征。片段生成与过滤模块利用词性信息对生成方式进行优化,高效划分并筛选出所有可能的方面词和观点词集合。三元组抽取模块则通过分类网络对可能的方面词-观点词组合进行判定,同时确定其对应的情感极性,最终生成准确的三元组。

为了便于后文的描述,将 ASTE 任务形式化定义为:给定包含 n 个单词的句子 $S = \{\omega_1, \omega_2, \dots, \omega_n\}$,ASTE 任务旨在抽取句子 S 中包含的所有情感三元组构成的集合 $T = \{t_1, t_2, \dots, t_m\}$ 。其中,每个三元组 $t_i = (A_i, O_i, P_i)$ 由方面词 A_i 、观点词 O_i 和情感极性 P_i 组成。此外, $|T|$ 表示句子中包含三元组的数量。

的语义一致性。具体而言,对于输入句子 S ,在其开头和结尾分别增加起始标识符[CLS]以及结束标识符[SEP],经过分词器 Tokenizer 处理后得到编码层的输入序列 S_x :

$$S_x = \text{Tokenizer}(S) = \{x_{cls}, x_1, \dots, x_i, \dots, x_m, x_{sep}\} \quad (1)$$

将 S_x 输入 SpanBert 中进行编码,获得其在上下文中 D 维的嵌入表示 H_x :

$$H_x = \text{SpanBert}(S_x) \quad (2)$$

通过该编码过程,模型能够有效捕获丰富的上下文语义信息,同时避免上下游任务训练方式不一致而导致的多词实体语义割裂问题。

3.2 特征提取与交互模块

编码层的 SpanBert 主要基于自注意力机制,适合捕获全

局依赖关系,但其在局部连续性建模上存在不足。对此,SESS模型引入了双向长短期记忆网络(Bidirectional Long Short Term Memory Network, Bi-LSTM)对 \mathbf{H}_s 进行进一步的特征提取,从而获得增强局部特征的表示 \mathbf{H}_b :

$$\mathbf{H}_b = \text{Bi-LSTM}(\mathbf{H}_s) \quad (3)$$

其中, Bi-LSTM由两个结构相同但方向相反的多层LSTM组成,每个LSTM的输出维度为 $D/2$ 。

对于大多数自然语言处理任务而言, \mathbf{H}_b 的文本嵌入表示已经能够满足要求。然而,在ASTE任务中,由于多词实体边界的不确定性以及方面词和观点词之间尤为复杂的联系,仅靠 \mathbf{H}_b 不足以有效表征这些特征。为了更深入地挖掘上下文中的语义信息,本文引入了句法特征挖掘模块和语义特征提取模块,并通过交互融合模块对两者进行有效整合,从而获得更深层次的文本特征。

3.2.1 句法特征挖掘模块

在句法特征挖掘模块中,输入句子 S 首先通过句法解析工具CoreNLP^[31]进行句法分析生成句法依存树(Dependency Tree, DT)。在依存树中,每个节点对应句子中的一个词,而每条边表示词与词之间的依存关系。为了进一步融合句法知识,将句法依存树转换为一张无向图,并为每个节点添加自环。其中,图的节点特征表示为 \mathbf{H}_b ,邻接矩阵中 \mathbf{D}_{ij} 的计算方式如下:

$$\mathbf{D}_{ij} = \begin{cases} 1, & \text{若 } w_i \text{ 和 } w_j \text{ 存在依存关系} \\ 0, & \text{若 } w_i \text{ 和 } w_j \text{ 不存在依存关系} \end{cases} \quad (4)$$

随后,将邻接矩阵 \mathbf{D} 和 \mathbf{H}_b 作为句法图卷积网络(Syn-GCN)的输入,生成句法增强的隐藏状态表示 \mathbf{H}_{syn} 。第 i 个节点在第 l 层句法图卷积网络的隐藏状态计算方式如下:

$$\mathbf{H}_{\text{syn}}^l(i) = \text{ReLU}\left(\sum_{j=1}^N \mathbf{D}_{ij} \mathbf{W}_{\text{syn}}^l \mathbf{H}_{\text{syn}}^{l-1}(j) + \mathbf{b}_{\text{syn}}^l\right) \quad (5)$$

其中, $\mathbf{W}_{\text{syn}}^l$ 和 $\mathbf{b}_{\text{syn}}^l$ 为句法特征挖掘模块第 l 层句法图卷积网络的权重矩阵和偏置项。当 $l=1$ 时, $\mathbf{H}_{\text{syn}}^0(j) = \mathbf{H}_b(j)$ 。

\mathbf{H}_{syn} 的重点是深层次句法特征的表示,经过非线性变换后可能会损失部分浅层次上下文信息。为了确保句法特征挖掘模块能够全面表征句子的句法信息,模块的输出增加了对原始上下文浅层编码 \mathbf{H}_s 的保留,最终得到融合深层句法信息和浅层编码特征的表示 \mathbf{H}'_{syn} ,定义如下:

$$\mathbf{H}'_{\text{syn}} = \mathbf{H}_s + \mathbf{H}_{\text{syn}} \quad (6)$$

此外,若直接使用 \mathbf{H}_{syn} 而不增加 \mathbf{H}_s 的浅层特征,可能会导致模型在联合训练时优化困难。深层次的图卷积网络使模型整体参数更加复杂,在反向传播过程中可能出现梯度爆炸或梯度消失问题。引入残差学习的方式,能够有效解决深层模型的退化问题,同时缓解梯度消失带来的优化难题,从而提升模型的稳定性和训练效率。

3.2.2 语义特征提取模块

当句子结构较为复杂时,依存句法树可能会因解析精度不足而产生误差,仅依靠句法信息难以充分表征多词关联下的深层语义特征。对此,本文提出语义特征提取模块,其核心目标是通过多源语义信息的融合,弥补依存句法分析潜在的不足,生成适应复杂任务需求的深层语义特征表示。

语义特征提取模块基于自注意力机制来计算节点间的关联度矩阵 \mathbf{A} :

$$\mathbf{A} = \text{softmax}\left(\frac{\mathbf{W}_Q \mathbf{H}_b \times (\mathbf{W}_K \mathbf{H}_b)^T}{\sqrt{d}}\right) \quad (7)$$

其中, \mathbf{W}_Q 和 \mathbf{W}_K 为可学习的变换权重矩阵, d 为节点特征维度, $\mathbf{A} \in \mathbf{R}^{n \times n}$, \mathbf{A}_{ij} 表示第 i 个节点和第 j 个节点之间的关联度。

基于矩阵 \mathbf{A} 和特征表示 \mathbf{H}_b ,模块进一步通过语义图卷积网络(SemGCN)来提取深层次语义特征:

$$\mathbf{H}'_{\text{sem}}(i) = \text{ReLU}\left(\sum_{j=1}^N \mathbf{A}_{ij} \mathbf{W}_{\text{sem}}^l \mathbf{H}'_{\text{sem}}(j) + \mathbf{b}'_{\text{sem}}\right) \quad (8)$$

其中, $\mathbf{W}_{\text{sem}}^l$ 和 \mathbf{b}'_{sem} 为第 l 层语义图卷积网络的权重矩阵和偏置项。当 $l=1$ 时, $\mathbf{H}'_{\text{sem}}(j) = \mathbf{H}_b(j)$ 。类似地,为确保浅层次语义特征的完整性以及提升训练的收敛效率,语义特征提取模块采用残差连接的形式,将浅层语义特征与深层语义特征融合,生成最终的语义特征表示 \mathbf{H}'_{sem} ,进一步提升模型对复杂文本的适应性和鲁棒性。

$$\mathbf{H}'_{\text{sem}} = \mathbf{H}_s + \mathbf{H}_{\text{sem}} \quad (9)$$

3.2.3 交互融合模块

为了有效传递和交互句法信息和语义信息之间的相关特征,在Shi等^[19]的启发下,SESS模型引入了一种交互注意力机制,用于融合两个通道的信息。对于句法特征 \mathbf{H}'_{syn} 和语义特征 \mathbf{H}'_{sem} ,分别使用式(10)和式(11)计算得到各自的注意力矩阵:

$$\text{Att}(\mathbf{H}'_{\text{syn}}) = \text{softmax}(\mathbf{H}'_{\text{syn}} (\mathbf{H}'_{\text{syn}})^T) \quad (10)$$

$$\text{Att}(\mathbf{H}'_{\text{sem}}) = \text{softmax}(\mathbf{H}'_{\text{sem}} (\mathbf{H}'_{\text{sem}})^T) \quad (11)$$

其中, $\text{Att}(\mathbf{H}'_{\text{syn}})$ 反映了每个词对在句法关系上的相关性, $\text{Att}(\mathbf{H}'_{\text{sem}})$ 反映了每个词对在深层次语义关系上的相似性。得到注意力矩阵后,将其交错地对应到通道特征上,以调整每个通道的信息权重并实现信息交互。同时,为了增强原始特征信息的传递性,在融合过程中引入自环机制。最终,融合后的多通道文本表征 \mathbf{H} 的计算方法如下:

$$\mathbf{H}_{\text{Syn2Sem}} = \text{Att}(\mathbf{H}'_{\text{syn}}) \mathbf{H}'_{\text{sem}} + \mathbf{H}'_{\text{sem}} \quad (12)$$

$$\mathbf{H}_{\text{Sem2Syn}} = \text{Att}(\mathbf{H}'_{\text{sem}}) \mathbf{H}'_{\text{syn}} + \mathbf{H}'_{\text{syn}} \quad (13)$$

$$\mathbf{H} = \mathbf{H}_{\text{Syn2Sem}} + \mathbf{H}_{\text{Sem2Syn}} \quad (14)$$

\mathbf{H} 既保留了句法信息和语义信息的独立性,又实现了不同层次特征的协同建模。

3.3 片段生成与过滤模块

对于输入句子 S ,可以枚举所有可能的片段来生成候选方面词和观点词。然而,这种做法的时间复杂度是 $O(n^2)$,而且大量的无效片段会显著影响系统的效率和性能。

Li等^[22]的研究指出,在ASTE任务中,方面词通常为名词或名词短语,观点词多为形容词或形容词短语。但其忽略了动词以及副词与其他词组合作为观点词的情况。例如,在句子“The audience highly recognizes my performance”中,“performance”是方面词,而“highly”(副词)和“recognizes”(动词)共同构成了观点词,表达了积极的情感极性。受此启发,SESS模型结合句法分析中的词性信息,通过剪枝操作来减少无效片段的生成。

SESS模型在生成片段时仅筛选目标词性词汇(名词、动词、形容词、副词),并以其为中心生成满足条件的子序列。具体来说,给定最大窗口长度 L ,定位句子中的目标词性词汇 W_k ,并以 W_k 为中心向左向右分别扩展窗口,生成包含 W_k 的所有可能子序列。其中,向左扩展最多包含 W_k 前 L 个词,向右

扩展最多包含 W_k 后 L 个词。通过组合不同的窗口长度,最终生成所有满足条件的子序列。剪枝操作使得片段生成的时间复杂度从 $O(n^2)$ 降低到 $O(mL^2)$, m 为目标词性词汇数量,通常为 n 的40%~80%,而 L 为一个远小于句子长度 n 的值。这种优化方法能够最大程度生成正确片段,同时也能通过词性知识在一定程度上进行剪枝,提高效率。

对于文本片段 $Span_i = \{x_{start(i)}, \dots, x_{end(i)}\}$,长度 $len_i = end(i) - start(i) + 1$,选取对应特征 $\{H_{start(i)}, \dots, H_{end(i)}\}$,通过最大池化对这些特征进行归一化,以突出片段中的关键信息。然而,最大池化操作会导致文本片段长度信息丢失,为弥补这一缺陷,SESS模型引入了一个可学习的长度矩阵 E ,并将长度向量 $E_{len(i)}$ 与最大池化后的片段特征拼接,得到片段 $Span_i$ 的向量表示 Sp_i :

$$Sp_i = f(H_{start(i)}, \dots, H_{end(i)}); E_{len(i)} \quad (15)$$

其中, f 代表最大池化操作,“;”代表拼接操作。

随后,将片段向量 Sp_i 与标识符CLS对应的句子特征向量 H_{cls} 进行拼接,通过前馈神经网络对文本片段 $Span_i$ 进行分类,判断该片段是否属于方面词、观点词或者都不是,生成最终的候选片段集合。

$$y_i^T = \text{softmax}(W_i(Sp_i; H_{cls}) + b_i) \quad (16)$$

其中, W_i 和 b_i 为可训练的权重矩阵和偏置项, y_i^T 为预测的概率分布。

3.4 三元组抽取模块

将候选的方面词片段和观点词片段两两配对生成最终的情感三元组特征,并通过分类器预测其情感极性。具体而言,对于候选的文本片段对 $(Span_i, Span_j)$,首先通过最大池化操作得到其包含的局部上下文特征 $C_{i,j}$,随后将候选片段的向量表示 Sp_i, Sp_j 和 $C_{i,j}$ 拼接得到片段对的特征表示 $P(s_i, s_j)$,最后通过前馈神经网络对其进行分类,得到该文本片段对的情感极性分布 $y^R(s_i, s_j)$ 。其表达式如下:

$$C_{i,j} = f(H_{start(i)+1}, \dots, H_{end(j)-1}) \quad (17)$$

$$P(s_i, s_j) = [Sp_i; C_{i,j}; Sp_j] \quad (18)$$

$$y^R(s_i, s_j) = \text{softmax}(W_r P(s_i, s_j) + b_r) \quad (19)$$

其中, f 代表最大池化操作,“;”代表拼接操作, W_r 和 b_r 为可训练的权重矩阵和偏置项。

3.5 损失函数

SESS模型的损失函数 L 定义为方面词与观点词抽取以及情感极性判断两个子任务损失函数的加权求和:

$$L = \alpha L^T + (1 - \alpha) L^R \quad (20)$$

$$L^T = - \sum_{i=1}^{k_1} \bigwedge_{j=1}^{\wedge} y_i^T \log y_i^T \quad (21)$$

$$L^R = - \sum_{i=1}^{k_2} \bigwedge_{j=1}^{\wedge} y_{(s_i, s_j)}^R \log y_{(s_i, s_j)}^R \quad (22)$$

其中, α 通常取0.5, k_1 和 k_2 分别代表文本片段的类别数量和情感极性的类别数量, L^T 表示文本片段预测类别分布 y_i^T 和真实类别分布 $\bigwedge_{j=1}^{\wedge} y_i^T$ 之间的交叉熵损失函数, L^R 表示情感极性判断任务的交叉熵损失函数。

4 实验

4.1 数据集

本文选用标准数据集ASTE-Data-V2^[4]对SESS模型的

有效性进行评估。ASTE-Data-V2数据集在ASTE-Data-V1数据集的基础上进一步细化了三元组关系的界定,有效提升了多词实体边界的精准确度。此外,该数据集还对ASTE-Data-V1中存在的标注错误和不一致问题进行了全面修正。它总共包含4个子数据集:14Lap,14Res,15Res和16Res。这些数据集的样本均经过全面标注,包含所有情感三元组的信息,以确保评估的高质量与可靠性。表1列出了各个子数据集的统计信息,其中,#S表示数据集中句子的数量,#T表示句子中包含的三元组数量。这些多领域的高质量数据集为模型在不同场景下的性能评估提供了坚实的基础。

表1 ASTE-Data-V2数据集信息统计

Table 1 Information statistics of ASTE-Data-V2 dataset

数据集	训练集		验证集		测试集	
	#S	#T	#S	#T	#S	#T
14Lap	906	1460	219	346	328	543
14Res	1266	2338	310	577	492	994
15Res	605	1013	148	249	322	485
16Res	857	1394	210	339	326	514

4.2 实验参数设置

本文模型基于深度学习框架PyTorch实现,关键实验参数设置如表2所列。

表2 实验参数设置

Table 2 Experimental parameters setting

参数	值
操作系统	Linux
GPU	V100 32GB
Batch Size	16
Learning Rate	5×10^{-5}
Epoch	120
损失函数	交叉熵损失函数
优化器	AdamW
图卷积网络层数	2
SpanBert版本	base-cased
窗口长度 L	3

4.3 评价指标

本文采用准确率P、召回率R和F1值作为评价指标。

$$P = \frac{TP}{TP + FP} \quad (23)$$

$$R = \frac{TP}{TP + FN} \quad (24)$$

$$F1 = \frac{2 \times P \times R}{P + R} \quad (25)$$

其中,TP(True Positive)表示被正确预测的三元组数量,FP(False Positive)表示被错误预测为三元组的数量,FN(False Negative)表示未能正确预测的三元组数量,TN(True Negative)表示被正确预测为非三元组的数量。需要特别注意的是,仅当三元组中的所有元素(方面词、观点词和情感极性)均被正确预测时,才能认为该三元组被成功预测。这一严格的标准确保了模型评估的准确性和可靠性。

4.4 实验结果与分析

为了验证SESS模型的有效性,将其与其他ASTE任务模型进行对比。具体对比模型如下。

Peng-two-stage^[3]:采用流水线方式将ASTE任务拆分为两个阶段,第一阶段标注方面-情感对和观点词,第二阶段将

两者配对完成三元组抽取。

BMRC^[12]:基于双向阅读理解的方法解决 ASTE 任务。一个方向依次提取方面词、观点词和情感极性,另一个方向交换方面词和观点词的提取顺序,再提取情感极性。

GTS-Bert^[5]:将三元组抽取任务转换为统一的网格标记任务,采用标集集{A,O,POS,NEG,NEU,N}标记句子中的词对,依据标记结果直接抽取三元组。

EMC-GCN^[18]:在 GTS 模型基础上,结合词性、句法依赖信息、相对距离等语言学特征,通过多通道图卷积网络学习词与词之间的关系,同时细化网格标注标签。

BDTF^[7]:通过关系区域的检测和分类完成三元组抽取,利用边界识别解决多词实体边界不一致问题。

Span-ASTE^[6]:基于双通道片段剪裁策略生成候选的方面词和观点词集合,并从片段角度预测候选方面-观点对的情感极性。

SSJE^[16]:利用图卷积网络学习依存句法关系,枚举所有可能的候选片段,解决方面词和观点词之间的一对多、多对一问题。

Span-SACTE^[21]:在 Span-ASTE 基础上引入词性特征过滤无效片段,并通过对比学习增强模型对不同情感极性样本的区分能力。

Dual-Span^[22]:通过结合句法和词性信息来降低无效片段对模型性能的负面影响,并利用关系图神经网络^[32]学习候选片段的特征表示。

D2E2S^[33]:引入双编码器结构,以增强句法和语义信息表示,并使用异构特征交互模块(HFIM)来实现两种信息的交互。

MvLFE^[34]:通过精细化处理、精确对齐以及高效聚合多角度的语言特征,实现情感三元组的准确抽取。

由于 Peng-two-stage,BMRC,GTS-Bert 采用的是 ASTE-Data-V1 数据集,为了确保公平性,本文采用其在 ASTE-Data-V2 数据集上复现后的结果。其余实验结果均来自于对应的原文。

本文 SESS 模型在对比实验中的表现如表 3 所列,其显著的性能提升源于对复杂句法结构处理能力的增强和情感识别能力的提升。具体而言,SESS 采用了端到端的结构,有效解决了 Peng-two-stage 模型中因误差传播引起的性能下降问题,在所有数据集上,其 F1 值均有大幅度提升。相较于 Span-ASTE 模型,SSJE 模型通过结合依存句法关系的图卷积网络来学习句法知识,而 SESS 模型进一步引入了语义特征提取模块,能更全面地捕捉句法依赖信息和语义信息。这使得 SESS 模型在 F1 值上比 Span-ASTE 和 SSJE 平均提高了 4.53 个百分点和 3.45 个百分点。尽管基于表格标注的模型(GTS-Bert,EMC-GCN 和 BDTF)在缓解多词实体情感不一致性和边界错误方面做出了改进,但其性能仍受限于召回率较低的问题。以改进较多的 BDTF 为例,其在 Res16 数据集上的 F1 值为 72.27%,较 SESS 仍低 2.65 个百分点。相较于基于片段的 Dual-Span 模型及 D2E2S 模型,SESS 模型能够更好地适应下游基于片段的任务需求。因此,SESS 模型在除 14Lap 以外的 3 个数据集上均实现了最佳的 F1 值。尽管 MvLFE 模型使用了多种前沿技术,但 SESS 模型依旧在 14Res 与 15Res 两个数据集上获得了最高的 F1 值,充分验证了本文方法的优越性和有效性。

表 3 对比实验结果

Table 3 Results of comparative experiments

模型	14Lap			14Res			15Res			16Res		
	P	R	F1	P	R	F1	P	R	F1	P	R	F1
Peng-two-stage	37.38	50.38	42.87	43.24	63.66	51.46	48.07	57.51	52.32	46.96	64.24	54.21
BMRC	65.12	54.41	59.27	71.32	70.09	70.69	63.71	58.63	61.05	67.74	68.56	68.13
GTS-Bert	57.52	51.92	54.58	70.92	69.49	70.20	59.29	58.07	58.67	68.58	66.60	67.58
EMC-GCN	61.70	56.26	58.81	71.21	72.39	71.78	61.54	62.47	61.93	65.62	71.30	68.33
Span-ASTE	63.44	55.84	59.38	72.89	70.89	71.85	62.18	64.45	63.27	69.45	71.17	70.26
SSJE	67.43	54.71	60.41	73.12	71.43	72.26	63.94	66.17	65.05	70.82	72.00	71.38
Span-SACTE	65.20	60.18	62.59	73.33	76.31	74.79	68.39	61.97	65.03	71.02	71.31	71.17
BDTF	68.94	55.97	61.74	75.53	73.24	74.35	68.76	63.71	66.12	71.44	73.13	72.27
Dual-Span	67.14	62.13	64.49	77.01	74.00	75.47	67.97	66.34	67.13	73.56	73.48	73.49
D2E2S	67.38	60.31	63.65	75.92	74.36	75.13	70.09	62.11	65.86	77.97	71.77	74.74
MvLFE	66.12	62.33	64.17	76.37	74.46	75.40	69.97	64.14	66.93	77.02	73.41	75.17
SESS	64.77	63.16	63.96	76.40	77.03	76.71	68.83	65.84	67.30	76.56	73.36	74.92

(%)

4.5 消融实验

为进一步验证模型各模块对 SESS 性能的贡献,本文在样本量较大的 14Res 数据集上开展了消融实验,实验结果如表 4 所列,其中,w/o 表示去除对应模块,+表示添加对应模块。

当将预训练模型 SpanBert 替换为 Bert 时,由于两者的预训练任务存在差异,因此下游任务难以充分利用预训练模型的语义信息,F1 值从 76.71%下降至 74.78%,表明 SpanBert 更契合下游基于片段的抽取任务。

当移除 BiLSTM 模块后,模型的局部上下文信息的建模能力显著削弱,F1 值下降至 74.06%;即使使用卷积层替代 BiLSTM 来尝试建模上下文信息,模型性能仍未达到完整模型的水平,说明 BiLSTM 在捕获序列依赖和细粒度特征方面具有更强的能力。

当去掉语义特征提取模块中的 SemGCN,仅依赖句法特征进行建模时,由于句法分析的准确性受限,因此模型难以有效捕获深层次语义依赖关系,F1 值显著下降至 73.28%。同样地,移除句法特征提取模块中的 SynGCN 后,模型在句法

特征的深层次表达上受到限制, F1 值下降至 73.91%, 表明深层次句法信息对提升抽取效果至关重要。

当去掉交互注意力模块, 直接将语义特征与句法特征进行简单相加时, 特征之间因缺乏深度融合而相互干扰, 召回率下降至 69.93%, F1 值相比完整模型降低了 4.8 个百分点, 进一步验证了交互注意力模块在增强句法与语义特征协同作用方面的关键性。

综上, 消融实验结果表明, SpanBert 作为预训练模型、BiLSTM 用于上下文建模、SemGCN 和 SynGCN 分别提取深层次语义与深层次句法特征, 以及交互注意力模块实现特征深度融合, 这些模块共同构成了 SESS 模型的核心优势。它们的协同作用使得模型能够更全面地捕获句子中的多层次特征, 显著提升三元组抽取的性能。

表 4 消融实验结果

Table 4 Results of ablation experiments

方法	P	R	F1
w/o SpanBert+Bert	76.85	72.81	74.78
w/o BiLSTM	72.88	75.28	74.06
w/o BiLSTM+Conv	74.54	75.08	74.81
w/o SemGCN	79.35	68.07	73.28
w/o SynGCN	74.30	73.53	73.91
w/o Att	74.13	69.93	71.97
SESS	76.40	77.03	76.71

4.6 方面词与观点词抽取

本文进一步在 14Lap 和 14Res 两个数据集上, 分别针对方面词抽取和观点词抽取两个子任务开展实验, 实验结果如图 3 和图 4 所示。




图 3 14Lap 数据集上方面词和观点词抽取结果

Fig. 3 Results of aspect and opinion term extraction on 14Lap dataset

结果显示, 基于词对标注的模型 GTS 在这两项任务中的抽取效果最差。这表明仅关注单词对的标注策略难以捕获多词实体的整体语义信息, 而结合多词实体整体语义进行片段级别的建模, 对 ASTE 任务至关重要。

相比基于片段的其他模型, SESS 在两个数据集上均取得了较优的抽取效果, 在识别实体边界和区分方面词与观点词的能力上表现出色。然而, SESS 模型在 14Lap 数据集上的观点词抽取任务表现不及 Span-SACTE 模型。这是由于 14Lap 数据集中观点词的特征分布相对模糊且易受噪声干扰, 使得 SESS 难以充分捕获有效特征。而 Span-SACTE 模型采用了对比学习策略, 有效减少了无关信息的干扰, 在该数据集上取得了最高的召回率, 进一步使得 F1 值高于 SESS 模型。




图 4 14Res 数据集上方面词和观点词抽取结果

Fig. 4 Results of aspect and opinion term extraction on 14Res dataset

4.7 单词和多词实体三元组抽取

为了深入验证 SESS 模型在处理包含多词实体的三元组抽取任务中的有效性, 本文在 14Lap 和 14Res 两个数据集上开展了相关实验研究。数据集的统计信息如表 5 所列, 其中, #SW 代表方面词和观点词均为单一词汇构成的三元组数量, #MW 代表方面词和观点词中至少有一个为多词实体的三元组数量。实验结果如图 5 和图 6 所示。

表 5 数据集中单词和多词实体三元组信息统计

Table 5 Statistics of single-word and multi-word entity triplets in the dataset

数据集	训练集		验证集		测试集	
	#SW	#MW	#SW	#MW	#SW	#MW
14Lap	824	636	190	156	291	252
14Res	1586	752	388	189	657	337




图 5 14Lap 数据集上单词和多词实体三元组抽取结果

Fig. 5 Results of single-word and multi-word entity triplet extraction on 14Lap dataset




图 6 14Res 数据集上单词和多词实体三元组抽取结果

Fig. 6 Results of single-word and multi-word entity triplet extraction on 14Res dataset

可以看出, SESS 模型在单词实体三元组抽取和多词实体三元组抽取两项任务中均取得了最高的 F1 值。此外, 在两个数据集的多词实体三元组抽取任务中, SESS 模型取得了最高的召回率。这一结果表明, SESS 模型不仅能够精确识别句

子中包含的方面词和观点词,还能基于实体片段特征和局部上下文特征准确判断方面词和观点词之间的对应关系,并有效识别出所属的情感类别。

4.8 案例分析

本文对4个数据集中的复杂句式进行了深入分析,重点关注方面词与观点词之间的一对多关系,以及多词实体的识别问题。为了更直观地呈现研究结果,本节选取了部分经典案例,并展示了相应的运行结果。鉴于SSJE和SESS在模型设计上具有一定的相似性,这里选择SSJE模型作为基准对比模型。表6列出了具体案例,其中×标注部分为抽取错误的三元组。

案例1包含多词实体“traditional Italian items”,以及对

应的两个观点词“great”和“cheap”。SSJE由于缺乏深层次语义信息以及对依存句法树精度丢失的补偿能力不足,出现了多词实体边界识别错误的问题,同时未能正确识别全部观点词。而SESS通过整合语义和句法特征,有效捕获了多词实体的整体语义信息,并准确识别出所有观点词,体现出其在复杂实体边界识别中的优越性。

案例2中,句子包含方面词和观点词的一对多关系。SESS通过引入特征交互模块,深入挖掘语法与语义之间的关联并融合后,成功提取了句子中所有的三元组,包括方面词“meal”以及与之相关的多个观点词。然而,SSJE在观点词“great”的识别中出现遗漏,导致召回率下降。

表6 情感三元组抽取案例

Table 6 ASTE cases

句子	正确三元组	SSJE	SESS
The traditional Italian items are great-cheap and served in a cozy setting.	{(traditional Italian items, great, pos), (traditional Italian items, cheap, pos), (setting, cozy, pos)}	{(Italian items, great-cheap, pos) × (traditional Italian items, great-cheap, pos) × (setting, cozy, pos)}	{(traditional Italian items, great, pos), (traditional Italian items, cheap, pos), (setting, cozy, pos)}
appetizer are excellent here; you can make a great (and inexpensive) meal out of them.	{(appetizer, excellent, po), (meal, inexpensive, pos), (meal, great, pos)}	{(appetizer, excellent, pos), (meal, inexpensive, pos), ×}	{(appetizer, excellent, pos), (meal, great, pos), (meal, inexpensive, pos)}
the host(owner) and servers are personable and caring.	{(host (owner), personable, pos), (host (owner), caring, pos), (servers, personable, pos), (servers, caring, pos)}	{(host, personable, pos) × (host, caring, pos) × (owner, personable, pos) × (owner, caring, pos) × (servers, personable, pos), (servers, caring, pos)}	{(host (owner), personable, pos), (host (owner), caring, pos), (servers, personable, pos), (servers, caring, pos)}

案例3中,“host”和“owner”属于同一方面词。SSJE模型由于缺乏对多词实体内在联系的建模能力,将其错误划分为两个独立的方面词,造成错误识别。相比之下,SESS不仅准确识别出了“host”和“owner”属于同一方面词,还完整提取了对应的观点词及其情感极性,全面展示了其对复杂实体关系的优异处理能力。

结束语 本文提出的SESS模型,在端到端框架中结合了句法与语义特征,通过引入语义特征提取模块和句法特征挖掘模块分别对语义和句法特征进行深度建模,并通过交互注意力模块实现了两类特征的高效融合。此外,采用基于片段的抽取方法,显著提升了对长实体和复杂情感极性的识别能力。实验结果表明,SESS在各项指标上均表现出色,尤其在复杂句式和多关系情感表达的处理上展现出显著优势。消融实验进一步验证了各模块的必要性和设计的合理性。未来工作中,可以进一步探索将模型拓展至跨语言和多领域数据集上,进一步验证并提高其通用性和鲁棒性。本文为解决ASTE任务中的关键难题提供了新思路,为相关领域的研究与应用奠定了基础。此外,为便于后续研究的开展,本文提供了SESS模型的源代码¹⁾。

参考文献

[1] CHEN Z, QIAN T Y, LI W L, et al. A Survey on Aspect-level Sentiment Analysis under Low-resource Conditions[J]. Chinese Journal of Computers, 2023, 46(7): 1445-1472.

[2] JOSHI M, CHEN D Q, LIU Y H, et al. SpanBERT: Improving Pre-training by Representing and Predicting Spans[J]. Transactions of the Association for Computational Linguistics, 2020, 8: 64-77.

[3] 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 AAAI Conference on Artificial Intelligence. 2020: 8600-8607.

[4] 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 (EMNLP). 2020: 2339-2349.

[5] 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. 2020: 2576-2585.

[6] XU L, CHIA Y K, BING L D. Learning Span-Level Interactions for Aspect Sentiment Triplet Extraction[C]//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. 2021: 4755-4766.

[7] ZHANG Y C, YANG Y F, LI Y H, et al. Boundary-driven table-filling for aspect sentiment triplet extraction[C]//Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing. 2022: 6485-6498.

[8] CHEN Y Q, ZHANG Z Q, ZHOU G Y, et al. Span-based dual-decoder framework for aspect sentiment triplet extraction[J]. Neurocomputing, 2022, 492: 211-221.

[9] CHEN Y Q, CHEN K M, SUN X, et al. A Span-level Bidirectional Network for Aspect Sentiment Triplet Extraction[C]//Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing. 2022: 4300-4309.

[10] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is

¹⁾ <https://github.com/cx563/SESS>

- All You Need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. 2017; 6000-6010.
- [11] MAO Y, SHEN Y, YU C, et al. A joint training dual-mrc framework for aspect based sentiment analysis[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2021; 13543-13551.
- [12] CHEN S W, WANG Y, LIU J, et al. Bidirectional machine reading comprehension for aspect sentiment triplet extraction[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2021; 12666-12674.
- [13] 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. 2021; 9279-9291.
- [14] ZHANG W X, LI X, DENG Y, et al. Towards generative aspect-based sentiment analysis[C]// Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. 2021; 504-510.
- [15] YAN H, DAI J Q, 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 and the 11th International Joint Conference on Natural Language Processing. 2021; 2416-2429.
- [16] LI Y, LIN Y D, LIN Y M, et al. A span-sharing joint extraction framework for harvesting aspect sentiment triplets[J]. Knowledge-Based Systems, 2022, 242: 108366.
- [17] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks[J]. arXiv:1609. 02907, 2016.
- [18] CHEN H, ZHAI Z P, FENG F X, et al. Enhanced multi-channel graph convolutional network for aspect sentiment triplet extraction[C]// Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics. 2022; 2974-2985.
- [19] SHI L L, HAN D H, HAN J Y, et al. Dependency graph enhanced interactive attention network for aspect sentiment triplet extraction[J]. Neurocomputing, 2022, 507: 315-324.
- [20] LI Y B, HE Q, ZHANG D M. Dual graph convolutional networks integrating affective knowledge and position information for aspect sentiment triplet extraction[J]. Frontiers in Neurobotics, 2023, 17: 1193011.
- [21] LI Q L, WEN W S, QIN J H. Improving span-based Aspect Sentiment Triplet Extraction with part-of-speech filtering and contrastive learning[J]. Neural Networks, 2024, 177: 106381.
- [22] LI P, LI P, ZHANG K. Dual-Channel Span for Aspect Sentiment Triplet Extraction[C]// Proceedings of the 2023 Conference on Empirical Methods in Natural Language Processing. 2023; 248-261.
- [23] ZHANG C, REN L, MA F, et al. Structural Bias for Aspect Sentiment Triplet Extraction[C]// Proceedings of the 29th International Conference on Computational Linguistics. 2022; 6736-6745.
- [24] PENG K, JIANG L, PENG H, et al. Prompt Based Tri-Channel Graph Convolution Neural Network for Aspect Sentiment Triplet Extraction[C]// Proceedings of the 2024 SIAM International Conference on Data Mining (SDM). Society for Industrial and Applied Mathematics, 2024; 145-153.
- [25] JIANG B X, LIANG S H, LIU P Y, et al. A semantically enhanced dual encoder for aspect sentiment triplet extraction[J]. Neurocomputing, 2023, 562: 126917.
- [26] 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: Human Language Technologies. 2019; 4171-4186.
- [27] DAI D W, CHEN T, XIA S Y, et al. Double embedding and bidirectional sentiment dependence detector for aspect sentiment triplet extraction [J]. Knowledge-Based Systems, 2022, 253: 109506.
- [28] SUN X W, QI J T, ZHU Z F, et al. SenticNet and Abstract Meaning Representation driven Attention-Gate semantic framework for aspect sentiment triplet extraction [J]. Engineering Applications of Artificial Intelligence, 2025, 139: 109625.
- [29] WANG B, JIANG B X, WANG G J, et al. Knowledge complementation based dual-table filling approach for aspect sentiment triplet extraction[J]. Neurocomputing, 2025, 611: 128625.
- [30] LIU D X, DUAN L G, CUI J J, et al. A Semantic Matching Strategy for Short Texts by Integrating Sememe Similarity Matrix and Dual-channel Word Vectors [J]. Computer Science, 2024, 51(12): 250-258.
- [31] MANNING C D, SURDEANU M, BAUER J, et al. The Stanford CoreNLP natural language processing toolkit [C]// Proceedings of 52nd Annual Meeting of the Association for Computational Linguistics: System Demonstrations. 2014; 55-60.
- [32] BAI X F, LIU P B, ZHANG Y. Investigating typed syntactic dependencies for targeted sentiment classification using graph attention neural network[J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2020, 29: 503-514.
- [33] ZHAO X W, ZHOU Y, XU X J. Dual Encoder: Exploiting the Potential of Syntactic and Semantic for Aspect Sentiment Triplet Extraction[C]// Proceedings of the 2024 Joint International Conference on Computational Linguistics, Language Resources and Evaluation (LREC-COLING 2024). 2024; 5401-5413.
- [34] SU G X, WU M M, HUANG Z Q, et al. Refine, align, and aggregate: multi-view linguistic features enhancement for aspect sentiment triplet extraction [C]// Findings of the Association for Computational Linguistics ACL 2024. 2024; 3212-3228.



CHANG Xuanwei, born in 2002, post-graduate. His main research interest is sentiment analysis.



DUAN Ligo, born in 1970, Ph.D, professor, master's supervisor, is a senior member of CCF(No. 15823S). His main research interest is natural language processing.