

融合句法增强与语义增强的方面情感分析

刘耀^{1,2}, 吴云飞³, 周红静³, 黄少年³, 张震¹

(1. 湖南工商大学长沙人工智能社会实验室, 湖南 长沙 410205;

2. 湖南工商大学数字媒体工程与人文学院, 湖南 长沙 410205;

3. 湖南工商大学计算机学院, 湖南 长沙 410205)

摘要: 使用图神经网络在句子的句法依赖树上建模进行方面情感分析时, 主要关注句子的句法结构, 但是忽视了对依赖树本身以及语义信息的研究, 同时非结构化文本中句法信息会带来额外噪声。针对上述问题, 提出一种融合句法增强与语义增强的图卷积网络模型, 使用注意力机制提取方面信息和全局信息并通过门控机制结合增强语义信息, 同时利用外部情感知识以及单词的距离特征重塑依赖树来提高意见词权重增强句法信息, 最后对句法信息和语义信息进行动态特征融合。在3组公开数据集上进行了大量的实验, 结果表明, 提出的模型准确率和宏F1值相较于对比模型更高, 验证了融合句法增强和语义增强在方面情感分析中的有效性。

关键词: 方面情感分析; 图卷积网络; 注意力机制; 门控机制

中图分类号: TP391.1

文献标志码: A

doi: 10.11959/j.issn.2096-6652.202505

Fusion of syntactic enhancement and semantic enhancement for aspect-based sentiment analysis

LIU Yao^{1,2}, WU Yunfei³, ZHOU Hongjing³, HUANG Shaonian³, ZHANG Zhen¹

1. Changsha Social Laboratory of Artificial Intelligence, Hunan University of Technology and Business, Changsha 410205, China

2. School of Digital Media Engineering and Humanities, Hunan University of Technology and Business, Changsha 410205, China

3. School of Computer Science, Hunan University of Technology and Business, Changsha 410205, China

Abstract: The graph neural networks mainly focus on the syntactic structure when they are used to model the syntactic dependency tree of a sentence for aspect-based sentiment analysis (ABSA). However, these methods neglect the study of dependency tree itself and semantic information, and syntactic information in unstructured text can bring additional noise. To address these issues, a graph convolutional network (GCN) model integrating syntactic and semantic enhancements was proposed. Attention mechanism was used to extract aspect information and global information, and enhance semantic information through gating mechanism. Simultaneously, dependency tree was reshaped to increase the weight of opinion words and enhance syntactic information by utilizing external emotional knowledge and the distance features of words. Finally, dynamic feature fusion was performed on semantic and syntactic information. Extensive experiments were conducted on three public datasets. The experiment results show that the accuracy and macro-F1 values are better than the compared models, which indicate the effectiveness of the fusion of syntactic enhancement and semantic enhancement for ABSA.

Key words: aspect-based sentiment analysis, graph convolutional network, attention mechanism, gating mechanism

收稿日期: 2024-09-27; 修回日期: 2025-01-03

通信作者: 周红静, hjzhou@hutb.edu.cn

基金项目: 长沙人工智能社会实验室资助项目; 国家自然科学基金项目 (No.62202161); 湖南省教育厅科学研究项目 (No.21A0376); 湖南省社会科学成果评审委员会课题 (No.XSP25YBC164)

Foundation Items: The Project of Changsha Social Laboratory of Artificial Intelligence, The National Natural Science Foundation of China (No.62202161), The Scientific Research Project of the Department of Education of Hunan Province (No.21A0376), The Project of Hunan Social Science Achievement Appraisal Committee (No.XSP25YBC164)

0 引言

网络社交媒体现在成为人们发表评论和表达观点的重要渠道,有效识别和利用这些评论和观点的情感极性(积极、消极和中性)^[1]在舆情分析与防控、政策制定与评估、市场科学决策等领域具有广泛的应用前景。情感分析通过对给定的文本数据进行解析,推断出其中所要表达的态度或情感极性。传统情感分析主要针对给定文本的整体情感,无法评价某个特定方面的具体情感。方面情感分析(aspect-based sentiment analysis, ABSA)旨在检测一个句子在不同方面的情感倾向^[2],从而能够满足用户更细粒度的情感分析需求。例如,在句子“This laptop has an excellent screen, but the graphics card is comparatively poor.”中,包含了对“screen”和“graphics card”两个方面的情感倾向。在“screen”这个方面,情感倾向是积极的;但在“graphics card”这个方面,情感倾向则是消极的。通过方面情感分析,研究人员可以精准了解人们对特定话题、事件或产品的情感倾向,从而掌握人们的喜好、态度甚至行为模式,为相关研究和决策提供有力的支持。

ABSA任务最初主要使用基于情感词典和传统机器学习的方法^[3-4],需要人工提取特征,成本耗费高,模型的性能和泛化能力却不理想。为了更好地理解文本中词语之间的依赖关系和语义信息,提高情感分析的准确性,神经网络模型^[5-10]被用来捕捉文本中的上下文信息,但这类方法容易受句子中噪声的影响,也忽略了句法结构和所涉及的方面来获得更丰富的情感信息。研究者利用句法依赖树构建图神经网络(graph neural network, GNN)^[11-14]来得到上下文和方面词之间的句法依赖关系,使得模型能够捕捉句法信息和长距离依赖关系,有助于更好地理解文本中的情感信息。一些研究工作同时利用句法结构和语义相关性构建图神经网络模型^[15-17],通过整合两者信息增强方面特征。尽管这类方法在ABSA任务中已经取得了良好的性能,但在特定情况下效果仍不理想。例如, Twitter数据集中的句子“you got google wave? well, well, well”表达简洁,缺乏明确的句法结构,对这类非结构化语句提取句法信息反而会给模型引入额外的噪声。同时,目前大多数工作集中在从依赖树中通过句法知识学习上下文与方面词之间的依赖关系,而忽视了意见词对情感依赖关系的重要性,并且对语义信

息的提取不够充分。

因此,本文提出了一种融合句法增强与语义增强的图卷积网络(fusion of syntactic enhancement and semantic enhancement for graph convolutional network, FSESE-GCN)模型,主要贡献如下。

- 设计了语义增强图,引入方面注意力机制提取方面信息增强语义特征,并通过门控机制与自注意力机制提取的全局上下文信息进行结合;设计了句法增强图,引入外部情感和单词的距离特征重塑依赖树,通过增强意见词的重要性来增强上下文与方面词的情感依赖关系,并减少无关词带来的噪声。
- 根据文本序列长度区分结构化和非结构化语句设计特征融合模块,动态赋予句法信息和语义信息不同权重进行融合来解决图卷积网络(graph convolutional network, GCN)模型对非结构化语句建模会引入额外噪声的问题。
- 在3个公开数据集上进行了大量的实验来评估模型性能,结果表明,本文提出的模型在不同数据集下准确率和宏F1均能取得较好的性能。

1 相关工作

方面情感分析是一种细粒度的情感分类,用于判别句子中特定方面的情感极性。早期基于情感词典和传统机器学习的方法需要大量的人工判断,无法完全覆盖各种语境和领域,存在很大局限性。因此,一些研究者探索基于深度学习的方法实现ABSA任务。由于循环神经网络(recurrent neural network, RNN)具有优秀的序列学习能力,之前的许多研究利用RNN及其变体学习句子中单词之间的关系。Tang等^[5]提出两种基于长短期记忆(long short term memory, LSTM)网络的模型,整合方面词与上下文之间的联系,提高分类的准确性。Ruder等^[6]构造层次化的双向LSTM网络,同时考虑句子内部与句子之间的关系来提升模型性能。卷积神经网络(convolutional neural network, CNN)模型相比RNN模型更擅长捕捉文本的局部特征,因此被用于ABSA任务的方面特征提取^[7]。基于注意力机制的方法能够高度关注特定的信息,可以让方面词参与注意力权重的计算^[8]。Ma等^[9]构造交互式注意力网络,通过使用两个注意力网络来交互地建模方面词和上下文,更有效地学习方面词和上下文特征。徐志栋等^[10]使用卷积和交互注意力提取上下文和方面词特征,并引入胶囊网络解决单

句文本中的特征重叠问题。虽然这类模型能较好地提取句子的语义信息,但在句子有多个方面词时会受噪声影响,且存在效率低、容易产生梯度消失和梯度爆炸、无法有效处理长距离依赖关系的问题。

基于图神经网络的方法处理非结构化数据具有很好的优势,近年来被应用到ABSA任务中。在句法依赖树上构建GCN能有效捕捉句法结构和长距离依赖关系^[11]。Wang等^[12]定义了一种以目标方面为根的方面导向依赖树结构,并用关系图注意力网络建模进行情感分类。Zhao等^[13]使用GCN捕捉同一句子中不同方面之间的情感依赖关系。外部情感知识库SenticNet作为常识知识与GCN编码器相结合能够丰富句子中的情感信息^[14]。在GCN的基础上结合语义信息能够帮助模型更好地理解上下文。Li等^[15]使用双通道图卷积网络分别构建了基于语法和语义的图卷积网络,并利用双仿射模块对两个通道信息进行交互。Liu等^[16]将GCN与门控机制相结合,以增强GCN对节点信息的完全聚合并加强对给定方面的关注,再将情感知识整合到图神经网络中细化情感特征的感知。Wang等^[17]提出方面融合注意力,并与修剪的依赖树结合来精确意见词的识别范围,再与语义信息进行交互。虽然这类模型已经取得了很好的性能,但仍然存在语义信息提取不充分的问题。

2 FSESE-GCN模型

FSESE-GCN模型架构如图1所示,由词嵌入与双向长短期记忆(bidirectional long short term memory, Bi-LSTM)、语义增强图、句法增强图、特征融合、图卷积网络、最终表示层和输出层7个模块组成。

2.1 问题定义

FSESE-GCN模型的输入由句子单词序列 $s = \{w_1, w_2, \dots, w_n\}$ 和方面序列 $s^a = \{w_1^a, w_2^a, \dots, w_m^a\}$ 两部分组成。其中, w_i 表示句子单词序列中的第 i 个词, w_i^a 表示方面序列中的第 i 个词, s^a 是 s 的子序列。

2.2 词嵌入与Bi-LSTM

本文分别使用了GloVe^[18]和BERT^[19]作为词嵌入的预训练模型。首先,将输入序列中的每个词通过嵌入矩阵 $E \in \mathbb{R}^{|N| \times d_e}$ 映射到一个低维向量空间中。其中, $|N|$ 为词典大小, d_e 是词嵌入维度。输入的单词 w_i 由向量 v_i 表示,生成的词嵌入矩阵为 $V = \{v_1, v_2, \dots, v_n\}$ 。

将词嵌入矩阵 V 输入Bi-LSTM中进行句子编码,得到上下文相关的隐藏状态向量表示 $H^c = \{h_1^c, h_2^c, \dots, h_n^c\}$ 及其对应的方面项表示 $h^a = \{h_1^a, h_2^a, \dots, h_m^a\}$ 。




图1 FSESE-GCN模型架构

2.3 语义增强图

本文使用自注意力机制，通过获取单个句子中任意两个单词之间的交互信息构建语义图，计算式如式（1）所示：

$$A_i^{\text{self}} = \frac{H^C W^Q \times (H^C W^K)^T}{\sqrt{d}} \quad (1)$$

其中，查询向量 Q 和键向量 K 均由编码层输出的隐藏状态向量 H^C 代替， $W^Q \in \mathbb{R}^{d \times d}$ 和 $W^K \in \mathbb{R}^{d \times d}$ 是可学习的权重， i 表示注意力头数， d 是输入向量特征的维度。

由于句子中有很多无效词干扰，并且大部分研究忽视了对特定方面的关注。本文使用方面感知注意力机制捕捉特定方面的语义信息以学习与方面相关的特征^[20]，计算式如式（2）所示：

$$A_i^{\text{asp}} = \tanh \left(H^a W^a \times (H^C W^K)^T + b \right) \quad (2)$$

其中， $W^a \in \mathbb{R}^{d \times d}$ 是方面学习的权重， b 为偏差项， i 为注意力头数， $H^a \in \mathbb{R}^{n \times d}$ 表示将 h^a 均值池化并复制 n 次得到的句子中特定方面隐藏状态向量。

最后，将得到的方面注意力矩阵 A_i^{asp} 与自注意力矩阵 A_i^{self} 利用门控机制实现融合，使模型自适应调整权重来减少语义噪声，得到增强后的语义图 A^{sem} 计算式如式（4）所示：

$$G = \text{sigmoid}(A_i^{\text{self}} H^C W (A_i^{\text{asp}} H^a)^T) \quad (3)$$

$$A^{\text{sem}} = G \odot A_i^{\text{self}} + (1 - G) \odot A_i^{\text{asp}} \quad (4)$$

其中， $W \in \mathbb{R}^{d \times d}$ 是可学习的权重， G 是自动生成的门控权重矩阵， $\odot$ 为哈达玛积。

2.4 句法增强图

考虑句法结构，本文对句子进行句法依赖分析并构建句法依赖树，将树中的关系作为边来构建图，并将每个单词视为节点，图的邻接矩阵 $D \in \mathbb{R}^{n \times n}$ 表示为：

$$D_{i,j} = \begin{cases} 1, w_i \text{和} w_j \text{存在依赖关系} \\ 0, \text{其他} \end{cases} \quad (5)$$

本文构建无向图，认为单词之间的依赖关系是相互的，父节点与其子节点相互影响^[11]，即 $D_{i,j} = D_{j,i}$ 。

目前研究更多地关注对基于深度学习的ABSA模型的改进，而忽略了依赖关系图的构建。同时，方面对应的意见词有助于判断方面情感极性。因此，引入外部情感知识和单词的距离特征重塑依赖树 D ，通过增强意见词的重要性来增强依赖关系，

增强后的邻接矩阵 $A^{\text{syn}} \in \mathbb{R}^{n \times n}$ 表示为：

$$A_{i,j}^{\text{syn}} = D_{i,j} \times (S_{i,j} + T_{i,j} + 1) \quad (6)$$

其中， $S_{i,j}$ 表示外部情感知识信息， $T_{i,j}$ 表示包含节点距离信息的加权矩阵。

本文采用文献[21]的方法，将SenticNet作为外部情感知识，增强方面词和上下文的情感信息，从而提高方面词和意见词之间的依赖强度，计算式如式（7）所示：

$$S_{i,j} = \text{SenticNet}(w_i) + \text{SenticNet}(w_j) \quad (7)$$

其中， $\text{SenticNet}(w_i) \in [-1, 1]$ 表示单词 w_i 的情感得分。得分为0，则表示单词是中性词或没被包含在SenticNet中。

在句子中，单词之间的距离和它们的语义相关度往往密切相关，两个单词之间的距离越短，则表示它们的语义相关程度越高。意见词往往在文本距离或句法距离上更靠近方面词，由此可以根据方面词与上下文之间的距离关系构建加权矩阵 $T_{i,j}$ ，从而精确意见词范围，增强意见词的重要程度，如下所示：

$$T_{i,j} = \begin{cases} 1 - \frac{\exp(p_{i,j})}{\exp(p_{\max}) + 1}, w_i \text{或} w_j \text{是方面词} \\ 0, \text{其他} \end{cases} \quad (8)$$

其中， $p_{i,j}$ 表示单词的距离特征， $p_{\max}$ 表示单词之间距离的最大值。

单词的距离特征可分为序列距离和依赖距离^[22]，序列距离指两个单词在句子序列中的距离，餐厅评论的依赖关系树如图2所示。单词“food”和单词“was”序列距离为5；依赖距离指两个单词在句法依赖树上所对应节点之间的最短距离，例如单词“food”和单词“was”的依赖距离为1。两种距离特征都表示着不同程度的局部上下文信息，因此本文融合两种距离特征，得到的融合距离 $p_{i,j}$ ：




图2 餐厅评论的依赖关系树

$$p_{i,j} = \frac{p_{i,j}^{\text{dep}} + p_{i,j}^{\text{seq}}}{2} \quad (9)$$

其中， $p_{i,j}^{\text{dep}}$ 表示 w_i 和 w_j 之间的依赖距离， $p_{i,j}^{\text{seq}}$ 表示

w_i 和 w_j 之间的序列距离。

2.5 特征融合

序列长度越短的文本越可能为非结构语句，通过简洁的信息传达核心内容。序列长度越长的文本，越可能包含复杂的句法结构。因此，句法信息在短句中更可能引入额外噪声，而在长句中会显得更加重要。对此本文设计了动态加权求和算法来自适应地调整语义增强图和句法增强图的融合权重，使模型对短句更关注语义信息，而对长句更关注句法信息。增强模型对句法信息和语义信息的互补能力，从而尽可能地减轻噪声的影响，权重 β 的计算式如式(10)所示：

$$\beta = \begin{cases} 1, n \leq k \\ \frac{k}{n}, n > k \end{cases} \quad (10)$$

其中， n 表示输入文本序列长度， k 为设置的长度阈值。最后，得到融合了语义信息和句法信息的邻接矩阵 $A \in \mathbb{R}^{n \times n}$ ，如式(11)所示：

$$A = \beta A^{\text{sem}} + (1 - \beta) A^{\text{syn}} \quad (11)$$

2.6 图卷积网络

基于在句法增强图和语义增强图融合后导出的邻接矩阵，将它输入GCN层中以学习给定方面的情感依赖。然后，根据Bi-LSTM层学习的隐藏表示 h_i 作为原始节点来更新GCN中第 l 层中的每个节点 h_i^l ，如下所示：

$$h_i^l = \text{relu}(\tilde{A}_i g_i^{l-1} W^l + b^l) \quad (12)$$

$$g_i^l = \mathcal{F}(h_i^l) \quad (13)$$

其中， $\tilde{A}_i = A_{i,j}/(x_i + 1)$ 是归一化矩阵， $x_i = \sum_{j=1}^n A_{i,j}$ 表示第 i 个节点的度， g_i^l 为 h_i^l 经过分配位置权重的函数 $\mathcal{F}(\cdot)$ 转换得到的特征表示^[11]。 W^l 和 b^l 分别是第 l 层的权重矩阵和偏置项。最后，最终 L 层图卷积输出表示为 $H^L = [h_1^L, h_2^L, \dots, h_n^L]$ 。

2.7 最终表示层

对GCN生成的输出进行遮掩来突出方面词的重要特征，从而提高模型对于特定方面情感的识别能力。具体操作是通过屏蔽非方面词，并保留方面词不变，如式(14)所示：

$$\tilde{h}_t = \begin{cases} h_t^L, & \tau \leq t < \tau + m \\ 0, & \text{其他} \end{cases} \quad (14)$$

其中， τ 是方面项的开始位置， m 是方面词长度。最后得到特定方面掩码的隐藏向量表示为： $\tilde{H}_{\text{mask}} =$

$$\{0, \dots, h_{\tau}^L, \dots, h_{\tau+m-1}^L, \dots, 0\}。$$

根据给定序列的隐藏状态向量 H^C ，利用基于检索的注意力机制^[11]，衡量上下文词与方面词之间的情感信息和语义相关性，得到第 t 个上下文词相对于方面词的注意力分数 γ_t ，如式(15)所示；并为每个上下文词按照重要程度分配注意力权重 α_t ，如式(16)所示：

$$\gamma_t = \sum_{i=1}^n h_t^{C^T} \tilde{h}_i = \sum_{i=\tau}^{\tau+m-1} h_t^{C^T} \tilde{h}_i \quad (15)$$

$$\alpha_t = \frac{\exp(\gamma_t)}{\sum_{i=1}^n \exp(\gamma_i)} \quad (16)$$

最终表示为带注意力权重的特征向量，计算式如式(17)所示：

$$r = \sum_{i=1}^n \alpha_i h_i^C \quad (17)$$

2.8 输出层

将特征向量 r 输入全连接层做维度变换，通过Softmax函数得到预测情感极性的分类 y ，如式(18)所示：

$$y = \text{Softmax}(W_y r + b_y) \quad (18)$$

其中， W_y 是权重矩阵， b_y 为偏置项。

模型采用标准梯度下降算法进行参数优化和更新，同时结合了L2正则化和交叉熵损失函数，以降低过拟合的风险并提高模型的泛化能力，损失函数 $L(\theta)$ 表示为：

$$L(\theta) = - \sum_{i=1}^N \sum_{j=1}^C \hat{y}_i^j \cdot \ln(y_i^j) + \lambda \|\theta\|^2 \quad (19)$$

其中， N 是训练样本的数量， C 是情感极性标签的维数， $\hat{y}_i^j$ 代表真实标签， y_i^j 代表预测标签， θ 表示所有可训练参数， λ 是L2的正则化系数。

3 实验与结果分析

3.1 数据集和评价指标

本文实验都是在配置为Intel Core i9-13980HX CPU、NVIDIA RTX4060 GPU的服务器上，使用Python 3.10实现。本文使用SemEval-2014 Task 4的Restaurant和Laptop数据集^[23]以及Twitter短文评论数据集^[24]来验证FSESE-GCN模型的有效性，每个数据集都包含一个训练集和测试集。数据集信息见表1。模型采用准确率(accuracy, Acc)和宏F1值(macro-F1)作为性能评价指标。

表1 数据集信息

数据集	积极		中性		消极	
	训练集 /个	测试集 /个	训练集 /个	测试集 /个	训练集 /个	测试集 /个
Restaurant	2 164	728	637	196	807	196
Laptop	994	341	464	169	870	128
Twitter	1 561	173	3 127	346	1 560	173

3.2 实验设置

实验使用 spaCy 生成句法依赖树以及单词的序列距离和依赖距离，分别采用单词嵌入维度为 300 的 GloVe 词向量和维度为 768 的 BERT 预训练模型。GCN 层的深度为 2，注意力头数设置为 8，L2 正则化项的系数为 0.00001，防止网络过拟合以及加快网络收敛，批训练样本设置为 32。对于所有神经网络层，隐藏状态向量的维度为 300，学习率为 0.001，使用 Adam 对训练参数进行优化和更新。

3.3 对比模型

ATAE-LSTM^[8]：基于注意力的 LSTM 模型，学习方面词嵌入并让方面词参与计算注意力权重。

IAN^[9]：通过交互注意力网络学习方面词与上下文的注意力，能有效表示方面词和上下文，并能注意对判断方面词情感极性很重要的词。

AOA^[25]：使用注意力机制增强方面词与上下文之间的语义信息交互作用，并对句子的重要成分自动关注。

MGAN^[26]：结合了细粒度和粗粒度注意力机制，利用细粒度注意力机制负责链接和融合方面和上下文的单词，以捕捉单词层面的交互。

ASGCN^[11]：在句子的依赖树上建立一个图卷积网络，利用句法结构和单词依赖性进行基于方面的情感分类。

R-GAT^[12]：使用关系图注意力网络对句法结构编码构建面向方面的依赖树结构，用于基于方面的情感预测。

DualGCN^[15]：采用双通道图卷积网络，通过 SynGCN 模块解析句法结构，并结合具有自注意力机制的 SemGCN 模块捕捉单词间的语义相关性。

SenticGCN^[21]：结合 SenticNet 的情感知识构建图神经网络来增强句子的依赖树，同时考虑了上下文和方面词的依赖关系以及观点词和方面词的情感信息。

DAGCN^[17]：提出了一种基于距离和面向方面的图卷积网络，通过修剪依赖树和使用方面融合注

意力来消除上下文噪声，精确识别意见词范围。

BERT^[19]：适用于 ABSA 任务的 BERT 预训练模型。

APARN^[27]：用抽象意义表示取代句法依赖树的语义结构来提取语义特征，并提出关系增强的自注意机制来改善句子特征。

3.4 实验结果分析

实验结果对比见表 2。从表 2 可以看出，本文提出的 FSESE-GCN 模型总体上优于基准模型，这些实验结果验证了模型结构的有效性。

当编码器为 Bi-LSTM 时，FSESE-GCN 模型除了在 Twitter 数据集上的准确率低于 DAGCN 模型外，其他都高于基准模型。与 ATAE-LSTM、IAN 和 AOA 等基于注意力机制的方法相比，FSESE-GCN 模型在利用自注意力提取上下文信息的基础上，增强了方面词的重要性，同时减少了由注意力机制带来的噪声影响；与 ASGCN、R-GAT 和 DualGCN 等基于句法图的方法相比，FSESE-GCN 模型通过额外引入外部情感知识和单词的距离特征增强了与意见词的重要性，取得了更好的性能。

当编码器为 BERT 时，模型性能相比编码器为 Bi-LSTM 时得到了明显的提升，因为 BERT 生成的词嵌入是动态的，同一个词在不同的上下文中会有不同的词嵌入表示，通过它的 Transformer 结构可以捕捉到句子中的上下文信息，从而生成上下文相关的词嵌入。FSESE-GCN 模型与基准模型相比，在 Restaurant 数据集上仅宏 F1 值低于 APARN 模型；在 Laptop 数据集上的准确率和宏 F1 值均高于基准模型；在 Twitter 数据集上的准确率和宏 F1 值都低于 APARN 模型，是由于 APARN 模型使用的 AMR 解析器预先在与 Twitter 数据集相似的数据集上进行了训练，使其更适合 Twitter 数据集，但本文模型依然取得了相近的结果，说明了 FSESE-GCN 模型处理非结构化语句的有效性。

3.5 消融实验

通过消融实验来分析 FSESE-GCN 中每个模块的作用，w/o syn 表示去掉句法增强图，w/o sem 表示去掉语义增强图，w/o mask 表示去掉方面掩码，w/o FF 表示去掉特征融合层，将两个模块得到的输出直接进行拼接。

消融实验结果见表 3。从表 3 可以看出，模型具有完整模块时，实现了最佳性能。在 Restaurant、Laptop 数据集上去掉句法增强图比去掉语义增强图

表2 实验结果对比

类型	模型	Restaurant		Laptop		Twitter	
		Acc	宏F1值	Acc	宏F1值	Acc	宏F1值
Attention	ATAE-LSTM	77.20%	67.02%	68.70%	63.93%	—	—
	IAN	79.26%	70.09%	72.05%	67.38%	—	—
	AOA	79.97%	70.42%	72.62%	67.52%	72.30%	70.20%
	MGAN	81.25%	71.94%	75.39%	72.47%	72.54%	70.81%
Graph	ASGCN	80.77%	72.02%	75.55%	71.05%	72.15%	70.40%
	R-GAT	83.30%	76.08%	77.42%	73.76%	75.57%	73.82%
	DualGCN	84.27%	78.08%	78.48%	74.74%	75.92%	74.29%
	SenticGCN	84.03%	75.38%	77.90%	74.71%	—	—
	DAGCN	84.72%	78.08%	78.96%	75.07%	77.10%	75.66%
	FSESE-GCN	84.80%	78.31%	79.15%	75.32%	77.01%	75.69%
BERT	BERT	85.62%	78.28%	77.58%	72.38%	75.28%	74.11%
	R-GAT+BERT	86.60%	81.35%	78.21%	74.07%	76.15%	74.88%
	DualGCN+BERT	87.13%	81.16%	81.80%	78.10%	77.40%	76.02%
	SenticGCN+BERT	86.92%	81.03%	82.12%	79.05%	—	—
	APARN	87.76%	82.44%	81.96%	79.10%	79.76%	78.79%
	FSESE-GCN+BERT	87.81%	81.79%	82.37%	79.16%	78.81%	78.13%

对性能的影响更大,说明在 Restaurant、Laptop 数据集上句法增强图能够通过外部知识和单词距离特征增强意见词的重要性来增强上下文与方面词的依赖关系。而在 Twitter 数据集上,模型去掉语义增强图后的性能相比去掉句法增强图下降更明显,主要原因是方面感知注意力能够捕捉方面相关语义信息,同时有许多非正式和复杂的用户评论对句法信息不敏感,句法信息会引入额外噪声。去掉方面掩码后,模型性能均有下降,表明特定方面掩码能够在一定程度上消除无关信息,使模型做出正确的情感极性判断。特征融合层的移除也使模型效果显著下降,证明了根据句子序列长度融合句法增强图和语义增强图的有效性,使模型获得更准确的复合特征。

表3 消融实验结果

模型	Restaurant		Laptop		Twitter	
	Acc	宏F1值	Acc	宏F1值	Acc	宏F1值
w/o syn	82.03%	71.73%	75.91%	73.11%	72.70%	71.03%
w/o sem	82.40%	74.12%	76.51%	73.67%	72.30%	70.74%
w/o mask	83.82%	76.45%	78.08%	74.79%	76.68%	74.22%
w/o FF	84.12%	77.87%	77.98%	74.71%	75.27%	73.79%
FSESE-GCN	84.80%	78.31%	79.15%	75.32%	77.01%	75.69%

3.6 参数选择对模型的影响

由于 FSESE-GCN 在特征融合层使用了基于文本序列长度的动态加权方法,为了选取每个数据集

最合适的序列长度阈值 k ,本文设置了不同的阈值进行实验。在 Restaurant 数据集、Laptop 数据集和 Twitter 数据集上不同阈值 k 对模型准确率和宏 F1 值的影响如图 3 所示。

从实验结果可知,对于 Restaurant 数据集而言,在模型训练时将阈值 k 设置为 5 的效果更好。在 Laptop 和 Twitter 数据集上对模型进行训练时,将阈值 k 分别设置为 8 和 4。Laptop 数据集上的文本长度相对更长,高的阈值能够更好地协调句法信息和语义信息。而 Twitter 数据集上的推文内容通常包含口语化表达,较为简短,因此阈值较低。Restaurant 数据集则介于两者之间。

3.7 GCN 层数对模型的影响

GCN 层数对模型准确率和宏 F1 值的影响如图 4 所示,由于单层 GCN 无法获取节点深层的聚合信息,准确率和宏 F1 值都达不到最优。当 GCN 层数为 2 时,模型性能最优。而 GCN 层数超过 2 时,模型性能都有下降,这是因为 GCN 层数增加时参数也随之增加,节点的聚合信息过于复杂,产生的噪声影响模型稳定性,削弱了模型性能。因此,实验中 GCN 层数设置为 2。

3.8 样例分析

样例分析见表 4,给出了不同特征句子使用不同模型比较的结果。第 1 个例句有两个方面词,其



图3 不同阈值 k 对模型准确率和宏F1的影响

图4 GCN层数对模型准确率和宏F1的影响

表4 样例分析

评论	ATAE-LSTM	ASGCN	SenticGCN	FSESE-GCN
(1)Great food but the service was dreadful!	消极(✗)	积极(✓)	积极(✓)	积极(✓)
	消极(✓)	消极(✓)	消极(✓)	消极(✓)
(2) Works well, and I am extremely happy to be back to an apple OS .	积极(✓)	积极(✓)	积极(✓)	积极(✓)
	积极(✓)	中性(✗)	积极(✓)	积极(✓)
(3)The space is small and lovely, and the service is helpful.	消极(✗)	消极(✗)	积极(✓)	积极(✓)
	积极(✓)	积极(✓)	积极(✓)	积极(✓)
(4) Harry Potter time suckah !!.	中性(✗)	中性(✗)	中性(✗)	消极(✓)

中对于方面词“food”，注意力模型ATAE-LSTM受到噪声词“dreadful”的干扰导致不正确的预测。尽管句法依赖树可以建立给定方面词与意见词的依赖关系，但对于复杂句子，方面词与意见词之间的关联度可能很小。在第2个例句中，方面词“apple OS”与意见词“happy”在依赖距离上相距甚远，因此，依赖句法知识的ASGCN模型未能正确预测情感极性。在第3个例句中，对于方面词“space”，

出现“small”“lovely”代表不同情感的意见词，需要模型有提取重要情感信息的能力，ATAE-LSTM和ASGCN容易被噪声词“small”干扰，导致预测失败。第4个例句是Twitter数据集上的评论，句子长度较短并且缺乏明显的情感倾向和句法结构，除了FSESE-GCN模型外，其他模型都没有准确预测情感极性。从4个例句可以看出，FSESE-GCN模型能够充分提取句法信息和语义信息，验证了模型




图5 例句中单词情感贡献注意力可视化

在方面情感分析任务上的有效性。

3.9 可视化分析

为了更直观地展示出所提 FSESE-GCN 模型各模块的有效性, 本文对 Laptop 数据集中评论句“air has higher resolution but the fonts are small.”的方面词“fonts”进行注意力可视化分析, 例句中单词情感贡献注意力可视化如图5所示。其中, sem 表示保留语义图, syn 则表示保留句法图, 颜色越深表示该词越受关注。从热力图中可以看出, 当模型仅使用语义图进行训练时, 能够给予方面词“fonts”更高的权重, 同时也被另一个方面词“resolution”干扰, 产生了噪声。当仅使用句法图进行训练时, 意见词“small”受到了更多关注, 但句中“higher”也为意见词从而得到了更高的情感分数, 干扰了模型的判断。本文提出的 FSESE-GCN 模型能够通过特征融合模块结合两个模块的优点, 为方面词与意见词赋予更高权重来增强上下文与方面词的情感依赖关系并减少噪声, 最终判断出正确的情感极性。

4 结束语

本文提出了一种面向 ABSA 的融合句法增强和语义增强的图卷积网络模型, 首先, 利用方面感知注意力机制捕捉方面语义信息, 再通过门控机制与自注意力机制结合, 得到方面增强的语义特征; 同时, 通过引入外部情感知识和单词的距离特征重塑依赖树, 提高意见词权重, 从而增强上下文与方面词的情感依赖关系; 最后, 采用动态加权将增强的句法特征和语义特征交互融合, 从而减少句法噪声和语义噪声。实验结果表明, 模型在3个公开数据集上都获得了较好的性能。然而, 遇到含隐晦表达的非结构化语句时, 模型可能无法有效地提取关键信息, 同时会带来更多噪声, 从而影响模型性能。在下一步工作中将针对此问题优化模型, 以提高情感分类的准确性。

参考文献:

- [1] 张文轩, 殷雁君. 用于方面级情感分析的图指导的差异化注意力网络[J]. 中文信息学报, 2023, 37(7): 102-113.
ZHANG W X, YIN Y J. Graph-guided differentiated attention network for aspect-level sentiment analysis[J]. Journal of Chinese Information Processing, 2023, 37(7): 102-113.
- [2] 陈壮, 钱铁云, 李万理, 等. 低资源方面级情感分析研究综述[J]. 计算机学报, 2023, 46(7): 1445-1472.
CHEN Z, QIAN T Y, LI W L, et al. Low-resource aspect-based sentiment analysis: a survey[J]. Chinese Journal of Computers, 2023, 46(7): 1445-1472.
- [3] MALOUF R, MULLEN T. Taking sides: user classification for informal online political discourse[J]. Internet Research, 2008, 18(2): 177-190.
- [4] WANG H N, LU Y, ZHAI C X, et al. Latent aspect rating analysis without aspect keyword supervision[C]//Proceedings of the 17th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2011: 618-626.
- [5] TANG D, QIN B, FENG X C, et al. Effective LSTMs for target-dependent sentiment classification[C]//Proceedings of the 26th International Conference on Computational Linguistics. New York: ACM, 2016: 3298-3307.
- [6] RUDER S, GHAFARI P, BRESLIN J G. A hierarchical model of reviews for aspect-based sentiment analysis[C]//Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2016: 999-1005.
- [7] HUANG B X, CARLEY K. Parameterized convolutional neural networks for aspect level sentiment classification[C]//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2018: 1091-1096.
- [8] WANG Y Q, HUANG M L, ZHU X Y, et al. Attention-based LSTM for aspect-level sentiment classification[C]//Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2016: 606-615.
- [9] MA D H, LI S J, ZHANG X D, et al. Interactive attention networks for aspect-level sentiment classification[C]//Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence. Menlo Park: AAAI press, 2017: 4068-4074.
- [10] 徐志栋, 陈炳阳, 王晓, 等. 基于胶囊网络的方面级情感分类研究[J]. 智能科学与技术学报, 2020, 2(3): 284-292.
XU Z D, CHEN B Y, WANG X, et al. Research on capsule network-based for aspect-level sentiment classification[J]. Chinese Journal of Intelligent Science and Technology, 2020, 2(3): 284-292.
- [11] ZHANG C, LI Q C, SONG D W. 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). Stroudsburg: ACL, 2019: 4568-4578.
- [12] WANG K, SHEN W Z, YANG Y Y, et al. Relational graph attention network for aspect-based sentiment analysis[C]//Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. Stroudsburg: ACL, 2020: 3229-3238.
- [13] ZHAO P L, HOU L L, WU O. Modeling sentiment dependencies with graph convolutional networks for aspect-level sentiment classification[J]. Knowledge-Based Systems, 2020, 193: 105443.
- [14] ZHOU J, HUANG J X, HU Q V, et al. SK-GCN: modeling syntax and knowledge via graph convolutional network for aspect-level sentiment classification[J]. Knowledge-Based Systems, 2020, 205: 106292.
- [15] LI R F, CHEN H, FENG F X, et al. DualGCN: exploring syntactic and semantic information for aspect-based sentiment analysis[J]. IEEE Transactions on Neural Networks and Learning Systems, 2024, 35(6): 7642-7656.
- [16] LIU H T, WU Y M, LI Q Y, et al. Enhancing aspect-based sentiment analysis using a dual-gated graph convolutional network via contextual affective knowledge[J]. Neurocomputing, 2023, 553: 126526.
- [17] WANG Z H, ZHANG B, YANG R, et al. DAGCN: distance-based and aspect-oriented graph convolutional network for aspect-based sentiment analysis[C]//Proceedings of the Findings of the Association for Computational Linguistics. Stroudsburg: ACL, 2024: 1863-1876.
- [18] PENNINGTON J, SOCHER R, MANNING C. GloVe: global vectors for word representation[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). Stroudsburg: ACL, 2014: 1532-1543.
- [19] 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, Minneapolis, Minnesota. Stroudsburg: ACL, 2019: 4171-4186.
- [20] ZHANG Z, ZHOU Z L, WANG Y N. SSEGNC: 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. Stroudsburg: ACL, 2022: 4916-4925.
- [21] LIANG B, SU H, GUI L, et al. Aspect-based sentiment analysis via affective knowledge enhanced graph convolutional networks[J]. Knowledge-Based Systems, 2022, 235: 107643.
- [22] 夏鸿斌, 李强, 刘渊. 局部与全局特征融合的方面情感分析网络模型[J]. 计算机科学与探索, 2023, 17(4): 902-911.
- XIA H B, LI Q, LIU Y. Local and global feature fusion network model for aspect-based sentiment analysis[J]. Journal of Frontiers of Computer Science and Technology, 2023, 17(4): 902-911.
- [23] PONTIKI M, GALANIS D, PAVLOPOULOS J, et al. SemEval-2014 task 4: aspect based sentiment analysis[C]//Proceedings of the 8th International Workshop on Semantic Evaluation (SemEval 2014). Stroudsburg: ACL, 2014: 27-35.
- [24] DONG L, WEI F R, TAN C Q, 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 (Volume 2: Short Papers). Stroudsburg: ACL, 2014: 49-54.
- [25] HUANG B X, OU Y L, CARLEY K M. Aspect level sentiment classification with attention-over-attention neural networks[C]//Proceedings of Social, Cultural, and Behavioral Modeling: 11th International Conference on Social Computing, Behavioral-Cultural Modeling and Prediction and Behavior Representation in Modeling and Simulation. Cham: Springer International Publishing, 2018: 197-206.
- [26] FAN F F, FENG Y S, ZHAO D Y. Multi-grained attention network for aspect-level sentiment classification[C]//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2018: 3433-3442.
- [27] MA F K, HU X M, LIU A W, et al. AMR-based network for aspect-based sentiment analysis[C]//Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). Stroudsburg: ACL, 2023: 322-337.


[作者简介]



刘耀 (1976-), 男, 博士, 湖南工商大学数字媒体工程与人文学院副教授, 主要研究方向为情感计算、边缘智能。



吴云飞 (1999-), 男, 湖南工商大学计算机学院硕士生, 主要研究方向为情感分析、机器学习。



周红静 (1976-), 女, 湖南工商大学计算机学院讲师, 主要研究方向为机器学习、边缘智能。



黄少年 (1977-), 女, 博士, 湖南工商大学计算机学院副教授, 主要研究方向为机器学习、行为分析与建模。



张震 (1994-), 男, 博士, 湖南工商大学长沙人工智能社会实验室副教授, 主要研究方向为理论计算、机器学习。