

图注意力与语义强化机制的方面情感三元组抽取^①



雷海卫, 王志英

(中北大学 计算机科学与技术学院, 太原 030051)

通信作者: 王志英, E-mail: 1968306728@qq.com

摘要: 为提升方面情感三元组抽取 (aspect sentiment triplet extraction, ASTE) 的准确性和效率, 本文提出了一种结合图卷积和图注意力网络的 ASTE 模型, 模型引入图卷积网络, 结合双向机器阅读理解框架, 进一步集成了多头图注意力网络, 利用其自注意力机制动态分配权重, 增强了模型对文本中复杂和隐含语义关系的识别能力, 提升了对情感表达的精准捕捉. 在此基础上, 引入对比学习以增强全局语义特征, 结合强化学习, 通过智能体与环境交互、依据奖励反馈优化策略, 促使模型更精准地识别三元组. 在 4 个公开数据集上的广泛实验验证了模型在 ASTE 任务上的卓越性能, 和现有的模型相比, 准确率、召回率和 $F1$ 值均有显著提升.

关键词: 方面情感三元组抽取; 图卷积网络; 图注意力网络; 对比学习; 强化学习

引用格式: 雷海卫, 王志英. 图注意力与语义强化机制的方面情感三元组抽取. 计算机系统应用, 2025, 34(10): 110-121. <http://www.c-s-a.org.cn/1003-3254/9965.html>

Aspect Sentiment Triplet Extraction of Graph Attention and Semantic Reinforcement Mechanism

LEI Hai-Wei, WANG Zhi-Ying

(School of Computer Science and Technology, North University of China, Taiyuan 030051, China)

Abstract: To enhance the accuracy and efficiency of aspect sentiment triplet extraction (ASTE), this study proposes an ASTE model that integrates graph convolution networks with graph attention networks. The model incorporates graph convolution networks within a bidirectional machine reading comprehension framework and further integrates a multi-head graph attention mechanism. By leveraging self-attention, dynamic weight allocation is achieved, enabling more effective identification of complex and implicit semantic relationships and more precise extraction of sentiment expressions. In addition, contrastive learning is employed to enhance global semantic representations, and reinforcement learning is introduced to refine the extraction strategy through agent-environment interaction and reward-guided optimization. Extensive experiments conducted on four public datasets demonstrate that the proposed model achieves superior performance on the ASTE task, with significant improvements in accuracy, recall, and $F1$ compared to existing approaches.

Key words: aspect sentiment triplet extraction (ASTE); graph convolutional network (GCN); graph attention network (GAT); contrast learning; reinforcement learning (RL)

1 引言

近年来, 在细粒度意见挖掘领域^[1], ASTE 任务受到了广泛关注^[2]. ASTE 旨在从文本中抽取与特定方面

相关的意见表达, 并确定其情感倾向. Mukherjee 等^[3]提出了一种对比学习预训练策略, 通过使用方面提示和情感掩盖预训练编码器-解码器模型, 并结合多任务

① 收稿时间: 2025-02-28; 修改时间: 2025-03-28; 采用时间: 2025-04-11; csa 在线出版时间: 2025-08-28

CNKI 网络首发时间: 2025-08-29

微调方法进行意见项检测和三元组计数。Mukherjee 等^[4]提出无标签端到端方法,利用指针网络解码,克服了现有序列和网格标记在捕获意见因素依赖性和识别重叠三元组上的不足。然而,尽管基于跨度的方法可以识别实体,但仍可能忽略复杂依赖关系和全局上下文信息。Chen 等^[5]将 ASTE 任务转化为多轮双向阅读理解任务,设计了 3 种类型的查询以建立子任务间的关联。但是该方法在处理上下文之间的复杂关系时仍存在局限性,无法有效聚合局部区域内的语义特征,且难以灵活捕获词与词之间的复杂和隐含关系。针对以上问题,本文在现有研究基础上做出改进,引入了图卷积网络(graph convolutional network, GCN)和多头图注意力网络(graph attention network, GAT)。融合 BERT 编码的深度语义特征与依存树的语法信息,通过设计 GCN 和 GAT 的结合,显著提升对文本中词与词之间复杂语义依存关系及隐含联系的捕捉能力。模型通过多头图注意力机制有效并行处理文本的多维度语义特征,显著提升了情感倾向的识别精度。结合双向查询的深度分析,能够全面捕捉文本中的复杂情感细节。

尽管上述模型在 ASTE 任务中取得了一定成果,但仍存在局限性。图卷积和图注意力网络在处理复杂语义关系时,依赖局部结构信息,致使对全局语义的理解不够精准。例如,在处理长文本或语义关系隐晦的评论时,难以全面捕捉远距离词之间的潜在关联,易造成信息缺失或误判。原模型在训练过程中缺乏有效的自我监督与动态调整机制,对不同文本数据的适应性相对固定,难以根据 ASTE 任务的特定目标灵活优化模型决策。为克服这一缺陷,本文在原有模型基础上进一步改进,引入对比学习和强化学习。对比学习通过构建正负样本对,使模型从更宏观的语义视角区分不同文本表征的差异,有助于打破图结构带来的局部性限制,促使模型关注全局语义特征的共性与差异。例如,对比同一产品不同评价中方面词相同但情感极性相反的文本对,能让模型更深入地理解语义变化对情感表达的影响,从而有效提升对长距离或复杂语义关系中关键信息的捕捉能力,增强对文本整体语义的感知与分析精度,为更准确地判断方面与情感的关联提供有力支持。在处理 ASTE 任务相关文本时,强化学习依据预先设定的奖励机制,根据模型在提取方面词、识别观点以及判断情感极性等任务上的表现给予反馈,进而引导模型调整自身行为。这一机制弥补了图卷积与图注意力网络缺乏动态

决策优化的不足,显著提高了模型对不同类型文本任务的适应性与准确性,确保模型在复杂多变的 ASTE 任务场景中能够更精准地输出方面、观点与情感的三元组信息,有力提升了整体任务的完成效果。

2 相关工作

2.1 ASTE

ASTE 主要沿着两条研究路径发展:管道化提取方法和联合提取方法。Peng 等^[2]提出两阶段管道方法处理框架,第 1 阶段预测方面术语、情感表达及其原因;第 2 阶段输出三元组。该方法为细粒度情感分析提供了新的视角,但可能因错误传播和子任务间交互缺失而受限。与管道方法不同,联合提取方法试图在一个统一的框架内同时解决所有子任务,以减少错误传播并提高整体性能。该方法可分为基于跨度和基于深度学习的方法。Xu 等^[6]提出的基于跨度的方法通过明确考虑目标和观点的完整语义交互,并采用双通道跨度剪枝策略。Yan 等^[7]利用预训练序列到序列模型 BART 来解决端到端框架中的所有 ABSA 子任务。Chen 等^[8]利用两个 Transformer 解码器和多头注意力机制来分别提取方面和意见实体,从而提高长实体识别的准确性并减少级联错误。Zhang 等^[9]提出边界驱动表填充,通过检测和分类关系区域改进三元组表示,并开发学习方法增强单词与关系间的交互。余军等^[10]将 ASTE 问题转换成集合预测问题,以端到端的方式进行三元组提取。

2.2 GCN

GCN^[11]是一种在图结构数据上应用卷积操作的神经网络。GAT 是 GCN 的一个扩展,它在 GCN 中引入了注意力机制,允许模型在聚合邻居信息时,更为灵活地为不同邻居分配不同权重。高龙涛等^[12]利用方面感知注意力和图卷积网络结合双仿射注意力机制和词对细化策略精确抽取情感三元组。赵园春等^[13]通过设计词对标记方案和使用结点自适应网络挖掘句法信息,结合卷积注意力捕捉语义依赖。Jiang 等^[14]提出了一个结合 BERT 基础编码器和 Bi-LSTM-GCN 特定编码器的框架,并通过依赖树建模增强语义理解。Peng 等^[15]通过将表格关系转化为图,并利用提示注意力分数确定边权重,构建目标感知图以增强提取过程,随后应用三通道卷积模块精确提取情感知识。石恽本等^[16]提出一种融合句法结构的 BERT 预训练模型,通过注意力层和图卷积网络增强词对间语义关系学习。Chen 等^[17]提

出一种增强型多通道图卷积网络模型来充分利用单词之间的关系。Shi 等^[18]提出了一种基于多分支 GCN 的模型,采用结构化 BERT 增强语义特征,并通过双仿射注意力模块细化特征,改善不同文本特征间的交互作用。Yang 等^[19]提出多域 ABSA 的特征感知上下文学习框架,通过多头图注意力网络优化文本编码,并利用对比学习优化句子表示。杨芳捷等^[20]提出了一种融合语法结构和语义信息的提取模型,使用 LAL-Parser 依赖解析模型构建语法图,自注意力机制构建语义图,并通过相互仿射变换层优化特征交换。

2.3 对比学习

在 ASTE 领域,对比学习已成为一项重要的研究方向, Yang 等^[21]提出了一种 ASTE 配对增强方法,该方法在训练阶段结合对比学习,将方面-意见配对知识注入三元组提取模型中。Yu 等^[22]将检索到的语义相似三元组的标签信息整合到目标对的增强表示中并通过对比学习将这些信息融入当前文本的处理过程中,从而更准确地预测最终情感。Xu 等^[23]提出了一种具有图注意力网络和对比学习的双重增强生成模型 GAC,它将图注意力网络与对比学习相结合,并且第 1 个探索了图神经网络与生成模型的集成,有效解决了现有生成式模型在处理具有复杂结构和多词项的句子时遇到的挑战。Xiong 等^[24]开发了一个三元组对比学习网络来协调句法信息和语义信息,提出了句子级对比学习方案来突出情感词的特征,基于三重对比学习,句法信息和语义信息充分交互和协调,可以同时利用全局语义和句法。Sun 等^[25]提出了一种集成极简标签方案和新型令牌级对比学习策略来改进和利用预训练表示的方法。Mukherjee 等^[3]设计基于方面的提示,并掩盖相应的情感,通过对解码器生成的屏蔽术语的方面感知情感表示应用对比学习来训练编码器-解码器模型。

2.4 语义强化

Zhang 等^[26]提出了 ASTE 的目标到源增强方法。该方法侧重于学习一个可根据标签和句法模板直接生成新句子的生成器,为确保生成句子的质量,引入流畅性和对齐判别器来提供对生成句子的反馈,利用该反馈并通过强化学习框架来优化生成器。Obiedat 等^[27]使用强化学习减少对大型语言资源(例如字典)的需求,以理解基于词典的方法中所见的情感歧义。Keerthana 等^[28]认为更高的强化学习性能包含更高的累积奖励,有助于引发积极的人类情绪。Zhao 等^[29]提出了一种增强依赖

图卷积网络(RDGCN),通过所提依赖树上最小距离的重要性计算标准,并设计距离重要性函数,利用强化学习进行权重分布搜索和相异性控制,以及针对依赖类型无显式语法使用全局注意力和掩码机制设计类型重要性函数,最后合并权重实现特征聚合和分类,从而改进距离和类型视图中依赖关系的重要性计算。Wu 等^[30]提出了一种基于方面的词库和语法增强意见归纳树的情感分析模型,具体而言,通过强化学习和注意力机制,将词汇知识和语法知识(即短语结构和依赖关系)整合在一起,为每个方面词引入知识感知意见归纳树,建立了基于知识感知意见归纳树的 ABSA 图神经网络。Dai 等^[31]提出了一种填充增强强化学习模型,通过设计多重异构图,将文本的顺序结构和句法结构涵盖其中,以此丰富节点间的相互作用并缓解长距离问题,将提取任务形式化为马尔可夫决策过程,让模型在设计好的图上进行游走推理,以找到每个方面对应的意见,利用强化学习的延迟奖励机制来优化模型的决策过程。

3 方法

3.1 问题描述

给定一个带有 N 个标记的评论句子 $W=\{w_1, w_2, \dots, w_N\}$, ASTE 任务旨在识别三元组 $T=\{(a_i, o_i, s_i)\}$ 的集合,其中, a_i 、 o_i 和 s_i 分别表示评论中描述的方面、表达的观点和对应的情感。

3.2 模型整体框架

图 1 展示了本文所提模型的整体框架。向编码器输入一个句子,由 BERT 对基本语义进行编码,捕捉每个词的上下文含义;随后根据识别出的依存关系构建依存树以进行细粒度的分析;GCN 结合 BERT 的深度语义特征,分析依存树的语法信息,进一步捕获词与词之间的语义依存关系,加强局部语义特征聚合;通过双向机器阅读理解框架对句子进行深入分析,提供双向的语义增强,抽取方面和观点的对应关系;多头图注意力网络将双向查询的输出与 GCN 的表征相结合,引入邻接矩阵,通过自注意力机制动态地为节点邻居分配权重,使模型能够更加灵活地捕获节点间的复杂关系,并通过多头注意力学习多个表示子空间,从而捕获到更丰富的语义信息。在此基础上,对比学习模块以 GCN 和 GAT 处理前的文本数据构建正、负样本对作为输入,经对比损失函数引导模型从宏观语义视角区分文本表征差异,打破图结构局部性限制,关注全局语义特

征共性与差异,将优化后的特征反馈给双向查询模块增强关键信息捕捉能力;语义强化模块以模型在提取方面词、识别观点及判断情感极性等任务的输出为输入,依据预设奖励机制输出调整后的模型决策策略,引导模型调整行为.最后通过情感分类查询预测每个方面的极性,模型融合不同查询的答案形成三元组(方面,观点,情感).

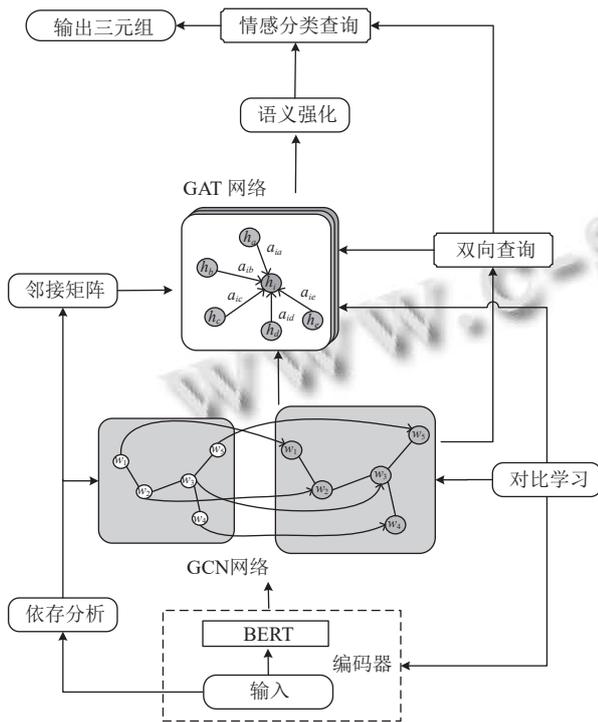


图1 模型整体框架图

3.3 编码模块

基于 BERT 强大的上下文理解能力和预训练优势,将其作为文本编码器.给定一个评论句子 W ,它由 N 个标记组成.首先,将标记与评论句子 W 合并,形成一个新的输入序列,这个序列以特定的标记[CLS]开始,以 [SEP]标记结束,中间穿插查询和评论中的标记.将这些初始表示 E 作为输入,使用 BERT 模型进行编码. BERT 通过一系列 Transformer 层来处理初始表示序列,生成一系列隐藏表示 H .该过程可以表示为:

$$H = BERT(E) \quad (1)$$

3.4 图卷积模块

依存树和 GCN 的结合能够提供更丰富的语义信息,帮助模型更准确地完成观点抽取任务.使用 spaCy 工具包来解析句子,并进一步构建句法依存图.利用依存树中的词及其依存关系来构建图,从而获得更长距

离的依存关系.将文本中的词语构建依存树,该树表示了词与词之间的直接联系,其中词语作为节点,语法依赖作为边,从而创建一个结构化的语法网络;将 BERT 预训练的输出 H 作为输入特征,对相应的依存树进行多层图卷积运算,得到语法增强的上下文表示 h_b .该过程可表示为:

$$h_b^l = \sigma(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} h_b^{l-1} W^{l-1}) \quad (2)$$

其中, h_b^{l-1} 表示每层的特征,对于输入层, $h_b^0 = H$. σ 是激活函数, W 表示每层的可训练参数. A 是 0-1 邻接矩阵,记录单词之间的连通状态,依据图的边集 G 重新定义取值的邻接矩阵. D 是度矩阵,记录每个节点的邻居数量, \tilde{D} 是通过将 A 的列求和得到的度矩阵. \tilde{A} 和 \tilde{D} 生成表示为:

$$\tilde{A} = \begin{cases} 1, & (w_i, w_j) \in G \\ 0, & (w_i, w_j) \notin G \end{cases} \quad (3)$$

$$\tilde{D}_{ij} = \sum_j \tilde{A}_{ij} \quad (4)$$

其中, (w_i, w_j) 表示节点 w_i 和 w_j 之间的边, G 表示图中的边集. $(w_i, w_j) \in G$ 表示图中存在从 w_i 到 w_j 的边.在每一层的图卷积中,每个节点 w_i 都会综合其相邻节点 w_j 的属性,通过邻接矩阵所定义的权重来调整自己的特征表示.具体来说,使用归一化的图卷积公式更新依存树上的节点,先定义节点 i 的更新操作 \tilde{g}_i 为:

$$\tilde{g}_i = \sum_{j=1}^n A_{ij} W g_j \quad (5)$$

其中, A_{ij} 代表矩阵 A 中的第 i 行第 j 列的元素, g_i 是节点 i 的特征向量,为了减少不同节点由于度数不同而引起的特征尺度差异,引入归一化操作,使用节点 i 在依赖关系树上的度数 d_i 对 \tilde{g}_i 进行归一化:

$$d_i = \sum_{j=1}^n A_{ij} \quad (6)$$

$$g_i = \frac{1}{d_i + 1} \tilde{g}_i \quad (7)$$

其中, $d_i + 1$ 用于避免除以 0 的情况,并确保归一化后的节点特征向量保持稳定.进一步地,对归一化后的节点特征向量 g_i 应用 $ReLU$ 激活函数,引入非线性:

$$g_i = ReLU(g_i + b) \quad (8)$$

其中, b 是可训练的偏置参数.这种特征融合过程允许模型在保持局部语义信息的同时,也捕捉到更广泛的上下文信息.通过依存树引导的图卷积运算,模型不仅学习了词与词之间的语义关联,还学习了它们之间的语法结构,有助于更准确地识别文本中的观点和方面.

在获得了经过语法增强的上下文表示 h_b 之后, 可以进一步利用这些特征来进行情感极性的预测, 从而完成观点抽取任务.

3.5 双向查询模块

通过双向查询, 可以从两个维度全面理解文本内容, 从而更准确地抽取观点并情感分类. 首先, 从方面到观点的提取查询如下.

- 非限制性查询: 查询“文本中提及了哪些方面”, 来提取文本中的方面集合.

- 限制性查询: 查询“对于每个方面, 文本中表达了哪些具体的观点”, 来提取每个方面的具体观点集合.

其次, 从观点到方面的提取查询如下.

- 非限制性查询: 查询“在文本中讨论的观点有哪些”, 来提取与每个观点相关的文本片段集合.

- 限制性查询: 查询“每个观点描述了哪些方面”, 来识别每个文本片段所对应的方面集合.

通过上述双向查询, 观点实体提取和关系检测自然地融合在一起, 且通过限制性提取查询可以很好地学习它们之间的依赖关系.

3.6 多头图注意力网络

为了进一步细化和丰富节点间的语义关系, 将经过双向查询增强的图结构 G' 输入到 GAT 中. GAT 通过自注意力机制为图中的每条边分配权重, 捕获更细微的语义联系, 从而更有效地建立目标词和情感之间的关系. GAT 由多个图注意力层组成, 单层的图注意力更新机制如图 2.

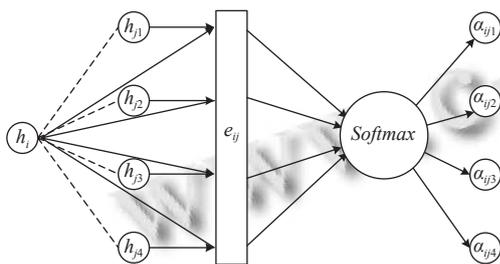


图 2 图注意力神经架构

首先, 定义第 i 层的输入和输出节点特征向量集合为 $h = \{\vec{h}_1, \vec{h}_2, \dots, \vec{h}_N\}$ 和 $h' = \{\vec{h}'_1, \vec{h}'_2, \dots, \vec{h}'_N\}$, 其中, $\vec{h}_i \in \mathbb{R}^F$, $\vec{h}'_i \in \mathbb{R}^F$, N 和 F 分别为节点个数和特征个数. 每个节点的特征通过共享权重矩阵 W 进行线性变换, 得到式 (9):

$$Z^i = Wh^i \quad (9)$$

然后采用自适应邻接矩阵作为标记向量的特征传播矩阵. A^{Lig} 表示语言特征对应的自适应邻接矩阵, 可通过式 (10) 计算:

$$A^{Lig} = Sigmoid(HW^{Lig}H^T) \quad (10)$$

其中, W^{Lig} 是语言特征的可学习权重. 第 i 个和第 j 个标记之间的注意力系数 α_{ij} 计算如式 (11):

$$\alpha_{ij} = \frac{\exp(LeakyReLU(\vec{d}^T[W_a\|W_a h_j]))}{\sum_{A_{ik}^{Lig} > \delta} \exp(LeakyReLU(\vec{d}^T[W_a h_j\|W_a h_k]))} \quad (11)$$

其中, δ 作为阈值, 用于滤除邻接矩阵中的噪声, \vec{d} 和 W_a 是可学习权重, $\|$ 表示 i 和 j 的向量拼接, \vec{d}^T 表示将拼接向量转化为标量. 然后, 利用归一化的注意力系数 α_{ij} 来预测每个节点的输出特征:

$$h^i = \sigma\left(\sum_{j \in N_i} \alpha_{ij}^l W h^j\right) \quad (12)$$

为了稳定自注意力机制的学习过程, 采用多头注意力机制, 其中 k 个独立的注意力头并行处理, 并将它们的特征连接起来, 得到最终的输出特征表示:

$$h^{(i)} = \sigma\left(\frac{1}{k} \sum_{k=1}^K \sum_{j \in N_i} \alpha_{ij}^{l,k} W^k h^j\right) \quad (13)$$

其中, σ 是激活函数, K 是注意力头的数量. 这种设计不仅提高了模型对复杂语义关系的捕捉能力, 而且通过灵活的权重分配, 增强了对不同上下文信息的敏感性. 最后, 设计情感分析查询来对观点方面的情感进行分类, 细化观点表达, 以提高整体的准确性和解释性.

3.7 对比学习模块

本文所构建的对比学习模块如图 3 所示.

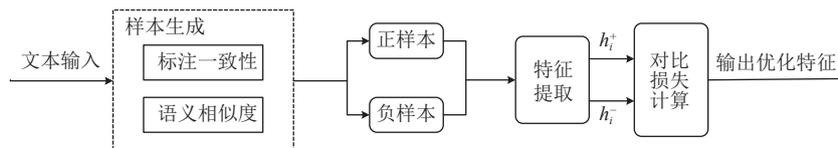


图 3 对比学习模块图

3.7.1 正负样本对构建

从标注一致性和语义相似度两个维度构建正样本对.

基于标注一致性的构建过程: 由数据集标注可知, “T-POS”和“T-NEG”分别表示对特定目标的积极和消

极相关标注;“S”表示对描述性词语的关键程度标注;“O”表示其他描述. 设定规则: 当两条文本关键标注元素所属类别相同且描述方面相近, 则构成正样本对候选. 设数据集 D 有 n 条数据, 包含文本 T_i 与标注 A_i . 遍历文本 T_i 与 A_i , 函数 $SAC(A_i, A_j)$ 判断标注类别 (如均为“T-POS”或“T-NEG”则为相同); 函数 $SA(A_i, A_j)$ 判断描述方面是否相近. 当两者都为真时, (T_i, T_j) 构成的正样本对集合 P_1 可以表示为:

$$P_1 = \{(T_i, T_j) \mid SAC(A_i, A_j) = \text{True} \wedge SA(A_i, A_j) = \text{True}, T_i, T_j \in D, i \neq j\} \quad (14)$$

基于语义相似度构建过程可以表示为: 将数据集中的文本输入到预训练的 BERT 模型中. BERT 模型会对文本进行深度处理, 将每个文本转化为一个固定维度的向量表示. 设文本 T_i 经过 BERT 编码后得到的向量为 h_i , 其维度为 d , 即 $h_i \in R^d$. 对于文本 T_i 及其向量 h_i , 需要计算它与数据集中其他文本 T_j 的向量 h_j 之间的余弦相似度. 余弦相似度公式为:

$$\begin{aligned} \text{CosineSimilarity}(h_i, h_j) &= \frac{h_i \cdot h_j}{\|h_i\| \|h_j\|} \\ &= \frac{\sum_{k=1}^d h_{i,k} h_{j,k}}{\sqrt{\sum_{k=1}^d h_{i,k}^2} \sqrt{\sum_{k=1}^d h_{j,k}^2}} \end{aligned} \quad (15)$$

设定阈值 t , 如果 $\text{CosineSimilarity}(h_i, h_j) \geq t$, 则将 (T_i, T_j) 视作基于语义相似度的正样本集合 P_2 :

$$P_2 = \{(T_i, T_j) \mid \text{CosineSimilarity}(v_i, v_j) \geq t, T_i, T_j \in D, i \neq j\} \quad (16)$$

最终正样本对集合为 $P = P_1 \cup P_2$.

类似的, 对于负样本对, 设函数 $DAC(A_i, A_j)$ 判断标注差异, (T_i, T_j) 构成负样本对集合 N_1 :

$$N_1 = \{(T_i, T_j) \mid DAC(A_i, A_j) = \text{True}, T_i, T_j \in D, i \neq j\} \quad (17)$$

计算文本向量的欧几里得距离 $d(v_i, v_j)$, 设定阈值 t_d , 若距离大于 t_d , 则 (T_i, T_j) 作为基于语义差异的负样本对收集到集合 N_2 , 该过程表示为:

$$d(v_i, v_j) = \sqrt{\sum_{k=1}^m (v_{i,k} - v_{j,k})^2} \quad (18)$$

$$N_2 = \{(T_i, T_j) \mid d(v_i, v_j) > t_d, T_i, T_j \in D, i \neq j\} \quad (19)$$

最终负样本对集合为 $N = N_1 \cup N_2$.

3.7.2 对比损失函数

采用 InfoNCE 损失函数指导学习. 设 h_i 为 anchor

样本向量, h_i^+ 为正样本向量, h_i^- 为负样本向量. 通过余弦相似度函数计算相似度. 该函数表示为:

$$\text{sim}(h_i, h_j) = \frac{h_i \cdot h_j}{\|h_i\| \|h_j\|} \quad (20)$$

InfoNCE 损失函数为:

$$\begin{aligned} L_{\text{contrast}} &= \\ &= - \sum_{i=1}^N \log \frac{\exp(\text{sim}(h_i, h_i^+))}{\exp(\text{sim}(h_i, h_i^+)) + \sum_{j=1}^M \exp(\text{sim}(h_i, h_j^-))} \end{aligned} \quad (21)$$

其中, N 为 anchor 样本数量. 模型训练时, 依此损失函数调整参数, 拉近正样本与 anchor 样本距离, 推远负样本与 anchor 样本距离, 学习区分性特征表示. 总体损失函数 L 表示为:

$$L = L_{\text{basic}} + \beta L_{\text{contrast}} \quad (22)$$

其中, β 为平衡系数, L_{basic} 为基本损失函数, L_{contrast} 为对比损失函数. 通过调整 β , 依据任务需求与数据特点控制对比学习影响力, 使模型在不同学习目标间平衡, 实现更优性能与精准结果输出.

3.8 语义强化模块

语义强化模块主要由 3 个组件构成, 分别是面向方面的情感分类、意见词提取和方面词提取, 且呈现出两级层次结构.

3.8.1 情感分类组件

在高层情感分类过程中, 智能体对句子进行顺序扫描时, 会依据当前状态判断是否检测到针对方面词的情感, 其中智能体是指在强化学习框架中负责执行决策并与环境交互的实体. 其当前状态由多个关键部分组成. 高层情感分类状态 s_t^u 状态除了从预训练 BERT 模型获取并在数据集上微调的当前隐藏状态 h_t 、借助词性标注工具 spaCy 得到的词性 POS 标签 p_t 、反映情感极性的向量 v_t^c 以及前一时间步的高层状态 s_{t-1}^u 外, 还进一步融入了双向查询的结果信息, 包括方面集合信息 A_t 和观点集合信息 O_t . 这些信息综合起来, 经由多层感知机 MLP 实现的非线性函数 f_s^u 处理后, 通过特定策略确定情感选项的概率分布. 其状态表示公式更新为:

$$s_t^u = f_s^u(W_s^u[h_t; p_t; v_t^c; s_{t-1}^u; A_t; O_t]) \quad (23)$$

其中, W_s^u 是可学习的权重矩阵; h_t 携带了句子丰富的语义信息; p_t 有助于剖析语法结构对情感表达的潜在影响; v_t^c 则体现了情感的连贯性和变化趋势; 双向查询获取的 A_t 和 O_t 主要用于辅助判断句子的整体情感态势.

低层情感分类状态 s_t^l 除了包含类似的 h_t 和 p_t 、意见/方面标签向量 $v_t^{O,A}$ 、前一时间步的低层状态 s_{t-1}^l 、上下文向量 v_t^{ctx} 和BERT模型的[CLS]输出向量 h_t^{CLS} 外,还加入了针对当前情感相关的方面和观点的详细双向查询结果 A_t^{detail} 和 O_t^{detail} .其状态表示公式为:

$$s_t^l = f_s^l(W_s^l[h_t; p_t; v_t^{O,A}; s_{t-1}^l; v_t^{ctx}; h_t^{CLS}; A_t^{detail}; O_t^{detail}]) \quad (24)$$

其中, f_s^l 是由MLP实现的非线性函数, W_s^l 是可学习的权重矩阵. v_t^{ctx} 和 h_t^{CLS} 使得低层能够更好地结合高层情感判断结果和句子的全局语义信息,例如在处理复杂句子结构时,能借助高层信息更精确地识别出哪些词属于当前情感下的方面词或意见词,而 $v_t^{O,A}$ 则直接与标签预测紧密相关.

3.8.2 策略网络架构

在高层情感分类过程中,策略网络采用多层感知机(MLP)结构,具体架构如下.

- 输入层: 输入维度为 D_{input} ,包括当前隐藏状态 h_t 、词性标签 p_t 、情感极性向量 \vec{s} 、前一时间步的高层状态 \vec{h}_{t-1} 以及双向查询结果 A_t 和 O_t .

- 隐藏层: 包含两层全连接层,第1层输出维度和第2层输出维度为 D_{hidden} ,每层后接ReLU激活函数.

- 输出层: 输出维度为 D_{output} ,即情感分类的类别数(如positive、negative、neutral等),使用Softmax函数将输出转换为概率分布.

在低层情感分类过程中,策略网络同样采用多层感知机结构,具体架构如下.

- 输入层: 输入维度为 D'_{input} ,包括当前隐藏状态 h_t 、词性标签 p_t 、意见/方面标签向量 \vec{s} 、前一时间步的低层状态 \vec{h}_{t-1}^l 、上下文向量 \vec{c} 、BERT模型的[CLS]输出向量 \vec{c}_{CLS} 以及针对当前情感相关的方面和观点的详细双向查询结果 \vec{A}_{detail} 和 \vec{O}_{detail} .

- 隐藏层: 包含两层全连接层,第1层输出维度和第2层输出维度为 D'_{hidden} ,每层后接ReLU激活函数.

- 输出层: 输出维度为 D'_{output} ,即动作标记的类别数(如B、I、O等),使用Softmax函数将输出转换为概率分布.

3.8.3 策略奖励机制

本文采用了一种分层策略网络结构,包含高层情感分类策略网络和低层序列标注策略网络两个主要组成部分.

高层策略网络接收维度为300的状态向量作为输

入,通过特征融合层整合双向查询结果,其中采用门控机制实现信息筛选:

$$g_t = \sigma(W_g[h_t; A_t; O_t]) \quad (25)$$

$$\tilde{h}_t = g_t \odot MLP([h_t; A_t; O_t]) \quad (26)$$

其中, $W_g \in \mathbb{R}^{3d_h \times d_h}$ 为可学习参数, \odot 表示逐元素相乘.

$$\pi^{high}(o_t | s_t^{high}) = \text{Softmax}(W_p \tilde{h}_t + b_p) \quad (27)$$

低层策略网络与高层共享BERT编码层和GAT特征,通过条件投影层将高层动作嵌入为条件向量 $e_t \in \mathbb{R}^{50}$,在联合推理层实现细粒度预测:

$$u_t = \text{ReLU}(W_u[h_t; e_t; c_t] + b_u) \quad (28)$$

$$\pi^{low}(a_t | s_t^{low}) = \text{Softmax}(W_a u_t + b_a) \quad (29)$$

该架构通过参数共享、梯度裁剪($\gamma = 1.0$)和层归一化等设计,有效缓解了参数敏感问题.

高层情感分类策略 π_u 依据更新后的状态 s_t^u 确定情感选项的概率分布,公式为:

$$O_t \sim \pi_u(O_t | s_t^u) = \text{Softmax}(W_\pi^u s_t^u) \quad (30)$$

其中, O_t 从 $L^C = \{\text{none, positive, negative, neutral}\}$ 中选择.在奖励机制方面,每个时间步会根据选项执行情况给予不同奖励,若检测到有效情感(即 O_t 在句子中实际存在的有效情感选项集合 X 中)时奖励1.0,预测错误时惩罚-0.2,部分匹配时给予0.1的中间奖励.此外,若在某个时间步检测到针对方面词的情感(即 $O_t \neq \text{none}$),智能体将启动两个低层RL过程进行意见和方面词提取,完成后返回高层继续扫描句子.当所有选项采样完成(即整个分层RL过程结束),高层过程有最终奖励:

$$r_{final}^u = F_1(X) \quad (31)$$

其中, X 是句子中实际存在的有效情感选项集合, F_1 是 X 中情感的精度和召回率的调和均值.双向查询的结果在一定程度上影响最终奖励的获取,因为更准确地方面和观点识别有助于提高情感精度和召回率,进而提高最终奖励.

低层情感分类策略 π_l 根据低层状态 s_t^l 和启动当前子任务的高层选项 O_t^l 确定每个动作的概率分布,公式为:

$$a_t \sim \pi_l(a_t | s_t^l; O_t^l) = \text{Softmax}(W_\pi^l [O_t^l; s_t^l]) \quad (32)$$

其中, W_π^l 是权重矩阵.双向查询信息的融入,使得策略在选择动作(如B、I、O标记)时,能够更好地结合文本的语义结构及已识别的方面、观点关系,从而提高

标签标记的准确性. 在奖励机制上, 低层序列标注任务则包含 3 个维度的奖励: 边界奖励根据 B/I/O 标签的预测正确性分别给予 0.5、0.3 和 0.1 的奖励; 一致性奖励在方面-观点对匹配真实三元组时额外奖励 0.2; 语法奖励通过 POS 标签验证预测合理性, 如形容词作为观点词时奖励 0.1. 最终奖励函数整合各个维度的贡献.

$$R = \sum_{t=1}^T (\alpha R_t^{\text{high}} + \beta R_t^{\text{low}}) + \lambda r_{\text{consist}} + \eta r_{\text{grammar}} \quad (33)$$

其中, $\alpha=0.6$ 、 $\beta=0.3$ 、 $\lambda=0.1$ 为平衡系数, 通过课程学习动态调整, 如下:

$$\eta = \min(0.05 \times \text{epoch}, 0.2) \quad (34)$$

双向查询的结果对奖励有重要影响, 准确的双向查询能提高标签预测的准确性, 进而增加获得高奖励的概率. 在策略优化算法方面, 本文采用 PPO 算法进行模型训练, 优势估计 GAE ($\lambda=0.95$, $\gamma=0.99$), 重要性采样设置 clip 范围 $\epsilon=0.2$, 多目标优化可以表示为:

$$L = E[L_{\text{clip}} + 0.01L_{\text{value}} + 0.02H(\pi)] \quad (35)$$

其中, $H(\pi)$ 为策略熵正则项.

3.8.4 训练流程

首先进行预训练, 使用真实选项或动作对模型进行 40 个 epoch 的预训练, 学习率设置为 $2E-5$. 在这个过程中, 双向查询的结果也参与到模型的学习中, 帮助模型更快地掌握文本的语义结构和常见的方面、观点、情感组合模式. 同时, 预训练过程可以限制智能体在高维状态空间中的探索, 防止其陷入不合理的情况, 例如避免出现 I 标签在 B 标签之前等错误情况, 从而加快学习速度.

接着进入微调阶段, 基于开发集 (Dev) 的 $F1$ 分数选择最佳模型, 然后使用 RL 策略对其进行 15 个 epoch 的微调, 学习率调整为 $5E-6$. 在 RL 微调过程中, 每个数据点采样 5 条轨迹, 且在每次采样时都充分利用双向查询的结果来优化模型. 在模型训练过程中, BERT 参数从预训练权重初始化并更新, 情感极性和意见/方面标签嵌入维度设为 300, POS 嵌入维度设为 25, 状态向量维度 s_t^a 和 s_t^s 设为 300. 在 f_s^a 和 f_s^s 的非线性激活后应用 dropout, 丢弃率为 0.5. 训练批次大小设置为 16, 使用 Adam 优化器优化模型参数. 通过这样的训练流程, 模型能够不断学习和优化, 逐步提升在 ASTE 任务中的性能表现, 精准地提取方面情感三元组信息.

整体而言, 通过最大化智能体依照高层和低层策略采样轨迹时每个时间步的预期总奖励来驱动策略学习, 运用策略梯度方法和 REINFORCE 算法对所有策略进行深度优化. 在不断学习迭代的过程中, 模型持续调整自身行为, 逐步提升在 ASTE 任务中的表现, 从而精准捕捉文本中的情感三元组信息.

3.8.5 模型复杂度分析

随着模型中多个复杂模块的引入, 模型结构变得更为复杂, 这不可避免地会对模型的参数量、训练时间等方面产生影响. 因此, 对这些方面进行评估分析.

在编码模块, 基于 BERT 的文本编码器本身具有大量参数, 设其参数量为 P_{BERT} . 图卷积模块中, 多层图卷积运算涉及可训练参数 W , 设 GCN 层的参数量为:

$$P_{\text{GCN}} = \sum_{l=1}^{L_{\text{GCN}}} F_{\text{GCN}}^2 \quad (36)$$

其中, L_{GCN} 为 GCN 层数, F_{GCN} 为每层特征维度. 多头图注意力网络中, 每个节点特征通过共享权重矩阵 W 进行线性变换, GAT 层的参数量为:

$$P_{\text{GAT}} = K \times F^2 \quad (37)$$

其中, K 为注意力头数量, F 为特征个数. 对比学习模块中参数量为 P_{contrast} . 语义强化模块中多层感知机 MLP 的参数量为:

$$P_{\text{RL}} = \sum_{l=1}^{L_{\text{MLP}}} (I_{\text{MLP}} \times H_{\text{MLP}} + H_{\text{MLP}} \times O_{\text{MLP}}) \quad (38)$$

其中, I_{MLP} 为输入维度, H_{MLP} 为隐藏层维度, O_{MLP} 为输出维度. 整个模型参数量为:

$$P_{\text{total}} = P_{\text{BERT}} + P_{\text{GCN}} + P_{\text{contrast}} + P_{\text{RL}} \quad (39)$$

训练时间主要受数据量、模型复杂度以及硬件性能等因素影响. 在本模型中, 编码模块使用 BERT 进行编码, 这是一个计算量较大的过程, 设其单次编码时间为 T_{BERT} . 图卷积模块对依存树进行多层图卷积运算, 设每层运算时间为 $T_{\text{GCN-layer}}$, 则 GCN 模块总运算时间为 $T_{\text{GCN}} = L_{\text{GCN}} \times T_{\text{GCN-layer}}$. 多头图注意力网络的计算涉及自注意力机制和多头注意力计算, 设其单次计算时间为 T_{GAT} . 对比学习模块构建正负样本对以及计算对比损失函数也需要一定时间, 设其单次处理时间为 T_{contrast} . 设语义强化模块中, 智能体与环境交互、策略更新等过程的单次运行时间为 T_{RL} . 则总训练时间为:

$$T = E \times D \times (T_{\text{BERT}} + T_{\text{GCN}} + T_{\text{GAT}} + T_{\text{contrast}} + T_{\text{RL}}) \quad (40)$$

其中, D 为训练数据集大小, E 为训练轮数.

4 实验

4.1 数据集

实验中,采用了4个来自 SemEval 竞赛任务的公开基准数据集,其中 Rest14、Rest15 和 Rest16 是来自餐厅的评论数据;Lap14 是来自笔记本电脑的评论数据,表 1 展示了数据集的基本信息.评论表达和关系的注释采用 Wu 等^[32]提供的方法.

表 1 数据集

属性	Lap14		Rest14		Rest15		Rest16	
	Train	Dev Test	Train	Dev Test	Train	Dev Test	Train	Dev Test
句子数	920	228 339	1300	323 496	593	148 318	842	210 320
方面数	1283	317 475	2079	530 849	834	225 426	1183	291 444
三元组数	1265	337 490	2145	524 862	923	238 455	1289	316 465

4.2 实验设置

本文编码层采用了 BERT-base-uncased 模型,选择 AdamW 算法作为优化器进行权重的更新,设置权重衰减参数为 0.01.对于分类器和 BERT 模型的微调,分别设定 $1E-3$ 和 $1E-5$ 的学习率,dropout 率为 0.5,批量大小为 32.使用预训练的 GloVe 词向量来初始化词嵌入,嵌入维度为 300,同时设置隐藏状态 d_h 和方面及意见表示 d_r 的维度分别为 300 和 100.训练在 NVIDIA GeForce RTX 3090 上进行,共进行了 40 个 epoch 的训练.每次测试中,都选取了开发集上性能最优的模型进行评估.

4.3 评价指标

本文采用精确率 P (Precision)、召回率 R (Recall)、 $F1$ 值 ($F1$ -Score) 这 3 个指标来全面衡量模型和基线的性能.公式定义如式 (41)–式 (43):

$$P = \frac{TP}{TP + FP} \quad (41)$$

$$R = \frac{TP}{TP + FN} \quad (42)$$

$$F1 = \frac{2PR}{P + R} \quad (43)$$

其中, TP 表示模型正确识别出的实际为正类样本的数量, FP 表示模型错误地将实际为负类的样本预测为正类的数量, FN 表示模型未能识别出的实际为正类的样本的数量.

4.4 基线模型

为了实现对所提方法严格和全面的评估,本文选取了一系列具有代表性的基线模型来进行比较,以便

深入分析和评估本文模型在 ASTE 任务中的性能.

(1) OTE-MTL^[33]: 提出了一个多任务学习框架来联合提取方面和意见术语,并同时使用双仿射评分器解析它们之间的情感依赖关系.

(2) BMRC^[5]: 一个双向机器阅读理解框架,将观点抽取任务转化为多轮阅读理解过程.

(3) BARTABSBA^[7]: 提出了一种统一的 ABSA 端到端解决方案,并利用 BART 模型处理所有子任务.

(4) BDTF^[9]: 提出了一种边界驱动表填充方法,将 ASTE 任务转化为关系区域的检测和分类,通过学习表示来优化三元组的识别,同时利用单词间和关系间的交互提升性能.

(5) dual-encoder^[14]: 结合 BERT 和 Bi-LSTM 与图卷积网络组成的特定编码器,通过依赖树建模和词性位置信息,实现多视角语义融合.

(6) CONTRASTE^[3]: 是利用对比学习来提高 ASTE 性能的预训练策略.设计基于方面的提示并掩盖情感,训练编码器-解码器模型.

(7) EMC-GCN^[17]: 是一种增强型多通道图卷积的网络模型,利用双仿射注意力模块嵌入句子中单词间的关系,并将其转换为多通道图.

(8) MBGCN^[18]: 是一种基于多分支图卷积网络的文本表示模型,通过结构化 BERT 增强语义特征,利用双仿射注意力模块整合特征.

(9) PT-GCN^[15]: 是一种基于提示的三通道图卷积神经网络模型,通过将关系表转化为图,利用提示注意力计算边权重来探索全面关系,并通过三通道卷积抽取情感知识.

(10) ASTE-RL^[34]: 是一种新型范式,将方面和观点术语视为句子中表达情感的参数,首先考虑情感极性,然后使用单独的强化学习过程识别相关观点和方面术语.重复此过程以提取句子中存在的所有三元组.

(11) MiniConGTS^[25]: 提出了一种通过集成极简标记方案和令牌级对比学习策略来改进和利用预训练表示的方法,该框架增强了预训练模型产生的上下文嵌入,且无缝适应极简网格标记方案.

4.5 实验结果

实验过程中,通过与多个基线模型比较,发现所提模型在 ASTE 任务中表现出显著性能优势.具体来说,如表 2 所示,在 $F1$ 分数上超越了其他模型.

与 BMRC 相比,本文基础模型 (Ours_basic) 在 $F1$

分数上取得了平均 4.42% 的显著提升, 与 CONTRASTE 相比, 在 Lap14、Rest14、Rest15 和 Rest16 上 $F1$ 值分别实现了 1.61%、2.54%、2.87% 和 2.03% 的提升. 综合考虑 P 、 R 和 $F1$ 分数, 模型在 ASTE 任务中展现出

全面的性能优势, 归功于其核心的图卷积网络和图注意力网络机制. 这种结合图结构的先进特征抽取和关系建模策略, 赋予了模型在处理细粒度情感分析时的深度和灵活性.

表 2 ASTE 在数据集上的实验结果 (%)

模型	Lap14			Rest14			Rest15			Rest16		
	P	R	$F1$									
OTE-MTL	49.53	39.22	43.42	62.00	55.97	58.71	56.37	40.94	47.13	62.88	52.10	56.96
BMRC*	65.12	54.41	59.27	71.32	70.09	70.69	63.71	58.63	61.05	67.74	68.65	68.13
BARTABSA	60.58	54.90	57.59	71.58	71.00	71.28	59.28	61.10	60.17	62.73	66.24	64.44
BDTF	64.45	55.51	59.64	78.73	69.14	73.62	69.52	60.65	64.78	78.05	67.31	72.28
dual-encoder	62.23	53.46	57.51	73.30	73.89	73.59	67.10	56.04	61.07	66.47	72.90	69.53
CONTRASTE	63.40	59.30	61.30	71.40	71.90	71.60	62.00	66.40	64.10	68.90	73.50	71.10
EMC-GCN	60.63	56.51	58.50	69.79	73.29	71.49	54.45	63.28	58.53	69.81	72.08	70.93
MBGCN	57.30	57.62	57.46	72.89	71.79	72.33	60.76	58.42	59.57	71.68	69.22	70.43
PT-GCN	67.53	57.30	62.00	<u>74.63</u>	71.32	72.94	68.53	62.88	65.59	70.34	66.92	68.59
ASTE-RL	64.80	54.99	59.50	70.60	68.65	69.61	65.45	60.29	62.72	72.11	67.21	69.69
MiniConGTS	64.11	60.17	62.08	72.06	76.56	<u>74.24</u>	66.08	63.83	64.94	66.12	72.32	69.08
Ours_basic	<u>68.50</u>	58.16	<u>62.91</u>	74.27	74.01	74.14	<u>70.28</u>	63.95	<u>66.97</u>	72.51	73.76	<u>73.13</u>
Ours	68.63	<u>59.38</u>	63.67	74.21	<u>74.82</u>	74.95	70.84	<u>64.61</u>	67.58	<u>73.07</u>	<u>73.54</u>	73.31

注: “*”表示数据从该文献中获得, 其他均为在相同条件下对文献复现得到的结果, 其中最佳效果用加粗表示, 次佳效果用下划线表示.

改进模型 (Ours) 在基础模型上, 进一步引入了对比学习和强化学习机制, 以提升模型在 ASTE 任务中的性能. 改进模型在多个数据集上均取得了显著的性能提升. 具体来说, 如表 2 所示, 与基础模型相比, 在 Lap14、Rest14、Rest15 和 Rest16 上 $F1$ 值分别实现了 0.76%、0.81%、0.61% 和 0.18% 的提升. 在准确率和召回率指标上也均有提升, 其归功于对比学习和强化学习的引入. 通过结合 GCN、GAT 以及对比学习和强化学习的协同运作机制, 各个模块在 ASTE 任务中形成了一个有机整体, 全方位地提升了对文本语义的理解与分析能力. 不仅能够精准识别文本中的情感倾向、意见表达以及涉及的具体方面, 还能在复杂语境下准确把握它们之间的相互关系.

在训练时间评估方面, 对比了 BMRC 和改进模型时的训练时间, 结果如表 3. 可以看出, 改进模型的训练时间明显长于 BMRC 模型. 多个复杂模块的叠加增加了计算量, 导致训练时间延长.

表 3 模型在数据集上的训练时间

模型	训练时间 (h)
BMRC	$T_{\text{base}}=1.4$
Ours	$T_{\text{full}}=2.3$

4.6 消融实验

为进一步验证本文模型 (Ours) 中各模块的有效性, 进行了消融实验, 分别去除模型中的不同模块进行

评估: 去除 GCN 网络的模型标记为-GCN, 去除 GAT 网络的模型标记为-GAT, 同时去除 GCN 和 GAT 网络的模型标记为-GNN, 该模型即 BMRC^[9], 去除对比学习模块的模型标记为-对比, 去除语义强化模块的模型标记为-强化, 同时去除对比和强化模块的模型标记为 Ours_basic, 即为本文基础模型. 在 4 个数据集运行后的结果如表 4 所示.

将 GCN 网络去掉之后, 与基础模型的 $F1$ 分数相比, 在 4 个数据集分别下降了 1.36、0.32、0.01、0.65 个百分点, 这是因为 GCN 可以捕获文本语义信息, 能够从文本中抽取出情感相关的特征, 提高了观点抽取任务的准确性; 将 GAT 去掉之后, 与基础模型的 $F1$ 分数相比, 在 4 个数据集分别下降了 1.8、0.77、0.68、1.49 个百分点, 这是因为 GAT 能够捕捉文本中复杂的语义关系, 且能动态评估不同关系的重要性, 有助于更准确地识别和抽取观点. 将 GCN 和 GAT 网络同时去掉之后, 与基础模型的 $F1$ 分数相比, 在 4 个数据集分别下降了 3.64、3.45、5.61、5 个百分点, 这表明对于原始模型, GCN 和 GAT 网络缺一不可. GCN 专注于局部特征的聚合, 通过依存树结构捕捉词与词之间的语义依存关系; GAT 则通过自注意力机制捕捉全局关系, 为每个节点的邻居动态分配权重, 以捕获更加全局的语义信息; GCN 和 GAT 的结合有助于特征的融合, 可以减少模型对特定类型数据偏差的依赖, 增强模型的

泛化能力。

在改进模型上,当去掉对比学习模块时,与基础模型的 $F1$ 分数相比,在 4 个数据集分别下降了 0.79、1.38、0.77、0.7 个百分点,这是因为对比学习通过构

建正负样本对,运用对比损失函数,助力模型学习到更具鲁棒性与区分性的特征表示。缺少这一模块,模型在面对复杂多样的文本数据时,难以精准识别语义关键特征,从而影响了后续分析的准确性与稳定性。

表 4 消融实验结果 (%)

方法	Lap14			Rest14			Rest15			Rest16		
	P	R	$F1$	P	R	$F1$	P	R	$F1$	P	R	$F1$
Ours	68.63	59.38	63.67	74.21	74.82	74.95	70.84	64.61	67.58	73.07	73.54	73.31
Ours_basic	68.50	58.16	62.91	74.27	74.01	74.14	70.28	63.95	66.97	72.51	73.76	73.13
-GCN	67.56	56.53	61.55	73.81	73.89	73.85	68.26	65.71	66.96	73.61	71.39	72.48
-GAT	67.07	56.12	61.11	72.74	74.01	73.37	68.64	63.51	65.98	71.03	72.25	71.64
-GNN	65.12	54.41	59.27	71.32	70.09	70.69	63.71	58.63	61.05	67.74	68.65	68.13
-强化	65.27	60.61	62.85	73.65	73.31	73.48	66.81	66.37	66.59	74.60	71.39	72.96
-对比	67.60	58.77	62.88	73.83	73.31	73.57	68.92	64.83	66.81	72.53	72.68	72.61

在去除语义强化模块后,与基础模型的 $F1$ 分数相比,在 4 个数据集分别下降了 0.82、1.47、0.99、0.35 个百分点,这是因为强化学习采用层次化策略学习方式,以最大化预期总奖励为目标,根据实际输出与真实标签之间的差异,不断优化自身策略。这种动态优化能力与 GCN 专注于局部特征聚合以及 GAT 捕捉全局语义信息的能力相辅相成,共同增强了模型在复杂语义环境下的分析能力和决策能力。对比学习、强化学习与 GCN、GAT 紧密协作,相互配合,共同构建起一个高效、精准的细粒度情感分析模型,有力地推动了 ASTE 任务的完成。

5 结论

本文基于已有的 BERT、GCN 和 GAT 架构提出了改进方法。在模型构建中,GCN 结合依存树的语法信息,强化了局部语义特征的聚合。多头 GAT 通过自注意力机制,灵活地捕获了节点间的复杂关系,并通过多头注意力学习到多个表示子空间,进一步丰富了模型的语义表达能力。通过引入对比学习和强化学习,有效弥补了模型在处理全局语义关系和动态决策优化方面存在的不足,这不仅打破了图结构的局部性限制,更使得模型在面对长距离语义依赖和复杂语义关系时,能够精准捕捉关键信息,显著提升了模型在不同文本场景下的性能表现。在公开数据集上一系列的实验结果充分验证了改进后模型的有效性和优越性。未来研究方向可进一步优化强化学习中的奖励机制设计,以实现 ASTE 模型性能的进一步提升。

参考文献

1 D'Aniello G, Gaeta M, La Rocca I. KnowMIS-ABSA: An

overview and a reference model for applications of sentiment analysis and aspect-based sentiment analysis. *Artificial Intelligence Review*, 2022, 55(7): 5543–5574. [doi: [10.1007/s10462-021-10134-9](https://doi.org/10.1007/s10462-021-10134-9)]

2 Peng HY, Xu L, Bing LD, *et al.* Knowing what, how and why: A near complete solution for aspect-based sentiment analysis. *Proceedings of the 34th AAAI Conference on Artificial Intelligence*. New York: AAAI Press, 2020. 8600–8607.

3 Mukherjee R, Kannan N, Pandey S, *et al.* CONTRASTE: Supervised contrastive pre-training with aspect-based prompts for aspect sentiment triplet extraction. *Proceedings of the 2023 Findings of the Association for Computational Linguistics*. Singapore: ACL, 2023. 12065–12080.

4 Mukherjee R, Nayak T, Butala Y, *et al.* PASTE: A tagging-free decoding framework using pointer networks for aspect sentiment triplet extraction. *Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing*. Punta Cana: ACL, 2021. 9279–9291.

5 Chen SW, Wang Y, Liu J, *et al.* Bidirectional machine reading comprehension for aspect sentiment triplet extraction. *Proceedings of the 35th AAAI Conference on Artificial Intelligence*. Palo Alto: AAAI, 2021. 12666–12674.

6 Xu L, Chia YK, Bing LD. Learning span-level interactions for aspect sentiment triplet extraction. *arXiv:2107.12214*, 2021.

7 Yan H, Dai JQ, Ji T, *et al.* A unified generative framework for aspect-based sentiment analysis. *arXiv:2106.04300*, 2021.

8 Chen YQ, Zhang ZQ, Zhou GY, *et al.* Span-based dual-decoder framework for aspect sentiment triplet extraction. *Neurocomputing*, 2022, 492: 211–221. [doi: [10.1016/j.neucom.2022.04.022](https://doi.org/10.1016/j.neucom.2022.04.022)]

9 Zhang YC, Yang YF, Li YH, *et al.* Boundary-driven table-filling for aspect sentiment triplet extraction. *Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing*. Abu Dhabi: ACL, 2022. 6485–6498.

- 10 余军, 过弋, 阮启铭. 基于集合预测的方面级情感三元组提取. 中文信息学报, 2024, 38(8): 147–157. [doi: 10.3969/j.issn.1003-0077.2024.08.017]
- 11 Veličković P, Cucurull G, Casanova A, *et al.* Graph attention networks. arXiv:1710.10903, 2017.
- 12 高龙涛, 李娜娜. 基于方面感知注意力增强的方面情感三元组抽取. 计算机应用, 2024, 44(4): 1049–1057.
- 13 赵园春, 韩虎, 徐学锋. 细粒度标记的结点自适应方面情感三元组抽取. 计算机工程与应用, 2025, 61(13): 208–216.
- 14 Jiang BX, Liang SH, Liu PY, *et al.* A semantically enhanced dual encoder for aspect sentiment triplet extraction. Neurocomputing, 2023, 562: 126917. [doi: 10.1016/j.neucom.2023.126917]
- 15 Peng K, Jiang L, Peng H, *et al.* Prompt based tri-channel graph convolution neural network for aspect sentiment triplet extraction. Proceedings of the 2024 SIAM International Conference on Data Mining. Houston: SIAM, 2024. 145–153.
- 16 石恽本, 苟刚. 结合句法结构和语义信息的方面情感三元组抽取. 计算机工程与设计, 2024, 45(8): 2468–2474.
- 17 Chen H, Zhai ZP, Feng FX, *et al.* Enhanced multi-channel graph convolutional network for aspect sentiment triplet extraction. Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics. Dublin: ACL, 2022. 2974–2985.
- 18 Shi XF, Hu M, Deng JW, *et al.* Integration of multi-branch GCNs enhancing aspect sentiment triplet extraction. Applied Sciences, 2023, 13(7): 4345. [doi: 10.3390/app13074345]
- 19 Yang SH, Jiang XK, Zhao HJ, *et al.* FaiMA: Feature-aware in-context learning for multi-domain aspect-based sentiment analysis. Proceedings of the 2024 Joint International Conference on Computational Linguistics, Language Resources and Evaluation. Torino: ACL, 2024. 7089–7100.
- 20 杨芳捷, 冯广, 唐业凯. 结合语法结构和语义信息的情感三元组抽取. 计算机系统应用, 2024, 33(3): 255–263. [doi: 10.15888/j.cnki.csa.009438]
- 21 Yang F, Zhang M, Hu GZ, *et al.* A pairing enhancement approach for aspect sentiment triplet extraction. Proceedings of the 16th International Conference on Knowledge Science, Engineering and Management. Guangzhou: Springer, 2023. 399–410.
- 22 Yu GX, Liu LM, Jiang HY, *et al.* Making better use of training corpus: Retrieval-based aspect sentiment triplet extraction via label interpolation. Proceedings of the 2023 Findings of the Association for Computational Linguistics. Toronto: ACL, 2023. 4914–4927.
- 23 Xu HW, Tang MW, Cai T, *et al.* Dual-enhanced generative model with graph attention network and contrastive learning for aspect sentiment triplet extraction. Knowledge-based Systems, 2024, 301: 112342. [doi: 10.1016/j.knsys.2024.112342]
- 24 Xiong HL, Yan ZH, Zhao HY, *et al.* Triplet contrastive learning for aspect level sentiment classification. Mathematics, 2022, 10(21): 4099. [doi: 10.3390/math10214099]
- 25 Sun Q, Yang LJ, Ma MH, *et al.* MiniConGTS: A near ultimate minimalist contrastive grid tagging scheme for aspect sentiment triplet extraction. Proceedings of the 2024 Conference on Empirical Methods in Natural Language Processing. Miami: ACL, 2024. 2817–2834.
- 26 Zhang YC, Yang YF, Li M, *et al.* Target-to-source augmentation for aspect sentiment triplet extraction. Proceedings of the 2023 Conference on Empirical Methods in Natural Language Processing. Singapore: ACL, 2023. 12165–12177.
- 27 Obiedat R, Qaddoura R, Al-Zoubi AM, *et al.* Sentiment analysis of customers' reviews using a hybrid evolutionary SVM-based approach in an imbalanced data distribution. IEEE Access, 2022, 10: 22260–22273. [doi: 10.1109/ACCESS.2022.3149482]
- 28 Keerthana RR, Fathima G, Florence L. Evaluating the performance of various deep reinforcement learning algorithms for a conversational chatbot. Proceedings of the 2nd International Conference for Emerging Technology. Belagavi: IEEE, 2021. 1–8.
- 29 Zhao XS, Peng H, Dai Q, *et al.* RDGCN: Reinforced dependency graph convolutional network for aspect-based sentiment analysis. Proceedings of the 17th ACM International Conference on Web Search and Data Mining. Merida: ACM, 2024. 976–984.
- 30 Wu HY, Zhou D, Sun CQ, *et al.* LSOIT: Lexicon and syntax enhanced opinion induction tree for aspect-based sentiment analysis. Expert Systems with Applications, 2024, 235: 121137. [doi: 10.1016/j.eswa.2023.121137]
- 31 Dai YQ, Wang PF, Zhu XF. Reasoning over multiplex heterogeneous graph for target-oriented opinion words extraction. Knowledge-based Systems, 2022, 236: 107723. [doi: 10.1016/j.knsys.2021.107723]
- 32 Wu Z, Ying CC, Zhao F, *et al.* Grid tagging scheme for aspect-oriented fine-grained opinion extraction. Proceedings of the 2020 Findings of the Association for Computational Linguistics. ACL, 2020. 2576–2585.
- 33 Zhang C, Li QC, Song DW, *et al.* A multi-task learning framework for opinion triplet extraction. Proceedings of the 2020 Findings of the Association for Computational Linguistics. ACL, 2020. 819–828.
- 34 Jian SYB, Nayak T, Majumder N, *et al.* Aspect sentiment triplet extraction using reinforcement learning. Proceedings of the 30th ACM International Conference on Information & Knowledge Management. Queensland: ACM, 2021. 3603–3607.

(校对责编: 王欣欣)