

基于特征增强式多轮机器阅读理解的方面情感三元组抽取

郝渊斌, 段利国, 李爱萍, 陈嘉昊, 崔娟娟, 常轩伟

引用本文

郝渊斌, 段利国, 李爱萍, 陈嘉昊, 崔娟娟, 常轩伟. [基于特征增强式多轮机器阅读理解的方面情感三元组抽取](#)[J]. 计算机科学, 2026, 53(3): 341-350.

HAO Yuanbin, DUAN Ligu, LI Aiping, CHEN Jiahao, CUI Juanjuan, CHANG Xuanwei. [Enhanced Multi-turn Machine Reading Comprehension for Aspect Sentiment Triplet Extraction](#) [J]. Computer Science, 2026, 53(3): 341-350.

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)

[深度融合句法和语义特征的情感三元组片段级抽取方法](#)

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

计算机科学, 2026, 53(2): 322-330. <https://doi.org/10.11896/jsjx.250100061>

[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/jsjx.240800061>

[基于句法、语义和情感知识的方面级情感分析](#)

Aspect-based Sentiment Analysis Based on Syntax, Semantics and Affective Knowledge

计算机科学, 2025, 52(7): 218-225. <https://doi.org/10.11896/jsjx.240500124>

[基于大小语言模型协同增强的中文电子病历依存句法分析](#)

Dependency Parsing for Chinese Electronic Medical Record Enhanced by Dual-scale Collaboration of Large and Small Language Models

计算机科学, 2025, 52(2): 253-260. <https://doi.org/10.11896/jsjx.231200054>

[融合义原相似度矩阵与字词向量双通道的短文本语义匹配策略](#)

Short Text Semantic Matching Strategy Fusing Sememe Similarity Matrix and Dual-channel of Character Word Vectors

计算机科学, 2024, 51(12): 250-258. <https://doi.org/10.11896/jsjx.231100147>

基于特征增强式多轮机器阅读理解的方面情感三元组抽取

郝渊斌¹ 段利国^{1,2} 李爱萍¹ 陈嘉昊¹ 崔娟娟¹ 常轩伟¹

1 太原理工大学计算机科学与技术学院 太原 030024

2 山西电子科技学院 山西 临汾 041000

(781900914@qq.com)

摘要 方面情感三元组抽取(ASTE)旨在同时提取出文本中的方面及其对应的观点和情感极性,是一项新兴且具有挑战性的方面级情感分析任务。现有方法中,基于多轮机器阅读理解的方法有效实现了情感三元组抽取,但仍存在一定的局限性:其一,多轮阅读理解中单一的文本特征难以适应特定子任务;其二,全局自注意力机制缺乏对语法层面更重要单词的关注,且其对不重要单词赋予更高的注意力权重。针对这些问题,提出一种特征增强式多轮机器阅读理解方法(EMT-MRC),在每轮机器阅读理解中设计双向注意力流构建文本与问题的交互关系,从而获得特定任务感知的文本表示。同时,将依存句法关系整合到Transformer编码器,通过依存距离约束模型注意力分布,加强模型对句子语法层面的关注。通过在两组基准数据集上的实验,证明了提出方法的有效性。

关键词: 方面级情感;三元组抽取;机器阅读理解;依存句法;双向注意力流

中图分类号 TP391

Enhanced Multi-turn Machine Reading Comprehension for Aspect Sentiment Triplet Extraction

HAO Yuanbin¹, DUAN Ligu^{1,2}, LI Aiping¹, CHEN Jiahao¹, CUI Juanjuan¹ and CHANG Xuanwei¹

1 Department of Computer Science and Technology, Taiyuan University of Technology, Taiyuan 030024, China

2 Shanxi Electronic Science and Technology Institute, Linfen, Shanxi 041000, China

Abstract ASTE aims to simultaneously extract aspects, their corresponding opinions, and sentiment polarities from text. It is an emerging and challenging task in aspect-level sentiment analysis. Among existing methods, those based on multi-turn machine reading comprehension have effectively achieved sentiment triplet extraction, but they still exhibit certain limitations. Firstly, the single text feature in multi-turn reading comprehension struggles to adapt to specific subtasks. Secondly, the global self-attention mechanism lacks focus on syntactically more important words and assigns higher attention weights to less significant words. To address these issues, this paper proposes an enhanced multi-turn machine reading comprehension(EMT-MRC) method, which designs a bidirectional attention flow in each turn of reading comprehension to construct the interaction between text and questions, thereby obtaining task-specific text representations. Additionally, dependency syntactic relations are integrated into the Transformer encoder, which constrains the model's attention distribution through dependency distances, thereby enhancing the model's focus on the grammatical aspects of sentences. Experiments on two groups of datasets demonstrate the effectiveness of the proposed method.

Keywords Aspect-level sentiment, Triplet extraction, Machine reading comprehension, Dependency syntax, Bidirectional attention flow

1 引言

方面级情感分析 ABSA^[1] (Aspect-Based Sentiment Analysis)是一种细粒度的情感分析任务,旨在抽取并分析文本中方面项的情感信息。它的研究路线主要涉及到3个方面级情感术语的抽取或分类,即方面词(Aspect)、观点词(Opinion)、情感极性(Sentiment Polarity)。方面情感三元组抽取ASTE(Aspect Sentiment Triplet Extraction)是ABSA领域最

近提出的一项任务,旨在以三元组形式同时提取出句子中的方面词、观点词和情感极性。ASTE通常涉及到两组不同但相关的子任务,即方面、观点提取(也称为方面术语提取)和方面-观点对情感分类。图1给出了一个例句及其所包含的方面情感三元组。以“The place feels cramped”为例,对于方面词“place”,其对应的观点为“cramped”,这组方面-观点的情感极性应为消极。反过来说,“cramped”这一观点词是模型识别出方面词“place”的证据。如何识别方面词和观点词间的复

到稿日期:2025-03-10 返修日期:2025-05-26

基金项目:山西省自然科学基金(202203021221234,202303021211052,202303021222248)

This work was supported by the Natural Science Foundation of Shanxi Province, China(202203021221234,202303021211052,202303021222248).

通信作者:段利国(463035793@qq.com)

杂关系并完整地抽出句子中所有的方面-观点对,是 ASTE 任务最关键也最具挑战的问题。

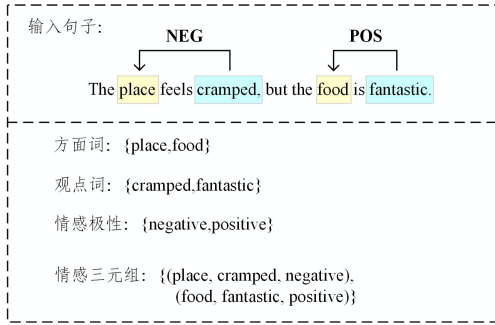


图1 方面情感三元组实例

Fig. 1 Example of aspect sentiment triplet

近年来,解决 ASTE 任务的模型不断被提出,基于机器阅读理解(MRC)的方法因性能优势和轻量级架构而成为该任务的主流方法之一。Chen 等^[2]提出的双向机器阅读理解模型(BMRC)通过多轮次阅读理解,将多重提取任务转换为跨度预测任务,实现了在统一框架中进行情感三元组的抽取,有效解决了该任务。然而,该方法忽略了 ASTE 任务以及机器阅读理解框架的一些固有特征。对此,本文主要考虑了以下两个问题:

首先,现有三元组抽取模型大多基于自注意力机制构建,自注意力机制可以很好地捕捉全局的依赖关系,但在处理句法与语义层级区分时仍存在局限,尤其当依赖关系呈现复杂结构时,其性能显著下降。这一问题在基于机器阅读理解的方法中表现得尤为突出。机器阅读理解模拟了人类的阅读和理解过程以解决问题,然而在人类的阅读和理解过程中,通常更多地关注文本中的关键词,而不是给每个词同等的关注。在全局注意力机制下,模型缺少对关键词的优先关注并错误地关注一些不重要的词,如介词、冠词等,这种问题在长文本下更为明显。因此,在使用注意力机制时,对单词特征的修剪和优先关注十分重要。

其次,在多轮机器阅读理解框架下,仅靠增强句子表征难以充分满足模型需求。解决此问题的关键在于,将文本构建为面向特定阅读理解问题的任务感知表示。多轮机器阅读理解方法需要模型通过迭代回答不同问题来抽取文本特征,这一过程依赖于模型对文本-问题交互关系的建模,构建任务感知表示能够帮助模型深入理解文本和问题间的交互,进一步提升情感三元组的抽取效果。

本文提出了一种特征增强型多轮机器阅读理解方法(Enhanced Multi-turn Machine Reading Comprehension, EMT-MRC)来解决上述问题。采用多轮机器阅读理解框架,将 ASTE 任务表示为 3 轮递进的机器阅读理解任务,后一轮问题引入前一轮答案,通过多轮次的问答交互将三元组抽取拆分,在每一轮机器阅读理解中,将文本和问题输入模型获得最终的预测结果。模型层面,构建了两个特征增强模块,分别是句法引导层和任务感知层。句法引导层将句法依存距离融入 Transformer 编码器^[3]中,依存距离的引入有效约束了方面词和观点词的识别边界以及配对关系,特别是增强了长距离依赖下方面-观点对的抽取效果;任务感知层通过双向注意力

流整合来自文本到问题和问题到文本的注意力,实现文本的任务感知表示。本文的主要贡献可概括为以下 3 点:

1) 将依存句法关系整合到 Transformer 编码器,通过语法知识的融入指导模型生成更丰富的语义表示;

2) 为了使模型适应多轮任务中不同阶段的子任务,通过双向注意力流来实现文本和问题间的交互,使文本生成特定任务感知表示;

3) 提出了一种用于 ASTE 任务的特征增强式多轮机器阅读理解模型 EMT-MRC,在两组基准数据集上进行了广泛的实验,实验结果表明,本文模型优于当前主流模型。

2 相关工作

在 ABSA 早期研究中,方面级情感分析主要为各个方面情感术语的单独抽取,如方面词提取 ATE^[4](Aspect Target Extraction)、观点词提取 OTE^[5](Opinion Target Extraction)和方面情感极性分类 ASC^[6](Aspect Sentiment Classification)。随后,一些研究集中在多个子任务的联合提取上,包括方面-观点对提取 AOPE^[7](Aspect-Opinion Pair Extraction)和端到端 ABSA 任务^[8](End-to-End ABSA)等。例如,Zhang 等^[9]提出的基于多任务联合训练的多实体情感分析方法旨在同时识别文本中的实体及其情感极性。然而,上述任务都未能在单一任务范式中完整地识别出文本中的方面词、观点词及情感极性。为了解决该问题,Peng 等^[10]首次提出了方面情感三元组抽取 ASTE 任务,并介绍了一种两阶段管道式方法(Pipeline)来完成 ASTE 任务:第一阶段识别情感三元组各个方面术语,第二阶段将它们逐一匹配。然而,这些基于管道的方法忽略了三元组之间的交互,可能会导致误差传播问题。

为了解决这一问题,之后的研究开始尝试在端到端(End-to-End)的统一框架下完成情感三元组的抽取。主流端到端方法中,Li 等^[11]首次将 BERT^[12]模型引入端到端方面级情感分析(BERT-E2E-ABSA)任务,采用统一的序列标注框架。BERT 的使用显著提升了深度学习模型在这一任务中的表现。2020 年,Wu 等^[13]针对 ABSA 中 AOPE 提出的网格标记方案(GTS)进行扩展,在实现方面观点对抽取的同时增加了对情感极性的分类。2020 年提出的 JET^[14]模型采用位置感知标记方式,联合提取方面、观点以及情感极性,并将位置信息融合到方面与观点中。Span-ASTE 由 Xu 等^[15]于 2021 年提出,该方法在提取情感三元组时直接捕捉跨度级交互,生成所有可能的方面和观点跨度的表示,并通过一种双通道跨度修剪策略来降低计算成本,为每一对方面和观点独立预测情感关系。SSJE^[16]于 2022 年提出,其增强了跨度表示,并通过图卷积捕获句法依赖信息来获得三元组 span 表示。HIM 模型^[17]于 2023 年提出,该模型为端到端的分层交互模型,主要通过两个交互模块进行子任务建模,两个交互层级分别学习隐式和词级交互。2023 年提出的 ES-ASTE^[18]构建了一个跨度级模型来提取方面情感三元组,引入句法依赖和词性特征,通过图卷积神经网络来处理方面和观点间的复杂关系。2024 年提出的 SBRS^[19]采用双路径识别提取方面-观点对,结合并行计算方法,提取方面-观点对后进行情感极性识别。2024 年

提出的基于提示的三通道图卷积神经网络(PT-GCN)^[20]基于提示词构建模板,通过三通道卷积模块精确提取情感知识。

除端到端方式外,还有研究人员引入 MRC 范式作为解决 ASTE 任务的方法。MRC 范式作为 NLP 研究中的一个经典范式,被广泛用于方面级情感分析(ABSA)的各类衍生任务中。应用于 ASTE 问题的 MRC 方法也在近年被提出并不断优化。除前文提到的 BMRC 模型外,2021 年提出的 Dual-MRC^[21]模型将原始问题转换为两个 MRC 问题,一个用于方面项抽取,另一个用于随后的观点抽取以及对应的情感极性预测,之后将两个问题放入两个预训练模型并进行联合训练。2022 年提出的 COM-MRC^[22]通过基于上下文屏蔽框架的 MRC 实现了对训练语料的数据增强,通过迭代屏蔽方面术语来实现基于 MRC 的推理方法。QoMRC^[23]模型于 2024 年提出,其采用两阶段方法。在第一阶段,为 3 个子任务生成 3 个不同的查询模板的适配器。在第二阶段,融合面向查询的适配器和共享编码器表示,获得特定于任务的表示。2024 年, Zou 等^[24]提出的 Triple-MRC 设计了一个基于多任务联合学习的机器阅读理解模型。多任务联合训练能有效避免组件之间的贡献分配问题, MRC 方法利用先验知识减少子任务间的错误传播,并降低了模型复杂性。

尽管 MRC 范式方法相比大多数其他方法展现出显著的性能优势,但这些基于 MRC 的方法仍存在问题亟待解决。这些问题是由 ASTE 任务特点和 MRC 范式特性共同导致的:首先,这些 MRC 方法大多采用全局注意力捕捉问题和

文本的语义关系,全局注意力机制将输入序列视为单一语义单元,忽视了句法结构关联,导致对关键词的关注不足,并错误地关注一些不重要的词,如介词、冠词等。这一问题在长难句处理时尤为显著,直接影响模型性能。其次,现有方法未能有效解决 ASTE 的多任务特性,虽然采用多轮 MRC 或联合训练策略为各 MRC 任务设计问题模板,但缺乏对任务针对性的特征表示机制,难以捕捉不同子任务间的差异。

本文认为大多数方法未能充分考虑上述两个 MRC 范式解决 ASTE 任务的关键特征,导致模型性能受限。本文针对性提出了句法引导结构和问答交互双向注意力流机制,旨在有效解决上述问题并进一步提升模型性能。

3 EMT-MRC 模型

3.1 任务定义

给定包含 n 个单词的文本 $C = \{c_1, c_2, \dots, c_m\}$, ASTE 任务的目标是从文本中抽取出所有三元组 $T = (a_i, o_i, s_i)_{i=1, \dots, t}$, 其中 a, o, s 分别表示方面词、观点词以及情感极性, t 表示文本所含方面情感三元组的数量。其中,方面词和观点词可以是单个词或是多个词,情感极性分为 3 类 {POS, NEG, NEU}, POS 表示积极情感, NEG 表示消极情感, NEU 表示中性情感。

3.2 多轮机器阅读理解构建

本文 EMT-MRC 的设计采用多轮机器阅读理解框架设计,具体流程如图 2 所示。

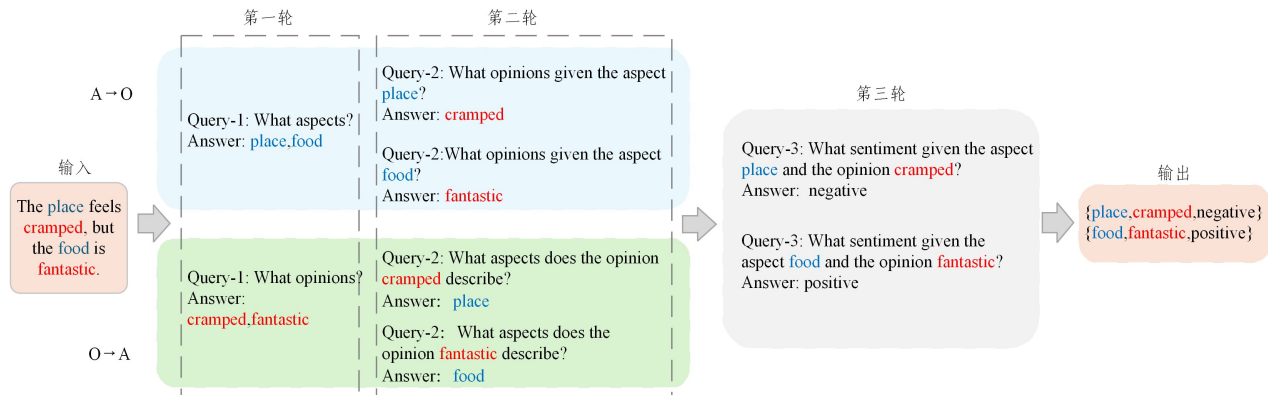


图 2 多轮机器阅读理解流程

Fig. 2 Process of multi-turn machine reading comprehension

对于一段目标文本,为其设计 3 轮机器阅读理解问题,后一轮问题引入前一轮结果。第一轮直接抽取方面或观点词,第二轮引入上一轮答案作为限制关系,专注于抽取方面-观点对。考虑到每对方面和观点之间的相互依赖关系,将其设计为双向结构,通过对方面到观点和观点到方面设计双向问题,实现更全面的方面-观点对抽取。最后一轮情感分类继续利用上一轮已经得到的方面-观点词对提问,得到该二元组对应的情感极性分类。在模型每一次回答问题时,将构建的问题和原始文本输入模型进行预测。图 3 展示了所提模型的多轮流程,其中蓝色和红色箭头表示模型的双向流程(方面到观点和观点到方面)。在每个方向,将 3 轮问题依次输入 EMT-MRC 模型,上一轮问题的答案会用于构建下一轮问题,并且为每个问题提供一组独立分类器。

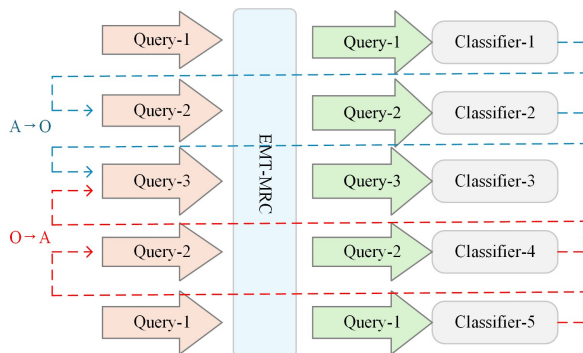


图 3 模型多轮流程图(电子版为彩图)

Fig. 3 Flowchart of multi-turn model

EMT-MRC 模型主要包含嵌入层、句法引导层、任务感知

层以及答案预测层 4 个部分,模型结构如图 4 所示,下文会对

模型的各个部分进行详细介绍。

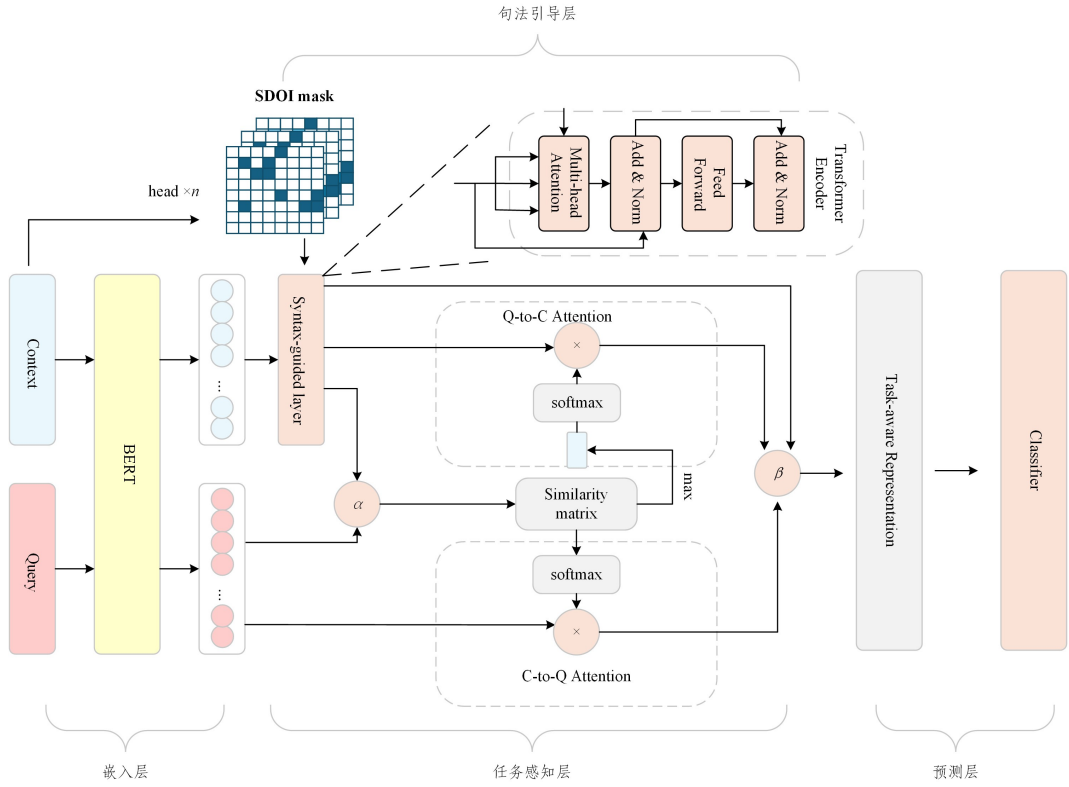


图 4 本文模型结构

Fig. 4 Structure of the proposed model

3.3 嵌入层

嵌入层采用预训练模型 BERT,在每轮机器阅读理解问题中,将问题和文本分别输入 BERT 中获得其上下文表示。给定有 m 个单词的文本 $C = \{c_1, c_2, \dots, c_m\}$ 和 n 个单词的问题 $Q = \{q_1, q_2, \dots, q_n\}$,嵌入层 BERT 分别输出文本表征 $H = \{h_1, h_2, \dots, h_m\}$ 和问题表征 $U = \{u_1, u_2, \dots, u_n\}$ 。

3.4 句法引导层

句法引导层的目标是尽可能有效地利用句子中结构化的句法信息,将依存距离引入自注意力计算之中。传统的全局注意力方法尽管能够捕捉文本中的全局信息,但往往忽略了文本中的句法层次和依存关系的细节。引入依存距离后,可以有效优化全局注意力机制的表现,特别是加强了复杂句法和长距离依赖下的方面与观点对间的交互。对于嵌入层输出的文本 H 和问题 U ,将文本向量表示 H 输入句法引导层,句法引导层通过一个融入了依存句法信息的 Transformer 编码层来实现这一过程。首先介绍 Transformer 编码器的基本结构,之后详细说明如何将句法信息融入其中。

3.4.1 Transformer 编码器

Transformer 编码器是 Transformer 架构中的核心组件,广泛用于各类自然语言处理任务中,过程表示为:

$$H = FFN(\text{MultiHead}(Q, K, V)) \quad (1)$$

其中, Q, K, V 来源于同一输入序列的嵌入表示,通常来说,设置 $Q = K = V$ 。编码器主要由多头自注意力层(MultiHead)和一个前馈神经网络(FFN)两层构成,在每层后使用残差连接并进行层归一化。多头注意力机制将查询向量(Query)、键向量(Key)、值向量(Value)映射到多个注意力头,在每个

头中独立计算自注意力,再将各个头的结果拼接后投影回原空间。单个注意力头的自注意力计算式为:

$$G_i = \text{Softmax}\left(\frac{Q_i K_i^T}{\sqrt{d_k}}\right) V_i \quad (2)$$

其中, Q_i, K_i 和 V_i 表示注意力头 i 对应的 Query, Key 和 Value; d_k 是 Key 的维度; $\sqrt{d_k}$ 为缩放因子,用于防止点积过大导致梯度消失的情况; Softmax 函数对点积分数进行归一化,得到每个 Value 的权重分布,和 Value 相乘得到最终上下文表示 G_i 。

3.4.2 句法引导的自注意力

句法引导层的具体实现是将依存句法信息融入上述 Transformer 编码器的第一层,即多头自注意力层中。具体来说,对于原始文本 $C = \{c_1, c_2, \dots, c_m\}$,首先使用依存句法解析器 spacy 对每个句子的依存结构进行标注并生成对应的依存句法树,根据依存树推导出每个单词 c_i 对应的祖先词集合 P_i 。之后根据依存句法树生成一个形状为 $n \times n$ 的兴趣句法依存 SDOI^[28] (Syntactic Dependency of Interest) 矩阵。该矩阵显式地表示了句子中每两个单词之间的句法关联程度,从而在后续的多头自注意力计算中引导模型更关注具有重要依存关系的词对。SDOI 矩阵生成规则如下:

$$M_{[i,j]} = \begin{cases} 1, & j \in P_i \text{ 或 } j = i \\ 0, & \text{otherwise} \end{cases} \quad (3)$$

当 $M_{[i,j]} = 1$ 时,表示句法依存树中单词 c_i 是 c_j 的祖先节点或其自身。另外,对于文本嵌入增加的功能标签 [SEP] 和 [CLS],在实现中对其进行单独处理,这些特殊标签只会关注它们自身。图 5 展示了句子 "The food is fantastic." 对应的依

存句法树和 SDOI 矩阵。

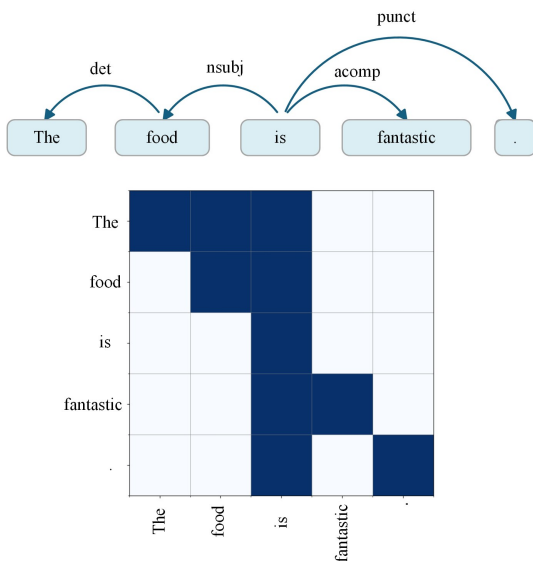


图5 句法依赖树和 SDOI 矩阵

Fig. 5 Dependency tree and SDOI matrix

之后,将文本向量表示 \mathbf{H} 投影到每个注意力头 i 的查询表示 \mathbf{Q}_i 、键表示 \mathbf{K}_i 和值表示 \mathbf{V}_i 。每个注意力头的计算中,在 Query 和 Key 的点积操作中结合 SDOI 掩码矩阵并通过 Softmax 函数得到注意力权重,最后将注意力权重与对应的 Value 相乘得到句法引导向量表示 \mathbf{W}_i ,公式如下:

$$\mathbf{A}_i = \text{Softmax}\left(\frac{\mathbf{M} \cdot (\mathbf{Q}\mathbf{K}^T)}{\sqrt{d_k}}\right) \quad (4)$$

$$\mathbf{W}_i = \mathbf{A}_i \cdot \mathbf{V}_i \quad (5)$$

最后,所有注意力头的输出 \mathbf{W}_i 拼接并通过一个线性层合并,经过之后的残差连接和归一化操作后得到最终向量表示 $\mathbf{H}_s = \{h_{s1}, h_{s2}, \dots, h_{sm}\}$ 。

3.5 任务感知层

为了更好地应对多轮机器阅读理解中不同子任务间的差异,设计了任务感知层,使模型生成同一文本对应特定问题下的任务增强表示。为此,需要将文本表征 $\mathbf{H}_s = \{h_{s1}, h_{s2}, \dots, h_{sm}\}$ 和问题表征 $\mathbf{U} = \{u_1, u_2, \dots, u_n\}$ 结合起来,使文本表征更适合当前的阅读理解问题。通过双向注意力流实现文本的任务感知表示。

双向注意力流主要包括两部分:从上下文到查询的注意力(Context-to-Query)和从查询到上下文的注意力(Query-to-Context)。注意力的生成来自文本及问题表征的相似度矩阵 \mathbf{S} ,形状为 $m \times n$ 。相似度矩阵的计算式如下:

$$\begin{cases} S_{ij} = \alpha(\mathbf{H}_{s_i}, \mathbf{U}_{i_j}) \\ \alpha(h, u) = \mathbf{w}_{(s)}^T \cdot [h; u; h \odot u] \end{cases} \quad (6)$$

其中, S_{ij} 代表了文本中第 i 个词和问题中第 j 个词的相关性; \mathbf{H}_{s_i} 和 \mathbf{U}_{i_j} 分别表示文本表征中第 i 个词的嵌入向量,以及问题表征中第 j 个词的嵌入向量; α 函数是一个可训练的标量函数; $\mathbf{w}_{(s)}$ 是一个可训练的权重向量,形状为 $3d \times 1$, d 为词嵌入维数; $[\cdot]$ 表示向量拼接; \odot 表示矩阵对应元素乘法。之后使用相似度矩阵 \mathbf{S} 得到两个方向上的注意力表示,公式如下:

$$\mathbf{A} = \text{Softmax}_{\text{row}}(\mathbf{S}) \quad (7)$$

$$\mathbf{z} = \text{Softmax}(\max_{\text{row}}(\mathbf{S})) \quad (8)$$

$$\tilde{\mathbf{U}} = \mathbf{A} \cdot \mathbf{U} \quad (9)$$

$$\tilde{\mathbf{H}} = [\mathbf{z}_1; \mathbf{z}_2; \dots; \mathbf{z}_n] \cdot \mathbf{H}_s \quad (10)$$

在上下文到查询方向上,矩阵 \mathbf{A} 通过矩阵 \mathbf{S} 的按行 Softmax 生成,矩阵 \mathbf{A} 的每一行 $A_{i\cdot}$ 代表一个注意力分布以表示每个问题词对第 i 个文本词的关注程度。将矩阵 \mathbf{A} 和问题表征 \mathbf{U} 相乘,得到上下文到查询方向的注意力权重矩阵 $\tilde{\mathbf{U}}$ 。在查询到上下文方向上,将 \mathbf{S} 矩阵按行取最大值后,进行 Softmax 操作生成向量 \mathbf{z} 。该向量表示每个文本词与问题文本整体的相关程度。将向量 \mathbf{z} 复制 m 次并按行拼接后与文本表征 \mathbf{H}_s 相乘,最终得到查询到上下文方向的注意力权重矩阵 $\tilde{\mathbf{H}}$ 。通过融合原始的文本表征 \mathbf{H}_s 以及双向注意力权重矩阵 $\tilde{\mathbf{U}}$ 和 $\tilde{\mathbf{H}}$,得到最终的任务感知表示 $\hat{\mathbf{H}} = \{\hat{h}_1, \hat{h}_2, \dots, \hat{h}_m\}$:

$$\begin{cases} \hat{\mathbf{H}} = \beta(\mathbf{H}_s, \tilde{\mathbf{U}}, \tilde{\mathbf{H}}) \\ \beta(a, b, c) = [a; b; a \odot b; a \odot c] \end{cases} \quad (11)$$

在任务感知层中,通过双向注意力有效地构建了文本和问题的双向交互信息,加强了文本表示的任务感知能力。之后将任务感知表示输入答案预测层进行最后结果的预测。

3.6 答案预测层

在机器阅读理解的前两轮方面和观点提取中,基于跨度的预测方式使用两个二分类器进行预测,一个分类器预测每个单词是否是答案的起始位置,另一个预测是否是结束位置,公式如下:

$$p(y_i^{\text{start}} | \hat{h}_i) = \text{Softmax}(\hat{h}_i \cdot \mathbf{W}_{\text{start}}) \quad (12)$$

$$p(y_i^{\text{end}} | \hat{h}_i) = \text{Softmax}(\hat{h}_i \cdot \mathbf{W}_{\text{end}}) \quad (13)$$

最后一轮情感极性分类中,使用一个三分类器情感预测(积极、中性、消极),公式如下:

$$p(y | \hat{H}) = \text{Softmax}(\hat{H} \cdot \mathbf{W}_{\text{cls}}) \quad (14)$$

此外,在多轮机器阅读理解中,为避免不同轮次和方向的查询间相互干扰,为每个查询提供了一组独立的分类器,即对于前两轮双向的阅读理解共 4 个问题采用 8 个分类器,最后的情感分类任务使用一个分类器。

3.7 损失函数

本文的预测均以交叉熵损失作为损失函数。为实现机器阅读理解各阶段的联合学习,将所有子任务的损失函数进行融合,构成模型训练的总损失函数。对于前两轮双向抽取的 4 个问题,采用损失函数 L_N ;对于最后一轮情感分类任务,采用损失函数 L_S 。具体公式如下:

$$L_N = - \sum_{i=1}^{|\mathcal{Q}^N|} \sum_{j=1}^N [p(y_j^q | x_j, q_i^N) \log \hat{p}(y_j^q | x_j, q_i^N) + p(y_j^c | x_j, q_i^N) \log \hat{p}(y_j^c | x_j, q_i^N)] \quad (15)$$

$$L_S = - \sum_{i=1}^{|\mathcal{Q}^S|} p(y_i^s | X, q_i^s) \log \hat{p}(y_i^s | X, q_i^s) \quad (16)$$

最后,将 5 个问题输入模型产生的损失函数相加,形成整个模型训练的总损失函数:

$$L_{\text{sum}} = L_{N1} + L_{N2} + L_{N3} + L_{N4} + L_S \quad (17)$$

4 实验

4.1 数据集

本文在公开数据集 ASTE-Data 的 v1 和 v2 这两组数据

集上进行了实验,两组数据集是 ASTE 任务的基准数据集,来自于 SemEval ABSA Challenges 竞赛,均包含 Laptop14, Rest14, Rest15 和 Rest16 这 4 个数据集,数据来源为笔记本电脑平台和饭店的评论。ASTE-Data-v1 由 Peng 等^[10]构建,ASTE-Data-v2 由 Xu 等^[15]构建,在 v1 版本基础上修改了标注格式并更新了一些三元组标记。由于 v2 是 v1 的修正版本,本文在 v1 和 v2 上分别进行了对比实验,之后的消融实验和研究性实验均在 v2 版本上进行。表 1 列出了两组数据集的统计数据,表中 S 表示句子个数, T 表示情感三元组个数。

表 1 数据集统计数据

Table 1 Statistics for the experimental datasets

	14Lap		14Res		15Res		16Res	
	S	T	S	T	S	T	S	T
v1								
训练集	899	1452	1259	2356	603	1038	863	1421
测试集	332	547	493	1008	325	493	328	525
验证集	225	383	315	580	151	239	216	348
v2								
训练集	906	1460	1266	2338	605	1013	857	1394
测试集	328	543	492	994	322	485	326	514
验证集	219	346	310	577	148	249	210	339

4.2 实验参数设置

本文使用 PyTorch 框架在 Linux 3.10 环境下实验,采用 bert-uncased 版本的 BERT 预训练模型作为编码器获得向量表征,词向量嵌入维度为 768。输入模型的批次大小设定为 4,在 Tesla V100 显卡(16GB)上训练 40 个轮次,4 个数据集上平均训练时长约 3 小时。训练过程中,模型学习率和 BERT 微调率分别为 1×10^{-3} 和 5×10^{-5} , dropout 率为 0.1。使用 AdamW^[26] 优化器,权重衰减(Weight Decay)和预热率(Warm-up)分别为 0.01 和 0.1。训练结束后,根据模型在验证集上的最佳性能保存模型参数,最终在测试集上获取实验结果。

4.3 实验评估方法

在情感三元组抽取任务中,只有当模型预测的{方面词、观点词、情感极性}三元组全部正确时,才视为一次正确预测。在衡量模型性能时,使用精确率(P)、召回率(R)和 F1 值(F1)作为评估指标,计算方法如下:

$$P = \frac{TP}{TP + FP} \quad (18)$$

$$R = \frac{TP}{TP + FN} \quad (19)$$

$$F1 = \frac{2 \times P \times R}{P + R} \quad (20)$$

其中, TP 是实际为正类且预测为正类的样本数量, FP 是实

际为负类且预测为正类的样本数量, FN 是实际为正类且预测为负类的样本数量。

4.4 对比实验

为了评估提出模型的性能,本文将模型与近年来提出的情感三元组抽取模型进行对比,实验在 ASTE-Data-v1 和 ASTE-Data-v2 数据集上进行。实验结果如表 2 和表 3 所列,* 代表结果由本文在相同条件及参数设置下复现所得,其余结果均从原论文中复制。对比模型涵盖了管道式(Pipeline)、端到端(End-to-End)以及基于机器阅读理解(MRC)的方法。

1) 管道式

Li-unified-R(2020):使用两个基于 Li-unified 的递归神经网络提取所有可能的候选三元组,之后使用二分类器识别所有有效三元组。

TSF(2020):采用两段式管道方法,第一阶段共同提取方面词和情感极性,并行提取观点在第二阶段与方面情感相匹配。

2) 端到端

SPAN-ASTE(2021):一种基于跨度的端到端抽取方法。模型识别文本中的所有可能的跨度,然后对检测到的方面-观点对进行情感分类。

ES-ASTE(2023):提出了一个跨度级模型来提取方面情感三元组。该框架通过引入句法依赖关系和词性组合特征,通过图卷积神经网络来处理方面术语和观点术语之间的复杂关系。

DGCNAP(2023)^[27]:将有向知识引入到两个并行通道的依赖图中,同时考虑了上下文特征和有向知识信息。

SBRS(2024):用两条识别路径提取方面观点对,两条路径在不同尺度上对单词进行操作,结合并行计算方法,通过 3 个相关特征识别情感极性。

3) 基于机器阅读理解

Dual-MRC(2021):构建了两个机器阅读理解问题,并通过联合训练两个具有参数共享的 BERT-MRC 模型来解决所有子任务。

BMRC(2021):将 ASTE 问题转换为多轮机器阅读理解问题,通过无限制提取查询和受限提取查询获得所有方面观点对,最后进行情感分类查询。

Triple-MRC(2024):提出了一个基于多任务联合学习和机器阅读理解(MRC)的模型。多任务联合训练能有效避免组件之间的贡献分配问题,MRC 方法利用来自问题的先验知识来减少任务之间的错误传播。

表 2 对比实验结果(ASTE-Data-v1)

Table 2 Comparative experiment results on the benchmark ASTE-Data-v1

模型	(%)											
	14Lap			14Res			15Res			16Res		
	P	R	F1	P	R	F1	P	R	F1	P	R	F1
Li-unified-R	42.25	42.78	42.47	41.44	68.79	51.68	43.34	50.73	46.69	38.19	53.47	44.51
TSF	40.40	47.24	43.50	44.18	62.99	51.98	40.97	54.68	46.79	46.76	62.97	53.62
Dual-MRC	57.39	53.88	55.58	71.55	69.14	70.32	<u>63.78</u>	51.87	57.21	68.60	66.24	67.40
BMRC	<u>65.12</u>	54.41	59.27	71.32	70.09	70.69	63.71	58.63	61.05	67.74	68.56	68.13
DGCNAP	63.91	54.34	58.74	71.83	68.77	70.26	62.03	57.18	59.49	69.39	72.20	70.77
SBRS	61.28	56.83	58.97	70.99	72.61	71.79	61.71	62.35	62.03	66.45	71.13	68.71
Ours	64.61	<u>57.21</u>	<u>60.69</u>	<u>72.49</u>	<u>73.45</u>	<u>72.97</u>	63.21	<u>64.57</u>	<u>63.88</u>	<u>69.93</u>	<u>73.05</u>	<u>71.46</u>

表3 对比实验结果(ASTE-Data-v2)

Table 3 Comparative experiment results on the benchmark ASTE-Data-v2

模型	14Lap			14Res			15Res			16Res		
	P	R	F1	P	R	F1	P	R	F1	P	R	F1
Li-unified-R	40.56	44.28	42.34	41.04	67.35	51.00	44.72	51.39	47.82	37.33	54.51	44.31
TSF	37.38	50.38	42.87	43.24	63.66	51.46	48.07	57.51	52.32	46.96	64.24	54.21
ES-ASTE	<u>66.43</u>	52.31	59.37	71.01	68.34	69.67	60.26	65.01	62.63	65.18	64.46	64.82
BMRC*	64.89	53.22	58.48	72.92	66.09	69.34	61.82	58.03	59.87	68.88	65.10	66.94
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
DGCNAP	62.02	53.79	57.57	72.90	68.69	70.72	62.23	60.21	61.19	69.75	69.44	69.58
SBRS	62.30	<u>57.47</u>	59.79	72.08	73.09	72.68	<u>62.50</u>	63.69	63.09	66.92	72.00	69.37
Triple-MRC	—	—	60.72	—	—	72.45	—	—	62.86	—	—	68.65
Ours	65.20	57.03	<u>60.84</u>	<u>73.09</u>	73.98	<u>73.53</u>	62.36	<u>65.30</u>	<u>63.80</u>	71.28	74.59	<u>72.90</u>

由表2和表3可知,本文提出的EMT-MRC模型在ASTE-Data-v1和ASTE-Data-v2两个数据集上的精确率(P)、召回率(R)和F1值(F1)3个方面均优于大多数模型。与基准模型BMRC相比,EMT-MRC在v1和v2数据集上的F1值平均高出2.47个百分点和4.11个百分点;与2024年提出的基于端到端方法的SBRS相比,在v1和v2数据集上的F1值平均高出1.88个百分点和1.54个百分点;与2024年提出的基于MRC方法的Triple-MRC相比,在v2数据集上的F1值平均高出1.60个百分点。上述结果表明,EMT-MRC方法具有性能优势。

对表2和表3的对比结果进行性能分析,可以得到几个观察性结论。

首先,采用端到端和基于MRC的模型性能显著优于管道式(Liunified-R和TSF),表明情感三元组抽取中,三元组联合提取的模型相较于管道式模型,减轻了不同抽取阶段的错误传播问题。

其次,相较于端到端方法,在均采用BERT预训练模型编码的情况下,本文模型表现出更优的性能,这表明多轮机器阅读理解方法在有效的模型指导下,能够更好地捕捉方面词、观点词极性之间的复杂关系,从而提升情感三元组抽取的整体效果。

再次,与使用MRC相关方法的双MRC, BMRC和Triple-MRC相比,本文模型表现出更优性能,这一结果侧面反映了句法引导层和任务感知层对MRC相关方法提供的性能增强。具体而言,本文模型通过多轮机器阅读理解逐步细化抽取过程,并结合句法引导层和任务感知层增强了文本表征能力,使得模型在识别长距离依赖和复杂的语义关系方面表现更为出色,这种句法和任务的双重语义增强有效提升了模型在MRC相关任务中的性能,同时增强了模型对ASTE任务中复杂语义中方面-观点对的识别和提取。

最后,在精确率和召回率较平衡的基础上,本文模型在召回率上的性能显著优于其他模型。这一优势主要归功于多轮机器阅读理解中的双向问题和任务感知层的问题与文本的双向注意力流交互,通过模型中的双向设计,提高了模型在情感三元组抽取中的全面性。

4.5 消融实验

本文在ASTE-Data-v2的4个数据集上进行了消融

实验。主要研究内容包括:1)两个特征增强模块对模型性能的贡献分析;2)句法引导中替换不同语义约束策略对注意力分布的影响。

4.5.1 特征增强模块的有效性

本节旨在评估本文提出的两个特征增强模块(句法引导层和任务感知层)对模型性能的影响,实验结果如表4和表5所列,w/o表示删除相应的模型结构。删除句法引导层后,文本和问题仅通过BERT获取向量表征,之后直接输入任务感知层进行双向注意力流交互,生成任务感知表示后送入预测层完成预测。实验结果显示,在ASTE任务中,移除句法引导层后模型在4个数据集上的F1值平均下降了2.24%。在移除了任务感知层的模型实验中,将每轮机器阅读理解的问题和文本拼接后输入BERT编码器。为了遵循单一变量原则,在句法引导层中将问题部分的注意力信息进行掩码处理。去除任务感知层后的模型在4个数据集上的F1值平均下降4.72个百分点。此外,为进一步验证模块有效性,在方面-观点对提取任务(AOPE)上进行了消融实验。作为ASTE任务的关键子任务,AOPE的性能对ASTE的最终效果具有直接影响。本文发现,两个特征增强模块在AOPE任务中的性能提升更为明显,如表5所列,在去除句法引导层和任务感知层后,F1值分别平均下降了4.8个百分点和6.44个百分点。

表4 模块有效性消融实验(ASTE)

Table 4 Ablation experiment of effect of module on ASTE task

	14Lap	14Res	15Res	16Res
Ours	60.84	73.53	63.80	72.90
w/o 句法引导	58.61	71.07	62.20	70.22
w/o 任务感知	57.54	67.19	59.95	67.50

表5 模块有效性消融实验(AOPE)

Table 5 Ablation experiment of effect of module on AOPE task

	14Lap	14Res	15Res	16Res
Ours	73.90	83.58	77.60	81.39
w/o 句法引导	69.51	78.93	70.57	78.27
w/o 任务感知	67.34	77.86	68.70	76.83

综上,句法引导层和任务感知层两个模块都显著增强了模型性能,其中任务感知层对模型性能的影响更大。实验结果表明,通过语法增强和任务感知增强,模型能够更好地理解和建模文本内部以及文本和问题之间的相关性,特别是在方面-观点对提取(AOPE)性能上取得了较大的提升。

4.5.2 不同语义距离影响

为了研究引入依存距离对模型的实际影响,本文新构建了两种不同的注意力引导模块:融入了相对距离的 Transformer 编码器和融入成分句法距离的 Transformer 编码器。相对距离通过一个相对位置矩阵 R 融入, R_{ij} 表示第 i 和第 j 个单词间的距离。成分句法分析采用 Hou 等^[28]的方式,计算每个单词在成分句法树中的句法距离,构建句法距离矩阵 C 。之后采用与依存距离相同的方式,分别将这两种语义距离信息融入自注意力计算式中。本文在 ASTE-Data-v2 的 4 个数据集上和这两种变体模型在 F1 值层面进行了对比,实验结果如表 6 所列。

表 6 不同语义距离影响

Table 6 Effect of different distances

语义距离	14Lap	14Res	15Res	16Res
依存距离	60.84	73.53	63.80	72.90
相对距离	53.54	62.38	51.28	65.50
句法距离	58.90	71.95	61.27	71.06

可以看出,本文使用的融入依存距离的模型取得了最好的结果,采用相对距离的模型结果下降较大。可能的原因有两点:一是 BERT 嵌入时的位置编码与相对位置冲突,二是本文所采用的融合方式不适合相对位置信息的融入。采用句法距离为模型性能带来了一定提升,但相比本文模型在 4 个数据集上 F1 值平均降低 1.97 个百分点。上述结果证明,采用依存距离融合模型带来了积极影响。

4.6 重叠三元组和多词三元组性能研究

现有研究表明^[29],ASTE 任务中,三元组重叠现象和多词三元组会显著影响抽取效果。重叠三元组现象可能导致模型产生方面和观点间错误匹配的问题,多词三元组要求模型具备更强的语义边界识别能力。为深入研究模型对这两种复杂问题的处理能力,本节对上述问题开展了系统的实验研究。

4.6.1 重叠三元组

重叠三元组指句子中方面-观点对出现多对一或多对多关系的情况,如图 6(a)中句子所示,方面词“food”在 3 个三元组中存在重叠。

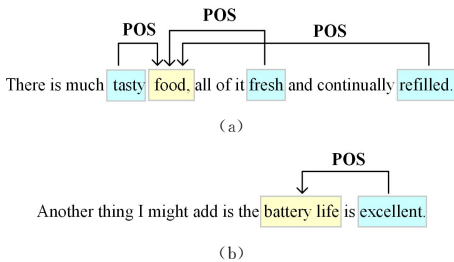


图 6 重叠三元组和多词三元组示例

Fig. 6 Examples of overlapping triplets and multi-word triplets


表 7 列出了 ASTE-Data-v2 上 4 个数据集中重叠三元组的统计数据,OS 和 OT 分别表示重叠三元组的句子数和存在与其他三元组出现重叠的三元组总数,经统计,在 4 个数据集中,含有重叠三元组的句子占比均达到 1/4 左右。为了验证模型处理重叠三元组问题的能力,将每个数据集中包含重叠三元组的句子重新组织为 4 个后处理数据集,并与 BMRC 和 SPAN-ASTE 方法进行对比。实验结果如图 7(a)所示,本文

模型在 4 个后处理数据集上的 F1 值平均比 BMRC 和 SPAN-ASTE 分别高出 5.27 个百分点和 2.71 个百分点,其中在 Res16 数据集上表现最优,分别高出 9.81 个百分点和 5.62 个百分点,结果表明,EMT-MRC 方法在处理重叠三元组问题上更具优势。


表 7 重叠三元组统计

Table 7 Overlapping triplet statistics

	训练集		验证集		测试集	
	OS	OT	OS	OT	OS	OT
14Lap	257	685	59	170	97	270
14Res	367	974	101	277	174	501
15Res	154	399	44	94	66	147
16Res	210	519	52	116	76	180



(a) 重叠三元组



(b) 多词三元组

图 7 后处理数据集对比实验

Fig. 7 Comparative experiment results on post-processed dataset

4.6.2 多词三元组

三元组中的方面词和观点词可能由多个单词组成,如图 6(b)所示,方面词“battery life”由两个单词组成。表 8 中统计了 ASTE-Data-v2 的 4 个数据集中包含多词三元组的句子情况,MS 和 MT 分别表示含多词三元组的句子数量和这些句子所含的三元组总数。为验证模型抽取多词三元组的能力,根据方面词或观点词跨度的长度构建了 4 个多词数据集,并将模型与 BMRC 和 SPAN-ASTE 进行了比较,实验结果如图 7(b)所示,EMT-MRC 在 4 个后处理数据集上的 F1 值平均比 BMRC 高出 1.87 个百分点。SPAN-ASTE 方法使用基于跨度的方法并配合跨度筛选,在多词抽取方面表现较好。但与 SPAN-ASTE 相比,本文模型仍具有一定竞争力。

表 8 多词三元组统计

Table 8 Multi-word triplet statistics

	训练集		验证集		测试集	
	MS	MT	MS	MT	MS	MT
14Lap	361	915	144	359	86	213
14Res	661	1733	286	788	157	424
15Res	267	675	112	275	72	173
16Res	353	890	134	322	92	221

4.7 案例分析

本节在 ASTE-Data-v2 的测试集上选取了一些代表性样本进行案例分析,以验证本文模型的有效性。将模型与 BMRC 和 SPAN-ASTE 进行对比,实验结果如表 9 所列。

BMRC 在案例 1 中没能提取出多词观点“down to earth”,这表明 BMRC 方法对方面、观点的边界识别能力有限。在案例 2 和案例 3 的复杂句法条件下,其未能完全识别所有三元组,这可能是由于 BMRC 单纯利用 BERT 编码,缺少语法层面的特征建模以及对句中方面-观点的长依赖关注。SPAN-ASTE 由于跨度级的提取策略,成功

提取了案例 1 中的多词观点;在案例 2 中提取了所有三元组,但未能正确识别句子情感极性;在面对案例 3 的句法长依赖句中,所有三元组均提取出错,本文认为这源于其跨度级策略忽略了语法层面的特征,导致跨度内部的语义不能被模型学习。相比之下,本文模型利用多轮阅读理解拆分任务,引入依存句法以及问答双向交互注意力流,更好地识别多词边界和长距离依赖下的方面-观点交互,有效解决了多词和重叠问题,完整提取了三元组并正确判断情感极性,进一步证明了其在复杂场景下的性能优势和鲁棒性。

表 9 案例分析
Table 9 Cases study

案例	提取结果
Case1: The staff there is very attentive and down to earth.	Ours: (staff, attentive, POS) ✓ (staff, down to earth, POS) ✓ BMRC: (staff, attentive, POS) ✓ (staff, down, POS) SPAN-ASTE: (staff, attentive, POS) ✓ (staff, down to earth, POS) ✓
Case2: The food was lousy-too sweet or too salty and the portions tiny.	Ours: (food, lousy, NEG) ✓ (food, too sweet, NEG) ✓ (food, too salty, NEG) ✓ (portions, tiny, NEG) ✓ BMRC: (food, lousy, NEG) ✓ (portions, tiny, POS) SPAN-ASTE: (food, lousy, NEG) ✓ (food, too sweet, POS) (food, too salty, POS) (portions, tiny, POS)
Case3: I guess the only good thing that came out of these were the speakers and the subwoofer.	Ours: (speakers, good, POS) ✓ (subwoofer, good, POS) ✓ BMRC: (thing, good, POS) SPAN-ASTE: (good thing, were, NEG) (speakers, were, NEG) (subwoofer, were, NEG)

结束语 本文提出了一种基于特征增强式多轮机器阅读理解的方面级情感三元组抽取方法 EMT-MRC,采用多轮机器阅读理解方法将三元组抽取问题分解为多个子任务并联合训练。在每轮机器阅读理解的答案预测中,本文设计了句法引导层和任务感知层两个特征增强模块。句法引导层将依存距离引入模型实现对文本注意力分布的语义约束,任务感知层设计了双向注意力流构建文本与问题的交互关系,从而获得特定任务感知的文本表示。通过对比实验、消融实验以及探究复杂场景下的模型性能实验,展示了本文模型的性能优势和鲁棒性。

在未来工作中,将从 3 方面继续探索。一是尝试在模型中融入更多的语义特征。在消融实验中发现,模型融入成分句法后性能也有提升,之后尝试构建了同时融入依存句法和成分句法的模型结构,但实验结果并不理想,后续会继续尝试将这两种关键语义特征同时融入模型。二是在更多数据集上进行实验以验证模型。目前,为了验证以及展示模型性能,本文只在情感三元组抽取领域最广泛采用的 ASTE-Data 数据集上进行了实验研究,后续会更多围绕模型鲁棒性展开,尝试在不同数据集上进行实验。三是考虑将目前工作与大模型进行结合,进一步提升模型的性能。

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]. IEEE Transactions on Knowledge and Data Engineering, 2022, 35(11): 11019-11038.

[2] CHEN S, 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.

[3] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C] // Proceedings of the 31st International Conference on Neural Information Processing Systems. 2017: 6000-6010.

[4] CHEN Z, QIAN T. Enhancing aspect term extraction with soft prototypes [C] // Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). 2020: 2107-2117.

[5] WU Z, ZHAO F, DAI X Y, et al. Latent opinions transfer network for target-oriented opinion words extraction [C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2020: 9298-9305.

[6] XUE W, LI T. Aspect Based Sentiment Analysis with Gated Convolutional Networks [C] // Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics. 2018: 2514-2523.

[7] HOU X, FU L, MENG C, et al. Train Once for All: A Transitional Approach for Efficient Aspect Sentiment Triplet Extraction [J]. arXiv: 2412.00208, 2024.

[8] BIE Y, YANG Y. A multitask multiview neural network for end-to-end aspect-based sentiment analysis [J]. Big Data Mining and Analytics, 2021, 4(3): 195-207.

[9] ZHANG H Y, DUAN L G, WANG Q C, et al. Multi-entity sentiment analysis of long text based on multi-task joint training [J]. Computer Science, 2024, 51(6): 309-316.

[10] 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.

[11] LI X, BING L, ZHANG W, et al. Exploiting BERT for End-to-End Aspect-based Sentiment Analysis [C] // Proceedings of the 5th Workshop on Noisy User-generated Text (W-NUT 2019).

- 2019;34-41.
- [12] KENTON J D M W C, TOUTANOVA L K. BERT: Pre-training of deep bidirectional transformers for language understanding [C]//Proceedings of NAACL-HLT. 2019.
- [13] 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.
- [14] 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.
- [15] 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 and the 11th International Joint Conference on Natural Language Processing. 2021;4755-4766.
- [16] LI Y, LIN Y, LIN Y, et al. A span-sharing joint extraction framework for harvesting aspect sentiment triplets[J]. Knowledge-Based Systems, 2022, 242;108366.
- [17] LIU Y, ZHOU Y, LI Z, et al. HIM: An end-to-end hierarchical interaction model for aspect sentiment triplet extraction[J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2023, 31;2272-2285.
- [18] WANG Y, CHEN Z, CHEN S. ES-ASTE: enhanced span-level framework for aspect sentiment triplet extraction[J]. Journal of Intelligent Information Systems, 2023, 60(3);593-612.
- [19] YANG X, PENG T, BI H, et al. Span-level bidirectional retention scheme for aspect sentiment triplet extraction[J]. Information Processing & Management, 2024, 61(5);103823.
- [20] 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.
- [21] 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.
- [22] ZHAI Z, CHEN H, FENG F, et al. COM-MRC: A COntext-masked machine reading comprehension framework for aspect sentiment triplet extraction[C]//Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing. 2022;3230-3241.
- [23] WANG K, LIU Y, ZHANG K, et al. QoMRC: Query-oriented Machine Reading Comprehension Framework for Aspect Sentiment Triplet Extraction[C]//International Conference on Database Systems for Advanced Applications. Singapore: Springer, 2024;173-189.
- [24] ZOU W, ZHANG W, WU W, et al. A multi-task shared cascade learning for aspect sentiment triplet extraction using BERT-MRC[J]. Cognitive Computation, 2024, 16(4);1554-1571.
- [25] ZHANG Z, WU Y, ZHOU J, et al. SG-Net: Syntax guided transformer for language representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 44(6);3285-3299.
- [26] KINGMA D P, BA J. Adam: A method for stochastic optimization[J]. arXiv;1412.6980, 2014.
- [27] LI Y, HE Q, ZHANG D. Dual graph convolutional networks integrating affective knowledge and position information for aspect sentiment triplet extraction [J]. Frontiers in Neurobotics, 2023, 17;1193011.
- [28] HOU S, KAI J, XUE H, et al. Syntax-guided Localized Self-attention by Constituency Syntactic Distance[C]//Findings of the Association for Computational Linguistics; EMNLP 2022. 2022;2334-2341.
- [29] GAO L, WANG Y, LIU T, et al. Question-driven span labeling model for aspect-opinion pair extraction[C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2021;12875-12883.



HAO Yuanbin, born in 1999, postgraduate, is a member of CCF (No. Z0508G). His main research interest is sentiment analysis.



DUAN Ligu, born in 1970, professor, is a member of CCF (No. 15823S). His main research interest is natural language processing.

(责任编辑:何杨)