

## 基于 TF-GRT 和 BERT 的微博评论情感预测及舆情分析

李潇萌<sup>1</sup> 赵庆峰<sup>2</sup> 张玉林<sup>1\*</sup>

LI Xiaomeng ZHAO Qingfeng ZHANG Yulin

## 摘要

针对微博舆情事件中网民观点演化规律难以精准挖掘、情感变化预测不够全面的问题,文章提出了一种融合多特征的舆情分析方法。以微博评论为研究数据,将评论的点赞量、回复量、转发量等交互特征,以及词频、词频增长率等文本特征融入传统 TF-IDF 算法,优化文本特征提取效果;采用 LDA 主题模型提取舆情事件各阶段评论池的核心主题,通过计算主题间相似度,明确网民观点随时间的动态演化形式。在此基础上,利用 BERT 等深度学习模型对舆论情感变化进行预测,结合召回率、准确率等评价指标,验证了所提模型在舆情分析中的有效性。最后,依据各阶段核心主题词的特征,将舆情事件的发展过程划分为酝酿期、发展期、爆发期、衰退期和稳定期五个阶段,为舆情事件的精准管控与科学引导提供理论支撑与技术参考。

## 关键词

微博评论;主题演化;TF-IDF;BERT;舆论情感

doi: 10.3969/j.issn.1672-9528.2026.03.030

## 0 引言

网络舆情是指在数字化信息环境中,各类社会主体通过互联网平台所发布和传播的具有情感色彩、价值判断或意向特征的信息内容,是群体性的态度、思想、情绪和要求的综合表现<sup>[1]</sup>。网络舆情主题挖掘能够全面把握热点事件的演化规律,为政府部门制定正确的舆论引导和监控起到积极作用。

微博作为当前主流的社交媒体平台,在信息传播领域发挥着双重作用:一方面为用户搭建了高效的信息交流渠道,另一方面则成为公众日常获取资讯和表达观点的重要载体。该平台最显著的特征在于其文本内容的简洁性,通过有效的挖掘算法从海量微博数据中提取分散的主题信息并快速定位核心内容,不仅有助于把握舆情动态,更为机关部门开展舆情监测与舆论引导工作提供了技术支撑。在舆情研究领域,微博舆情分析已成为热点发现机制中不可或缺的组成部分,王亚民等<sup>[2]</sup>通过融合 BTM 建模结果与改进的 TF-IDF 权重算法,对微博文本进行特征提取和相似性度量,继而运用 K-means 聚类算法实现热点话题的精准识别。安璐等<sup>[3]</sup>通过划分微博舆情演化的生命周期,基于 Word2vec 提取各阶段的微博主题,采用基于词典的情感分析方法对各类主题下的评论情感进行细粒度分类,实现了微博主题识别与情感分析

的协同分析。魏德志等<sup>[4]</sup>提出了一种改进的微博话题聚类方法,该方法基于优化的 FIHC 算法和二次聚类算法,以频繁词为特征进行话题识别,并运用改进的 TOPSIS 模型实现话题的量化分析与优先级排序。刘国威等<sup>[5]</sup>基于生命周期理论将网络舆情事件分为酝酿期、爆发期和衰退期 3 个阶段,利用 LDA 主题模型对各阶段的事件内容进行主题提取,生成微博热点事件的主题特征网络,进而对主题演化的规律进行揭示和分析。丁晟春等<sup>[6]</sup>提出一种 TF-IDF 算法,融合微博评论影响力选取特征词,通过主题强度与相似度的量化计算,提出了 6 种主题演化形式,进而挖掘出舆情事件中网民观点随时间变化的演化形式与演化规律。崔金栋等<sup>[7]</sup>提出了一种大数据背景下主流融媒体热点发现机制,利用 Scrapy-Redis 框架、HBase 数据库和 MapReduce 实现了数据的精准采集、有序存储和高效处理,利用 LDA2vec 模型和 Single-Pass 算法实现了信息归集和热点的发现与更新。

在对基于微博的网络舆情进行分析过程中,需要对微博评论进行量化,通过提取其关键词,发现热点主题以方便进行舆情分析。关键词的选择提取应该考虑词频、词性、词句的长度和位置等特征,目前国内外众多研究者在关键词提取领域已进行了广泛而深入的研究探索。李鹏等<sup>[8]</sup>通过对社会化标签数据的统计分析,优化了网页关键词抽取质量,并采用集成策略融合各类 Tag 下的词权重计算结果。钱爱兵等<sup>[9]</sup>依据新闻网页的内容特征,深入阐述了中文网页关键词的构成规律,通过改进传统 TF-IDF 加权公式,提出了一种多因素融合的关键词评分加权公式。刘佳宾等<sup>[10]</sup>利用一种基于机器学习的关键词自动抽取技术采用 N-grams 方法和词性相结

1. 山东科技大学数学与系统科学学院 山东青岛 266590

2. 山东科技大学计算机科学与工程学院 山东青岛 266590

[基金项目] 2022 年度青岛市社会科学规划研究项目 (QDSKL2201137)

合的方法进行关键词的提取,考虑了词组频率、词组位置和单词个数等特征,提升了准确率。陶琳<sup>[11]</sup>使用 GPT 技术建立舆情系统,挖掘出可预见的威胁。Cheliger 等<sup>[12]</sup>利用人工智能定性数据分析实时、快速地分析基于文本的数据,从而实现了基于 TF-IDF 的关键词挖掘技术。

本文提出了一种新的关键词提取算法,将评论的点赞量、评论回复量、转发量、词频以及词频增长率融入了 TF-IDF 值的计算,能够更精确地捕捉到舆论关键词的动态变化。将其转换为词频权重,对每个评论池的词语出现频率进行加权。将加权后的评论池传入 LDA 主题模型算法,提取出每个评论池主题。进一步,基于评论文本以及与之相关联的情感标签(正面或负面),使用 BERT 等深度学习模型进行情感分类训练和预测,最终结合情感百分比来综合探查舆论的变化趋势。

## 1 基于情感的网络舆情分析

### 1.1 评论池阈值设定

本文按照评论池窗口爬取微博数据,设定一个零时刻标准进行数据采集,并且设定评论池阈值。从零时刻开始不断监听微博评论数量,当评论数量达到或超过评论池阈值时,就会触发数据采集操作,将评论池中的数据打包成一个数据池,包含主帖的主评论(一级评论)及对这些主评论的回复评论(二级评论),并按照时间顺序排列。

每次触发数据采集时,都会记录下用户的昵称、评论内容、点赞量、回复量,以及评论的时间等关键信息。按照评论量进行提取,当达到阈值时便提取一次,而不是按照时间范围进行提取,这种动态采集策略能够更灵活捕捉微博中的重要互动,且无须事先知道评论量会在哪些时间点达到高峰。不仅提高了采集效率,还使得更全面地理解微博事件的发展和用户互动情况。

### 1.2 TF-GRT 方法

TF-IDF<sup>[13]</sup>作为衡量词汇重要性的经典算法,广泛应用于特征词提取任务中。然而,传统 TF-IDF 方法存在两个局限性:一是忽略了文档对词特征权重的贡献度;二是难以有效处理微博等短文本数据。本研究设计了一种融合微博评论影响力的 TF-IDF 改进算法,通过这种方式确定特征词权重,使所选特征词能够更准确地反映当下时间窗内的评论观点。

记第  $t$  个时间窗中词  $j$  的权重为  $w_{jt}$ ,  $W(d)$  表示微博评论  $d$  的影响力。则有公式为:

$$w_{jt} = \sum_{d=1}^{D_t} W(d) \cdot \text{TFGR}_{dj} \quad (1)$$

$D_t$  表示第  $t$  个时间窗内的评论总数,假设微博评论  $d$  受到回复数  $\text{RC}_d$  和点赞数  $\text{LC}_d$  以及词频数  $\text{tf}_d$  三个关键权重因子直接影响。本文研究的重点是随着时间的推移,舆论热点的变化趋势,因此每条评论的影响程度上还必须融入时间上

的影响因素,能够体现出时间上的变化趋势。若第  $t+1$  个时间窗口下的词  $A$  相对于第  $t$  个时间窗口下的词  $A$  的数量多  $a(t)$  个,  $t$  时刻  $A$  的词频数有  $n(t)$  个,增长率  $G(t)$  定义为:

$$G(t) = \log\left[1 + \frac{a(t)}{n(t)}\right] \quad (2)$$

因此其微博评论  $d$  的影响力计算公式为:

$$W(d) = [\alpha \log(\text{RC}_d + N) + \beta \log(\text{LC}_d + N) + \gamma \text{tf}_d] \cdot G(t) \quad (3)$$

式中:  $\alpha$ 、 $\beta$ 、 $\gamma$  为权重因子;  $N$  为参数。

最终  $\text{TFGR}_{dj}$  等于词  $j$  在评论  $d$  中出现的频次  $\text{tf}_{dj}$  与词  $j$  在第  $t$  个时间窗内的逆文档频率  $\text{idf}_{jt}$  的乘积,计算公式为:

$$\text{TFGR}_{dj} = \text{tf}_{dj} \cdot \text{idf}_{jt} \quad (4)$$

$$\text{idf}_{jt} = \log\left(\frac{1 + D_t}{1 + \text{df}_{jt}}\right) \quad (5)$$

由此计算出第  $t$  个时间窗内词的特征权重值,通过降序排列后,选取 Top- $N$  个高权重词构成当前时间窗的特征词集合。

本文使用 LDA 主题模型<sup>[14]</sup>对提取出来的 Top- $N$  关键词进行主题提取。将 Top- $N$  关键词作为输入数据,使用 LDA 算法,将其分成若干个主题,每个主题都包含一组相关的关键词,通过计算提取出的主题之间的相似度来探查时间窗之间的主题演化。然后计算不同时间窗口下的主题之间的余弦相似度或其他相似性指标。舆情分析数据集应该包含评论文本以及与之相关联的情感标签(正面、负面),可以使用深度学习模型,进行情感分类训练和测试。

## 2 数据选取与预处理

选择一个包含  $m$  条微博评论数据的数据集,这些评论被分为两个不同的情感标签:积极和消极。具有以下特点:

(1) 微博评论的特点是短小杂乱以及信息密度相对较低。这些评论通常限制在一个很短的文本长度内,因此情感表达必须更加精练和直接。与传统文本数据不同,微博评论不仅反映了作者的情感和情绪,还受到社交平台的独特语境和动态性的影响。

(2) 积极和消极两类情感标签能够捕捉到微博用户在不同情境下的情感趋势,从而更好地覆盖微博评论区的主流情感。

对数据爬取之后对原数据进行清洗。首先对数据中的日期进行时间序列转换,有助于后续的时间分析。然后将评论内容和用户名分离,使其各自为一列,并提取回复条数。将  $m$  条评论平均分布在  $k$  个数据池窗口,确保数据池窗口的平均分布,完成数据清洗与分配步骤,以更好地理解微博用户的互动模式和趋势。

## 3 数值实验

### 3.1 分类方法

GBDT+LR 是一种机器学习模型的组合<sup>[15]</sup>,由梯度提

升决策树 (gradient boosting decision tree, GBDT) 和逻辑回归 (logistic regression, LR) 两个独立的算法组合而成。利用 Boosting Tree 模型本身具备特征筛选的能力以及高阶特征组合能力, 通过 GBDT 来进行特征筛选和组合, 进而生成新的离散特征向量用于 LR 模型的输入, 使得预测效果更好。LightGBM 是一种轻量级的梯度提升机<sup>[16]</sup>, 其核心机制是将损失函数的相反梯度作为当前决策树的残差近似值, 拟合形成新的决策树。该算法的主要优势体现在内存消耗的显著降低和训练速度的大幅提升。与传统决策树相比, LightGBM 在预测精度方面表现更优, 实现了训练效率与预测准确性的有效平衡。TextCNN 通过采用不同尺寸的卷积核来提取局部特征, 使得获得的特征向量呈现出多样性特点, 并具有更强的代表性, 在文本二分类任务上也取得了很好的结果<sup>[17-19]</sup>。与 Word2vec 不同, BERT 嵌入方法融合了单词嵌入、分段嵌入和位置嵌入<sup>[20]</sup>。基于 BERT 的情感分类神经网络结构如图 1 所示, 由 BERT 模型进行嵌入, 经过全连接层后在输出层, 使用 Softmax 函数来进行情感二分类。这样可以在一定程度上减少 LSTM 的周期性问题, 提高特征提取的有效性和分类精度。




图 1 基于 BERT 的情感分类

### 3.2 实验结果

以“×× 抨击 ×× 新闻”为实验数据集, 爬取了 2023 年 8 月 7 日 19:00 到 2023 年 8 月 11 日 12:04 时间段的微博评论数据, 并对所得数据进行数据处理。首先进行中文分词及去除停用词, 再将文本数据转换为 TF-IDF 稀疏矩阵, 其中每个文档 (评论) 都表示了一个高维度向量。然后利用 TF-GRT 方法对每条评论提取最具代表性的 TOP10 关键词。通过制作数据词典, 将每一条评论中的分词逐一替换为其对应的唯一序号, 这样每条评论都变成了一个数字序列, 用于神

经网络输入。最后计算所有评论长度的众数, 被用作截断的最大长度, 以确保输入的文本数据长度一致。完成上述步骤后, 对所有评论进行 padding 处理, 以使其具有相同的长度。将数据输入到 BERT 神经网络的嵌入层, 将词语转化为高维的固定词向量。随机抽取其 80% 作为训练集, 20% 作为测试集, 在 BERT 神经网络上进行情感分析和文本分类任务。模型的评价指标为:

**Recall (召回率):** 正类别样本中被正确分类为正类别的比例;

**Precision (准确率):** 在模型识别为正类的样本中, 真实类别确为正类的样本比例;

**$F_1$ -score:** 综合考虑召回率和精确率的评估指标, 是其调和平均值;

**AUC:** 是 ROC 曲线下的面积, 用于度量分类器在不同阈值下的性能, AUC 分数越高, 表示模型越能有效地区分正类别和负类别样本。

通过对 BERT 进行调参和网络结构优化, 表 1 中 BERT 的预测准确率为 0.904 8, 召回率得分为 0.844 2, 表示该模型成功识别了 84.42% 的正类别样本, BERT 的  $F_1$  值最高为 0.854 1, 表示该模型在平衡召回率和精确率方面表现良好。

表 1 各模型评价指标比较

| 模型       | Accuracy       | Recall         | Precision      | $F_1$          | AUC            |
|----------|----------------|----------------|----------------|----------------|----------------|
| BERT     | 0.904 8        | 0.844 2        | 0.846 7        | <b>0.854 1</b> | <b>0.920 0</b> |
| GBDT+LR  | 0.847 9        | 0.723 4        | <b>0.908 2</b> | 0.805 3        | 0.825 2        |
| LightGBM | <b>0.918 6</b> | 0.767 5        | 0.906 2        | 0.831 1        | 0.840 0        |
| TextCNN  | 0.857 7        | <b>0.853 9</b> | 0.854 4        | 0.845 9        | 0.854 6        |

这表明该模型在分类任务中具有相对较好的性能, 能够有效区分不同类别的样本。进一步画出 ROC 曲线, 如图 2 所示, 发现 BERT 和 GBDT+LR 模型对应的 ROC 曲线所围成的面积最大, 其 AUC 达到 92%, 二者在假阳性率大于 0.4 后近乎重合。




图 2 ROC 曲线

综合考虑各个指标,本文选择 BERT 作为文本二分类任务的模型,用于对十个评论池窗口进行情感占比评分。进一步,融入评论的点赞数、回复数、转发数、词频以及词频增长率的 TF-IDF 算法与 TF-IDF,融合评论影响力的 TF-IIDF 方法进行实验比较,实验结果如表 2 所示,本文提出的 TF-GRT 的方法在 Accuracy、Recall 和 Precision 三个指标上均为最优,说明了方法的有效性。

表 2 各模型评价指标比较

| 模型指标         | Accuracy       | Recall         | Precision      |
|--------------|----------------|----------------|----------------|
| TF-IDF+BERT  | 0.871 5        | 0.781 3        | 0.838 2        |
| TF-IIDF+BERT | 0.904 8        | 0.767 5        | 0.838 2        |
| TF-GRT+BERT  | <b>0.904 8</b> | <b>0.844 2</b> | <b>0.846 7</b> |

进一步对微博的情感趋势进行预测,以“××抨击××新闻”为例,在最初阶段,这个话题的积极情感得分较低,大多数人对铁头的行为持有负面情感。然而,随着时间的推移,大家的情感态度逐渐变得中立,褒贬不一,积极情感和消极情感各占一半。情感变化趋势如图 3 所示。




图 3 情感趋势变化图

此外,根据该新闻的不同发展时期,得出不同的主题词,如表 3 所示。

表 3 各发展时期主题概括

| 发展阶段 | 主题概括                              |
|------|-----------------------------------|
| 酝酿期  | 质疑动机、批评、讽刺、正义与私利                  |
| 发展期  | 支持铁头、“双减”政策、社会进步、教育公平、寒门学子        |
| 爆发期  | 教育需求、补课必要性、家长困境、私人补课费用            |
| 衰退期  | 社会问题关注、“996”工作制、公摊面积、教育负担、家庭责任    |
| 稳定期  | 个人背景、历史案底、教育改革、全国考卷统一、师资力量、私立公立差异 |

按照发展阶段分为五个时期:酝酿期、发展期、爆发期、衰退期和稳定期,相应的主题也在不断变化,批评讽刺→社会进步→教育需求→教育负担→教育改革,这种情感变化的观察提供了有关舆论演变的重要见解。显示了社交媒体上

的情感情绪可以随时间而变化,受到事件、讨论和其他因素的影响。这种深入的情感分析有助于理解公众对不同话题和事件的看法如何演化,并可以用于更好地了解舆论动态,制定相关决策或采取行动。这对于媒体、品牌、政府和研究机构来说都具有重要意义,可以更好地应对社交媒体上的舆论波动。

#### 4 结论

基于微博评论,将评论的点赞数、回复数、转发数、词频以及词频增长率融入 TF-IDF 算法,提出了 TF-GRT 算法,能够更精确地捕捉到舆论关键词的动态变化。将其转换为词频权重,并利用 LDA 主题模型提取每个评论池主题。最后使用 BERT 神经网络、GBDT+LR 集成模型、LightGBM 及 TextCNN 进行情感分类任务的实验。实验发现不同的机器学习模型在情感分类任务中表现出不同的性能,其中 BERT 在准确率和 AUC 方面具有显著优势,且在 Recall 和 Precision 指标上也具有较好的效果,能够更好地理解和处理社交媒体上的舆论数据。将改进的数据处理方法与深度学习相结合并应用于微博舆情分析,可以有效克服网络评论词义不明、时效性强、元素权重不均等多种问题,使舆情分析与监控更加精确、及时,降低了舆情危机爆发的可能性。

#### 参考文献:

- [1] 彭丽霞,谢欣.要素视角下的微博舆论引导方法研究[J].中国编辑,2019(6):49-53.
- [2] 王亚民,胡悦.基于 BTM 的微博舆情热点发现[J].情报杂志,2016,35(11):119-124.
- [3] 安璐,吴林.融合主题与情感特征的突发事件微博舆情演化分析[J].图书情报工作,2017,61(15):120-129.
- [4] 魏德志,陈福集,林丽娜.基于 MFIHC 聚类 and TOPSIS 的微博热点发现方法[J].计算机应用研究,2018,35(4):1014-1017.
- [5] 刘国威,成全.基于网络舆情生命周期的微博热点事件主题演化研究[J].情报探索,2018(4):9-12.
- [6] 丁晟春,刘笑迎,李真.融合评论影响力的网络舆情热点主题演化研究[J].现代情报,2021,41(8):87-97.
- [7] 崔金栋,李晨雨,李菲菲.大数据背景下主流融媒体热点发现机制研究[J].情报科学,2021,39(12):72-79.
- [8] 李鹏,王斌,石志伟,等.Tag-TextRank:一种基于 Tag 的网页关键词抽取方法[J].计算机研究与发展,2012,49(11):2344-2351.
- [9] 钱爱兵,江岚.基于改进 TF-IDF 的中文网页关键词抽取—以新闻网页为例[J].情报理论与实践,2008,31(6):945-950.
- [10] 刘佳宾,陈超,邵正荣,等.基于机器学习的科技文摘关键词自动提取方法[J].计算机工程与应用,2007(14):170-172.

- [11] 陶琳. ChatGPT/生成式人工智能对高校网络舆情的影响及应对策略[J]. 情报科学, 2023, 29(8): 15-21.
- [12] CHELIGEER K, YANG L, NANDI T, et al. Natural language processing (NLP) aided qualitative method in health research[J]. Journal of integrated design and process science, 2022, 27(4-5): 1-18.
- [13] 胡亮, 夏磊, 李伟. 基于改进 TF-IDF 算法的关键词抽取系统[J]. 厦门理工学院学报, 2017, 25(5): 67-72.
- [14] 曹娟, 张勇东, 李锦涛, 等. 一种基于密度的自适应最优 LDA 模型选择方法[J]. 计算机学报, 2008(10): 1780-1787.
- [15] 张丽娟. 基于 GBDT+LR 模型在个人信用风险评估中的研究[J]. 网络安全技术与应用, 2021(7): 40-42.
- [16] 刘佳梅, 丁楷. 基于 Stacking 集成学习的中文问句分类算法[J]. 智能计算机与应用, 2023, 13(9): 85-88.
- [17] 俞立群. 基于 TextCNN 的试飞运营问题分类[J]. 民用飞机设计与研究, 2023(4): 1-5.
- [18] 刘春磊, 武佳琪, 檀亚宁. 基于 TextCNN 的用户评论情感极性判别[J]. 电子世界, 2019(3): 48-50.
- [19] LIU J X, ZHANG Y L. An attribute-weighted bayes classifier

based on asymmetric correlation coefficient[J]. International journal of pattern recognition and artificial intelligence, 2020, 34(10): 2050025.

- [20] DEVLIN J, CHANG M W, LEE K, et al. BERT: pre-training of deep bidirectional transformers for language understanding[C]//Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Brussels: ACL, 2019: 4171-4186.

#### 【作者简介】

李潇萌 (2000—), 女, 山东济宁人, 硕士研究生, 研究方向: 大数据挖掘。

赵庆峰 (1974—), 男, 黑龙江齐齐哈尔人, 博士, 讲师, 研究方向: 情报管理。

张玉林 (1979—), 通信作者 (email: zhangyulin@sdust.edu.cn), 男, 山东济宁人, 博士, 副教授, 研究方向: 大数据挖掘。

(收稿日期: 2025-07-22 修回日期: 2026-02-24)

(上接第 119 页)

漏检率达到 35% 以上。相比之下, 本研究通过引入集成学习框架, 构建了多层次的漏洞特征分析模型, 最终将漏检率控制在 20% 以内, 整体检测准确率提升至 92.6%, 显著优于现有方法。这一改进源于集成模型对各类漏洞特征的自适应学习能力, 以及对复杂漏洞模式的有效捕捉。

### 3 结语

本研究以数字化教学软件安全漏洞检测为切入点, 探索了基于集成学习算法的安全漏洞检测方法, 该方法引入无监督主成分分析方法对安全漏洞数据进行降维与分类, 并结合静态漏洞特征和动态漏洞特征, 能够发现潜在的安全漏洞类型, 可实现实时、高精度的识别和响应。实验表明, 该方法在真实教学软件数据集上的检测准确率较高, 满足应用要求, 本文研究可为教育软件安全领域提供一种低误报、高可解释性的智能检测手段, 有助于构建一个安全可靠的数字教学环境, 对推动智能教学生态健康发展具有重要实践价值。

#### 参考文献:

- [1] 程广振. 基于多源数据融合的无线网络安全漏洞信息检测方法[J]. 桂林航天工业学院学报, 2025, 30(3): 433-440.
- [2] 曹子亨, 何立风, 贾鸥, 等. 基于双向数据流分析与图抽象嵌入的漏洞检测方法[J]. 计算机应用研究, 2025, 42(7): 2176-2183.

- [3] 辛瑞雯, 高云. 基于知识图谱技术的计算机网络链路漏洞检测研究[J]. 现代电子技术, 2025, 48(1): 97-101.
- [4] 沈东舟. 基于深度学习的港口信息系统网络安全漏洞检测与防御技术[J]. 中国信息界, 2024(9): 228-230.
- [5] 费圣翔, 陈子龙, 王冲, 等. 基于图神经网络的异构网络信息安全漏洞深度检测方法[J]. 华南地震, 2024, 44(3): 180-186.
- [6] 刘悦. 基于孤立森林算法的计算机网络信息安全漏洞检测方法[J]. 信息与电脑(理论版), 2024, 36(4): 68-70.
- [7] 张和伟, 王奉章. 基于被动分簇算法的即时通信网络安全漏洞检测方法[J]. 智能计算机与应用, 2023, 13(7): 119-122.
- [8] 杨一健, 李明, 方赛银. 基于信息熵的改进蚁群算法求解 TSP 问题[J]. 计算机工程与设计, 2024, 45(9): 2874-2881.
- [9] 李刚, 吴麒, 王翔, 等. 基于样本信息熵辅助的深度强化学习抗干扰策略[J]. 通信学报, 2024, 45(9): 115-128.
- [10] 黄鹤, 黄佳慧, 刘国权, 等. 采用混合策略联合优化的模糊 C-均值聚类信息熵点云简化算法[J]. 西安交通大学学报, 2024, 58(7): 214-226.

#### 【作者简介】

尚进 (1992—), 女, 甘肃陇南人, 本科, 讲师, 研究方向: 教育信息化。

(收稿日期: 2025-08-21 修回日期: 2026-03-17)