

# 融合语法和语义信息的方面级情感分析模型

黄志勇 李弼程 魏巍

华侨大学计算机科学与技术学院 福建 厦门 361000

(22014083021@stu.hqu.edu.cn)

**摘要** 随着网络上越来越多的人发表自己的观点,带有情绪的贴文也逐渐增多,负面情绪的累积可能导致舆论失控,准确地识别贴文的情感极性能够有效分析舆论现状。目前方面级的情感分析尚未有效融合语法信息以及语义信息,无法同时考虑语法结构的互补性和语义相关性。为此,提出了一个融合语法和语义的方面级情感分析模型(Asspect-level Sentiment Analysis Models Based on Syntax and Semantics, SS-GCN),包括语法分析模块、语义分析模块以及融合模块。首先将文本作为预训练 BERT 模型的输入,通过语法分析模块获得语法关联关系的特征表示,同时经由邻域增强机制的语义分析模块捕获语义的相关性的特征表示。最后把二者输入到融合模块,在仿射变换的作用下对语法信息和语义信息进行有效的交互和融合,实现方面级情感分析。

**关键词** 情感分析;情感分类;细粒度;语义;语法;融合

**中图分类号** TP391

## Aspect-level Sentiment Analysis Models Based on Syntax and Semantics

HUANG Zhiyong, LI Bicheng and WEI Wei

College of Computer Science and Technology, Huaqiao University, Xiamen, Fujian 361000, China

**Abstract** As more and more people express their opinions online, the prevalence of emotionally charged posts is gradually increasing. The accumulation of negative emotions may lead to the loss of control over public opinion. Accurately identifying the emotional polarity of posts can effectively analyze the current state of public opinion. Current aspect-level sentiment analysis has not effectively integrated syntactic and semantic information, failing to simultaneously consider the complementarity of grammatical structures and semantic relevance. Therefore, a model for aspect-level sentiment analysis that integrates syntax and semantics (SS-GCN) is proposed, comprising syntax analysis module, semantics analysis module, and fusion module. Firstly, the text is input to a pre-trained BERT model to obtain feature representations of syntactic relationships through the syntax analysis module. Simultaneously, the semantics analysis module, enhanced by a neighborhood enhancement mechanism, captures feature representations of semantic relevance. Finally, both representations are input to the fusion module, where under the action of affine transformation, syntactic and semantic information are effectively interacted and integrated, achieving aspect-level sentiment analysis.

**Keywords** Sentiment analysis, Sentiment classification, Fine-grained, Semantic, Syntax, Fusion

### 1 引言

在阅读评论、社交媒体帖子或产品评价时,读者常常想知道用户对不同方面的看法。方面级情感分析(Asspect-Based Sentiment Analysis, ABSA)正是为了解决这个问题而诞生的。它不仅仅关注整个句子的情感极性,还深入挖掘用户对特定目标对象的不同方面的评价。随着网络的飞速发展,X、meta、微博等软件已成为人们日常生活中的一部分。而方面级情感分析深入挖掘用户对特定目标对象的评价,从而提供更细粒度的信息。因此,在商品评论、社交媒体、舆情分析等领域,方面级情感分析有广泛的应用价值。如图1所示,这是一个关于方面级情感分析简单的句子。

在这句话中,方面是“食物”和“环境”,对应的方面意见词分别是“积极”和“消极”。识别方面的情感极性对于整个语句

的极性判定有正向的促进作用。

The service is excellent but the environment is poor.

图1 方面意见示意案例

Fig. 1 Illustrated case of opinions on aspects

传统的方面级情感分析方法是基于手工标出特征的机器学习模式,但由于效率不佳,现在多是采用深度学习的方法,主要分为两类:基于注意力机制的方法和基于图卷积神经网络的方法。

采用注意力机制的方法能更准确地得到上下文信息以提高模型分类的准确性。Song等<sup>[1]</sup>结合多头注意力和双门多通道卷积,用于提取方面相关的语义特征。CHENG等<sup>[2]</sup>提出一种基于组件关注的多头共注意力网络模型,用于从用户生成的内容中预测特定目标的情感极性。Huang等<sup>[3]</sup>采用

基金项目:装备预研教育部联合基金(8091B022150)

This work was supported by the Joint Fund of Ministry of Education for Equipment Pre-research(8091B022150).

通信作者:李弼程(lbclm@163.com)

一种基于门控脉冲神经 P 模型和注意力机制的新模型,该模型用两个通道分别处理内容词和方面项,并利用注意力机制对方面项进行加权。该研究是第一个将注意力机制引入 GSNP 模型的工作。Gu 等<sup>[4]</sup>构建一个包含句子本身和外部知识的异构图,使用图卷积网络和图注意力网络来学习方面和上下文词的关系,使用双线性注意力机制来捕获方面和上下文词之间的关系,并使用多层感知器来预测方面的情感极性。Phan 等<sup>[5]</sup>提出语法相对距离来降低与方面词语法联系弱的无关词的影响,利用句子的语法信息和自注意力机制来提高方面抽取和方面情感分类的性能。

与基于注意力机制的方法相比,图卷积神经网络通过丰富的图节点数据来捕获节点之间的关联关系以提高分类精度。Zhang 等<sup>[6]</sup>构建一个全局词汇图来编码语料级的词共现信息,以及一个句法图来表示句子的句法结构。在这两个图上建立一个概念层次,以区分不同类型的依存关系或词对,设计一个双层交互图卷积网络来充分利用这两个图的信息。Xiao 等<sup>[7]</sup>提出一种基于注意力编码和图卷积网络的目标情感分类模型,利用多头注意力机制和依存树构建的改进图卷积网络,分别捕获语义信息、句法信息和它们的交互信息,避免句法无关的上下文词误导情感预测。Liu 等<sup>[8]</sup>结合了循环神经网络和卷积神经网络的优势,利用门控机制动态调整两种网络的输出,提高了模型效率。Zhao 等<sup>[9]</sup>出了一种新的图卷积网络,通过聚合不同的图结构和注意力机制,来增强节点表示和捕捉长距离依赖。Liang 等<sup>[10]</sup>利用句子的成分树的语法信息,来建模每个方面的情感感知上下文和方面之间的情感关系。但在图卷积神经网络中节点只能接受其邻居节点的信息,而且信息传播的范围通常是固定的。这可能会导致长距离信息传播困难。

与之前的方法相比,本文模型利用双语法树相结合的形式进行语法关系分析,能更好地对齐方面术语和相应的情感。并且本文采用的语义分析模块突出了邻近词的各种组成和给定的方面,同时通过仿射变换对句子的语法信息与语义信息进行交互而不是分别进行处理,使两者的特征得到有效交换。

本文的主要贡献如下:

1)为了整合多个特征信息,本文设计了一种融合网络,由仿射变换和多头注意力机制组成,该模型能交换不同特征的信息,有效融合文本的语法和语义特征,得到更具代表性的特征表示。

2)针对文本语义信息失配问题,本文提出了一种基于邻域增强的语义分析模块,该模块能更好地捕获与给定方面相关的信息。

## 2 相关工作

### 2.1 语法分析

在情感分析中,语法分析是一种重要的资源,它可以提供有关文本结构、句法关系和语义信息的信息。有了语法信息的帮助,就能够更好地理解文本的情感倾向。

在依赖树(Deep. Tree)和成分树(Con. Tree)上使用图神经网络(GNN)来显式地利用句子句法结构,能有效提高准确率<sup>[10-16]</sup>。虽然集合树和依赖树共享共同的句子语法信息,但它们从不同的角度捕获语法细节。

依赖树(Deep. Tree)可以建立句子中单词之间的

联系<sup>[16]</sup>,而成分树(Con. Tree)提供精确的短语分割和层次结构,这有助于将方面与情感指示词精确对齐<sup>[10]</sup>。

### 2.2 语义分析

语义分析是一种用于理解文本中的语义信息和关系的技术,语义分析可以帮助处理文本中的复杂情感现象,还可以帮助识别文本中的情感对象、情感持有者、情感类型和情感词等元素,从而构建文本的情感结构化表示。

文献<sup>[17]</sup>利用外部知识增强 ABSA 模型的语义特征。例如,Zhou 等<sup>[18]</sup>使用与知识图相关的词构建子图作为种子节点。基于子图的方法产生了显著的结果,但可能会带来复杂性,特别是在处理大量方面项时。Zhong 等<sup>[19]</sup>将外部知识图整合到低维嵌入中,以有效地表示特定方面的知识。

许多学者都单独针对语法或者语义进行研究,近年来将两者结合使用的研究相对较少,因为未能将两者有效结合在一起,本文提出一个融合模块能交换语法和语义信息,使之能更充分地融合。

## 3 本文模型

针对情感分析所需要的语法分析和语义分析,本文提出了融合两者的方面级情感分析模型。该模型可以有效对文本的语法结构和语义信息进行建模,通过融合模块提高极性判别的准确率,模型主要由 3 个部分构成:基于依赖树的语法分析模块、基于邻域增强的语义分析模块和融合模块。基于依赖树的语法分析模块负责将文本转变为语法特征嵌入并从中发现语法关系。基于邻域增强的语义分析模块更关注文本中某一特征表示与其邻域特征的关联关系,挖掘深层的语义信息。融合模块采用仿射变换使语义特征和语法特征进行有效交换。模型结构图如图 2 所示。

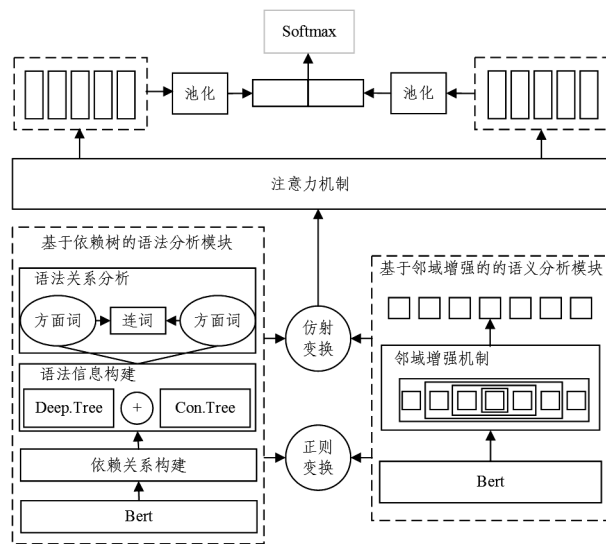


图 2 模型结构图

Fig. 2 Model structure diagram

### 3.1 问题定义

方面级情感分析旨在识别给定文本中各个方面情感极性。形式上,给定一条数据  $D$ ,提取出  $(C, A, O, P)$  4 项情感元素,其中  $C$  为方面类别,  $A$  为方面术语,  $O$  为观点术语,  $P$  为情感极性。方面级情感分析方法根据数据  $D$ ,通过模型得出  $[(C, A, O, P), (C, A, O, P), \dots]$ 。

### 3.2 基于依赖树的语法分析模块

语法信息特征可以帮助提升文本表示的质量,从而改善

许多自然语言处理(Natural Language Processing, NLP)任务的模型效果。传统的基于语法依赖树的图模型可能会受到依赖树中不相关关系的干扰,为了解决这个问题,模块引入了一种语法关系分析方法,充分利用了句法树中的语法信息。该模块以句子和文本中的所有方面为输入,并输出每个方面的情感预测。

它包含两个部分:

1)语法信息构建部分。该模块对输入文本进行编码,以获得目标方面的特定于方面的表示,它包含两个编码器:一个是处理输入文本的编码器,一个是构建依赖以及组成树语法信息的语法编码器。

2)语法关系分析部分。该部分包括一个关系编码器,该编码器应用于构建的方面关系分析图,输出方面之间的语法关系。通过基于规则的映射函数,该分析图将给定句子和短语细分为方面单位。在语法树构建部分中依赖树构建部分中处理输入文本的编码器的预训练模型采用 BERT,将文本输入 BERT 模型中,可表示为  $h^t = \{h_0^t, h_1^t, \dots, h_{n'}^t\}$ , 因此计算  $w_i$  的上下文公式为:

$$\hat{h}_i^t = \frac{1}{|\text{BERT}(w_i)|} \sum_{k=1}^i h_k^t \quad (1)$$

其中,  $w_i$  表示句子中的每个词,  $\text{BERT}(w_i)$  返回  $w_i$  在 BERT 序列中子词的索引集,  $|\cdot|$  返回其大小,  $k \in \text{BERT}(w_i)$ 。

为了表示每个词之间的连接,本文选择以自底向上的方式遵循的语法结构,构建相应的邻接关联矩阵(CRA)。Con. Tree 的每一层都由组成输入文本的几个短语组成,每个短语代表一个单独的语义单元,再根据这些短语构造相关的图, CRA 构建计算式如下:

$$\text{CRA}_{i,j}^l = \begin{cases} 1, & \text{if } w_i, w_j \text{ in same phrase} \\ 0, & \text{otherwise} \end{cases} \quad (2)$$

其中,  $l$  表示当前层数。

语法编码器由多个分层图注意块堆叠,目的是将语法信息分层地编码成单词表示。每个块由多个图注意(即 GAT)层组成,这些层在成分树或依赖树的指导下分层编码语法信息,如图 3 所示。

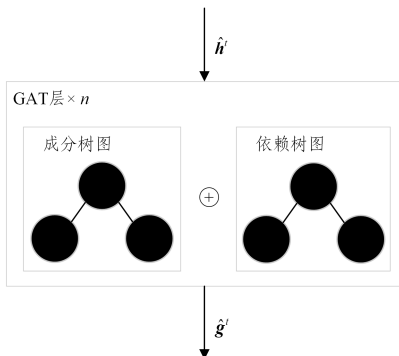


图 3 GAT 层  
Fig. 3 GAT layer

每个 GAT 层都利用隐式的自注意力机制来聚合邻居节点的信息,并利用一个全连接的前馈网络将节点表示映射到统一的语义空间。自注意力机制可以适应邻接词的多样性,并给予更相关的词更高的权重,具体计算式可表示为:

$$\hat{g}_i^{t,l} = FC(g_i^{t,l} + \hat{g}_i^{t,l-1}) \quad (3)$$

$$g_i^{t,l} = \left\| \sum_{z=1}^Z \sigma \left( \sum_{j \in \mathcal{N}^l(i)} \alpha_{ij}^z W_z^l \hat{g}_j^{t,l-1} \right) \right. \quad (4)$$

$$\alpha_{ij}^z = \frac{\exp(f(\hat{g}_i^{t,l-1}, \hat{g}_j^{t,l-1}))}{\sum_{j' \in \mathcal{N}^l(i)} \exp(f(\hat{g}_i^{t,l-1}, \hat{g}_{j'}^{t,l-1}))} \quad (5)$$

其中,  $\mathcal{N}^l(i)$  为在第  $w_i$  层的邻居集合,  $\hat{g}_i^{t,l}$  为  $w_i$  在第  $l$  层的最终表示,  $FC$  为全连接前馈网络;  $g_i^{t,l}$  是  $w_i$  在掩蔽自注意机制后的表示;  $\parallel$  表示向量拼接;  $Z$  为注意头数,  $\sigma$  为激活函数;  $W_z^l$  是第  $l$  层第  $z$  个头的可训练参数;  $f$  是衡量两个词相关性的分数函数。

多层 GAT 块使用多个 GAT 块的输出为输入,第一个 GAT 块的输入为  $\hat{h}^t$ 。为简单起见,将语法编码器的输出定义为  $\hat{g}^t$ 。

为了融合两种语法树信息,将 Deep. Tree 视为无向图,并构造邻接关联矩阵(DRA),其计算式如下:

$$\text{DRA}_{i,j} = \begin{cases} 1, & \text{if } w_i, w_j \text{ link directly in Deep. Tree} \\ 0, & \text{otherwise} \end{cases} \quad (6)$$

融合操作包含 3 种具体如下:

1)点积运算。对于 Con. Tree 的每一层,该操作只考虑同样处于同一短语中的 Deep. Tree 的邻居节点,具体计算式如下:

$$FA = \text{CRA} \cdot \text{DRA} \quad (7)$$

2)加法运算。对于 Con. Tree 的每一层,该操作考虑相同短语中的单词和 Deep. Tree 的邻居,具体计算式如下:

$$FA = \text{CRA} + \text{DRA} \quad (8)$$

3)条件加法运算。该操作考虑 Con. Tree 的短语语法信息和 Deep. Tree 的句级语法信息。它首先删除所有跨子句的依赖边,然后对剩余的依赖边进行按位置添加操作,具体计算式如下:

$$FA = \text{CRA} \oplus \text{DRA} \quad (9)$$

语法编码器的输出的具体表述如下:

$$v_i^{as} = [\hat{h}_i^t + \hat{g}_i^t; h_0^t] \quad (10)$$

语法关系分析部分的目的是探究方面之间的相互影响,具体过程如图 4 所示。




图 4 方面相关图

Fig. 4 Aspect related diagram

这部分使用了一种基于规则的映射函数  $MF$ 。该函数用于返回两个方面之间的短语切分。具体而言,给定两个方面,首先找到它们的最低共同祖先(LCA)。LCA 包含了两个方面的信息,并且尽量减少了无关的上下文。将 LCA 中两个方面所在的子树之间的分支称为“内部分支”。如果在内部分支中存在文本单词,则会返回这些单词;否则会返回输入文本中两个方面之间的单词。其计算式如下:

$$MF(a_i, a_j) = \begin{cases} \{w_k\}, & \text{if } |Br(a_i, a_j)| = 0 \\ Br(a_i, a_j), & \text{otherwise} \end{cases} \quad (11)$$

其中,  $i < k < j$  和  $Br(a_i, a_j)$  返回  $a_i$  和  $a_j$  内部分支中的文本单词。利用映射函数  $PS$  提取相邻方面的分词项后,通过将

方面与相应的分词项联系起来,构建语法关系分析图,帮助推断关系。然后,以 $\{v_i^s, t \in A_s\}$ 和BERT编码的相应短语分词表示作为输入,将上述分层图注意块作为关系编码器,得到各方面 $a_i$ 的关系增强表示 $v_i^{as}$ 。

最后,将两部分的输出结合起来形成最终的输出表示 $o_i$ ,即:

$$o_i = v_i^{as} + v_i^{at} \quad (12)$$

### 3.3 基于邻域增强的语义分析模块

为了利用给定方面周围的单词所包含的情感倾向信息,该模块设计了多个聚合单元,它们可以模仿方面及其前后的标签,称为邻域增强。

在这个模块中,本文使用了一种掩码机制来处理多种距离的邻域。首先,识别每个令牌相对于方面的位置,然后计算每个标记相对于方面的相对距离 $d_i$ 。这样能够更好地捕捉到方面周围的上下文信息,记为:

$$d_i = \begin{cases} P_{a+1} - P_i, & i < a+1 \\ 0, & a+1 \leq i \leq a+m \\ P_i - (P_{a+1} + m), & i > a+m \end{cases} \quad (13)$$

其中, $i$ 的取值范围为0到 $n$ , $n$ 为输入句子的长度, $P_i$ 表示第 $i$ 个 $token$ 的位置, $P_{a+1}$ 表示方面术语 $A$ 的起始位置, $m$ 表示方面术语 $A$ 的长度。

为了表示上下文邻域词的各种组合,基于跨度大小阈值 $L$ 构建了多个邻域,其范围为0到 $L$ 。这种方法产生 $L+1$ 个邻域。对于大小为 $l \in [0, L]$ 的跨度中的每个上下文词,掩码向量 $V_i^l$ 定义为:

$$V_i^l = \begin{cases} E, & d_i \leq l \\ O, & d_i > l \end{cases} \quad (14)$$

其中, $E \in \mathbb{R}^d$ 是1向量, $O \in \mathbb{R}^d$ 是0向量, $V_i^l$ 表示第 $i$ 个 $token$ 的掩码向量。

对于距离的大小 $l$ ,可以得到第 $l$ 个邻域表示 $H_{span}^l \in \mathbb{R}^{(n+1) \times d}$ ,即:

$$H_{span}^l = M^l \cdot H \quad (15)$$

其中,掩码矩阵 $M^l = \{V_0^l, V_1^l, \dots, V_n^l\} \in \mathbb{R}^{(n+1) \times d}$ 由 $n+1$ 个掩码向量 $V_i^l$ 组成,表示输入句子的大小为 $l$ 的距离。

将邻域表示与原上下文表示 $H$ 进行串联,得到邻域增强表示 $H_{enhance}^l \in \mathbb{R}^{(n+1) \times d}$ ,并通过线性变换映射回 $d$ 维语义空间,可表示为:

$$H_{enhance}^l = W_1 (H_{span}^l \odot H) + b_1 \quad (16)$$

其中, $W_1 \in \mathbb{R}^{d \times 2d}$ 为线性变换层中的权矩阵和偏置矩阵, $\odot$ 为串联运算。

### 3.4 融合模块

为了在语义分析模块和语法分析模块之间有效地交换相关特征,本文采用仿射变换作为桥梁,即:

$$H^{syn'} = \text{softmax}(H^{syn} W_1 (H^{sem})^T) H^{sem} \quad (17)$$

$$H^{sem'} = \text{softmax}(H^{sem} W_2 (H^{syn})^T) H^{syn} \quad (18)$$

其中, $W_1$ 和 $W_2$ 为可训练参数, $H^{sem}$ 为语义分析模块得出的特征矩阵, $H^{syn}$ 为语法分析模块得出的特征矩阵。

对语义分析模块和语法分析模块的方面节点进行了平均池化和连接操作,得到最终特征表示,即:

$$h_a^{syn} = f(h_{a_1}^{syn}, h_{a_2}^{syn}, \dots, h_{a_m}^{syn}) \quad (19)$$

$$h_a^{sem} = f(h_{a_1}^{sem}, h_{a_2}^{sem}, \dots, h_{a_m}^{sem}) \quad (20)$$

$$r = [h_a^{syn}, h_a^{sem}] \quad (21)$$

其中, $f(\cdot)$ 是应用于方面节点表示的平均池化函数。

将得到的表示 $r$ 输入线性层,再通过 $\text{softmax}$ 函数得到情感概率分布 $p$ ,即:

$$p(a) = \text{softmax}(W_p r + b_p) \quad (22)$$

其中, $W_p$ 和 $b_p$ 是可学习的权重和偏差。

在语法分析和语义分析模块的两个邻接矩阵之间采用微分正则化器。正则化器仅限制于 $A^{sem}$ ,即:

$$R_D = \frac{1}{\|A^{sem} - A^{syn}\|_F} \quad (23)$$

标准的交叉熵损失 $\ell_C$ 的定义如下:

$$\ell_C = - \sum_{(s,a) \in D} \sum_{c \in C} \log p(a) \quad (24)$$

其中, $D$ 包含所有的句子对, $C$ 是不同情绪极性的集合。

训练目标是 minimized 以下总目标函数:

$$\ell_T = \ell_C + \lambda_1 R_O + \lambda_2 R_D + \lambda_3 \|\Theta\|_2 \quad (25)$$

其中, $\lambda_1, \lambda_2, \lambda_3$ 为正则化系数, $\Theta$ 为所有可训练的模型参数。

经过损失函数调整就可以获得最终的情感分类。

## 4 实验分析

本章首先描述实验中使用的数据集及其相关参数设置,接着介绍用于评估的指标以及作为比较基准的模型,然后对比本文模型与基线模型在性能上的表现,随后通过消融实验验证模型中各个模块的有效性,最后对实验结果进行详细分析。

### 4.1 实验数据与实验平台

本模型选用公开的 SemEval-2014 Task4 数据集进行实验,分别是餐厅(以下简称 Rest14)和笔记本电脑数据集(以下简称 Lap14),两个数据集都有3种情绪极性:积极、消极和中性。这些数据集的每个句子都用标记的方面及其对应的极性进行注释。数据集的统计数据如表1所列。

表1 数据集统计

Table 1 Dataset statistics

数据集		积极	中立	消极
Rest14	train	2164	637	807
	test	728	196	196
Lap14	train	994	464	870
	test	341	169	128

### 4.2 实验参数设置

本模型使用 PyTorch 框架在 RTX3090GPU 上运行,实验中采用了随机梯度下降算法对预训练的 BERT 模型进行优化。为了提高优化效率,BERT 预训练模型的学习率设置为 $3 \times 10^{-5}$ 。

### 4.3 评估指标

模型采用准确率(Accuracy, Acc)与宏平均 F1 分数(macro F1, MF1)作为评价指标,准确率 Acc 是各个模型常用的指标,MF1 是宏平均精准率和宏平均召回率的调和平均值,它同时兼顾了分类模型的准确率和召回率,是统计学中用来衡量二分类(或多任务二分类)模型精确度的一种指标。其计算公式如下:

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (26)$$

$$macroF1 = \frac{2macroP \times macroR}{macroP + macroR} \quad (27)$$

其中, $TP$ 是情感极性为积极并被正确判断的数量, $TN$ 是情感极性为消极并被正确判断的数量, $FP$ 是情感极性为积极

并被错误判断的数量,  $FN$  是情感极性为消极并被错误判断的数量。  $macroP$  为宏平均准确率,  $macroR$  为宏平均召回率。

#### 4.4 基线方法

为了验证模型的性能, 本文选择以下模型进行对比。

1) ATAE-LSTM<sup>[20]</sup>: 该模型是一种基于注意力机制和方面嵌入的 LSTM 模型, 用于细粒度的文本情感分类任务。

2) MemNet<sup>[21]</sup>: 该模型是一种用于处理序列到序列任务的神经网络模型。它的设计灵感来自于人类的记忆, 通过记忆单元和注意力机制实现了对序列数据的有效处理。

3) IAN<sup>[22]</sup>: 该模型是一种用于文本分类的神经网络模型。它使用交互式注意力机制来捕捉文本中的关键信息, 提高了情感分析的性能。

4) AOA<sup>[23]</sup>: 该模型引入了 Attention-over-Attention 机制, 它不仅考虑了 document 对 query 的注意力, 也考虑了 query 对 document 的注意力, 从而增强了 query 和 document 之间的交互信息。

5) MGAN<sup>[24]</sup>: MGAN 模型是一种用于情感分析的多粒度注意力网络, 它结合了粗粒度和细粒度的注意力机制, 来捕捉方面和上下文在词级别上的交互。

6) Bi-GCN<sup>[25]</sup>: 构建句法结构时有时会忽略词语之间的共现信息以及不同句法依赖类型对结果的影响。为了解决这个问题, 该模型分别构建词法图和句法图, 并在它们之间进行交互和聚合, 从而提高模型的性能。

7) kumaGCN<sup>[6]</sup>: 该模型可以自动为每个方面词导出一个离散的意见树结构, 然后利用图卷积网络来学习方面词和意见词之间的交互关系。

8) AGGCN<sup>[26]</sup>: 该模型利用注意力机制构建全连接图, 使用密集连接的图卷积网络编码图结构, 通过线性组合层整合多个图表示。

9) AFGCN<sup>[27]</sup>: 为了集成句法相对依赖位置图, 该模型构建了一个句法依赖模块, 可利用注意力机制来提取与方面语义相关的显著特征, 从而得到一个融合了语义和句法特征的向量表示。

10) MIA-GCN<sup>[28]</sup>: 该模型通过交互注意力机制对语句进行语义交互和句法交互, 从而进行方面级情感分析。

#### 4.5 实验结果

为了评估模型性能, 本文在两个数据集 Rest14 和 Lap14 上进行实验, 两者都为全英文的数据集。实验结果如表 2 所列。

通过观察结果表可知, 本文模型在这两个数据集上优于所有模型。与 ATAE-LSTM, IAN 和 RAM 等基于注意力的方法相比, 注意力机制虽然能够一步到位获取全局与局部的联系, 但无法学习序列中的顺序关系, 无法捕捉位置信息, 本文模型利用语法依赖树建立词与词之间的位置关系, 还使用邻域增强机制获取相关性较高的语义信息, 从而提高预测准确性。在 Rest14 数据集上的正确率提高了 4 个百分点, 在 Lap14 数据集上也提升了将近 3.3 个百分点。此外 MF1 值也分别提升了 6.58% 和 2.29%, 基于图卷积网络的方法(如 AGGCN, AFGCN, MIA-GCN 等)比基于注意力的方法取得了更好的性能, 因为图结构更适合于语法信息捕获, 但它们忽略了词与词之间的语法联系。本文模型通过分析不同方面词之间的语法关系, 包括转折、并列等, 从而避免了该缺点。故本

文模型在 Rest14 数据集上的正确率和 MF1 值分别都比之高出了 2.4% 与 3.08%, 在 Lap14 数据集上的正确率和 MF1 值分别比之高出了 1.21% 和 1.26%, 这证明了本文模型的有效性。

表 2 对比实验结果

Method	Rest14		Lap14	
	Acc	F1	Acc	F1
ATAE-LSTM	78.60	67.02	68.88	63.93
MemNet	79.61	69.64	70.64	65.17
IAN	78.60	70.09	72.10	67.38
AOA	79.97	70.42	72.62	67.52
MGAN	81.25	71.94	75.39	72.47
Bi-GCN	81.97	72.02	74.59	71.84
kumaGCN	81.43	73.48	76.12	72.42
AGGCN	84.37	73.82	73.53	68.99
AFGCN	82.50	73.66	77.43	73.64
MIA-GCN	82.85	75.44	77.42	73.50
SS-GCN	85.25	78.52	78.63	74.76

#### 4.6 消融实验

为了进一步探究语法模块和语义模块对方面级情感分析的作用, 以及两个模块的有效性, 本文进行了消融实验, 结果如表 3 所列。

表 3 消融实验结果

Method	Rest14		Lap14	
	Acc	F1	Acc	F1
SS-GCN	85.25	78.52	78.63	74.76
SS-GCN(-sem)	84.91	76.32	77.27	72.96
SS-GCN(-syn)	84.45	76.15	76.58	72.19

首先只进行语法分析模块 SS-GCN(-sem) 测试, 再进行只有语义分析模块 SS-GCN(-syn) 测试, 最后进行有融合模块的完整模型测试。从实验结果可得, SS-GCN(-sem) 模型在 Rest14 数据集上正确率和 MF1 值分别下降 0.34% 和 2.2%, 并且在 Lap14 数据集上分别下降 1.36% 和 1.8%。这表明语法分析模块能够对句子语法关系进行建模并有效分析其中的语法构成, 利用语法信息增强模型的建模能力。而 SS-GCN(-syn) 模型在 Rest14 数据集上的正确率和 MF1 值分别下降 0.8% 和 2.37%, 并且在 Lap14 数据集上分别下降 2.05% 和 1.57%。这表明语义增强模块能够提升 SS-GCN 模型的语法分析能力, 利用邻域增强的方式对句中语义信息进行有效提取。以上实验结果表明, 融合模块在本文模型中对正确率和 MF1 值的提升具有一定促进作用。

#### 4.7 注意力可视化

本文以餐馆和笔记本电脑评论为例, 对比了提取的两个句子的注意力权重, 展示了 SS-GCN 模型如何改进方面情感预测。在图 5 和图 6 中, 加粗文本代表方面词。本文选择了具有两个方面的句子, 并使用深色阴影来突出显示每个单词的权重。从图中可以看出, 在第一句中, “higher” 一词对于确定 “resolution” 这一方面的情感极性至关重要, 而 “small” 这个形容词并没有明确的情感极性, 但通过 “but” 转折词可以推断出其消极情感。因此, 语法关系分析模块为没有情感极性的单词(例如 “and” 和 “but”) 分配了一定的权重。在第二句中, “disappointed” 这个语境词对于确定 “service” 和 “food” 这两个方面的情感极性非常关键, 并通过 “and” 连接词判断 “service” 和 “food” 属于相同的情感极性。这些多方面的例子表明本文

提出的 SS-GCN 模型能够准确识别不同方面词的情感极性。

模型会变得不稳定,导致测试结果不理想。




图 5 笔记本数据集句子注意力可视化

Fig. 5 Visualization of sentence attention in Lap14 dataset




图 6 餐厅数据集句子注意力可视化

Fig. 6 Visualization of sentence attention in Rest14 dataset

#### 4.8 模型层数影响分析

为了研究层数对 SS-GCN 模型的影响,本文在 Rest14 和 Lap14 数据集上用 1~8 层来测试模型。测试指标分别为 Acc 和 MF1 值,具体的结果如图 7 和图 8 所示。

根据实验结果得出具有 3 层的 SS-GCN 模型表现最好。一方面,当层数较少时,节点表示无法向远距离传播。另一方面,如果层数过多,由于梯度逐渐消失以及信息冗余的积累,

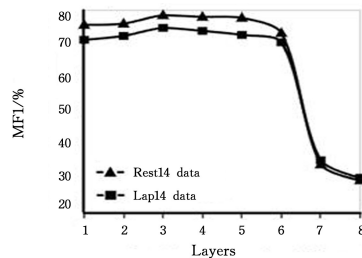


图 7 模型层数对 Acc 的影响

Fig. 7 Impact of model layers on Acc




图 8 模型层数对 MF1 的影响

Fig. 8 Impact of model layers on MF1

#### 4.9 案例分析

如表 4 所列,本文使用了不同的模型在不同的案例上分析以说明 SS-GCN 模型的性能。

表 4 SS-GCN 模型与基线模型的案例比较

Table 4 Case comparison between SS-GCN and baseline models

Sentence	MemNet	IAN	SS-GCN
But make sure you have enough room on your credit card as the <b>bill</b> will leave a big dent in your wallet.	(N×)	(N×)	(N√)
I definitely enjoyed the <b>food</b> as well.	(P√)	(P√)	(P√)
The <b>food</b> is surprisingly good ,and the <b>decor</b> is nice.	(P×,P√)	(P√,P√)	(P√,P√)
Finally let into the store 5 at a time ,to buy expensive <b>slices</b> from a harried staff.	(N×,N√)	(N×,N×)	(N√,N√)
But <b>dinner</b> here is never disappointing,even if the <b>prices</b> are a bit over the top.	(P×,N×)	(P√,N×)	(P√,N√)

在第三个示例中,基于注意力的方法(如 IAN)集中于“good”和“nice”这两个词。然而,在没有明确形容词修饰的方面词中,通常需要考虑语法上的转折关系来确定其情感极性,就像在第五个示例中,“prices”这个方面词缺乏明显的情感修饰词,导致 MemNet 和 IAN 模型判断错误。然而,包含语法关系分析模块的模型能够成功判断,因为它能够通过前文中的“but”转折词来确定“prices”的情感极性与“dinner”相反。SS-GCN 模型提出的方法可以处理多个方面的句子,并从更复杂的句子中提取详细的情感特征,以涵盖句法和语义信息。

**结束语** 本文提出了一个结合了语法和语义特征的面向方面的情感分析模型,该模型利用 BERT 作为预训练模型,通过分析句子的语法结构建立依存树并结合语法关系分析得到更精确的语法特征信息。再根据距离结合方面周围的特征,得到语义信息。将两者通过融合模块融合在一起,提高了情感分析的效果并在数据集上得到了验证。

此外,模型还有可以进一步改进的地方,如没有考虑到特征信息之间存在的语义差异问题对融合的影响,接下来可以在这方面进行探索。

#### 参考文献

- [1] SONG W, WEN Z, XIAO Z, et al. Semantics perception and refinement network for aspect-based sentiment analysis [J]. Knowledge-Based Systems, 2021, 214: 106755.
- [2] CHENG L C, CHEN Y L, LIAO Y. Aspect-based sentiment analysis with component focusing multi-head co-attention networks[J]. Neurocomputing, 2022, 489: 9-17.
- [3] HUANG Y, PENG H, LIU Q, et al. Attention-enabled gated spiking neural P model for aspect-level sentiment classification [J]. Neural Networks, 2023, 157: 437-443.
- [4] 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.
- [5] PHAN M H, OGUNBONA P O. Modelling context and syntactical features for aspect-based sentiment analysis[C]// Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. 2020: 3211-3220.
- [6] ZHANG M, QIAN T. Convolution over hierarchical syntactic and lexical graphs for aspect level sentiment analysis[C]// Pro-

- ceedings of the 2020 Conference on Empirical Methods in Natural Language Processing(EMNLP). 2020;3540-3549.
- [7] XIAO L, HU X, CHEN Y, et al. Targeted sentiment classification based on attentional encoding and graph convolutional networks[J]. *Applied Sciences*, 2020, 10(3):957.
- [8] LIU N, SHEN B. Aspect-based sentiment analysis with gated alternate neural network[J]. *Knowledge-Based Systems*, 2020, 188:105010.
- [9] ZHAO M, YANG J, ZHANG J, et al. Aggregated graph convolutional networks for aspect-based sentiment classification[J]. *Information Sciences*, 2022, 600:73-93.
- [10] LIANG S, WEI W, MAO X L, et al. BiSyn-GAT+: Bi-syntax aware graph attention network for aspect-based sentiment analysis[J]. *arXiv:2204.03117*, 2022.
- [11] ZHANG C, LI Q, SONG D. Aspect-based sentiment classification with aspect-specific graph convolutional networks[J]. *arXiv:1909.03477*, 2019.
- [12] SUN K, ZHANG R, MENSAH S, et al. Aspect-level sentiment analysis via convolution over dependency tree[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; 5679-5688.
- [13] 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.
- [14] LIANG B, YIN R, GUI L, et al. Jointly learning aspect-focused and inter-aspect relations with graph convolutional networks for aspect sentiment analysis[C]// *Proceedings of the 28th International Conference on Computational Linguistics*. 2020;150-161.
- [15] WANG K, SHEN W, YANG Y, et al. Relational graph attention network for aspect-based sentiment analysis[J]. *arXiv:2004.12362*, 2020.
- [16] 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 (Volume 1: Long Papers)*. 2021;6319-6329.
- [17] MA Y, PENG H, CAMBRIA E. Targeted aspect-based sentiment analysis via embedding commonsense knowledge into an attentive LSTM[C]// *Proceedings of the AAAI conference on artificial intelligence*. 2018;32(1).
- [18] ZHOU J, HUANG J X, HUQ V, et al. Sk-gen: Modeling syntax and knowledge via graph convolutional network for aspect-level sentiment classification[J]. *Knowledge-Based Systems*, 2020, 205:106292.
- [19] 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.
- [20] 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.
- [21] TANG D, QIN B, LIU T. Aspect level sentiment classification with deep memory network[J]. *arXiv:1605.08900*, 2016.
- [22] MA D, LI S, ZHANG X, et al. Interactive attention networks for aspect-level sentiment classification[J]. *arXiv:1709.00893*, 2017.
- [23] HUANG B, OU Y, CARLEY K M. Aspect level sentiment classification with attention-over-attention neural networks[C]// *11th International Conference Social, Cultural, and Behavioral Modeling(SBP-BRIMS 2018)*. Washington, DC, USA, Springer International Publishing, 2018;197-206.
- [24] FAN F, FENG Y, ZHAO D. Multi-grained attention network for aspect-level sentiment classification[C]// *Proceedings of the 2018 cNference on Empirical Methods in Natural Language Processing*. 2018;3433-3442.
- [25] ZHANG M, QIAN T. Convolution over hierarchical syntactic and lexical graphs for aspect level sentiment analysis[C]// *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing(EMNLP)*. 2020;3540-3549.
- [26] LU Q, ZHU Z, ZHANG G, et al. Aspect-gated graph convolutional networks for aspect-based sentiment analysis[J]. *Applied Intelligence*, 2021, 51(7):4408-4419.
- [27] ZHANG F, ZHANG Y, HOU S, et al. Aspect Fusion Graph Convolutional Networks for Aspect-Based Sentiment Analysis[C]// *27th China Conference Information Retrieval (CCIR 2021)*. Dalian, China, Springer International Publishing, 2021; 74-87.
- [28] XIA Y, WU W N, YANG C C. Graph Convolutional Network-Based Multi-Interaction Attention Aspect-Level Sentiment Analysis[J]. *Computer Engineering and Design*, 2023, 44(12): 3691-3699.



**HUANG Zhiyong**, born in 1994, post-graduate. His main research interests include natural language processing, emotional analysis and topic detection.



**LI Bicheng**, born in 1970, Ph.D, professor, Ph.D supervisor. His main research interests include intelligent information processing, network ideological security, network public opinion monitoring and guidance, and big data analysis and mining.