

基于BERT模型和图注意力网络的方面级情感分析

林煌, 李弼程

引用本文

林煌, 李弼程. 基于BERT模型和图注意力网络的方面级情感分析[J]. 计算机科学, 2024, 51(11A): 240400018-7.

LIN Huang, LI Bicheng. Aspect-based Sentiment Analysis Based on BERT Model and Graph Attention Network [J]. Computer Science, 2024, 51(11A): 240400018-7.

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)

[MB-ATMK:融合属性权重和时序元知识的多行为序列推荐模型](#)

MB-ATMK: Multi-behavior Sequential Recommendation Integrating Attribute Weights and Temporal Meta-knowledge

计算机科学, 2024, 51(11A): 231100047-9. <https://doi.org/10.11896/jsjcx.231100047>

[基于相似性增强传播结构的谣言检测](#)

Rumor Detection Based on Similarity-enhanced Propagation Structure

计算机科学, 2024, 51(11A): 240200116-8. <https://doi.org/10.11896/jsjcx.240200116>

[FCTNet:基于双域深度学习的公交车到站时间预测方法](#)

FCTNet: Bus Arrival Time Prediction Method Based on Dual Domain Deep Learning

计算机科学, 2024, 51(11A): 231000180-7. <https://doi.org/10.11896/jsjcx.231000180>

[基于季节分解的混合神经网络的时间序列预测](#)

Time Series Prediction of Hybrid Neural Networks Based on Seasonal Decomposition

计算机科学, 2024, 51(11A): 231200008-7. <https://doi.org/10.11896/jsjcx.231200008>

[基于相对位置编码转换器模块的深度步态识别网络](#)

Deep Gait Recognition Network Based on Relative Position Encoding Transformer

计算机科学, 2024, 51(11A): 240400064-6. <https://doi.org/10.11896/jsjcx.240400064>

基于 BERT 模型和图注意力网络的方面级情感分析

林 煌 李弼程

华侨大学计算机科学与技术学院 福建 厦门 361021

(1209285067@qq.com)

摘 要 方面级情感分析是一项细粒度的情感分析任务,旨在对给定文本中的特定方面进行情感极性分析。当前基于语法分析的方法严重依赖于依存树的单一解析结果,并且大部分研究对于语义和语法特征的融合并不充分。因此,提出了一种基于 BERT 模型和图注意力网络的方面级情感分析方法。该方法能够充分挖掘句子结构中的语义和语法信息,并通过交互注意力机制融合这些信息,从而获得更精确的情感特征。首先,利用 BERT 预训练模型得到文本的初始化向量,并使用注意力机制对方面词进行全局的语义信息关联,得到文本的语义特征。其次,利用语法解析器构建短语结构图和依存图,并利用图注意力网络对节点信息进行编码,得到文本的语法特征。最后,通过交互注意力机制结合学习到的语义和语法特征,实现了多个视角的融合,从而全面理解方面-观点关系。实验结果表明,所提方法在多个数据集上的 ACC 值和 F1 值均优于现有的多个先进方法。

关键词: 方面级情感分析;语法分析;图注意力网络;注意力机制

中图分类号 TP391.1

Aspect-based Sentiment Analysis Based on BERT Model and Graph Attention Network

LIN Huang and LI Bicheng

College of Computer Science and Technology, Huaqiao University, Xiamen, Fujian 361021, China

Abstract Aspect-based sentiment analysis is a fine-grained sentiment analysis task that aims to analyze the sentiment polarity of specific aspects in a given text. Current syntax-based methods heavily rely on a single parsing result from the dependency tree, and most of the existing research lacks sufficient integration of semantic and syntactic features. Therefore, this paper proposes an aspect-based sentiment analysis approach based on the BERT model and graph attention network. This method can effectively explore the semantic and syntactic information in sentence structures and fuse these information through an interactive attention mechanism to obtain more accurate sentiment features. Firstly, the BERT pre-trained model is utilized to obtain the initial vectors of the text, and an attention mechanism is employed to associate the global semantic information of aspect words, resulting in the semantic features of the text. Secondly, a syntax parser is used to construct a phrase structure graph and a dependency graph, and a graph attention network is applied to encode the node information, leading to the syntactic features of the text. Finally, through an interactive attention mechanism, the learned semantic and syntactic features are combined to achieve a comprehensive understanding of aspect-opinion relationships from multiple perspectives. Experimental results show that the proposed method outperforms the existing state-of-the-art methods with ACC and F1 values on multiple datasets.

Keywords Aspect-based sentiment analysis, Syntax analysis, Graph attention network, Attention mechanism

1 引言

方面级情感分析是一项细粒度的情感分析任务,旨在准确提取文本中的情感方面,并对方面的情感极性进行分类。随着互联网的迅速发展和数字化信息的爆炸增长,网络上充斥着网民发表的大量信息和观点。这些信息和观点不仅能够迅速产生舆论效应,还能够潜移默化地影响人们的思想,改变人们的观念。因此,对网络上的观点进行细粒度情感分析,对于科学监管和引导互联网环境具有重要的社会治理和商业经济效益。然而,面对网上复杂多样的情感评论句子,如何有效地捕捉评论句子中的情感目标和情感

极性对是细粒度情感分析任务的难点。

在方面级情感分析早期的研究中,研究人员将注意力机制融入序列化模型^[1-3],这些方法通常假设与目标方面相关的词语更靠近目标。然而,在处理复杂句子时,这些假设可能失效。例如,在句子“The price is very nice but the environment and service are terrible”中,“environment”对应的情感词应该是“terrible”,但模型可能会将其对应到“nice”上,导致目标情感极性错误。为了解决这个问题,研究人员利用语法知识构建模型^[4],如树型 MSNN 和 TreeLSTM,这些研究已经证明了语法知识对情感分析是有效的^[5]。近年来,随着图数据的快速增长,图神经网络在方面级情感分析中得到广泛研究。

基金项目:装备预研教育部联合基金(8091B022150)

This work was supported by the Joint Fund of Equipment Pre-research and Ministry of Education(8091B022150).

通信作者:李弼程(lbclm@163.com)

这些研究证明了图神经网络在捕获知识方面具有强大的能力。一些学者^[6]通过构建不同的语法图神经网络来有效利用非顺序信息,从而显著提高情感分析的准确率。然而,这些模型受到语法解析工具准确性的影响,而且依存树结构可能引入噪声,对捕捉每个方面的情感词产生影响。因此,研究人员^[7]通过改造依存树结构或构造适合方面级情感分析任务的结构来提高句子的语法结构的有效性,并且取得了良好的效果。

以往的研究已经证明语法信息对情感分析至关重要,但是单一语法结构对于一些复杂句子的建模能力有限。为了解决这一问题,本文提出了一种基于 BERT 模型和图注意力网络的方面级情感分析方法。该方法旨在通过引入短语结构来完善句子语法结构,并利用交互注意力机制结合语义和语法信息,得到句子情感的综合表示。具体来说,首先,使用 BERT 模型获取句子的语义信息;其次,使用语法解析器分别获取句子的短语结构图和依存图,通过图注意力网络对图节点进行编码;接下来,通过交互注意力机制将语义和语法特征充分融合;最后,将融合的语义和语法信息的情感特征输入到情感分类层,得到最终的情感分类结果。本文的贡献主要如下:

1) 提出了一种具有多语法结构的方面级情感分析方法,通过引入短语结构来弥补仅依赖依存关系的缺陷,增强对复杂句子中情感信息对的捕获;

2) 在语义特征和语法特征融合时引入交互注意力机制,通过交互注意力机制可以有效结合学习到的语义和语法信息,得到具有基本语义信息、短语结构信息和依存关系信息的句子情感综合特征;

3) 在 4 个基准数据集上进行对比实验,本文方法在多个数据集上优于当前较先进的方法。

2 相关工作

2.1 基于注意力机制的方面级情感分析

早期学者通过人工设计直接提取与目标相关的情感信息进行方面级情感分析^[8],然而,这些方法具有一定的主观性和局限性,特征选择高度依赖于研究人员的主观判断。因此,研究人员希望从目标信息中挖掘情感信息,但这些方法并未考虑上下文信息。为了有效将目标信息和上下文信息进行充分联系,基于注意力机制的方面级情感分析方法逐渐成为主流方法。Wang 等^[9]将注意力机制加入到 LSTM 模型中,旨在使模型能够关注目标对应的关键信息。Chen 等^[10]考虑到单一的注意力机制仅能捕获很少的目标信息,提出基于多重注意力机制的神经网络模型来捕获长距离文本中特定方面词的情感极性。Ma 等^[11]为了充分利用上下文信息,协调方面词与上下文词的依赖关系,提出了多粒度注意力模型。Lu 等^[12]将传统方法与注意力机制结合,提出了基于规则的交互式注意力神经网络模型,进一步提高了目标与上下文信息的交互能力。

2.2 基于预训练模型的方面级情感分析

在方面级情感分析研究中,通常使用预训练模型处理输入文本,并将其整合到更深层的神经网络中。Xv 等^[13]基于 BERT 模型探索了一种新型后训练方法来充分增强文本语义表示。为了将动态语义与模型融合,Song 等^[14]通过将目标词直接附加到上下文句子中来准备输入序列,利用 BERT 模

型对输入序列进行编码以获得更准确的情感分析结果。Zhang 等^[15]为了融合动态语义信息,基于 BERT 模型,通过动态加权分配来更好地进行情感分析。此外,一些学者将方面级情感分析任务转换为生成任务。例如,Yan 等^[16]利用变分自编码器和生成对抗网络,通过 BERT 对方面和情感信息进行编码与生成,实现了文本的生成和情感分析的结合。

2.3 基于图神经网络的方面级情感分析

上述方法虽然在方面级情感分析中有着广泛应用,但是无法深入挖掘句子中的语法结构信息,难以对具有多个方面的复杂句子进行有效建模。为了解决这些问题,Zhang 等^[17]通过图卷积神经网络对句子中的方面和观点之间的依存关系进行建模,证明了语法信息对于方面级情感分析任务的重要性。Li 等^[18]利用图神经网络同时处理两个图来建模方面-观点和观点-上下文之间的依赖关系,更好地捕捉方面、观点和上下文之间的复杂依赖关系。Liang 等^[19]通过引入情感知识图作为额外的信息源,结合语法结构图和情感知识图的信息,利用图卷积神经网络更新节点表示,使模型能够更好地捕捉方面和情感之间的关系。此外,针对特定方面词的分析,Chen 等^[20]通过计算方面词和情感词的关联度来构建观点树,并利用图卷积神经网络对节点信息进行编码得到最终情感。Zhao 等^[21]通过设计一个距离重要性函数对依存关系结构进行改造,更好地利用了依存语法结构信息。Zhao 等^[22]整合了语法结构图以及知识图等多种知识来增强语义特征。以上许多工作都利用了依存树结构的语法信息,但是依存树的固有结构存在噪声,会对方面级情感分析任务产生一定影响。因此,本文希望通过引入短语结构来得到更加全面的语法信息。此外,针对文本语义和语法信息的交互融合不充分的问题,本文利用交互注意力机制来学习具有语义和语法信息的综合情感特征。

3 基于 BERT 模型和图注意力网络的方面级情感分析方法

3.1 方法定义

在方面级情感分析任务中,给定一个句子对 $D=(S,A)$, $S=[w_1, w_2, \dots, w_n]$ 表示长度为 n 的句子, $A=[a_1, a_2, \dots, a_k]$ 表示不同方面词的序列,方面词 $a_i=[w_i, w_{i+1}, \dots, w_{i+m-1}]$ 最多由 m 个词组成,预测方面词子序列 A 所对应的情感极性是本文的研究目标。

本文提出了一种基于 BERT 模型和图注意力网络的方面级情感分析方法,如图 1 所示,其中包括输入层、编码层、注意力层、图注意力层、交互注意力层以及输出层。

输入层获取文本序列中每个单词的初始化表示;编码层利用 BERT 作为句子初始嵌入的提取器,分别获取隐藏的上下文及方面词的向量表示,输出具有丰富语义特征的词序列;注意力层通过注意力机制引导文本中的各个单词进行交互学习,获取文本语义信息的内部关联关系;图注意力层利用语法解析工具得到短语结构图和依存树的语法结构图,通过图注意力网络聚合目标方面词的节点信息,从而捕获更丰富的层次的语法信息;交互注意力层则利用交互注意力机制结合学习到的语义和语法信息;最后,输出层将获取的结果输入到

情感分类器来获取目标方面的情感极性。

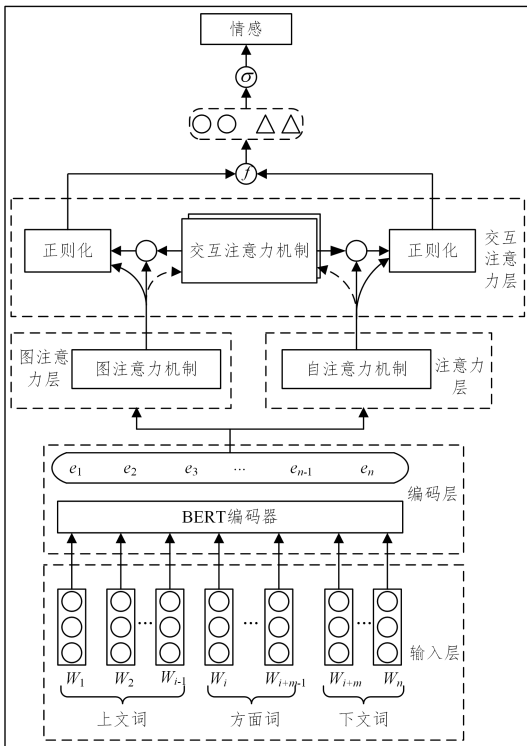


图1 方法流程图

Fig.1 Method flow chart

3.2 编码层

BERT 预训练语言模型在自然语言处理领域中具有巨大贡献,其利用 Transformer 模型的 Encoder 层对待预测文本序列进行特征提取。大量研究都证明,通过 BERT 模型来获取文本单词的初始化表示能够显著提高方面级情感分析任务的准确率。因此,采用 BERT 模型作为词嵌入提取器。

本文方法通过构造辅助句子对的方式将原始文本序列与方面词拼接输入到 BERT 模型,其输入方式为:

$$Input=[CLS]+S+[SEP]+a_i+[SEP] \quad (1)$$

其中,[CLS]是 BERT 模型中代表句子的开头的特殊标记符;[SEP]用来分隔不同句子或序列的特殊标记符。

3.3 注意力层

注意力机制能够根据计算权重度量不同位置信息特征的重要性来捕捉各文本单词之间的依赖关系,从而得到全局语义信息。利用注意力得分矩阵更新文本序列表示:

$$h_b = \text{softmax}\left(\frac{E \cdot E^T}{\sqrt{d_k}}\right)E \quad (2)$$

其中,\$E\$为编码层得到的文本初始化表示;\$d_k\$为词嵌入向量维度;\$h_b\$是最终文本语义特征。

3.4 图注意力层

3.4.1 语法分析

语法分析^[23-24]是用于分析句子内部的语言依赖关系的一种重要技术手段,能够将给定的文本序列转换成具有丰富语法信息的图形结构。本文分别将输入文本序列转换成短语结构树和依存树结构来获取更加全面的语法信息。短语结构树通过准确且区分明确的短语分割和层级结构来表示句子的语法信息。而依存树则更关注单词之间的语法联系。两种语法结构能够广泛应用于方面级情感分析和关系抽取等场景。短语结构树和依存树的结构如图 2 和图 3 所示。




图2 短语结构树结构

Fig.2 Structure of phrase structure tree

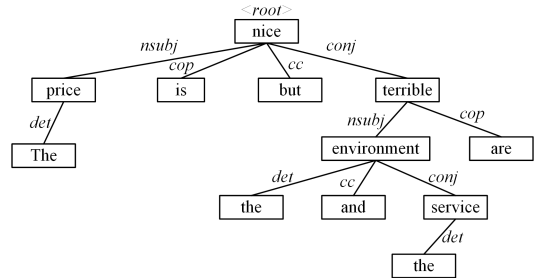


图3 依存树结构

Fig.3 Structure of dependency tree

LAL-Parser^[25]是一种基于局部注意力机制的语法分析器。它是一种轻量级的、高效的语法分析模型,用于将自然语言句子转换为具有丰富语法信息的图形结构。因此,本文使用解析工具 LAL-Parser 生成输入文本相应的短语结构树和依存树结构图。具体过程如图 4 所示。




图4 结构树解析过程

Fig.4 Parsing procedure of structure tree

3.4.2 语法图的构建

如图 2 所示,本文以自底向上的方式遵循短语结构树的语法结构。短语结构树的每一层都由组成输入文本的几个短语组成,每个短语代表一个单独的语义单元。因此,该图包含 \$n\$ 个节点,每一层可以表示成不同的邻接矩阵 \$CA^l\$,同一短句内的单词可视为构成一个小的全连接图,即:

$$CA_{i,j}^l = \begin{cases} 1, & \text{如果 } \omega_i, \omega_j \text{ 位于同一个短句中} \\ 0, & \text{否则} \end{cases} \quad (3)$$

其中,\$CA_{i,j}^l\$表示语法结构树第 \$l\$ 层构建的邻接矩阵;\$\omega_i\$和\$\omega_j\$表示句子的不同单词。

依存树结构同样可以表示成包含 \$n\$ 个节点的邻接矩阵 \$DA_{i,j}\$,图中节点代表句子中的单词,单词之间的依存关系用边连接,即:

$$DA_{i,j} = \begin{cases} 1, & \text{如果 } \omega_i, \omega_j \text{ 在依存树结构中直接连接} \\ 0, & \text{否则} \end{cases} \quad (4)$$

其中,\$DA_{i,j}\$表示依存句法树构建的邻接矩阵;\$\omega_i\$和\$\omega_j\$表示句子上的不同单词。

接下来将两种语法信息进行融合,对边进行按位置相加操作,从而得到包含两种语法信息的邻接矩阵图:

$$FA = CA \oplus DA \quad (5)$$

其中, FA 表示包含依存句法树和短语结构树语法信息的邻接矩阵图; CA 表示短语结构树的邻接矩阵图; DA 表示依存树的邻接矩阵图。

3.4.3 图注意力网络

通过上述过程得到了包含两种语法信息的图,相对于由单一语法树结构的图,具有更加丰富的语法信息。为了捕获更加丰富的层级特征,本文使用多层图注意力网络来聚合节点信息。多层图注意力网络的结构如图 5 所示。




图 5 图注意力网络

Fig. 5 Graph attention network

图注意力网络在图神经网络的基础上增加了注意力机制,可以利用注意力机制来聚合相邻的信息,并利用一个完全连接的前馈网络将表示映射到相同的语义空间。注意力机制可以处理邻接词的多样性,并赋予更多的相关词更高的权重,具体表述如下:

$$h_i^{t,l} = \parallel \sum_{j \in N^l(i)} \alpha_{ij}^k W_h^k \hat{h}_j^{t,l-1} \quad (6)$$

$$\alpha_{ij}^k = \frac{\exp(f(\hat{h}_i^{t,l-1}, \hat{h}_j^{t,l-1}))}{\sum_{j \in N^l(i)} \exp(f(\hat{h}_i^{t,l-1}, \hat{h}_j^{t,l-1}))} \quad (7)$$

$$\hat{h} = FC(h_i^{t,l} + \hat{h}_i^{t,l-1}) \quad (8)$$

其中, $N^l(i)$ 为第 l 层单词 w_i 的邻居集合; $\hat{h}_i^{t,l-1}$ 为第 l 层 w_i 的最终表示; $FC()$ 为全连接层; $h_i^{t,l}$ 是 w_i 在注意力机制后的表示; \parallel 表示向量连接; Z 表示为注意力头数; σ 为激活函数; W_h^k 是第 l 层第 k 个头的可训练参数; $f()$ 是衡量单词的相关性分数函数。

可以将图注意力网络简化为:

$$h_p = GAT(H, A; \theta) \quad (9)$$

其中, $H \in R^{(n+k) \times d_{\text{hid}}}$ 表示节点特征; $A \in R^{(n+k) \times (n+k)}$ 表示图的邻接矩阵; θ 表示参数集; h_p 表示得到的文本语法结构特征。

3.5 交互注意力层

交互注意力机制用于实现语义和语法信息的融合,促进模型得到更全面的文本情感信息。基本语义 h_b 反映了词的隐藏状态,语法 h_p 反映了句子的语法结构,这两种信息从不同的角度反映了句子的特征。为了充分结合两种不同侧重点的信息,设计了交互注意力机制。首先,将基本语义信息 h_b 和语法信息 h_p 输入到交互注意力模块中,得到每个词各自的注意分数 a_b 和 a_p 。

$$a_b = \text{softmax}(h_b h_b^T) \quad (10)$$

$$a_p = \text{softmax}(h_p h_p^T) \quad (11)$$

其中, $a_b \in R^{n \times n}$ 记录了单词之间的语义相关性,反映语义上的紧密密度; $a_p \in R^{n \times n}$ 表示关于词的语法相关性信息。

为了两种信息可以相互作用,增强表达,本文通过注意力分数 a_b (a_p) 相互作用于语义和语法特征 h_b (h_p),充分融合两种信息,即:

$$h_b' = \text{Dropout}(a_p h_b) + h_b \quad (12)$$

$$h_p' = \text{Dropout}(a_b h_p) + h_p \quad (13)$$

其中, h_b' 表示充分融合语法信息的语义特征; h_p' 表示充分融合语义信息的语法特征; Dropout 表示正则化层,用来抵抗梯度传播误差。

通过上述交互,得到最终的语义和语法输出和作为交互注意力层的输出,并将其输入到输出层中。

3.6 输出层

将交互后的语义和语法输出信息结合起来形成最终的表示,然后用 softmax 激活函数将其馈送到全连接层,生成 3 种情绪极性的概率:

$$O_i = h_b' + h_p' \quad (14)$$

$$p(t) = \text{softmax}(W_i O_i + b_i) \quad (15)$$

其中, O_i 表示充分融合的语法和语义特征; W_i 和 b_i 表示可学习参数; $p(t)$ 表示最终预测结果。

3.7 损失函数

损失定义为极性标签与所有(句子、方面)对的预测极性分布之间的交叉熵损失:

$$L(\theta) = - \sum_{t, a_i \in A_s} \sum_{t} \text{loss}(p(t), y(t)) \quad (16)$$

其中, $p(t)$ 表示预测标签; $y(t)$ 表示真实标签; $\text{loss}()$ 是标准交叉熵损失。

4 实验结果与分析

4.1 实验数据集

实验使用 SemEval-2014 Task4^[26] 中的 Restaurant14 和 Laptop14 两个数据集,以及 Twitter 数据集^[27] 和 MAMS 数据集^[28] 来验证方法的有效性。

具体而言,Restaurant14, Laptop14 和 Twitter 数据集的每条评论都包含了一个或多个方面及其对应情感极性标签。而 MAMS 是近两年更具有挑战性的数据集,每个评论都至少有两个及两个以上的方面及其对应的情感标签。数据集详细样本数量统计如表 1 所列,在这 4 个公开数据集中的评论信息中,每个句子中的方面词都对应 3 种不同的情感极性。

表 1 数据集分布

Table 1 Dataset distribution

数据集名称	积极(+1)	中性(0)	消极(-1)
Restaurant14 训练集	2164	637	807
Restaurant14 测试集	727	196	196
Laptop14 训练集	976	455	851
Laptop14 测试集	337	167	128
Twitter 训练集	1507	3016	1528
Twitter 测试集	172	336	169
MAMS 训练集	3380	5042	2764
MAMS 测试集	400	607	329

4.2 对比方法

为了进一步验证本文方法的有效性,分别选取以下有代表性的方法作为对比方法进行实验。

1)MGAN^[29]:通过结合 BiLSTM 和多粒度注意机制,充分利用上下文信息,并对不同粒度的信息进行加权处理,有效提高了模型的性能。

2)RAM^[30]:通过结合 RNN 和注意力机制,使模型能够对序列中的不同部分进行建模和关注,从而提高了模型的性能。

3)AEN^[14]:通过引入门控机制和注意力机制,能够有效捕捉文本评论中不同方面的情感信息,并提高模型的性能。

4)BERT-SPC^[14]:将“[CLS]+句子+[SEP]+方面+[SEP]”作为输入序列输入到BERT模型,最后通过平均池化送入到情感分类层。

5)CDT^[31]:通过在依存树上应用卷积操作,能够更好地建模方面级情感信息,从而提高模型的性能。

6)RGAT^[27]:通过引入关系图注意力网络,使模型能够更好地捕捉句子中单词之间的复杂关系,并提高模型性能。

7)AEGCN^[32]:通过引入多头注意力机制和GCN来聚合语义和语法信息,并在GCN加入注意力机制来提高模型性能。

8)RMN^[33]:通过GCN编码依存图来生成方面表示,并且引入双向注意力机制来获取方面和上下文之间的关系。

4.3 实验环境与参数配置

本文基于Pytorch框架搭建实验环境,具体配置如表2所列。

表2 实验环境

Table 2 Experimental environment

实验环境	环境配置
操作系统	Windows10 专业版 64 位
CPU	Intel(R) Core(TM) i7-8700K
内存	16GB
GPU	NVIDIA GeForce RTX 2080 Ti
开发工具	PyCharm

本文方法的部分超参数设置如表3所列。

表3 参数配置

Table 3 Parameter configuration

参数	值
优化器	Adam
BERT 层学习率	0.00002
迭代次数	15
批量处理大小	32
句子最大长度	110
隐藏层数	200
L2 正则化权重	0.01
BERT 模型	bert-base-uncased

4.4 实验结果与分析

本文采用了方面级情感分析任务中两个常用的评价指标,来验证方法的效果。第一个评价指标是准确率ACC,表示在任务中正确预测样本占所有样本的比例,预测正确的可能是正样本或负样本,即:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (17)$$

其中,TP表示预测正确的正样本数,TN表示预测正确的负样本数,FP表示预测错误的正样本数,FN表示预测错误的负样本数。

第二个评价指标是F1值,通常用于综合评估分类模型性能,即:

$$\begin{cases} P = \frac{TP}{TP + FP} \\ R = \frac{TP}{TP + FN} \\ F1 = \frac{2P \times R}{P + R} \end{cases} \quad (18)$$

其中,P表示情感类别中的精确率,R表示情感类别中的召回率。

4.5 实验结果与分析

4.5.1 实验结果

本文通过选取对比方法在Restaurant14,Laptop14,Twitte和MAMS这4个公开数据集上进行实验。对比方法和本文方法的实验结果如表4所列。结果表明,在4个公开数据集上,本文方法所取得的结果都要优于其他对比方法。

1)本文方法在所有数据集上的实验结果都优于RMN。虽然RMN通过图卷积神经网络编码依存图来生成方面表示,并且引入双向注意力机制来获取方面和上下文之间的关系,但是实验结果证明了以依存图为基础构建图网络的方法对语法信息的提取并不充分,因此需要通过引入新的语法结构来提取到更深层次的文本情感信息,并且图注意力网络比图卷积网络对依存图的特征识别效果更好。

表4 实验结果

Table 4 Experiment results

Models	(%)							
	Restaurant14		Laptop14		Twitter		MAMS	
	Acc	F1	Acc	F1	Acc	F1	Acc	F1
MGAN	81.25	71.94	75.39	72.47	72.54	70.81	70.31	69.45
RAM	80.23	70.80	74.49	71.35	69.36	70.85	68.52	67.35
AEN	80.98	72.14	73.51	69.04	72.83	69.81	66.72	65.57
BERT-SPC	84.46	76.98	78.99	75.03	73.55	72.14	82.82	81.90
CDT	82.30	74.02	77.19	72.99	74.66	73.66	80.70	79.79
RGAT	86.68	80.92	80.94	78.20	76.28	75.25	84.52	83.74
AEGCN	84.46	76.33	80.37	76.68	75.99	75.01	83.74	83.13
RMN	84.56	79.05	77.95	70.83	74.35	73.79	79.97	78.79
Ours	87.22	81.29	79.74	76.78	77.25	76.10	85.32	84.71

2)本文方法在所有数据集上的实验结果均优于RGAT。具体而言,本文方法在Twitter和MAMS数据集上的Acc和F1值均优于RGAT,这表明本文方法对于语法解析准确性的提升更加有效。然而,在Laptop数据集中,本文方法句子的Acc和F1值略低于RGAT,可能是由于该数据集句子长度较短导致语法结构相对简单,因此补充语法结构的方法并不能进一步提取到更深层次的情感信息,导致本文方法实验结果略低。相比之下,RGAT引入了关系标签特征,能够在句子长度较短的情况下更好地利用语法结构得到新的有效信息,使得RGAT在Laptop数据集获得更好的表现。

3)本文选取的对比方法可分为依赖语法特征和不依赖语法特征两类。通过上述实验结果可知,依赖语法特征的方法比不依赖语法特征的方法效果更好,证明了引入语法结构信息能够更加深入地挖掘文本情感特征。AEGCN即使在上述语法特征增强的方法(如RGAT,AEGAT,IAGAT)中表现较差,但仍然优于所有不依赖语法特征的方法,这进一步证明了在方面级情感分析任务中引入语法结构信息的有效性。此外,相比于不使用注意力的方法,使用注意力机制的方法在实验中取得了更好的效果,证明了注意力机制对于方面级情感分析任务的重要性。

4.5.2 参数选择实验

为了研究本文方法中图注意力网络层数对性能的影响,本文在4个公开数据集上进行了实验,并且分别对图注意力网络层数 $L = \{1, 2, 3, 4, 5\}$ 时的分类效果进行分析,结果如表5所列。在Restaurants14, Twitters和MAMS数据集上,当 $L = 2$ 时,模型表现最好;而在Laptop14数据集上,当 $L = 4$

时,模型表现最好, $L=2$ 时次之。多层图注意力网络能够让节点关注其邻域的特征,为邻域中的不同节点赋予不同的权重。但是当层数较少时,节点表示无法传播很远,语义特征之

间的交互学习还不够充分。此外,如果层数过多,由于训练集大小不变,可能导致模型过参数现象严重,使得训练过程中模型难以收敛。

表 5 图注意力网络层数对模型的影响
Table 5 Influence of GAT layers on the model

图注意力网络层数	1	2	3	4	5
Restaurants14	85.34/79.35	87.22/81.29	84.99/76.57	85.96/80.58	85.43/76.96
Laptop14	78.96/75.96	79.11/75.90	78.64/75.64	79.74/76.78	78.17/73.64
Twitters	74.59/73.89	77.25/76.10	75.48/74.53	75.04/73.15	75.04/74.23
MAMS	83.34/82.56	85.31/84.71	83.95/83.18	83.65/82.91	84.94/84.50

图注意力网络层数对 ACC 和 F1 的影响的可视化结果如图 5 和图 6 所示。

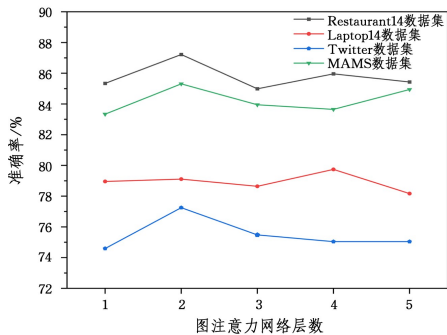


图 5 图注意力网络层数对准确率的影响
Fig. 5 Influence of GAT layers on ACC




图 6 图注意力网络层数对 F1 值的影响
Fig. 6 Influence of GAT layers on F1 score

4.5.3 消融实验

本文分别移除了依存树语法信息、短语结构树语法信息和交互注意力机制来进行消融实验,通过在 4 个公开数据集上进行实验来验证本文方法的有效性,其中 w/o 为 without 的缩写。实验结果如图 7 和图 8 所示。通过观察实验结果可知,在 Restaurant14, Twitter 和 MAMS 数据集上,本文方法的效果最好。其中,当缺少短语结构树语法信息时,在 3 个数据集上的效果分别下降了 2.41%/3.77%,2.21%/1.54% 和 0.99%/0.88%;当缺少依存树语法信息时,方法效果分别下降了 1.16%/2.18%,1.33%/1.46% 和 0.15%/0.16%;当缺少交互注意力机制而简单使用 Concat 来融合语义和语法特征时,效果分别下降了 1.61%/1.80%,1.03%/0.54% 和 1.64%/1.59%。然而在 Laptop14 数据集上,当缺少短语结构树语法信息时模型的表现最佳,可能是由于 Laptop14 的数据集中的文本结构较为简单,并不需要复杂的语法信息。




图 7 各组件对准确率的影响

Fig. 7 Influence of the components on Acc

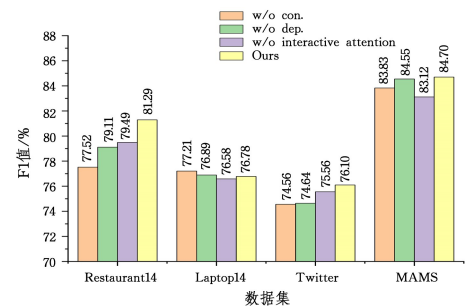


图 8 各组件对 F1 值的影响

Fig. 8 Influence of the components on F1 score

结束语 本文提出了一种基于 BERT 模型和图注意力网络的方面级情感分析方法,用于弥补方面级情感分析任务中严重依赖单一语法分析的缺陷。首先,使用预训练模型 BERT 获取句子的语义信息;其次,使用语法解析器分别获取句子的短语结构图和依存图,通过图注意力网络对图节点进行编码;接下来,通过交互注意力机制将获取的语义和语法特征充分融合;最后,将融合了语义和语法信息的情感特征输入到情感分类层,得到最终的情感分类结果。实验结果表明,本文方法在多个公开数据集上比现有先进方法具有更好的情感分类性能。然而,其在 Laptop14 数据集上的性能仍有待提高,可能是因为该数据集中的文本更加口语化和简单,导致无法充分提取到有效的语法特征。此外,现实世界中网民所发布的文本评论往往是随意化、口语化和多样化的,因此本文方法在处理这类文本数据时存在一定的局限性。未来的工作将探索引入对比学习对方法进行改进,旨在获得更多更准确的语义特征表示。

参考文献

- [1] WANG Y, HUANG M, ZHU X, et al. Attentionbased LSTM for aspect-level sentiment classification [C] // Conference on

- Empirical Methods in Natural Language Processing. 2016:606-615.
- [2] TANG D, QIN B, FENG X, et al. Effective lstms for target-dependent sentiment classification[C]// International Conference on Computational Linguistics. 2016:3298-3307.
- [3] ZENG X Q, HUA X, LIU P S, et al. Emotion Wheel and Lexicon based emotion distribution Label Enhancement Method[J]. Chinese Journal of Computers, 2021, 44: 1080-1094.
- [4] WU H, ZHANG Z, SHI S, et al. Phrase dependency relational graph attention network for Aspect-based Sentiment Analysis [J]. Knowledge-Based Systems, 2022, 236: 247.
- [5] WU H, ZHANG Z, WU Q. Exploring syntactic and semantic features for authorship attribution[J]. Applied Soft Computing, 2021, 111: 127.
- [6] ZHANG M, QIAN T. Convolution over hierarchical syntactic and lexical graphs for aspect level sentiment analysis[C]// Conference on Empirical Methods in Natural Language Processing. 2020:3540-3549.
- [7] WANG K, SHEN W, YANG Y, et al. Relational graph attention network for aspect-based sentiment analysis[C]// Association for Computational Linguistics. 2020:3229-3238.
- [8] ZHAO G Y, LV C G, FU G H, et al. Domain Specific Sentiment Words Based Attention Model for Cross-Domain Attribute-Oriented Sentiment Analysis[J]. Journal of Chinese Information Processing, 2021, 35(6): 93-102.
- [9] WANG Y, HUANG M, ZHU X, et al. Attention-based LSTM for aspect-level sentiment classification[C]// Conference on Empirical Methods in Natural Language Processing. 2016:606-615.
- [10] CHEN P, SUN Z, BING L, et al. Recurrent attention network on memory for aspect sentiment analysis[C]// Conference on Empirical Methods in Natural Language Processing. 2017:452-461.
- [11] MA D, LI S, ZHANG X, et al. Interactive attention networks for aspect-level sentiment classification[C]// Conference on International Joint Conference on Artificial Intelligence. 2017:4068-4074.
- [12] LU Q, ZHU Z, ZHANG D, et al. Interactive rule attention network for aspect-level sentiment analysis[J]. IEEE Access, 2020, 8:52505-52516.
- [13] XU H, LIU B, SHU L, et al. BERT post-training for review reading comprehension and aspect-based sentiment analysis [C]// Annual Conference of the North American Chapter of the Association for Computational Linguistics. 2019:2324-2335.
- [14] SONG Y, WANG J, JIANG T, et al. Attentional encoder network for targeted sentiment classification [C] // International Conference on Artificial Neural Networks. 2019:93-103.
- [15] ZHANG K, ZHANG K, ZHANG M, et al. Incorporating dynamic semantics into pre-trained language model for aspect-based sentiment analysis[C]// Annual Meeting of the Association for Computational Linguistics. 2022:3599-3610.
- [16] YAN H, DAI J, QIU X, et al. A unified generative framework for aspect-based sentiment analysis [C] // International Joint Conference on Natural Language Processing. 2021:2416-2429.
- [17] ZHANG C, LI Q, SONG D. Aspect-based sentiment classification with aspect-specific graph convolutional networks [C] // Conference on Empirical Methods in Natural Language Processing. 2019:4568-4578.
- [18] LI R, CHEN H, FENG F, et al. Dual graph convolutional networks for aspect-based sentiment analysis[C]// International Joint Conference on Natural Language Processing. 2021: 6319-6329.
- [19] 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: 1-11.
- [20] CHENG, TENG Z, WANG Z, et al. Discrete opinion tree induction for aspect-based sentiment analysis[C]// Annual Meeting of the Association for Computational Linguistics. 2022:2051-2064.
- [21] ZHAO X, PENG H, DAI Q, et al. Rdgcn: Reinforced dependency graph convolutional network for aspect-based sentiment analysis [C] // International Conference on Web Search and Data Mining. 2024:976-984.
- [22] ZHAO X, ZHOU Y, XU X, et al. Extensible Multi-Granularity Fusion Network for Aspect-based Sentiment Analysis [J]. arXiv:2402.07787, 2024.
- [23] TU K W, LI J. A Survey of Recent Developments in Syntactic Parsing[J]. Journal of Chinese Information Processing, 2020, 34(7):30-41.
- [24] CHAI W. A Review of the Constituency Parsing[J]. Computer Knowledge and Technology, 2020, 16(16):3-10.
- [25] MRINI K, DERNONCOURT F, BUI T, et al. Rethinking self-attention: An interpretable self-attentive encoder-decoder parser [C]// Conference on Empirical Methods in Natural Language Processing. 2020:731-742.
- [26] HERCIG T, BRYCHCÍN T, SVOBODA L, et al. Uwb at semeval-2016 task 5: Aspect based sentiment analysis[C]// International Workshop on Semantic Evaluation. 2016:342-349.
- [27] DONG L, WEI F, TAN C, et al. Adaptive recursive neural network for target-dependent twitter sentiment classification[C]// Annual Meeting of the Association for Computational Linguistics (volume 2: Short papers). 2014:49-54.
- [28] JIANG Q, CHEN L, XU R, et al. A challenge dataset and effective models for aspect-based sentiment analysis[C]// Conference on Empirical Methods in Natural Language Processing. 2019: 6280-6285.
- [29] FAN F, FENG Y, ZHAO D. Multi-grained attention network for aspect-level sentiment classification[C]// Conference on Empirical Methods in Natural Language Processing. 2018:3433-3442.
- [30] CHEN P, SUN Z, BING L, et al. Recurrent attention network on memory for aspect sentiment analysis[C]// Conference on Empirical Methods in Natural Language Processing. 2017:452-461.
- [31] SUN K, ZHANG R, MENSAH S, et al. Aspect-level sentiment analysis via convolution over dependency tree[C]// Conference on Empirical Methods in Natural Language Processing. 2019: 5679-5688.
- [32] MA M, NA S, WANG H. AEGCN: An autoencoder-constrained graph convolutional network [J]. Neurocomputing, 2021, 432: 21-31.
- [33] ZENG J, LIU T, JIA W, et al. Relation construction for aspect-level sentiment classification [J]. Information Sciences, 2022, 586:209-223.



LIN Huang, born in 2000, postgraduate. His main research interests include sentiment analysis in natural language processing, intelligent data management and analysis, and deep learning.



LI Bicheng, born in 1970, professor, Ph.D supervisor. His main research interests include artificial intelligence, natural language processing, public opinion monitoring and guidance.