

基于改进 BiLSTM 算法的大学生 心理健康问题研究分析

高星宇^{1,2}, 施姣杰^{1,2}, 陈 坚³

(1.浙江省文化和旅游发展研究院,浙江 杭州 311231)

(2.浙江旅游职业学院酒店管理学院,浙江 杭州 311231)

(3.浙江工业大学,浙江 杭州 310023)

[摘要] 随着深度学习模型应用越来越广泛,模型精度不断提高,为智能化研判系统提供了可行性. 大学生的心理行为同时具备外显性和内隐性,目前在心理咨询过程中内隐性信息往往容易被忽视. 为更有效提取内隐信息,通过深度学习方法对大学生心理访谈数据进行心理特征提取,构建大学生心理咨询智能化分析算法. 为加深词向量中的情感导向,采用 BERT 模型替换传统的 Word2vec 模型,并采用双向 LSTM 算法加强上下文之间的关联性. 实验证明,该算法可有效获取心理咨询过程中隐喻、低频的语义信息,对心理咨询数据进行二分类,并准确对负面情绪的访谈数据进行预警.

[关键词] 大学生心理,情感分析,深度学习,BiLSTM,词向量

[中图分类号] TP391 **[文献标志码]** A **[文章编号]** 1672-1292(2023)04-0043-07

Research and Analysis on Psychological Health Problems of College Students Based on Improved BiLSTM Algorithm

Gao Xingyu^{1,2}, Shi Jiaojie^{1,2}, Chen Jian³

(1.Zhejiang Provincial Institute of Culture and Tourism Development, Hangzhou 311231, China)

(2.School of Hotel Management, Zhejiang Tourism Vocational College, Hangzhou 311231, China)

(3.Zhejiang University of Technology, Hangzhou 310023, China)

Abstract: With the more and more wide application of deep learning models, the accuracy of the models continues to improve, providing feasibility for intelligent research and judgment systems. The psychological behavior of college students have both explicitness and implicitness. At present, implicit information is often overlooked in the process of psychological counseling. In order to extract implicit information more effectively, this paper uses the deep learning method to extract the psychological characteristics of college students' psychological interview data, and constructs an intelligent analysis algorithm for college students' psychological counseling data. In order to deepen the emotional orientation in the word vector, this paper uses the BERT model to replace the traditional Word2vec model. And the BiLSTM algorithm is used to strengthen the correlation between contexts. Experiments prove that the algorithm effectively obtains metaphorical and low-frequency semantic information in the process of psychological counseling, classifies psychological counseling data (positive emotion and negative emotion), and accurately warns the interview data of negative emotions.

Key words: college student psychology, sentiment analysis, deep learning, BiLSTM, word vector

大学生心理健康教育是高校人才培养体系的基本组成部分,保障大学生心理健康发展对于大学生自我发展有良好的促进作用^[1]. 然而,高强度的学习、沉重的经济负担、复杂严峻的就业形势等多方面的压力,使得大学生的心理健康问题频发^[2]. 心理咨询是解决大学生心理健康问题的主要手段之一^[3]. 目前大学生的心理咨询还存在着一些问题,如传统的心理咨询模式还不够完善、教师的教育方法存在问题等^[4],

收稿日期:2023-04-28.

基金项目:浙江旅游职业学院招标课题专项项目(2023ZB02).

通讯作者:高星宇,助教,研究方向:深度学习. E-mail:gaoxingyu@tourzj.edu.cn

同时还存在随意性、滞后性、说教化、套路多、总结少等问题^[5]。因此,建立心理危机服务体系,结合情感分析方法和智能化手段推动心理咨询发展,具有十分重要的意义。

情感分析是指综合运用自然语言处理等相关计算机技术,分析与挖掘用户表达中所包含的情感信息,相较于传统的由人工进行情感信息分析的方法,通过算法分析可以节约人工并获得较好的性能^[6]。情感分析主要分为词语级、短语级、句子级、篇章级及多篇章级等几个研究层次^[7]。大学生心理咨询情感分析主要通过咨询的短语级、句子级文本内容来判断表达的情感倾向,这种具有情感表达的短语被称为极性词,同样句子之中往往包含了情感表达,因此句子也具有极性^[8]。

情感分析需要数据集支撑,目前国内外情感分析数据集都处于发展过程。英文情绪分析数据集目前主要包含 IMDB 数据集、SemEval2018 数据集、斯坦福情感树库数据集等。中文情绪分析数据集目前较匮乏,陈颖等^[9]于 2018 年构建了一个包含共计 5 376 条语音样本的数据集,共分为 7 种情感分类,提高了情感分析样本数据库的质量,证明了情感有明显的可区分性。

过去已有大量的情感分析研究。Wiebe 等^[10]提出的主观性分类为情感分析提供了理论基础,他提出将句子分为主观与客观两类,其中主观句子中包含个人情感类信息,并通过朴素贝叶斯进行了分类。姚天昉等^[7]建立分析模型,通过语义分析对网络评论进行分析,得到了较高的精度。Kamal^[11]提出了监督机器学习和基于规则的方法的组合,用于从主观审查句子中挖掘可行的特征意见对。Schouten 等^[12]提出了一种简单的方面检测算法,是一种基于共现的类别检测方法和一种基于字典的情绪分类算法。

深度学习被认为是机器学习中的一个新兴方法,近年被广泛应用于各个领域^[5,13]。与传统方法相比,深度学习技术具有几个优势,包括具有无需手动特征提取和调整即可检测复杂结构和特征的能力;倾向于从给定的原始数据中提取低级特征及处理未标记数据的能力^[14]。循环神经网络(RNN)和长短期记忆(LSTM)等深度学习模型被应用于语音或文本处理(如自然语言处理(NLP)和 SER)时非常有效^[15]。

Mikolov 等^[16]提出了将 Word2vec 模型应用于情感分析问题,但该模型提取词向量属于静态,虽然泛用性较强,但在某些限定任务的动态优化问题上性能较差。谢思雅等^[17]使用 Word2vec(word vector)生成词向量,在双向长短期记忆网络(bidirectional long short-term memory, BiLSTM)中结合注意力机制,取得了较好的效果。Devlin 等^[18]为改进 Word2vec 模型提出了 BERT(bidirectional transformers encoder representations from transformers)模型,该模型为 Transformer 结构的掩码语言模型。BERT 相较于传统单向语言模型,通过动态提取词向量,能较好地结合上下文语境,以有效避免歧义问题发生。Zhang 等^[19]提出了一个方面级情感分类模型 PWCN(proximity-weighted convolution network),该模型利用了方面与其上下文之间的句法关系,即上下文词在句法上与方面的接近性,证明了句法相关比语义相关更有利于方面级情感分类。

基于深度学习的心理咨询问题研究也在高速发展。其中,IBM 研发了一种临床高危人群精神障碍发作预测系统,可以实现患者语音的自动采集并进行分析预测^[20]。Starlet 等^[21]提出了一种基于 Emo-DB 的情感识别系统,对语音中的韵律特征进行提取和分割,具有较好的情感识别效果。Tadesse 等^[22]通过深度学习和基于机器学习方法针对 Reddit 数据以此来检查其是否包含自杀的想法,并建立了一种基于情绪环形模型的网络社区组标签和基于关键字的数据获取技术,以提高实验精度。

基于以上研究,在大学生心理咨询分析领域,目前主流的方法依赖于 Word2vec 生成词向量,在情感提取方面较为缺乏,且在实现有效分类的同时,这些模型在应用时也存在一定的局限性。与 RNN 模型相比, LSTM 能够处理可变输入数据并对远程顺序文本数据进行建模,但对上下文关联的识别较弱^[13]。且 LSTM 模型在特征提取层面可能造成文本信息缺失导致网络学习不充分,同时不能对句中上下文关联依赖进行充分利用。本文提出一种基于 BERT 与 BiLSTM 相结合的模型,在词向量转换时有效保留语义中的情感信息,同时通过双向网络模型更有效地学习文本全局语义信息和长距离依赖信息。将所构建的模型应用于 IMDB 数据集及所采集的大学生心理评估数据进行实验,以验证模型在心理评估上的准确性。

1 模型设计

本文提出基于 BERT^[19]和 BiLSTM^[20]的大学生心理咨询情感分析算法,其设计主要包括数据预处理、BERT 词向量表示、BiLSTM 改进算法、文本分类结果等模块,如图 1 所示。




图1 大学生心理咨询情感分析算法流程

Fig. 1 Algorithm process for emotional analysis in psychological counseling for college student

在获取大学生心理访谈文本后,采用文本特征表示方法,将大学生的文本信息转化为词向量,然后基于本文方法对所获得的词向量进行语义分析,以获得实验结果. 模型设计依据系统方法理念,分析确定评估等级,设计自动评估框架,选择评估策略,实施模型评估,评价模型评估效果,修正模型参数并加以应用. 模型主要分为数据清洗及预处理、基于文本特征表示、基于深度学习的情感计算、心理健康评估模型生成4个部分.

1.1 数据处理

数据预处理是一种去除文本中的噪点数据和干扰项,保留有效信息,以更好地对有效语义进行特征提取的方法. 本文采用机器学习和数据挖掘的方法,从文本语料库中提取有意义的信息后将其提供给任何分类模型.

数据预处理方法如图2所示,主要分为5个步骤:

(1)数据清洗:去除文本中的无意义符号,仅保留字母、数字、汉字;

(2)统一语言:将获取的中文转换为英文,并对数据进行统一;

(3)数据去噪:过滤掉文本中的无实际表达意义的文本,并进行二次分词;

(4)构建情感词典:采用预分词技术,提取情感表达较强烈的词语,特别注意提取语句中的否定词以保留语义,构建情感词典;

(5)生成数据集:将数据集分为训练集和测试集,取数据集中25%的数据用于精度测试.

1.2 词向量提取优化

BERT^[18]模型采用Transformer(Trm)结构及无监督与训练,主要用于语言模型构建,采用无监督学习方法进行训练以提取无标注文本中的深层次的文本特征向量;针对不同下游任务进行微调(fine-tune),将预训练得到的模型结构和参数作为输入,根据具体问题数据集调整最后一层网络的参数,以进一步拟合模型. BERT模型结构如图3所示.

图中, $E_1 \sim E_n$ 为输入文本,表示通过 n 个模块对输入信息,经过随机初始化或word-piece嵌入等方法转换为一维词向量, $T_1 \sim T_n$ 为经过计算后输出的结果.由此可见,BERT与其他预训练模型最大的区别在于采用了双向Transformer结构,且由于预训练只需学习语义特征无需解码,因而可利用其中的编码(Encoder)模块进行特征表示,再根据词汇信息经编码将词汇转变为向量,通过计算将每个词语转换为分布式的词向量供计算机识别,如图4所示.

BERT作为一种预训练模型,主要完成了以下任务:

(1)MLM(masked language model)任务:BERT会对传入的心理咨询语句中的15%的单词进行mask,

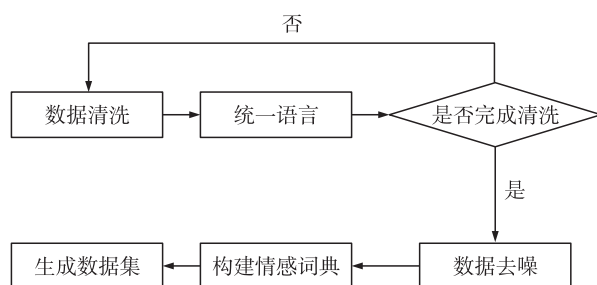



图2 数据预处理流程

Fig. 2 Data preprocessing

图3 BERT的架构图^[18]Fig. 3 Architecture diagram of BERT^[18]

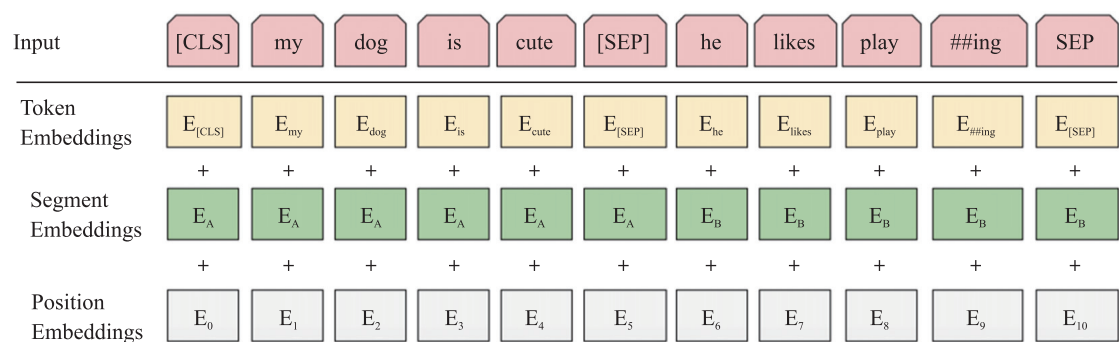


图 4 BERT 输入表示^[18]

Fig. 4 BERT input representation^[18]

随后模型对该部分单词中的 80%单词使用[MASK] 标签替换,10%的单词进行随机替换,剩余 10%的词保持不变但需要进行被预测. 通过该方法可以让模型对心理咨询中的原有词进行预测,而非对随机单词进行预测,从而使模型拥有更好的提取心理咨询语句上下文信息的特征.

(2)NSP(next sentence prediction)任务:将心理咨询语句采用 A、B 两句为一组的方式组成样本,正样本采用 AB 句式,负样本采用 BA 句式. 其中,50%的数据确定采用 BA 句式组句,标记为(IsNext) ;剩余 50%的数据 B 选自随机组句,标记为(NotNext) ,并通过模型预测 B 是否为 A 的下句.

相较于传统的单词表示技术并未充分利用单词的形态结构包含有关单词含义的关键信息,采用 BERT 对算法进行优化,可以更好地发现单词之间的上下文联系,从而获取深层的情感特征.

1.3 算法改进

目前基于深度学习的情感识别方法所采用的主流网络结构是 LSTM,其结构如图 5 所示,可以更好地克服 RNN 模型在长序列预测中的缺陷,且在实验中获得了较高的精度. 但本文通过实验发现 LSTM 为单向网络,在实际训练中无法获取文本信息中高质量的情感特征表示. 为了增强 LSTM 在情感分析实验中对逆向语义信息的缺失,本文采用改进后的 BiLSTM 算法来进行情感提取^[22].




图 5 LSTM 结构图^[23]

Fig. 5 LSTM structure diagram^[23]

BiLSTM 神经网络为共享权重的双向 LSTM 神经网络,包含前后两个方向的 LSTM,可以学习神经网络中的正向与逆向语义信息,从而更有效地处理谈话中的情感时间序列信息,更好地提取语义中的时间序列,更精确地处理语义中表达的情感信息. BiLSTM 结构如图 6 所示.

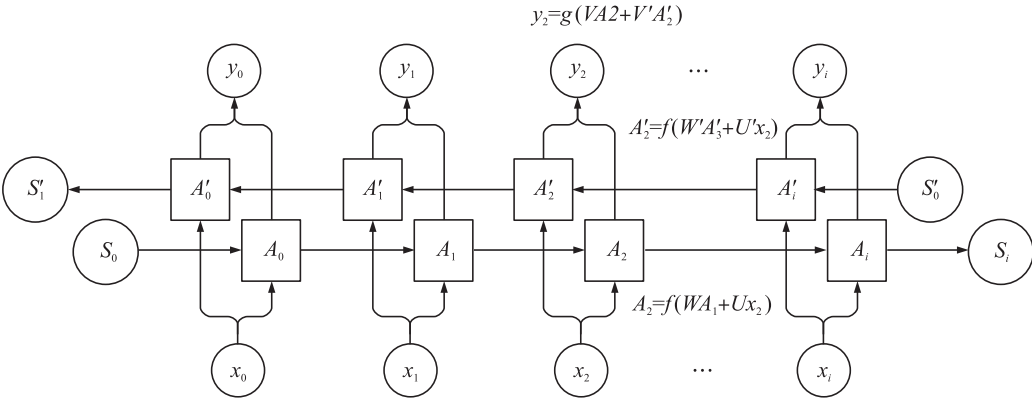


图 6 BiLSTM 结构图

Fig. 6 BiLSTM structure diagram

该网络包含正向计算与反向计算,预测结果通过前向和反向计算共同决定,整个神经网络共享权值,最终输出及结果来自于 A 和 A' 。进行正向计算时保存每个隐含层的输出,并在反向计算时进行二次计算,结合相应时刻前向和后向的计算结果进行学习预测。

在 BiLSTM 中,首先输入层接受谈话信息的时间序列数据,然后网络模型进行正向传播,接收并处理谈话信息文本内容及时间序列数据,输出隐藏层向量。而后进行反向传播,并输出另一个隐藏层向量。最后,将前向和后向输出结果进行连接。BiLSTM 可以有效地提取学生谈话记录中的语义信息和情感内容,双向训练可以有效加强模型提取能力,更适合于情感提取任务。

本文基于 BiLSTM 提取的情感语义特征模型,通过增加自注意力机制(Self-Attention)对文本进行编码,加强模型对关键特征的注意力,并将其作为独立的语义特征加入到提取的特征表示中,以提高情感提取能力。注意力机制可以提升模型对输入数据中不同位置之间的相互作用,可通过下式计算:

$$\text{Self-Attention} = \text{softmax}\left(\frac{\mathbf{W} * \mathbf{W}^T}{\sqrt{k}}\right) \mathbf{W}.$$

2 实验及结果分析

2.1 数据集

实验采用来自 IMDB 的公开数据集,研究改进模型效率。数据集包含 50 000 条影评数据,已被标记包含正/负(即积极/消极)两个类别的二分类,样本依据评级进行标记,评级小于 5 为负样本,其余为正样本,正负样本比为 1:1。经预处理后,将数据集的 25% 作为测试集进行测试。使用训练集来训练神经网络模型,对多种神经网络进行调试,最后用测试集评估各个模型的泛化能力。

为了解模型在高校心理咨询工作中的实际运行情况,本文共对 10 位学生开展访谈工作。为保证访谈的顺利进行,在正式访谈之前对 10 位学生均有了解和接触,具备访谈要求的信任关系。访谈在相对固定的谈话室进行,保证谈话环境的灯光、环境,确保会谈不受打扰。在受访者知情且同意的情况下,对谈话采用录音的数字化记录方式,再将语音资料转换为文字稿,通过深度学习方式进行实时识别。选取正负样本各 40 条,建立学生测评样本集。采用 80% 的数据作为训练集,20% 的数据作为测试集,对训练效果进行评估,以测试本文设计方法在实际应用中的分析效率。同时与现有的部分情感分析算法进行对比,如传统 RNN 算法、传统 LSTM 算法,并引入准确率指标 ACC 对精度进行分析。

2.2 实验配置环境

本文采用 BiLSTM 的预训练模型,将 IMDB 数据和大学生心理数据分别作为基准数据集进行实验比较,将 RNN、LSTM、BiLSTM 与本文训练方法进行实验效果对比。实验配置为 i7-13700K,内存 32G,Ubuntu20.04 操作系统,Python 运行环境。实验标准安装设计流程,统一所有的参数设置,实验循环次数均以拟合最优结果进行实验预测。

2.3 评价指标

本文将网络模型生成结果与实验组人工标识结果进行对比,正确结果为 True,错误结果为 False,最终实验精度计算公式为:

$$\text{ACC} = \frac{\text{True}}{\text{True} + \text{False}}.$$

2.4 实验结果

混淆矩阵是用来评价分类器性能的一种特殊矩阵,通过将分类器的预测结果与真实情况进行比较,得出预测正确和预测错误的情况,进而计算出评价指标。本文采用混淆矩阵来验证所提模型的精度。为了验证各项改进部分的作用,根据模型设置实验组,对这些模型进行对比实验,具体结果如表 1 所示。

可以看出,BiLSTM 获得了较好的实验精度,通过 BERT+BiLSTM 可以更好地提取文本中的隐含语义。LSTM 较好地解决了 RNN 因梯度问题与长短句问题导致的准确率较低问题,在实验结果中 LSTM 的

表 1 IMDB 数据集实验精度

Table 1 Experimental accuracy of IMDB dataset

模型	ACC
N1	82.63%
N2	86.08%
N3	96.21%

注:N1,RNN 模型;N2,LSTM 算法;N3,本文提出方法。

结果优于 RNN 模型,证明基于 LSTM 的网络在提取语义方面有较好的性能。但 LSTM 在结合下文内容方面要弱于 BiLSTM。日常表达式情绪信息点较为分散且上下文关联较大,本文提出的方法可以更有效解决上述问题。本文所提方法准确率可达 96.21%,可以较好地应用于日常学生心理咨询的文本信息处理。

通过对学生日常心理咨询数据进行训练与分析,并改进模型生成预测结果,可以有效识别学生语言中表达的情感导向,实验精度可达 89.73%,可以有效地应用于大学生情感提取。

3 结论

本文从深度学习模型结构与词向量转换等角度进行尝试,并通过相关实验进行验证,得出以下结论:

- (1) 针对语义情感提取,本文提出方法有较大优势;
- (2) 在相同参数下,使用 BREF 转换词向量有助于提升精度;
- (3) 加入自注意力机制可以在保持较高的精度下,有效地提高模型的运行效率;
- (4) 针对不同网络结构组成不同的模型,本文的模型能取得更好的指标,进一步证明了本文模型对大学生情感语义分析的改善。

本文通过批量分析对学生心理问题做了对比研究,采用 BERT 的文本表示模型并与 BiLSTM 模型结合提升了模型精度。与传统的 RNN 模型和 LSTM 模型相比,本文模型在 IMDB 上获得了 96.21%的精度,且在实际学生日常心理咨询数据中获得了 89.73%的精度,具有较好的应用价值。本文方法为大学心理工作者在日常谈话心理分析工作中提出一个批量处理方案,帮助工作者提取容易忽视的隐含语义,从而进行更有效的分析。

[参考文献](References)

- [1] 俞国良,王浩. 构建新时代心理健康教育新格局[N]. 中国社会科学报,2021-12-09(007).
- [2] 黄潇潇,张亚利,俞国良. 2010~2020 中国内地大学生心理健康问题检出率的元分析[J]. 心理科学进展,2022,30(5): 991-1004.
- [3] 赵志川. 大学生心理咨询与心理健康教育概述——评《大学生心理咨询与心理健康教育》[J]. 中国教育学刊,2023, 362(6):127.
- [4] 陈爱平. 高职院校学生心理健康教育现状与实施策略探究[J]. 创新创业理论与实践,2021,4(9):58-59.
- [5] 刘潇,张磊. 高校辅导员谈心谈话工作开展探究[J]. 教育理论与实践,2020,40(6):41-43.
- [6] 原多多. 产品评论文本的情感分析方法研究[D]. 兰州:兰州财经大学,2019.
- [7] 姚天昉,程希文,徐飞玉,等. 文本意见挖掘综述[J]. 中文信息学报,2008,22(3):71-80.
- [8] 钟丁媛,高峰洲,金皓辰,等. 基于 NLP 文字处理的评论有用性探究[J]. 科技风,2020(31):150-153.
- [9] 陈颖,肖仲喆. 离散标签与维度空间结合的语音数据库设计[J]. 声学技术,2018,37(4):380-387.
- [10] WIEBE J M, BRUCE R F, O'HARA T P. Development and use of a gold-standard data set for subjectivity classifications[C]// Proceedings of the 37th Annual Meeting of the Association for Computational Linguistics. Stroudsburg, USA: ACL, 1999:246-253.
- [11] KAMAL A. Subjectivity classification using machine learning techniques for mining feature-opinion pairs from web opinion sources[J/OL]. arXiv Preprint arXiv:1312.6962, 2013.
- [12] SCHOUTEN K, FRASINCAR F, DE JONG F. Commit-P1wp3: a co-occurrence based approach to aspect-level sentiment analysis [C]//Proceedings of the 8th International Workshop on Semantic Evaluation(SemEval 2014). Dublin, Ireland: ACL, 2014.
- [13] 肖海艳. 基于深度学习的在线教师课程评论情感分析模型[J]. 电子设计工程, 2023, 31(6):39-42.
- [14] WANI T M, GUNAWAN T S, QADRI S A A, et al. A comprehensive review of speech emotion recognition systems[J]. IEEE Access, 2021, 9:47795-47814.
- [15] 柴源. 基于 LSTM 和 Word2vec 的图书评论文本情感分析研究[J]. 信息技术, 2022, 46(7):59-64.
- [16] MIKOLOV T, CHEN K, CORRADO G, et al. Efficient estimation of word representations in vector space[J/OL]. arXiv Preprint arXiv:1301.3781, 2013.
- [17] 谢思雅,施一萍,胡佳玲,等. 基于 BiLSTM-ATT 的微博用户情感分类研究[J]. 传感器与微系统, 2021, 40(2):26-29.
- [18] DEVLIN J, CHANG M W, LEE K, et al. BERT: pre-training of deep bidirectional transformers for language understanding[J/OL].

- arXiv Preprint arXiv:1810.04805,2018.
- [19] ZHANG C, LI Q C, SONG D W. Syntax-aware aspect-level sentiment classification with proximity-weighted convolution network[C]//Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in information Retrieval. New York, USA: ACM,2019:1145–1148.
- [20] CORCORAN C M, CARRILLO F, FERNÁNDEZ-SLEZAK D, et al. Prediction of psychosis across protocols and risk cohorts using automated language analysis[J]. World Psychiatry: Official Journal of the World Psychiatric Association(WPA), 2018, 17(1): 67–75.
- [21] STARLET B A, BEN B P, LEENA M. Utterance and syllable level prosodic features for automatic emotion recognition[C]//Proceedings of the 2018 IEEE Recent Advances in Intelligent Computational Systems(RAICS). Thiruvananthapuram, India: IEEE, 2018, 31–35.
- [22] TADESSE M M, LIN H F, XU B, et al. Detection of suicide ideation in social media forums using deep learning[J]. Algorithms, 2019, 13(1): 7.
- [23] GREFF K, SRIVASTAVA R K, KOUTNÍK J, et al. LSTM: a search space odyssey[J]. IEEE Transactions on Neural Networks and Learning Systems, 2016, 28(10): 2222–2232.

[责任编辑:严海琳]