

<http://bhxb.buaa.edu.cn> jbuaa@buaa.edu.cn

DOI: 10.13700/j.bh.1001-5965.2022.0728

多源知识融合的方面级情感分析模型

韩虎*, 郝俊, 张千锟, 赵启涛

(兰州交通大学 电子与信息工程学院, 兰州 730070)

摘要: 方面级情感分析 (ABSA) 是一项细粒度情感分析任务, 其目的是针对评论语句中出现的特定方面给出对应的情感极性。现有的基于深度学习的 ABSA 方法大多侧重于评论语句语义和句法的挖掘, 往往忽略了评论语句可能涉及的概念知识和情感程度信息。针对此问题, 提出一种融合多源知识的神经网络模型, 通过句法依赖揭示句子的结构框架、词共现捕捉单词之间的语义联系、情感网络和概念图谱的嵌入为模型提供情感和背景知识, 共同实现评论语句上下文与评价方面的增强表示, 并通过双交互注意力模式实现评论语句上下文与评价方面的协调优化。通过在 4 个公开数据集上的实验验证, 该模型在 ABSA 任务中, 准确率分别达到了 75.00%、77.90%、81.55%、90.10%, 与基准模型相比均有所提高。研究成果不仅验证了多源知识融合在 ABSA 任务中的有效性, 也为未来的研究提供了新的思路和方法。

关键词: 方面级情感分析; 图卷积网络; 多源融合; 知识图谱; 交互注意力机制

中图分类号: TP391

文献标志码: A

文章编号: 1001-5965(2024)09-2688-08

方面级情感分析 (aspect-based sentiment analysis, ABSA) 指针对句子中不同的方面给出对应的情感标签。区别于给定整个文本情感极性, 方面级情感分析是一项粒度较细的任务^[1-2]。例如, “This tool is simple to use, but it costs too much!” 一句提到了 2 个方面: “use” 和 “cost”, 方面 “use” 情感是积极的, 而 “cost” 是消极的。

近年来, 深度学习在情感分析领域取得了令人瞩目的成功, 其基本思想可以总结为基于语义角度和语法角度的建模。基于语义角度的模型利用卷积神经网络 (convolutional neural network, CNN)、长短期记忆 (long short-term memory, LSTM) 网络等提取方面和上下文的特征, 再利用注意力机制捕捉特定方面的上下文表征^[3-4]。然而, 句子中存在多个方面的情况, 基于语义的模型往往容易混淆方面与对应情感之间的联系。而句法信息蕴含着更深层次的文本信息, 能够反映词与词的依赖关系, 这种依

赖关系是联系方面与情感的有效媒介。

因此, 基于语法角度的模型利用图卷积网络 (graph convolutional network, GCN) 处理句法依赖树这类数据^[5-7]。此外, 语料库层面的词共现信息可以反映语言学中的固定搭配, 加强这类语义特征能够更好地把握全局词汇信息^[8]。上述模型虽能很好地集成语言知识, 但由于评论文本存在自身较短的特点, 容易在实际分类过程中造成歧义。因此, 尝试利用常识和情感等先验知识为模型提供监督信号, 提高模型语义解析能力^[9-11]。

受上述工作的启发, 本文提出一种多源知识融合的方面级情感分析 (multi-source knowledge fusion for aspect-based sentiment analysis, MSKFS) 模型, 从以下 3 个方面增强了模型的分类能力:

1) 提出一种同时融入语言知识、情感知识、概念知识的交互注意力网络 MSKFS, 将上下文语义特征与多源化知识进行融合表示。

收稿日期: 2022-08-17; 录用日期: 2023-01-14; 网络出版时间: 2023-03-23 09:01

网络出版地址: link.cnki.net/urlid/11.2625.V.20230322.0955.001

基金项目: 国家自然科学基金 (62166024)

* 通信作者. E-mail: hanhu_lzjtu@mail.lzjtu.cn

引用格式: 韩虎, 郝俊, 张千锟, 等. 多源知识融合的方面级情感分析模型 [J]. 北京航空航天大学学报, 2024, 50 (9): 2688-2695.

HAN H, HAO J, ZHANG Q K, et al. Multi-source knowledge fusion model for aspect-based sentiment analysis [J]. Journal of Beijing University of Aeronautics and Astronautics, 2024, 50 (9): 2688-2695 (in Chinese).

2) 通过句法依赖、词共现、情感网络和概念图谱的嵌入对评论语句上下文与评价方面增强表示。

3) 使用双交互注意力机制建模方面和上下文, 完成方面与上下文之间的协调优化, 提高情感分类的准确率。

1 相关工作

方面级情感分析是一种细粒度的情感分析任务, 能够识别句子给定方面的情感倾向, 经典模型主要使用神经网络从上下文中提取特定于方面的特征表示。Tang 等^[4]提出目标依赖的长短期记忆(target-dependent long short-term memory, TD-LSTM)网络, 通过简单的拼接完成目标信息的增强。Wang 等^[12]对 TD-LSTM 进行了改进, 引入注意力机制挖掘方面和观点词之间的潜在相关性。Ma 等^[13]考虑到句子上下文与方面词之间互有影响, 借助 LSTM 网络分别编码上下文和方面, 通过

交互注意力机制达成上下文与方面的增强表示。

对于句子中具有不同极性的多个方面的情况, 这类基于语义的模型往往混淆了方面与对应情感之间的联系。句法依存关系通过分析给定的语法体系获取句法结构, 建立依存关系树识别词语之间的依存关系。Zhang 等^[5]利用依存关系树表示句子(见图 1), 提出利用 GCN 挖掘依存关系树中的句法信息。Wang 等^[6]提出了一种面向方面的依赖树结构, 并利用关系图注意力网络对树结构进行编码。此外, 语义的关联也同样重要。Zhang 和 Qian^[8]研究了语言学中词语共现的特点, 设计了层次句法图和词汇图(见图 2), 更好地利用了语料库级别的单词共现信息及不同类型的句法依存关系。图 2 中: S_i 表示依存关系类型, d_i 表示词可在语料库中的共现频率。Pang 等^[14]提出了一种多通道 GCN, 用于有效融合句法和语义信息。Li 等^[15]使用了由 SemGCN 和 SynGCN 模块组成的双重 GCN 模型, 以利用句法结构和语义关联的互补性。




图 1 依存句法树^[5]

Fig. 1 Dependency syntax tree^[5]

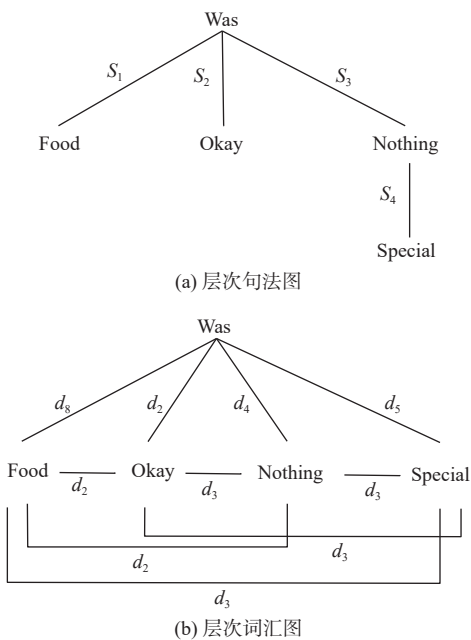


图 2 层次图^[8]

Fig. 2 Hierarchical graph^[8]

同时, 评论语句在内容表达上非常灵活, 仅从句子本身出发会造成偏差, 外部知识在许多自然

语言处理(natural language processing, NLP)任务中的重要作用已经得到了验证。Zhou 等^[10]提出将句法信息和外部知识联合编码, 知识通过单个节点进行采样。Zhong 等^[16]提出了一种知识图增强网络, 并设计分层融合模块实现知识间的互补性。Chen 等^[17]通过引入知识图谱来解决不同语境下的“一词多义”问题。Bian 等^[18]使用多头注意力机制来表示目标和上下文, 并从外部知识库中提取概念知识融合来增强上下文和目标的语义表示。

在情感分析任务中, 外部情感常识知识通常被用作增强情感特征表征的来源。例如, 利用 SenticNet 情感词典获得额外的情感分析资源^[19-20], 作为一种多功能的情感知识库, SenticNet 在增强情感表示任务上表现出色。Ma 等^[9]利用 SenticNet 增强 LSTM 模型, 提取方面和上下文的情感特征。Xing 等^[21]的研究结果表明, SenticNet 的表现优于其他情感词典。Liang 等^[22]利用 SenticNet 作为常识知识库, 对图进行润色, 进而增强图模型提取的情

感表示。

受上述工作的启发,语言知识、外部知识、句子本身不应只是简单的结合,而是将这些知识与上下文进行交叉融合,以获得更丰富的特征表示,指导模型做出正确的情感极性判别。本文提出了一种融合多种知识的方面级情感分析模型 MSKFSA,

有效融合方面的上下文信息和依赖信息,并在实验中验证了模型的效果。

2 模型

本文提出的 MSKFSA 模型如图 3 所示,由如下 4 个部分组成。

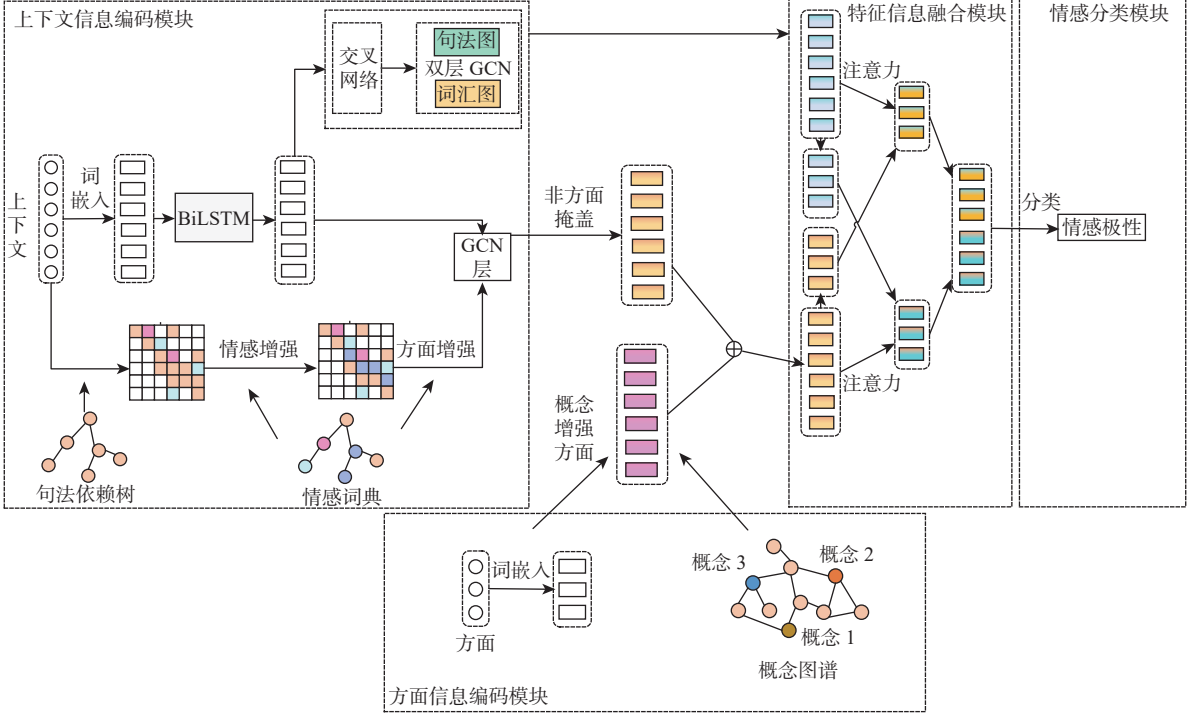


图3 MSKFSA 模型网络整体框架

Fig. 3 Overall framework of MSKFSA model

2.1 上下文信息编码模块

给定单词序列 $s = [w_1, w_2, \dots, w_{a_1}, \dots, w_{a_m}, \dots, w_n]$, 其中, $a = [a_1, \dots, a_m]$ 为包含 m 个词的方面(方面词或方面短语)。使用 GLoVe^[23] 将文本单词嵌入 d_w 维的特征空间中, 得到对应的连续词向量表示 $e = [e_1, e_2, \dots, e_{a_1}, \dots, e_{a_m}, \dots, e_n]$, $e_i \in \mathbf{R}^{d_w}$, 将词向量输入双向长短期记忆(bidirectional long short-term memory, BiLSTM)网络中, 得到上下文信息的句子表示 $h^c = [h_1^c, h_2^c, \dots, h_n^c]$ 。

将得到的向量与词汇图、句法图作为输入, 借助局部层次词汇图和层次句法图^[8] 获得更优表示, 基本思想是使 2 个图与经过 BiLSTM 处理的上下文进一步交互。局部层次句法图和词汇图含有层次结构, 因此, 利用可以聚合关系的双层 GCN 进行操作。

1) 将相同关系的节点聚合到虚拟节点, 在 GCN 中使用相同的归一化隐藏特征总和作为聚合函数来获取虚拟节点嵌入, 每种关系类型 r 对应的表示为 \tilde{h}_i^{lr} , l 为层号, i 为聚合的目标节点。

2) 聚合所有虚拟节点及其关系, 使用平均聚合函数, 针对不同关系类型(虚拟节点)更新目标节点 i 的表示形式:

$$h_i^l = \text{ReLU} \left(\mathbf{W}^l \cdot \left(\oplus_r \tilde{h}_i^{lr} \right) \right) \quad (1)$$

式中: “ \oplus_r ” 表示不同关系类型对应表示的连接; \mathbf{W}^l 为第 l 层中的权重矩阵; h_i^l 为聚合操作后的输出。

2.2 方面信息编码模块

2.2.1 情感增强部分

在句法依赖树上获得邻接矩阵 $\mathbf{D} \in \mathbf{R}^{n \times n}$ 。其中, 邻接矩阵 \mathbf{D} 的构建规则为: 若节点 i 、 j 间存在依存关系, 则 $D_{ij} = 1$, 否则 $D_{ij} = 0$ 。另外, 本文在构建邻接矩阵时, 均考虑单词自身的依存关系, 即 $D_{ii} = D_{jj} = 1$ 。

在此基础上, 为充分利用上下文词与方面词之间的情感信息, 借助 SenticNet 情感词典, 其中, $\text{SenticNet}(w_i) \in [-1, 1]$ 表示词 w_i 在 SenticNet 中的情感分数。当 $\text{SenticNet}(w_i) = 0$, 表示词 w_i 是中性词或在 SenticNet 中不存在。在句子的依存树中提取相邻节点的情感依存关系强度, 表示为 S_{ij} :

$$S_{ij} = \text{SenticNet}(\mathbf{w}_i) + \text{SenticNet}(\mathbf{w}_j) \quad (2)$$

此外,考虑到 \mathbf{w}_i 、 \mathbf{w}_j 是否为方面词的情况,构建方面增强矩阵 \mathbf{Z} ,当其中含有方面词时, $Z_{ij} = 1$,否则 $Z_{ij} = 0$,得到情感增强后的矩阵 \mathbf{A} :

$$\mathbf{A}_{ij} = D_{ij}(S_{ij} + Z_{ij} + 1) \quad (3)$$

将处理后的情感邻接矩阵 \mathbf{A} 作为输入,根据其邻域的隐藏表示来更新第 l 个GCN层中的每个节点:

$$\mathbf{h}_i^l = \text{ReLU}(\tilde{\mathbf{A}}_i \mathbf{g}_i^{l-1} \mathbf{W}^l + \mathbf{b}^l) \quad (4)$$

$$\mathbf{g}_i^{l-1} = F(\mathbf{h}_i^{l-1}) \quad (5)$$

式中: \mathbf{g}_i^{l-1} 为节点 i 在GCN中第 l 层的输入隐藏状态; $\tilde{\mathbf{A}}$ 为标准化对称情感邻接矩阵, $\tilde{\mathbf{A}}_i = \mathbf{A}_i / (\mathbf{E}_i + \mathbf{O})$, \mathbf{O} 为元素全为1的矩阵, $\mathbf{E}_i = \left[\sum_{j=1}^n A_{ij} \right]$; \mathbf{W}^l 为线性变换权重矩阵; \mathbf{b}^l 为偏置项; $F(\cdot)$ 为位置感知转换函数,能够加强靠近该方面的上下文的重要性,减少过程中产生的噪声^[5]。

l 层GCN的输出结果为: $\mathbf{H}^l = [\mathbf{h}_1^l, \mathbf{h}_2^l, \dots, \mathbf{h}_{a_1}^l, \dots, \mathbf{h}_{a_m}^l, \dots, \mathbf{h}_n^l]$ 。

为突出方面词的重要特征,利用特定于方面的掩蔽,来掩蔽由最终GCN层学习的输出向量的非方面词,并保持方面词表示不变:

$$\mathbf{h}_t^l = \mathbf{0} \quad 1 \leq t < a_1, a_m < t \leq n \quad (6)$$

式中: \mathbf{h}_t^l 为GCN层最终输出学习到的第 t 个单词的表示; a_1 为方面词的开始索引; a_m 为方面词的结束索引。

因此,得到情感方面表示:

$$\mathbf{S} = [\mathbf{0}, \dots, \mathbf{h}_{a_1}, \dots, \mathbf{h}_{a_m}, \dots, \mathbf{0}] \quad (7)$$

2.2.2 概念增强部分

使用Concept Graph知识图谱^[24]对方面进行概念化,获取方面相关概念集合 $\mathbf{C} = \{\mathbf{c}_1, \mathbf{c}_2, \dots, \mathbf{c}_m\}$, m 为所取概念的个数, \mathbf{c}_i 为概念集中的第 i 个概念向量。另外,对概念进行自注意力计算,筛选出恰当的概念,注意力计算公式如下:

$$\delta_i = \text{softmax}(\mathbf{v}^T \tanh(\mathbf{W}\mathbf{c}_i) + \mathbf{b}) \quad (8)$$

式中: δ_i 为概念集中的第 i 个概念向量的注意力权重; $\mathbf{W} \in \mathbf{R}^{d_c \times d}$ 为权重矩阵, d 为维度, d_c 为超参数; $\mathbf{v} \in \mathbf{R}^{d_c}$ 为权重向量; \mathbf{b} 为偏置。注意力机制根据重要程度给予概念权重。

对每个概念向量进行加权计算,获取最终的概念表示:

$$\mathbf{p} = \sum_{i=1}^m \delta_i \mathbf{c}_i \quad (9)$$

式中: m 为概念个数。

组合方面向量 \mathbf{a} 与其对应的概念向量 \mathbf{p} ,获取概念增强方面部分 $\mathbf{K} = (\mathbf{k}_1, \mathbf{k}_2, \dots, \mathbf{k}_m)$ 。将概念增强方面 \mathbf{K} 与情感增强方面 \mathbf{S} 进行拼接,得到最终的方面表示 $\tilde{\mathbf{a}}$ 。

2.3 特征信息融合模块

使用交互注意力机制对2部分表示进行交互建模。首先,对隐藏状态向量取平均,得到上下文的初始表示:

$$\mathbf{c}_{\text{avg}} = \sum_{i=1}^n \mathbf{h}_i^l / n \quad (10)$$

$$\mathbf{a}_{\text{avg}} = \sum_{i=1}^m \tilde{\mathbf{a}}_i / m \quad (11)$$

1) 方面-上下文注意力计算。对于上下文表示,利用 γ 函数计算上下文的隐藏状态向量 $\mathbf{h}_i^l \in \mathbf{H}^l$ 与方面向量 \mathbf{a}_{avg} 的语义关联,为每个上下文词 \mathbf{h}_i^l 分配相关的注意力权重 α_i :

$$\alpha_i = \frac{\exp(\gamma(\mathbf{h}_i^l, \mathbf{a}_{\text{avg}}))}{\sum_{j=1}^n \exp(\gamma(\mathbf{h}_j^l, \mathbf{a}_{\text{avg}}))} \quad (12)$$

式中: γ 函数的计算形式为

$$\gamma(\mathbf{h}_i^l, \mathbf{a}_{\text{avg}}) = \tanh(\mathbf{h}_i^l \mathbf{W}_a \mathbf{a}_{\text{avg}}^T + \mathbf{b}_a) \quad (13)$$

其中: \mathbf{W}_a 和 \mathbf{b}_a 分别为权重矩阵和偏置。

2) 上下文-方面注意力计算。同理,使用上下文表示 \mathbf{c}_{avg} 来计算方面表示的注意力向量:

$$\beta_i = \frac{\exp(\gamma(\tilde{\mathbf{a}}_i, \mathbf{c}_{\text{avg}}))}{\sum_{j=1}^m \exp(\gamma(\tilde{\mathbf{a}}_j, \mathbf{c}_{\text{avg}}))} \quad (14)$$

经过上述计算后,得到上下文和方面表示:

$$\mathbf{c}_r = \sum_{i=1}^n \alpha_i \mathbf{h}_i^l \quad (15)$$

$$\mathbf{a}_r = \sum_{i=1}^m \beta_i \tilde{\mathbf{a}}_i \quad (16)$$

连接方面表示 \mathbf{a}_r 和上下文表示 \mathbf{c}_r ,作为最终表示:

$$\mathbf{z} = \mathbf{c}_r \oplus \mathbf{a}_r \quad (17)$$

2.4 情感分类模块

利用交互注意力层的输出 \mathbf{z} 作为全连接层输入,通过softmax函数输出最终情感极性,即

$$\mathbf{y} = \text{softmax}(\mathbf{W}\mathbf{z} + \mathbf{b}) \quad (18)$$

式中: \mathbf{W} 为全连接层权重矩阵; \mathbf{b} 为偏置。

使用交叉熵损失函数进行模型优化:

$$\zeta = - \sum_{i=1}^J y_i \ln \hat{y}_i + \lambda \|\theta\| \quad (19)$$

式中: J 为所有的训练数据; y_i 和 \hat{y}_i 分别为训练集的真实值和预测值; θ 为所有可训练参数; λ 为 L_2 正则化系数。

3 实验

3.1 数据集

使用 Twitter^[25]、SemEval-2014^[26]、SemEval-2015^[27]、SemEval-2016^[28] 4 个数据集进行实验, 样本如表 1 所示。

表 1 ABSA 任务数据集

Table 1 ABSA task datasets

数据集	训练集个数			测试集个数		
	积极	中性	消极	积极	中性	消极
Twitter	1 561	3 127	1 560	173	346	173
Lap14	994	464	870	341	169	128
Rest15	912	36	256	326	34	182
Rest16	1 240	69	439	469	30	117

3.2 参数设置

实验使用 GloVe 初始词嵌入向量, BiLSTM 的隐藏层节点数为 300, 概念向量维度为 300, 模型中的权重采用均匀分布进行初始化。使用 Adam 作为优化器, 学习率设置为 0.002, L_2 正则项系数设置为 0.000 02, Twitter、Lap14、Rest15、Rest16 批量训练样本分别设置为 16、32、16、64。

3.3 对比实验

本文选取 10 组模型进行对比实验。

1) LSTM^[4]。利用 LSTM 编码上下文信息, 将最后一层隐藏向量作为文本特征表示输入分类器中。

2) RAM^[29]。将多重注意力捕获的语义特征和 LSTM 捕获的特征整合, 得到最终表示。

3) IAN^[13]。一种利用注意力机制对上下文和目

标交互学习的模型。

4) MGAN^[30]。一种多粒度注意力网络, 可以捕获方面与上下文之间的词级交互, 降低信息损失。

5) AOA^[31]。联合建模方面与上下文, 并自动关注句子中的重要部分。

6) ASGCN^[5]。依赖树上的 GCN 来挖掘句法信息和单词依赖, 并结合注意力机制进行情感分类。

7) BiGCN^[8]。一种结合层次句法和词汇图的双级 GCN, 更好地利用语料库级别的单词共现信息及不同类型的句法依存关系。

8) GL-GCN^[32]。一种引入全局和局部信息的 GCN 模型, 有效提高了文本分类的性能。

9) KEATGCN^[33]。一种借助知识图谱和 GCN 的交互注意力模型, 为评论文本注入背景信息和语言知识。

10) MIGCN^[34]。一种多交互 GCN 模型, 可以同时考虑到位置距离特征和文本词间的语法信息, 并设计 2 种交互用来捕获其中的关系。

3.4 实验结果

本文按照基准分类进行了 3 组实验, 对比实验结果如表 2 所示。本文提出的 MSKFSA 模型的分类准确率和 Marco- F_1 与 3 类基准模型相比均展示出优越性。其中, 准确率在 Twitter、Lap14、Rest15、Rest16 数据集上均取得最优, 分别达到了 75.00%、77.90%、81.55%、90.10%, 相较于基准模型的最优结果分别提高了 0.43%、0.99%、0.39%、0.6%。在 Twitter、Lap14、Rest15 数据集上, 相较于对比模型最优结果的 Marco- F_1 , 分别提高了 0.69%、0.93%、1.57%。另外, 在 Twitter、Lap14、Rest15 数据集上, 准确率和 Marco- F_1 均达到了最优结果, 验证了本文模型相较于其他模型的优越性。

根据结果可知, 相比仅使用 LSTM 的模型, 基于 GCN 的模型在 4 个数据集上表现较优。综上所述

表 2 不同模型结果对比

Table 2 Results of different models

类别	模型	准确率				Marco- F_1			
		Twitter	Lap14	Rest15	Rest16	Twitter	Lap14	Rest15	Rest16
LSTM模型	LSTM ^[4]	69.56	69.28	77.37	86.80	67.70	63.09	55.17	63.88
	RAM ^[29]	69.36	74.49			67.30	71.35		
交互模型	IAN ^[13]	72.50	72.05	78.54	84.74	70.81	67.38	52.65	55.21
	MGAN ^[30]	72.54	75.27			70.81	70.81		
	AOA ^[31]	72.30	76.62	78.17	87.50	70.20	67.52	57.02	66.21
GCN模型	ASGCN ^[5]	72.15	75.55	79.89	88.99	70.40	71.05	61.89	67.48
	BiGCN ^[8]	74.16	74.59	81.16	88.96	73.35	71.84	64.79	70.84
	GL-GCN ^[32]	73.26	76.91	80.81	88.47	71.26	72.76	64.99	69.64
	MIGCN ^[34]	73.31	76.59	80.81	89.50	72.12	72.44	64.21	71.97
	KEATGCN ^[33]	74.57	76.65	80.07	89.45	73.34	73.21	65.90	74.81
本文模型	MSKFSA	75.00	77.90	81.55	90.10	74.03	74.14	67.47	71.99

述, LSTM 能够有效捕捉上下文信息, 但句子长度越长, 与方面情感判别无关的噪声信息也随之增加, 而 GCN 可以较好地解决该问题。通过把握句法依存关系, 进一步学习单词与单词之间的依赖关系, 得到方面的最终表示。

相较于 3 类模型, 本文模型的性能进一步提高, 这是因为对于长度较短的文本, 其本身包含的

信息有限, 而模型可以有效融入先验知识来丰富表示。另外, 针对特定情感分析任务, 融合词与词之间的情感得分能够有效指引模型对特定方面情感进行正确的判定。

3.5 消融实验

为进一步检查模型的每个组件对性能的影响, 本文对模型进行消融研究, 结果如表 3 所示。

表 3 消融实验结果

Table 3 Results of ablation experiments

%

模型	准确率				Marco-F ₁			
	Twitter	Lap14	Rest15	Rest16	Twitter	Lap14	Rest15	Rest16
MSKFSA	75.00	77.90	81.55	90.10	74.03	74.14	67.47	71.99
w/o lan	73.99	72.26	79.89	87.18	72.37	67.28	62.81	68.95
w/o em	74.13	72.10	78.78	87.01	72.29	67.16	64.83	64.78
w/o co	74.42	70.85	78.60	86.69	72.91	64.71	60.06	67.65
w/o in	74.57	76.65	80.63	88.96	73.03	72.95	66.05	67.51

1) w/o lan。去掉模型中的上下文信息编码模块中的词汇、句法编码部分。

2) w/o em。去掉模型中的情感增强部分。

3) w/o co。去掉模型中的概念增强部分。

4) w/o in。去掉模型中的特征信息融合模块, 将 2 部分表示拼接做最后的分类。

可以看出, 去除交互注意力指导的 w/o in 模型整体表现优于其他消融模型, 且与完整模型之间差距较小。表明语言知识和外部知识深刻的影响整个情感分析任务, 如果能够对这些知识进行充分的挖掘利用, 有相当重要的作用。比较分别去除情感知识和概念知识的 w/o em 和 w/o co 模型, 在 4 个数据集上的表现基本相同, w/o co 模型在 Lap14、Rest15 数据集上的 Marco-F₁ 弱于 w/o em 模型, 但在 Twitter、Rest16 上又优于 w/o em 模型。表明情感知识与概念知识同等重要, 均不可忽略。同时, 去除语言知识的 w/o lan 模型与 w/o in 模型相比, 在 Lap14、Rest15、Rest16 上的准确率有较大下降, 说明虽然有情感、概念知识的武装, 但上下文中具有更重要的语义信息, 语言知识不可或缺。本文所设计的 MSKFSA 模型结合多源知识, 将方面的 3 部分特征较好地融合, 增强了模型的分类能力。

综上所述, MSKFSA 模型可以通过外部知识和 GCN 分别引入概念、情感知识及上下文语义知识, 通过双交互注意力机制学习上下文与方面之间的交互关系, 进一步提高模型的性能。

3.6 GCN 层数的影响

为研究 GCN 层数对 MSKFSA 模型的影响, 在上述数据集中将 GCN 层数设置为 1, 2, ..., 8, 以评估 MSKFSA 模型。如图 4 和图 5 所示, 当 MSKFSA 模

型层数为 2 时, 综合性能最佳, 但随着网络深度的增加, 模型的 Marco-F₁ 波动剧烈。一方面, 当层数较少时, 节点表示不能传播很远; 另一方面, 如果层

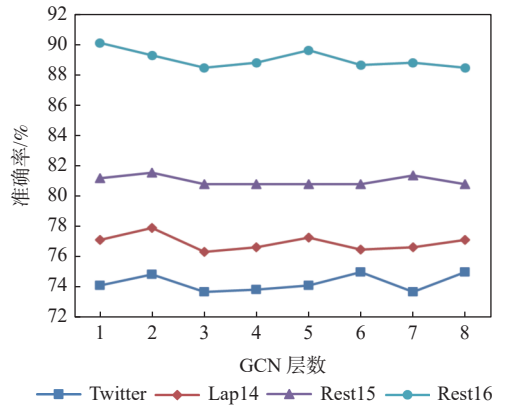


图 4 GCN 层数与准确率的关系

Fig. 4 Relationship between number of GCN layers and accuracy




图 5 GCN 层数与 Marco-F₁ 的关系

Fig. 5 Relationship between number of GCN layers and Marco-F₁

数过多,由于梯度消失和信息冗余,模型会变得不稳定。

4 结 论

本文提出了一种利用多源知识的交互注意力网络模型。

1) 通过融合句法依赖、词共现信息、情感网络和概念图谱等多源知识实现了对评论语句更全面的理解和分析。

2) 通过设计双交互注意力机制增强评论语句上下文与评价方面之间的关联,用于实现两部分的协调优化。

3) 实验结果显示,语言知识及外部知识同等重要,均不可忽略,且对上下文与方面进行交互是有利的,所提模型在公开数据集上的准确率与 Macro- F_1 大部分性能指标优于基准模型。

随着预训练语言模型的出现,未来将进一步探索如何融合更多元的知识源,以提高情感分析的效率和准确性。

参考文献 (References)

- [1] LIU B, ZHANG L. A survey of opinion mining and sentiment analysis[M]//AGGARWAL C C, ZHAI C X. Mining text data. Berlin: Springer, 2012: 415-463.
- [2] 唐晓波, 刘广超. 细粒度情感分析研究综述[J]. 图书情报工作, 2017, 61(5): 132-140.
TANG X B, LIU G C. Research review on fine-grained sentiment analysis[J]. Library and Information Service, 2017, 61(5): 132-140 (in Chinese).
- [3] KIM Y. Convolutional neural networks for sentence classification [C]//Proceedings of the Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2014: 1746-1751.
- [4] TANG D Y, QIN B, FENG X C. Effective LSTMs for target-dependent sentiment classification[C]//Proceedings of the 26th International Conference on Computational Linguistics. Stroudsburg: ACL, 2016: 3298-3307.
- [5] ZHANG C, LI Q C, SONG D W. Aspect-based sentiment classification with aspect-specific graph convolutional networks[C]//Proceedings of the Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing. Stroudsburg: ACL, 2019: 4567-4577.
- [6] 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.
- [7] 谢珺, 王雨竹, 陈波, 等. 基于双指导注意力网络的属性情感分析模型[J]. 计算机研究与发展, 2022, 59(12): 2831-2843.
XIE J, WANG Y Z, CHEN B, et al. Aspect-based sentiment analysis model with bi-guide attention network[J]. Journal of Computer Research and Development, 2022, 59(12): 2831-2843(in Chinese).
- [8] ZHANG M, QIAN T Y. Convolution over hierarchical syntactic and lexical graphs for aspect level sentiment analysis[C]//Proceedings of the Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2020: 3540-3549.
- [9] MA Y K, PENG H Y, CAMBRIA E. Targeted aspect-based sentiment analysis via embedding commonsense knowledge into an attentive LSTM[C]//Proceedings of the 32nd Conference on Artificial Intelligence. Palo Alto: AAAI, 2018: 5876-5883.
- [10] 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.
- [11] ZHAO A P, YU Y. Knowledge-enabled BERT for aspect-based sentiment analysis[J]. Knowledge-Based Systems, 2021, 227: 107220.
- [12] WANG Y Q, HUANG M L, ZHU X Y, et al. Attention-based LSTM for aspect-level sentiment classification[C]//Proceedings of the Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2016: 606-615.
- [13] 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. New York: ACM, 2017: 4068-4074.
- [14] PANG S G, XUE Y, YAN Z H, et al. Dynamic and multi-channel graph convolutional networks for aspect-based sentiment analysis [C]//Proceedings of the Findings of the Association for Computational Linguistics. Stroudsburg: ACL, 2021: 2627-2636.
- [15] LI R F, CHEN H, FENG F X, 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. Stroudsburg: ACL, 2021: 6319-6329.
- [16] ZHONG Q H, DING L, LIU J H, et al. Knowledge graph augmented network towards multiview representation learning for aspect-based sentiment analysis[EB/OL]. (2022-01-13)[2022-08-01]. <http://arxiv.org/abs/2201.04831>.
- [17] CHEN J D, HU Y Z, LIU J P, et al. Deep short text classification with knowledge powered attention[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2019, 33(1): 6252-6259.
- [18] BIAN X M, FENG C, AHMAD A, et al. Targeted sentiment classification with knowledge powered attention network[C]//Proceedings of the IEEE 31st International Conference on Tools with Artificial Intelligence. Piscataway: IEEE Press, 2019: 1073-1080.
- [19] CAMBRIA E, SPEER R, HAVASI C, et al. SenticNet: A publicly available semantic resource for opinion mining[C]//Proceedings of the AAAI Fall Symposium. Palo Alto: AAAI, 2010: 14-18.
- [20] 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. New York: ACM, 2020: 105-114.
- [21] XING F Z, PALLUCCHINI F, CAMBRIA E. Cognitive-inspired domain adaptation of sentiment lexicons[J]. Information Processing and Management, 2019, 56(3): 554-564.
- [22] 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.
- [23] PENNINGTON J, SOCHER R, MANNING C. GloVe: Global vec-

- tors for word representation[C]//Proceedings of the Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2014: 1532-1543.
- [24] JI L, WANG Y J, SHI B T, et al. Microsoft concept graph: Mining semantic concepts for short text understanding[J]. *Data Intelligence*, 2019, 1(3): 238-270.
- [25] 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. Stroudsburg: ACL, 2014: 49-54.
- [26] 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. Stroudsburg: ACL, 2014: 27-35.
- [27] PONTIKI M, GALANIS D, PAPAGEORGIOU H, et al. SemEval-2015 task 12: Aspect based sentiment analysis[C]//Proceedings of the 9th International Workshop on Semantic Evaluation. Stroudsburg: ACL, 2015: 486-495.
- [28] PONTIKI M, GALANIS D, PAPAGEORGIOU H, et al. SemEval-2016 task 5: Aspect based sentiment analysis[C]//Proceedings of the 10th International Workshop on Semantic Evaluation. Stroudsburg: ACL, 2016: 19-30.
- [29] CHEN P, SUN Z Q, BING L D, et al. Recurrent attention network on memory for aspect sentiment analysis[C]//Proceedings of the Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2017: 452-461.
- [30] FAN F F, FENG Y S, ZHAO D Y. Multi-grained attention network for aspect-level sentiment classification[C]//Proceedings of the Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2018: 3433-3442.
- [31] HUANG B X, OU Y L, CARLEY K M. Aspect level sentiment classification with attention-over-attention neural networks[M]//THOMSON R, DANCY C, HYDER A, et al. Social, cultural, and behavioral modeling. Berlin: Springer, 2018: 197-206.
- [32] ZHU X F, ZHU L, GUO J F, 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.
- [33] 韩虎, 郝俊, 张千锟, 等. 知识增强的交互注意力方面级情感分析模型[J]. *计算机科学与探索*, 2023, 17(3): 709-718.
- HAN H, HAO J, ZHANG Q K, et al. Knowledge-enhanced interactive attention model for aspect-based sentiment analysis[J]. *Journal of Frontiers of Computer Science and Technology*, 2023, 17(3): 709-718(in Chinese).
- [34] 王汝言, 陶中原, 赵容剑, 等. 多交互图卷积网络用于方面情感分析[J]. *电子与信息学报*, 2022, 44(3): 1111-1118.
- WANG R Y, TAO Z Y, ZHAO R J, et al. Multi-interaction graph convolutional networks for aspect-level sentiment analysis[J]. *Journal of Electronics & Information Technology*, 2022, 44(3): 1111-1118(in Chinese).

Multi-source knowledge fusion model for aspect-based sentiment analysis

HAN Hu*, HAO Jun, ZHANG Qiankun, ZHAO Qitao

(School of Electronic and Information Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China)

Abstract: Aspect-based sentiment analysis (ABSA) is a fine-grained sentiment analysis task that aims to give the corresponding sentiment polarity for specific aspects that appear in review statements. Most existing aspect-based sentiment analysis methods relying on deep learning focus on mining the semantics and syntax of review statements, often ignoring the conceptual knowledge and sentiment degree information that may be involved in the review statements. To address this problem, a neural network model incorporating multi-source knowledge. It reveals the structural framework of sentences through syntactic dependencies, captures semantic connections between words through word co-occurrence, and embeds emotional networks and concept graphs to provide emotional and background knowledge for the model, and coordinated optimization of the contextual and evaluative aspects of review statements was realized through a dual-interaction attention model. Experimental results on four public datasets show that the model achieves better performance than existing models, with accuracy reaching 75.00%, 77.90%, 81.55%, and 90.10%, respectively, all of which were improved compared to the benchmark model. This achievement not only verifies the effectiveness of multi-source knowledge fusion in ABSA tasks, but also provides new ideas and methods for future research.

Keywords: aspect-based sentiment analysis; graph convolutional network; multi-source fusion; knowledge graph; interactive attention mechanisms

Received: 2022-08-17; Accepted: 2023-01-14; Published Online: 2023-03-23 09:01

URL: link.cnki.net/urlid/11.2625.V.20230322.0955.001

Foundation item: National Natural Science Foundation of China (62166024)

* Corresponding author. E-mail: hanhu_lzjtu@mail.lzjtu.cn