



# 计算机科学

COMPUTER SCIENCE

## SS-GCN:情感增强和句法增强的方面级情感分析模型

李帅, 徐彬, 韩祎珂, 廖同鑫

引用本文

李帅, 徐彬, 韩祎珂, 廖同鑫. SS-GCN:情感增强和句法增强的方面级情感分析模型[J]. 计算机科学, 2023, 50(3): 3-11.

LI Shuai, XU Bin, HAN Yike, LIAO Tongxin. SS-GCN:Aspect-based Sentiment Analysis Model with Affective Enhancement and Syntactic Enhancement [J]. Computer Science, 2023, 50(3): 3-11.

---

## 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)

### [文档增强型知识库问答](#)

Document-enhanced Question Answering over Knowledge-Bases

计算机科学, 2023, 50(3): 266-275. <https://doi.org/10.11896/jsjcx.220300022>

### [异构信息网络的注意力感知多通道图卷积评分预测模型](#)

Attention-aware Multi-channel Graph Convolutional Rating Prediction Model for Heterogeneous Information Networks

计算机科学, 2023, 50(3): 129-138. <https://doi.org/10.11896/jsjcx.220300004>

### [基于图神经网络的多信息优化实体对齐模型](#)

Multi-information Optimized Entity Alignment Model Based on Graph Neural Network

计算机科学, 2023, 50(3): 34-41. <https://doi.org/10.11896/jsjcx.220700242>

### [基于联合模型的端到端事件可信度识别](#)

End-to-End Event Factuality Identification with Joint Model

计算机科学, 2023, 50(2): 292-299. <https://doi.org/10.11896/jsjcx.211200108>

### [基于会话式机器阅读理解模型的事件抽取方法](#)

Event Extraction Method Based on Conversational Machine Reading Comprehension Model

计算机科学, 2023, 50(2): 275-284. <https://doi.org/10.11896/jsjcx.220400271>

# SS-GCN:情感增强和句法增强的方面级情感分析模型

李帅 徐彬 韩祎珂 廖同鑫

东北大学计算机科学与工程学院 沈阳 110819

(lishuai@stumail.neu.edu.cn)

**摘要** 方面级情感分析(Asspect-Based Sentiment Analysis, ABSA)作为知识图谱下游应用,属于细粒度情感分析任务,旨在理解人们对评价目标在方面层次的情感极性。近年来,相关研究已经取得显著进步,但现有方法侧重于利用句子内的顺序性或句法依赖约束,而没有充分利用上下文词与方面词之间的依赖类型。此外,现有的基于图卷积神经网络模型对节点特征保留的能力不足。针对该问题,首先,在句法依赖树的基础上,充分挖掘上下文词与方面词之间的依赖类型,将其融入依赖图的构建;其次,定义了一个“敏感关系集合”,利用它来构建辅助句以增强特定上下文词与方面词之间的关联性,同时结合情感知识网络 SenticNet 以增强句子的依赖图,进而改进图神经网络的构建;最后,引入上下文保留机制,来减小节点特征在多层图卷积神经网络中的信息损失。提出的 SS-GCN 模型将并行学习到的句法表示和上下文表示进行融合以完成情感增强和句法增强。在 3 个公开数据集上进行了广泛的实验,证明了 SS-GCN 的有效性。

**关键词:** 方面级情感分析;图卷积神经网络;SenticNet;注意力机制;Bi-LSTM

中图法分类号 TP391

## SS-GCN: Aspect-based Sentiment Analysis Model with Affective Enhancement and Syntactic Enhancement

LI Shuai, XU Bin, HAN Yike and LIAO Tongxin

School of Computer Science and Engineering, Northeastern University, Shenyang 110819, China

**Abstract** Aspect-based sentiment analysis (ABSA), as a downstream application of knowledge graph, belongs to the fine-grained sentiment analysis task, which aims to understand the sentiment polarity of people on the evaluation target at the aspect level. Relevant research in recent years has made significant progress, but existing methods focus on exploiting sequentiality or syntactic dependency constraints within sentences, and do not fully exploit the type of dependencies between context words and aspect words. In addition, the existing graph-based convolutional neural network models have insufficient ability to retain node features. In response to this problem, firstly, based on the syntactic dependency tree, this paper fully excavates the dependency types between context words and aspect words, and integrates them into the construction of the dependency graph. Second, we define a “sensitive relation set”, which is used to construct auxiliary sentences to enhance the correlation between specific context words and aspect words, and at the same time, combined with the sentiment knowledge network SenticNet to enhance the sentence dependency graph, and then improve the construction of the graph neural network. Finally, a context retention mechanism is introduced to reduce the information loss of node features in the multilayer graph convolution neural network. The proposed SS-GCN model fuses the syntactic and contextual representations learned in parallel to accomplish sentiment enhancement and syntactic enhancement, and extensive experiments on three public datasets demonstrate the effectiveness of SS-GCN.

**Keywords** Aspect-level sentiment analysis, Graph convolutional networks, SenticNet, Attention mechanism, Bi-LSTM

### 1 引言

随着互联网产业的飞速发展,用户在社交媒体或电商

平台产生的数据量与日俱增,从文本中挖掘和理解观点变得十分重要,例如从电子商务平台的评论中挖掘客户对商品的意见有助于改进服务和产品,尤其是细粒度的意见,可以更好

到稿日期:2022-07-24 返修日期:2022-12-06

基金项目:中央高校基本科研业务费专项资金(N2116019);辽宁省自然科学基金面上项目(2022-MS-119);全国高等院校计算机基础教育研究会计算机基础教育教学研究课题(2022-AFCEC-237)

This work was supported by the Fundamental Research Funds for the Central Universities(N2116019), Liaoning Natural Science Foundation (2022-MS-119) and Teaching Research Project of Computer Basic Education of AFCEC(2022-AFCEC-237).

通信作者:徐彬(xubin@mail.neu.edu.cn)

地帮助商家精准定位存在的问题。然而,由于人工难以细粒度地分析海量评价,因此方面级情感分析(ABSA)任务近几年得到了广泛的关注。ABSA 任务旨在确定句子中不同方面的情感极性。例如:“great food but the service was dreadful!”, ABSA 应识别出 food 的情感极性是积极的,而 service 的情感极性是消极的。

ABSA 任务需要提取评论中的语义特征。早期的研究中,研究人员广泛使用注意力机制和循环神经网络(RNN)来建模方面词与上下文词之间的语义相关性,并将相关性作为权重分配给每个上下文词,以表示该词对方面词情感极性的重要性。此外,CNN 网络也被用来抽取语义特征。然而,CNN 无法像 RNN 那样计算方面词与上下文的关联度,对于含有多目标的评论,CNN 可能会失败。由于 RNN 和 CNN 都无法处理方面词与上下文词之间的情感依赖问题和远距离词依赖问题,研究人员尝试引入图神经网络,Zhang 等<sup>[1]</sup>使用 GCN 句法信息进行编码,并在句法上将各个方面词与相关的意见词联系起来,这类模型可以有效捕捉两个距离较远的单词之间的依存关系。此外,最近的研究表明,利用外部知识可以提高 ABSA 模型的性能,Zhou 等<sup>[2]</sup>提出了一种基于句法和知识的图卷积网络模型,他们对句法依赖树和常识知识进行编码,以丰富句子中给定方面的表示。Liang 等<sup>[3]</sup>为了将情感信息融入到依赖关系中,使用 SenticNet<sup>[4-9]</sup>的情感知识构建图神经网络。

尽管上述工作已经取得令人满意的结果,但大多数现有模型在构建图神经网络时无差别地对待所有词级依赖关系,而实际情况是,模型应更关注于方面的特定意见词(如形容词等)。为了解决上述问题,本文提出了 SS-GCN 模型,并定义了一个敏感依赖关系集合,以提取满足敏感依赖关系的上下文词,进而更有效地抽取上下文词和方面词之间的情感依赖关系。具体来说,该模型首先使用 Stanza<sup>[10]</sup>解析句法依存树,将 SenticNet 作为情感常识知识库来修饰图,并且结合敏感依赖关系集合来增强句子的邻接矩阵表示。其次,为了生成特定于方面的上下文表示,该模型用提取到的上下文词构建辅助句,并对这些特定上下文词赋予较大的权重,以突出其对方面词的情感极性的重要性。

本文的主要贡献如下:

(1)将 SenticNet 用于图的构建,并定义了一个敏感关系集合,利用该集合识别出有潜力的上下文词和增强句子的邻接矩阵表示。

(2)为了获得更好的特定于方面的上下文表示,使用位置感知和依赖感知,对特定上下文词赋予较大的权重。

(3)在 3 个标准数据集上进行了一系列实验,验证了 SS-GCN 模型在方面级情感分析中的有效性和优越性。

## 2 相关工作

### 2.1 方面级情感分类

深度学习技术在方面级情感分类任务中取得了巨大成功,越来越多的研究人员致力于将深度学习技术引入情感分析领域。由于评论的上下文信息蕴含着方面的情感极性,早期的研究人员从上下文信息中深度挖掘特征。Tang 等<sup>[11]</sup>提出了

方面相关的长短时记忆模型,将方面信息融入 LSTM,进而在生成句子表示时捕获方面词与其上下文之间的联系。Wang 等<sup>[12]</sup>提出了一种基于注意力的长短期记忆网络(LSTM),用于方面级情感分类,对于不同的方面,它可以将注意力集中在句子的不同部分。与 Tang 等<sup>[11]</sup>一样, Ma 等<sup>[13]</sup>也认为应该对方面和上下文分别建模,他们采用了两个注意力网络来交互学习上下文和方面中的注意力,并分别生成方面和上下文的表示。Chen 等<sup>[14]</sup>采用多重注意力机制来捕获长距离情感特征。然而,考虑到 LSTM 相关的序列模型的低效性与复杂性,以及基于注意力权重的词级特征组合可能会引入噪声并降低预测精度,因此越来越多的研究人员开始转向探索 CNN 来捕获 n-gram 特征。Li 等<sup>[15]</sup>通过改进 TF-IDF 对类别区分能力不同的词语赋予不同的权重,并将基于该方法构建的词向量作为 CNN 的输入,有效提升了文本的情感分类效果。Xue 等<sup>[16]</sup>使用卷积神经网络来提取上下文特征,并采用门控机制选择性地输出最终的情感特征。然而,CNN 无法像 RNN 一样计算方面词与上下文词的关联度,对于含有多方面词的评论,CNN 可能会失败。为了解决这个问题, Li 等<sup>[17]</sup>使用了基于 CNN 的特定于方面的转换组件,进而生成方面特定的单词表示。

但是普通 CNN 可能会将方面词与不相关的意见词相关联,为了解决这个问题, Li 等<sup>[17]</sup>采用了近邻策略,使得该问题得到了一定的缓解,但方面词的邻居可能并没有为方面词情感极性做出重要贡献,相反,方面的意见词可能距离方面很远,即远距离依赖。为了解决这一问题,本文利用句法依赖树解析出方面词与上下文词之间的依赖关系,进而找出对方面的情感极性做出重要贡献的上下文词,并将其作为辅助句。对于构造出的辅助句,给予较大的权重输入到卷积层。

### 2.2 图神经网络

最近,由于用图(Graph)可以更好地表示文本的结构信息,并且可以更准确地获取词级依赖信息,越来越多的自然语言处理问题开始引入图结构,如文本分类、NER、关系抽取。另外,图神经网络(Graph Convolutional Neural Network, GCN)在 ABSA 任务上也取得了出色的表现,最近的研究集中在利用句子的句法结构,来有效地建立方面词与上下文之间的依赖关系<sup>[1,18-20]</sup>。Zhang 等<sup>[1]</sup>引入句法依赖树来表示句子,并提出了特定于方面的 GCN 模型,它与 LSTM 和注意力机制相结合,能够有效地实现方面级情感分类。Wang 等<sup>[19]</sup>提出了一个统一的面向方面的依赖树结构,并使用关系图神经网络(R-GAT)来编码这个新颖的依赖树结构。Li 等<sup>[20]</sup>考虑到依存句法分析结果的不准确性以及评论表达的复杂性,提出了一种兼顾句法信息和语义相关性的模型。

现有方法的一个重要限制是,它们对句法依存树解析到的词级依赖关系一视同仁,但实际情况是方面词的情感应专注于方面意见词。评论中与方面有依赖关系的单词,对方面词的情感极性判断所做的贡献是不一样的,例如在情感极性分类中,与方面词有依赖关系的形容词、动词等应发挥更重要的作用。我们可以称它们为“裁判词”。本文定义了一个敏感依赖关系集合,利用句法依赖树得到的方面词与上下文词之间的依赖关系,通过结合敏感依赖关系集合来增强句子的

邻接矩阵表示,进而强化“裁判词”对方面情感极性的影响。

### 2.3 结合外部知识

由于外部知识信息通常能够提供很好的可控性和指导意义,因此将外部知识作为情感分析任务中的情感特征表示,能够有效地提升模型性能<sup>[3]</sup>。有研究人员开始将外部情感和常识知识库引入 ABSA 任务中。Zhou 等<sup>[21]</sup>引入常识知识图谱来增强句子表示。Xing 等<sup>[22]</sup>将现有的多种情感词典适应到目标领域,发现 SenticNet 作为一种普适领域情感词典,与其他情感词典相比,表现最为出色。Liang 等<sup>[3]</sup>提出了一种基于 SenticNet 的图卷积神经网络,进而弥补了现有的研究大多侧重于从句子的句法依赖树中学习信息,缺乏对方面的上下文的情感知识的利用。Zhong 等<sup>[23]</sup>为了有效地将外部知识和句法信息以及上下文信息相结合,提出了一种知识图谱增强网络。

SenticNet 作为情感分析的公开资源,涉及到众多领域,它提供了一组与 100 000 个自然语言概念相关的语义和极性。概念的极性是 -1 到 +1 之间的浮点数,其中强烈的消极概念

的极性接近 -1,而强烈的积极概念的极性接近 +1。Li 等<sup>[24]</sup>将作为先验知识的 SenticNet 加入到词嵌入中,证明了 SenticNet 能够有效地增强情感表示。Liang 等<sup>[3]</sup>提出了一种基于 SenticNet 的图卷积神经网络,也有效地提升了模型在方面级情感分类任务的表现。与文献<sup>[3]</sup>类似,本文利用 SenticNet 作为情感常识知识库来修饰图,配合上文提到的敏感依赖关系集合来增强情感表示。

### 3 SS-GCN 模型

本文提出的 SS-GCN 模型的架构如图 1 所示。模型整体分为两部分,左边部分从预训练词嵌入表示中提取句法特征,并利用 SenticNet 和“敏感关系集合”增强句子中方面词和意见词之间的相关性。右半部分借助“敏感关系集合”构建了辅助句,并在位置感知时对辅助句中的上下文词赋予较大的权重,以突出其对方面词的情感极性的重要性。最后将左右两部分模块学习到的特征进行融合。

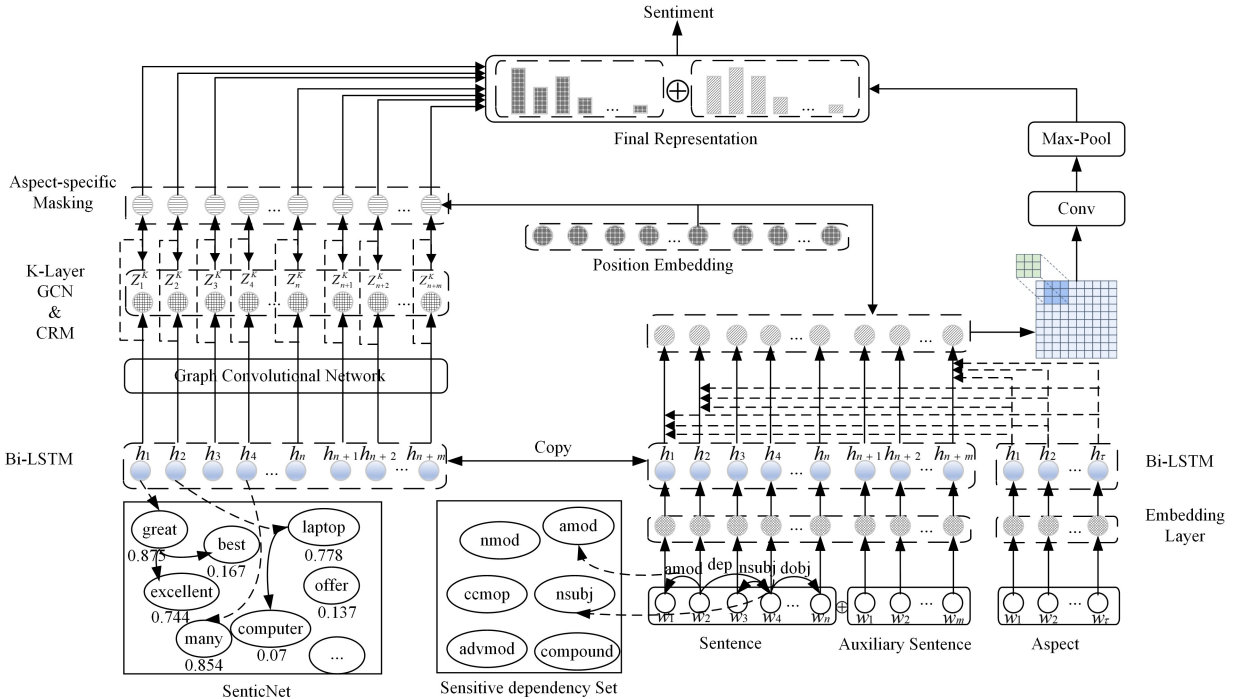


图 1 SS-GCN 模型的架构

Fig. 1 Architecture of SS-GCN model

### 3.1 问题定义

给定一个由  $n$  个单词组成的句子  $S = (w_1, \dots, w_{t+1}, \dots, w_{t+m}, \dots, w_n)$ , 其中  $\{w_{t+1}, \dots, w_{t+m}\}$  是  $S$  的子序列, 它表示句子中的方面词, ABSA 任务的目的是预测给定方面词的情感极性  $y \in \{P, N, O\}$ , 其中  $P, N$  和  $O$  分别表示“积极”“消极”和“中性”情绪。

### 3.2 词嵌入和 Bi-LSTM 层

本文使用轻量级预训练 GloVe<sup>[25]</sup> 词嵌入矩阵  $M \in R^{d_e \times |V|}$  嵌入句子, 其中  $d_e$  是词嵌入的维数,  $V$  是词汇量。通过查找  $M$  将句子中每个单词嵌入到  $d_e$  维的向量中, 并得到句子的嵌入矩阵  $E = (ew_1, \dots, ew_{t+1}, \dots, ew_{t+m}, \dots, ew_n)$ , 其中  $ew_i \in R^{d_e}$  是上下文词  $w_i$  的词嵌入, 而  $ew_{t+i} \in R^{d_e}$  是方面词的词嵌入。

将词嵌入输入到 Bi-LSTM 层来积累输入句子中每个单词在两个方向的上下文信息, 每个单词的上下文表示如式(1)、式(2)所示:

$$\vec{h}_i = \overrightarrow{\text{LSTM}}(ew_i, \theta_{\text{LSTM}}), i \in [1, n] \quad (1)$$

$$\overleftarrow{h}_i = \overleftarrow{\text{LSTM}}(ew_i, \theta_{\text{LSTM}}), i \in [n, 1] \quad (2)$$

其中,  $\theta_{\text{LSTM}}$  表示 LSTM 模型的参数, 将正向和反向隐藏状态连接起来, 即  $ew_i$  的隐藏状态表示为  $h_i = [\vec{h}_i, \overleftarrow{h}_i], i \in [1, n]$ , 可以得到上下文化的词表示  $h_i^0 = [h_1, h_2, \dots, h_n] \in R^{n \times 2d_e}$ 。

### 3.3 辅助句的构造

句子的上下文信息包含了情感信息, 但方面级情感分类更关注于意词, 考虑到现有研究中使用的 GCN 忽略了依赖类型中携带的信息, 即现有方法平等地对待所有词级关系, 从而可能导致模型无法区分重要依赖关系。如图 2 所示,

方面词‘service’与‘the’和‘dreadful’有依赖关系,但‘dreadful’对‘service’应是最重要的,因为它们之间的依赖类型为‘nsubj’,即‘service’是‘dreadful’的名词性主语。因此,为了更好地识别相应意见词并突出它们,本文结合句法信息和语义上下文来构建辅助句,具体来说,使用 Stanza<sup>[10]</sup>来获得句子的句法依存树,同时定义了一个敏感依赖关系集合,  $SDR = \{‘nsubj’, ‘amod’, ‘advmod’, ‘ccomp’, ‘compound’, ‘nmod’\}$ ,令  $R_{w_i, w_z}$  为上下文词  $w_i$  和方面词  $w_z$  之间的依赖关系,若  $R_{w_i, w_z} \in SDR$ ,则说明上下文词  $w_i$  对方面词的情感分类比其他上下文词更重要,即“裁判词”,本文将这类词抽取出来构建成一个伪句子,拼接在原始句子的后面,以便在后续的任务中应用。如图 2 所示,示例句子“great food but the service was dreadful.”中方面词为“food”,则抽取到的裁判词为“great”。因此,句子  $S$  的表示被更新为  $\tilde{S} = (\omega_1, \dots, \omega_{\tau+1}, \dots, \omega_{\tau+m}, \dots, \omega_n, \omega_{n+1}, \dots, \omega_{n+a})$ ,其中子序列  $\{\omega_{n+1}, \dots, \omega_{n+a}\}$  表示构建的辅助句,请注意,若未识别到“裁判词”,则辅助句为空,即保持原句子不变。




图 2 ABSA 任务的一个例句

Fig. 2 Example sentence of ABSA task

### 3.4 优化的基于 GCN 的特征提取

#### 3.4.1 优化的图构建

本文使用 Stanza 来获得句子的句法依存树,依据句法依存树,可以构建邻接矩阵  $A \in R^{N \times N}$ ,其中  $N = n + a$  为句子的长度。邻接矩阵  $A$  的定义如式(3)所示:

$$A_{i,j} = \begin{cases} score, & \text{if } w_i, w_j \text{ contains dependency} \\ 1, & i=j \\ 0, & \text{otherwise} \end{cases} \quad (3)$$

其中,  $score$  取决于多种因素,例如单词  $w_i, w_j$  的情感和它们之间的依赖关系以及是否为方面词,下文将详细介绍  $score$  的推导。另外,为了保留自身节点的信息,本文将邻接矩阵的主对角线设为 1。请注意,本文构建的是无向图,即  $A_{i,j} = A_{j,i}$ ,因为我们认为有向图会丢失部分依赖信息。

#### (1)情感增强

受到 Liang 等<sup>[8]</sup>的启发,本文在构建邻接矩阵时也使用了 SenticNet 的情感知识来表示单词之间的情感信息,如式(4)所示:

$$S_{i,j} = \begin{cases} SenticNet(w_i) + 1, & \text{if } |SenticNet(w_i)| > |SenticNet(w_j)| \\ SenticNet(w_j) + 1, & \text{if } |SenticNet(w_i)| \leq |SenticNet(w_j)| \end{cases} \quad (4)$$

其中,  $SenticNet(w_i) \in [-1, 1]$  表示单词  $w_i$  在 SenticNet 词典中的情感分数,强烈的消极概念的极性接近  $-1$ ,而强烈的积极概念的极性接近  $+1$ ,  $SenticNet(w_i) = 0$  则表示词  $w_i$  的

情感极性为中性或者词  $w_i$  在 SenticNet 词典中不存在。这里将  $Score_{i,j}$  取值为词  $w_i$  和  $w_j$  在 SenticNet 词典中的分数较大者,因为两个词之间的依赖关系更依赖于情感较强烈的一方。

#### (2)句法增强

通过句法依存树可以获取和方面词有依赖关系的上下文词,但 ABSA 任务应更专注于方面对应的意见词,为了强化相关意见词对方面的影响,本文在构建邻接矩阵时考虑了单词之间的依赖类型,并对 3.3 节利用 SDR 构建的辅助句中的“裁判词”进行强调。具体来说,对“裁判词”和方面词之间的依赖关系进行增强,如式(5)所示:

$$X_{i,j} = \begin{cases} 1, & \text{if } w_j \text{ is a aspect word and } R_{w_i, w_j} \in SDR \\ 0, & \text{otherwise} \end{cases} \quad (5)$$

另外,方面词是 ABSA 任务不可或缺的词,因此其进一步增强了方面词与上下文词之间的依赖关系,如式(6)所示:

$$Z_{i,j} = \begin{cases} 1, & \text{if } w_i \text{ or } w_j \text{ is a aspect word} \\ 0, & \text{otherwise} \end{cases} \quad (6)$$

经过上述计算,可以得到改进后的句子的邻接矩阵,其计算式如式(7)所示:

$$A_{i,j} = S_{i,j} + X_{i,j} + Z_{i,j} \quad (7)$$

#### 3.4.2 优化的图卷积神经网络

得到改进的图的邻接矩阵之后,将图输入 GCN 层,它以多层方式在图的节点上进行卷积计算,这里使用两层 GCN 模块来提取句子的句法特征。节点根据其邻域的隐藏表示来更新自己,并在通过非线性转换之前进行归一化。具体来说,在  $L$  层 GCN 中,用  $h_i^l (l \in \{1, \dots, L\})$  表示节点  $i$  在第  $l$  层的输出,  $h_i^0$  则是初始隐藏状态向量,其他情况下的  $h_i^l$  被定义为:

$$h_i^l = \sigma \left( \frac{A_i h_i^{l-1} W^l}{D+1} + B^l \right) \quad (8)$$

$$D_{i,j} = \begin{cases} 1, & A_{i,j} \neq 0 \\ 0, & A_{i,j} = 0 \end{cases} \quad (9)$$

其中,  $\sigma$  是非线性激活函数,  $W^l$  是线性变换权重,  $B^l$  是线性变换偏置项,  $D = \sum_{j=1}^{n+a} D_{i,j}$  是  $A_i$  的度数,  $h_i^{l-1}$  则是从前一层的 GCN 转换过来的隐藏表示。与文献[1]类似,本文没有将前一层 GCN 的输出直接输入到下一层 GCN 中,而是先使用了位置感知转换来揭露上下文词相对于给定方面词的重要性。具体来说,我们根据上下文词与方面词之间的距离为句子中每个词定义了位置权重,尤其是对“裁判词”赋予较大的位置权重,如式(10)所示:

$$g_i = \begin{cases} 1 - \frac{\tau+1-i}{n}, & 1 \leq i \leq \tau+1 \\ 0, & \tau+1 \leq i \leq \tau+m \\ 1 - \frac{i-\tau-m}{n}, & \tau+m < i \leq n \\ 1 - \frac{1}{n}, & 1 \leq a \text{ and } n+1 \leq i \leq n+a \end{cases} \quad (10)$$

因此,式(8)中的图卷积运算被重新表述为:

$$h_i^l = \sigma \left( \frac{A_i g_i h_i^{l-1} W^l}{D+1} + B^l \right) \quad (11)$$

经过图卷积和位置感知转换后,来自上一层(如 Bi-LSTM)的上下文信息将丢失。Li 等<sup>[17]</sup>证明了上下文保留机制能有效改善上下文丢失的问题,为了更加充分地利用上下文信息,我们在将  $h_i^l$  传递给下一层 GCN 前,把上下文化的  $h_i^0$

直接转发给  $h_i^l$ , 即输入到第  $l+1$  层 GCN 的  $h_i^l$  如式(12)所示:

$$\tilde{h}_i^l = h_i^l + h_i^0 \quad (12)$$

由式(12)可以看出,上下文化的单词表示被包含在每一层 GCN 的输入中,如图3所示。因此,式(8)中的图卷积运算最终被表述为:

$$h_i^l = \sigma \left( \frac{\mathbf{A}_i \mathbf{g}_i (h_i^{l-1} + h_i^0) \mathbf{W}^l}{\mathbf{D} + 1} + B^l \right), l \in \{1, \dots, L\} \quad (13)$$




图3 上下文保留机制的结构

Fig. 3 Structure of context retention mechanism

### 3.4.3 特定方面的情感表示

上述 GCN 已经感知到方面词的隐藏状态中的重要信息,为了突出方面词的重要性和消除其他状态带来的噪声,用零屏蔽输出向量的非方面词,而方面词的表示保持不变,如式(14)所示:

$$\bar{h}_i^l = 0, 1 \leq t < \tau + 1, \tau + m < t \leq n + a \quad (14)$$

因此,得到了特定方面掩码的表示:

$$\bar{h}_{\text{mask}}^l = \{0, \dots, h_{\tau+1}^l, \dots, h_{\tau+m}^l, \dots, 0\} \quad (15)$$

与文献[26]类似,使用点积注意力机制从上下文信息中抽取特定方面的特征,并为每个上下文词设置相应的注意力权重,注意力权重的计算式如下:

$$\beta_i = \sum_{i=\tau+1}^{\tau+m} h_i^0 \bar{h}_i^l \quad (16)$$

$$\alpha_i = \frac{\exp(\beta_i)}{\sum_{i=1}^{n+a} \exp(\beta_i)} \quad (17)$$

点积可以计算方面词和上下文词之间的语义相关性,进而计算出注意力权重矩阵,因此输入向量的最终计算方法如式(18)所示:

$$\mathbf{R}_{\text{gen}} = \sum_{i=1}^{n+a} \alpha_i h_i^0 \quad (18)$$

### 3.5 优化的基于 CNN 的特征提取

基于 CNN 的特征抽取可以让模型有能力处理不合法的句子,在将句子的嵌入表示输入 CNN 之前,首先计算上下文词与方面词之间的语义相关性,具体来说,我们将上下文词和方面词动态关联,以生成特定方面的表示<sup>[17]</sup>,如式(19)所示:

$$\mu_i = \sum_{j=1}^m h_{\tau+j} * \mathcal{F}(h_i^0, h_{\tau+j}) \quad (19)$$

其中,  $h_i^0$  是与基于 GCN 的特征抽取模块共享的 Bi-LSTM 隐藏状态,  $h_{\tau+j}$  则是另一个 Bi-LSTM 输出的方面词表示:  $h_{\tau+j} = \overrightarrow{h_{\tau+j}} \leftarrow h_{\tau+j}$ ,  $j \in [1, m]$ 。函数  $\mathcal{F}$  计算第  $j$  个方面词表示  $h_{\tau+j}$  与第  $i$  个上下文词表示  $h_i^0$  之间的相关性,其计算式如式(20)所示:

$$\mathcal{F}(h_i^0, h_{\tau+j}) = \frac{\exp(h_i^{0\top} h_{\tau+j})}{\sum_{k=1}^m \exp(h_i^{0\top} h_{\tau+k})} \quad (20)$$

随后将  $h_i^0$  与  $\mu_i$  拼接后送入全连接层,得到第  $i$  个词  $w_i$  的特定于方面的表示,如式(21)所示:

$$h_i^\tau = \sigma(\mathbf{W}^\tau [h_i^0; \mu_i] + B^\tau) \quad (21)$$

其中,  $\sigma$  是非线性激活函数,“;”表示向量连接,  $\mathbf{W}^\tau$  和  $B^\tau$  是可训练的参数。

为了突出 3.3 节所抽取的“裁判词”和方面词邻近的上下文词的重要性,我们采取了和 3.4.1 节一样的位置权重感知策略。具体来说,我们利用式(10)计算第  $i$  个词  $w_i$  和方面词  $w_\tau$  之间的位置权重  $g_i$ 。此外,若上下文词  $w_i$  和方面词  $w_\tau$  之间的依赖类型在敏感依赖关系集合  $SDR$  中,则为上下文词  $w_i$  赋予较大的权重,以强化其重要性。转换后的特征表示如式(22)所示:

$$\hat{h}_i^\tau = h_i^\tau * g_i, i \in [1, n] \quad (22)$$

将  $\hat{h}_i^\tau$  输入卷积层以进一步地抽取特征:

$$c_i = \sigma(\mathbf{W}_c^T \hat{h}_{i+s-1} + B_c) \quad (23)$$

其中,  $\hat{h}_{i+s-1}$  是向量  $\hat{h}_i^\tau, \dots, \hat{h}_{i+s-1}^\tau$  的连接,  $s$  是卷积核(内核)的大小,  $\mathbf{W}_c$  和  $B_c$  是可训练的参数。为了保留主要特征并减少计算量,应用最大池化<sup>[27]</sup>来获得句子的最终表示,如式(24)所示:

$$\mathbf{R}_{\text{cnn}} = [\max(c_1), \dots, \max(c_{np})] \quad (24)$$

其中,  $np$  是内核的数量。

### 3.6 情感分类

上述  $\mathbf{R}_{\text{gen}}$  和  $\mathbf{R}_{\text{cnn}}$  是分别从基于 GCN 和 CNN 的特征抽取模块得到的,为了将它们共同作用于极性分类,本文将其进行连接,即最终的特征表示  $\mathbf{R} = [\mathbf{R}_{\text{gen}}; \mathbf{R}_{\text{cnn}}]$ 。随后将其输入到全连接层和 softmax 层以产生概率分布  $y \in \mathcal{R}^{d_p}$ 。

$$y = \text{softmax}(\mathbf{W}^o \mathbf{R} + B^o) \quad (25)$$

其中,  $d_p$  是情感极性的数量,  $\mathbf{W}^o$  和  $B^o$  是可训练的参数。

## 4 实验

### 4.1 数据集

本文在 3 个公开标准方面级数据集上评估了本文模型,即 SemEval 2014 Task 4<sup>[28]</sup> 中的 Restaurant14 和 Laptop14,以及由 Dong 等<sup>[29]</sup> 收集的 Twitter 数据集。与 Tang 等<sup>[30]</sup> 的方式一样,本文删除了一些具有冲突情感极性的实例,并列出了这些数据集的最终统计数据(见表 1)。

表 1 数据集的统计信息

Table 1 Statistics of datasets

Datasets	# Division	# Position	# Negative	# Neutral
Rest14	Train	2159	800	632
	Test	730	195	196
Laptop14	Train	980	858	454
	Test	340	128	171
Twitter	Train	1567	1563	3127
	Test	174	174	346

### 4.2 实验设置

本文使用 300 维预训练的 GloVe 向量初始化词嵌入,所有的参数均采用均匀初始化。模型中的 GCN 层数设置为 2 层,这是我们经过实验得出的最优层数。使用 Adam 作为

优化器,学习率设置为 0.001。为了防止过拟合,在训练模型中对输入层和隐藏层应用 Dropout,Dropout rate 设置为 0.5,L2 正则系数为 0.000 01。

#### 4.3 基线模型

为了评估 SS-GCN 在 ABSA 任务中的性能,将其与以下方法进行了比较,并按照模型所使用的主要特征将它们分为 3 类,即基于上下文的模型、基于句法的模型和引入外部知识的混合模型。其中混合模型不仅引入了外部知识,还使用了上下文信息或句法依赖信息,如表 2 所列。

表 2 SS-GCN 与基线模型的对比

Table 2 Comparison of SS-GCN with baseline models

Model	Contextual	Syntactical	Hybrid
ATAE-LSTM	•		
RAM	•		
TNet-AS	•		
MGAN	•		
R-GAT		•	
DGEDT		•	
ASGCN-DT		•	
ASGCN-DG		•	
GL-GCN		•	
CDT		•	
SK-GCN			•
Sentic-LSTM			•
Sentic-GCN			•
MTKEN			•
SS-GCN			•

##### 4.3.1 基于上下文的模型

(1)ATAE-LSTM<sup>[12]</sup>:该方法将基于注意力的长短期记忆网络用于方面级别的情感分类。

(2)RAM<sup>[14]</sup>:该方法采用多重注意力机制和记忆网络来捕获长距离情感特征。

(3)TNet-AS<sup>[17]</sup>:使用了基于 CNN 的特定于方面的转换组件,进而生成方面特定的单词表示。

(4)MGAN<sup>[31]</sup>:该方法结合粗粒度和细粒度注意力机制来学习方面词与上下文词之间的关联关系。

##### 4.3.2 基于句法的模型

(1)R-GAT<sup>[19]</sup>:该方法使用一个统一的面向方面的依赖树结构,并使用关系图注意网络来编码这个新颖的依赖树结构。

(2)DGEDT<sup>[32]</sup>:该方法将 Transformer 引入到模型中,以减少不正确的依赖树所导致的错误。

(3)ASGCN-DT<sup>[1]</sup>:该方法使用句法依赖树为每个句子构建一个有向图,并使用 GCN 来解决情感分类中远程多词依赖问题。

(4)ASGCN-DG<sup>[1]</sup>:与 ASGCN-DT 类似,除了构建的图是无向的。

(5)GL-GCN<sup>[33]</sup>:将全局结构信息和局部结构信息同时引入到方面级情感分类任务。

(6)CDT<sup>[26]</sup>:将 GCN 与 Bi-LSTM 模型相结合,以获取句子的结构和上下文信息,使用 GCN 对依赖树执行卷积,以优化 Bi-LSTM 嵌入。

##### 4.3.3 引入外部知识的混合模型

(1)SK-GCN<sup>[2]</sup>:该方法使用 GCN 同时集成了句法依赖树和常识知识图。

(2)Sentic-LSTM<sup>[34]</sup>:该方法扩展了 LSTM,以在深层神经网络序列模型中利用常识知识。

(3)Sentic-GCN<sup>[3]</sup>:该方法通过整合来自 SenticNet 的情感知识来构建图神经网络,以增强句子的依赖图。

(4)MTKEN<sup>[35]</sup>:该方法利用子句提取结构知识,并将其与情感知识融合,以增强模型的性能。

#### 4.4 实验结果

如表 3 所列,本文报告了基线模型以及提出的 SS-GCN 模型的性能。根据表 3 可以得到以下结果:SS-GCN 模型在 3 个数据集上优于其他前沿方法,尤其是在 Laptop14 和 Restaurant14 数据集上始终优于其他所有模型。具体来说,SS-GCN 比仅将外部知识应用到 GCN 的 Sentic-GCN 和 SK-GCN 的表现更好,表明了增强句法信息的优越性。同时,与未使用外部知识的模型相比,SS-GCN 在准确度和 Macro-F1 指标上都至少高出 1%~2%,这表明在方面级情感分类任务中引入外部知识的重要性和有效性。此外,在仅考虑上下文信息的基线模型中,TNet-AS 采用 CNN 层将方面信息融入上下文单词中,在同类型模型中取得了较有竞争力的表现,但 SS-GCN 模型除了将方面信息融入到上下文信息外,还做了情感增强和句法增强,因此与仅考虑上下文信息的模型相比,SS-GCN 性能提升了很多。尽管 SS-GCN 模型在 Twitter 数据集上的准确率表现欠佳,但它在 Macro-F1 指标方面优于所有基线模型。上述结果证明了 SS-GCN 的有效性和优越性。

表 3 模型在 3 个数据集上的评价指标对比

Table 3 Comparison of model evaluation metrics on three datasets

Model	Laptop14		Restaurant14		Twitter	
	Accuracy	Macro-F1	Accuracy	Macro-F1	Accuracy	Macro-F1
ATAE-LSTM	68.88	63.93	78.60	67.02	68.64	66.60
RAM	74.49	71.35	80.23	70.80	69.36	67.30
TNet-AS	76.54	71.75	80.69	71.27	74.90	73.60
MGAN	76.21	71.42	81.49	71.48	74.62	73.53
R-GAT	77.42	73.76	83.30	76.08	<b>75.57</b>	73.82
DGEDT	76.80	72.30	83.90	75.10	74.80	73.40
ASGCN-DT	74.14	69.24	80.86	72.19	71.53	69.68
ASGCN-DG	75.55	71.05	80.77	72.02	72.15	70.40
GL-GCN	76.91	72.76	82.11	73.46	73.26	71.26
CDT	77.19	72.99	82.30	74.02	74.66	73.66
SK-GCN	73.20	69.18	80.36	70.43	71.97	70.22
Sentic-LSTM	70.88	67.19	79.43	70.32	70.66	67.87
Sentic-GCN	77.90	74.71	84.03	75.38	72.83	71.28
MTKEN	73.43	69.12	79.47	68.08	69.80	67.54
SS-GCN	<b>78.68</b>	<b>75.02</b>	<b>84.29</b>	<b>77.61</b>	75.00	<b>74.05</b>

## 4.5 消融实验

### 4.5.1 SenticNet 的影响

为了更具体地探究 SenticNet 对模型性能是否有提升,本文在 3 个数据集上分别对比了将 SenticNet 应用于随机抽取的不同比例的样本时的结果,如图 4 所示。可以发现,在 3 个数据集上,使用 SenticNet 的模型的性能在 Accuracy 和 Macro-F1 上明显比不使用 SenticNet 的模型好,这表明了使用 SenticNet 增强情感对方面级情感分类的有效性。当使用 SenticNet 的实例所占比例低于 50% 时,模型的 Accuracy 和 Macro-F1 分数有较小的波动。并且,当应用 SenticNet 的实例所占比例越大时,模型的性能越好。尤其是,在全部实例上使用 SenticNet 时,模型取得了最优的性能,这表明充分地利用 SenticNet 的情感知识可以更好地表达实例中单词间的依赖关系,进而能更精确地确定方面词的情感极性。




图 4 SenticNet 的影响

Fig. 4 Impact of the proportion of SenticNet

### 4.5.2 句法增强的影响

在 ABSA 任务中,“裁判词”对方面词的情感极性是十分重要的,而不相关的内容可能会带来更多噪声。基于此,在为句子构建邻接矩阵时,对方面词和“裁判词”之间的依赖关系值进行显式加权。为了验证句法增强方法的有效性,本文在 3 个数据集上分别对比了在不同比例的实例上使用句法增强后模型的性能,结果如图 5 所示。可以发现,在任何数据集上,句法增强的引入有效地提升了 Acc 和 F1,这验证了使用句法增强的有效性。值得注意的是,使用句法增强的实例所占比例越高,模型的 Accuracy 和 Macro-F1 越高,虽然 Macro-F1 分数出现了波动,但整体仍呈上升趋势。尤其是在全部数据集上使用句法增强时,模型取得了最佳性能。




图 5 句法增强的影响

Fig. 5 Impact of the proportion of syntactic enhancement

### 4.5.3 GCN 层数的影响

为了更好地证明 GCN 层数对模型性能的影响,本文将 GCN 层数从 1 增加到 5,步长为 1。图 6 给出了 SS-GCN 模型在 3 个数据集上使用不同 GCN 层数得出的结果。可以观察到,当 GCN 层数  $L$  在 3 个数据集上增长时,模型性能开始

随着  $L$  的增加而提升,然后开始下降。具体来说,当 GCN 层数设置为 2 时,模型取得了最佳性能;当  $L$  大于 2 时,模型性能开始递减。因此,本文建议将模型的 GCN 层数设置为 2,以取得较好的性能。 $L$  层的 GCN 可以在  $L$  步内捕获邻居的信息,可以分析得到,当  $L=1$  时,不足以捕获足够的邻居信息,因此模型性能表现较差;相反,当  $L$  过大时,模型会变得更加复杂,参数急剧增加可能会给模型引入更多噪声,因为在一定范围内,方面词附近的词对其情感极性总是更重要。




图 6 GCN 层数的影响

Fig. 6 Impact of the number of GCN layers

### 4.5.4 GCN 中加入上下文保留的影响

经过 GCN 的变换后,来自上一层(如 Bi-LSTM)的上下文信息将丢失,Lai 等<sup>[36]</sup>发现抽取和利用上下文信息是十分重要的,并且 4.5.3 节已经证明 GCN 的层数设置为 2 时,模型取得了最佳表现。基于此,本文将来自 Bi-LSTM 的上下文信息在转换前直接馈送到第二层 GCN,即第二层 GCN 的输入将包含来自 Bi-LSTM 的原始上下文信息以及第一层 GCN 的输出。为了验证该方法的有效性,本文在 3 个数据集上分别对比了使用上下文保留策略和不使用上下文保留策略时的结果,如图 7 所示。可以观察到,当移除上下文保留时,模型的性能在 3 个数据集上都下降,这表明了将原始上下文信息作为特征持续融入 GCN 的有效性。




图 7 上下文保留机制的影响

Fig. 7 Impact of context retention mechanism

## 4.6 案例分析

为了更好地观察 SS-GCN 模型在实际应用中的表现,本文从 3 个评估数据集选择案例做进一步的分析,并报告了模型在这些案例下的结果,如表 4 所列。

句子 1 中包含了否定,这就很容易导致模型预测错误。句子 2 中包含了两个方面词,且极性相反,这种情况会阻碍基于注意力机制的模型准确地抽取对应的情感信息。句子 3 是疑问句,并且包含两个不同极性的方面词,这种情况要求模型能针对不同的方面提取出对应的有效的信息。句子 4 的方面词和对应的意见词距离很远,模型需要准确地捕捉方面词对应的情感极性,但由于意见词距离方面词较远,且该句子中

没有明确表达情感的词,因此模型需要抽取隐含语义,这给情感极性的预测也带来了困难。

表 4 样本预测结果  
Table 4 Example predictions

Sentences	Tent-AS	ASGCN-DG	Sentic-GCN	SS-GCN
1. Did not enjoy the new [Windows8] <sub>N</sub> and touchscreen functions.	P×	N	N	N
2. The [falafal] <sub>N</sub> was rather over cooked and dried but the [chicken] <sub>P</sub> was fine.	(P×, P)	(N, O×)	(N, P)	(N, P)
3. How can they survive serving mediocre [food] <sub>O</sub> at exorbitant [prices] <sub>N</sub> ?	(N×, N)	(N×, N)	(O, O×)	(O, N)
4. The reason why I choose apple MacBook because of their design and the [aluminum casing] <sub>P</sub> .	P	P	N×	P

通过表 4 可以观察到,仅使用上下文信息的典型模型 Tnet-AS 在大多数案例中都预测失败了,而基于语法的方法则表现较好,这是由于利用语法信息可以更有效地建立方面词与其对应的意见词之间的依赖关系。此外,SS-GCN 在全部案例中都做出了正确的预测,进一步表明了它的有效性和优越性。尤其是句子 3,如表 5 所列,它含有两个不同极性的方面词,且其中一个为中性,这在预测时是很困难的,但是 SS-GCN 模型通过引入 SenticNet 情感知识能够更准确地捕获情感信息,并且通过句法增强将裁判词“mediocre”和“exorbitant”的特征进行进一步增强,结合上下文信息,使得模型能够准确地预测出方面词对应的情感极性。

表 5 单个样本分析  
Table 5 Single case prediction

Aspect	Auxiliary	Sentences	Prediction	TrueLabel
food	mediocre	How can they survive serving mediocre <b>food</b> at exorbitant prices ?	Neural√	Neural
prices	exorbitant	How can they survive serving mediocre food at <b>exorbitant prices</b> ?	Negative√	Negative

**结束语** 本文重新审视了现有模型在 ABSA 任务上的不足,为了更加充分地利用外部情感知识和句法信息,本文提出了情感增强和句法增强的 SS-GCN 模型。具体来说,本文在构建图时融入了 SenticNet 的情感知识。此外,SS-GCN 模型更加充分地考虑了句法信息,将显式修饰方面的单词,即“裁判词”突出,来帮助 GCN 和 CNN 模块更准确地抽取特征。最后将抽取到的特征融合,共同作用于情感极性的分类。大量实验证明了本文提出的 SS-GCN 的有效性和优越性。消融研究显示了其不同模块的功效,从而验证了 SS-GCN 架构的合理性。

在今后的研究中,我们将在更多数据集上验证所提方法的性能,并在现阶段工作的基础上,将模型推广到交叉领域的情感分析中。

## 参考文献

- [1] ZHANG C, LI Q, SONG D. Aspect-based sentiment classification with aspect-specific graph convolutional networks[J]. arXiv:1909.03477, 2019.
- [2] 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.
- [3] LIANG B, SU H, GUI L, et al. Aspect-based sentiment analysis via affective knowledge enhanced graph convolutional networks [J]. Knowledge-Based Systems, 2021, 235:107643.
- [4] CAMBRIA E, SPEER R, HAVASI C, et al. SenticNet: A publicly available semantic resource for opinion mining [C] // AAAI CSK. Arlington, 2010:14-18.
- [5] CAMBRIA E, HAVASI C, HUSSAIN A. Senticnet 2: A semantic and affective resource for opinion mining and sentiment analysis [C] // Twenty-Fifth International FLAIRS Conference. 2012:202-207.
- [6] CAMBRIA E, OLSHER D, RAJAGOPAL D. SenticNet 3: a common and common-sense knowledge base for cognition-driven sentiment analysis [C] // Twenty-eighth AAAI Conference on Artificial Intelligence. 2014:1515-1521.
- [7] CAMBRIA E, PORIA S, BAJPAI R, et al. SenticNet 4: A semantic resource for sentiment analysis based on conceptual primitives [C] // Proceedings of COLING 2016, the 26th International Conference on Computational Linguistics: Technical papers. 2016:2666-2677.
- [8] CAMBRIA E, PORIA S, HAZARIKA D, et al. SenticNet 5: Discovering conceptual primitives for sentiment analysis by means of context embeddings [C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2018:1795-1802.
- [9] CAMBRIA E, LI Y, XING F Z, et al. SenticNet 6: Ensemble application of symbolic and subsymbolic AI for sentiment analysis [C] // Proceedings of the 29th ACM International Conference on Information & Knowledge Management. 2020:105-114.
- [10] QI P, ZHANG Y, ZHANG Y, et al. Stanza: A Python natural language processing toolkit for many human languages [J]. arXiv:2003.07082, 2020.
- [11] TANG D, QIN B, FENG X, et al. Effective LSTMs for target-dependent sentiment classification [J]. arXiv:1512.01100, 2015.
- [12] 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.
- [13] MA D, LI S, ZHANG X, et al. Interactive attention networks for aspect-level sentiment classification [J]. arXiv:1709.00893, 2017.
- [14] CHEN P, SUN Z, BING L, et al. Recurrent attention network on memory for aspect sentiment analysis [C] // Proceedings of the 2017 Conference on Empirical Methods in Natural Language

- Processing, 2017;452-461.
- [15] LI C B, ZHAO L, LI X G, et al. Text Sentiment Classification Model Based on TF-IDF Weighted Convolutional Neural Network[J]. Journal of Chongqing University of Technology(Natural Science), 2021, 35(11):109-115.
- [16] XUE W, LI T. Aspect Based Sentiment Analysis with Gated Convolutional Networks[J/OL]. <https://arxiv.org/abs/1805.07043>.
- [17] LI X, BING L, LAM W, et al. Transformation networks for target-oriented sentiment classification [J]. arXiv: 1805. 01086, 2018.
- [18] HOU X, QI P, WANG G, et al. Graph ensemble learning over multiple dependency trees for aspect-level sentiment classification[J]. arXiv:2103. 11794, 2021.
- [19] WANG K, SHEN W, YANG Y, et al. Relational graph attention network for aspect-based sentiment analysis [J]. arXiv: 2004. 12362, 2020.
- [20] 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.
- [21] 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(3): 106292.
- [22] XING F Z, PALLUCCHINI F, CAMBRIA E. Cognitive-inspired domain adaptation of sentiment lexicons [J]. Information Processing & Management, 2019, 56(3): 554-564.
- [23] ZHONG Q, DING L, LIU J, et al. Knowledge Graph Augmented Network Towards Multiview Representation Learning for Aspect-based Sentiment Analysis [J]. arXiv: 2201. 04831, 2022.
- [24] LI M, LU Q, LONG Y, et al. Inferring affective meanings of words from word embedding [J]. IEEE Transactions on Affective Computing, 2017, 8(4): 443-456.
- [25] PENNINGTON J, SOCHER R, MANNING C D. Glove: Global vectors for word representation [C] // Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). 2014;1532-1543.
- [26] 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.
- [27] CHEN Y. Convolutional neural network for sentence classification [D]. Waterloo: University of Waterloo, 2015.
- [28] MARIA P, DIMITRIS G, JOHNP, et al. SemEval-2014 Task 4: Aspect Based Sentiment Analysis [C] // Proceedings of the 8th International Workshop on Semantic Evaluation (SemEval 2014). 2014;27-35.
- [29] 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.
- [30] TANG J, LU Z, SU J, et al. Progressive self-supervised attention learning for aspect-level sentiment analysis [J]. arXiv: 1906. 01213, 2019.
- [31] 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.
- [32] TANG H, JI D, LI C, et al. Dependency graph enhanced dual-transformer structure for aspect-based sentiment classification [C] // Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. 2020;6578-6588.
- [33] ZHU X, ZHU L, GUO J, et al. GL-GCN: Global and local dependency guided graph convolutional networks for aspect-based sentiment classification [J]. Expert Systems with Applications, 2021, 186: 115712.
- [34] MA Y, PENG H, KHAN T, et al. Sentic LSTM: a hybrid network for targeted aspect-based sentiment analysis [J]. Cognitive Computation, 2018, 10(4): 639-650.
- [35] WU S, XU Y, WU F, et al. Aspect-based sentiment analysis via fusing multiple sources of textual knowledge [J]. Knowledge-Based Systems, 2019, 183: 104868.
- [36] LAI S, XU L, LIU K, et al. Recurrent convolutional neural networks for text classification [C] // Twenty-ninth AAAI Conference on Artificial Intelligence. 2015;2267-2273.



**LI Shuai**, born in 1998, postgraduate. His main research interests include affective computing and aspect-level sentiment analysis.



**XU Bin**, born in 1980, Ph. D, associate professor, is a member of China Computer Federation. His main research interests include artificial intelligence and smart education.