

基于关系特征交互的方面级情感分类方法

赵 振¹, 朱振方^{1*}, 王文玲²

(1. 山东交通学院 信息科学与电气工程学院, 山东 济南 250357;

2. 鲁东大学 文学院, 山东 烟台 264025)

摘 要: 方面级情感分类是一项细粒度的情感分析任务,其目的是识别一句话中的方面词、观点项及其对应的情感极性。现有的方面级情感分类方法对模型的构建存在不足,难以有效利用句子中的依存关系信息,从而导致分类准确率较低。基于此,该文提出一种基于关系交互的图注意力网络模型。该模型首先利用单词之间的依存关系构建句法依存树,并使用双向门控循环单元提取句子上下文特征,然后将两者融入图注意力网络和关系感知网络中进行关系交互,以学习句子间的句法和语义信息,最后将关系的表征结果结合并输出方面词的情感类别(正面、负面、中性)。在四个公开数据集上的实验结果表明,该模型在方面级情感分类任务上充分挖掘并利用了文本的句法关系信息,进一步提升了情感分类的准确率。

关键词: 句法依存树;关系交互;图注意力网络;双向门控循环单元;文本情感分析;自然语言处理

中图分类号: TP391

文献标识码: A

文章编号: 1673-629X(2023)03-0187-07

doi: 10.3969/j.issn.1673-629X.2023.03.028

An Aspect-level Sentiment Classification Method Based on Relational Feature Interaction

ZHAO Zhen¹, ZHU Zhen-fang^{1*}, WANG Wen-ling²

(1. School of Information Science and Electrical Engineering, Shandong Jiaotong University, Jinan 250357, China;

2. School of Chinese Language and Literature, Ludong University, Yantai 264025, China)

Abstract: Aspect-level sentiment classification is a fine-grained sentiment analysis task, which aims to identify aspect terms, opinion items and their corresponding sentiment polarity in a sentence. Existing aspect-level sentiment classification methods are inadequate for model construction, and it is difficult to effectively utilize the information of dependency relations in sentences, which leads to low classification accuracy. Based on this, we propose a relational interaction graph attention network (RIGAT). Firstly, the model builds a syntactic dependency tree based on the dependencies between words, and uses bi-directional gated recurrent unit (Bi-GRU) to extract sentence context features. Secondly, we integrate the two into the graph attention network and the relational-aware network for relational interaction to learn the syntactic and semantic information between sentence. Finally, we combine the representation results of the relationship and output the sentiment polarity (positive, negative, or neutral) of the aspect word. Experimental results on four public datasets show that the model fully excavates and utilizes the syntactic relationship information of the text in aspect-level sentiment classification tasks, and further improves the accuracy of sentiment classification.

Key words: syntactic dependency trees; relational interactions; graph attention networks; bi-directional gated recurrent unit; text sentiment analysis; natural language processing

0 引言

随着互联网的迅速发展,越来越多的用户热衷于在网络上发表评论,产生了大量带有情感倾向的评论文本,挖掘并分析这些文本所对应的情感极性,可以帮助政府、商家等做出正确的决策。若要逐个分析文本

中多个评价对象的情感倾向,则需要用到基于方面的情感分析(Asspect-Based Sentiment Analysis, ABSA)^[1]技术。

基于方面的情感分析主要涉及两个任务,即确定句子的所有方面和计算特定方面的情感极性(如正

收稿日期: 2022-05-29

修回日期: 2022-09-30

基金项目: 国家社科基金一般项目(19BYY076); 山东省重大科技创新工程(2019JZZY010129)

作者简介: 赵 振(1996-),男,硕士研究生,CCF会员(C9742G),研究方向为情感分析、自然语言处理、深度学习;通讯作者: 朱振方(1980-),男,博士,教授,CCF会员(13973S),研究方向为自然语言处理、网络舆情分析与监管、网络信息过滤、智能计算。

面、负面、中性)。对于第二个任务,即基于方面的情感分类,常用的方法是通过缩短方面词与观点词之间的单词距离,从而更有效地将观点词传播到方面词。

在 ABSA 领域,情感文本的组成元素包括评论者、评论主体、体现评论者情感的情感词等,各个组成元素之间存在着各种依存关系,如主谓关系、动宾关系等,利用这些联系,能够更直接地通过句法结构的规则约束筛选出文本中的观点词和方面词,丰富文本的特征表示,进一步提高情感分类的准确率。

句法依存分析是自然语言处理中的关键技术之一,其中“句法”指句子的结构方式,它以词作为基本单位;“依存”指词与词之间支配与被支配的关系,这种关系具有方向。应用该技术可生成具有单词节点和节点关系的句法依存树,它在形式上可看作是一种图结构,并具有以下特点:(1)缩短了句子各个方面与目标方面之间的距离;(2)可以捕捉每个单词之间的句法关系;(3)为依存关系树中的信息传播提供句法识别路径。这种结构有助于使目标方面更接近其相关上下文,从而促进特征表示,对方面情感分类具有一定的辅助作用。

在最近的 ABSA 任务中,诸多学者对句法依存树进行了研究,取得了优越的成果。他们的方法是将依存树视为邻接矩阵,使用图卷积网络(Graph Convolutional Network, GCN)^[2]或图注意力网络(Graph Attention neTwork, GAT)^[3]根据这些矩阵对输入句子进行编码。例如,Sun 等^[4]提出了用于编码句法依存特征的图卷积网络,以建立目标和上下文之间的信息交换;Bai 等^[5]研究了一种集成类型化句法依存信息的关系图注意力网络,从而可以有效地对句法特征进行编码,实验结果表明了该方法的有效性。然而,之前的研究对单词间的依存关系利用并不充分,忽略了单词之间的依存关系类型信息,从而导致模型可能出现丢失重要情感信息的问题。

为了解决上述问题,该文提出一种关系交互图注意力网络(Relational Interaction Graph Attention Network, RIGAT)模型,该模型将关系特征融入到注意力机制中,使用一个新的扩展注意力来引导信息从目标方面的句法上下文传播到目标方面本身。首先,模型采用图注意力网络来学习依存树中单词节点的向量表示,并捕获其局部位置;其次,使用关系感知网络对依存树中每个单词节点之间的依赖关系进行特征表示,使模型更多地关注方面词;最后,将图注意力网络与关系感知网络的最终表示进行融合,然后通过分类函数计算并输出对应方面的情感极性。实验结果表明,该模型在基于方面的情感分类任务上取得了较高的准确率,进一步验证了模型的有效性。

1 相关工作

近年来,随着深度学习技术的发展,注意力机制逐渐开始应用于方面级情感分析任务。例如,马远等^[6]提出一种融合左右双边注意力机制的文本情感分析模型,通过内部注意力机制来处理方面词,并根据方面词和上下文词设计了双边交互注意力机制,最后将上述注意力的处理结果进行级联并分类;程艳等^[7]提出一种基于注意力机制的多通道 CNN 和 BiGRU 的神经网络模型,该模型通过注意力机制对情感极性分类重要的词语进行关注,并使用 CNN 与 BiGRU 分别提取文本的局部特征和上下文语义特征,获得了较好的效果;冯超等^[8]提出使用层次注意力机制和门机制处理方面级情感分类任务,层次注意力机制负责更新方面词与上下文词的表示,门机制选择出对于方面词有用的上下文信息,实验结果进一步证明了该方法的有效性。

然而,基于注意力机制的情感分类方法并未考虑到文本的句法依存信息,忽略了文本句法结构对情感分类的重要性。已有学者对注意力机制与句法依存信息做了进一步研究,例如,Lu 等^[9]提出了一个交互式规则注意力网络,通过模拟句子的句法功能,并使用注意力网络从上下文中学习注意力信息,来考虑句法规则对情感的影响;张文轩等^[10]提出一种将注意力机制与句法知识相结合的新方法,他利用依存句法关系和位置关系为每个句子建立面向方面的依存树,然后利用其对注意力权重进行监督,从而在利用语义和句法信息的同时减轻对依存树的依赖程度;Ke 等^[11]提出了一种新的基于句法依赖的注意力网络,该模型首先对每个单词和方面之间的依赖路径进行建模,随后将生成的句法表示输入注意力层,以进一步推断情感预测的依赖权重。

最近的研究利用图神经网络对句法结构进行编码,它解决了 CNN 和 RNN 无法处理非结构化数据的问题,同时对节点信息与结构信息进行端到端学习,从而有效地提取空间特征,增强方面情感分类的性能。例如,Zhang 等^[12]提出了一个特定于方面的图卷积网络,它将句法信息和长距离单词依赖性纳入分类模型,解决了由于缺乏相关句法约束和长距离词依赖而导致的模型对观点词判断错误问题;Wang 等^[13]提出了一个关系图注意力网络来编码依存树结构,他们以目标方面为根,重塑和修剪依存树来定义一个面向方面的依存树结构;Li 等^[14]提出了一种双图卷积网络模型,该模型同时考虑了句法结构和语义的互补性,进一步解决了由于依赖解析结果的不准确性以及文本的非正式表达所带来的问题;王光等^[15]提出一种句法信息感知的方面级情感分类模型,该方法使用注意力机制,结合记忆文本语义、词性、方面与位置信息的记忆网络,

以及基于依存句法分析树的图卷积神经网络,从而更准确地建立了方面词与观点词之间的联系;夏鸿斌等^[16]提出了一种结合图卷积网络和注意-过度注意网络的方面级情感分类模型,他们通过在每个句子的依赖树上建立相应的图卷积网络,并利用注意力机制捕获方面词与上下文之间的交互和表示,实验结果证明了其优越性。

受以上方法启发,该文使用双向门控循环单元、图注意力网络和注意力机制来完成方面级文本情感分类任务,将文本的句法依存关系融合到上下文的语义信息中,再通过注意力机制学习方面词及其上下文之间的交互信息,从而进一步提高情感分类任务的性能。

2 关系交互图注意力网络

对于该文所提模型,每个训练实例由三个组件组成:目标方面、句子和句子的依赖树。形式上,可将这些组件表示为三元组: (a, s, d) , 其中 $a = \{w_i, w_{i+1}, \dots, w_{i+m-1}\}$ 表示方面词序列, $s = \{w_1, w_2, \dots, w_i, \dots,$

$w_{i+m}, \dots, w_n\}$ 表示句子序列, a 和 s 的长度分别是 m 和 n , $d = \{V, \mathbf{A}, \mathbf{R}\}$ 表示句子 s 上的一个依存树, V 包含所有的单词节点, \mathbf{A} 表示一个邻接矩阵, 其中 $A_{ij} = 1$ 表示词 w_i 和 w_j 之间存在依赖关系, 否则 $A_{ij} = 0$, \mathbf{R} 表示一个标签矩阵, 它记录 \mathbf{A} 中相对应的关系。方面情感分类的目标是通过给定的句子 s 和方面词 a , 预测情感极性 $y = \{-1, 0, 1\}$, 其中 $-1, 0, 1$ 分别表示消极、中性、积极。

RIGAT 模型的整体结构如图 1 所示, 主要由三部分组成:

(1) 双向门控循环单元: 它将句子上下文编码进行特征学习。

(2) 图注意力层与关系感知层: 前者侧重于将句法信息与上下文信息进行建模, 生成上下文感知的单词嵌入; 后者侧重于捕获词与词之间的依存关系, 生成关系感知的单词嵌入。

(3) 特征融合与分类: 它用于动态组合上下文和句法表示, 并使用简单的池化函数进行特征融合。




图1 模型框架

2.1 双向门控循环单元

该文使用双向门控循环单元对上下文信息进行双向建模, 该结构将具有 n 个有序词嵌入的句子 s 作为输入, 将上下文信息集成到词嵌入中。其中, 输入特征由 GloVe 嵌入 v_i 、词性嵌入 t_i 和位置嵌入 p_i 组成, 因此, 一个单词就可以被表示为 $w_i = [v_i; t_i; p_i]$ 。

若给定一个词嵌入序列 $s = \{w_1, w_2, \dots, w_n\}$, 前向与后向 GRU 可以分别学习到词嵌入 s 传播的隐藏状态 h_1 与 h_2 , 这就可以在向前的方向上捕获上下文信息。最后, 将前向和后向 GRU 建模的并行嵌入连接成更高维的表示 $h = \{h_1; h_2\}$ 。

2.2 图注意力层与关系感知层

与标准的 GAT 相比, 该文所提出的 RIGAT 模型还可以利用标签关系, 从而产生更多的信息表示。对

于未使用标签关系的 GAT, 其依存树形式表示为 $d = \{V, \mathbf{A}\}$, 它使用相邻的矩阵作为结构信息, 因此忽略了依赖特性。RIGAT 扩展了原始 GAT, 将关系特征融入到注意力计算和聚合过程中, 使其能对有标签关系的依存树 $d = \{V, \mathbf{A}, \mathbf{R}\}$ 进行建模。

对于图注意力层, 依存树可以看作是一个图 G , 其中节点表示句子中的单词, 由上述 Bi-GRU 编码的实值向量给出, 边表示单词之间的句法依存路径, 由依存解析器的结果给出。GCN 可以对图直接进行卷积操作, 同时使用注意力机制更多地关注方面词与上下文之间的句法依存关系。其中, 对于一个 l 层的图卷积, 节点 i 的第 l 层表示 h_i^l 可以计算为:

$$h_i^l = \rho \left(\sum_{j=1}^n A_{ij} W^l h_j^{l-1} \right) \quad (1)$$

其中, h_i 表示节点 i 的最终状态; ρ 是激活函数; W 是线性权重; A 表示图 G 的一个邻接矩阵。

对于关系感知层, 该文将依存树中两个词 w_i 和 w_j 之间的关系 R_{ij} 转换成一个与依存关系维度一致的向量 r_{ij} 。在计算节点之间的注意力权重时, 考虑了节点特征和关系特征, 其中第 l 层节点感知的注意力权重 e^N 和关系感知的注意力权重 e^R 的计算公式分别如下:

$$e_{ij}^N = f(h_i^{l-1}, h_j^{l-1}) \quad (2)$$

$$e_{ij}^R = f(h_i^{l-1}, r_{ij}) \quad (3)$$

上述两种类型的注意力得分进行结合, 最终得分 \hat{a} 表示为:

$$\hat{a}_{ij} = \frac{\exp(e_{ij}^N + e_{ij}^R)}{\sum \exp(e_{ij}^N + e_{ij}^R)} \quad (4)$$

通过这种方式, 模型得到的注意力分数同时包含了节点特征和关系特征。

2.3 特征聚合与分类

通过使用图注意力层和关系感知层, 可以获得上下文及句法感知的向量表示 $\{h_i, h_{i+1}, \dots, h_{i+m-1}\}$ 和关系感知表示 $\{\hat{h}_i, \hat{h}_{i+1}, \dots, \hat{h}_{i+m-1}\}$, 然后通过对这些向量使用平均池化操作获得两个全局表示 h_g 和 h_t 。为了学习包含上下文和句法特征的复合表示, 该文引入了细粒度的特征融合机制来控制融合率, 使用了基于门控机制的特征融合机制, 将句法表示 h_t 和上下文表示 h_g 通过以下方式计算融合结果 h_a :

$$h_a = \varphi \circ h_t + (1 - \varphi) \circ h_g \quad (5)$$

其中, \circ 是元素正交运算, φ 是由上下文和句法感知表示共同加权并经激活函数 σ 计算所得:

$$\varphi = \sigma(W_\varphi[h_g; h_t] + b_\varphi) \quad (6)$$

表 1 数据集统计信息

数据集	正面		负面		中性	
	train	test	train	test	train	test
Restaurant	2 164	727	807	196	637	196
Laptop	976	337	851	128	455	167
Twitter	1 507	172	1 528	169	3 016	336
MAMS	3 380	400	2 764	329	5 042	607

在实验参数设置方面, 该文采用 300 维的 Glove^[21] 向量, 其中包括 8 400 亿个词嵌入向量, 依存关系向量为 30 维, 这些向量在训练过程中会被调整。Batch Size 设置为 32, 学习率设置为 0.001, 优化器使用 Radam^[22], 句子的依存树使用 Stanford^[23] 解析工具生成。同时, 该文在所有公开数据集上使用固定的随机种子进行训练, 以尽可能避免随机数对模型的影响。

该文使用准确率对模型性能进行评估, 准确率的定义如下:

分类器是一个全连接网络, 它将融合表示 h_a 作为输入, 并计算每个情感类别 c 的概率:

$$P(y = c) = \frac{\exp(W h_a + b)_c}{\sum_{c \in C} \exp(W h_a + b)_c} \quad (7)$$

其中, W 和 b 为模型的可调参数, C 表示所有情感类别的集合。

2.4 模型训练

该文在损失优化部分, 使用的训练方法是 L_2 正则化的交叉熵损失:

$$L = - \sum_{i=1}^N \sum_{c \in C} I(y = c) \log(P(y = c)) + \lambda \|\theta\|^2 \quad (8)$$

其中, N 表示训练案例数; I 表示指标函数; λ 表示正则化超参数; θ 表示模型可调参数的集合。同时, 该文采用了自正则化非单调函数 Mish^[17], 其定义为:

$$F(x) = x \tanh(\ln(1 + e^x)) \quad (9)$$

与常见的激活函数 ReLU^[18] 相比, Mish 的梯度更平滑, 可以更好地让信息穿透神经网络, 从而获得更高的准确性。

3 实验及结果

3.1 实验设置与评估指标

该文在四个公开数据集上进行实验, 包括 SemEval 2014 的 Restaurant 和 Laptop 数据集^[1]、Twitter 提供的推文数据集^[19] 和一个大规模多方面多情感 (MAMS) 数据集^[20], 它们的情感极性可分为正面、负面和中性。表 1 显示了这些数据集中每个样本类别的统计信息, 以及训练集、测试集的划分情况。

$$P = \frac{TP}{TP + FP} \quad (10)$$

其中, $P \in [0, 1]$ 为模型预测的准确程度, TP 表示预测正确的样本数, FP 表示预测错误的样本数。

3.2 基线模型

为了验证 RIGAT 的性能, 该文与使用相同数据集的最新模型进行了比较, 包括:

(1) CapsNet^[20]: 利用一种基于胶囊网络的模型来学习方面和上下文之间的复杂关系。

(2)G-ATT^[24]:提出一种带有记忆融合的图注意力网络,通过给边分配不同的权重来扩展 GCN。

(3)R-GAT^[13]:通过对普通的依赖解析树进行重塑和剪枝,定义了一个基于目标方面的依赖树结构。

(4)RGAT^[5]:提出一种新的关系图注意力网络,通过集成类型化的句法依赖信息,有效地提高了情感分类性能。

(5)UP-CNN^[25]:提出一种基于先验知识的方面检测网络,并通过方面掩码来构建具有方面感知的上下文表示。

(6)SPRN^[26]:提出一种基于方面的语义感知和细化网络,该方法采用了双门控多通道卷积来获取句子中的方面相关语义特征。

(7)GL-GCN^[27]:提出一种全局和局部依赖引导的图卷积网络,通过利用句法依赖结构和句子序列信息来挖掘句子的局部结构信息,通过对整个语料库构图,挖掘单词之间的全局依赖信息。

(8)AFGCN^[28]:通过引入依赖树和依赖位置图来增强每个实例的句法依赖,并使用图卷积网络将两者融合以生成交互情感特征。

3.3 结果分析

将该文所提模型与上述基线模型进行对比,以验证方法的有效性。实验结果的准确率如表2所示,其中“-”表示未找到对应数据。

分析表2的对比结果可以发现,RIGAT在四个数据集上的表现均优于其他基线模型,准确率分别达到了85.92%、79.37%、76.65%、83.56%。相较于目前性能最好的RGAT模型,该文所述方法在Laptop数据集上的性能提升最小,原因可能是由于Laptop数据集内的隐式情感表达样本较多,且数据量较少,导致模型不能很好地捕捉并分析方面与观点词之间的内在关系;而对于MAMS数据集,模型的性能提升最大,说明模型可以更好地捕获长距离单词间的依存关系。

表2 RIGAT模型与基线模型在不同数据集上的分类准确率 %

模型名	Restaurant	Laptop	Twitter	MAMS
UP-CNN ^[25]	80.05	73.73	70.95	79.93
SPRN ^[26]	80.77	73.2	72.1	-
CapsNet ^[20]	80.79	-	-	79.78
G-ATT ^[24]	81.59	76.18	73.6	-
GL-GCN ^[27]	82.11	76.91	73.26	-
AFGCN ^[28]	82.5	77.43	74.69	-
R-GAT ^[13]	83.3	77.42	75.57	-
RGAT ^[5]	83.55	78.02	75.36	81.75
RIGAT	85.92	79.37	76.65	83.56

与其他基线模型相比,文中提出的RIGAT模型可以更好地对句法依存关系进行交互,考虑到英文文本具有时序性,通过句法解析的方式缩短了单词之间的依存路径,进一步简化了句子结构。同时,句法关系和注意力机制的融入进一步提高了句法信息的可靠性,使得模型可以更好地对每个单词进行权重分配,并在不同层次之间进行信息传播,从而得到更为准确的情感倾向。

3.4 消融实验

3.4.1 句法关系信息对模型的影响

为探究句法关系信息对情感预测的有效性,该文使用传统GAT,去除句法关系信息,仅对方面和上下文进行建模。实验结果如图2所示,相较于仅使用传统的图注意力网络,RIGAT不仅考虑到了方面词与上下文之间的交互信息,而且充分地利用了单词与单词之间的句法关系信息,其在Restaurant数据集上的准确率分别提高了3.28个百分点、2.16个百分点、2.61个百分点和3.44个百分点。可见将句法关系信息融入到上下文信息之中,能有效提升情感预测的准确率。




图2 GAT与RIGAT在数据集上的准确率比较

3.4.2 RNN、LSTM与GRU的性能比较

将GRU分别替换为LSTM、RNN网络,以验证GRU在所提模型中的优越性。实验结果如图3所示,可以发现相较于传统的LSTM,GRU在四个Restaurant和Laptop数据集上更具优势,分别提高了2.06个百分点和3.37个百分点,可能的原因是GRU使用了更新门与重置门存储并过滤信息,这种方式更适合于文本情感分类任务。




图3 LSTM、RNN、GRU分别在数据集上的准确率比较

3.4.3 模型层数的影响

分别调整图注意力网络与关系感知网络的层数,

检查对 RIGAT 准确率的影响。实验结果如图 4、图 5 所示。综合结果分析,可以发现准确率曲线呈现出上下波动的趋势,并且往往在一开始就表现出最高分数。对于 Restaurant 和 Twitter 数据集,它们都在图注意力网络和关系感知网络层数为 1 时表现出最高的准确率;对于 Laptop 和 MAMS 数据集,当图注意力网络和关系感知网络层数为 2 时,模型的准确率最高。




图 4 不同数量的图注意力层在数据集上的准确率




图 5 不同数量的关系感知层在数据集上的准确率

4 结束语

该文提出一种基于关系交互图注意力网络的情感分类研究方法,利用图注意力网络与句法关系感知相交互的方式,共同提取句子的语义和句法信息,旨在充分利用文本间的句法依存特性,进一步提高方面情感分类的准确率。在公开数据集的实验结果表明,该文所提出的 RIGAT 模型相对于基线模型有更优越的表现。

尽管该文在情感分类任务上取得了不错的效果,但仍具有进一步改进的空间。一方面,由于该文只着重于公开数据集上的性能提升,而忽略了对模型的鲁棒性研究,在未来的研究中,模型需要结合更多的对抗性文本进行训练,以提升在方面情感分类上的鲁棒性能。另一方面,目前的研究仅局限于英文文本的情感分类研究,而忽视了中文情感文本,下一步将探索模型在中文文本上的可能性。

参考文献:

[1] PONTIKI M, GALANIS D, PAVLOPOULOS J, et al. SemE-

val-2014 task 4: aspect based sentiment analysis [C]//Proceedings of the 8th international workshop on semantic evaluation. Dublin: The Association for Computer Linguistics, 2014: 27-35.

[2] KIPF T N, WELLING M. Semi-supervised classification with graph convolutional networks [C]//5th international conference on learning representations. Toulon: OpenReview. net, 2017.

[3] VELIČKOVIĆ P, CUCURULL G, CASANOVA A, et al. Graph attention networks [C]//6th international conference on learning representations. Vancouver: OpenReview. net, 2018.

[4] 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). Stroudsburg: Association for Computational Linguistics, 2019: 5678-5687.

[5] BAI X, LIU P, ZHANG Y. Investigating typed syntactic dependencies for targeted sentiment classification using graph attention neural network [J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2021, 29: 503-514.

[6] 马 远,程春玲.融合左右双边注意力机制的方面级别文本情感分析[J].计算机应用研究,2021,38(6):1753-1758.

[7] 程 艳,尧磊波,张光河,等.基于注意力机制的多通道 CNN 和 BiGRU 的文本情感倾向性分析[J].计算机研究与发展,2020,57(12):2583-2595.

[8] 冯 超,黎海辉,赵洪雅,等.基于层次注意力机制和门机制的属性级别情感分析[J].中文信息学报,2021,35(10):128-136.

[9] LU Q, ZHU Z, ZHANG D, et al. Interactive rule attention network for aspect-level sentiment analysis [J]. IEEE Access, 2020, 8: 52505-52516.

[10] 张文轩,殷雁君.基于依存树增强注意力模型的方面级情感分析[J].计算机应用研究,2022,39(6):1656-1662.

[11] KE W, GAO J, SHEN H, et al. Incorporating explicit syntactic dependency for aspect level sentiment classification [J]. Neurocomputing, 2021, 456: 394-406.

[12] ZHANG C, LI Q, SONG D. Aspect-based sentiment classification with aspect-specific graph convolutional networks [C]//Proceedings of the 2019 conference on empirical methods in natural language processing and the 9th international joint conference on natural language processing (EMNLP-IJCNLP). Stroudsburg: Association for Computational Linguistics, 2019: 4567-4577.

[13] WANG K, SHEN W, YANG 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: Association for Computational Linguistics, 2020; 3229–3238.
- [14] 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. Stroudsburg: Association for Computational Linguistics, 2021; 6319–6329.
- [15] 王 光, 李鸿宇, 邱云飞, 等. 基于图卷积记忆网络的方面级情感分类[J]. 中文信息学报, 2021, 35(8): 98–106.
- [16] 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.
- [17] MISRA D. Mish: a self regularized non-monotonic activation function[C]//31st British machine vision conference 2020. Virtual Event: BMVA Press, 2019.
- [18] GLOROT X, BORDES A, BENGIO Y. Deep sparse rectifier neural networks[C]//Proceedings of the fourteenth international conference on artificial intelligence and statistics. Fort Lauderdale: JMLR. org, 2011; 315–323.
- [19] 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. Stroudsburg: Association for Computational Linguistics, 2014; 49–54.
- [20] JIANG Q, CHEN L, XU R, et al. A challenge dataset and effective models for aspect-based sentiment analysis [C]//Proceedings of the 2019 conference on empirical methods in natural language processing and the 9th international joint conference on natural language processing (EMNLP-IJCNLP). Stroudsburg: Association for Computational Linguistics, 2019; 6279–6284.
- [21] PENNINGTON J, SOCHER R, MANNING C. Glove: global vectors for word representation [C]//Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP). Stroudsburg: Association for Computational Linguistics, 2014; 1532–1543.
- [22] LIU L, JIANG H, HE P, et al. On the variance of the adaptive learning rate and beyond[C]//8th international conference on learning representations. Addis Ababa: OpenReview. net, 2020.
- [23] MANNING C, SURDEANU M, BAUER J, et al. The Stanford CoreNLP natural language processing toolkit[C]//Proceedings of 52nd annual meeting of the association for computational linguistics; system demonstrations. Stroudsburg: Association for Computational Linguistics, 2014; 55–60.
- [24] YUAN L, WANG J, YU L C, et al. Graph attention network with memory fusion for aspect-level sentiment analysis [C]//Proceedings of the 1st conference of the Asia-Pacific chapter of the association for computational linguistics and the 10th international joint conference on natural language processing. Suzhou: Association for Computational Linguistics, 2020; 27–36.
- [25] WANG X, LI F, ZHANG Z, et al. A unified position-aware convolutional neural network for aspect based sentiment analysis[J]. Neurocomputing, 2021, 450; 91–103.
- [26] 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.
- [27] 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.
- [28] ZHANG F, ZHANG Y, HOU S, et al. Aspect fusion graph convolutional networks for aspect-based sentiment analysis [C]//Information retrieval – 27th China conference. Dalian: Springer, 2021; 74–87.