

结合多种语言学特征的中文隐式情感分类

陆靓倩, 王中卿, 周国栋

引用本文

陆靓倩, 王中卿, 周国栋. 结合多种语言学特征的中文隐式情感分类[J]. 计算机科学, 2023, 50(12): 255-261.

LU Liangqian, WANG Zhongqing, ZHOU Guodong. [Chinese Implicit Sentiment Classification Combining Multiple Linguistic Features](#) [J]. Computer Science, 2023, 50(12): 255-261.

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)

[基于CodeBERT的设计模式语言模型](#)

CodeBERT-based Language Model for Design Patterns

计算机科学, 2023, 50(12): 75-81. <https://doi.org/10.11896/jsjcx.230100115>

[接诉即办智能派单业务调度算法研究](#)

Study on Scheduling Algorithm of Intelligent Order Dispatching

计算机科学, 2023, 50(11A): 230300029-7. <https://doi.org/10.11896/jsjcx.230300029>

[基于局部上下文焦点机制和交谈注意力的方面级情感分析](#)

Aspect-based Sentiment Analysis Based on Local Context Focus Mechanism and Talking-Head Attention

计算机科学, 2023, 50(11A): 220900266-6. <https://doi.org/10.11896/jsjcx.220900266>

[基于MacBERT和对抗训练的审计文本命名实体识别](#)

Audit Text Named Entity Recognition Based on MacBERT and Adversarial Training

计算机科学, 2023, 50(11A): 230200083-6. <https://doi.org/10.11896/jsjcx.230200083>

[基于BERT和多特征门控机制的口语理解联合方法](#)

Joint Method for Spoken Language Understanding Based on BERT and Multiple Feature Gate Mechanism

计算机科学, 2023, 50(11A): 230300002-6. <https://doi.org/10.11896/jsjcx.230300002>

结合多种语言学特征的中文隐式情感分类

陆靓倩 王中卿 周国栋

苏州大学计算机科学与技术学院 江苏 苏州 215006

(20204227059@stu.suda.edu.cn)

摘要 情感分析一直是自然语言处理中的热点研究方向,隐式情感分类指无显式情感词的情感分类任务,目前,隐式情感分析还处于起步阶段。隐式情感分析面临缺乏显式情感词、表达方式委婉、语义难以理解等问题,传统的情感分析方法如情感词典、词袋模型等难以生效,使得隐式情感分类任务更加艰巨。针对以上问题,提出了一种结合文本、词性与依存关系的图神经网络模型来进行隐式情感分类。具体来说,模型首先抽取文本的词性和依存特征,然后使用预训练语言模型 BERT 提取文本向量特征,从而构建了一个基于多种语言学特征的图注意力神经网络。该模型在 SMP2021 隐式情感识别公开数据集上进行了多次实验。实验结果表明,相较于多种基线模型,所提模型取得了较好的分类效果,证实了所提出的融合了多种语言学特征的隐式情感分类方法具有可行性和有效性。

关键词: 隐式情感分类;词性标注;依存分析;图模型;BERT;语言学特征

中图法分类号 TP391

Chinese Implicit Sentiment Classification Combining Multiple Linguistic Features

LU Liangqian, WANG Zhongqing and ZHOU Guodong

School of Computer Science and Technology, Soochow University, Suzhou, Jiangsu 215006, China

Abstract Sentiment analysis has always been a hot research direction in natural language processing. Implicit sentiment classification refers to the task of sentiment classification without explicit sentiment words. At present, implicit sentiment analysis is still in its infancy. Implicit sentiment analysis is faced with problems such as lack of explicit sentiment words, euphemism of expression, and difficulty in understanding semantics. Traditional sentiment analysis methods, such as sentiment dictionary and bag-of-word models, are difficult to be effective, making the task of implicit sentiment classification more difficult. To solve the above problems, this paper proposes a graph neural network model that combines text, part-of-speech tags and dependency to perform implicit sentiment classification. Specifically, the model first extracts part of speech and dependency features of the text, and then uses pre-training language model BERT to extract text vector features, thus builds a graph attention neural network based on multiple linguistic features. The model has been tested on SMP2021 implicit sentiment recognition public dataset for several times. Experimental results show that the proposed model achieves the best results compared with multiple baseline models. The proposed implicit sentiment classification method is feasible and effective.

Keywords Implicit sentiment classification, Part-of-speech tagging, Dependency analysis, Graph model, BERT, Linguistic features

文本情感分析指运用计算机技术对文本的观点、情感、极性进行发掘和剖析,评估文本的主体情感倾向^[1],是自然语言处理领域的热门研究方向之一。与传统的显式情感分析不同,隐式情感分析指“不含有显式情感词,但表达了主观情感的语言片段”^[2]。现实场景的自然语言文本中不乏隐式情感句的例子。据统计,汉语中含有隐式情感表述的句子约占 15%~20%^[3-4]。这类隐式情感句表达的情感往往复杂抽象,且时常倾向于通过含蓄委婉的修辞手法进行表达。

根据表述方式的不同,隐式情感句可分为事实型和修辞型,其中修辞型又可分为比喻型、反问型和反讽型^[3]。如表 1

所列,句子 S1 是一个基础的显式情感表达句,句子 S2 和 S3 都是隐式情感句。其中,句子 S1 包含的显式情感词“喜欢”表达了情感倾向;句子 S2 不包含任何显式情感词,仅对曼听公园进行了客观描述,但仍以“1300 多年的历史”暗示了曼听公园悠久的历史,以此表达褒义的情感,该句采用这种描述客观事实的方式表达情感,属于事实型隐式情感句;句子 S3 同样不具备显式情感词,却通过一个比喻“疯狗”表达了贬义的情感。由此可见,虽然隐式情感句中并没有显式情感词来直接地表达情感倾向,但仍可以通过含蓄委婉的方式来表达隐式情感。

到稿日期:2022-10-25 返修日期:2023-03-05

基金项目:国家自然科学基金(62076175,61976146)

This work was supported by the National Natural Science Foundation of China(62076175,61976146).

通信作者:王中卿(wangzq@suda.edu.cn)

表1 显式情感和隐式情感相关句子示例

Table 1 Examples of explicit and implicit sentiment-related

sentences		
序号	句子	类型
S1	我喜欢曼听公园美丽的景色	显式情感句
S2	曼听公园以前是傣王御花园，有1300多年的历史	事实型
		隐式情感句
S3	被疯狗咬了，咱们不能再去咬疯狗了	修辞型
		隐式情感句

显式情感分析是情感分析长期以来重点关注的方向，在各方面研究成果丰硕，其技术也比较先进。显式情感句含有明确表达情感信息的情感词、情感转折词等，能够通过情感词典或机器学习等方法进行识别。然而，隐式情感句不具备显式情感词或其他明显的情感相关特征，使得传统情感分析的方法难以处理隐式情感分析任务。相比显式情感分析，隐式情感分析存在如下挑战^[5]：(1)隐式情感句缺少显式情感词，并且使用词汇的情感倾向较为中立，导致基于情感词典、机器学习、词袋模型等的方法难以发挥作用；(2)隐式情感句的表达方式较为含蓄委婉，易受说话者个人认知的影响，使得隐式情感句的语义的表示和理解难度加大；(3)相比其他语言，中文的隐式情感分类任务难度更大。汉语作为孤立语，重意合轻形合，注重隐性连贯，表达形态上更加变化多端，而英语等屈折语重形合轻意合，注重显性连接。

目前学术界对于隐式情感分析的关注较少，相关研究比较匮乏。现有的隐式情感分类方法主要利用上下文信息增加语义特征，来辅助隐式情感分析。这种做法的主要缺点有：(1)隐式情感句的上下文通常不具备显式情感词，只能提供有限的情感倾向信息。如表1中S2的上下文是“景区集中体现了‘傣王室文化、佛教文化、傣民俗文化’三大主题特色”，该上下文并不具备明显的情感指示内容。(2)文本情感分析常常使用在线商品评论、微博文本作为数据来源，这些文本通常篇幅较短，上下文信息不充足。因此，仅靠上下文信息提供单一的语义特征进行隐式情感分析具有局限性。

本文选择使用原始文本的多种语言学特征进行隐式情感分类。隐式情感句虽然不含显式情感词，但仍具有词性特征和句法特征，可以辅助隐式情感的表达。例如，句子S3使用形容词“疯”修饰名词“狗”，而“疯”常用于贬义的表达。因此，“疯狗”可以指示该句的贬义情感倾向。这也说明了词性特征对于情感识别具有一定作用。此外，短语结构如定中结构、主谓结构、动宾结构、副词修饰结构等往往影响着模型对句子情感极性的计算^[6]。例如，句子S2的“1300多年的历史”采用了定中结构，暗含了这个句子的褒义情感倾向，这说明依存句法特征对情感极性的判别也有一定的帮助。综合以上两点，本文提出了一种融合多种语言学特征的图神经网络模型来进行隐式情感分析。

具体而言，本文提出的模型首先抽取隐式情感句的词性特征和依存句法特征；其次，将词性特征与BERT文本向量特征相结合，得到融合词性的BERT文本向量特征；然后，根据融合词性的文本向量特征和依存句法特征构建图注意力神经网络；最后，输出对隐式情感句的预测结果。实验结果表明，相较于多种基线模型，本文模型在SMP2021隐式情感识别公开数据集上取得了较好的分类效果。本文提出的模型

在表现上超越了基于上下文的隐式情感分类模型，这也说明了本文提出的融合多种语言学特征的图神经网络模型方法具有可行性和有效性。

1 相关工作

根据是否有显式情感词，情感分析可以划分为隐式情感分析和显式情感分析。相比在多个方面成果丰硕的显式情感分析，隐式情感分析的相关研究较少，还处于萌芽时期。在进行隐式情感分析时，一部分研究会注重某一类型的隐式情感分析，另一部分研究则不区分隐式情感的类型。

1.1 单一类型的隐式情感分析

隐喻识别是隐式情感分析的研究方法之一^[7]，该任务以隐式情感句中的隐喻手法作为情感线索，识别句子中隐喻的存在和意义，并进一步判断情感倾向。例如，Guo等^[8]提出的隐喻识别模型采用transformer获得语义信息，并通过图卷积神经网络提取依存句法特征。Zhang等^[9]采用迁移学习和文本增强的方式进行隐喻识别。Huang等^[10]构建模型并结合上下文信息编码，且基于细粒度句法构图，进行隐喻识别。

有学者针对反问型隐式情感句进行深入研究。Bhattasali等^[11]构建基于n-gram的语言模型并结合上下文信息特征，进行反问句识别。Wen^[12]采用卷积神经网络分别提取文本语义特征和反问特征，从而进行反问句的隐式情感识别。Li等^[13]采用标签注意力机制抽取句法结构、符号标记等语言特征，基于Bi-LSTM构建了一个强化语言特征的反问句识别模型。

还有学者研究了反讽型隐式情感句。Sun等^[14]采用卷积神经网络和LSTM对反讽和讽刺文本进行情感识别。Lu^[15]采用卷积神经网络提取文本语义特征和反讽特征，并使用LSTM提取上下文特征。Luo等^[16]通过计算词之间的注意力分数捕获矛盾词对，从而进行反讽句的判别。

单一类型的隐式情感分析通常增加了特定类型的特征，如反问特征、反讽特征等，从而增强了对特定类型的隐式情感句的识别能力。

1.2 无类型的隐式情感分析

有学者在研究隐式情感分析时不局限于某种固定类型。Li等^[17]指出方面级情感分析(ABSA)中存在隐式的情感表达，并提出了监督对比预训练模型来学习情感知识。Zhou等^[18]对事件进行编码，基于事件信息进行隐式情感分析。Yang等^[19]提出了ISA-GACNN模型，构建了文本和词语的异构图谱，通过注意力机制得到词语在文本情感表达中的重要性。Huang等^[20]提出了ERNIE2.0-BiLSTM-Attention(EBA)模型融合上下文语境。Chen等^[21]构建了CA-TRNN模型，利用BiLSTM提取上下文语义特征，并通过TRNN提取隐式情感句的语义特征。Yuan等^[22]提出了GGBA模型，采用GCNN和GRU提取语义信息，通过BiGRU和Attention组合的方式提取上下文信息，最终将得到的文本语义信息与上下文信息融合进行隐式情感识别。Che等^[23]提出了一种新的隐式情感文本分类预处理方法Text To Picture(TTP)，以情感极性差异作为线索，将原始文本数据转换为词频图，通过深度学习突出中文隐式情感文本中不同情感极性之间的情感差异。Zhuang等^[24]采用TBCNN提取句法特征，采用BiGRU+Attention提取上下文信息，提出了基于上下文

信息、句法信息和语义信息构建的神经网络模型。

单一类型的隐式情感分析在特定类型的隐式情感句上效果显著,但不能应用于所有隐式情感句。而现有的不区分类型的隐式情感分析方法大多只考虑了单一的语义特征,Zhuang 等也仅增加了句法特征。与这些方法不同的是,本文综合考虑了隐式情感句中的多种语言学特征,采用了融合词性的预训练文本向量,并根据该向量与依存句法树构建图注意力神经网络模型,通过融合多种语言学特征的方式提高模型对隐式情感分类效果。

2 模型介绍

2.1 任务定义

隐式情感分类任务就是识别隐式情感句的情感倾向。为了更加直观地展示本文提出的模型,本节对结合多种语言学特征的隐式情感分类任务进行以下定义:

$$f: (\mathbf{S}, \mathbf{D}, \mathbf{P}) \rightarrow \mathbf{Y} = (Y_0, Y_1, Y_2) \quad (1)$$

给定隐式情感句 $\mathbf{S} = (\omega_1, \omega_2, \dots, \omega_n)$, 其中 ω_n 代表 \mathbf{S} 的第 n 个词。 \mathbf{D} 表示存储隐式情感句 \mathbf{S} 依存句法关系的 n 维邻接矩阵。 \mathbf{P} 表示对 \mathbf{S} 进行词性标注的结果, \mathbf{P} 可表示为 $\mathbf{P} = (p_1, p_2, \dots, p_n)$, 其中 p_n 代表第 n 个词语的词性。 $\mathbf{Y} = (Y_0, Y_1, Y_2)$ 表示隐式情感类别, 其中 Y_i 表示情感类别的概率, 即 Y_0, Y_1 和 Y_2 表示不含隐式情感、褒义隐式情感和贬义隐式情感类别的概率。结合语言学特征的隐式情感分类任务可定义为: 给定任意隐式情感句 \mathbf{S} 、依存句法关系邻接矩阵 \mathbf{D} 以及词性标注结果 \mathbf{P} , 判定 \mathbf{S} 对应的 \mathbf{Y} 。

2.2 模型结构

如图 1 所示, 本文提出的隐式情感分类模型由 4 个模块构成, 分别为 BERT 预训练语言模型层、图注意力网络层、全连接层和输出层。

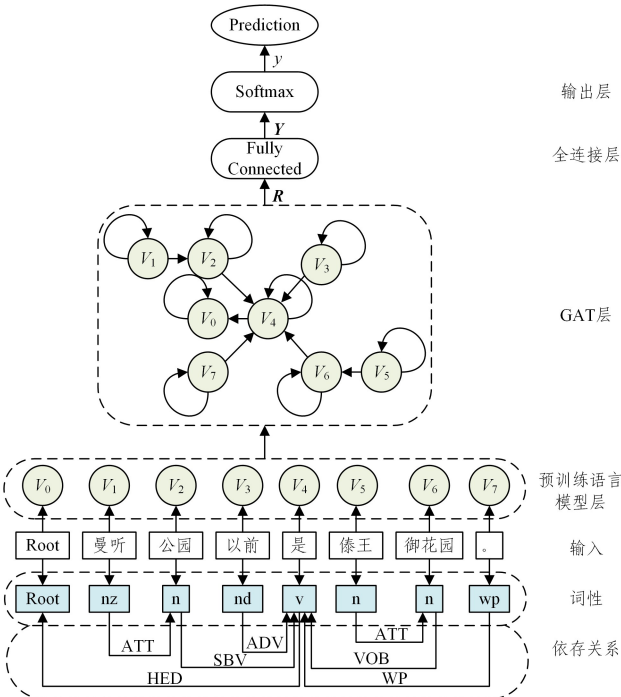


图 1 模型结构图

Fig. 1 Model structure diagram

以隐式情感句“曼听公园以前是傣王御花园”为例,首

先,使用 LTP 工具生成 \mathbf{S} 的词性 \mathbf{P} 和依存句法树 \mathbf{D} (采用邻接矩阵方式保存); 其次,将隐式情感句 \mathbf{S} 和词性 \mathbf{P} 输入本文改进的 BERT 进行编码获得结合词性特征的语义向量; 然后,将 BERT 编码得到的语义向量 \mathbf{V} 以及依存句法树 \mathbf{D} 输入 GAT 构图, 得到 $\mathbf{G} = (\mathbf{V}, \mathbf{D})$; 最后,选取依存句法树中的 Root 节点的向量表征作为全局表征,通过全连接层和输出层得到 \mathbf{S} 在 3 类标签上的概率 Y_i 。

该模型对 BERT 进行了改进,使其能在融合词性信息的基础上提取语义信息。此外,该模型构建了基于依存句法特征的图注意力模型,且加入了依存句法特征。综上所述,该模型实现了结合语义特征、词性特征、依存句法特征进行隐式情感分类。

2.2.1 BERT 预训练语言模型层

2018 年 10 月, Google 的 Devlin 等提出了 BERT 模型^[25-26], 该模型在提取文本语义特征方面效果显著, 因此本文选择使用 BERT 提取隐式情感句的语义信息。此外,由于隐式情感分类缺乏情感词作为线索, 本文希望通过加入词性信息来丰富语义信息, 因而对 BERT 进行了改进。本文改进的 BERT 能够在融合词性特征的基础上提取隐式情感句的语义特征, 更适用于隐式情感分类任务。BERT 的具体改进操作如下。

传统 BERT 的输入由词向量 (Token Embedding)、段向量 (Segment Embedding) 和位置向量 (Position Embedding) 3 部分拼接而成, 我们在原基础上增加了词性向量 (Pos Embedding), 将 4 个向量拼接作为 BERT 的新输入, 如图 2 所示。




图 2 BERT 的输入

Fig. 2 Input of BERT

其中,词向量 $\mathbf{E}_i = (e_1, e_2, \dots, e_n)$ 是由 BERT 将输入的隐式情感句 $\mathbf{S} = (\omega_1, \omega_2, \dots, \omega_n)$ 中的每个词 ω_m 根据词表初始化的词向量, 其中 e_n 表示 ω_n 的向量。位置向量是为了保存每个词的位置信息。段向量是为了区分 BERT 预测任务的上下句, 令 $\mathbf{S} = [\text{CLS}] + \mathbf{S} + [\text{SEP}]$ 对上下句进行分割, 并为上下句生成不同段向量。

本文新增的词性向量可以使 BERT 提取到融合词性特征的语义特征。对于输入的隐式情感句 $\mathbf{S} = (\omega_1, \omega_2, \dots, \omega_n)$, 我们使用哈工大的语言技术平台 (LTP) 提供的词性标注技术来获取隐式情感句词性标注结果 $\mathbf{P} = (p_1, p_2, \dots, p_n)$ 。LTP 工具标注的词性包含动词、名词以及副词等 27 种词性, 本文根据其在隐式情感表达中的重要性从低到高分别表示为 0-26 的整型数字, 从而获得词性向量 $\mathbf{E}_p = (e_{p_1}, e_{p_2}, \dots, e_{p_n})$, 其中 e_{p_n} 表示 ω_n 的词性。

模型在增加词性向量时需要考虑词性向量在所有向量拼接过程中的权重, 本文采用参数敏感性实验和分析的方式,

确定词性向量的权重系数为 0.1,即本文改进的 BERT 输入为词向量+段向量+位置向量+0.1*词性向量。

如图 3 所示,改进的 BERT 将隐式情感句 $S=(\omega_1, \omega_2, \dots, \omega_n)$ 以及词性特征 $P=(p_1, p_2, \dots, p_n)$ 转化为融合词性特征的语义特征 $V=\{v_1, v_2, \dots, v_n\}$,其中 v_n 包含了 ω_n 的文本信息和词性信息以及 ω_n 与其他词的语义关系信息。




图 3 改进后 BERT 的模型结构

Fig. 3 Model structure of improved BERT

2.2.2 图注意力网络(GAT)层

尽管中文隐式情感句在表达形态上变化多端,但是隐式情感句在表达情感时倾向于采用主谓、定中等结构,因此,依存句法特征可以作为隐式情感分析的线索之一。依存句法分析采用依存句法树的形式描述各个词之间的依存关系,因此本文选择根据依存句法树和融合词性特征的语义特征构建图注意力网络模型(GAT)^[27]。

GAT 是图神经网络(GNN)的一个变体,它通过使用多头注意力机制聚集邻居节点的表示来迭代更新每个节点的表示,实现了对不同邻居节点权重的自适应分配。GAT 可以实现聚集依存相关词的语义信息来更新每个词的语义信息,从而在语义特征中融合依存句法特征。

给定隐式情感句 $S=(\omega_1, \omega_2, \dots, \omega_n)$ 及其词性 $P=(p_1, p_2, \dots, p_n)$,经过依存句法分析可以得到一棵依存句法树,如图 4 所示。我们使用 LTP 工具获取句子的依存句法树,LTP 工具返回一个列表,列表内的元素是三元组,三元组的前两位分别表示从属词和核心词的位置,第三位表示两个词之间的依存关系,如(1,2,ATT)表示“曼听”从属于“公园”为定中关系,本文将获得的三元组转换为邻接矩阵进行保存,邻接矩阵维度为 150,句子长度不足部分用 0 补齐。




图 4 依存句法分析示意图

Fig. 4 Graph of dependency parsing

$$dp[i][j]=\begin{cases} 1, & \text{如果 } \omega_i \text{ 是 } \omega_j \text{ 的从属词} \\ 0, & \text{如果 } \omega_i \text{ 不是 } \omega_j \text{ 的从属词} \end{cases} \quad (2)$$

通过 GAT 可以将依存句法邻接矩阵 dp 和 BERT 输出的特征向量 $V=\{v_1, v_2, \dots, v_n\}$ 生成一个有向图 $G=(V, D)$,如图 5 所示,其中顶点 v_n 代表隐式情感句 S 中词 ω_n 的特征向量, D 为有向句法边,由从属词指向核心词,表示两个顶点存在依存关系。操作如下:

- (1)使用 W 对 v 进行线性变换,将 v 变换为 d' 维的向量。
- (2)使用 Attention 机制计算每条边连接的两个节点之

间的权重(注意力系数),即中心词和从属词之间依存关系的权重,词 ω_i 和 ω_j 的注意力系数为:

$$e_{ij} = \text{attention}(Wv_i, Wv_j) \quad (3)$$

(3)当一个词与多个词存在依存关系,即一个节点有多个邻节点时,需要使用 softmax 函数进行归一化,来避免某个注意力系数的值过大导致不便于训练。同时对线性变化后的值引入非线性激活函数,以泛化模型的拟合能力,最终得到的注意力系数为:

$$a_{ij} = \frac{\exp(\text{LeakyReLU}(e_{ij}))}{\sum_{k \in N(i)} \exp(\text{LeakyReLU}(e_{ik}))} \quad (4)$$

其中, $e_i \in N_i$ 。

(4)最后,将归一化的注意力系数与其由 BERT 编码的特征向量进行线性组合,从而得到每个词的最终输出特征向量。

$$v_i' = \sigma(\sum_{j \in N_i} a_{ij} Wv_j) \quad (5)$$

(5)此外,为了稳定自我注意力的学习过程,本文采用 3 个注意力机制,并将得到的结果拼接起来。

$$v_i'' = \parallel_{k=1}^3 \sigma(\sum_{j \in N(i)} a_{ij}^k W^k v_i) \quad (6)$$

此时, v_i'' 有更高的维度(1,3d'),因此模型在输出时对注意力机制的 v' 取平均。

$$\text{Output} = R = \sigma\left(\frac{1}{3} \sum_{i=1}^3 \sum_{j \in N(i)} a_{ij}^k W^k v_i\right) \quad (7)$$




图 5 根据依存句法构图示意图

Fig. 5 Graph of construct with dependency syntax information

2.2.3 全连接层和输出层

经过 BERT 和 GAT 后,隐式情感句中的每个词都包含了其他词的信息及该词与其他词的关系,因此本文模型选取依存句法树中根节点 Root 的表征作为全局表征,进行情感极性判定。

模型从 GAT 层的输出 R 中抽取 Root 表示 $R_{[Root]}$,将 $R_{[Root]}$ 输入全连接层进行分类,计算式如式(7)所示:

$$Y = \tanh(W_s \cdot R_{[Root]} + b_s) \quad (8)$$

其中, W_s 表示全连接层权重矩阵, b_s 是偏置向量。

输出层中,模型采用 softmax 函数进行归一化,将全连接层的输出 Y 转换为各情感类别的近似概率值 Y_i ,计算式如式(8)所示:

$$Y_i = \text{softmax}(W_o \cdot Y + b_o) \quad (9)$$

其中, W_o 表示输出层参数矩阵, b_o 表示偏置向量。

3 实验与分析

3.1 数据集

本文使用的隐式情感数据集来源于 SMP2021 中文隐式情感分析评测(SMP-ECISA 2021),该评测的训练数据由山

西大学提供,测试数据由微热点大数据研究院提供。数据大部分为微博短文本,涉及开学延期、英国脱欧等多个主题。

由表 2 可知,隐式情感表达数据集中不含情感的数据较多,占比接近 50%,这种数据不均衡现象增加了隐式情感的识别难度。

表 2 实验数据统计

Table 2 Statistics of experimental data

数据集	句子	褒义	贬义	不含情感
训练集	9000	2335	2400	4265
验证集	5788	1493	1557	2738
测试集	5145	1233	1358	2554

3.2 实验设置

本文采用 Pytorch 学习框架,并在 NVIDIA 1080TiGPU 上进行实验。本文通过借鉴有关文献和反复实验的方式,确定参数的取值。我们将 GAT 的层数设置为 1,将图注意力头数设置为 3,其他具体实验参数设置如表 3 所列。

表 3 参数设置

Table 3 Parameter setting

参数	数值
<i>max length</i>	250
<i>Batch Size</i>	6
<i>Epoch</i>	15
<i>Optimizer</i>	<i>Adam</i>
<i>BERTHidden size</i>	768
<i>Learning rate</i>	1×10^{-5}

3.3 对比实验模型

本文选取 Fast Text^[28], DPCNN^[29], TextCNN^[30], LSTM^[31], BERT, ERNIE^[32], AEN-BERT^[33], CA-TRNN^[21] 作为对比实验模型,其中, Fast Text, DPCNN, TextCNN, LSTM, BERT, ERNIE 都是情感分类常用的基线模型,下面将简要介绍这些对比模型。

Fast Text:一种快速文本分类算法,将隐式情感句的词及 n-gram 向量进行叠加和平均得到句子向量,然后使用句子向量做 softmax 多分类。

TextCNN:将卷积神经网络(CNN)应用于隐式情感分类,使用长度为 2,3,4 的卷积核分别提取隐式情感句的特征,然后将隐式情感句的特征经过最大池化和全连接层得到分类结果。

DPCNN:TextCNN 的改进模型,其对隐式情感句进行多次等长卷积加池化,以扩大下次卷积的感受野,从而捕获长距离文本特征。

LSTM:使用 LSTM 对隐式情感句进行编码得到隐式情感句的向量表示,再使用 softmax 函数计算隐式情感句的情感极性。

BERT:本文的 Baseline 模型,也是目前热门的预训练语言模型之一,使用 BERT 提取隐式情感句的语义信息,选取隐式情感句的[CLS]向量作为全句表征进行情感分类。

ERNIE:BERT 的改进模型,实现了实体级别的掩码机制,使用 ERNIE 提取隐式情感句的语义信息,选取隐式情感句的[CLS]向量作为全句表征进行情感分类。

AEN-BERT:在 BERT 基础上增加了注意力机制,使用 AEN-BERT 提取隐式情感句的语义信息,选取隐式情感句的[CLS]向量作为全句表征进行情感分类。

CA-TRNN:首先使用 BiLSTM 提取上下文语义特征,然

后使用 TRNN 提取隐式情感句的语义特征,最后对两个特征进行 softmax,得到分类结果。

3.4 实验结果分析

本小节首先对本文提出的模型与一系列基线模型进行对比分析实验,然后在保证参数、数据不变的情况下进行消融实验,以此来分析词性和依存句法各自对结果的影响。

3.4.1 对比实验结果分析

在 SMP-ECISA 数据集上,各基线与本文模型的对比实验结果如表 4 所列。

表 4 各分类模型的准确率、宏平均准确率、召回率和 F1 值

Table 4 Accuracy, macro average accuracy, macro recall rate and macro F1 value of each classification model

模型	(单位:%)			
	<i>Acc</i>	<i>P</i>	<i>R</i>	<i>F1</i>
Fast Text	73.6	70.9	70.0	70.2
TextCNN	72.7	71.4	71.0	70.5
DPCNN	75.1	71.9	70.0	70.6
LSTM	77.9	74.4	70.0	72.1
BERT	79.4	77.0	77.3	77.1
CA-TRNN	80.1	70.1	78.0	73.8
ERNIE	80.4	78.6	77.6	78.1
AEN-BERT	80.5	78.5	79.0	78.7
Our model	80.9	78.8	80.4	79.4

由表 4 可知, Text CNN, DPCNN, LSTM 等神经网络的 F1 值均高于算法 Fast Text; BERT, ERNIE, AEN-BERT 以及 Our model 均使用了预训练模型,它们在 F1 值上均高于 Text CNN, DPCNN, LSTM 等神经网络。由此可见,在隐式情感分类任务中,神经网络的分类效果优于 FastText 算法,而预训练模型的分类效果优于神经网络。因为语义信息提取是隐式情感分析的重点之一,所以在语义信息提取方面突出的预训练语言模型的分类效果更好,更适用于隐式情感分析。

相比使用上下文信息的 CA-TRNN, Our model 表现较好,可见在隐式情感分析中加入词性特征和依存句法特征比增加单一的上下文语义特征更有效,语言学特征可以作为隐式情感分析新的思路。

此外,融合依存句法特征和词性特征的模型准确率达 80.9%, F1 值达 79.4%, 明显高于其他模型。由此可见,本文通过融合词性特征提取语义特征,继而根据依存句法树构建图注意力网络模型,可以有效提高隐式情感识别的准确率。3.1 节中讨论到隐式情感数据集中不含情感的比例较大,数据不均衡导致褒义和贬义的隐式情感难以识别。由表 5 的实验结果可知,由于增加了词性特征和依存句法特征,所提模型显著提高了对褒义和贬义隐式情感的识别,从而验证了词性特征和依存句法特征在情感极性判断中发挥了重要作用。

表 5 模型在各情感类别上的 F1 值

Table 5 F1 value of the model on each emotion category

模型	(单位:%)		
	不含情感	褒义	贬义
BERT	86.1	67.8	77.5
Our model	86.3	72.0	79.8

3.4.2 消融实验结果分析

我们分别使用融合词性的 BERT 以及使用传统 BERT 并根据依存句法树构图的 GAT, 在 SMP-ECISA 数据集上进行隐式情感分析的消融实验,实验结果如表 6 所列。其中,

+dependency 表示使用传统 BERT 并根据依存句法树构图的 GAT,仅增加依存句法特征;+POS 表示融合词性的 BERT,仅增加词性特征;Our model 表示同时增加词性特征和依存句法特征的模型。

表 6 消融实验结果
Table 6 Ablation results

(单位:%)				
模型	Acc	P	R	F1
BERT	79.4	77.0	77.3	77.1
+dependency	79.9	78.3	77.5	77.7
+POS	80.1	77.9	79.3	78.5
Our model (+dependency+POS)	80.9	78.8	80.4	79.4

由消融实验结果可知,相比 BERT,增加词性特征和依存句法特征的模型 F1 值分别提高了 0.6% 和 1.4%,同时增加两种特征的模型相比仅增加一种特征的模型的 F1 值有了进一步提高。由此可知,增加词性特征和依存句法特征均有助

于提高模型对于隐式情感的识别,并且所提模型能有效利用这两种语言学特征。

在消融实验中,我们以贬义隐式情感句“伦敦奥运会在基本没怎么看的情况下,就要闭幕了”为例,绘制上述 4 个模型的特征热力图,如图 6 所示,进一步分析增加两种语言学特征对模型的影响。图中颜色越深代表两个词的关系越密切。

由图 6 可以看出,增加词性特征后,模型弱化了对隐式情感表达不重要的词性,强化了对隐式情感表达重要的词性,更突出了奥运会和闭幕的关系,从而强调了句子中的贬义情感;而增加依存特征后,模型则根据句法关系强化了奥运会和闭幕的关系;同时增加词性特征和句法特征的 Our model,既弱化了非关键词性,又突出了奥运会和闭幕的关系,并且进一步突出了“基本没怎么”,从而强调了句子的贬义情感。由模型特征空间的变化可知,增加词性特征和句法特征均能帮助模型捕获隐式情感。




图 6 BERT,BERT+POS,BERT+dependency 和 Our model 的特征热力图

Fig. 6 Characteristic heat diagram of BERT,BERT+POS,BERT+dependency and our model

结束语 本文深入研究了隐式情感分类任务,发现隐式情感句中缺少显式情感词、表达含蓄委婉等问题,导致传统情感分析方法难以发挥作用。本文提出了一种融合依存分析和词性标注的隐式情感分类方法。一方面,本文改进了 BERT,增加词性嵌入以融合词性特征,并使用改进的 BERT 提取隐式情感句的语义特征,实现了提取融合词性特征的语义特征;另一方面,本文根据依存句法树构建图注意力网络模型,实现了在语义特征中融合依存句法特征。在 SMP2021 公开数据集上的实验结果表明,在模型中融入词性特征和依存句法特征有助于模型对隐式情感的识别和分类,能够有效地提高隐式情感分类的准确率。


参考文献

- [1] YGNG L G,ZHU J,TANG S P. Review of text emotion analysis[J]. Computer Applications,2013,33(6):1574-1578.
- [2] LIU B. Sentiment analysis and opinion mining[M]. Americal: Morgan &. Claypool Publishers,2012.
- [3] LIAO J,WANG S G,LI D Y. Identification of fact- implied implicit sentiment based on multi-level semantic fused representation[J]. Knowledge-Based Systems,2019,165(1):197-207.
- [4] JIAN L,YANG L,WANG S G. The constitution of a fine-grained opinion annotated corpus on weibo[C]// Lecture Notes in Artificial Intelligence Volume. 2016:227-240.
- [5] YUAN J L,DING Y,PAN D X, et al. Chinese implicit emotion

- classification model based on temporal and contextual features [J]. *Computer Applications*, 2021, 41(10): 2820-2828.
- [6] ZHAO L G. Sentence level fine-grained affective computing based on dependency syntax[D]. Guangzhou: South China University of Technology, 2015.
- [7] LIAO J. Research on fact-based implicit affective analysis based on representation learning[D]. Taiyuan: Shanxi University, 2018.
- [8] GUO F R, HUANG X X, WANG R B, et al. Metaphor recognition based on transformer and graph convolution neural network [J]. *Data Analysis and Knowledge Discovery*, 2022, 6(4): 120-129.
- [9] ZHANG W, WANG H, CHEN Y T, et al. Research on knowledge recognition and relevance of Chinese idiom metaphor integrating transfer learning and text enhancement[J]. *Data Analysis and Knowledge Discovery*, 2022, 6(Z1): 167-183.
- [10] HUANG H Y, LIU X, LIU Q. Text metaphor recognition graph coding method based on knowledge enhancement[J]. *Computer Research and Development*, 2023(1): 140-152.
- [11] BHATTASALI S, CYTRYN J, FELDMAN E, et al. Automatic identification of rhetorical questions[C]// *Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing*. 2015: 743-749.
- [12] WEN Z. Research on rhetorical question recognition and emotion discrimination based on depth learning[D]. Shanxi: Shanxi University, 2019.
- [13] LI Y, WU Z J, WANG S G, et al. A rhetorical question recognition method based on automatic acquisition of linguistic features [J]. *Journal of Chinese Information Science*, 2020, 34(2): 96-104.
- [14] SUN X, HE J J, REN F J. Satirical pragmatic discrimination based on hybrid neural network model of multi feature fusion [J]. *Journal of Chinese Information*, 2016, 30(6): 215-223.
- [15] LU X. Research on Chinese Irony Recognition and Emotional Discrimination Based on Deep Learning [D]. Shanxi: Shanxi University, 2019.
- [16] LUO G Z, ZHAO Y Y, QIN B, et al. Irony Recognition for Social Media [J]. *Intelligent Computers and Applications*, 2020, 10(2): 301-307.
- [17] LI Z Y, ZOU Y C, ZHANG C, et al. Learning Implicit Sentiment in Aspect-based Sentiment Analysis with Supervised Contrastive Pre-Training[C]// *Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing*. 2021: 246-256.
- [18] ZHOU D Y, WANG J N, ZHANG L H, et al. Implicit Sentiment Analysis with Event-Centered Text Representation[C]// *Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing*. 2021: 6884-6893.
- [19] YANG S L, CHANG Z. Chinese implicit emotion analysis based on graph attention neural network [J]. *Computer Engineering and Application*, 2021, 57(24): 161-167.
- [20] HUANG S C, HAN D H, QIAO B Y, et al. An implicit emotion analysis method based on ERNIE2.0-BiLSTM-Attention [J]. *Small Microcomputer System*, 2021, 42(12): 2485-2489.
- [21] CHEN Q C, ZHAO H, ZUO E G, et al. Implicit emotion analysis based on context aware tree recurrent neural network [J]. *Computer Engineering and Application*, 2022, 58(7): 167-175.
- [22] YUAN J L, DING Y, PAN D X, et al. Chinese implicit emotion classification model based on temporal and contextual features [J]. *Computer Applications*, 2021, 41(10): 2820-2828.
- [23] CHEN M, UBUL K, XU X, et al. Connecting Text Classification with Image Classification: A New Preprocessing Method for Implicit Sentiment Text Classification [J]. *Sensors (Basel)*, 2022, 22(5): 1899.
- [24] ZHUANG Y, LIU Z, LIU T T, et al. Implicit sentiment analysis based on multi-feature neural network model [J]. *Journal Information*, 2022, 26(2): 635-644.
- [25] SUN Y, WANG S, LI Y K, et al. Ernie2.0: understanding a continuous language pre training framework [C]// *AAAI Artificial Intelligence Conference*. 2020: 8968-8975.
- [26] DEVLIN J, CHANG M W, LEE K, et al. Bert: pre-training of deep bidirectional transformers for language understanding [C]// *The 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*. Association for Computational Linguistics, 2019: 4171-4186.
- [27] VELIČKOVIĆ P, CUCURULL G, CASANOVA A, et al. Graph attention networks [C]// *The 6th International Conference on Learning Representations*. 2018: 1-12.
- [28] ARMAD J. Bag of Tricks for Efficient Text Classification [DB/OL]. (2016-8-9). [2023-3-20]. <https://arxiv.org/abs/1607.01759>.
- [29] RIE J, TONG Z. Deep Pyramid Convolutional Neural Networks for Text Categorization [C]// *Annual Meeting of the Association for Computational Linguistics (ACL)*. 2017.
- [30] YOON K. Convolutional neural networks for sentence classification [C]// *Conference on Empirical Methods in Natural Language Processing*. 2014: 1746-1751.
- [31] YANG L, WU Y G, WANG J L, et al. Review of research on cyclic neural networks [J]. *Computer Applications*, 2018, 38(S2): 1-6, 26.
- [32] SUN Y, WANG S, LI Y, et al. ERNIE: Enhanced Representation through Knowledge Integration [J]. *arXiv*: 1904. 09223, 2019.
- [33] SONG Y, WANG J, TAO J, et al. Attentional Encoder Network for Targeted Sentiment Classification [J]. *arXiv*: 1902. 09314, 2019.



LU Liangqian, born in 1998, postgraduate, is a member of China Computer Federation. Her main research interest is natural language processing.



WANG Zhongqing, born in 1987, Ph.D., associate professor, is a member of China Computer Federation. His main research interest is natural language processing.