

语义增强的图神经网络方面级文本情感分析

代祖华,刘园园,狄世龙

(西北师范大学 计算机科学与工程学院,兰州 073500)

摘要: 方面级情感分析是一种细粒度文本情感分析技术,可以判断文本目标方面的情感倾向,被广泛应用于商品评价、教育评价等领域,可以辅助用户更全面地了解实体属性并做出精准决策。但是现有方面级情感分析技术大多存在文本句法依存关系特征以及外部知识特征提取不充分的问题,为此,利用图卷积神经网络可以处理异构数据的特点,构建一种语义增强的方面级文本情感分析模型。将文本的词嵌入向量输入双向门控循环神经网络以提取文本和目标方面词的上下文语义信息,依据句法依存关系类型构建加权句法依存图,根据文本单词和外部知识库构建知识子图,使用图卷积神经网络处理加权句法依存图和知识子图,从而获取融合文本句法结构信息的文本特征和体现外部知识信息的目标方面特征,在此基础上,拼接两组特征向量完成情感极性分类。实验结果表明,在Laptop14、Restaurant14和Restaurant15数据集上,该模型的F1值分别达到77.34%、76.58%和68.57%,相比ATAE-LSTM、TD-LSTM、ASGCN等基线模型,其F1值分别平均提高7.28%、5.71%和6.28%,所提模型通过提取文本句法依存关系特征以及外部知识特征获得了更好的情感分析性能。

关键词: 方面级情感分析;图卷积神经网络;句法依存图;知识图谱;注意力机制

开放科学(资源服务)标志码(OSID):



中文引用格式: 代祖华,刘园园,狄世龙. 语义增强的图神经网络方面级文本情感分析[J]. 计算机工程, 2023, 49(6): 71-80.

英文引用格式: DAI Z H, LIU Y Y, DI S L. Semantic enhanced aspect-level text sentiment analysis of graph neural networks[J]. Computer Engineering, 2023, 49(6): 71-80.

Semantic Enhanced Aspect-Level Text Sentiment Analysis of Graph Neural Networks

DAI Zuhua, LIU Yuanyuan, DI Shilong

(School of Computer Science and Engineering, Northwest Normal University, Lanzhou 073500, China)

[Abstract] Aspect-level sentiment analysis is a fine-grained text sentiment analysis technology that determines the sentiment tendency of text targets. It is widely used in fields such as product and education evaluation, and assists users in establishing a more comprehensive understanding of entity attributes and making accurate decisions. However, a key challenge is that the majority of existing aspect-level sentiment analysis techniques do not sufficiently extract text syntax dependency and external knowledge features. Therefore, a semantic enhanced aspect-level text sentiment analysis model is proposed herein using graph convolution neural networks to process heterogeneous data. A word embedding vector of the text is input into a bidirectional gated circular neural network to extract contextual semantic information of text and target aspect words, a weighted syntactic dependency graph is constructed based on the type of syntactic dependency, and a knowledge subgraph is constructed based on the text words and external knowledge base, and a graph convolutional neural network is used to process the weighted syntactic dependency graph and knowledge subgraph, to obtain text features that integrate text syntactic structure information and target aspect features that reflects external knowledge information. On this basis, two sets of feature vectors are spliced to complete sentimental polarity classification. Experimental results demonstrate that on the Laptop14, Restaurant14, and Restaurant15 datasets, the model F1 values reach 77.34%, 76.58%, and 68.57%, respectively. Compared with baseline models such as ATAELSTM, TD-LSTM, and ASGCN, the model F1 values increase by an average of 7.28%, 5.71%, and 6.28%, respectively. The proposed model achieves an improved sentimental analysis performance by extracting textual syntactic dependency and external knowledge features.

[Key words] aspect-level sentiment analysis; graph convolution neural network; syntactic dependency graph; knowledge graph; attention mechanism

DOI: 10.19678/j.issn.1000-3428.0064850

基金项目: 甘肃省一流课程建设项目(200500531);甘肃省高等学校创新基金项目(2022B-092);西北师范大学研究生培养与课程改革项目(2022ALLX008)。

作者简介: 代祖华(1971—),女,副教授、博士,主研方向为深度强化学习、自然语言处理;刘园园、狄世龙,硕士研究生。

收稿日期: 2022-05-30 **修回日期:** 2022-07-17 **E-mail:** 2812704000@qq.com

0 概述

文本情感分析技术是自然语言处理领域的重要研究方向之一^[1]。按照情感分析粒度的不同,文本情感分析技术可分成篇章级情感分析、句子级情感分析和方面级情感分析^[2],前2种情感分析方法是对文本进行整体的情感倾向判别,但评论文本通常包含评价对象多方面的情感表达,文本的整体情感分析会掩盖人们对意见目标的细粒度情感表达,可能会导致分析结果在推荐系统、问答系统等应用中计算有误。因此,需要挖掘文本评论对象的各个方面,并确定文本针对每个方面表达的情感信息,上述过程即为基于方面的情感分析(Asspect Based Sentiment Analysis, ABSA)技术。

方面级情感分析任务旨在对评论文本的目标方面词进行情感分析,判断客户对被评论实体某一特定方面的情感倾向。比如“这家餐厅的菜品从没让人失望过,但是价格太高了!”,该文本提及餐厅实体“价格”和“菜品”这2个不同的评论方面,对“价格”方面表达的是负面观点,对“菜品”方面表达的是积极看法,2个评价方面的情感极性不一致。篇章级和句子级情感分析技术由于忽略了文本情感倾向与方面词之间的联系,在处理包含多个评价方面的文本时性能表现不佳。

方面级情感分析技术针对目标方面词进行情感极性判断,可以有效处理以上细粒度情感分析问题。方面级文本情感分析在商品评论、学业情绪等领域得到广泛应用。在电商领域,对用户购买商品的评论文本进行方面级情感分析,商家可以准确获取消费者群体对于产品各个属性的使用体验反馈,对积极情感极性的方面加以引导,从而实现智能化营销;针对消极的情感方面改进产品质量,降低用户投诉的风险,以更有效地服务消费者^[3]。杨梦琳等^[4]为了挖掘消费者对生鲜电商消费满意度的情况,采用LDA主题提取模型对在线评论文本进行主题提取,运用具有池化增强作用的BERT情感分析模型,嵌入极大-平均表示向量来有效解决分析过程中的过拟合问题,通过联合LDA提取结果以及AP-BERT情感分析结果,得出消费者主题满意度比例矩阵,从而实现生鲜电商领域的方面级情感分析,帮助企业在竞争和自身发展中发现市场差异化,挖掘消费者心理。在教育领域,存在大量的学业反馈文本数据,如学生提问、教师答疑、作业评语、主观题答案、知识点讨论对话、作业学习总结、学习心得等,这些数据包含了学生在学习过程中可能存在的学习障碍、学业认知状态、教学评价等重要教学信息,是诊断教学效果、深化和拓展教学内容的重要依据,对这类教学文本进行方面级学业情绪分析,可以智能化地挖掘学

生学业情绪,处理学生对教学活动的意见、评论、感受,有利于教育机构实施更好的教学干预与措施,也有助于教师探索学生对教学效果、课程内容的精准反馈^[5]。

方面级情感分析有基于规则的方法、基于统计学习的方法和基于深度学习的方法。HU等^[6]较早建立基于规则的细粒度情感分析模型,利用WordNet词典来查找情感词语的同义词和反义词,根据同义词情感相近以及反义词情感极性相反的规则来确定方面词的情感极性。基于规则的方法^[6-8]需要形容词极性标注和规则制定操作,领域适应性较差。基于统计学习的方法^[9-10]从文本中筛选出一组具有统计意义的词汇特征,然后使用机器学习算法构建分类模型判断方面的情感极性,这类方法需要对语料进行人工特征筛选,模型的准确率难以得到保证。随着深度学习的发展,神经网络技术在ABSA任务中也得到一定应用。早期的研究^[11-13]通常将文本进行语义特征向量表示然后输入LSTM网络模型,使用注意力机制提取上下文情感语义信息,以识别目标方面的情感极性。ABSA神经网络模型关注对文本上下文情感语义信息的提取,但忽略了对文本的句法依存特征和外部常识知识的利用。近年来,图神经网络由于具有图数据特征提取能力,被广泛应用于情感分析任务中,用以在特征表示学习中融合图结构特征,为模型有效提取句法依存关系^[14-16]、多个目标方面情感依赖关系^[17]、词性^[18]、语法距离^[19]、外部知识信息^[20-21],为增强方面词情感语义提供了一种研究思路。

基于图神经网络的方面级情感分析模型虽然取得了较好的效果,但是多数研究工作是对句法知识、常识知识等信息进行单独建模,且未充分提取文本句法依存图中的词性、依存关系类型、语法距离等有助于准确识别方面词情感的重要特征。针对该问题,本文提出一种基于语义增强的图卷积神经网络(SEGCN)方面级文本情感分析模型,该模型按句法关系类型设置不同的权重,构建加权的句法依存图,依据语法距离计算文本词的权重信息,利用图卷积网络建模该加权句法依存图,提取目标方面词的句法结构特征表示,从而增强方面词的语义信息表示。根据文本词和情感知识库构建知识子图,基于图卷积神经网络提取融合外部情感常识信息的目标方面词特征表示。最后,在Laptop14、Restaurant14、Restaurant15数据集上进行实验,以验证该模型的有效性。

1 相关工作

1.1 句法依存图

本文使用斯坦福句法分析器^[22]进行文本句法分

析,以“Although the food is delicious, the price is very expensive”为例,其句法依存图如图1所示,其中,蓝色字体表示方面术语(彩色效果见《计算机工程》官网HTML版)。根据单词之间的句法依赖信息,方面术语“food”通过句法依存关系“nsubj”关注

到对应的意见词“delicious”,方面术语“price”通过句法依存关系“nsubj”关注到意见词“expensive”。句法依存图中标明了句法依存关系,如“det”“nsubj”“cop”等,还标明了单词的词性、从句类型等缩写表示,包括“IN”“DT”“NN”“VBZ”“JJ”“DT”“NN”“VBZ”“RB”“JJ”等。




图1 句法依存图示例

Fig.1 Example of syntax dependency graph

1.2 语法距离

语法距离为句法依存树中方面词和其他文本词之间的路径长度,与目标方面词越相关的上下文单词其语法距离越小,与目标方面词越不相关的上下文单词其语法距离越大^[23]。例如,在句子“This French food tastes very well, but the restaurant has poor service.”中,方面词“French food”的依存树语法距离如图2所示^[23]。




图2 依存树语法距离

Fig.2 Syntax distance of dependency tree

语法距离向量表示为 $D = (d_1, d_2, \dots, d_i, \dots, d_n)$, 其中, d_i 为上下文词 w_i 与目标方面词之间的语法距离。假定目标方面词由 k 个词组成,将距离句法依存树根节点最近的单词作为方面词来计算语法距离。

1.3 图卷积神经网络

图神经网络将抽象为图结构数据的实际问题看作图中节点之间的连接和信息传播问题,对节点之间的依赖关系进行建模,是一种处理图结构数据的有效技术^[24]。图卷积神经网络是图神经网络中的一个重要分支,其将卷积神经网络(Convolutional Neural Network, CNN)思想应用到图结构数据处理中,为图中每一个节点聚合其邻居节点特征以提供图结构信息,大多数图神经网络模型是在图卷积神经网络上变化推导而来。

图卷积神经网络的特征聚合过程如下:首先根据图的邻接矩阵将图中每个节点的邻居节点及自身的特征进行聚合;然后使用激活函数对更新后的节点特征进行非线性变换,从而得到所有节点的特征

表示,实现节点之间的信息传递。以一层图卷积神经网络为例,第 $l-1$ 层神经网络每一个节点的特征表示为 h_i^{l-1} ,在更新每一个节点的特征表示时,第 l 层神经网络的输出 H^l 都可以通过非线性函数 f 表示为 $f(H^{l-1}, A)$, 其中, A 为邻接矩阵。图卷积计算公式如式(1)所示:

$$f(H^l, A) = \sigma(\hat{D}^{-1/2} \hat{A} \hat{D}^{-1/2} H^{l-1} W^l) \quad (1)$$

其中: $\hat{A} = A + I$ 为添加了自连接的邻接矩阵; $\hat{D} = \sum_j \hat{A}_{ij}$ 表示矩阵 $\hat{A}$ 的度矩阵; W^l 表示第 l 层网络的权重矩阵。通过图卷积操作,每一个节点特征的融合范围随着图卷积层数的增加而扩大,从而聚合到更多邻居节点的信息。

1.4 基于图神经网络的方面级情感分析模型

基于图神经网络的方面级情感分析模型可利用图神经网络建模文本的句法依存信息、常识知识等外部信息,从而丰富目标方面词的语义。ZHOU 等^[20]利用图神经网络,提出一种融合句法依存图和外部知识子图的方面级情感分析(SK-GCN)模型,为方面级情感分析任务融合外部知识提供了一种实现思路。如图3所示,SK-GCN模型使用2个图卷积神经网络模块分别建模常识知识子图和句法依存图,为目标方面词提取外部知识信息和句法结构信息,然后通过多头位置注意力层融合文本词的位置特征信息,在此基础上,拼接所提取的特征向量作为目标方面词最终的特征表示。SK-GCN模型对常识知识和句法知识进行联合建模,可有效提取多种外部知识信息,但是该模型忽略了句法依存图中的词性、依存关系类型、语法距离等有助于增强方面词语义信息的特征。针对该问题,本文提出一种基于语义增强的图卷积神经网络方面级文本情感分析模型 SEGNN,依据句法依存关系类型、语法距离和相对位置关系构建加权句法依存图,同时构建外部常识知识子图提取外部知识信息,利用多种特征增强目标方面词语义信息。




图3 SK-GCN模型框架

Fig.3 The framework of SK-GCN model

2 SEGCN模型框架

SEGCN模型引入外部情感知识图谱,构建加权“句法-知识”图,利用图卷积神经网络提取方面词的

增强语义信息。SEGCN模型主要由词嵌入与语义表示层、距离编码模块、句法依存类型权重计算模块、知识嵌入模块、图卷积神经网络层和分类层组成,模型整体网络结构如图4所示。




图4 SEGCN模型框架

Fig.4 The framework of SEGCN model

2.1 任务定义

本文所面向的方面级情感分析任务定义为:对于评论文本 $S = \{w_1, w_2, \dots, w_{n-1}, w_n\}$, 该文本中所包含的目标方面词表示为 $A_{\text{Aspect}} = \{w_{\text{start}}, w_{\text{start}+1}, \dots, w_{\text{end}-1}, w_{\text{end}}\}$, start 和 end 分别表示句子 S 的目标方面词序列 A_{Aspect} 的开始索引和结束索引, 其中, A_{Aspect} 由一个单词或者多个单词组成。方面级情感分析任务就是对文本 S 中的方面序列 A_{Aspect} 所表示的情感极性进行判别, 情感极性 $C \in \{0, 1, 2\}$, 其中, 0、1 和 2 分别表示“消极”“中性”“积极”的情感极性。

2.2 词嵌入与 Bi-GRU 层

给定包含 n 个单词的文本序列 $S = \{w_1, w_2, \dots, w_{n-1}, w_n\}$ 以及目标方面词序列 $A_{\text{Aspect}} = \{a_1, a_2, \dots, a_l, \dots, a_k\}$, 使用 BERT 预训练模型将文本序列和方面词序列映射为一个低维的语义向量表示, 得到词嵌入矩阵 $W^{n \times d_{\text{bert}}}$ 、 $E^{k \times d_{\text{bert}}}$, 其中, n 为单词个数, k 为目标方面词的单词个数, d_{bert} 为词嵌入维度。为了提取评论文本和目标方面词的上下文语义信息, 将文本 S 和目标方面 A_{Aspect} 的词嵌入向量输入到 Bi-GRU 层, 提取的隐藏层状态表示分别为 $H^c = (h_1^c, h_2^c, \dots, h_l^c, \dots, h_n^c)$ 和 $H^a = (h_1^a, h_2^a, \dots, h_l^a, \dots, h_k^a)$ 。

2.3 距离编码模块

语法距离向量可以表示为 $D = (d_1, d_2, \dots, d_l, \dots, d_n)$, 其中, d_i 为上下文词 w_i 与目标方面词之间的语法距离。假定目标方面词由 k 个词组成, 将距离句法依赖树根节点最近的单词作为方面词来计算语法距离。句子中每个词的语法距离权重计算公式如式(2)所示:

$$l_i = 1 - \frac{d_i}{2d_{\max}} \quad (2)$$

其中: $d_{\max}$ 为语法距离中的最大值。

上下文词 w_i 和目标方面词 a_i 的相对位置距离远近对目标方面词情感极性的影响也是不同的, 因此, 需要对文本词进行相对距离权重计算, 如式(3)所示:

$$l'_i = \begin{cases} 1 - \frac{\text{start} + 1 - i}{n}, & 1 \leq i < \text{start} + 1 \\ 0, & \text{start} + 1 \leq i \leq \text{start} + k \\ 1 - \frac{i - \text{start} - k}{n}, & \text{start} + k < i \leq n \end{cases} \quad (3)$$

其中: start 为目标方面词的开始索引; k 为目标方面词序列长度; n 为文本长度; i 为单词在文本中的位置。然后, 结合语法距离权重和相对距离权重生成新的距离权重表示:

$$q = (q_1, q_2, \dots, q_n)$$

$$q_i = \frac{l_i + l'_i}{2} \quad (4)$$

最后, 引入 q_i 更新文本包含的上下文语义信息隐藏层表示 $H^c = (h_1^c, h_2^c, \dots, h_n^c)$, 更新后的句子隐藏状态 $H^d = (h_1^d, h_2^d, \dots, h_l^d, \dots, h_n^d)$ 中包含了单词的位置信息和语义信息, 计算公式如式(5)所示:

$$h_i^d = q_i h_i^c \quad (5)$$

2.4 句法依存类型权重计算模块

对评论文本利用斯坦福句法分析器进行句法分析, 得到句法依存图 $G^s = (V^s, E^s)$, 其中: 节点集合 V^s 包含所有的文本词, 文本中的每一个单词代表一个节点; 边集 E^s 包含句法依存图中所有依存关系对应的边; 句法依存图的节点特征由经过 Bi-GRU 和距离编码模块的输出 H^d 来表示。按照依存关系类型的不同对邻接矩阵 A^s 进行权重计算, 具体过程如下:

1) 统计文本句法依存图的依存关系类型, 并将其嵌入表示为一个可训练的权重向量矩阵 $e_{i,j}^r$ 。

2) 对于句法依存图中文本词节点 x_i 和 x_j , 将两者之间依存关系类型对应的 $e_{i,j}^r$ 与图卷积神经网络的上一层文本词节点特征表示 h_i^{l-1} 和 h_j^{l-1} 进行拼接。对于图卷积操作的初始化特征, 使用文本经过 Bi-GRU 和语法距离编码之后的隐藏层输出 h_i^d 和 h_j^d 与 x_i 和 x_j 之间的依存关系类型嵌入向量 $e_{i,j}^r$ 进行拼接, 得到更新后的节点特征 s_i 和 s_j , 如式(6)、式(7)所示:

$$s_i^l = \text{Concat}(h_i^{l-1}, e_{i,j}^r) \quad (6)$$

$$s_j^l = \text{Concat}(h_j^{l-1}, e_{i,j}^r) \quad (7)$$

3) 根据式(8)利用未加权的句法依存图的邻接矩阵 A^s 中对应的值 $a_{i,j}$ 和更新后的节点特征 s_i 与 s_j , 计算得到节点 x_i 和 x_j 之间句法依存关系类型的权重 $p_{i,j}$, 生成初始的加权邻接矩阵 A^{ws} , 每一层图卷积操作前都根据式(6)~式(8)对 $p_{i,j}$ 进行更新计算。

$$p_{i,j}^l = \frac{a_{i,j} \cdot \exp(s_i^l \cdot s_j^l)}{\sum_{j=1}^n a_{i,j} \cdot \exp(s_i^l \cdot s_j^l)} \quad (8)$$

2.5 知识嵌入模块

本文将 SenticNet5^[25] 作为情感常识知识库, SenticNet5 知识库示例如表 1 所示。本节针对文本中的每一个单词, 从 SenticNet5 中查询提取相关的 5 个语义相近的概念词作为知识子图节点, 设置知识子图节点数量的上限值, 当一阶知识节点数量未达到上限值时, 可以将一阶知识节点作为概念词来提取二阶知识节点。最终构建的知识子图中包括文本词节点、知识子图节点、文本词与知识节点的连接关系以及知识子图节点之间的连接关系。

表1 SenticNet5知识库示例

Table 1 Example of SenticNet5 knowledge database

概念词	情感极性	情感极性值	与概念词语义相近的5个概念
abandon	negative	-0.840	'leave_alone','smelly_foot','unattractive','lose_team','leave_out'
caste	positive	0.063	'tribe','hierarchy','council','social_status','social_rank'
devil	negative	-0.800	'aggravated','exacerbate','exasperation','aggravate','provoked'
last	positive	0.067	'finish','end','finish_complete','end_point','finalize'

知识子图构建过程如图5所示,该图的节点集合 V^k 由文本词节点和知识子图节点组成,文本词节点的特征表示由包含上下文语义信息隐藏层表示 $H^c = (h_1^c, h_2^c, \dots, h_t^c, \dots, h_n^c)$ 来体现,知识节点的特征表示需要能够包含该节点在知识图中的结构特征和语义信息。affective-space情感词嵌入空间文档可以很好地将 SenticNet5 的知识信息映射到连续的低维嵌入矩阵 E^{aff} 中,同时不失去原始空间的语义和情感相关性,因此,知识子图节点的特征表示通过查找

affective-space 文件得到初始化的特征表示 $H^{\text{aff}} = (h_1^{\text{aff}}, h_2^{\text{aff}}, \dots, h_t^{\text{aff}}, \dots, h_m^{\text{aff}})$,其中, m 为知识子图中知识节点的个数。图 G^k 节点的整体特征表示记为 H^k ;边的集合 E^k 由文本词节点和知识节点之间的连接关系以及内部知识节点之间的连接关系组成。知识图的邻接矩阵 A^k 定义如式(9)所示:

$$A_{ij}^k = \begin{cases} 1, & i \text{ 和 } j \text{ 都是知识节点, } e_{ij} \in E^k \\ 1, & i = j \\ 0, & \text{其他} \end{cases} \quad (9)$$




图5 知识子图提取过程

Fig.5 Knowledge subgraph extraction process

2.6 图卷积神经网络层

图卷积神经网络处理加权句法依存图和知识子图,提取融合句法依存关系类型和外部常识信息的目标方面特征表示,以增强目标方面词的语义信息。

对于加权句法依存图 G^s ,将其邻接矩阵 A^{ws} 和特征表示 H^d 作为图卷积神经网络的输入,节点更新计算公式如式(10)所示:

$$h_i^{s(l)} = \sigma \left(\sum_{j=1}^n A^{ws} (W^{(l)} \cdot h_j^{d(l-1)} + b^{(l)}) \right) \quad (10)$$

其中: $W^{(l)}$ 是第 l 层权重矩阵; $b^{(l)}$ 是第 l 层偏置; n 为文本词的个数。

对于知识子图 G^k ,将其邻接矩阵 A^k 和特征表示 H^k 作为图卷积神经网络的输入,节点更新计算公式如式(11)所示:

$$h_i^{k(l)} = \sigma \left(\sum_{j=1}^{n+m} A^k (W^{(l)} \cdot h_j^{k(l-1)} + b^{(l)}) \right) \quad (11)$$

其中: m 为知识节点词的个数。

2.7 注意力层

本文模型对目标方面词的上下文语义特征 $H^a =$

$(h_1^a, h_2^a, \dots, h_t^a, \dots, h_k^a)$ 与图卷积神经网络输出的文本特征 $H^s = (h_1^s, h_2^s, \dots, h_t^s, \dots, h_n^s)$ 均采用注意力机制,从融合句法结构信息和距离编码信息的文本特征中提取对目标方面词重要的特征,计算公式如式(12)~式(14)所示,注意力层的输出记为 H^{sa} 。

$$\beta_i = \sum_{i=1}^k h_i^s (h_i^a)^T \quad (12)$$

$$\alpha_i = \frac{\exp(\beta_i)}{\sum_{i=1}^n \exp(\beta_i)} \quad (13)$$

$$H^{sa} = \sum_{i=1}^n \alpha_i h_i^s \quad (14)$$

2.8 情感分类层

针对融合了情感常识知识的特征表示 H^k ,通过方面遮罩层,将非目标方面词的特征表示置为0,保留目标方面词的特征表示 H^{ka} ,并将其与注意力机制的输出 H^{sa} 进行拼接作为最后的特征表示 r ,使用 Softmax 函数对其进行情感极性分类,如式(15)、式(16)所示:

$$\boldsymbol{r} = \text{Concat}(\boldsymbol{H}^{ka}, \boldsymbol{H}^{sa}) \tag{15}$$

$$\boldsymbol{y} = \text{Softmax}(\boldsymbol{w}\boldsymbol{r} + \boldsymbol{b}) \tag{16}$$

模型使用的损失函数为多分类交叉熵损失函数,交叉熵能够度量预测值与真实值概率分布的差异。本文模型有 3 个标签值,假设第 i 个样本预测为第 k 个标签的概率为 p_{ik} ,且 $\sum_{k=1}^3 p_{ik}=1$,其中,3 表示类别标签个数,样本数为 N ,则模型的损失函数如式(17)所示:

$$L = -\frac{1}{N} \sum_{i=1}^N \sum_{k=1}^3 y_{ik} \text{lb} p_{ik} \tag{17}$$

3 实验分析

3.1 数据集

本文实验采用来自 SemEval-2014^[26] 任务的 Laptop14 (Lap14) 和 Restaurat14 (Rest14) 数据集、SemEval-2015^[27] 任务的 Restaurat15 (Rest15) 数据集。表 2 中统计了数据集中方面词的情感极性分类,表 3 中统计了目标方面词长度大于等于 2 的词在数据集中所占的比例。

表 4 实验环境设置

Table 4 Experimental environment settings			
设备		参数	
CPU	Intel® Xeon® Silver 4210R CPU @ 2.40 GHz		
显存/GB	24		
操作系统	Ubuntu 18.04		
PyTorch	1.4.0		

设备		参数	
GPU	NVIDIA RTX 3090		
内存/GB	64		
Python	3.8		

表 5 模型参数设置

Table 5 Model parameter settings			
参数	设置	参数	设置
词嵌入维度	300	优化器	Adam
学习率	0.01	Batch size	32
训练迭代次数	30	Dropout rate	0.2
文本最大长度	120	知识节点个数	240

3.3 评价指标

本文实验使用准确率 (Acc) 和 F1 值作为评价指标。

准确率是分类任务的基本指标,其代表模型正确预测情感极性的数据与总数据的比例,计算如式(18)所示:

$$A_{\text{Acc}} = \frac{T_{\text{TP}} + T_{\text{TN}}}{T_{\text{TP}} + T_{\text{TN}} + F_{\text{FP}} + F_{\text{FN}}} \tag{18}$$

其中: T_{TP} 表示样本真实类别为正例、预测类别为正例的真正例; F_{FP} 表示样本真实类别为负例、预测类别为正例的假正例; T_{TN} 表示样本真实类别为负例、预测类别为负例的真负例; F_{FN} 表示样本真实类别为

表 2 数据集中的标签类别分布

Table 2 Distribution of label categories in datasets			
数据集	积极	消极	中性
Lap14-train	994	870	464
Lap14-test	341	128	168
Rest14-train	2 164	807	637
Rest14-test	728	196	196
Rest15-train	912	36	256
Rest15-test	326	34	182

表 3 方面词长度统计

Table 3 Aspect word length statistics		
数据集	方面词长度≥2的数据个数	方面词长度≥2的数据占比/%
Lap14-train	853	36.64
Lap14-test	287	45.00
Rest14-train	888	24.61
Rest14-test	316	28.21
Rest15-train	327	27.16
Rest15-test	157	28.97

3.2 实验平台及参数设置

本文实验环境及参数设置分别如表 4、表 5 所示。

正例、预测类别为负例的假负例。

精确率 (Precision) 是预测结果中真正例占预测结果为正例的数据的比例,计算公式如式(19)所示。召回率 (Recall) 是原始数据集中被正确预测为正例的数据占真正例数据的比例,计算公式如式(20)所示。F1 值计算公式如式(21)所示。

$$P_{\text{Precision}} = \frac{T_{\text{TP}}}{T_{\text{TP}} + F_{\text{FP}}} \tag{19}$$

$$R_{\text{Recall}} = \frac{T_{\text{TP}}}{T_{\text{TP}} + F_{\text{FN}}} \tag{20}$$

$$F1 = \frac{2 \times P_{\text{Precision}} \times R_{\text{Recall}}}{P_{\text{Precision}} + R_{\text{Recall}}} \tag{21}$$

3.4 对比模型

本文选用的基线对比模型有 3 类,分别为基于 LSTM 网络的模型 (TD-LSTM、ATAE-LSTM)、基于图卷积神经网络单独建模句法依存图的模型 (ASGCN、Bi-GCN)、联合建模外部知识和非加权句法依存图的 SK-GCN 模型。各模型介绍如下:

1) TD-LSTM^[11] 模型采用 2 个 LSTM 结构,分别对目标方面词之前的文本和目标方面词之后的文本

内容进行上下文语义建模,并将结果拼接起来进行情感判别。

2)ATAE-LSTM^[12]是一种结合注意力机制的情感分析模型,利用LSTM网络提取融合上下文语义的特征表示,然后将其与文本方面词的嵌入向量拼接起来,结合注意力机制提取对情感分析重要的信息,从而实现方面级情感倾向判别。

3)ASGCN^[14]首次使用图卷积神经网络建模句法依存图,模型通过双向LSTM建模文本的上下文语义,并对包含句法依存信息的目标方面词特征表示和文本的上下文语义信息进行注意力计算,从文本中提取对目标方面词比较重要的特征,从而进行方面级情感极性预测。

4)Bi-GCN^[28]是一种方面级情感分类模型,其利用双层交互式图卷积网络来融合语料库级别的单词共现信息和不同类型的句法依存关系。

5)SK-GCN^[20]基于图卷积神经网络分别建模句法依存图和常识知识子图,将提取的句法结构特征和常识知识特征进行拼接,融合句法信息和常识知识进行情感极性计算。

3.5 结果分析

实验结果如表6和图6所示,由表6、图6可以看出,SEGCN模型与ATAE-LSTM、TD-LSTM、ASGCN、Bi-GCN等基线模型相比,Acc和F1值在Lap14、Rest14和Rest15数据集上均有大幅提升,其中,准确率平均分别提高6.56%、4.56%和4.51%,F1值平均分别提高7.28%、5.71%和6.28%。

表6 3个数据集上的实验结果

Table 6 Experimental results on three datasets %

模型类别	模型名称	Lap14		Rest14		Rest15	
		Acc	F1	Acc	F1	Acc	F1
基线模型	ATAE-LSTM	68.85	63.88	78.56	67.00	78.42	62.79
	TD-LSTM	71.82	68.40	78.14	68.43	76.37	58.65
	ASGCN	75.55	71.05	80.77	72.02	79.89	61.89
	Bi-GCN	74.59	71.84	81.97	73.48	81.86	64.79
	SK-GCN	79.31	75.11	81.87	73.42	82.72	63.34
消融实验模型	SEGCN-p-w	78.83	74.79	83.45	74.67	82.21	65.68
	SEGCN-p	79.76	76.18	84.36	75.12	83.73	67.45
本文模型	SEGCN	80.58	77.34	84.82	76.58	84.36	68.57




图6 模型性能比较结果

Fig.6 Comparison results of models performance

ATAE-LSTM、TD-LSTM模型无法有效建模图结构数据,因此,不能有效提取句法依存图的信息;ASGCN、Bi-GCN模型为单独建模句法依存信息,因此,无法有效利用外部知识来丰富方面词语义;SK-GCN模型虽然联合建模了句法知识和常识知识信息,但是忽略了文本词的语义距离特征和句法依存图的句法依存类型特征,因此,不能充分提取句法结构特征;本文SEGCN模型对句法依存图、外部常识知识以及方面短语的语义信息进行联合建模,利用特征信息来对目标方面词的语义进行增强,从而提高了模型的分类准确率。

在表6的消融实验中,SEGCN-p-w模型联合建模句法信息和外部知识信息以及融合由多词组成的目标方面短语的语义信息,不考虑句法依存关系类型和语法距离位置信息,SEGCN-p为本文所提SEGCN去掉位置编码模块的模型。通过对比SEGCN模型与SEGCN-p-w模型的实验结果可以看出,相比SEGCN-p-w模型,SEGCN模型的准确率在3个数据集上分别提高了1.75%、1.37%、2.15%,这是因为SEGCN模型在SEGCN-p-w模型的基础上构建了加权的句法依存图,为不同依存关系类型赋予不同的权重,然后使用图卷积神经网络进行卷积操作,从而有效提取句法依存图中丰富的结构特征。除此之外,SEGCN模型还为句法依存图融合了语法距离和相对位置距离信息,有助于从上下文中提取与目标方面词最相关的特征。实验结果表明,基于图卷积神经网络建模基于依存关系类型加权的句法依存图,可以更加充分地提取文本的句法结构特征,从而提高模型性能。对于去掉位置编码模块的SEGCN-p模型,其性能优于SEGCN-p-w模型,但与SEGCN模型相比还有一定差距,这说明加权的句法依存关系确实有助于模型对句法结构特征进行更全面的特征提取,但仍不能忽略单词之间的相对位置特征。

3.6 样例分析

为了更直观地理解文本句法依存关系类型加权邻接矩阵以及文本语法距离权重分布,本文针对上述权重分布进行可视化。对评论语句“great food but the service was dreadful.”进行句法依存分析,其邻接关系如图7所示,其中,区域颜色代表单词之间的注意力权重(彩色效果见《计算机工程》官网HTML版,下同)。普通的句法依存图邻接矩阵被定义为二进制,2个文本词之间存在句法依存关系时用1表示,否则用0表示,因此,图7中有邻接关系的区域颜色相同。




图7 句法依存邻接关系示例

Fig.7 Example of syntactic dependency adjacency relationships

基于句法依存关系类型对上述评论文本构建加权的邻接矩阵,为不同依存关系类型对应的词节点之间的边分配不同权重,其邻接关系如图8所示,其中,区域颜色代表不同邻接关系的权重。




图8 加权句法依存邻接关系示例

Fig.8 Example of weighted syntactic dependency adjacency relationships

对于评论句“great food but the service was dreadful.”而言,与方面词“service”语法距离不同的单词权重不同,语法距离越小,句法依存关系越紧密,权重值越大,其语法距离权重分布如图9所示。



图9 语法距离权重分布示例

Fig.9 Example of syntax distance weight distribution

从图7~图9可以看出,基于句法依存关系类型加权的邻接矩阵对与方面词句法依存关系不同的文本词特征赋予了不同的权重,对文本进行语法距离特征与相对位置距离特征联合编码的方式,使得文本词中与方面词语法距离近且相对位置也近的单词被赋予了较高的权重,因此,通过图卷积神经网络建模融合了位置编码信息的加权句法依存图,可以融合句法依存类型特征、语法距离特征以及相对位置特征等多种信息,可以从文本中提取对方面词而言更重要的特征,从而增强了方面词语义。

4 结束语

本文提出一种基于语义增强的图卷积神经网络

方面级情感分析模型,利用多种外部知识增强目标方面词的语义信息,提高模型分类的准确率。为不同的句法依存关系类型设置不同的权重,构建加权的句法依存图,利用图卷积神经网络建模该句法图,以充分提取文本的句法结构特征。同时,模型融合文本单词的语法距离、位置信息及外部情感知识来丰富方面词的信息,实现多种外部知识的融合。实验结果表明,相对ATAE-LSTM、TD-LSTM等基线模型,该模型在3个公开数据集上的准确率和F1值均得到显著提升。然而,本文仅利用外部情感词典作为知识库来增强方面词背景知识,考虑到RippleNet网络的特征提取效果与在水上上传播的实际涟漪类似,可以自动和迭代地沿着知识图中的链接来扩展文本词的外部常识知识,从而建模知识图谱中的三元组关系。因此,下一步将使用RippleNet网络来对知识图谱进行建模,更全面地提取知识图谱的结构信息以丰富方面词语义。

参考文献

- [1] 赵妍妍,秦兵,刘挺. 文本情感分析[J]. 软件学报,2010,21(8):1834-1848.
ZHAO Y Y, QIN B, LIU T. Sentiment analysis[J]. Journal of Software, 2010, 21(8):1834-1848. (in Chinese)
- [2] LIU B. Sentiment analysis and opinion mining[M]. Berlin, Germany: Springer, 2012.
- [3] 张璞,李道,刘畅. 基于规则的评价搭配抽取方法[J]. 计算机工程,2019,45(8):217-223.
ZHANG P, LI X, LIU C. Evaluation collocation extraction method based on rules[J]. Computer Engineering, 2019, 45(8):217-223. (in Chinese)
- [4] 杨梦琳,卢益清. 基于在线评论的生鲜电商顾客满意度分析研究[J]. 中国物流与采购,2022(6):44-46.
YANG M L, LU Y Q. Analysis and research on customer satisfaction of fresh E-commerce based on online comments[J]. China Logistics & Purchasing, 2022(6):44-46. (in Chinese)
- [5] MISURACA M, SCEPI G, SPANO M. Using opinion mining as an educational analytic: an integrated strategy for the analysis of students' feedback [J]. Studies in Educational Evaluation, 2021, 68: 100979.
- [6] HU M Q, LIU B. Mining and summarizing customer reviews[C]// Proceedings of the 10th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York, USA: ACM Press, 2004:168-177.
- [7] 姜德成,姚天昉. 汉语句子语义极性分析和观点抽取方法的研究[J]. 计算机应用,2006,26(11):2622-2625.
LOU D C, YAO T F. Semantic polarity analysis and opinion mining on Chinese review sentences[J]. Journal of Computer Applications, 2006, 26(11):2622-2625. (in Chinese)
- [8] 朱嫣岚,闵锦,周雅倩,等. 基于HowNet的词汇语义倾向计算[J]. 中文信息学报,2006,20(1):14-20.
ZHU Y L, MIN J, ZHOU Y Q, et al. Semantic orientation

- computing based on HowNet[J]. Journal of Chinese Information Processing, 2006, 20(1): 14-20. (in Chinese)
- [9] KIRITCHENKO S, ZHU X D, CHERRY C, et al. NRC-Canada-2014: detecting aspects and sentiment in customer reviews[C]//Proceedings of the 8th International Workshop on Semantic Evaluation. [S. l.]: Association for Computational Linguistics, 2014: 437-442.
- [10] LIN C H, HE Y L, EVERSON R, et al. Weakly supervised joint sentiment-topic detection from text[J]. IEEE Transactions on Knowledge and Data Engineering, 2012, 24(6): 1134-1145.
- [11] TANG D Y, QIN B, FENG X C, et al. Effective LSTMs for target-dependent sentiment classification[EB/OL]. [2022-04-05]. <https://aclanthology.org/C16-1311.pdf>.
- [12] WANG Y Q, HUANG M L, ZHU X Y, et al. Attention-based LSTM for aspect-level sentiment classification[C]//Proceedings of 2016 Conference on Empirical Methods in Natural Language Processing. [S. l.]: Association for Computational Linguistics, 2016: 606-615.
- [13] MA D H, LI S J, ZHANG X D, et al. Interactive attention networks for aspect-level sentiment classification[EB/OL]. [2022-04-05]. <https://arxiv.org/pdf/1709.00893.pdf>.
- [14] ZHANG C, LI Q C, SONG D W. Aspect-based sentiment classification with aspect-specific graph convolutional networks[C]//Proceedings of 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing. [S. l.]: Association for Computational Linguistics, 2019: 4560-4570.
- [15] XIAO L W, HU X H, CHEN Y N, et al. Targeted sentiment classification based on attentional encoding and graph convolutional networks[J]. Applied Sciences, 2020, 10(3): 957.
- [16] 施荣华, 金鑫, 胡超. 基于图注意力网络的方面级文本情感分析[J]. 计算机工程, 2022, 48(2): 34-39.
- SHI R H, JIN X, HU C. Aspect-level text emotion analysis based on graph attention network[J]. Computer Engineering, 2022, 48(2): 34-39. (in Chinese)
- [17] ZHAO P L, HOU L L, WU O. Modeling sentiment dependencies with graph convolutional networks for aspect-level sentiment classification[J]. Knowledge-Based Systems, 2020, 193: 105443.
- [18] MENG F Y, FENG J L, YIN D P, et al. Sentiment analysis with weighted graph convolutional networks[C]//Proceedings of 2020 Conference on Empirical Methods in Natural Language Processing. [S. l.]: Association for Computational Linguistics, 2020: 586-595.
- [19] 巫浩盛, 缪裕青, 张万桢, 等. 基于距离与图卷积网络的方面级情感分析[J]. 计算机应用研究, 2021, 38(11): 3274-3278, 3321.
- WU H S, MIAO Y Q, ZHANG W Z, et al. Aspect level sentiment analysis based on distance and graph convolution network[J]. Application Research of Computers, 2021, 38(11): 3274-3278, 3321. (in Chinese)
- [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] 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.
- [22] MANNING C, SURDEANU M, BAUER J, et al. The stanford CoreNLP natural language processing toolkit[C]//Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics: System Demonstrations. [S. l.]: Association for Computational Linguistics, 2014: 55-60.
- [23] 苏锦钊, 欧阳志凡, 余珊珊. 基于依存树及距离注意力的句子属性情感分类[J]. 计算机研究与发展, 2019, 56(8): 1731-1745.
- SU J D, OUYANG Z F, YU S S. Aspect-level sentiment classification for sentences based on dependency tree and distance attention[J]. Journal of Computer Research and Development, 2019, 56(8): 1731-1745. (in Chinese)
- [24] 马帅, 刘建伟, 左信. 图神经网络综述[J]. 计算机研究与发展, 2022, 59(1): 47-80.
- MA S, LIU J W, ZUO X. Survey on graph neural network[J]. Journal of Computer Research and Development, 2022, 59(1): 47-80. (in Chinese)
- [25] CAMBRIA E, PORIA S, HAZARIKA D, et al. SenticNet5: discovering conceptual primitives for sentiment analysis by means of context embeddings[C]//Proceedings of the 32th AAAI Conference on Artificial Intelligence. [S. l.]: AAAI Press, 2018: 1795-1802.
- [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. [S. l.]: Association for Computational Linguistics, 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. [S. l.]: Association for Computational Linguistics, 2015: 486-495.
- [28] ZHANG M, QIAN T Y. Convolution over hierarchical syntactic and lexical graphs for aspect level sentiment analysis[C]//Proceedings of 2020 Conference on Empirical Methods in Natural Language Processing. [S. l.]: Association for Computational Linguistics, 2020: 3540-3549.