



开放科学
(资源服务)
标识码
(OSID)

基于混合机器学习的网络舆论情感识别方法研究

王思丽^{1,2} 杨恒^{1,2} 刘巍^{1,2}

1. 中国科学院西北生态环境资源研究院文献情报中心 兰州 730000;

2. 甘肃省知识计算与决策智能重点实验室 兰州 730000

摘要: [目的/意义] 提高网络舆论情感识别的效率和准确性, 为决策者评估舆情倾向提供有效技术支持。[方法/过程] 综合利用机器学习和深度学习的优点, 将情感极性向量 Sentimet_Embedding、预训练词向量 Word2Vec 等多通道特征嵌入方法, 双向长短期记忆网络 BLSTM、卷积神经网络 CNN 等深度神经网络模型, 以及随机失活 Dropout、批标准化 BN 等技术策略有机结合, 构建了融合文本情感极性和预训练语义特征的基于混合机器学习的网络舆论情感识别模型, 并通过收集社交媒体评论文本数据集对模型的可行性与有效性进行了验证。[局限] 方法及模型性能尚未达到最优, 未来仍有许多可以改进的空间。[结果/结论] 研究表明, 通过多通道特征嵌入方法及混合叠加神经网络模型能够显著提高网络舆论情感识别模型的性能; 基于混合机器学习的网络舆论情感识别模型比传统机器学习或单一深度学习分类模型的识别精度高。

关键词: 混合机器学习; 深度学习; 网络舆论; 情感识别; 特征嵌入

中图分类号: G356; TP391

Method of Online Public Opinion Sentiment Recognition Based on Hybrid Machine Learning

WANG Sili^{1,2} YANG Heng^{1,2} LIU Wei^{1,2}

1. Literature and Information Center of Northwest Institute of Eco-Environment and Resources, Chinese Academy of Sciences, Lanzhou 730000, China;

2. Key Laboratory of Knowledge Computing and Intelligent Decision, Gansu Province, Lanzhou 730000, China

Abstract: [Objective/Significance] Improve the efficiency and accuracy of online public opinion sentiment recognition, and provide effective technical support for decision-makers to evaluate public opinion tendencies. [Methods/Processes] This study

基金项目 甘肃省哲学社会科学规划项目“基于大数据技术提升新闻媒体舆论监督能力研究”(2021YB158); 甘肃省自然科学基金项目“甘肃省医疗健康大数据资产管理模式与再利用机制研究”(23JRRA581)。

作者简介 王思丽(1985-), 博士, 副研究馆员, 主要研究方向为知识计算挖掘、机器学习、情报智能分析, E-mail: wangsl@llas.ac.cn; 杨恒(1992-), 硕士, 馆员, 主要研究方向为知识计算挖掘、机器学习、自然语言处理; 刘巍(1980-), 硕士, 副研究馆员, 主要研究方向为自然语言处理、知识计算挖掘。

引用格式 王思丽, 杨恒, 刘巍. 基于混合机器学习的网络舆论情感识别方法研究[J]. 情报工程, 2024, 10(2): 11-26.

comprehensively utilizes the advantages of machine learning and deep learning, and organically combines multi-channel feature embedding methods such as Sentimet_Embedding and Word2Vec, deep neural network models such as BLSTM and CNN, as well as technical strategies such as random dropout and batch normalization, constructs a hybrid machine learning based online public opinion sentiment recognition model that integrates text sentiment polarity and pre trained semantic features. Finally, the feasibility and effectiveness of the model are verified by collecting social media public opinion data. [Limitations] The performance of the method and model has not yet reached its optimal level, and further improvements are needed in the future. [Results/Conclusions] Research results indicate that the performance of online public opinion sentiment recognition model can be significantly improved through multi-channel feature embedding methods and hybrid overlay neural networks. The online public opinion sentiment recognition model based on hybrid machine learning has higher accuracy than traditional machine learning classification models or single deep learning classification models.

Keywords: Hybrid Machine Learning; Deep Learning; Online Public Opinion; Sentiment Recognition; Feature Embedding

引言

近年来, 由于互联网和移动通信网络技术发展的飞速化、智能化, 信息发布格式的日益自由化、灵活化以及新媒体社交网络平台访问交流的愈加实时化、便捷化, 越来越多的互联网用户正倾向于从传统通信工具(邮件、论坛、博客等)转向新媒体社交网络平台服务。以新浪微博(Weibo)、推特(Twitter)、脸书(Facebook/Meta)、油管(YouTube)等为代表的新媒体社交网络平台已成为人们分享信息、寻求帮助、讨论和交流问题、表达意见和情感的主要渠道, 了解突发公共事件的首要信息来源和当前社会舆情传播的重要媒介。如中国的社会公众人物等大多使用新浪微博进行信息分享, 美国的前总统特朗普和奥巴马等习惯使用推特进行政治交流, 韩国的政客和财阀们喜欢使用油管进行政治交流。新媒体社交网络平台作为网络舆论的集散地和发酵场极大地改变了传统媒体和舆论格局, 使得网络舆论在人们社会生活中的作用愈加凸显, 并可能影响到政策制定和政治运动。已有研究表明, 突发事件的传播中经常会

出现多个不同的主题, 不同主题下网络用户的情感表达会直接影响事件传播的速度和方向^[1], 可见用户在社交网络平台中的意见和情感表达, 不仅影响信息的传播速度, 而且能快速侵扰并感染其他用户的情绪, 最终导致舆情爆发。因此, 通过及时准确地分析和评估突发事件中的情感倾向、主体类别以及主客观观点等, 可以快速有效地判断公众信息需求和关注点, 掌握舆情传播趋势和路径走向, 为政府及相关舆论监督管理部门的决策者有针对性地制定舆情管控措施提供科学依据。

但以往的舆情监测手段多为基于热点事件的专题分析, 舆情分析预测模型多采用调查、统计分析或传统机器学习方法等, 常需要依赖大量的人工数据处理和特征设计, 不仅人力、时间成本消耗大, 准确率也不高, 而且缺乏普适性和可移植性。如何借助人工智能领域的机器学习和深度学习等前沿先进技术方法对舆情信息进行高效精准地分析, 辅助决策者快速及时地掌握舆情形势, 对舆情风险进行分类排查监测, 对舆论导向进行有效监督引导, 构建和谐的网络舆论环境已成为当前学术界关注的重

要问题。针对网络舆情分析中人工数据处理与标注成本高、特征设计与提取难度大、分类识别准确率有待提高等问题,本研究将结合网络舆情分析的情境和语境特点,综合利用机器学习和深度学习等方法技术构建网络舆论情感识别模型,并通过收集社交媒体评论文本数据集进行模型验证与分析,以实现对其文本内容中所蕴含情感的深度高效理解和细粒度分类识别。

1 研究背景

网络舆论监督与治理是政府工作的重要组成部分,网络舆论主题与情感分析是网络舆论环境治理的基础性工作。网络舆论是指人们通过网络对自己关心的或者与自身权益密切相关的公共事件和社会现象的主观反映。它具有随机性、匿名性、突发性、复杂性、传播范围广、传播速度快等特点^[2],容易出现群体极化倾向,形成较大的群体压力。目前,国内外相关学者对网络舆论的产生/形成、传播/演化、监测/预警、引导/管控、应对/治理机制、路径和策略,对社会经济、政策和政治的影响和对策等都有一定的研究。如魏永^[3]对重大突发事件网络舆情群体极化的形成机制、传播过程和引导策略进行了研究。Huang^[4]分析了网络舆论对公共政策的影响并提出了对策。Kim等^[5]衡量了网络舆论在政治背景尤其是政府评价中的应用,并以总统认可为例进行了数据收集、模型训练与分析。

网络舆论情感分析所使用的数据集,一般可分为以下三种:(1)使用来自微博或推特的数据集。由于新浪微博和推特是当前国内和国外使用最广泛的社交媒体软件,具有用户基数

大、热点展示直观、传播速度快、易于采集挖掘等特点,现有文献大多以新浪微博或推特中的帖子主题、评论及相关信息作为数据集来源和研究对象。推特还提供了专门的应用程序访问接口 API,供研究者申请和获得授权使用后通过机器程序批量采集获取指定主题或时间段的推文及相关信息。如 Hu 等^[6]发布了一个从新浪微博收集的细粒度的大规模 COVID-19 社交媒体数据集 Weibo-COV V2,包含 6500 余万条新浪微博帖子信息、交互信息、位置信息和转发网络等综合信息块,可供用户从多个角度对疫情防控相关的网络舆情进行分析。(2)使用其他来源的公开数据集。在开源代码托管平台 Github、机器学习竞赛平台 Kaggle、国际语义评测大赛 SemEval 等平台上可免费获取一些不同主题的用于网络舆论情感分析研究的开源数据样本集、基准集等^[7-8]。(3)根据所研究关注的主题方向综合运用多种方法自行构建数据集。由于专用于网络舆论情感分析的公开数据集总体上相对还比较少,自行构建数据集是目前应用最广泛的方法。一般首先通过网络爬虫程序或采集工具进行主题搜索采集与解析清洗,然后通过人工或机器学习方法对数据进行标引分类,形成所需要的数据集。如 Liu 等^[9]通过领域关键词匹配抓取微博相关信息和人工标注分类方式构建了电力运维领域舆情数据集。Khan 等^[10]通过搜索采集谷歌地图平台中的实体评级和评论信息,构建了用于评估和分析用户对印度德里公共图书馆实施和服务意见的数据集。

网络舆论情感分析所使用的技术方法,一般可分为以下四种:(1)基于舆情调查的方

法。该方法具体又可包括民意调查（如面对面 / 焦点小组 / 实地、网络 / 电话 / 邮件访谈等）、问卷调查（线上、线下）、网络投票计数等。Chen 等^[11]提出舆情调查一般应从方向、强度、稳定性、信息内容等四个维度展开，其中方向维度用于显示公众在问题上的立场，如支持、反对或不确定等；强度维度用于表示公众对问题的感受有多强烈；稳定性维度用于指示随着时间的推移公众意见是否具有 consistency；信息内容维度用于揭示公众意见的具体内容，对公众形成对公共问题的合理意见至关重要。但该方法通常比较耗时，需要大量专业人员，可能存在样本代表性不足，难以处理海量数据和解决应急管理挑战等问题，并且在后期量化舆论与相关政策之间的关系时仍具有很大挑战性，有时甚至不可能实现。因此一般多由政治领导人、政府相关职能部门、新闻媒体类行业专业部门等针对一些非应急性公共政策问题发起使用。（2）基于情感词典的方法。常用的开源情感词库有情感认知评价模型 OCC（Ortony Clore Collins）^[12-13]、社交媒体网络情感分析库 VADER（Valence Aware Dictionary and sEntiment Reasoner）^[14-15]、基于英文词汇数据库 WordNet 扩充的情感词典、知网 HowNet 情感词典、BosonNLP 情感词典、清华大学中文褒贬义词典、台湾大学 NTUSD 中文情感极性词典、大连理工大学情感词汇本体库等。该方法因为易于操作实施，并且预测过程及结果可解释而曾被广泛使用。但需要依赖大量人工进行特征分类和分析，且属于机械式的模式规则匹配方法，常忽略了文本的上下文语义关系信息，可能存在与应用领域情景表达不匹配的情况，因

此目前一般作为机器学习的种子词典或先验方法使用，用于获取和生成机器学习模型训练所需的情感分类标注语料。（3）基于机器学习的方法。该方法是传统舆情分析最常使用的方法，其主旨是将舆论主题和情感分析转化为文本分类问题进行处理，因而几乎所有经典的机器学习算法模型都可直接或改进后使用。常用的如 LDA 主题模型^[16]、朴素贝叶斯 NB^[17]、支持向量机 SVM、决策树 DTree、随机森林 RF、高斯混合模型 GMM、最大熵模型 MaxEnt 以及各种数学推理及自然语言处理算法模型^[18-19]等。但传统机器学习文本分类方法仍依赖大量先验知识和人工提取复杂特征，会增加人力消耗并降低精度。（4）基于深度学习的方法。近年来，随着深度学习技术的不断发展，逐渐降低了早期人工特征选择提取的工作量，获得了更多的高维空间特征表示能力和更强的分析预测能力，并不断刷新和提高着分类精度。常用模型有卷积神经网络 CNN、循环神经网络 RNN、长短期记忆网络 LSTM、词向量模型 Word2Vec、双向语言表征模型 BERT（Bidirectional Encoder Representation from Transformers）以及通过对已有模型进行扩展改进形成的各种变体模型等^[20-26]。但大多数深度学习模型相对独立通用，通常直接对整个语料库文本进行编码，忽视了现有知识库的干预作用，很少结合场景特征和模型特征等多个模型进行多重滤波融合，使得预测的语义关系多而杂，却难以精而专。于是，许多研究者开始尝试将词典 / 规则、数学推理、机器学习和深度学习等多种算法模型以及多源数据或多模态数据结合起来^[27-32]进行研究探索，以提高网络舆论情感分类识别精度和

分析预测能力。如谭旭等^[27]结合BERT、LDA和时间序列预测模型ARIMA(Autoregressive Integrated Moving Average)等构建了基于深度学习的医患舆情情感分析预测模型,实验表明该模型可以有效地应用于医患舆情的多维度演化分析。Zhao等^[31]结合LSTM、门控循环单元GRU(Gated Recurrent Unit)和深度金字塔卷积神经网络DPCNN(Deep Pyramid Convolutional Neural Network)等多种深度神经网络算法模型构建了基于深度学习的微博文本舆情分析模型,实验表明该模型可以提高情感特征提取能力和分类精度。Alotaibi等^[32]基于特征提取算法TF-IDF(Term Frequency-Inverse Document Frequency)、双向长短期记忆网络BLSTM和启发式算法AFSO(Artificial Fish Swarm Optimization)构建了一种具有双向长短期记忆的人工鱼群优化模型AFSO-BLSTM,实验表明该模型可以有效地应用于舆论观点挖掘。

综合考虑上述各种研究方法的优缺点,本研究旨在构建网络舆论情感分析中的文本分类任务模型,通过融合和扩展已有情感认知模型、机器学习和深度学习等多种模型的优点,可以加速模型训练效率,提高情感倾向分类识别的细粒度和准确率,为相关行业部门实现舆情快速监测与有效监管提供技术方法支撑。

2 基于混合机器学习的网络舆论情感识别模型构建

2.1 网络舆论情感识别规则设计

本研究采用情感认知评价模型OCC设计情感规则知识库,作为网络舆论情感分析的基础

指标库和机器/深度学习模型的先验知识库,通过分类、量化、映射和表达等过程生成少量高质量的人工标注语料数据以形成初始训练集和情感极性向量Sentimet_Embedding,为下文研究奠定基础。OCC模型最早是在1988年,由Ortony等^[33]提出的一种情感分类词表,包含高兴、赞美、愤怒等22种基本情感类型,由于分类比较详细且易于量化计算,因而近年来被国内外学者从不同角度广泛研究改进和应用于情感计算建模。OCC模型的主旨思想是认为情感来源于人类对事件、对象和智能体所组成情境的认知评价。OCC模型的评价指标是事件结果、对象行为和对象形象,基本原理是首先根据一组评价指标将人类对特定情境的反应区分为正面或负面情绪,然后根据评价指标的不同取值组合判定最终的情感类型。本研究认为情感识别规则的构建不仅需要包含常见的情感词汇和分类,而且需要考虑评价主体所处的情境以及评论时的语境。可根据评价主体所处的不同情境而在分析时有所侧重,例如,如果评价主体更关注事件结果,则重点分析评价主体对事件结果的满意程度;如果评价主体更关注对象行为,则重点分析评价主体的行为规范;如果评价主体更关注对象形象,则重点分析评价主体对评价对象的情感态度。事件结果的满意程度、对象行为的规范程度、对评价对象的情感态度都将会影响最终的情感判定结果。与此同时,评论主体评论时的语境则可根据事件评论文本内容的语义以及评论句子与情感词汇之间的语义关系进行表达。本研究的最终目标是倾向于为相关部门监控舆论环境、掌控舆论动向提供理论参考与技术支撑,因此将更注重

于分析理解网络用户对社会事件评论的情感倾向，尤其是负面的细粒度的情感类别。

基于以上认知原理和情感细粒度分类需求，本研究将评价主体的情感倾向分类为正面、负

面和中立三大类的同时，参考原始 OCC 模型中对情感类型的详细划分和定义描述，最终筛选和确定了以下几种情感作为情感知识库的基础情感类型，见表 1。

表 1 情感识别规则

情感倾向	情感类别	唯一编码	评价指标
正面 (Positive)	高兴类 (Happy/Glad...)	P01	事件结果
	赞美类 (Good/Great...)	P02	对象行为
	感激类 (Appreciate/Thanks...)	P03	事件结果、对象行为
	喜欢类 (Love/Like...)	P04	对象形象
	同情类 (Sympathy/Pity...)	P05	对象行为、对象形象
负面 (Negative)	悲伤类 (Sad/Sorry...)	N01	事件结果
	批评类 (Condemn/Negate...)	N02	对象行为
	愤怒类 (Anger/Huff...)	N03	事件结果、对象行为
	厌恶类 (Disgust/Hate...)	N04	对象形象
	害怕类 (Fear/Scare...)	N05	对象行为、对象形象
中立 (Neutral)	其他类，如惊讶 (Surprise/Amaze...)	U01	不确定

这些情感识别规则并不能直接作为后续模型的输入内容，还需要转化为易于在文本中实现的功能形式。为了方便表达描述和量化映射计算，本研究为每一种情感类型都生成了唯一编码。如用“P01”表示“高兴”类情感，用“N01”表示“悲伤”类情感，则正面情感可表示为 P01-P05 的集合，负面情感可表示为 N01-N05 的集合。P01 和 N01 属于事件结果驱动的情感类型，用于表示评价主体对事件结果的满意程度，如果满意，则可将文本情感标记为 P01，反之，则为 N01。P02 和 N02 属于对象行为驱动的情感类型，用于表示对象行为规范是否符合评价主体的预期希望，如果符合，则可将文本情感标记为 P02，反之，则为 N02。P03 和 N03 属于双重驱动的情感类型，用于表示当事件结果与对象行为交互时，评价主体可能产生

的情感态度，如果趋向于正面情感，则标记为 P03，反之，则为 N03。P04 和 N04 属于对象形象驱动的情感类型，用于表示评价主体对对象行为的看法和偏好，如果认同，则标记为 P04，反之则为 N04。P05 和 N05 同样属于双重驱动的情感类型，用于表示当对象行为与对象形象相互叠加产生影响时，评价主体可能产生的情感态度，如果趋向于正面情感，则标记为 P05，反之，则为 N05。对于无法判定的情感类型，如惊讶等，则标记为 U01。如果最终把整个情感规则知识库视为情感向量空间，情感类型作为情感变量赋值给文本，则每个文本的情感极性向量计算公式可表示如下：

$$S = [S_{P01}, S_{P02}, S_{P03}, S_{P04}, S_{P05}, S_{N01}, S_{N02}, S_{N03}, S_{N04}, S_{N05}, S_{U01}] \quad (1)$$

其中：S 表示文本的情感极性向量， S_{P01} 等

表示情感极性向量在各维度的取值，取值范围为 [0,1]。

正面、负面、中立情感向量计算公式可分别表示如下：

$$S_{positive} = S_{P01} \cup S_{P02} \cup S_{P03} \cup S_{P04} \cup S_{P05} \quad (2)$$

$$S_{negative} = S_{N01} \cup S_{N02} \cup S_{N03} \cup S_{N04} \cup S_{N05} \quad (3)$$

$$S_{neutral} = 1 - S_{positive} - S_{negative} \quad (4)$$

2.2 网络舆论情感语料标注策略

常规的无标记网络舆论数据海量且易于获取，但基于机器学习的网络舆论分析通常还需要高质量的标注数据作为学习语料。而数据标注又需要较高的时间和经济成本，且难以实现对大规模语料的高效标注。随着人工智能技术的深入发展，如何利用少量人工标注数据来降低数据标注成本，提高机器模型的学习效率也已成为一个重要问题。鉴于此，本研究设计了主动学习算法对未标注的网络舆论数据集进行扩充标注，通过少量高质量人工标注数据，选择最有价值和信息量最大的样本进行机器自动标注，以有效减少模型学习所需的人工标注数据量及提高模型训练性能。

主动学习算法实施的关键在于未标记样本选择策略的使用。学界常用的主动学习策略有随机采样策略、不确定性策略、委员会投票策略、差异性缩减策略（方差 / 误差）、特征选择策略（密度 / 权重）等^[34]。本研究主要采用最大置信度与最不确定样本相结合的策略来选择高质量的未标记数据。在学习阶段，在初始训练集上训练基础分类器，得到初步的舆论分析模型，然后利用该模型对未标注样本进行分类，选择分类结果置信度最高的样本加入训练

集。同时，主动学习策略主要用于选择不确定性最高的样本，也即分类置信度最低的样本，该类样本中一般包含较多的情感信息，因此对于修正深度学习分类器模型最有帮助。这部分样本是利用上文所述方法人工标注形成的，然后将标注好的样本加入训练集中。在下一次迭代过程中，利用扩展的训练数据集建立分类模型，经过反复迭代，保存学习模型以供最终预测，直到满足终止条件。具体算法流程如下，见图 1：

(1) 将样本数据按照是否人工标注分为标注数据集和未标注数据集，标注数据集按照 7:2:1 的比例分为训练集、测试集和验证集；

(2) 使用已标注的少量舆论样本数据训练深度学习分类器，得到初始分类模型；

(3) 利用当前分类模型对未标注数据样本中的数据进行分类预测，得到每个样本数据的分类阈值。根据最大置信度和最不确定的抽样策略，将置信度高的数据直接加入训练数据集，人工标注高不确定性的样本数据；

(4) 将人工标注的舆论样本数据加入训练数据集中，然后使用更新后的训练集重新训练当前模型，得到更新后的分类模型；

(5) 验证更新后的模型，根据迭代次数从第 3 步循环到第 5 步。

2.3 网络舆论情感分析模型构建

网络舆论文本与普通文本的最大不同之处是网络舆论文本一般为短文本，且可能缺乏一定的上下文语境信息，从而导致舆论分析中缺少关键的语法和语义知识。因此，本研究主要采用多通道输入、多粒度卷积和高速通道直接

连接来预测缺失的知识元素，将多种神经网络有机结合，首先根据情感类型、时间和空间维度提取和表征特征，然后从规则、特征和结构方面对模型进行探索，最终构建了基于混合机

器学习的网络舆论情感识别模型，可以实现对网络舆论情感的客观快速识别和分类。具体步骤包括数据预处理、特征提取、模型构建、模型训练和测试四个方面。

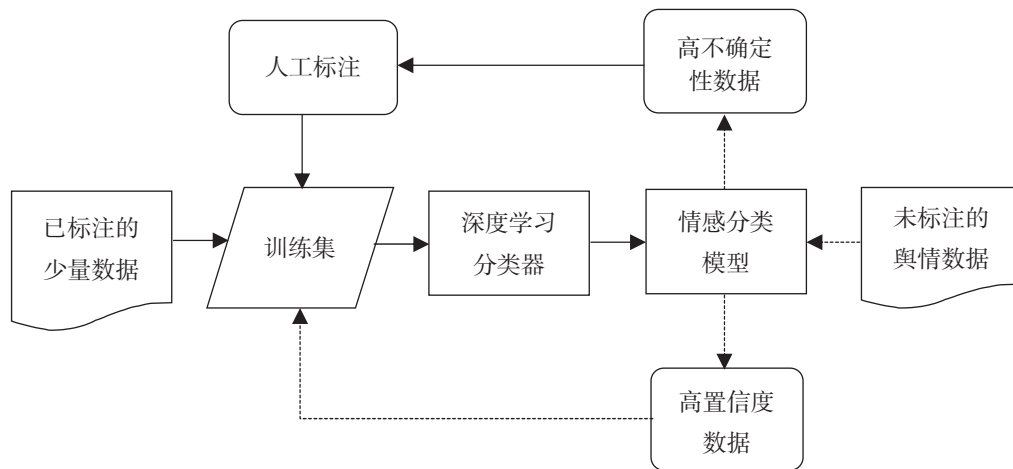


图1 基于主动学习策略的舆情数据集扩充标注算法流程

2.3.1 数据预处理

数据预处理主要是为了规范数据格式，改善数据集质量，从语料端提升模型表征能力和学习效率。首先，需要导入必需的数据清理和标记化组件库，如NLTK、spaCy等。其次，加载待分析的舆情样本数据集并执行一些初始化的探索性的数据清理。主要是删除一些不相关及含有噪声的嘈杂数据，如包含了超链接、特殊字符（表情符号、脏字符、乱码、HTML标签等）、艾特或提及了其他用户的文本内容部分等。再次，根据样本数据集语种的不同实施不同的处理策略，最终目的是将样本数据集中的每个文本都分解为规范的主题关键词集合。如果样本数据集为英文文本，则需要去除停用词、统一转换为小写（减少词汇量）、进行词干提取（将词的所有不同变体都用同一种形式表示）等。如果样本数据集为中文文本，则一般先利用分词工具及情感词典进行中文分词处理，然后根据文本实际情况去除停用

词及无意义的高频词汇等。最后，将处理后的文本数据标记化，转换为固定长度的数字序列格式以进行语义特征提取和表示。

2.3.2 特征提取

传统机器学习一般使用Bag-of-words、TF-IDF、N-gram等算法技术来表示文本数据。目前深度学习主要使用Word2Vec、GloVe、FastText等预训练词向量模型从已标记化的文本数据中提取特征。这些方法能够将文本数据转换为可以输入深度学习神经网络模型（如CNN、RNN、LSTM等）的固定长度向量，并且可以按需灵活替换。本文在前期主要使用Word2Vec作为特征提取的预训练词向量模型，对于其他词向量模型则用于在后期进行实验对比分析。Word2Vec主要使用神经网络模型从大型文本语料库中学习单词的语义关联信息，学习的结果是将单词的含义映射到一个实值向量空间，使得相同含义的单词具有相似的表示且倾向于聚

集在一起，反之则彼此远离。Word2Vec 模型有两种核心算法架构：CBOW 和 SkipGram。其中 SkipGram 主要通过文本的中心词去预测上下文词，虽然预训练的时间复杂度比 CBOW 要高，但更适合短文本、数据量较小、低频词出现次数较多的情景。因此，本文主要使用 SkipGram 算法训练 Word2Vec 模型，依次将标记化文本中的每个词作为中心词，利用其对上下文词的预测情况和随机梯度下降算法等不断调整中心词的词向量，直至所有文本遍历完毕，即可得到包含文本中所有词特征的词向量模型。假设一个短文本标记化后含有 10 个单词，Word2Vec 预训练生成的词向量模型维度为 200，则该文本序列可表示为一个 10×200 的二维张量矩阵。该矩阵可以作为深度学习分类器的输入向量。

2.3.3 模型构建

研究发现，长短期记忆网络 LSTM 可以更

好地表示文本数据中时空顺序序列的语义，卷积神经网络 CNN 可以更好地挖掘文本数据的文体风格特征。因而，本研究主要将 LSTM 和 CNN 相结合构建深度神经网络模型（即深度学习分类器）对舆情数据中评价对象主观评价的情感倾向进行预测和分类。首先，使用 BLSTM 表示时空顺序规则，对文本数据序列进行建模；其次，通过联合输入情感极性向量 Sentimet_Embedding 和预训练词向量模型 Word2Vec，学习初始舆情数据的浅层句法和情感语义特征；接着，将学习到的特征输入到 CNN 中以进一步挖掘和提取深层局部特征，并将主要特征组合形成高级特征；最后，使用归一化指数函数 Softmax 构建深度学习分类器进行分类，并使用一些算法对模型进行优化。模型的基本结构包括输入层、卷积层、池化层、输出层四部分，见图 2。




图 2 基于混合机器学习的网络舆论情感识别模型结构

(1) 输入层

LSTM 是 RNN 的一种变体，不仅能像 RNN 一样将历史信息与当前数据很好地关联起来，而且可以学习和处理长时间长距离依赖信

息，反映和表征更为完整的上下文语境信息。LSTM 实施的关键是在神经网络的隐藏层中新增了一个单元状态变量，用于长期保存输入数据的值及梯度。对于给定的输入序列，LSTM

按时间顺序排列，通常执行以下步骤：控制和更新上一时刻传播到当前时刻的单元状态的数量和权重；控制和更新当前时刻的输入保存到单元状态的数量和权重；控制和更新当前时刻的单元状态输出到隐藏层的数量和权重；将当前时刻的单元状态输出到激活函数中获得最终的输出值。考虑到舆情传播问题的连续性，本研究使用双向长短期记忆网络 BLSTM 在时间维度上对数据进行建模，即将数据添加到两个 LSTM 中，一个是正向的时间顺序，一个是反向的时间顺序。为了补全文本信息，还获取了 LSTM 中每个时间点所有隐藏层节点的输出，将其连接起来求取平均值（二维张量）以作为后续网络的输入。本研究主要使用双通道嵌入层作为 BLSTM 的输入。通过将嵌入层设置为双通道，增加了嵌入层在高速通道层中的权重。通过改变参数值，可以对模型进行多次强化训练。通过语义信息的均衡动态变化和原始词向量表示可以进一步控制和优化模型。本研究构建的多通道输入层，主要是指基于 OCC 情感规则知识库对舆情文本转换形成的情感极性向量表示层 Sentimet_Embedding 和基于 Word2Vec 等词向量模型对舆情文本进行语义映射形成的预训练词向量表示层。

（2）卷积层

CNN 的独特结构使其具有局部连接、权重共享和时空二次采样等特点，可以有效减少权重计算的数量，比较适合解决多变量的分类问题。因此，本研究构建了卷积层，利用 CNN 的卷积核通过窗口滑动来提取输入数据的深层局部特征，即文本词向量和情感极性向量的上下文信息，根据权重对两个通道上的向量信息进

行卷积。卷积层的输入实质是 BLSTM 的二维张量输出，包含了每个时间点的时间维度和隐藏层节点信息。卷积层实施的关键是确定不同卷积范围（即文本提取特征）的二维张量的粒子大小。本研究中卷积核的体积不同于图像处理任务中的卷积核，因为卷积核的长度通常与词向量维度是一致的。为了确定最优值，本文对卷积核大小和卷积核类别进行了实验。实验结果表明，卷积核长度和词向量维度应保持一致，当卷积核宽度被设置为 3 时可以获得最佳分类精度。

（3）池化层

池化层主要采用压缩提取的方式以简化神经网络中特征图计算的复杂度。常用方法是最大池化操作，通过对二维张量的小邻域内的特征点进行整合，从而获得新的高级特征。本研究构建池化层，首先对上一步得到的每个卷积向量进行最大池化操作，提取每个特征向量的最大值来表示特征。然后从每个卷积得到一维向量，拼接所有最大池化结果，最终得到文本的向量表示。

（4）输出层

输出层为模型的最后一层，主要使用池化层的输出作为输入来预测任务问题所属的情感倾向类别。深度学习分类器将对任务问题进行概率分析计算，确定每个类别的匹配程度。最终输出的预测类别是概率值最高的结果。本研究主要使用随机失活 Dropout 和批标准化 BN（Batch Normalization）等技术策略来正则化模型以防止过度拟合，并使用分类交叉熵函数进行损失计算，同时使用自适应运动估计算法 Adam（Adaptive Moment Estimation）对模型进

行优化。

2.3.4 模型训练和测试

本研究在经过了标注、预处理、特征提取的数据上训练模型，主要使用交叉验证等技术来评估模型的性能，并使用提前停止等技术来防止模型过度拟合训练数据。训练过程中涉及的其他一些超参数的设置，如训练迭代次数、批次大小、词向量的维度、卷积核大小等，可根据实际情况和需求进行不断调优。模型测试主要是在未用于训练的测试数据集上进行，以评估模型性能。主要使用精确率 P 、召回率 R 和 $F1$ 分数等指标来评估模型在测试数据上的表现和分析模型的性能，计算公式如下：

$$P = \frac{TP}{TP + FP} \quad (5)$$

$$R = \frac{TP}{TP + FN} \quad (6)$$

$$F1 = \frac{2 * P * R}{P + R} \quad (7)$$

其中， TP 为模型预测正确的样本数量， FP 为模型预测的所有样本数量， FN 为模型预测错误的样本量。

3 模型实验与结果分析

3.1 数据集获取与预处理

本研究主要通过收集一些社交媒体评论文本数据集，以确定评论中表达的意见或情感倾向是正面的、负面的，还是中立的，并且细化到某一具体情感类别。本实验主要以中国公众在新浪微博上表达的对俄乌冲突看法的评论数据为例展开详细说明，但在实验结果分析环节会增加本方法在其他评论数据集上的实验效果进行对比分析，以充分验证其适用性与有效性。

尽管我们已普遍知晓，中国政府目前在国际外交上是保持中立立场，没有公开支持或反对任何一方。但中国公众的舆论多种多样，情感反映差异较大，有支持俄罗斯的，有支持乌克兰的，还有呼吁坚定中立立场的。为了更深入地理解和挖掘这些舆论中表达的细粒度主题和情感反映，首先，本研究利用网络采集器从新浪微博上收集了一些 2022 年 1 月至 2023 年 6 月期间中国公民关于俄乌冲突意见的评论文本，每个文本平均长度在 200 个字符左右，虽然并不能全面反映公众对此事的看法，但可以作为机器学习的初始语料以验证本方法的有效性。其次，由于单纯依靠人工标注的时间和经济成本较高，本研究基于上文设计的情感规则知识库和主动学习策略对初始语料进行了少量人工标注和机器自动扩充标注，根据文本内容及情感极性将其标注为正面、负面或中立。最初人工标注了 300 个数据集样本，其中正面、负面、中立情感各 100 个，经过二十余轮的迭代学习和机器扩充标注，最终形成的关于俄乌冲突意见的舆情样本数据集共包含 5024 个文本，其中正面情感 1896 个，负面情感 2703 个，中立情感 425 个。最后，还根据预设规则对已标注数据进行了清洗降噪和预处理，形成规范化、格式化语料。

3.2 实验工具与参数设置

本研究主要引入和使用了 Python3.6、深度学习框架 Tensorflow、神经网络计算库 Keras、机器学习组件库 Sklearn、自然语言处理组件库 NLTK、语义主题建模组件库 Gensim、数值/数据处理组件库 Numpy/Pandas、不平衡数据处理库 Imblearn 作为实验的基础工具环境。本研

究构建的舆情识别模型中涉及的主要参数名称、描述、取值及说明见表2。需要总体说明的是，这些参数及取值并不是固定不变的，而是可配

置更改或替换的，也并非取值越大越好或越小越好，需根据实际样本数据和训练结果情况进行不断探索调整，以使模型性能达到最优。

表2 舆情识别模型的主要参数

参数名称	参数描述	参数取值及说明
smote	由于数据集样本类别分布不均衡对数据执行过采样。	SMOTE 函数，取自 Imblearn，基于插值来合成新样本的采样方法。
test_size	将数据集样本拆分为训练集和测试集时，测试集所占的比例。	0.2，取自 Sklearn。
shuffle	在进行数据集样本拆分时，是否将现有数据顺序打乱进行重组。	true，取自 Sklearn，选择不打乱重组则设置为 false。
max_len	预训练模型时，允许输入文本序列的最大长度。	200，取自 Keras，应用在序列化函数和 BLSTM 模型中。
embedding_size	预训练特征向量的维度，其大小取决于语料库的大小。	200，取自 Gensim 和 Keras，应用在 Word2Vec 及 BLSTM 模型的构建和训练过程中。
hidden_units	神经网络模型隐藏层的单元数，其大小取决于输入样本的最大长度。	256，取自 Keras，应用在 BLSTM 模型的构建和训练中。
dropout	随机失活比率，用于减少神经网络计算参数和容量，防止过拟合。	0.3，取自 Keras，应用在 BLSTM 模型的构建和训练中。
kernel	卷积核数量，与特征层的大小及能抽象出来的特征数量有关。	32，取自 Keras，应用在 CNN 模型的构建和训练中。
kernel_size	卷积核大小，卷积核较小能够更好地捕捉局部特征，较大则能够更好地捕捉全局特征。	3，取自 Keras，应用在 CNN 模型的构建和训练中。
batch_size	批次大小，其大小影响模型的优化效率和使用。	32，取自 Keras，应用在模型数据填充过程中。
epochs	训练迭代次数。	100，取自 Keras，应用在模型数据填充过程中。
optimizer	优化函数，用于优化神经网络模型结构。	adam 算法，取自 Keras，应用在模型编译过程中。
loss	损失计算函数，神经网络模型的评价指标。	categorical_crossentropy 算法，取自 Keras，应用在模型编译过程中。

3.3 实验过程与结果分析

实验的核心过程如下：

首先，为了对本次舆情的主题有一个全局的了解，在进行情感识别之前，本研究利用 Gensim 组件对样本数据执行了 LDA 语义主题建模。通过多次调整主题聚类个数发现，一些主题类团以“战争”“支持”“侵略”“和平”“反战”等描绘行为概念的高频词为中心，一些主题类团以“俄罗斯”“乌克兰”“美国”“叙利亚”等描绘实体对象的高频词为中心，其中前者是出现概率最高的主题类团。但通过这些主题类团中离散的词汇是难以理解其真正情感倾向的，

因而需要进行情感细粒度分类识别。

其次，将样本数据加载到 pandas，并按一定比例拆分为训练集、测试集与验证集。如果样本数据集类别分布不均衡，拆分时还需要进行处理。本实验由于样本数据集中负面情感数据占比过高，因而使用 smote 算法对正面和中立情感数据进行了显著的过采样。接下来标记化文本，包括将每个序列转换为整数编码表示，并规范序列的长度。最后，准备输出数据。在数据预处理阶段，情感数据已被分类标记为正面、负面或中立，为了使其更适用于神经网络模型，情感数据将被转换为固定长度的向量，

其中每个位置对应一个情感类别，如负面=0，中立=1，正面=2等。最终数据将被转化为整数键值用于查找嵌入矩阵。

再次，为本研究构建的舆情识别模型定义一个基线，以便于判断模型是否优于一般的机器学习方法，有助于进行模型微调或错误调试，并权衡深度学习模型的训练成本（GPU、计算量、内存）、性能、时间复杂度等。一些常见的基线选择方法如：①预测主体类别。如预先假设微博评论文本中最常出现的情感是负面的。这是最简单但也最不精确的方法。②传统机器学习分类模型。如支持向量机、朴素贝叶斯、随机森林等。③专家分类方法。让一名或多名专家自己执行相同的分类任务，并使用他们的准确率/错误率作为人工水平基准。考虑到各方法的性能和实施的难易程度，本研究选择随机森林分类模型作为基线。随机森林分类模型，由于其对类别不均衡具有很好的鲁棒性，并且能通过一个基评估器影响和调整模型的精确度及复杂度，是传统机器学习分类任务应用效果较好的模型。使用样本数据集对基线模型进行评估，平均精确率为0.67，F1分数为0.60，详细评估结果见表3。

表3 基线模型的性能评估结果

情感类别	精确率 P	召回率 R	F1 分数
正面情感	0.65	0.46	0.53
负面情感	0.78	0.85	0.81
中立情感	0.60	0.39	0.47

最后，有了基线之后，本研究的基础目标是生产出F1分数大于0.60的模型。与传统机器学习方法不同，深度神经网络模型的一个优

点是可以将不同模块堆叠在神经网络上以提高性能。因而，为了实现这一目标，本研究按照前文方法构建和训练了基于混合机器学习的网络舆论情感分析模型，一方面验证其在网络舆论情感分析任务中融合文本情感极性和预训练语义特征的有效性，另一方面也尝试了不同的体系架构和参数配置，以比较和确定哪种模型能够产生最优的结果。对于每种模型，都使用一组相同的统计指标来评估，包括精确率P、F1分数以及在验证集上的损失值。在大多数情况下，本研究希望将损失值降至最低，并最大限度地提高精确率P和F1分数。在F1分数不可微分的情况下，同时使用其他技术策略如基于准确性的模型检查点、提前停止等来确保选择最佳模型。最终实验结果见表4。

表4 不同模型策略的性能对比

模型 + 策略	精确率 P	F1 分数	损失值
LSTM	0.68	0.62	0.82
BLSTM	0.70	0.64	0.75
CNN	0.65	0.61	0.79
BLSTM + CNN	0.72	0.66	0.70
Glove + BLSTM + CNN	0.76	0.69	0.72
Word2vec + BLSTM + CNN	0.78	0.70	0.69
LSTM + Dropout + BN	0.70	0.65	0.80
CNN + Dropout + BN	0.69	0.63	0.78
BLSTM + CNN + Dropout + BN	0.80	0.72	0.76
Glove + BLSTM + CNN + Dropout + BN	0.83	0.75	0.65
Word2Vec + BLSTM + CNN + Dropout + BN	0.85	0.80	0.68
Sentimet_Embedding + Word2Vec + BLSTM + CNN	0.88	0.83	0.62
Sentimet_Embedding + Word2Vec + BLSTM + CNN + Dropout + BN	0.90	0.86	0.60

此外，为了充分验证本文方法的适用性与

有效性，本研究还在一些其他主题的公开评论数据集上进行了实验对比。实验过程与上述类似，不同数据集最佳模型的性能评估结果见表 5。由于公开数据集大多已经过严谨处理，数据格式相对比较规范，且较少含有与主题无关的内容，因而其在上的实验性能要略高于本文自建的俄乌冲突评论样本数据集，这是符合本文预期的。

表 5 不同数据集的性能对比

数据集	精确率 P	F1 分数	损失值
航空公司问题评论数据集 ^[7]	0.94	0.90	0.66
总统竞选辩论舆情数据集 ^[8]	0.92	0.88	0.63

综合表 4 和表 5 的实验结果发现，通过混合叠加神经网络或特征嵌入方法，可以得到性能比基线具有显著改进的模型。一些核心的超参数调整，如预训练向量维度、神经网络隐藏单元数、卷积核大小、随机失活速率等，有助于进一步提高模型的精确率，但总体提升程度有限。相同的体系架构与参数配置下，不同的特征嵌入方法对神经网络模型的学习效果和分类准确性具有较大影响，基于预训练语义特征的 Word2vec 和 Glove 等模型的表示方法要优于基于词频特征的情感极性向量模型 Sentimet_Embedding 的表示方法。此外，虽然 Word2Vec 对模型精度的提升效果略优于 Glove，但两者各自的总体影响结果相差不大。究其原因，两者在学习词汇表外词语的表示、分离向量空间中位置非常接近但语义情感相反的词汇方面均存在较大局限。最终，由于样本数据的过拟合性和构建的混合神经网络模型的局限性，在没有更大的调整优化空间下，模型将处于一个学习的平稳期与瓶颈期。总体实验结果表明，本

研究构建的舆情识别模型不仅可以实现网络舆论情感倾向的细粒度分类识别，模型的精确率最高达到 0.94，F1 分数最高达到 0.90，性能明显优于一般机器学习模型，精确率比基线模型提高了 27 个百分点，F1 分数比基线模型提高了 30 个百分点；而且充分验证了融合文本情感极性和预训练语义特征的混合机器学习模型在网络舆论情感分析中的适用性，以及随机失活 Dropout 和批标准化 BN 等技术策略对模型精度和性能提升的有效性。

4 结论

与传统机器学习方法不同，深度学习在数据挖掘方面具有更高的准确性，其独特的网络可叠加和参数可共享机制能够显著提升模型的学习效率并减少模型的训练时间。为了提高网络舆论情感倾向识别的效率和准确性，本研究综合利用机器学习和深度学习的优点，构建了融合文本情感极性和预训练语义特征的混合机器学习模型对网络舆情进行自动分析挖掘。首先，基于情感认知评价模型 OCC 设计情感规则知识库，作为网络舆情分析的基础指标库和机器学习的先验知识库，通过分类、量化、映射和表达等过程生成少量高质量的人工标注语料数据以形成初始训练集和情感极性向量 Sentimet_Embedding，为下文研究奠定基础。其次，设计主动学习算法，采用最大置信度与最不确定样本相结合的策略，基于人工标注的少量高质量样本数据对未标注的网络舆情数据集进行机器自动扩充标注，以减少机器学习所需的人工标注数据量和提高模型性能。最后，基于社交媒体上网络舆论一般为短文本、情感词出现

频率高但缺乏上下文语境信息等特点,将情感极性向量 `Sentimet_Embedding`、预训练词向量 `Word2Vec` 等多通道特征嵌入方法,双向长短期记忆网络 `BLSTM`、卷积神经网络 `CNN` 等深度神经网络模型,以及随机失活 `Dropout`、批标准化 `BN` 等技术策略有机结合,构建了融合文本情感极性和预训练语义特征的基于混合机器学习的网络舆论情感识别模型。实验结果表明,与基于词频特征的情感词汇索引法相比,融合了文本情感极性和预训练语义特征的多通道特征嵌入方法更适合作为网络舆论情感识别模型的输入;通过多通道特征嵌入方法及混合叠加神经网络模型能够显著提高网络舆论情感识别模型的性能;基于混合机器学习的网络舆论情感识别模型比传统机器学习或单一深度学习分类模型的识别精度高,能够为网络舆情自动挖掘分析提供有效技术方法与情报决策支持。此外,本研究构建的模型目前处于一个学习的平稳期与瓶颈期,性能尚未达到最优,未来仍需要继续改进以进一步提高可靠性与适用性。如可通过翻译增强技术或集成其他社交媒体数据源等更主动的学习策略进一步生成或收集更多更新的样本数据集以提高模型的训练性能;可通过添加网络计量元数据(如评论、点赞、转发、关注人数等)、其他维度统计特征(如表情符号、标点符号计数、具有强烈情感表示的大写字母/单词计数等)或多层级注意力联合机制^[35](如词汇级、关系级、句子级、图结构等)等融合更多元的、更深层的语义特征以提高模型的分类识别精度;可通过更精细地微调超参数、更改分类模型的决策阈值、使用范围更广的交叉验证等策略依次分析和确认模型体系架构的

变化是否会有助于产生模型性能上细微或显著的变化;可探索创建更复杂的算法模型架构以获得更高性能的分类识别模型,如对以 `BERT`、`GPT` 为代表的大规模语言模型的微调和增强应用,使其支持对网络舆情的高效挖掘分析和推理解释等。

参考文献

- [1] HAIHONG E, HU YX, PENG HP, et al. Theme and Sentiment Analysis Model of Public Opinion Dissemination Based on Generative Adversarial Network[J]. *Chaos, Solitons & Fractals*, 2019, 121: 160-167.
- [2] XI CN, LI Q, YANG LL. Network Public Opinion Characteristics and It's Development Trend in the Time of Regional Change[C]//Public Administration in the Time of Regional Change (ICPM 2013). Paris, France: Atlantis Press, 2013: 161-166.
- [3] 魏永. 重大突发事件网络舆情群体极化形成机制、传播过程及引导处置研究[D]. 长春: 吉林大学, 2021.
- [4] HUANG B. Analyze the Influence of Internet Public Opinion on Public Policy[J]. *Open Access Library Journal*, 2020, 7: 1-9.
- [5] KIM D, CHUNG CJ, EOM K. Measuring Online Public Opinion for Decision Making: Application of Deep Learning on Political Context[J]. *Sustainability*, 2022, 14(7): 4113.
- [6] HU Y, HUANG HY, CHEN AF, et al. Weibo-COV: A Large-Scale COVID-19 Social Media Dataset from Weibo[J]. *arXiv Preprint, arXiv: 2005.09174*, 2020.
- [7] Figure Eight. Twitter US Airline Sentiment[DB/OL]. (2015-02-25) [2023-06-20]. <https://www.kaggle.com/datasets/crowdfLOWER/twitter-airline-sentiment>.
- [8] Figure Eight. First GOP Debate Twitter Sentiment[DB/OL]. (2015-08-08) [2023-06-20]. <https://www.kaggle.com/datasets/crowdfLOWER/first-gop-debate-twitter-sentiment>.
- [9] LIU XS, LI ZQ, LV JX, et al. Research on Key Technologies of Public Opinion Analysis of Power Operation and Maintenance Based on Deep Learning[C]//Proceedings of 2021 2nd International Conference on Artificial Intelligence and Information Systems (ICAIS '21). New York, USA: Assoc Computing Machinery, 2021: 1-6.
- [10] KHAN AM, LOAN FA. Exploring the Reviews of Google Maps to Assess the User Opinions about

- Public Libraries[J]. *Library Management*, 2022,43(8-9): 601-615.
- [11] CHEN YD, LI Y, WANG ZF, et al. Rapid Perception of Public Opinion in Emergency Events through Social Media[J]. *Natural Hazards Review*, 2022, 23(2): 04021066.
- [12] HUANGFU LW, MAO WJ, ZENG D, et al. OCC Model-Based Emotion Extraction from Online Reviews[C]//11th IEEE International Conference on Intelligence and Security Informatics. New York, USA: IEEE, 2013: 116-121.
- [13] 吴鹏, 李婷, 仝冲, 等. 基于 OCC 模型和 LSTM 模型的财经微博文本情感分类研究 [J]. *情报学报*, 2020, 39(1): 81-89.
- [14] ALENZI BM, KHAN MB, HASANAT MHA, et al. Automatic Annotation Performance of TextBlob and VADER on Covid Vaccination Dataset[J]. *Intelligent Automation & Soft Computing*, 2022, 34(2): 1311-1331.
- [15] BORG A, BOLDT M. Using VADER Sentiment and SVM for Predicting Customer Response Sentiment[J]. *Expert Systems with Applications*, 2020, 162: 113746.
- [16] SHI WZ, ZENG FX, ZHANG AS, et al. Online Public Opinion During the First Epidemic Wave of COVID-19 in China Based on Weibo Data[J]. *Humanities & Social Sciences Communications*, 2022, 9: 159.
- [17] NARAYANAN V, ARORA I, BHATIA A. Fast and Accurate Sentiment Classification Using an Enhanced Naive Bayes Model[J]. *arXiv Preprint*, arXiv: 1305.6143, 2013.
- [18] KARAMOUZAS D, MADEMLIS I, PITAS I. Public Opinion Monitoring through Collective Semantic Analysis of Tweets[J]. *Social Network Analysis and Mining*, 2022, 12: 91.
- [19] QIAN C, MATHUR N, ZAKARIA NH, et al. Understanding Public Opinions on Social Media for Financial Sentiment Analysis Using AI-based Techniques[J]. *Information Processing & Management*, 2022, 59(6): 103098.
- [20] LI JZ, WANG YZ, WANG J. An Analysis of Emotional Tendency Under the Network Public Opinion Deep Learning[J]. *Informatica*, 2021, 45(1): 149-156.
- [21] GAO LQ, LIU YJ, ZHUANG HW, et al. Public Opinion Early Warning Agent Model: A Deep Learning Cascade Virality Prediction Model Based on Multi-Feature Fusion[J]. *Frontiers in Neurorobotics*, 2021, 15: 674322.
- [22] LI C, QIU YL, ZHU XP. Asynchronous Network-based Model and Algorithm for Sentiment Analysis of Online Public Opinions[J]. *Kybernetes*, 2022: Ahead-of-print.
- [23] 钟佳娃, 刘巍, 王思丽, 等. 文本情感分析方法及应用综述 [J]. *数据分析与知识发现*, 2021, 5(6): 1-13.
- [24] 曾慧玲, 李琳, 吕思洋, 等. 提示学习驱动的新闻舆情风险识别方法研究 [J]. *计算机工程与应用*, 2024, 60(1): 182-188.
- [25] 王剑, 彭雨琦, 赵宇斐, 等. 基于深度学习的社交网络舆情信息抽取方法综述 [J]. *计算机科学*, 2022, 49(8): 279-293.
- [26] 宋千里, 赖华. 采用深度学习的小语种舆情监控方法 [J]. *红外与激光工程*, 2021, 50(S2): 156-162.
- [27] 谭旭, 吴璞, 蒋知义, 等. 基于深度学习的医患舆情多维演化仿真分析 [J]. *计算机工程与应用*, 2023, 59(19): 82-91.
- [28] MIAO RM. Emotion Analysis and Opinion Monitoring of Social Network Users Under Deep Convolutional Neural Network[J]. *Journal of Global Information Management*, 2023, 31(1): 1-12.
- [29] AKILA R, REVATHI S. Opinion Mining of Social Media Reviews Using Fuzzy Inference and Intent Prediction Using Deep Learning[J]. *Advances in Engineering Software*, 2022, 174: 103293.
- [30] LIU W, YUE XD, CHEN YF, et al. Trusted Multi-View Deep Learning with Opinion Aggregation[C]//36th AAAI Conference on Artificial Intelligence. Palo Alto, USA: Assoc Advancement Artificial Intelligence, 2022: 7585-7593.
- [31] ZHAO YX, MIAO R. Network Media Public Opinion and Social Governance Supported by the Internet-of-Things Big Data[J]. *Security and Communication Networks*, 2022: 2459815.
- [32] ALOTAIBI SS, ALABDULKREEM E, ALTHAHABI S, et al. Artificial Fish Swarm Optimization with Deep Learning Enabled Opinion Mining Approach[J]. *Computer Science, Hardware & Architecture*, 2023, 45(1): 737-751.
- [33] ORTONY A, CLORE G L, COLLINS A. The Cognitive Structure of Emotions: Factors Affecting the Intensity of Emotions[J]. *Contemporary Sociology*, 1988, 18(6): 2147-2153.
- [34] SAHAN M, SMIDL V, MARIK R. Active Learning for Text Classification and Fake News Detection[C]//2021 International Symposium on Computer Science and Intelligent Controls (ISCSIC 2021). New York, USA: IEEE, 2021: 87-94.
- [35] CHEN L, XU S, ZHU L J, et al. A Deep Learning Based Method Benefiting from Characteristics of Patents for Semantic Relation Classification[J]. *Journal of Informetrics*, 2022, 16(3): 101312.