

知识辅助和强化句法驱动的方面级情感分析

郑诚, 班晴晴

引用本文

郑诚, 班晴晴. 知识辅助和强化句法驱动的方面级情感分析[J]. 计算机科学, 2026, 53(4): 406-414.

ZHENG Cheng, BAN Qingqing. [Knowledge-assisted and Reinforced Syntax-driven for Aspect-based Sentiment Analysis](#) [J]. Computer Science, 2026, 53(4): 406-414.

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)

[跨模态融合的少样本勒索软件分类器:基于预训练模型的多模态编码](#)

Cross-modal Fusion Few-sample Ransomware Classifier:Multimodal Encoding Based on Pre-trained Models

计算机科学, 2026, 53(4): 435-444. <https://doi.org/10.11896/jsjcx.250500078>

[融合局部多视角语言特征和全局特征的对话情感四元组抽取](#)

Multi-view Local Language Feature and Global Feature Fusion for Conversational Aspect-based Sentiment Quadruple Analysis

计算机科学, 2026, 53(4): 384-392. <https://doi.org/10.11896/jsjcx.250900032>

[基于多任务强化学习的优先级加权软模块化方法:SM-PHT](#)

SM-PHT:Robust,Scalable,and Efficient Method for Multi-task Reinforcement Learning

计算机科学, 2026, 53(4): 366-376. <https://doi.org/10.11896/jsjcx.250700198>

[基于深度强化学习的长期因果效应估计](#)

Long-term Causal Effect Estimation Based on Deep Reinforcement Learning

计算机科学, 2026, 53(4): 235-244. <https://doi.org/10.11896/jsjcx.250600043>

[STWD-DLFRD:基于序贯三支决策与深度学习的多粒度虚假评论检测方法](#)

STWD-DLFRD:Multi-granularity Fake Review Detection via Sequential Three-way Decisions and Deep Learning

计算机科学, 2026, 53(4): 188-196. <https://doi.org/10.11896/jsjcx.250500088>

知识辅助和强化句法驱动的方面级情感分析

郑 诚 班晴晴

安徽大学计算机科学与技术学院 合肥 230601

计算智能与信号处理教育部重点实验室 合肥 230601

摘 要 方面级情感分析旨在对齐方面和其相应的意见表达,以识别特定方面的情感极性。现有的基于依赖树的图神经网络模型在方面级情感分析中取得了显著的性能提升,但大多数研究未充分利用句法依赖树的完整信息,通常忽略了句法依赖距离信息或依赖标签信息。这种忽视可能导致在含有多个方面的句子中,意见词与相应的方面词无法有效对齐。针对上述问题,构造一种知识辅助和强化句法驱动的网络模型。具体来说,首先通过引入外部知识库设计一个意见词感知模块,以增强模型对句子中意见表达的识别能力。然后,利用强化学习指导句法距离图的构建,并将其与基于单词关系和依赖标签构建的动态句法标签图进行启发式集成,从而提高对给定方面捕获相关意见表达的准确性和全面性。此外,采用方面关注注意力机制来更好地处理句法结构不明确的句子。在3个公共数据集上进行广泛的实验,结果验证了该模型的有效性。

关键词: 方面级情感分析;情感词典;句法依赖树;强化学习;图卷积网络;注意力机制;深度学习

中图分类号 TP391

Knowledge-assisted and Reinforced Syntax-driven for Aspect-based Sentiment Analysis

ZHENG Cheng and BAN Qingqing

School of Computer Science and Technology, Anhui University, Hefei 230601, China

Key Laboratory of Intelligent Computing and Signal Processing, Ministry of Education, Hefei 230601, China

Abstract Aspect-based sentiment analysis aims to align aspects with their corresponding opinion expressions to identify the sentiment polarity of specific aspects. Existing dependency tree-based graph neural network models have achieved significant performance improvements in aspect-based sentiment analysis. However, most studies fail to fully exploit the complete information of the syntactic dependency tree, often overlooking syntactic dependency distance or dependency label information. This limitation may prevent effective alignment between opinion words and their corresponding aspect terms, particularly in sentences containing multiple aspects. To address these issues, a knowledge-assisted and reinforced syntax-driven network model is constructed. Specifically, an opinion word perception module is designed by incorporating external knowledge information to enhance the model's ability to recognize opinion expressions in sentences. Then, reinforcement learning is employed to guide the construction of the syntactic distance graph. This graph is then heuristically integrated with the dynamic syntactic label graph, which is built based on word relations and dependency labels, thereby improving the accuracy and comprehensiveness of capturing relevant opinion expressions for a given aspect. Additionally, an aspect-focused attention mechanism is employed to better handle sentences with ambiguous syntactic structures. Extensive experiments conducted on three public datasets validate the effectiveness of the proposed model.

Keywords Aspect-based sentiment analysis, Sentiment lexicon, Syntax dependency tree, Reinforcement learning, Graph convolution networks, Attention mechanism, Deep learning

1 引言

在互联网高度发达、高度普及的今天,用户越来越倾向于在社交媒体和购物网站上表达情感,这些情感信息蕴含着个体和群体的意见、态度以及情感体验,理解这些含有观点的文本数据的情感有助于深入了解人们的偏好和行为,以及支持

跨领域的决策^[1]。因此,准确地理解和分析用户对具体事物的情感变得至关重要。方面级情感分析(Asspect-based Sentiment Analysis, ABSA)作为一种细粒度的情感分析任务,也被称为“意见挖掘”^[2],其核心目标是判断给定句子中每个方面词的情感极性(积极、消极或中性),这些方面词通常是句子中的目标实体。例如,在“The price is reasonable although the

到稿日期:2025-06-18 返修日期:2025-09-19


基金项目:安徽省重点研究与开发计划(202004d07020009)

This work was supported by the Key Research and Development Program of Anhui Province(202004d07020009).

通信作者:郑诚(csahu@126.com)

service is poor”这句话中,可以分别根据意见词“reasonable”和“poor”来识别出方面词“price”积极的情感极性和方面词“service”消极的情感极性。实际上,意见词蕴含着一定的情感信息,而方面级情感分析任务的关键则在于如何准确地识别与特定方面相关的意见表达。

早期的研究将注意力机制应用于循环神经网络等序列模型^[3-5]中,以提取不同方面的意见表达。这些模型虽然简单有效,但在处理包含极性相反的多个方面的复杂句子时,通常会混淆各个方面和相关意见词之间的关系。随着神经网络在句法解析中的进步,句子依赖树的准确性得到了显著提高^[6],使得方面词与上下文之间的句法依赖关系能够被更精准地捕捉和分析。因此,最近的研究主要利用图神经网络(GNN)对句子的依赖树进行编码,使模型能够捕捉特定方面与其对应的意见词之间的关系。Huang等^[7]采用多层图注意力网络(GAT)对句子的依赖图进行编码,将情感特征从重要的句法相邻词传播到目标方面。Zhong等^[8]使用图卷积网络(GCN)来学习方面词和相关词之间的句法信息。然而仅利用单词间的依赖联系,可能会使模型难以区分哪些词是有价值的。一些研究表明^[9-10],在大多数情况下,依赖树中的意见词是接近于方面词的,这意味着可以只从句法角度考虑方面词周围的上下文词。图1给出了句子“The price is reasonable although the service is poor”的句法解析依赖树。其中,方面词和意见词分别用绿色和黄色标记,有向边表示两个词之间存在依赖关系,同时标明了相应的依赖关系标签。方面词“price”和其对应的意见词“reasonable”之间的句法依赖距离较近,而和方面“service”的意见词“poor”之间的句法依赖距离较远,这表明在依赖树中方面结点周围的词更有可能是其相应的意见词。



注:这句话包含两个情感极性相反的方面词。

图1 一个例句的句法依赖树

Fig. 1 Example sentence with its dependency tree

此外,还有研究表明^[11],在大多数情况下,每个方面词都通过相同的句法依赖标签连接到相应的意见词。如图1所示,方面词“price”和“service”通过句法依赖标签“nsbj”分别关联到对应的意见词“reasonable”和“poor”,这表明“price”和“service”分别是“reasonable”和“poor”的名词性主语,这会显著地引导对“price”和“service”情感的分析。因此,句法依赖距离和依赖标签信息都有助于捕捉句子中的意见表达以及将方面词和其相应的意见表达对齐。然而,现有的大多数研究往往没有充分利用这两种句法信息。

为了解决上述问题,本文提出了一种知识辅助和强化句法驱动的方面级情感分析模型,旨在更精准地捕捉意见词,并缓解方面词与意见词之间不匹配的问题。具体来说,为了增强模型捕获句子中意见表达的能力,使用意见词感知模块,让编码器更加关注句子中的意见词。为了更准确全面地捕获与给定方面相关的意见词,使用基于强化学习的距离函数构建

句法距离图,以关注依赖树中方面词的局部范围,减少候选的意见词库,同时,基于上下文嵌入以及依赖标签嵌入构建句法标签图,考虑意见词与方面词距离较远的情况。然后,将两种句法图进行启发式集成得到综合句法图,并在此基础上构造综合句法图卷积网络(SGCN)。此外,为了应对句法结构不明确的情况,引入方面关注注意力机制,以便更好地处理那些对句法信息不敏感的句子。最后将特定方面的句法特征和语义特征进行融合,以确定该方面的情感极性。

本文的主要贡献如下:

1) 提出一个知识辅助和强化句法驱动的方面级情感分析模型,该模型能够更准确地识别出句子中的意见词,以及将方面词和其相应的意见词进行对齐;

2) 将基于强化学习方法得到的句法距离图与结合单词关系和依赖标签信息得到的动态句法标签图进行启发式融合,得到综合句法图,其从全面句法的角度解释了上下文词的重要性;

3) 在3个基准数据集上进行了对比实验,实验结果验证了所提模型的有效性。

2 相关工作

方面级情感分析是一种自然语言处理技术,主要关注于利用意见词来确定各方面的情感极性,实现对情感更细致的理解。早期的一些研究^[12-14]主要依赖于手工设计的特征来训练情感分类器,然而这种方法通常需要大量的人力和物力资源,且容易受到特征选择和分类器的影响。随着深度学习的兴起,各种神经网络模型因具备自动提取句子上下文特征的能力,被广泛应用于方面级情感分析的任务中。其中具有代表性的两种方法分别为基于注意力机制的方法和基于句法依赖树的方法。

由于注意力机制可以帮助模型关注重要的区域,因此一些研究使用结合注意力机制的神经网络模型来获取方面和上下文之间的语义关系。例如,Wang等^[3]提出了一个结合注意力机制的LSTM模型,该模型考虑了方面词的特征表示,使模型能够关注与特定方面相关的重要信息。Fan等^[4]为了缓解粗粒度的注意力在一定情况下会导致信息丢失的问题,提出了一种细粒度的注意力机制,并将其和粗粒度的注意力组成多粒度的注意力网络,来获取方面词和上下文之间单词级别的相互影响。由于RNN难以进行并行计算,且其梯度在随时间反向传播时容易消失或爆炸,导致模型难以捕捉长距离的依赖关系,因此Zhang等^[15]利用卷积将单词和多词的文本特征进行整合,并利用多头自注意力提取序列中的语义信息,保留了网络的并行性。然而,注意力机制可能会将高权重分配给与方面无关的词,因此,Huang等^[16]引入了两个非对称的位置加权函数来调整不同位置的上下文词的权重,实验结果表明,位置信息在学习与方面相关的上下文时起到了重要的作用。

句法依赖树描述了句子中各个词之间的依存关系,而图神经网络具备出色的特征聚合能力,因此近年来的研究通常采用图神经网络对依赖树进行建模,以便能更好地捕捉文本中的结构信息和句法关系。Zhang等^[17]首次使用GCN来捕

获依赖树中方面词和上下文之间的句法关系。之后,图神经网络逐渐被应用于方面级情感分析的任务中。Hou 等^[18]通过结合来自不同解析器的依赖关系解析树,构建了一个集成图,显著提高了模型对解析错误的鲁棒性。为了更好地将方面和意见词通过句法结构联系起来,Kong 等^[19]基于句法距离重构了长句子的句法依赖图,缩小了意见词和方面词之间的距离。此外,一些学者还将情感知识和语法规则等信息整合到依赖图神经网络中^[20-22],以增强其捕获情感特征的能力。其中,Gu 等^[21]通过整合词性信息和 SenticNet 知识库来增强句子的依赖图,考虑了上下文词与方面词的依赖性以及意见词与方面之间的情感信息。强化学习能够通过与环境交互和反馈机制来自动探索最优策略,从而提升模型在复杂任务中的决策能力和整体性能。因此,Cao 等^[23]提出一种基于知识图谱的强化学习机制,不仅能通过外部知识补充句法依赖信息,还能通过强化学习准确捕捉与方面相关的关键上下文。Wu 等^[24]利用强化学习和注意力机制构建一个词汇与

句法增强的意见归纳树。

尽管现有的基于依赖树的图神经网络及其变体模型在方面级情感分析中取得了良好的效果,但大多数研究未能充分挖掘句法依赖树中的句法信息,导致模型无法有效提取与方面词相关的意见表达。因此,本文通过整合句法依赖树中的依赖距离和依赖标签信息,获得更加全面的句法特征表示,从而更精确地识别与各个方面词对应的意见表达。此外,针对标记数据稀缺的问题,本文通过引入外部知识的意见词感知模块,增强模型对句子中意见词的感知能力,避免遗漏潜在的有价值的意见表达。

3 知识辅助和强化句法驱动的方面级情感分析模型

本章将详细介绍所提出的知识辅助和强化句法驱动的方面级情感分析模型。该模型主要包括序列编码、意见词感知模块、综合句法图表示学习、方面关注注意力、分类层和模型训练。模型的整体框架如图 2 所示。

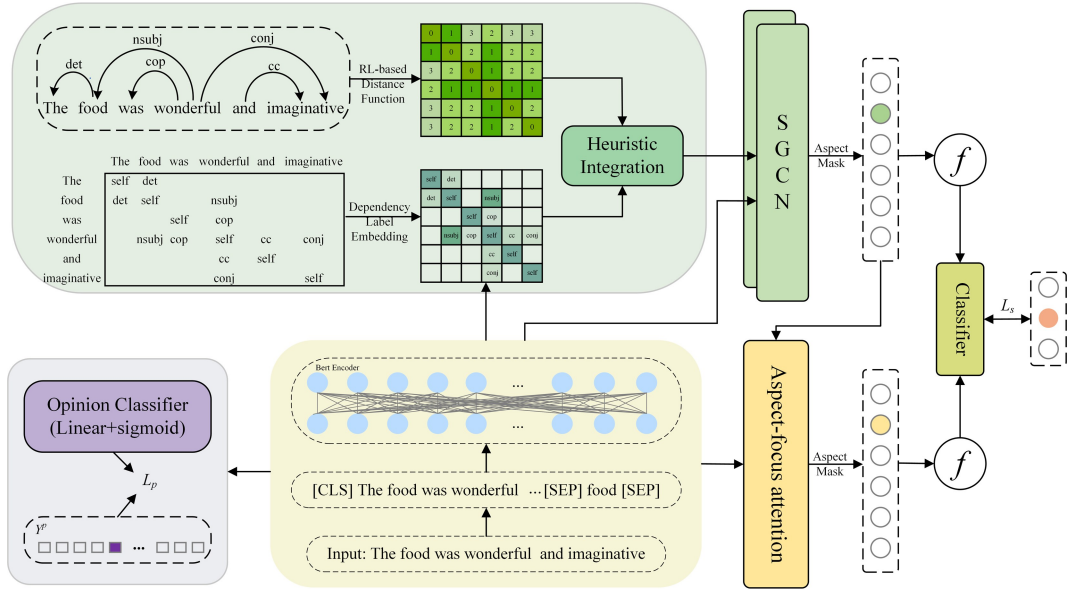


图 2 模型整体框架

Fig. 2 Overall framework of the proposed model

3.1 问题描述

对于给定的包含 n 个单词的文本序列 $S = \{\omega_1, \omega_2, \dots, \omega_{\tau+1}, \omega_{\tau+2}, \dots, \omega_{\tau+m}, \dots, \omega_n\}$ 和包含 m 个单词的方面项 $A = \{\omega_{\tau+1}, \omega_{\tau+2}, \dots, \omega_{\tau+m}\}$, 其中 $\omega_{\tau+i}$ 表示该方面的第 i 个单词, 方面级情感分析模型的目标是预测方面 A 在文本序列 S 中所对应的情感极性。

3.2 序列编码

本文采用预训练语言模型 BERT^[25] 作为编码器来获得每个词的上下文表示。对于给定的句子方面对 (S, A) , 遵循 BERT-SPC^[26] 构造一个基于 BERT 的序列, 如式(1)所示:

$$BERT_in = [CLS] + S + [SEP] + A + [SEP] \quad (1)$$

其中, [CLS] 和 [SEP] 分别是 BERT 中用于分类和句子分离的特殊标记符。然后将该序列作为 BERT 的输入, 来获得每个词上下文表示 $\mathbf{H} = [\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_n] \in R^{n \times d}$, 其中 d 表示 BERT 嵌入的维度, \mathbf{h}_i 表示第 i 个词的上下文表示。如果一个

句子中包含多个方面词, 则为每个方面词构造一个输入。

3.3 意见词感知模块

如果模型仅依赖标记数据, 可能会导致一些有价值的意见表达被遗漏。受 Chen 等^[27] 的启发, 本节构建一个意见词感知模块来指导上下文编码器学习意见词感知的表示, 从而提升模型对意见表达的捕捉能力。

首先, 引入刘兵意见词典^[28] 作为外部知识库, 该词典包含积极词和消极词列表, 用于获取输入句子中每个单词的意见标签 $Y^p = [Y_1^p, Y_2^p, \dots, Y_n^p]$, 其中 $Y_i^p \in \{0, 1\}$ 表示第 i 个单词是否是一个意见词。然后, 将上下文表示 \mathbf{H} 输入一个具有激活函数的全连接层中, 输出结果如式(2)所示:

$$y^p = \text{sigmoid}(\mathbf{W}^p \mathbf{H} + \mathbf{b}^p) \quad (2)$$

其中, \mathbf{W}^p 和 \mathbf{b}^p 分别表示可训练的权重和偏差, y^p 表示每个词为意见词的概率。通过最小化二元交叉熵损失函数, 使得 \mathbf{H} 能够学习每个单词是否为意见词的信息, 从而有效地区分意见词与非意见词的表示, 如式(3)所示:

$$L_p = -\sum_{i=1}^N (y_i^p \log Y_i^p) + (1 - y_i^p) \log(1 - Y_i^p) \quad (3)$$

其中, N 表示训练样本的数量。

3.4 综合句法图表示学习

3.4.1 句法距离图的构建

对于给定的句子,首先使用依赖解析器来进行句法分析并生成相应的依赖树。由于在依赖树中靠近方面节点的上下文节点通常与该方面具有更高的情感相关性,特别是与方面词在依赖树中距离较近的意见词,往往更能有效反映该方面的情感极性。因此,与之前大多数主要关注依赖树节点间联系的研究不同,本节利用依赖树中节点之间的相对位置信息构造句法距离图,使模型能够关注方面词的局部范围,从而减少候选的意见词库。

为了获取句法依赖树中的句法距离信息,首先将依赖关系视为无向边,以确保句子中任意两个节点之间都是可达的。然后,将节点之间的最短路径作为相对位置的参考,并使用 $D_{i,j}$ 来表示节点 i 和节点 j 之间的句法距离。值得注意的是,节点本身的句法距离被设置为 0,如式(4)所示:

$$D_{ij} = \begin{cases} DIS(i, j), & \text{if } i \neq j \\ 0, & \text{otherwise} \end{cases} \quad (4)$$

其中, $DIS(i, j)$ 表示节点 i 和节点 j 之间的最短路径长度,即最短路径上的边数。

在获得句法距离后,通过对每对节点之间的距离进行建模来构造句法距离图,与以往采用线性衰减或倒数方法来确定节点间距离权重分布的研究不同,本节采用基于距离-重要性函数^[29]的句法距离权值的优化策略来显式建模句法距离权值的分布。具体来说,为了使不同距离值的重要性权重具有可区分性,采用一个幂函数 DP 来最大化最小和最大句法距离边权值的差异,从而保留中间值的差异空间,并将权重范围限制在 0 到 1 之间。同时,为了避免等距分布和非光滑分布,采用指数函数 DE 不成比例地降低依赖距离的权重并平滑权重分布。最后通过乘法运算将两个函数合并,从而使权重分布切实合理。最终的句法距离权重的计算如式(5)所示:

$$A^d = DP \times DE = \left(1 - \left(\frac{D}{L}\right)^\alpha\right) \exp(\beta \cdot D) \quad (5)$$

其中, L 表示预定义的句法距离边界, α 为幂函数的衰减因子, β 为指数的曲率。由于不同的曲率会显著影响权重分布和关键句法距离间隔,直接影响到模型的性能,因此,最优曲率 β 的选择至关重要。然而, β 的候选集规模较大且缺乏先验知识,通过人工调优来找到最优的 β 既费力又低效。此外,不同的数据集往往对应不同的最优曲率值。因此,为了提升模型的鲁棒性和通用性,引入强化学习中双臂老虎机的概念^[30-32]来自动寻找最佳的曲率 β 。

具体来说,将寻找最优曲率的问题形式化表示为 $\{A, R, T\}$ 。其中, A 是包含两个动作的动作空间,这里使用 ϵ -贪心策略,在每个动作中将一个固定的值 r 加到曲率值中或从曲率值中减去。 R 是奖励函数,这里将验证集在相邻时间间隔的准确率作为奖励指标。 T 是终止函数,用于判断搜索过程是否结束。具体如式(6)式(8)所示:

$$A = \begin{cases} \beta + r, & \text{if } R = 1 \\ \beta - r, & \text{if } R = -1 \end{cases} \quad (6)$$

$$R_k = \begin{cases} +1, & \text{if } ACC(S_{val})_k > ACC(S_{val})_{k-1} \\ -1, & \text{if } ACC(S_{val})_k \leq ACC(S_{val})_{k-1} \end{cases} \quad (7)$$

$$T = \left| \sum_{k=20}^k R_k \right| = 0 \quad (8)$$

其中, $ACC(S_{val})_k$ 表示在第 k 时刻验证集上的情感分类准确率。如果当前模型在验证集上的分类准确率高于前一个时间步长的准确率,则模型获得的奖励 R 为 +1,执行添加 r 到 β 的动作;否则,模型获得的 R 为 -1,执行从当前曲率 β 中减去 r 的动作。搜索过程将在过去 20 个时间步的奖励总和为 0 时停止,从而确定特定数据集的最佳曲率值。

3.4.2 句法标签图的构建

虽然通过上述方法构建的句法距离图已经有效缩小了意见词的候选范围,但非意见词仍然可能存在于这个范围内,此外,在某些情况下,意见词与其对应的方面词之间的句法距离是较远的,仅通过依赖距离信息难以有效捕捉这些关系。因此,本节引入句法标签信息,并结合单词关系构建句法标签图,以更精准地识别局部范围内的有效意见词,同时关注句法距离较远但仍具有重要情感联系的意见词。具体来说,首先从依赖树中生成邻接矩阵 M 和依赖类型矩阵 T ,分别用于表示单词之间的句法依赖关系及其对应的依赖标签。其中,邻接矩阵 M 是一个二进制矩阵,若节点 i 和节点 j 之间存在依赖边,则 $M_{ij} = 1$,否则 $M_{ij} = 0$ 。而依赖类型矩阵 T 中的每个元素则表示相应节点对之间的依赖标签。为了处理无依赖关系的情况,将“root”填充到矩阵 T 的对角线位置,并使用“none”作为无效边的填充值。随后,为了有效利用依赖标签信息,基于语料库中依赖标签出现的频率,构建了一个依赖标签字典 V :

$$V = \left\{ \text{deptype:mapid} \left(\frac{N(\text{deptype})}{N} \right) \right\} \quad (9)$$

其中, $N(\text{deptype})$ 表示依赖标签 deptype 在语料库中出现的次数; N 表示语料库中所有依赖标签出现次数的总和; $\text{mapid}(\cdot)$ 根据每种依赖标签在语料库中的出现频率,将其映射为对应的唯一整数 ID。随后,利用依赖标签字典 V 获取每个依赖标签的初始词向量表示 e_{ij} 。对于每条依赖边,将该边两端节点在第 $(l-1)$ 层 GCN 中的上下文嵌入分别与对应的依赖标签嵌入进行拼接,以此得到 $H_i^{(l)}$ 和 $H_j^{(l)}$,从而计算该依赖边的权重。权重计算如式(10)、式(11)所示:

$$A_{ij}^{(l)} = \frac{\mathbf{M}_{ij} \cdot \mathbf{F}(H_i^{(l)} \cdot H_j^{(l)})}{\sum_{j=1}^N \mathbf{M}_{ij} \cdot \mathbf{F}(H_i^{(l)} \cdot H_j^{(l)})} \quad (10)$$

$$F(x) = \exp\left(\text{softmax}\left(\frac{x}{d}\right)\right) \quad (11)$$

其中, d 表示嵌入维度。这里 M 作为句法掩码矩阵,用于去除依赖标签为“none”的边,从而保持依赖树的原始结构。

3.4.3 综合句法图卷积网络

由于句法距离信息和句法标签信息是可以互补的,但简单地将两种句法图相加可能会造成信息混淆,从而不能准确反映上下文的重要性差异。因此,本节通过启发式加权的方

法来集成句法距离图和句法标签图,从而生成一个能够全面表征句法依赖关系的综合句法图,该图以全面句法的角度解释了上下文的重要性,能更精准地识别与目标方面最相关的意见词。其集成过程如式(12)所示:

$$\mathbf{A}^c = \mu_1 \times \mathbf{A}^d + \mu_2 \times \mathbf{A}^l \quad (12)$$

其中, μ_1 和 μ_2 为根据每个数据集特点设置的两个句法图的融合系数,用于控制不同句法信息的贡献度; $\mathbf{A}^c \in \mathbf{R}^{n \times n}$ 为综合句法图,该图随后被用作 SGCN 邻接矩阵。在此基础上,将意见感知模块生成的意见感知表示作为 SGCN 的初始节点特征输入,再通过多层图卷积操作,来获得意见感知增强的节点表示。在第 l 层图卷积网络中,特征聚合过程如式(13)所示:

$$\mathbf{H}^{s(l)} = \text{ReLU}(\mathbf{A}^c \mathbf{H}^{s(l-1)} \mathbf{W}^{s(l)}) \quad (13)$$

其中, $\mathbf{H}^{s(l)}$ 表示第 l 层 GCN 的输出, $\mathbf{W}^{s(l)}$ 为第 l 层 GCN 的可训练参数。

3.5 方面关注注意力

由于语料库中包含一些非正式表达的句子,这些句子通常没有明显的句法结构。因此,本节引入方面关注注意力机制,从语义角度捕获与目标方面相关的重要上下文特征。具体来说,为了减少不相关上下文的干扰,首先对 SGCN 生成的方面词嵌入向量进行平均池化,再将其复制 n 次并拼接起来获得查询向量 \mathbf{H}_q^s ,将该查询向量与意见感知的上下文表示进行注意力计算,生成注意力权重分布 \mathbf{A}^c 。最后,将注意力权重矩阵与初始特征矩阵相乘,得到句子表示 \mathbf{H}^c ,该表示能够聚焦于与目标方面最相关的上下文信息。计算过程如式(14)、式(15)所示:

$$\mathbf{A}^c = \text{softmax}(\mathbf{H}_q^s \mathbf{W}^q \times (\mathbf{H} \mathbf{W}^k)^T) \quad (14)$$

$$\mathbf{H}^c = \mathbf{A}^c \cdot \mathbf{H} \quad (15)$$

其中, \mathbf{W}^q 和 \mathbf{W}^k 为可学习的参数。

3.6 分类层

首先,分别对综合句法图卷积网络生成的句法表示和方面关注注意力生成的语义表示进行掩码操作,以提取特定方面的表示。然后,对这两种方面表示分别进行平均池化获得 \mathbf{H}_b^a 和 \mathbf{H}_a^c 。最后,采用特征拼接策略融合这两种特征表示,获得包含丰富结构信息和语义信息的最终方面表示 \mathbf{H}^a 。

$$\mathbf{H}_b^a = f(\text{mask}(\mathbf{H}_1, \mathbf{H}_2, \dots, \mathbf{H}_n)) \quad (16)$$

$$\mathbf{H}_a^c = f(\text{mask}(\mathbf{H}_1^c, \mathbf{H}_2^c, \dots, \mathbf{H}_n^c)) \quad (17)$$

$$\mathbf{H}^a = [\mathbf{H}_b^a, \mathbf{H}_a^c] \quad (18)$$

其中, $\text{mask}(\cdot)$ 为掩码函数,用于过滤掉非方面词的表示; $f(\cdot)$ 表示平均池化操作; $[\cdot]$ 表示特征拼接操作。将融合后的方面表示 \mathbf{H}^a 输入到一个线性层中,再通过一个 softmax 函数,获得情感极性的概率分布,过程如式(19)所示:

$$\mathbf{y}^s = \text{softmax}(\mathbf{W}^s \mathbf{H}^a + \mathbf{b}^s) \quad (19)$$

其中, \mathbf{W}^s 和 \mathbf{b}^s 为可学习的权重矩阵和偏置。

3.7 模型训练

模型的总损失函数由两个关键部分组成,即方面级情感分类损失和意见词感知模块的损失。其中,方面级情感分类采用标准的交叉熵损失函数。因此,模型的训练目标是最小化整体损失函数 L ,如式(20)所示:

$$L = L_s + L_p = - \sum_{i=1}^N \sum_{j=1}^C y_{ij}^s \log(Y_{ij}^s) + L_p \quad (20)$$

其中, N 为训练样本的个数, C 为情感极性的类别数, \mathbf{y}^s 为模型预测的情感概率分布, \mathbf{Y}^s 为样本的真实情感标签分布。

4 实验及结果分析

4.1 数据集和实验设置

为了验证模型的有效性,本文在来自 SemEval 2014 Task 4^[33] 的 Laptop 和 Restaurant 数据集以及来自 ACL 14^[34] 的 Twitter 数据集上进行了广泛的实验。其中 Laptop 和 Restaurant 数据集中的每个句子包含一个或多个方面词,而 Twitter 数据集中的每个句子仅包含一个方面词。所有方面词及其对应的情感极性(积极、中性和消极)都已经在数据集中进行了标注。这些数据集的统计信息如表 1 所列。

表 1 3 个基准数据集的统计信息

Table 1 Statistics for three benchmark datasets

Dataset		Positive	Negative	Neutral
Laptop	train	976	851	455
	test	337	128	167
Restaurant	train	2164	807	637
	test	727	196	196
Twitter	train	1507	1528	3016
	test	172	169	336

在实验中,采用 BERT 的 bert-base-uncased 版本作为句子编码器,并设置图神经网络的层数为 2, 暂退率为 0.3。对于 Laptop, Restaurant 和 Twitter 数据集,批量大小分别设为 32, 16 和 16。模型参数的优化使用 Adam 优化器,学习率设为 2×10^{-5} 。所有数据集均采用早停策略,并将最大训练轮数(Epochs)设置为 20。为了引入句法信息,所有句子使用斯坦福的 CoreNLP^[35] 解析器进行句法依赖解析,并将句法距离的最大阈值设为 10, 3 个数据集的加权系数 μ_1 和 μ_2 分别设为 (0.8, 0.3), (1.0, 0.1) 和 (0.3, 0.8)。为了降低强化学习的计算开销,将更新值 r 设为 0.1, 并将曲率的搜索空间限定在 (0, 5) 内。最终,通过实验确定了 Laptop, Restaurant 和 Twitter 数据集上最优的 α 和 β 分别为 (7, 2.5), (11, 0.8) 和 (7, 1.5)。

4.2 基线模型

为了验证本文模型的有效性,在上述 3 个数据集上进行了实验,并与现有的主流模型进行比较,以下是这些基线模型的简要描述。

Kuma-GCN^[36]: 通过一种门控机制来动态结合单词的依赖图和潜在图信息,从而利用潜在的语义依赖性来补充句法特征。

ACL^T^[9]: 提出一种可学习的以方面为中心的潜在树结构,从而缩短方面词与相应意见词之间的距离。

BERT4GCN^[37]: 通过 BERT 中间层的输出和单词之间的位置信息来增强 GCN, 以更好地编码句法依赖图。

DualGCN^[38]: 通过两个 GCN 分别学习句子的句法信息和语义信息,并引入正交和差分正则化器,以约束语义 GCN 更有效地学习语义相关性。

AGCN^[39]: 提出一种聚合 GCN, 利用两个聚合函数来捕捉长距离信息,从而更充分地利用上下文。

SSEGCN^[40]: 提出一种结合自注意力的方面感知注意力

机制,并构造句法掩码矩阵来补充语义信息。

dotGCN^[10]:通过关联注意力分数和句法距离,诱导生成离散意见树,并采用基于策略的强化学习对树诱导器进行训练。

MGFN^[20]:提出一种基于潜在图的多图融合网络,来利用更丰富的句法依赖关系标签信息和情感语义信息。

HGCN^[41]:提出一种混合图卷积网络,通过综合从成分树和依赖树中获得的信息,从而丰富句子表示。

LSOIT^[24]:通过强化学习和注意力机制,为每个方面生成知识感知的意见归纳树,这些机制整合了义元知识、短语结构和依赖关系。

SynPrompt^[42]:提出一种基于提示工程的新型句法感知增强提示方法,该方法强调通过句法关系设计出更强大的提示内容。

GCNet^[48]:通过将全局语义特征融入顺序建模过程,以更好地处理隐含表达的方面情感。

4.3 对比实验结果

对于所有实验,采用准确率(Acc)和宏平均 F1 分数(Macro-F1)作为模型分类性能的评价指标。对比实验结果如表 2 所列。实验结果表明,本文模型在 3 个数据集上的性能均优于所有基线模型,这验证了该模型能够有效捕捉特定方面与其对应意见词之间的关系,从而更准确地预测出方面词的情感极性。与 KumaGCN 和 GCNet 等仅考虑依赖树结构信息的模型相比,考虑句法依赖距离或句法依赖标签信息的模型(如 SSEGCN 和 MGFN)取得了更好的结果,该结果强调了使用句法依赖距离和依赖标签信息的重要性。而与 SSEGCN 和 MGFN 等仅利用单一类型句法信息的模型相比,本文模型以更有效的方式利用了句法依赖距离和句法依赖标签信息,在 3 个数据集上均取得了更优的性能表现,这表明全面有效地利用句法依赖信息能够增强模型对方面相关意见表达的捕捉能力,提升模型性能。此外,与 ACLT, HGCN 和 SynPrompt 等基于句法信息的模型相比,本文模型通过引入外部情感知识来增强对意见词的关注度,取得了更好的效果。

表 2 模型在 3 个基准数据集上的实验结果比较

Table 2 Comparison of experimental results of models on three benchmark datasets

Model	(%)					
	Laptop		Restaurant		Twitter	
	Acc	F1	Acc	F1	Acc	F1
KumaGCN	79.57	75.61	84.91	77.22	74.33	73.42
ACLT	79.68	75.83	85.71	78.44	75.48	74.51
BERT4GCN	77.49	73.01	84.75	77.11	74.73	73.76
DualGCN	81.80	78.10	87.13	81.16	77.40	76.02
AGCN	79.94	76.52	82.77	73.29	75.43	74.11
SSEGCN	81.01	77.96	87.31	81.09	77.40	76.02
dotGCN	81.03	78.10	86.16	80.49	78.11	77.00
MGFN	<u>81.83</u>	<u>78.26</u>	<u>87.31</u>	<u>82.37</u>	<u>78.29</u>	<u>77.27</u>
HGCN	79.59	76.24	86.45	80.60	76.52	73.57
LOSIT	81.41	77.16	86.88	82.27	77.75	76.94
SynPrompt	81.28	77.19	85.96	78.45	76.23	74.30
GCNet	80.79	77.61	87.08	81.35	77.55	76.56
Ours	82.12	79.18	87.58	82.80	78.73	77.74

注:最优结果用粗体标识;次优结果用下划线标识。

4.4 消融实验

为了验证模型中每个模块的有效性,进一步进行了消融实验,分别从原始模型中去掉意见词感知模块(即 w/o OPA)、句法距离图(w/o SD)、句法标签图(w/o SR)、综合句法图(w/o SG, w/o SD&SR)、方面关注注意力(w/o AF),其中 w/o SG 是将两个句法图直接相加代替启发式融合, w/o SD&SR 是使用句法联系矩阵代替综合句法图,实验结果如表 3 所列。可以观察到,去除模型中的任何一个模块都会导致模型在所有数据集上的性能下降,这说明了每个模块的有效性和必要性。具体来说,当去除意见词感知模块时,模型在所有数据集上的性能下降最多,这表明该模块能够有效增强模型对意见词的关注度;而当去除句法距离图和句法标签图时,模型在 Restaurant 数据集上的性能下降幅度最大,这说明对于语言相对规范、表达较为正式的数据来说,引入句法距离信息和句法标签信息是十分重要的。

表 3 消融实验结果

Table 3 Results of ablation study

Model	(%)					
	Laptop		Restaurant		Twitter	
	Acc	F1	Acc	F1	Acc	F1
w/o OPA	79.59	76.51	85.61	78.94	76.81	75.86
w/o SD	80.22	76.87	85.70	79.19	76.37	75.20
w/o SR	79.79	76.44	85.17	78.94	76.81	76.03
w/o SG	81.65	78.48	87.22	81.33	78.43	77.43
w/o SD&SR	80.85	77.61	85.17	78.74	76.96	76.07
w/o AF	79.91	76.82	86.06	79.45	77.99	76.82
Ours	82.12	79.18	87.58	82.80	78.73	77.74

4.5 关键超参数分析

本节在 3 个基准数据集上分析了 4 个关键超参数(句法距离上界、GCN 层数以及两个句法图的融合系数)对模型性能的影响,相关实验结果如图 3 所示。

句法距离上界的取值范围设定为 5~25,结果如图 3(a)所示,可以观察到,当句法距离上界为 10 时,模型在所有数据集上均取得了最优性能。这是因为若距离上界过小,模型可能无法充分利用长距离的依赖关系,从而丢失部分关键的句法信息。此外,该距离函数对远距离边的权重具有衰减特性,然而随着上界值的增大,模型性能并未出现显著下降。对于 GCN 层数,设置范围为 1~8,结果如图 3(b)所示,可以发现,当 GCN 层数设置为 2 时,模型达到最佳性能。这是由于单层 GCN 仅能聚合直接邻居的特征信息,使得模型学习到的信息较为有限,而过多的 GCN 层可能导致节点特征过度平滑,并引入冗余信息,从而削弱模型的分类能力。对于两个句法图的融合系数,采用固定其中一个系数,调整另一个系数(取值为 0.1~1)的方式进行实验,句法距离图和句法标签图的系数分别如图 3(c)和图 3(d)所示,可以看到,不同句法信息对不同数据集的重要性是不同的。例如,在 Twitter 数据集上,当句法距离图的系数为 0.3 和句法标签图的系数为 0.8 时,模型性能最好,这是由于该数据集中的每个句子只包含一个方面,因此句子中的大多数词都可能与该方面的情感相关,在这种情况下,句法依赖标签信息要比句法距离更为重要。因此,依据数据集的特征来设定不同句法信息的融合权重是很重要的。

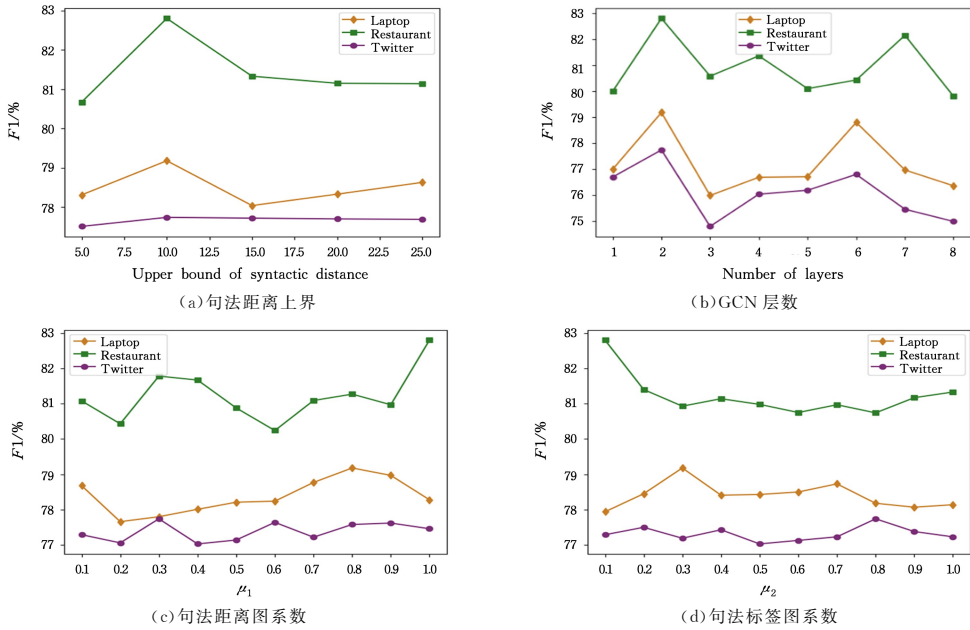


图3 关键超参数的影响

Fig. 3 Influence of key hyperparameters

4.6 强化学习的有效性分析

为了评估强化学习的搜索结果,在曲率搜索范围(0,5)内为每个数据集随机生成了10个不重复的曲率值,并进行实验。图4展示了3个数据集的随机曲率值及其对应的模型性能,其中3条水平虚线分别表示在3个数据集上通过强化学习找到的最优曲率值所对应的模型性能。从图中可以观察到,在3个数据集上,通过强化学习找到的曲率值所对应的模型性能均优于其他随机值的性能,这表明使用强化学习的方法能够高效找到最佳曲率值,而无须遍历所有可能的取值。此外,可以发现,不同数据集的最优曲率值是不同的,这表明对不同数据集搜索最佳曲率值有助于提升模型性能。这些发现验证了强化学习模块的有效性,尤其是在参数搜索空间较大或计算资源有限的情况下。

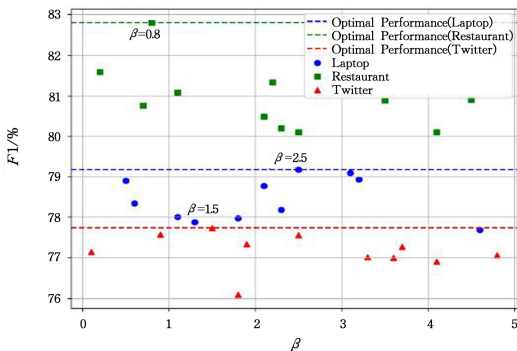


图4 强化学习的有效性分析

Fig. 4 Analysis of effectiveness of reinforcement learning

4.7 综合句法图可视化

图5展示了两个说明性实例的可视化结果,以验证所提出模型为特定方面词识别相应意见表达的有效性。在第一个实例中,模型通过综合句法图成功捕捉到了与方面词“folding chair”相关的意见表达“seated”和“uncomfortable”。尽管这些意见词与方面词相距较远,但模型通过利用意见感知的上下文表示和句法标签信息,显著提升了“uncomfortable”的权重,

同时降低了局部范围内其他无关词的权重(例如“at”),使模型能够集中在相关的意见表达上。此外,第二个实例包含多个方面词和意见词,在缺乏局部句法距离约束的情况下,模型可能错误地将远距离的意见词与目标方面建立关联,导致分类偏差。而本文模型通过有效地集成句法距离和句法标签信息,能够消除与方面无关的上下文干扰,从而更准确地识别每个方面词对应的意见表达。




图5 综合句法图的两个可视化例子

Fig. 5 Two visualization examples of the integrated syntactic graph

4.8 案例研究

通过采用不同模型对几个典型示例进行分类来进行案例研究,结果如表4所列。表中的符号P、N和O分别表示积极、消极和中性的情感极性。在第一个句子中,方面“food”和“service”与其对应意见词的距离都是较近的,因此3个模型都能正确预测这两个方面的情感极性。在第二个句子中,虽然每个方面词都有明确的情感表达,但方面“bar menu”与其对应的意见词“Disappointingly”的距离较远,而更接近“Saketini”的意见表达。由于DualGCN模型不能识别句法依赖标签和句法距离信息,所以可能更倾向于关注“wonderful”,从而导致对“bar menu”方面的错误预测。第三个句子虽然缺乏明显的情感线索,但模型能够基于上下文和句法信息进行推理。然而,DualGCN和MGFN模型由于没有考虑句法

距离信息,且在理解句子时出现一定程度的语义偏差,最终导致预测错误。总之,与真实标签相一致的预测表明,相较于基

线模型,本文模型捕获了更多的互补句法信息,可以更准确地识别特定方面对应的意见表达。

表4 个例研究的实验结果

Table 4 Experimental results of case study

Sentence	Label	DualGCN	MGFN	Ours
Great food but the service was dreadful!	(P,N)	(P,N)	(P,N)	(P,N)
Disappointingly,their wonderful Saketini has been taken off the bar menu .	(P,N)	(P,O)	(P,N)	(P,N)
On start up it asks endless questions just so itune can sell you more of their products!	(N,N)	(P,O)	(P,O)	(N,N)

注:加粗表示每句话的各个方面;Label代表方面词的真实情感极性;DualGCN,MGFN和Ours代表对应模型预测的情感极性。

结束语 本文提出一种知识辅助和强化句法驱动的方面级情感分析方法,它能够更准确地识别出句子中的意见表达,并将每个意见表达与其相应的方面词进行对齐。首先,引入外部知识库构建意见词感知模块,来让编码器关注句子中的意见表达。然后,基于距离函数的优化策略构建句法距离图,同时,对于每条依赖边,通过结合每层GCN单词间的关系来构建句法标签图,并对这两种句法图进行集成,以获取局部到全局的句法信息,从而识别出与方面最相关的意见表达。最后,使用方面关注注意力来处理一些非结构化句法的句子。在3个基准数据集上的实验结果验证了本文模型的有效性。

虽然本文设计了适合于方面级情感分析的综合句法图,但其构建主要基于依赖树的句法信息,而依赖树结构只揭示单词之间的关系,在大多情况下无法对句子的复杂关系(如并列、疑问或从属关系)进行建模,所以未来应该考虑更多其他的句法结构信息(如短语结构树),来更全面地学习句子的句法信息。此外,刘兵意见词典虽然覆盖了大量的意见词,但在处理领域特定情感词和新兴词汇方面仍存在不足。因此,未来应该探索更多对外部情感知识库的利用,帮助模型更全面地识别与方面相关的意见表达。

参 考 文 献

- [1] HUA Y C, DENNY P, WICKER J, et al. A systematic review of aspect-based sentiment analysis: domains, methods, and trends [J]. *Artificial Intelligence Review*, 2024, 57(11): 296.
- [2] WANKHADE M, KULKARNI C, RAO A C S. A survey on aspect base sentiment analysis methods and challenges[J]. *Applied Soft Computing*, 2024, 167: 112249.
- [3] WANG Y, HUANG M, ZHU X, et al. Attention-based LSTM for aspect-level sentiment classification[C]// *Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing*. 2016: 606-615.
- [4] FAN F, FENG Y, ZHAO D. Multi-grained attention network for aspect-level sentiment classification [C] // *Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing*. 2018: 3433-3442.
- [5] HUANG B, OU Y, CARLEY K M. Aspect level sentiment classification with attention-over-attention neural networks[C]// *International Conference on Social Computing, Behavioral-Cultural Modeling and Prediction and Behavior Representation in Modeling and Simulation*. Cham: Springer, 2018: 197-206.
- [6] DAI J, YAN H, SUN T, et al. Does syntax matter? a strong baseline for aspect-based sentiment analysis with roberta[J]. *arXiv*: 2104. 04986, 2021.
- [7] HUANG B, CARLEY K M. Syntax-Aware Aspect Level Sentiment Classification with Graph Attention Networks[C]// *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP)*. 2019: 5469-5477.
- [8] ZHONG Q, DING L, LIU J, et al. Knowledge graph augmented network towards multiview representation learning for aspect-based sentiment analysis[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(10): 10098-10111.
- [9] ZHOU Y, LIAO L, GAO Y, et al. To be Closer: Learning to Link up Aspects with Opinions[C]// *2021 Conference on Empirical Methods in Natural Language Processing, EMNLP 2021, ACL*, 2021: 3899-3909.
- [10] CHEN C, TENG Z, WANG Z, et al. Discrete opinion tree induction for aspect-based sentiment analysis[C]// *Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics*. 2022: 2051-2064.
- [11] CHEN B, OUYANG Q, LUO Y, et al. S2GSL: Incorporating Segment to Syntactic Enhanced Graph Structure Learning for Aspect-based Sentiment Analysis[C]// *Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics*. 2024: 13366-13379.
- [12] HUTTO C, GILBERT E. Vader: A parsimonious rule-based model for sentiment analysis of social media text[C]// *Proceedings of the International AAAI Conference on Web and Social Media*. 2014: 216-225.
- [13] KIRITCHENKO S, ZHU X, CHERRY C, et al. NRC-Canada-2014: Detecting aspects and sentiment in customer reviews [C]// *Proceedings of the 8th International Workshop on Semantic Evaluation (SemEval 2014)*. 2014: 437-442.
- [14] KALBHOR S, GOYAL D. Survey on ABSA based on machine learning, deep learning and transfer learning approach[C]// *AIP Conference Proceedings*. AIP Publishing, 2023.
- [15] ZHANG Y, XU B, ZHAO T. Convolutional multi-head self-attention on memory for aspect sentiment classification[J]. *IEEE/CAA Journal of Automatica Sinica*, 2020, 7(4): 1038-1044.
- [16] HUANG B, GUO R, ZHU Y, et al. Aspect-level sentiment analysis with aspect-specific context position information [J]. *Knowledge-Based Systems*, 2022, 243: 108473.
- [17] ZHANG C, LI Q, SONG D. Aspect-based Sentiment Classification with Aspect-specific Graph Convolutional Networks[C]// *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP)*. 2019: 5469-5477.

- NLP). 2019;4568-4578.
- [18] HOU X, QI P, WANG G, et al. Graph Ensemble Learning over Multiple Dependency Trees for Aspect-level Sentiment Classification[C]// Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics; Human Language Technologies. 2021;2884-2894.
- [19] KONG M, FENG L, ZHANG C, et al. Distance-reconstructed dependency enhanced aspect-based sentiment analysis with sentiment strength[J]. *Neurocomputing*, 2024, 608:128459.
- [20] TANG S, CHAI H, YAO Z, et al. Affective knowledge enhanced multiple-graph fusion networks for aspect-based sentiment analysis[C]// Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing. 2022;5352-5362.
- [21] GU T, ZHAO H, HE Z, et al. Integrating external knowledge into aspect-based sentiment analysis using graph neural network [J]. *Knowledge-based Systems*, 2023, 259:110025.
- [22] GU T, HE Z, LI Z, et al. Information-assisted and sentiment relation-driven for aspect-based sentiment analysis [J]. *Expert Systems with Applications*, 2025, 278:127308.
- [23] CAO Y, TANG Y, DU H, et al. Heterogeneous reinforcement learning network for aspect-based sentiment classification with external knowledge[J]. *IEEE Transactions on Affective Computing*, 2023, 14(4):3362-3375.
- [24] WU H, ZHOU D, SUN C, et al. LSOIT: Lexicon and syntax enhanced opinion induction tree for aspect-based sentiment analysis[J]. *Expert Systems with Applications*, 2024, 235:121137.
- [25] 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.
- [26] SONG Y, WANG J, JIANG T, et al. Attentional encoder network for targeted sentiment classification [J]. *arXiv*: 1902.09314, 2019.
- [27] CHEN M, LI X. Swafn: Sentimental words aware fusion network for multimodal sentiment analysis[C]// Proceedings of the 28th International Conference on Computational Linguistics. 2020;1067-1077.
- [28] HU M, LIU B. Mining and summarizing customer reviews[C]// Proceedings of the Tenth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2004;168-177.
- [29] ZHAO X, PENG H, DAI Q, et al. Rdgcn: Reinforced dependency graph convolutional network for aspect-based sentiment analysis [C]// Proceedings of the 17th ACM International Conference on Web Search and Data Mining. 2024;976-984.
- [30] VERMOREL J, MOHRI M. Multi-armed bandit algorithms and empirical evaluation [C]// European Conference on Machine Learning. Berlin; Springer, 2005:437-448.
- [31] ZHAO X, DAI Q, WU J, et al. Multi-view tensor graph neural networks through reinforced aggregation[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2022, 35(4):4077-4091.
- [32] ZHAO X, WU J, PENG H, et al. Deep reinforcement learning guided graph neural networks for brain network analysis[J]. *Neural Networks*, 2022, 154:56-67.
- [33] PONTIKI M, GALANIS D, PAPAGEORGIOU H, et al. Semeval-2014 task 4: Aspect based sentiment analysis[C]// International Workshop on Semantic Evaluation. 2014;27-35.
- [34] DONG L, WEI F, TAN C, et al. Adaptive recursive neural network for target-dependent twitter sentiment classification[C]// Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics. 2014;49-54.
- [35] MANNING C D, SURDEANU M, BAUER J, et al. The StanfordCoreNLP natural language processing toolkit[C]// Proceedings of 52nd Annual Meeting of the Association for Computational Linguistics; System Demonstrations. 2014;55-60.
- [36] CHEN C, TENG Z, ZHANG Y. Inducing target-specific latent structures for aspect sentiment classification[C]// Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). 2020;5596-5607.
- [37] XIAO Z, WU J, CHEN Q, et al. Bert4gcn: Using bert intermediate layers to augment gcn for aspect-based sentiment classification[J]. *arXiv*:2110.00171, 2021.
- [38] LI R, CHEN H, FENG F, et al. Dual graph convolutional networks 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;6319-6329.
- [39] ZHAO M, YANG J, ZHANG J, et al. Aggregated graph convolutional networks for aspect-based sentiment classification[J]. *Information Sciences*, 2022, 600:73-93.
- [40] ZHANG Z, ZHOU Z, WANG Y. SSEGCN: Syntactic and semantic enhanced graph convolutional network for aspect-based sentiment analysis[C]// Proceedings of the 2022 Conference of the North American Chapter of the Association for Computational Linguistics; Human Language Technologies. 2022;4916-4925.
- [41] XU L, PANG X, WU J, et al. Learn from structural scope: Improving aspect-level sentiment analysis with hybrid graph convolutional networks[J]. *Neurocomputing*, 2023, 518:373-383.
- [42] YIN W, LIU C, XU Y, et al. SynPrompt: Syntax-aware Enhanced Prompt Engineering for Aspect-based Sentiment Analysis[C]// Proceedings of the 2024 Joint International Conference on Computational Linguistics, Language Resources and Evaluation (LREC-COLING 2024). 2024;15469-15479.
- [43] ZHOU T, SHEN Y, LI Y. Gcnct: Global-and-context collaborative learning for aspect-based sentiment analysis[C]// Proceedings of the 2024 Joint International Conference on Computational Linguistics, Language Resources and Evaluation (LREC-COLING 2024). 2024;7570-7580.



ZHENG Cheng, born in 1964, Ph.D, associate professor. His main research interests include data mining, text analysis, and natural language processing.