·计算机技术与应用·

面向方面级情感分析的交互式图卷积网络

朱忆红,陈晓亮*,付俊森,杜亚军
(西华大学计算机与软件工程学院,四川 成都 610039)

摘　要: 针对现有的基于图网络的情感分析模型在处理方面短语的内部语义和不同方面之间的情感交互关系时准确度不高等局限性,文章提出一种面向方面级情感分析的交互式图卷积网络模型。首先,利用句子中上下文和方面词之间的句法依存关系,在方面短语内部模块中整合各方面短语之间的内部语义相关性,并将不同方面之间的情感交互关联起来,生成 4 种类型的邻接矩阵图,实现对方面短语内部语义性和句子中不同方面之间情感交互关系的建模。其次,构建一个方面交互图,用于跨方面关系的建模,以解决不同方面之间的情感交互。最后,在图卷积网络中设置一个全局节点,进一步解决句子中存在多个方面词时精度浮动的问题。在 4 个公开数据集上的结果表明,该模型在准确率和 F_1 值上均有所提升。

关键词: 方面级情感分析;图卷积网络;短语结构树

中图分类号: TP391.1;TP399　　**文献标志码:** A　　**文章编号:** 1673–159X(2024)03 − 0008 − 10

doi:10.12198/j.issn.1673 − 159X.5256

Interactive Graph Convolutional Network for Aspect-level Sentiment Analysis

ZHU Yihong, CHEN Xiaoliang*, FU Junsen, DU Yajun
(*School of Computer and Software Engineering*, *Xihua University*, *Chengdu* 610039 *China*)

Abstract: A novel interactive graph convolutional network model is proposed to overcome the limitations of existing sentiment analysis models based on graph networks. This model effectively addresses the challenges of handling the internal semantic relations of aspect phrases and the sentiment interactions between different aspects within a sentence. Firstly, by leveraging the syntactic dependencies between context and aspect words, the aspect-inside module integrates the internal semantic correlations among aspect phrases and establishes sentiment interactions between different aspects, resulting in four types of adjacency matrix graphs. This allows for accurate modeling of aspect phrase semantics and the affective interactions between different aspects within a sentence. Secondly, an aspect interaction graph is constructed to capture cross-aspect relations, effectively resolving the issue of sentiment interactions between different aspects. Lastly, the inclusion of a global node in the graph convolutional network further addresses the problem of fluctuating accuracy when multiple aspect words are present in a sentence. The results of experi-

收稿日期:2023 − 09 − 08
基金项目:国家自然科学基金项目(61902324);四川省科技厅重点研发项目(2023YFS0424)。
*** 通信作者:**陈晓亮(1984—),男,教授,博士,硕士生导师,主要研究方向为自然语言处理。
ORCID: 0000 − 0002 − 8201 − 9631　　E-mail: chenxl@mail.xhu.edu.cn

引用格式:朱忆红,陈晓亮,付俊森,等. 面向方面级情感分析的交互式图卷积网络[J]. 西华大学学报(自然科学版),2024,43(3):8 − 17.
ZHU Yihong, CHEN Xiaoliang, FU Junsen, et al. Interactive Graph Convolutional Network for Aspect-level Sentiment Analysis[J]. Journal of Xihua University(Natural Science Edition), 2024, 43(3): 8 − 17.

mental on four publicly available datasets demonstrate the effectiveness of the proposed model, showing significant improvements in both accuracy and F_1 size.

Keywords: aspect-level sentiment analysis；graph convolutional networks；phrase structure tree

方面级情感分析[1]是自然语言处理[2−3]的一个重要任务,旨在确定给定句子中特定方面的情感极性。相较于句子级情感分类,方面级情感分析具有更细的粒度,能更深入地理解用户对各方面的情感倾向。例如句子“The food was good, but the service was poor”可以被分析出用户对“food”方面表达了积极情感,对“service”方面表达了消极情感。方面级情感分析在许多应用场景中具有重要意义,如商品推荐系统中根据用户对各个方面的情感进行个性化推荐[4]、医疗文本中分析患者对不同治疗方面的情感反馈[5],以及突发公共卫生事件中对民众情感倾向的分析[6]等。通过深入分析方面级情感可以更准确地理解用户需求,改进产品和服务,从而提升用户满意度和体验。

关于方面级情感分析的研究方法主要有 2 类:基于注意力机制的递归神经网络(recursive neural network, RNN)[7]和卷积神经网络(convolution neural network, CNN)[8]。然而,这些方法在进行情感分析时仍存在一些局限。基于注意力机制的递归神经网络虽然可以强制模型关注给定的方面,但仅考虑了单个方面的注意力信息,并未有效地利用上下文的全部信息。由于句子的复杂性,注意力机制容易受到噪声干扰,无法准确捕捉上下文词和方面之间的语法依赖关系。这可能导致模型错误地将注意力集中在与语法无关的上下文词上,忽略了与方面相关的重要信息。CNN 使用局部连接和参数共享的机制,因此在捕捉文本局部特征的同时,可以降低模型的复杂度,在捕捉全局的句子信息方面也有着很大的优势。CNN 在方面级情感分析中具有很大的潜力,但也存在一些挑战和限制,例如对计算资源的要求高、对文本长度敏感以及无法处理一词多义现象等问题。目前比较流行的图卷积网络(graph convolutional networks, GCN)可以较好地解决以上问题。GCN 通过定义一种类似于卷积操作的方式,在图结构数据上进行特征提取。其核心思想是利用邻接矩阵来描述图的拓扑结构,通过多层的图卷积操作,逐渐传播和聚合节点的信息。

为此,本文提出了一种基于 GCND 的新方法。该方法利用 GCN 来构建语法依赖关系,并引入方面交互图来捕捉方面之间的情感关系,通过全面利用语法依赖和方面交互的信息进行方面级情感分析。本文的主要贡献如下。

1)提出了一种交互式图卷积网络模型,用于面向方面级情感分析。该模型能够有效地捕捉特定方面短语的内部语义相关性和不同方面词之间的情感交互关系。通过在图卷积网络中融合方面交互图,全面考虑方面之间的情感传递和影响,从而提升情感分析的准确度和表达能力。

2)为了更准确地建模不同方面单词的依赖关系,本文采用了短语结构树来构建方面交互图,以捕捉句子中方面单词之间的语法依赖关系,进而提升模型对句子结构的理解能力。同时,在 GCN 中引入一个全局节点,解决存在多个方面词时精度浮动的问题。

3)通过大量实验证明本文提出的模型是有效的,并通过消融实验进一步确认了各个模块的重要性。

1　相关工作

早期的方面级情感分析方法主要依赖于语言规则和情感词典[9]。然而,这些方法在应对人工规则和特征工程的复杂性方面存在困难,并且无法有效地构建方面词与上下文之间的关系。随着深度学习在自然语言处理领域的广泛应用,研究者开始探索基于神经网络的方面级情感分析方法。Tang 等[10]提出了基于目标依赖的长短期记忆网络(TD-LSTM)和基于目标关联的长短期记忆网络(TC-LSTM),并对其进行了改进。Ruder 等[11]提出了使用层次化和双向 LSTM 模型来进行方面级情感分类,利用单词嵌入作为句子级双向 LSTM 的输入。Wang 等[12]提出一种基于注意力的方面嵌入 LSTM 方法,注意力机制被用来学习句子的权重。现有的基于神经网络的方法通常从上下文中学习方面词相关的信息[13]。Ma 等[14]提出了一种交互式注意网络(interactive attention networks, IAN),使

用 2 个注意力网络来交互式地检测目标描述的重要单词和整个上下文的重要单词。Tang 等[15] 引入了一种面向方面的情感分类的端到端存储网络模型,使用具有外部存储器的注意力机制,来捕获相对于给定方面的每个上下内容单词的重要性。Fan 等[16] 提出了一种细粒度的注意力机制,以捕获方面词和上下文之间的词级交互,并将其与粗粒度的注意力机制结合形成多粒度注意力机制网络。

近年来,由于出色的图表示能力,图神经网络(graph neural network, GNN)受到越来越多的关注。GCN 是一种有效的卷积神经网络变体,由 Kipf 等[17] 于 2017 年提出。在方面级情感分析中,研究者也利用 GCN 来增强模型的性能。Zhang 等[18] 首次将 GCN 运用到方面级情感分析任务中,提出了特定方面术语图卷积网络(ASGCN)。Liang 等[19] 整合了句法和上下文信息来解释特定方面和其他方面之间的相关性。Zhou 等[20] 提出了一个基于句法和知识的图卷积模型(SK-GCN),构建了句法依赖图和常识知识图,以增强句子对给定方面词的表示来进行情感分类。Lu 等[21] 考虑了句子的不同方面间的依赖关系。夏鸿斌等[22] 将图卷积网络与过度注意神经网络结合用来判断方面情感。

以上研究主要依赖于深度学习算法和 GCN 来提高方面级情感分析的有效性,但在处理复杂的语法依赖和长跨度的多方面句子时,这些方法的准确度有待提高。为此,本文提出了一种利用 GCN 来捕获语义依赖和方面交互的情感分析方法(SEAI-GCN 模型)。

2 SEAI-GCN 模型

本文提出的模型(SEAI-GCN 模型)结构如图 1 所示,主要由 3 个部分构成。

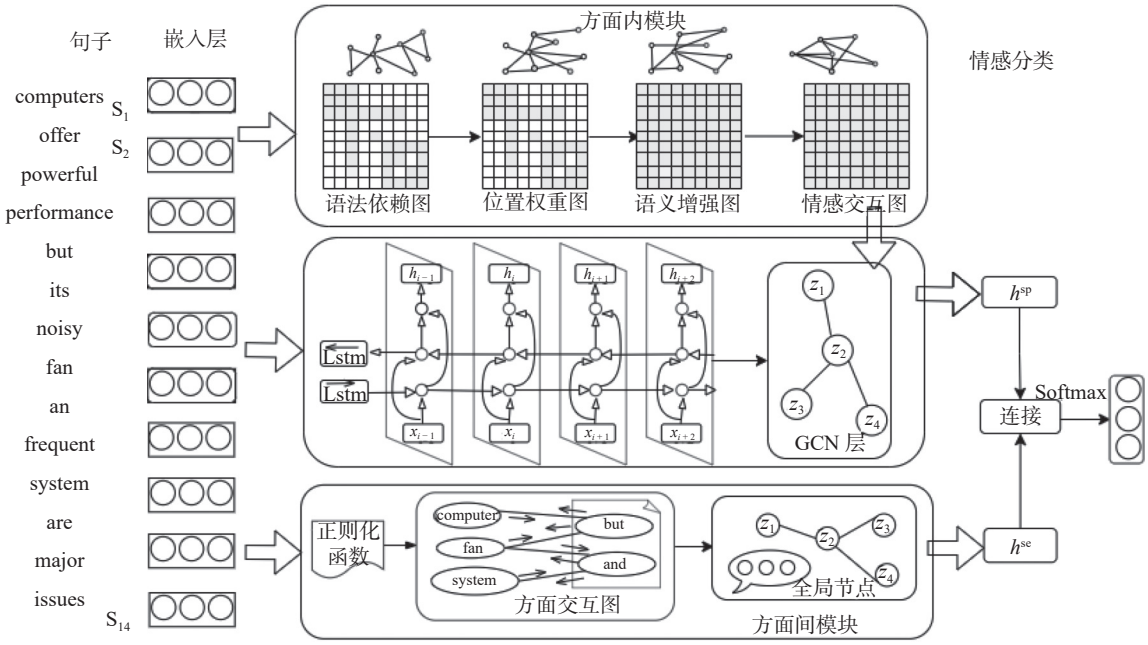

图 1 SEAI-GCN 模型

Fig. 1 SEAI-GCN model

1)方面内模块。其目标是捕捉特定方面的特征,包括 4 个邻接矩阵图:语法依赖图、位置权重图、语义增强图和情感交互图。

2)方面间模块。其目标是增强方面的表述,通过使用基于规则的映射函数构建一个方面交互图。方面交互图被输入到一个全局 GCN 中,全局 GCN 利用全局节点来整合方面交互图中的信息,使模型能更好地考虑整个句子的语境和全局关系。

3)情感分类。最终的情感预测是基于 2 个模块的 GCN 输出进行综合得到,并利用 Softmax 函数进行分类。

2.1 方面内模块

在方面内模块中,本文首先根据句法依赖树构建了一个依赖图,接着,通过计算特定方面短语之

间的相对位置信息生成位置权重图,并将语法依赖图和位置权重图整合到一起生成语义增强图。此外,本文还构建了情感互动图,用于综合不同方面之间的情感交互信息。最后,情感交互图与隐藏状态向量表示一起输入到 GCN 中进行卷积运算。

2.1.1　语法依赖图

受 GCN 模型[19] 的启发,构建一个建立在依赖树上的新型依赖图。

$$D_{i,j}^{\mathrm{G}}=\begin{cases}1 & i=j \text{ or } s_i \text{ and } s_j \text{ in the dependency tree}\\ 0 & \text{其他}\end{cases} \tag{1}$$

式中: $D_{i,j}^{\mathrm{G}}$表示语法依赖图; s_i表示第i个上下文单词; s_j表示第j个上下文单词。

2.1.2　位置权重图

为了更准确地捕捉句子中方面词之间的语义关系并凸显它们之间的相互联系,本文引入了相对位置权重。通过计算这些相对位置权重,强调语义依赖方面的重要性,从而更有效地构建方面之间的关联,并将其整合为相对位置权重图。图结构提供了有关方面词之间相对位置的关键信息,进一步增强了模型对方面级情感分析任务的表达能力。具体如公式(2)所示。

$$D_{i,j}^{\mathrm{P}}=\begin{cases}1 & s_i\in A \text{ and } s_j\in A\\ 1/(|j-p_a|+1) & s_i\in A\\ 1/(|i-p_a|+1) & s_j\in A\\ 0 & \text{其他}\end{cases} \tag{2}$$

式中: $D_{i,j}^{\mathrm{P}}$表示位置权重图; $|\cdot|$表示绝对值; s_i和s_j为上下文词; A表示特定方面短语; p_a为特定方面的起始位置。

2.1.3　语义增强图

为了强化上下文词的句法依赖关系,并构建方面和上下文词之间的关系,本文将语法依赖图和位置权重图整合,形成了语义增强图,从而得到以方面内部信息为中心的邻接矩阵。

当$D_{i,j}^{\mathrm{G}}=1$时

$$D_{i,j}^{\mathrm{E}}=D_{i,j}^{\mathrm{G}}+D_{i,j}^{\mathrm{G}}*D_{i,j}^{\mathrm{P}} \tag{3}$$

其他情况下:

$$D_{i,j}^{\mathrm{E}}=\begin{cases}1 & s_i\in A \text{ and } s_j\in A\\ 1/(|j-p_a|+1) & s_i\in A\\ 1/(|i-p_a|+1) & s_j\in A\\ 0 & \text{其他}\end{cases}$$

式中$D_{i,j}^{\mathrm{E}}$表示语义增强图。

2.1.4　情感交互图

例如,在句子“The Lenovo desktop computer offers powerful performance,but its noisy fan and frequent system crashes are major issues.”中,“Lenovo desktop”“noisy fan”和“frequent system crashes”这些方面在情感上是相互关联的。为了准确捕捉这些不同方面之间的情感交互,本文创建了一个情感交互图。该图能更好地理解和分析这些方面之间的情感动态,并揭示它们之间的关系。

$$D_{i,j}^{\mathrm{C}}=\begin{cases}1/\left(p_o\sum_{n=1}^{N}\dfrac{p_o}{p_o+1}+1\right), & s_i \text{ and } s_j\in A\\ 1/\left(p_o\sum_{n=1}^{N}\dfrac{p_o}{p_o-j}+1\right), & s_i\in A \text{ and } s_j\in O\\ 1/\left(p_o\sum_{n=1}^{N}\dfrac{p_o}{p_o-i}+1\right), & s_j\in A \text{ and } s_i\in O\\ 0 & \text{其他}\end{cases} \tag{4}$$

$$A_{i,j}^{\mathrm{C}}=1+1/(|p_a-p_o|+1)*D_{i,j}^{\mathrm{C}} \tag{5}$$

式中: $D_{i,j}^{\mathrm{C}}$表示情感交互图; $A_{i,j}^{\mathrm{C}}$表示最终得到的情感交互图,用于引导对不同方面的关注; O表示其他方面对应的短语集合; p_o是句子中其他方面的起始位置,表示其他方面对应的短语集合。

2.2　图卷积网络

情感交互图A^{C}与隐藏状态向量$\boldsymbol{h}_i^{\mathrm{C}}$一同输入到图卷积网络中进行卷积运算,最后通过一个具有归一化因子的图卷积操作来更新每个节点的隐藏表示。

$$h^{\mathrm{sp}}=\mathrm{Relu}\left(\sum_{j=1}^{n}\boldsymbol{A}_{i,j}\boldsymbol{W}_l g_j^{l-1}+\boldsymbol{b}_l\right) \tag{6}$$

式中: Relu 为激活函数; $h_i^l\in\mathbf{R}^{2d}$为l层 GCN 的隐藏表示; g_j^{l-1}为从l-1 层 GCN 得到的表示; $\boldsymbol{A}_{i,j}$表示情感交互邻接矩阵; $d_i=\sum_{j=1}^{n}\boldsymbol{A}_{i,j}$表示树的度; $\boldsymbol{W}_l$是权重矩阵; $\boldsymbol{b}_l$是训练过程中要学习的偏置向量。

2.3　方面间模块

为了解决方面内部模块忽略方面词之间相互依赖的问题,引入了方面交互图。通过加入全局节点,解决多个方面词时模型准确度波动的问题,以提高模型性能。

2.3.1　短语分割树

为揭示方面之间的关系,本文采用 RF(regular function)[23] 的正则函数来识别它们之间的关联,通过分割词语(如连接词)来确定给定 2 个方面之间的短语分割术语。短语结构树如图 2 所示。

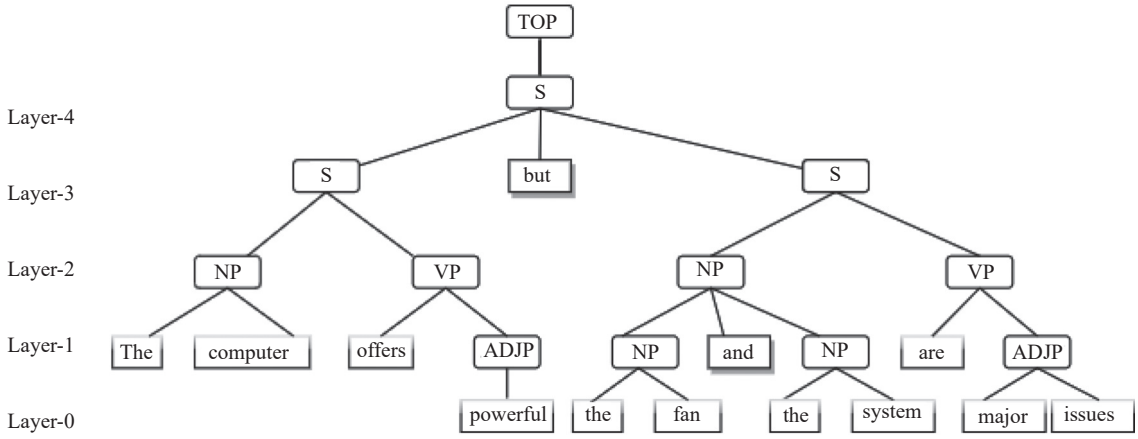

图 2 短语结构树

Fig. 2 Phrase composition tree

首先,找到这 2 个方面的最低共同祖先。然后,在子树中搜索连接这 2 个方面的内部分支。这样的子树只包含与这 2 个方面相关的信息,减少了无关元素的存在。如果存在内部分支,RF 函数返回该分支中的所有词语。反之,如果找不到内部分支,则返回位于这 2 个方面之间的词语。其表达式为

$$\mathrm{RF}\left(a_i,a_j\right)=\begin{cases}\{w_k\}, & \text{if } \left|B_w\left(a_i,a_j\right)\right|=0\\ B_w\left(a_i,a_j\right), & \text{其他}\end{cases} \tag{7}$$

式中: $i<k<j$; $\mathrm{RF}\left(a_i,a_j\right)$表示返回$a_i$和$a_j$内部分支中的文本词。

2.3.2 方面交互图

在方面分析中,方面的影响应该具有连续性,而且不同方面之间的相互作用会随着它们之间的距离增加逐渐减弱。为了处理长距离依赖,减少计算负担,本文专注于相邻方面之间的关系,利用 RF 函数得到相关短语切割术语,通过将各个方面与相应的短语分割项连接起来,构建了一个方面交互图来推断它们之间的关系。如图 3 所示,为了区分方面上下文图上的双向关系,构建了 2 个相应的邻接矩阵:第 1 个处理句子中所有方面的奇数方面到偶数方面的影响;第 2 个与之相反。然后,将 RF 得到的短语分割项作为输入,获得各方面关系的增强表示,再将其输入到包含有全局节点的 GCN 中。这样可以更好地捕捉方面之间的影响并减少噪声。

2.3.3 全局 GCN

为了解决句子中存在多个方面词时模型准确度不稳定的问题,在 GCN 中,本文为全局节点设置

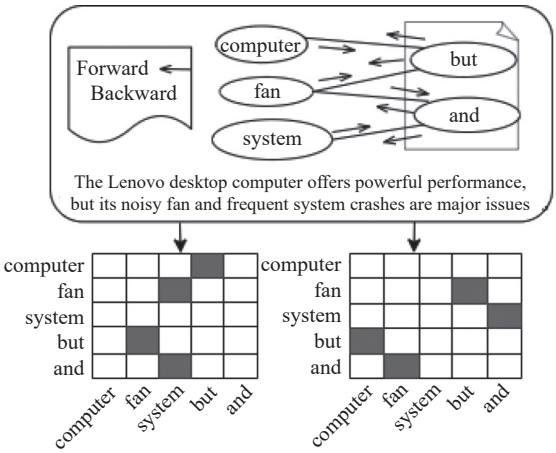

图 3 方面交互图和对应的邻接矩阵

Fig. 3 Aspect interaction graph and the corresponding adjacency matrix

了等量的节点,每个全局节点的隐藏状态仅与其意见范围内的节点状态相关,并且其对应的方面术语被包含在其特定的更新过程中。通过这种方式,能够更好地处理句子中多个方面词之间的上下文信息和关系,表达式为

$$h^{\mathrm{se}}=\sum_{i=1}^{T}a\cdot h_i^L \tag{8}$$

式中: $h^{\mathrm{se}}\in\mathbf{R}^{2d}$; a为可训练参数; h_i^L为 L 层 GCN 的输出。

2.4 模型训练

为了优化所有参数,并尽可能地最小化损失函数,本文使用交叉熵损失函数对模型进行训练。首先,将方面内模块的输出h^{sp}和方面间模块的输出h^{se}组合为最终的表示,然后将其输入到 Softmax 激活层,得到情感极性分类,最后利用损失函数对

SEAI-GCN 进行训练优化。

$$\boldsymbol{v} = \left[h^{\mathrm{sp}}, h^{\mathrm{se}}\right] \tag{9}$$

$$y = \mathrm{softmax}\left(W_p \boldsymbol{v} + b_p\right) \tag{10}$$

$$\mathcal{L}_{\mathrm{C}} = -\sum_i^N y_i \log\left(\hat{y}_i\right) + \lambda \|\theta\|^2 \tag{11}$$

式中: v 是方面内和方面间模块的输出表示; N 为数据集中的样本数; y_i为预测的情感极性的真实概率; $\hat{y}_i$为估计概率; λ为正则化因子; $\mathcal{L}_{\mathrm{C}}$是损失函数; W_p、b_p和θ表示可训练的参数。

3　实验及分析

3.1　数据集

为了评估本文方法的有效性, 在 4 个公开数据集上进行了实验。数据集信息如表 1 所示。

表 1　数据集统计信息

Tab. 1　Data set statistics

数据集		积极	中性	消极
Lap14	Train	994	464	870
	Test	341	169	128
Rest14	Train	2 164	637	807
	Test	728	196	196
Rest15	Train	912	36	256
	Test	326	34	182
Rest16	Train	1 240	69	439
	Test	469	30	117

3.2　实验评价指标

为了比较各个模型算法的性能, 采用准确率(Acc)和宏平均(F_1)作为评价指标, 定义为:

$$\mathrm{Acc} = \frac{\mathrm{TP}+\mathrm{TN}}{\mathrm{TP}+\mathrm{TN}+\mathrm{FP}+\mathrm{FN}} \tag{12}$$

$$\mathrm{Precision} = \frac{\mathrm{TP}}{\mathrm{TP}+\mathrm{FN}} \tag{13}$$

$$\mathrm{Recall} = \frac{\mathrm{TP}}{\mathrm{TP}+\mathrm{FP}} \tag{14}$$

$$F_1 = \frac{2\mathrm{TP}}{2\mathrm{TP}+\mathrm{FP}+\mathrm{FN}} = \frac{2\mathrm{Precision}\cdot\mathrm{Recall}}{\mathrm{Precision}+\mathrm{Recall}} \tag{15}$$

式中: TP 是将正类预测为正类数; TN 是将负类预测为负类数; FP 是将负类预测为正类数; FN 是将正类预测为负类数。

3.3　对比模型

为对比本文模型的效果, 选取了以下基线模型。

1)MemNet[10]: Tang 等将给定方面的内容和位置整合到一个深层存储网络中, 构建基于上下文信息的记忆并利用注意力机制捕捉不同方面情感倾向的相关信息。

2)MGAN[15]: 结合了依赖树和神经网络, 使用 Bi-LSTM 学习句子特征, 引入注意力机制对齐跨任务特征。

3)ASGCN-DG[18]: 通过基于 GCN 的依赖树提取句法信息和词语依赖关系, 利用有向和无向图提取特定方面的相应情感。

4)BiGCN[13]: 利用双向图卷积捕捉方面词和单词之间的句法和语义依赖关系。

5)InterGCN[19]: 通过构建方面词与单词的相互影响, 利用交互式图卷积捕捉方面词和单词之间的交互关系。

6)SK-GCN[20]: 通过 GCN 联合构建句法依赖树和常识知识图, 形成了一种句法和知识结合的 GCN 模型。

7)SPGCN[21]: 考虑了句子的不同方面间的依赖关系。

8)ASGCN-AOA-DG[22]: 结合图卷积网络和过度注意力机制, 以提高对特定方面情感的准确度。

3.4　实验结果及分析

本文使用python3.6、pytorch1.0.0 和SpaCy2.0.18 框架来实现 SEAI-GCN 模型。实验中, 引入预先训练好的 glove 来初始化单词嵌入, 采用 glove 向量将每个单词初始化为 300 维的单词嵌入, 隐藏向量表示维数设为 300, GCN 的层数设置为 2, 选用 Adam 作为优化器。

使用 4 个数据集对模型进行评估, 并且与几种情感分析中典型的基线模型方法做比较, 以验证本文提出的 SEAI-GCN 模型的有效性。实验结果如表 2 所示。

实验结果显示, SEAI-GCN 模型在 Rest15 数据集上的 F_1 得分相比 SPGCN 模型低 0.76%, 但其 Acc 却提高了 0.58%。同时, 在其他数据集上, SEAI-GCN 模型的 Acc 和 F_1 得分均优于大多数其他基线模型。值得注意的是, SEAI-GCN 模型在 Lap14 数据集上的 Acc 性能比 SPGCN 模型提高了 2.34%。

SEAI-GCN 模型相较于基于注意力机制和

表 2 实验结果

Tab. 2 Experimental results

Model	Rest14		Lap14		Rest15		Rest16	
	Acc	F_1	Acc	F_1	Acc	F_1	Acc	F_1
MemNet	78.16	65.83	70.33	64.09	77.89	59.52	83.04	56.91
MGAN	81.25	71.94	75.39	72.47	79.36	57.26	87.06	62.29
ASGCN-DG	80.77	72.02	75.55	71.05	79.89	61.89	88.99	67.48
InterGCN	82.23	74.01	77.86	74.32	81.76	65.67	89.77	73.05
SK-GCN	80.36	70.43	73.20	69.18	80.12	60.70	85.17	68.08
SPGCN	83.16	74.91	77.90	73.86	81.37	**68.07**	90.75	75.20
ASGCN-AOA	82.57	73.45	75.24	70.29	80.31	63.60	89.23	70.58
SEAI-GCN	**83.95**	**75.21**	**80.24**	**74.00**	**81.95**	67.31	**91.43**	**75.50**

LSTM 的模型“MemNet”和“MGAN”，表现出显著的性能提升。这主要得益于 SEAI-GCN 模型能够准确捕捉句法依赖树中的句法信息，并构建了方面词和上下文之间的长距离情感依赖关系，从而避免了错误的关联和情感判断。

相较于其他 6 个基于 GCN 的模型，SEAI-GCN 模型能够更好地捕捉句子中不同方面之间的情感交互关系，而不只是关注特定方面与上下文的句法依赖。在包含 36.58% 的多方面词句子的 Rest14 数据集上，SEAI-GCN 模型的 Acc 和 F_1 值分别比基线模型 SPGCN 提高了 0.79% 和 1.11%。这证明了 SEAI-GCN 模型在处理含有多个方面词的句子时能够展现出更好的效果，同时也验证了方面间模块的重要性。

综上所述，通过利用语法依赖构建邻接矩阵图和使用组成树构建方面交互图，能够显著影响方面短语的内部语义性和方面之间的情感交互。这对于提高方面级情感分类的准确率具有重要意义。

3.5 消融实验

为深入研究 SEAI-GCN 模型中每个组成部分对性能的影响程度，本文对 SEAI-GCN 模型进行了消融实验。实验过程中，实验环境、数据集和评价指标不变，去掉了模型图中的不同部分，即分别去除了本文提出的位置权重模块、语法距离模块、情感交互模块等。结果发现，去掉模型图中的不同模块对实验结果有着不同程度的影响，如表 3 所示。

表 3 消融实验结果

Tab. 3 Results of ablation experiment

Model	Rest14		Lap14		Rest15		Rest16	
	Acc	F_1	Acc	F_1	Acc	F_1	Acc	F_1
SEAI-GCNw/o pos.	83.11	74.73	79.84	73.58	81.10	67.22	91.34	74.36
SEAI-GCNw/o dis.	82.67	73.66	79.42	73.21	80.06	65.78	90.51	74.24
SEAI-GCNw/o sent.	82.02	73.08	76.48	72.65	81.32	65.01	88.79	70.83
SEAI-GCNw/o intra.	83.23	73.45	79.21	72.43	81.40	66.49	91.22	74.36
SEAI-GCNw/o inter.	82.78	73.59	79.36	73.27	81.57	67.03	90.84	73.92
SEAI-GCN	**83.95**	**75.21**	**80.24**	**74.00**	**81.95**	**67.31**	**91.43**	**75.50**

1）移除位置权重 (SEAI-GCN w/o pos.)，导致模型无法准确捕捉方面短语内部的语义相关性。这表明位置权重在提取方面内部信息方面起到了重要作用。

2）移除语法距离 (SEAI-GCN w/o dis.)，相比于移除位置权重，进一步降低了模型的性能。这表明上下文词与方面词之间的距离对方面词的情感表达具有重要影响。

3)移除情感交互 (SEAI-GCN w/o sent.), 导致模型性能低于移除位置权重和移除语法距离的情况。这验证了句子中存在复杂的情感关系和多个方面词之间的交互对模型的性能具有重要影响。

4)移除方面内模块 (SEAI-GCN w/o intra.) 和移除方面间模块 (SEAI-GCN w/o inter.), 都导致模型性能下降, 但移除方面间模块的影响更大。说明在存在较多包含多个方面词的复杂句子中, 如果单纯地考虑方面单词内部的信息而忽略方面单词之间的交互, 将会对模型的效果产生较大的影响。

3.6　讨论

3.6.1　全局节点数量

如图 4 所示, 当全局节点数量为 1 时, 随着方面词数量的增加, 模型的精度逐渐下降, 且精度波动较大。当全局节点的数量为 3、方面词的数量小于 3 时, 模型精度略有下降, 但波动幅度不大。然而, 如果将全局节点的数量保持 3 不变, 而方面词数量增加到 3 及以上时, 模型的准确率会大幅下降。此外, 当全局节点数为 5 时, 其准确率的变化情况与全局节点数为 3 时类似。当全局节点数为 7, 且方面词数量保持在 7 个以内时, 模型精度会逐渐下降, 但波动幅度不大。可见, 引入全局节点信息可以更有效地处理句子中含有多个方面词的情况, 有效地解决模型在处理多个方面词时准确度波动的问题。

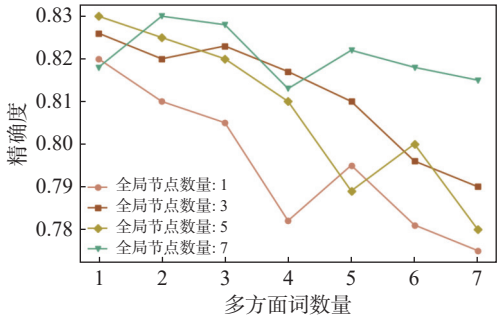

图 4　全局节点数与多方面词数量对 Acc 的影响

Fig. 4　The influence of the number of global nodes and the number of multifaceted words on Acc

3.6.2　GCN 层数影响

为探究 GCN 层数对 SEAI-GCN 模型性能的影响, 进行了实验, 评估 GCN 层数从 1 变化到 8 时对 4 个数据集的 Acc 和 F_1 值的影响, 实验结果如图 5 和图 6 所示。

实验结果显示: 当 GCN 的层数设置为 2 时, 模型表现出最佳性能; 当 GCN 的层数超过 2 时, 模型的性能会下降。这是因为层数的增加会为模型带来更多的噪声干扰, 从而降低 GCN 的学习能力, 导

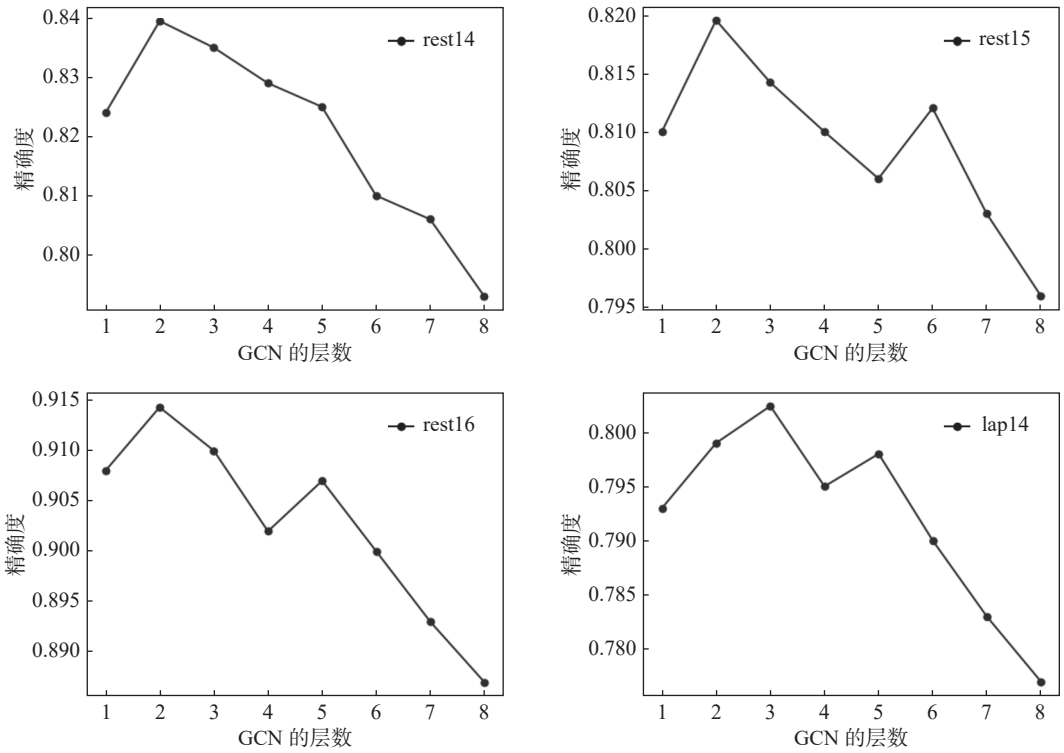

图 5　GCN 层数对 Acc 的影响

Fig. 5　The influence of the number of GCN layers on Acc

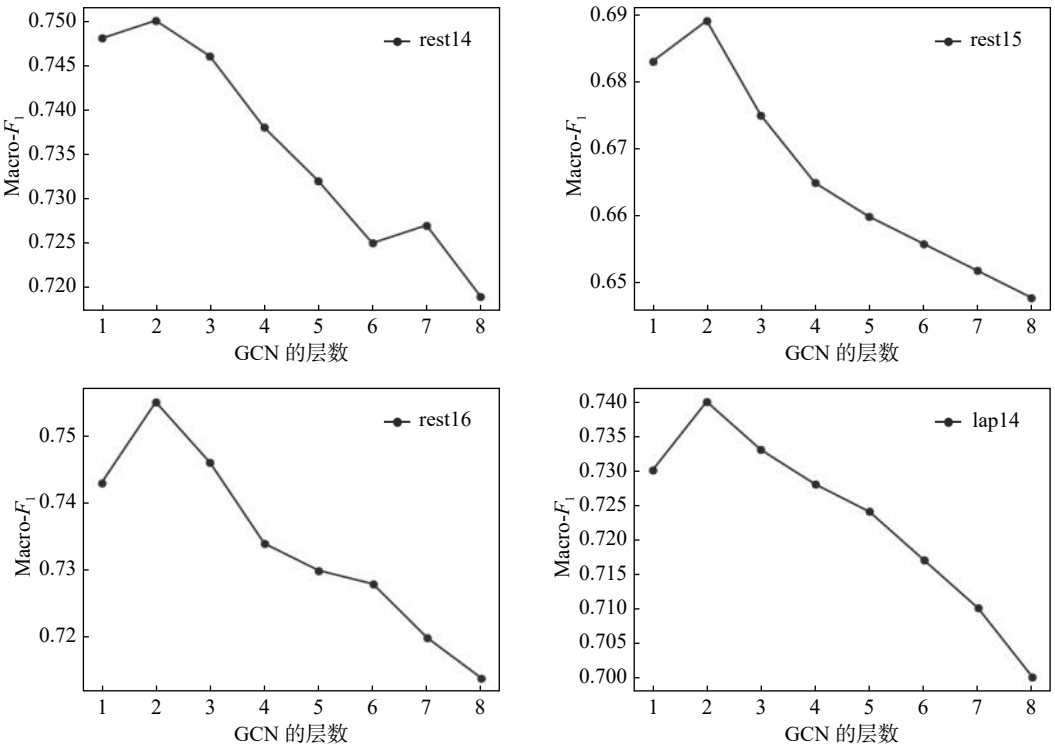

图 6 GCN 层数对 F_1 的影响

Fig. 6 The influence of the number of GCN layers on F_1

致性能迅速下降。为了在性能和学习能力之间找到平衡,本文模型使用了 2 层的 GCN。

3.7 案例分析

为了验证本文模型的有效性,从数据集中选择了几个典型句子进行分析,结果如表 4 所示。这些句子分别被标记为 P(积极)、N(消极)和 O(中性),以表示它们的情感倾向。

表 4 案例分析

Tab. 4 Case studies

序号	例子	模型			
		MGAN	SK-GCN	SPGCN	SEAI-GCN
1	Great **food** but the **service** was dreadful !	($N_{\surd}$,$N_{\times}$)	($P_{\surd}$,$N_{\surd}$)	($P_{\surd}$,$N_{\surd}$)	($P_{\surd}$,$N_{\surd}$)
2	The smaller **size** was a bonus because of space restrictions.	$N_{\times}$	$N_{\times}$	$P_{\surd}$	$P_{\surd}$

在第 1 个例子中,MGAN 模型对“service”的情感预测错误,而其他 3 个基于 GCN 的模型都作出了正确的预测。这说明基于 GCN 的模型可以灵活地捕获语法依赖信息和单词之间的依赖关系。

在第 2 个例子中,句子中的方面词由多个单词组成,这可能导致模型难以准确捕捉到关键词“size”,而错误地将注意力集中在修饰词“smaller”上,从而导致错误的负向情感预测。然而,本文模型能够根据方面短语内部语义性正确地识别并预测方面词。

4 总结与展望

本文探讨了方面短语内部语义相关性和不同方面情感交互的关联,提出了一种面向交互式图卷积网络的方面级情感分析模型。通过在 GCN 中结合邻接矩阵图与方面交互图,实现了较好的性能。实验结果也验证了本文模型的有效性和准确性。在未来,计划将外部知识整合到模型中,以促进情感依赖分析。尤其对于隐含地表达情感极性的句子,通常很难从明确的线索角度推断出它们的情感。然而,具有推理能力的知识图可以利用其丰富

的知识来推断和判断隐含的情感。

参 考 文 献

[1] 邓钰. 面向短文本的情感分析关键技术研究 [D]. 成都: 电子科技大学, 2021.

DENG Y. Research on key technologies of sentiment analysis for short text[D]. Chengdu: University of Electronic Science and Technology of China, 2021.

[2] SCHOUTEN K, FRASINCAR F. Survey on aspect-level sentiment analysis[J]. IEEE Transactions on Knowledge and Data Engineering, 2016, 28(3): 813 – 830.

[3] CHENG J J, ZHAO S L, ZHANG J N, et al. Aspect-level sentiment classification with HEAT (HiErarchical ATtention) network[C]//Proceedings of the 2017 ACM on Conference on Information and Knowledge Management. Singapore: ACM, 2017: 97 – 106.

[4] QIU J T, LIU C H, LI Y H, et al. Leveraging sentiment analysis at the aspects level to predict ratings of reviews[J]. Information Sciences, 2018, 451/452: 295 – 309.

[5] LI Q, WENG L H, DING X H. A novel neural network-based method for medical text classification[J]. Future Internet, 2019, 11(12): 255.

[6] SHADADI E, KOUSER S, ALAMER L, et al. Novel approach of predicting human sentiment using deep learning[J]. Journal of Computer Science and Engineering (JCSE), 2022, 3(2): 107 – 119.

[7] ZHENG Y Q, LI X, SU G X, et al. Position-aware hybrid attention network for aspect-level sentiment analysis[C]//Information Retrieval: 26th China Conference, CCIR 2020. Xi'an: ACM, 2020: 83 – 95.

[8] XUE W, LI T. Aspect based sentiment analysis with gated convolutional networks[C]//Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). Melbourne: Association for Computational Linguistics, 2018: 2514 – 2523.

[9] RAO D, RAVICHANDRAN D. Semi-supervised polarity lexicon induction[C]//Proceedings of the 12th Conference of the European Chapter of the Association for Computational Linguistics. Athens: ACM, 2009: 675 – 682.

[10] TANG D, QIN B, FENG X, et al. Effective LSTMs for target-dependent sentiment classification[C]//Proceedings of the 26th International Conference on Computational Linguistics. [S.l.]: Technical Papers, 2016: 3298 – 3307.

[11] RUDER S, GHAFFARI P, BRESLIN J. A hierarchical model of reviews for aspect-based sentiment analysis[J/OL]. [2023-06-06]. http://arxiv.org/abs/1609.02745.

[12] 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. Austin, Texas: Association for Computational Linguistics, 2016: 606 – 615.

[13] ZHANG M, QIAN T Y. 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). Stroudsburg: Association for Computational Linguistics, 2020: 3540 – 3549.

[14] MA D H, LI S J, ZHANG X D, et al. Interactive attention networks for aspect-level sentiment classification[C]//Proceedings of the 26th International Joint Conference on Artificial Intelligence. Melbourne: ACM, 2017: 4068 – 4074.

[15] TANG D Y, QIN B, LIU T. Aspect level sentiment classification with deep memory network[C]//Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing. Austin, Texas: Association for Computational Linguistics, 2016: 214 – 224.

[16] 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. Brussels: Association for Computational Linguistics, 2018: 3433 – 3442.

[17] KIPF T, WELLING M. Semi-supervised classification with graph convolutional networks[C]//Proceedings of the 5th International Conference on Learning Representations. Toulon: OpenReview, 2017: 1–11.

[18] 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). Hong Kong: Association for Computational Linguistics, 2019: 4568 – 4578.

[19] LIANG B, YIN R D, 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. Barcelona: International Committee on Computational Linguistics, 2020: 150 –161.

(下转第 53 页)

ic and digital manufacturing technology of Pascal curve gears[J]. Manufacturing Technology & Machine Tool, 2011(12): 90 – 93.

[6] 王英, 陈建能, 赵雄, 等. 非圆齿轮行星轮系传动的栽植机构参数优化与试验[J]. 农业机械学报, 2015, 46(9): 85 – 93.

WANG Y, CHEN J N, ZHAO X, et al. Parameter optimization and experiment of planting mechanism driven by planetary non-circular gears[J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(9): 85 – 93.

[7] 任廷志, 刘才. 节曲线向径按余弦规律变化的齿轮与非圆齿轮共轭的研究[J]. 机械工程学报, 2004, 40(10): 181 – 184.

REN T Z, LIU C. Study on the gear which its pitch curve is changed as cosine rule conjugate with the non-circular gear[J]. Chinese Journal of Mechanical Engineering, 2004, 40(10): 181 – 184.

[8] 孙新城, 叶军, 陈建能, 等. 高阶变性巴斯噶蜗线非圆齿轮传动特性分析[J]. 浙江理工大学学报 (自然科学版), 2015, 33(2): 203 – 208.

SUN X C, YE J, CHEN J N, et al. Analysis on non-circular gears transmission characteristic of high-order deformed pascal spiral line[J]. Journal of Zhejiang Institute of Science and Technology, 2015, 33(2): 203 – 208.

[9] 刘永平, 谢瑞雪, 陈向宇. 变性椭圆齿轮传动特性与运动仿真分析[J]. 兰州理工大学学报, 2018, 44(4): 40 – 44.

LIU Y P, XIE R X, CHEN X Y. Transmission characteristics of denatured elliptical gear and its motion simulation analysis[J]. Journal of Lanzhou University of Technology, 2018, 44(4): 40 – 44.

[10] 王国强, 蔺文刚, 赵云鹏. Pascal 蜗线齿轮的设计研究[J]. 自动化与仪器仪表, 2016(6): 87 – 89.

WANG G Q, LIN W G, ZHAO Y P. Design and research of Pascal worm gear[J]. Automation & Instrumentation, 2016(6): 87 – 89.

[11] 赵玉龙, 郭吉苹, 郭正华, 等. 正交弧线齿面齿轮传动的啮合接触分析[J]. 制造技术与机床, 2021(2): 61 – 65.

ZHAO Y L, GUO J P, GUO Z H, et al. Analysis of meshing contact of orthogonal arc tooth face-gear driver [J]. Manufacturing Technology & Machine Tool, 2021(2): 61 – 65.

[12] 冯新强. 基于黄金分割法的热工参数辨识及 PID 参数优化 [D]. 北京: 华北电力大学, 2016.

FENG X Q. Thermal parameter identification and PID parameter optimization based on the golden section method[D]. Beijing: North China Electric Power University, 2016.

[13] 叶军, 陈建能, 赵雄, 等. 一种新型类偏心圆非圆齿轮设计及其应用[J]. 中国机械工程, 2018, 29(5): 565 – 571.

YE J, CHEN J N, ZHAO X, et al. Design and applications of generalized eccentric noncircular gears[J]. China Mechanical Engineering, 2018, 29(5): 565 – 571.

(责任编辑: 饶莉)

(上接第 17 页)

[20] 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.

[21] LU Q, SUN X, SUTCLIFFE R, et al. Sentiment interaction and multi-graph perception with graph convolutional networks for aspect-based sentiment analysis[J]. Knowledge-Based Systems, 2022, 256: 109840.

[22] 夏鸿斌, 顾艳, 刘渊. 面向特定方面情感分析的图卷积过度注意 (ASGCN-AOA) 模型[J]. 中文信息学报, 2022, 36(3): 146 – 153.

XIA H B, GU Y, LIU Y. Graph convolution overattention(ASGCN-AOA)model for specific aspects of sentiment analysis[J]. Journal of Chinese Information Processing, 2022, 36(3): 146 – 153.

[23] LIANG S, WEI W, MAO X L, et al. BiSyn-GAT+: Bi-syntax aware graph attention network for aspect-based sentiment analysis[C]//Findings of the Association for Computational Linguistics: ACL 2022. Dublin: Association for Computational Linguistics, 2022: 1835 – 1848.

(责任编辑: 饶莉)