

基于图神经网络与表示学习的文本情感分析

尹帮治¹, 徐 健², 唐超尘^{3,4}

(1.邵阳职业技术学院, 信息技术学院, 湖南 邵阳 422000)

(2.桂林电子科技大学机电工程学院, 广西 桂林 541001)

(3.桂林理工大学物理与电子信息工程学院, 广西 桂林 541004)

(4.西安电子科技大学通信工程学院, 陕西 西安 710071)

[摘要] 近年来,情感分析是近年来自然语言处理领域备受学者关注的核心研究方向,传统文本情感分析模型只能捕捉文本的表面特征,在不同领域或语境下缺乏泛化能力,难以处理长文本以及语义歧义等问题.针对上述问题,本文设计了基于图神经网络与表示学习的文本情感分析模型(a text sentiment analysis model based on graph neural networks and representation learning, GNNRL).利用 Spacy 生成句子的语法依赖树,利用图卷积神经网络进行编码,以捕捉句子中词语之间更复杂的关系;采用动态 k-max 池化进一步筛选特征,保留文本相对位置的序列特征,避免部分特征损失的问题,从而提高模型的特征提取能力.最后将情感特征向量输送到分类器 SoftMax 中,根据归一化后的值来判断情感分类.为验证本文所提 GNNRL 模型的有效性,采用 OS10 和 SMP2020 两个文本情感分析数据集进行测试,与 HyperGAT、IBHC、BERT_CNN、BERT_GCN、TextGCN 模型比较,结果表明,综合 accuracy、precision、recall、f1 4 个指标,本文改进的 AM_DNN 模型均优于其他模型,在文本情感中具有较好的分类性能,并探究了不同优化器的选择对本模型的影响.

[关键词] 文本情感分析,图神经网络,表示学习,词嵌入

[中图分类号] TP301 [文献标志码] A [文章编号] 1001-4616(2024)03-0097-07

Text Sentiment Analysis Based on Graph Neural Networks and Representation Learning

Yin Bangzhi¹, Xu Jian², Tang Chaochen^{3,4}

(1.School of Information Technology, Shaoyang Polytechnic, Shaoyang 422000, China)

(2.School of Mechanical and Electrical Engineering, Guilin University of Electronic Science and Technology, Guilin 541001, China)

(3.School of Physics and Electronic Information Engineering, Guilin University of Technology, Guilin 541004, China)

(4.School of Communication Engineering, Xidian University, Xi'an 710071, China)

Abstract: In recent years, sentiment analysis has become a core research direction in the field of natural language processing. Traditional text sentiment analysis models can only capture the surface features of text, and lack generalization ability in different fields or contexts, making it difficult to deal with long text and semantic ambiguity. In response to the above problems, A Text Sentiment Analysis Model Based on Graph Neural Networks and Representation Learning (GNNRL) is designed in this paper. Spacy is used to generate syntactic dependency tree of sentences, and graph convolutional neural network is used for coding to capture more complex relationships between words in sentences. Dynamic k-max pooling is used to further screen features, retain the sequence features of text relative position, and avoid the problem of partial feature loss, so as to improve the feature extraction ability of the model. Finally, the emotion feature vector is transferred to the classifier SoftMax, and the emotion classification is judged according to the normalized value. In order to verify the validity of the GNNRL model proposed in this paper, two text sentiment analysis datasets OS10 and SMP2020 are used for testing. Compared with HyperGAT, IBHC, BERT_CNN, BERT_GCN and TextGCN models, the results show that by synthesizing accuracy, precision, recall and f1, the improved AM_DNN model in this paper is superior to other models and has better classification performance in text emotion. Moreover, the influence of the selection of different optimizers on this model is explored.

Key words: text sentiment analysis, graph neural networks, representation learning, word embedding

收稿日期: 2023-05-06.

基金项目: 国家自然科学基金项目(61474032)、桂林医学院博士启动基金项目(31304019011).

通讯作者: 尹帮治, 博士, 副教授, 研究方向: 深度学习, 数据分析. E-mail: ybzdcc@163.com

情感分析是近年来自然语言处理领域备受学者关注的核心研究方向,其广泛应用于多个领域^[1-2].

BERT 等预训练模型的出现极大地推动了文本情感分析的发展,通过大规模文本语料上进行预训练,这些模型能够获取丰富的语言表示,从而在情感分析等任务上取得了很好的效果. 随着文本、图像等多模态数据的普及,研究者开始探索如何将多种模态数据结合起来进行情感分析^[3-4].

除了提高模型性能外,研究者还关注情感分析模型的可解释性,即模型如何做出预测以及为什么做出这样的预测. Jia 等^[5]在情感词典的基础上,构建了基于注意力的学习模型来对文本情感进行分类;Sadr 等^[6]利用迁移学习来提高情感分析的性能,取得了较好的分类精度;Basiri 等^[7]提出了一种基于融合 4 种深度学习和一种经典监督机器学习模型的新方法,用于对来自 8 个国家的冠状病毒相关推文进行情感分析,了解人们在社交媒体评论中表达的情绪. Antonakaki 等^[8]使用机器学习方法,分析推特中的社交图结构以及各种实体的情感;Chiny 等^[9]提出一种基于规则的情感分析词典和术语频率-逆文档频率加权方法的混合情感分析模型,在 IMDB 数据集上获得的知识,处理来自 Twitter 公司情感数据集.

然而,上述方法往往只能捕捉文本的表面特征,在不同领域或语境下缺乏泛化能力,难以处理长文本以及语义歧义等问题. 此外,现有模型在处理文本时往往忽视了词语之间的复杂关系和文本的序列特征,这限制了情感分析的准确性和深度. 针对上述挑战,本文提出了一种基于图神经网络与表示学习的文本情感分析模型(graph neural networks and representation learning, GNNRL). 我们的模型主要创新点在于:(1)利用 Spacy 生成句子的语法依赖树,并通过图卷积神经网络进行编码,以捕捉句子中词语之间更复杂的关系,从而增强模型对文本信息的分析识别能力;(2)采用动态 k-max 池化进一步筛选特征,保留文本相对位置的序列特征,避免部分特征损失的问题,从而提高模型的特征提取能力;(3)结合表示学习,通过自编码器和词嵌入技术,将复杂的图数据结构转换为低维向量,以更好地挖掘图中的信息,并提高下游任务的效率. 我们在 OS10 和 SMP2020 两个公开文本情感分析数据集上进行了广泛的实验,证明了所提模型在文本情感分析中的优越性能.

1 图神经网络

图神经网络(graph neural networks, GNN)近年来在各种领域中取得了显著的成果,包括社交网络分析、推荐系统、生物信息学等. 在图数据的表示中,图由节点和边组成,通常表示为 $G=(V,E)$,其中 V 表示节点集合, E 表示边集合^[10]. 每个节点可以携带特征信息,例如节点的属性或向量表示,而每条边通常也可以携带权重或其他信息. 图神经网络旨在学习节点之间的关系以及整个图的全局结构^[11]. 在数学上,图可以表示为邻接矩阵 A .

对于图卷积神经网络,设节点 i 的表示为 $h[i]$,那么更新规则可以表示为:

$$h_i^{(l+1)} = \sigma \left(\sum_{j \in N(i)} \frac{1}{c_{ij}} W^{(l)} h_j^{(l)} \right), \quad (1)$$

式中, $h_i^{(l)}$ 为节点 i 在第 l 层的表示, $N(i)$ 为节点 i 的邻居集合, c_{ij} 为归一化系数, $W^{(l)}$ 为权重矩阵, σ 为激活函数.

图注意力网络是一种利用注意力机制来学习节点之间关系的图神经网络^[12]. 与卷积网络不同,注意力网络允许每个节点对其邻居节点分配不同的重要性,因此更加灵活,其更新规则可以表示为:

$$h_i^{(l+1)} = \sigma \left(\sum_{j \in N(i)} \alpha_{ij} W^{(l)} h_j^{(l)} \right), \quad (2)$$

式中, $\alpha_{ij} = \frac{\exp(e_{ij})}{\sum_{k \in N(i)} \exp(e_{ik})}$, 表示节点 i 对 j 的注意力权重, a 为注意力参数, LeakyReLU 为线性整流函数.

图神经网络已经被成功应用于多个领域,本文结合图神经网络的特性,将其应用于文本情感分析模型中,增强对文本信息的分析识别.

2 表示学习

表示学习(representation learning)是一种将复杂的图数据结构转换为低维向量的方法,以便更好地挖掘图中的信息,从而提高下游任务的效率^[13]. 近年来,社交网络、交通网络和生物信息学等领域的数据日益普

遍,需要有效的图表示学习方法来处理这些数据,以解决实际问题. 表示学习的核心是通过学习数据的有效表示来提取数据中的有用信息,这种表示可以是低维稠密向量,也可以是高维稀疏向量,其目的是捕捉数据之间的内在结构和关系^[14]. 其中最常见假设是数据具有低维度的流形结构,即数据分布在一个低维流形上. 通过将数据映射到这个低维流形上,可以实现数据的降维和特征提取,从而更好地理解数据.

在表示学习中,通常使用损失函数来衡量学习到的表示与原始数据之间的差异. 常见的损失函数包括重构损失、对比损失等. 其中,重构损失用于衡量解码后的数据与原始数据之间的差异,而对比损失则用于衡量不同样本之间的相似度. 通过最小化损失函数可以优化模型参数,学习到更好的数据表示^[15].

自编码器是表示学习中最常见的方法之一,其基本思想是通过将输入数据编码成低维表示,再解码回原始数据. 在编码阶段通过最小化重构损失来学习到数据的有效表示,在解码阶段通过最小化解码损失来学习到数据的重构能力. 自编码器的数学模型可以表示为:

$$h=f(Wx+b), \quad (3)$$

$$x'=g'(Wh'+b'), \quad (4)$$

式中, x 是输入数据, h 是编码后的表示, x' 是解码后的数据, f 和 g 分别为激活函数, W 和 b 是模型参数.

词嵌入的表示方法中,保留单词语义信息的同时,可以使得计算机可以更好地理解和处理自然语言. 最常见的方法是 Word2Vec,包括连续词袋模型和跳字模型. Skip-gram 是 Word2Vec 在预测给定中心词的情况下,其周围上下文词的概率分布. 设有一个文本序列 $w_1, w_2, \dots, w_T, w_i$ 表示第 i 个单词,采用式(5)最大化给定中心词 w_i 条件下上下文词的联合概率:

$$\text{maximize } \prod_{i=1}^T \prod_{-c \leq j \leq c, j \neq 0} P(w_{i+j} \text{ mid } w_i), \quad (5)$$

式中, c 是上下文窗口的大小,用于控制考虑中心词周围多少个词的上下文信息. 使用 softmax 函数建模条件概率如式(6)所示.

$$P(w_{i+j} \text{ mid } w_i) = \frac{\exp(\text{score}(w_{i+j}, w_i))}{\sum_{i=1}^V \exp(\text{score}(w_i, w_i))}, \quad (6)$$

式中, V 是词汇表的大小, score 函数可以是任意函数,用于计算中心词和上下文词之间的相似度得分.

3 基于图神经网络与表示学习的文本情感分析

本文提出的文本情感分析模型由词嵌入层、图卷积层、池化层、输出层组成,如图1所示.




图1 模型结构图

Fig. 1 Model structure diagram

3.1 词嵌入层

文本分析需要将原始文本数据转化为向量表示,本文借鉴了文献[9]提出的基于大规模语料库预训练的词向量模型,该模型在处理输入序列时能够考虑所有位置,并为每个位置分配不同的注意力权重,使模型能够更准确地表达单词、句子以及上下文之间的关系^[16-17].

例如对于包含 n 个词汇的文本,本文用 $w_i \in V^d$ 表示第 i 个单词通过 GloVe 词向量嵌入得到的 d 维词向量 w_i . 然后将这些词向量组合成文本矩阵 T ,表示为 $T=[w_1, w_2, \dots, w_n]$.

3.2 图卷积层

传统的卷积操作在提取 n -grams 特征时存在一个问题,即相较于原始信息,提取到的特征信息长度减短.如图 2 所示,本文采用宽卷积额外提取的特征主要集中在文本两端,使得提取到的特征更加全面,有助于提高特征的表达能力.

使用 Spacy 依存解析器生成句子的语法依赖树,这种结构展示了句子中单词之间的依赖关系.在这个过程中,方面词以蓝色字体标记,情感词以红色字体标记,边表示依赖项,而标签表示依赖项类型,由 det、acomp、scounj、nsubj、advmod、marker 等句法依存关系标签词构成.以“这家食物味道很好但餐厅环境很差”这句话为例,依赖结构如图 3 所示.




图 2 标准卷积与宽卷积

Fig. 2 Standard convolution and wide convolution




图 3 句法依存图

Fig. 3 Syntactic dependency diagram

在构建多方面情感图时,本文考虑了句子中各个方面之间的依赖信息,利用图卷积神经网络对句法依赖树进行编码.句法依存树可以被视为一个上下文句法图 $G_{sy}(V, E)$,多方面情感图的节点数量由方面的数量决定,节点 V 表示单词的隐藏状态,而边 E 表示单词之间的联系.每个节点 v_i 和 v_j 之间的关系都可以用数学表达式(7)来表示.

$$A_{ij}^{sy} = \begin{cases} 1 & \text{if } e_{ij} \in E \\ 1 & \text{if } i=j \\ 0 & \text{otherwise} \end{cases}, \quad (7)$$

式中, A_{ij}^{sy} 为邻接矩阵, $i, j \in [1, n]$, $e_{ij} \in E$ 表示节点 i 依赖于 j .

为了考虑上下文与方面词之间的相对距离,本文引入了位置编码.如式(8)所示,位置编码使用方面词的索引和上下文词的相对距离来定义,从而有效地捕捉到了方面词与上下文之间的语法关系.

$$p_i = \begin{cases} 1 - \frac{a_{\text{start}} - i}{n} & 0 \leq i < a_{\text{start}} \\ 0 & a_{\text{start}} \leq i < a_{\text{end}} \\ 1 - \frac{i - a_{\text{end}}}{n} & a_{\text{end}} \leq i \leq n \end{cases}, \quad (8)$$

式中, a_{start} 为开始索引和结束索引, n 为句子 length, p_i 为上下文词到方面的相对距离.

图卷积层通过图节点之间的信息传递与聚合,有效地捕获了节点间的关系,并在多层结构中不断地更新节点的表示,在每一层中,GCN 都会聚合上下文信息,以便更好地理解句子中的语法结构,归一化因子的图卷积运算如式(9)所示.

$$h_i^{sy(l)} = \text{RELU} \left(\sum_{j=1}^n \tilde{A}_{ij}^{sy} h_j^{l-1} \mathbf{W}^l + b^l \right), \quad (9)$$

式中, $\tilde{A}^{sy} = \tilde{D}^{-\frac{1}{2}} A^{sy} \tilde{D}^{-\frac{1}{2}}$ 为归一化对称矩阵, \tilde{D} 为 A^{sy} 的度矩阵, h_j^{l-1} 为上一层位置词表征, \mathbf{W}^l 和 b^l 为第 l 层的权重矩阵和偏差.

3.3 池化层

卷积操作后对特征做进一步筛选,相较于最大池化, k -max 池化的作用是从文本中提取出 k 个最重要的特征值,这种方法有效地保留了文本信息的序列性特征,从而避免了信息的丢失.而动态调整 k 值则是根据输入文本的长度和当前网络的层数来决定的.在网络较浅的层次,需要提取更多的特征值来支持后

续的处理步骤,因此选择一个相对较大的 k 值;而在网络较深的层次,则逐步减小 k 值,以在减少网络参数数量的同时保留重要特征. 这种动态变化使得网络结构更加灵活. k 值的选择方式可以用以下公式表示; k 值的选取方式如式(10)所示.

$$k_l = \max\left(k_{\text{top}}, \frac{L-l}{L}n\right), \quad (10)$$

式中, L 为卷积层的总层数; l 表示当前池化操作所在的层数; k_{top} 为顶层的固定池化 k 值; n 表示输入句子的长度.

卷积层和池化层在协同作用下形成一个特征提取层. 设表示第 i 层第 j 个卷积核提取的特征,则可以用以下形式表示:

$$D_j^i = \sum_{k=1}^n m_{j,k}^i * D_k^{i-1}, \quad (11)$$

式中, $m_{j,k}^i$ 表示参数矩阵, D_k^{i-1} 表示 $i-1$ 层第 k 个卷积核的特征. 经上述计算处理,最终输出为式(12)、式(13)所示.

$$D^{\text{top}} = [D_1^{\text{top}}, D_2^{\text{top}}, \dots, D_n^{\text{top}}], \quad (12)$$

$$D_j^{\text{top}} = \sum_{k=1}^n m_{j,k}^{\text{top}} * D_k^{\text{top}-1}. \quad (13)$$

3.4 输出层

最后将情感特征向量 D 输送到分类器 SoftMax 中,根据归一化后的值来判断情感分类,如图4所示. SoftMax 是一种用于多分类器中的逻辑回归技术^[18],通过将可以确定为同一类别的特征进行加总,并将其转换为一个概率值,从而使得类别划分更加有效精准. 可以帮助我们更好地理解 and 预测类别之间的关系,具体计算公式如式(14)所示.

$$p(y=i) = \frac{e^{xW_i^T}}{\sum_{j=0}^{k-1} e^{xW_j^T + b_j}}, \quad (14)$$

式中,文本特征向量用 X 表示, k 为类别个数,对应的损失函数如式(15)所示.

$$L(\theta) = -\log p(y=i). \quad (15)$$

4 实验结果与分析

4.1 实验相关设置

为验证本文模型的有效性,本文在 OS10 和 SMP2020 两个公开文本情感分析数据集上进行实验^[19]. OS10 数据集来自电商平台的产品评论构成,总计 6 万条数据,涵盖了书籍、酒店、娱乐等十个类别的产品; SMP2020 数据集来源于微博,包含了来自不同情感类别的数据. 实验以式(16)至(19)为评价标准,通过在 OS10 数据集和 SMP2020 微博数据集上的实验验证,将实验重复进行 5 次后取平均值作为最终结果,全面评估本文所提出模型在不同领域和不同平台上的情感分析效果,从而验证其在实际应用中的有效性和可靠性.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}, \quad (16)$$

$$Precision = \frac{TP}{TP+FP}, \quad (17)$$

$$Recall = \frac{TP}{TP+FN}, \quad (18)$$

$$F1 = \frac{2 * Precision * Recall}{Precision + Recall}. \quad (19)$$

经过实验调试,发现不同初始参数设置对实验结果产生了明显影响. 将隐藏层设置为 100,卷积核设




图4 SoftMax 输出
Fig. 4 Softmax output

置为(3,2),具体模型的整体参数设置如表 1 所示. 通过在 OS10 和 SMP2020 数据集上的实验验证,我们发现这些参数的设置能够取得较好的平衡,从而在多次实验中获得稳定的性能表现.

表 1 模型参数信息
Table 1 Model parameter information

参数名称	参数含义	设置值	参数名称	参数含义	设置值
批量大小	每次训练过程中输入模型的样本数量	64	词向量维度	词向量表示的维度	200
学习率	优化器更新模型权重的速率	0.001	BiGUR 层数	生成词向量的双向门控循环单元层的数量	2
训练轮数	模型训练的总次数	10	隐藏层维度	隐藏层的神经元数量	100
失活率	防止过拟合的神经元失活比例	0.5	卷积核	卷积操作中使用的卷积核大小	(3,2)

4.2 对比实验

为验证本文所提出的 GNNRL 模型在文本情感分析中的性能,在 OS10 和 SMP2020 数据集上将本文提出的 GNNRL 模型与文献[4]、文献[10]、文献[11]、文献[18]、文献[19]提出的 HyperGAT、IBHC、BERT_CNN、BERT_GCN、TextGCN 模型比较,实验结果如表 2 所示.

表 2 6 种模型下的实验比较结果
Table 2 Experimental comparison results under six models

模型	accuracy	precision	recall	f1	模型	accuracy	precision	recall	f1
BERT_CNN	0.73	0.69	0.65	0.67	HyperGAT	0.72	0.69	0.64	0.67
BERT_GCN	0.75	0.71	0.66	0.68	IBHC	0.83	0.77	0.74	0.76
TextGCN	0.78	0.74	0.70	0.72	GNNRL	0.85	0.81	0.81	0.79

由实验结果绘制如图 5 所示条形对比图,其更直观地展示了各模型的性能差异.




图 5 实验结果对比图
Fig. 5 Comparison chart of experimental results

从表 2 和图 5 中可以看出,对比其他 5 种模型,本文所提模型在两个数据集上的准确率达到 85%,且其他指标均优于另外 5 个模型,证明了本文所改进 GNNRL 模型的有效性.

此外,优化器的选择对模型也具有较大的影响. 因此,本文通过对两个数据集进行详尽的比较实验,深入研究了 SGD、RMSProp、AdaDelta 和 Adam 等 4 种广泛使用的优化器对模型性能的深刻影响,其中对准确率和损失值的影响如图 6 所示.

由图 6 可以观察到 SGD 的收敛速度相对较缓慢,而且在训练过程中出现了损失的振荡现象, RMSProp、Adam 和 AdaDelta 性能相对于 SGD 更为优越. Adam 收敛速度较快,振荡较小,整体性能表现最佳.

综上,本文所提出的 GNNRL 模型在处理文本的情感倾向分析任务中取得了显著的效果,优于现有其他模型.

5 结论

为解决传统文本情感分析在不同领域或语境下缺乏泛化能力、池化层破坏文本序列特征等缺点,利用




图 6 优化器对准确率的影响结果
Fig. 6 Effect of optimizer on accuracy

Spacy 生成句子的语法依赖树,利用图卷积神经网络进行编码,以捕捉句子中词语之间更复杂的关系;采用动态 k -max 池化进一步筛选特征,避免部分特征损失的问题,从而提高模型的特征提取能力. 最后将情感特征向量输送到分类器 SoftMax 中. 为验证本文所提 GNNRL 模型的有效性,采用 OS10 和 SMP2020 两个文本情感分析数据集进行测试,与 CNN、BiLSTM、Transformer、BERT 模型和文献[11]、文献[23]、文献[14]提出的 BERT_CNN、TextGCN 和 BERT_GCN 模型比较,结果表明,本文改进的 AM_DNN 模型均优于其他模型,在文本情感中具有较好的分类性能,并探究了不同优化器的选择对本模型的影响.

[参考文献]

- [1] LI H, MA Y, MA Z, et al. Weibo text sentiment analysis based on bert and deep learning[J]. Applied sciences, 2021, 11(22): 10774.
- [2] LI Y, LI N. Sentiment analysis of Weibo comments based on graph neural network[J]. IEEE access, 2022, 10: 23497–23510.
- [3] YANG X, XU S, WU H, et al. Sentiment analysis of Weibo comment texts based on extended vocabulary and convolutional neural network[J]. Procedia computer science, 2019, 147: 361–368.
- [4] 王珊, 黄海燕, 乔伟涛. 基于 Reformer 模型的文本情感分析[J]. 计算机工程与设计, 2022, 43(4): 1089–1095.
- [5] JIA W, PENG J. The public sentiment analysis of double reduction policy on weibo platform[J]. Computational intelligence and neuroscience, 2022, 2022(1): 3212681.
- [6] SADR H, PEDRAM M M, TESHNEHLAB M. Convolutional neural network equipped with attention mechanism and transfer learning for enhancing performance of sentiment analysis[J]. Journal of AI and data mining, 2021, 9(2): 141–151.
- [7] BASIRI M E, NEMATI S, ABDAR M, et al. A novel fusion-based deep learning model for sentiment analysis of COVID-19 tweets[J]. Knowledge-based systems, 2021, 228: 107242.
- [8] ANTONAKAKI D, FRAGOPOULOU P, IOANNIDIS S. A survey of Twitter research: Data model, graph structure, sentiment analysis and attacks[J]. Expert systems with applications, 2021, 164: 114006.
- [9] CHINY M, CHIHAB M, BENCHAREF O, et al. LSTM, VADER and TF-IDF based hybrid sentiment analysis model[J]. International journal of advanced computer science and applications, 2021, 12(7): 11–22.
- [10] 李全鑫, 庞俊, 朱峰冉. 结合 Bert 与超图卷积网络的文本分类模型[J]. 计算机工程与应用, 2023, 59(17): 107–115.
- [11] DANG N C, MORENO-GARCÍA, MARÍA N, et al. Sentiment analysis based on deep learning: a comparative study[J]. Electronics, 2020, 9(3): 483.
- [12] 李文彬, 许雁玲, 钟志楷, 等. 基于稳定学习的图神经网络模型[J]. 湖南理工学院学报(自然科学版), 2023, 36(4): 16–18.
- [13] 魏苏波, 张顺香, 朱广丽, 等. 基于正交投影的 BiLSTM-CNN 情感特征抽取方法[J]. 南京师大学报(自然科学版), 2023, 46(1): 139–148.
- [14] 李青, 王一晨, 杜承烈. 图表示学习方法研究综述[J]. 计算机应用研究, 2023, 40(6): 1601–1613.
- [15] 邹然, 柳杨, 李聪, 等. 图表示学习综述[J]. 北京师范大学学报(自然科学版), 2023, 59(5): 716–724.
- [16] 陈豪伶, 虞慧群, 范贵生, 等. 基于分层表示和上下文增强的类摘要生成技术[J]. 计算机研究与发展, 2024, 61(2): 307–323.
- [17] BASIRI M E, NEMATI S, ABDAR M, et al. ABCDM: An attention-based bidirectional CNN-RNN deep model for sentiment analysis[J]. Future generation computer systems, 2021, 115: 279–294.
- [18] JIAWA Z, WEI L, SILI W, et al. Review of methods and applications of text sentiment analysis[J]. Data analysis and knowledge discovery, 2021, 5(6): 1–13.
- [19] SINGLA C, AL-WESABI F N, PATHANIA Y S, et al. An optimized deep learning model for emotion classification in tweets[J]. Computers, materials & continua, 2022, 70(3): 118–131.

[责任编辑: 陆炳新]