

GWO-LSTM 预测下的高校网络舆情 风险演化研究*

曹超¹ 凌春雨² 罗方禄³

(1. 中南大学党委学生工作部 长沙 410083;

2. 中南大学党委组织部 长沙 410083;

3. 中南大学马克思主义学院 410083)

摘要: [研究目的] 提高高校网络舆情事件风险预测的准确性对于维护国家和社会稳定具有重要意义。[研究方法] 本研究基于微博平台中高校网络舆情事件的热度和评论, 提出了一种基于舆情事件热度和情感分析结果的舆情风险模型, 使用灰狼算法与 LSTM 相结合作为预测模型, 分析高校网络舆情风险演化的情况, 并结合案例进行了分析验证。[研究结论] 本文构建了全链条高校网络舆情分析框架, 模型考虑因素更为全面, 预测精度和拟合度高, 能全面地反映实际舆情的风险态势及其变化, 防控演化分析表明利用模型预测舆情可及时将舆情事件控制, 防止持续发酵。研究表明, 该模型能很好地反映并预测舆情风险的程度与变化, 在验证事件中, 平均绝对误差为 13.8%, 同时利用模型的演化分析论证了高校网络舆情预测的重要性和必要性。

关键词: 高校网络舆情; 舆情风险; LSTM; 情感分析; 灰狼算法; 舆情演化

中图分类号: C912.63;D64 文献标识码: A

Research on College online public opinion risk based improved GWO and LSTM

Cao Chao¹, Ling Chunyu², Luo Fanglu³, Zhao Xiangkang⁴

¹(Student Work Department, Central South University Party Committee, Changsha 410083, China)

²(Organization Department of Party Committee, Central South University, Changsha 410083, China)

Abstract: [Research objective] Improving the accuracy of online public opinion event risk prediction in universities is of great significance for maintaining national security and social stability. [Research method] Based on the popularity and comments of online public opinion events in colleges and universities on Weibo platform, this study proposed a public opinion risk model based on the popularity of public opinion events and sentiment analysis results. The Grey Wolf algorithm combined with LSTM was used as a prediction model to analyze the evolution of online public opinion risks in colleges and universities, and analyzed and verified with cases. [Research Conclusion] This paper builds a whole-chain online public opinion analysis framework in universities. The model has more comprehensive considerations, high prediction accuracy and fitting degree, and can fully reflect the risk situation and changes of actual public opinion. The analysis of prevention and control evolution shows that using the model to predict public opinion can control public opinion events in time and prevent continuous fermentation. The research shows that the model can well reflect and predict the degree and change of public opinion risk, and the average absolute error is 13.8% in the verification event. At the same time, the importance and necessity of online public opinion prediction in universities are demonstrated by the evolutionary analysis of the model.

Key words: University public opinion online; Public opinion risk; LSTM; Emotion analysis; Grey Wolf algorithm; Evolution of public opinion

1 引言

随着网络信息与智能技术的迅速发展和普及，互联网体现的不仅仅是技术属性，更被赋予传播属性、社交属性和意识形态属性，人们的各种想法和意见通过发达的网络平台表达出来，且传播的时间和空间距离不断缩小，极易形成危害社会安全稳定的“舆论场”。高校作为意识形态斗争的前沿阵地，历来备受社会关注，且高校师生作为思想活跃，与互联网有着极强的粘连性，高校的突发事件更容易形成网络舆论热点。

高校网络舆情作为网络舆情中的一种，有其特殊性。首先是受众广泛，不仅仅关系到学校师生，还涉及到校友、家长、社会公众等多个群体，舆情的传播范围广泛，影响力较大，很可能会演化为社会危机事件问题；敏感性高，高校作为教育机构，其舆情往往与教育教学、学术研究、学生管理等方面密切相关，一旦出现负面舆情，可能对学校声誉、招生、教职员工的稳定等方面造成严重影响。高校舆情往往在短时间内迅速扩散，给学校的声誉和形象带来巨大挑战。影响学校声誉，干扰学校正常秩序，影响学校发展。然而，部分高校在了解捕捉舆情信息、精准预测网络舆情发展态势、快速制定网络舆情应对方案方面往往存在准备不足，处置被动，错失舆情处置的“黄金6小时”。这就要求高校能够及时发现高校网络舆情问题，了解学校内外的舆情动态，发现潜在问题和风险，及时掌握舆情发展趋势，提前预判可能出现的危机，从而制定相应的危机应对策略，降低危机对学校的影响。因此，研究高校网络舆情预测已成为当前学术界和政府、高校关注的重点内容。

针对以上所述，加强高校网络舆情治理既是维护校园安全稳定的需要，更是为培养德智体美劳全面发展的时代新人提供更加清朗的成长空间的需要。本文将从网络环境下高校网络舆情的特点和实际出发，进一步厘清高校网络舆情的发生机制，并提出有效的管控策略。

2 研究现状

由于网络舆情具有复杂性、迅速性、突发性和互动性的特点，如果不能对其传播演化进行及时正确的引导，负面的网络舆情会对社会公共安全造成重大影响^[1]。因此，建立网络舆情预测模型，掌握网络舆情风险程度和发展趋势，提前预测并及时有效处理网络舆情危机，对维护社会秩序，提高民众满意度与社会安全感以及提升政府治理体系和治理能力有着重要的作用^[2]。

网络舆情预测方法分为传统数学模型预测和基于机器学习和深度学习的非线性时间序列预测方法^[3]。早期，学者们主要使用灰色预测^[4]、指数平滑法^[5]等传统预测模型以及马尔科夫链^[6]等统计学方法，这些方法简单易用，但往往预测精度不高。

随着机器学习和深度学习的发展，预测精度得到了显著提高。赵磊和王松^[7]利用时间序列数据结合BP神经网络理论，有效地预测了网络事件的舆情热度趋势。黄亚驹、陈福集等^[8]采用遗传算法与粒子群算法混合优化BP神经网络，从而提高了模型的预测效果。兰月新^[9]等建立了舆情热度模型，使用多维度Logistic模型对舆情热度进行预测。

为了进一步提高网络舆情预测精度并确保社会舆论安全，许多学者采用了组合预测和深度学习方法来提高模型精度。徐敏捷等^[11]将Logistic模型、指数平滑法和灰色预测结合起来预测网络舆情；李彤、宋之杰^[10]运用模型集成理论，对ARIMA、神经网络和支持向量机回归进行集成，构建出平均集成模型来预测微博的情感趋势；钟义勇^[11]利用Logistic模型、ARIMA模型和LSTM模型组合预测微博舆情的演化趋势。孙靖超、周睿等^[12]考虑到传统模型及不同神经网络对非线性数据的预测效果较差，提出了一种基于循环神经网络处理时间序列的舆情预测模型，从而进一步提高了模型的预测精度。综上所述，诸多学者从不同角度展开了对网络舆情发展态势的研究，逐步拓展了网络舆情趋势预测的方法。但网络舆情的相关数据具有一定的时序相关性，采用统计学或者传统的机器学习方法很难挖掘出时序

数据在时间维度上的关联性，同时也难以有准确的预测精度，所以对于利用深度学习的方法进行网络舆情建模与预测，仍待进一步的研究。

本文考虑 LSTM 这一深度学习网络作为舆情预测的模型基础，建立一种网络舆情风险模型，更加关注于舆情的风险信息，同时融入情感分析作为考虑指标，更能体现网络舆情的复杂性、危害程度。在此基础上，加入灰狼算法优化 LSTM 模型参数，提高了模型的训练速度与预测精度，准确地预测出突发事件网络舆情热度与风险的发展趋势，为及时采取舆情防范措施提供依据。

3 研究方法

3.1 情感分析模型原理

SnowNLP 为 Python 中专门处理中文自然语言处理的库。其自带中文正负情感训练集，能很好地

$$= \frac{P(B_1, \dots, B_n | A_1) \cdot P(A_1)}{P(B_1, \dots, B_n | A_1) \cdot P(A_1) + P(B_1, \dots, B_n | A_2) \cdot P(A_2)}$$

该式即为 SnowNLP 情感分析的基本计算式。该式表明，一段含有 $B_1, B_2 \dots B_n$ 词语的评论其为积极情感的概率可通过标定数据集计算出。

3.2 LSTM

LSTM^[12]的工作方式与 RNN 基本相同，都具有记忆功能，这一优势使之可以考虑输入数据的前后依赖关系，输出该时刻网络输入和网络历史信息结合产生的结果，因此更加适用于模拟时间序列的趋势^[14]。

LSTM 在结构上与 RNN 并无不同，均有输入层、隐含层、输出层组成。不同点在于，它解决了传统 RNN 训练过程中的梯度消失和梯度爆炸^[15]的问题。

适用于中文文本数据处理，原理基于朴素贝叶斯原理^[13]实现，如下：

假设情感分析有积极 A_1 和消极 A_2 两种。所获取的一段评论中含有 $B_1, B_2 \dots B_n$ 等相互独立的词语组成。有贝叶斯公式如下：

$$P(A_1 | B_1, \dots, B_n) = \frac{P(B_1, \dots, B_n | A_1) \cdot P(A_1)}{P(B_1, \dots, B_n)} \quad (1)$$

由全概率公式得：

$$P(B_1, \dots, B_n) = P(B_1, \dots, B_n | A_1) \cdot P(A_1) + P(B_1, \dots, B_n | A_2) \cdot P(A_2) \quad (2)$$

将其代入上式，可得到

$$P(A_1 | B_1, \dots, B_n)$$

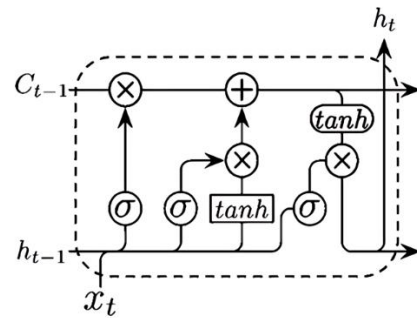


图 1 LSTM 隐含层结构图

Fig.1 LSTM Hidden Layer Structure

与 RNN 不同的是，LSTM 隐含层具有记忆单元和门结构，包括输入门、输出门和遗忘门。其组成模块见图 1。其中， x_t 为模型的输入向量， h_t 为模型的输出向量，可以看到上一层的输出向量作为该层的输入参与到网络的构建， c_t 为记忆单元。

其隐含层前向传播及门结构控制机制如下：

在 t 时刻，输入门根据隐藏节点 h_{t-1} 和输入数据

x_t , 对记忆单元临时值进行更新。 C_t 由遗忘门确定的上一时刻状态保留程度结合输入门的计算而得。最终的隐藏层状态由输出门得出, 有个两部分, 第一部分利用激活函数 σ 获得输出状态 o_t , 而第二部分由经过激活函数 \tanh 处理后 C_t 的组成。最终, 输出状态 o_t 取决于前一时刻的隐藏层状态 h_{t-1} 和当前时刻输入数据 x_t 。

使用 LSTM 模型能够很好地捕捉和处理时间序列中的长期依赖关系, 针对网络舆情时间序列发展的复杂性, 能自动有效地学习到其重要特征, 处理数据内部关联关系。

3.3 灰狼优化算法

(1) 灰狼算法^[16]是一种受灰狼捕食猎物活动启发而开发的优化搜索方法。自然界中, 灰狼通过协作和竞争的方式来寻找食物资源, 从而生存下去。灰狼算法利用了这种行为特点, 通过模拟灰狼的优胜者和劣胜者在搜索空间中的位置变换, 逐步提高整个群体的适应度值, 从而找到问题的最优解。

其基本原理是: 根据灰狼群体成员中的优胜者和劣胜者进行位置变换和迭代更新。算法包括四个基本步骤:

- 1) 初始化灰狼群体: 确定灰狼的初试位置, 并计算其适应度值。
- 2) 搜索过程: 根据灰狼个体之间的距离和适应度值, 更新每个灰狼的位置和适应度值。在本文模型中适应度函数为 LSTM 模型训练集的均方误差。
- 3) 选择最优灰狼: 根据适应度值确定全局优胜者, 即最优解。
- 4) 更新位置: 根据最优灰狼的位置和其他灰狼的相对位置, 更新每个灰狼的位置。

(2) 改进灰狼算法

自灰狼智能优化算法被提出以来, 不同学者提出各种改进策略, 以来平衡全局搜索与局部搜索, 优化解的质量。本文采用文献^[17]中提出的已经成熟的基于佳点集方法初始化、非线性参数控制改进的灰狼优化算法(IGWO)。

通过该方法初始化灰狼个体位置能增加群体的

多样性, 在一定程度上能提高灰狼的全局搜索能力, 并加快算法的收敛速度。其次, GWO 算法中的参数 A 对平衡其全局搜索能力与局部开发能力起着关键作用。经典灰狼算法的 A 值是随着迭代次数由 2 到 0 线性变化。研究^[18]表明, 对参数 A 进行非线性变换有助于更好的寻优性能。本文运用三角余弦函数对算法中参数 A 进行非线性变化。

灰狼算法通具有群体协作、简易实现、快速收敛以及强大的全局搜索能力等优势, 在高维度优化问题中能够较快地收敛到最优解, 能够在多个局部最优解之间进行搜索。本文中利用灰狼算法优化 LSTM 超参数, 寻找模型最优解。

4 模型构建

本模型在针对网络突发事件造成的高校网络舆情, 分析探究舆情事件的风险性变化。基于情感分析、LSTM 长短期记忆递归神经网络建立网络舆情风险评价预测模型。其过程包括数据采集、风险指数模型建立、风险指数预测。

本模型不同于从舆情热度出发来预测热度峰值从而为相关部门提供决策最佳时刻与预警提醒, 更加关注舆情风险的大小, 评定舆情风险指数, 考虑舆情的正负面态势, 同时使用深度学习模型预测指数变化, 提供决策意见。

其过程可分为三部分, 数据收集、风险模型建立、模型预测。首先选择具体突发网络舆情事件作为研究对象, 多渠道获取相关数据; 其次, 分类处理不同指标数据, 进行数据清洗工作, 并计算风险指数; 最后, 基于 LSTM 训练模型, 并做评估与演化分析。具体流程如图 2 所示。

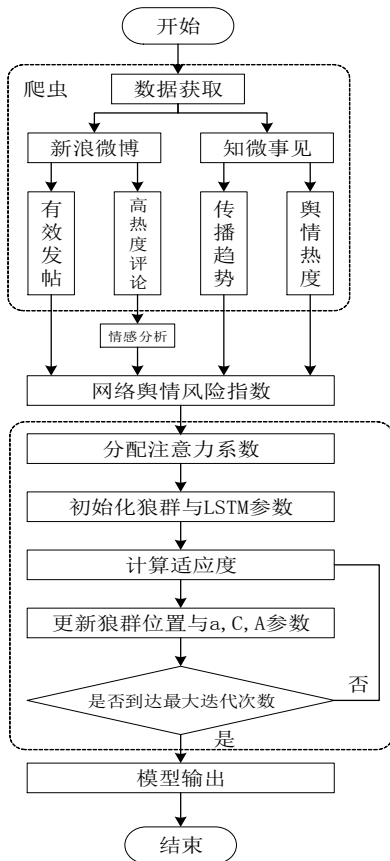


图 2 舆情风险指数预测模型流程图

Fig. 2 Public Opinion Risk Index Prediction Model

4.1 数据采集与预处理

以 2023 年 6 月发生的“四川大学地铁事件”为论证实例。该事件历时 16 天 9 时，期间历经事件爆发、反转、处理结果公布等多个细节。该事件立足高校人员，舆情事件对高校影响大。

本文选择事件反转期的 3 天半时间作为模型构建的数据集。爬取微博话题“自证未偷拍仍遭曝光涉事女子已道歉”下的博文评论作为第一数据集。经清洗后，得到有效评论数 6806 条，见表 1。收集“知微事见”下的时间传播趋势数据作为第二数据集。

表 1 爬取微博话题下博文评论

Table 1 Blog Comments Under Weibo Topics

序号	评论	时间
1	“对不起这次你放过我下次我还敢”	6-12 00:16

2	给他人造成全国性的负面影响，如果就这么简单的道歉就结束了事，那这个案例只会纵容鼓励更多的人继续这么干，成本太低了	6-12 00:45
...
6806	大叔可以原谅，是因为善良。社会不可以原谅，是因为正义。否则，就会有更多这样的大叔被无端欺负。我希望看到这个女的付出应有的代价。	6-14 23:43

以一个小时为时序单位，统计 6806 条评论的发布时刻，其舆情热度变化见图 3。

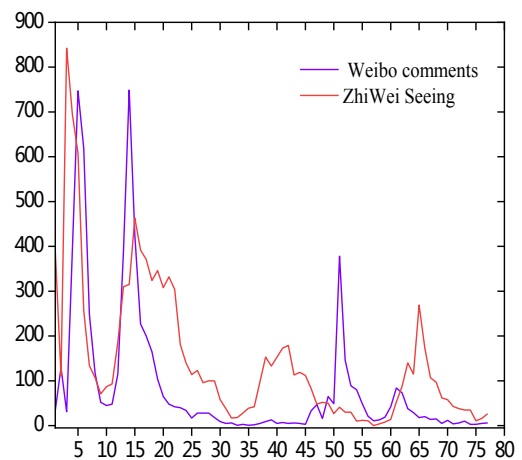


图 3 舆情热度图

Fig.3 Public Opinion Heat

截取的时间序列从 6 月 11 日 19 时开始，到 6 月 14 日 24 时截止。由舆情热度图变化可知，在本轮舆情 3 天半的时间中，共有 4 次重点舆情讨论高峰期，其中在事件发布第 4-5 个小时舆情热度达到最高峰。同时，可以看到，由微博和“知微事见”两个平台爬取统计的热度数据变化趋势大体一致，在本文中采取数据来源结合加权的方式来计算网络舆情风险指数，使模型更加具有普遍性、准确性。

归一化处理。考虑从不同平台获取数据的评价体系与单位，对时序数据进行线性归一化，消除量纲和数据取值范围的影响。同样在本文的情感分析统计中，亦采用本公式计算。公式如下

$$= \frac{x - \min(x)}{\max(x) - \min(x)} \quad (4)$$

4.2 情感分析

使用 SnowNLP 对 6806 条实效评论数据进行情感分析评分^[13]，分类统计出消极评论数见表 2。

表 2 微博评论总体情感分析

Table 2 Emotion Analysis of Weibo Comments

情感	负面	正面或中性
数量	5210	1596

统计评论对应时间，以一个小时为单位，计算单位时间内平均情感得分，获得舆情时序评论情感变化，作为舆情风险指数的重要指标。

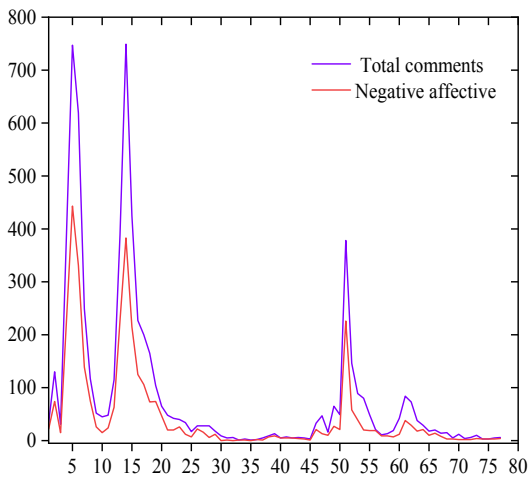


图 4 负面情绪变化图

Fig.4 Change of Negative Emotion

取单位时序内负面评论数与剩余评论数的差值作为该单位时序内的负面情感程度作对比图，见图 4。分析可知，在该舆情发展的时期，任意单位时序内负面评论数总是大于剩余评论数，这说明该网络舆情有着明显的负面特征。且负面情感程度的变化趋势总体与总评论相一致，当总评论数量较多时，负面情绪程度占比有所下降；当总评论数量较少时，负面情绪程度有所降低，这表明情绪变化与网络舆情热度有一定的正相关性。

4.3 舆情风险指数

舆情风险指数没有规范统一的定义，本文将从上述两个数据来源考虑，同时加入情感分析统计，

使用主成分分析法对三种统计指标做重要性解释^[19]，得到评价模型的权重，见表 3，使用以下公式与权重计算舆情风险指数。

$$Z = W \cdot A \quad (5)$$

这样做的优点在于，既多方面综合考虑了舆情热度的信息，又结合情感分析结果获取了舆情的正面负面信息。

表 3 信息权重表

Table 3 Information Weight

数据来源	知微事见趋势	微博评论热度	微博评论负面情感
权重 ω_i	0.383	0.263	0.354

值得注意的是，时序单位为一个小时，热度随时间变化有较为明显的周期性，当处于深夜时段，舆情热度有明显的降低。为探究舆情变化内部更为深层次的规律，本文在预测部分使用智能算法优化的 LSTM 这一深度学习模型，将时序单位选择带来的周期性变化一同考虑在内。




图 5 网络舆情风险指数变化图

Fig.5 Change of Network Public Opinion Risk Index

图 7 中，本次舆情在舆情爆发后的 5 个小时后到达最大风险值。

4.4 模型预测

本文使用 Python 环境下的 TensorFlow 框架搭建 LSTM 神经网络^[20]，同时加入注意力机制优化获得最佳模型结果^[21]。根据本文以上构建的网络舆情风险指数模型，将时间序列下的 77 个风险指数放入模型中进行训练，划分为 75%训练集和 25%的测试集。

最后对整体舆情发展进行预测，预测结果值与实际真实值对照图如图 8 所示，测试集的预测误差见表 4。

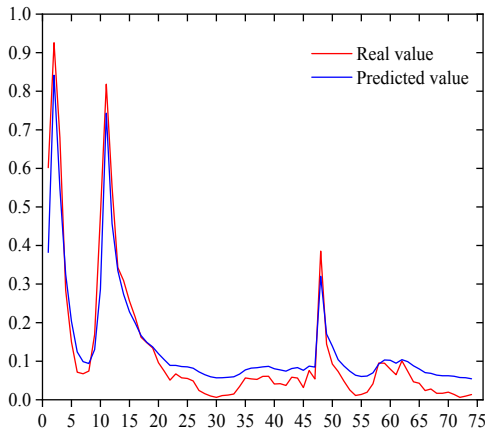


图 6 模型预测对照图

Fig.8 Comparison of Model Prediction

表 4 误差对比表

Table 4 Error Comparison

序号	实际值	优化后	相对误差
1	0.04662	0.04487	3.75%
2	0.04282	0.04051	5.39%
3	0.02379	0.02489	4.62%
4	0.02791	0.02861	2.51%
5	0.01675	0.01884	12.48%
6	0.0168	0.01752	4.29%
7	0.0197	0.02032	3.15%
8	0.01374	0.0145	5.53%
9	0.00624	0.00568	8.97%

为对所建预测模型预测效果进行评价，选取具有代表性的统计指标^[20]MAE（平均绝对误差，Mean Absolute Error）、RMSE（均方根误差，Root Mean Square Error）以及它们的平均相对误差作为评价指标。平均绝对误差和均方根误差的计算公式为：

MAE

$$= \frac{1}{n} \sum_{i=1}^n |y_i - \widehat{y}_i| \quad (6)$$

$RMSE$

$$= \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \widehat{y}_i)^2} \quad (7)$$

评价指标数值越小，表明预测误差越小，预测效果越好。对比方法，误差见表 5。

表 5 误差表

Table 5 Error

模型	MAE	RMSE
PSO-BP	0.0107	0.0111
SVR	0.0088	0.0103
CNN	0.0080	0.0085
LSTM	0.0079	0.0086
GWO-LSTM	0.0041	0.0044

由上表可知，使用 GWO-LSTM 模型能更好的训练出优良的模型。在众多预测模型中，训练后最优模型测试集结果 MAE 与 RMSE 均最低。同时，相比没考虑调参的 LSTM 网络，优化算法得到的参数使其 MAE 相比下降 48%，RMSE 相比下降 49%。

4.5 模型验证与演化分析

本文选取该事件下的另一话题“川大地铁事件涉事学生被留校留党察看”来验证本模型的准确性。按照以上模型建立该话题下的网络舆情风险指数模型。将本节中训练的保存下来，用于预测新话题的舆情风险指数。其结果见图 7。

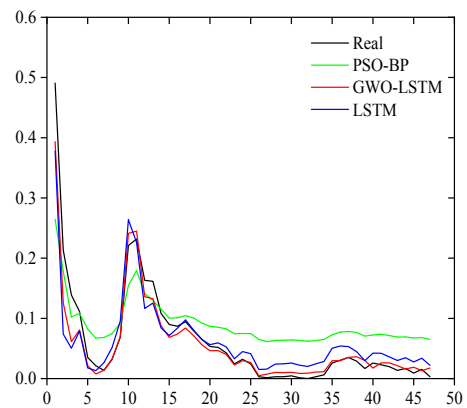


图 7 新话题下模型预测效果图

Fig.7 Model Prediction Effect

通过图表数据的对比，黑色表示实际值，红色表示优化后的 LSTM 模型，两者最为接近，平均绝对误差为 13.8%。可以看出，在测试时间序列中，

BP神经网络和LSTM神经网络都能相对准确地预测出舆情的变化趋势，但明显PSO-BP网络模型与实际值有较大的差距，而使用GWO优化过LSTM超参数的预测模型，有着几乎与实际值相同的预测精度，其预测效果明显较优。这说明LSTM神经网络对时间序列预测有着很好的适应性，同时经过GWO超参数后的LSTM模型，相比选定常规参数的LSTM模型其训练模型更为优秀，预测精度更高。与传统方法相比，本文选择的方法模型训练预测精度高，预测稳定性好，浮动更小，能更好地拟合实际网络舆情中的变化。

为使用该模型来对高校舆情事件进行演化分析，考虑对事件特定时刻热度做人为干预。在序列时刻的第二波峰值做干预，降低风险的70%、50%、20%。结果如下图所示。




图8 验证集下的演化分析图

Fig.8 Prediction of The Test Set

从图8 验证集下的演化分析图可以看出，当在人为干预舆情热度降低其风险值的情况下，后续舆情发展会更快趋于平稳。并且，结果表明在风险指数降低30%与降低70%，后续事态的平稳发展相差不多。而仅使风险指数降低30%的情况下，事态后续发展将会相比未干预产生较大的影响。这表明，及时干预、控制舆情发展对于舆情整体发展有着一定的“蝴蝶效应”，而如果按照舆情正常自然发酵或控制不及时，会造成很大的社会效益等损失。

5 结论

本文从研究高校网络舆情的风险随时间变化这一基本点出发，重点考虑风险这一概念，并将情感分析作为其中的一种重要考虑因素，使用LSTM作为预测舆情风险指数的变化趋势的方法，分析人为干预情况下舆情风险的演化发展。通过最近发生的舆情实例进行模型验证与演化分析，最终得到预测结果与实际结果相符合，且准确性较高，同时演化结果表明干预对舆情控制的重要性。本研究丰富了舆情预测方面的研究内容，并为舆情控制演化研究提供参考，有一定的理论价值。采用本模型可及时识别和响应舆论的变化能够有效预防危机的发生，或者在危机初起时快速采取行动，限制危机的扩散。由于影响高校网络舆情演化传播的因素较多，本文方法可能未能完全实际情况相符，在预测精度优化与控制演化分析，有待更深入的研究。

参考文献

- [1] 徐敏捷,兰月新,刘冰月.基于组合预测的网络舆情数据预测模型研究[J].情报科学,2016,34(12):40-45+87.
- [2] 曾关秀,胡峰.机器学习视域下网络舆情公开渠道精准化治理研究[J].领导科学,2021(20):50-52.
- [3] 任秉嘉.基于机器学习的网络舆情预测研究综述[J].信息技术,2023,47(01):98-103.
- [4] 王宁,赵胜洋,单晓红.基于灰色系统理论的网络舆情预测与分级方法研究[J].情报理论与实践,2019,42(02):120-126.
- [5] 徐敏捷.基于指数平滑法的微博舆情预测模型研究[J].中国公共安全(学术版),2016,No.42(01):80-84.
- [6] 王新猛.基于马尔可夫链的政府负面网络舆情热度趋势分析——以新浪微博为例[J].情报杂志,2015,34(07):161-164.
- [7] 赵磊,王松.基于BP神经网络的舆情热度趋势仿真模型研究[J].情报学报,2016,35(09):989-999.
- [8] 黄亚驹,陈福集,游丹丹.基于混合算法和BP神经网络的网络舆情预测研究[J].情报科学,2018,

- 36(02):24-29.
- [9] 兰月新,刘冰月,张鹏等.面向大数据的网络舆情热度动态预测模型研究[J].情报杂志,2017,36(06):105-110+147.
- [10] 李彤,宋之杰.基于模型集成的突发事件舆情分析与趋势预测研究[J].系统工程理论与实践,2015,35(10):2582-2587.
- [11] 钟义勇,何巍,张鹏等.基于LAL的微博舆情演化趋势预测与实证研究[J].情报探索,2023(06):23-30.
- [12] 孙靖超,周睿,李培岳等.基于循环神经网络的网络舆情趋势预测研究[J].情报科学,2018,36(08):118-122+127.
- [13] 白健,洪小娟.基于弹幕的网络舆情文本挖掘与情感分析[J].软件工程,2022,25(11):44-48.
- [14] Graves A, Mohamed A, Hinton G. Speech recognition with deep recurrent neural networks [C] 2013 IEEE International Conference on Acoustics, Speech and Signal Processing. IEEE, 2013:6645-6649.
- [15] Bengio Y, Simard P, Frasconi P. Learning long-term dependencies with gradient descent is difficult.[J].IEEE Transactions on Neural Networks, 2002,5(2):157-166.
- [16] 张晓凤,王秀英.灰狼优化算法研究综述[J].计算机科学,2019,46(03):30-38.
- [17] 林玲,陈福集,谢加良等.基于改进灰狼优化支持向量回归的网络舆情预测[J].系统工程理论与实践,2022,42(02):487-498.
- [18] Mittal N, Singh U, Sohi B S, et al. Modified grey wolf optimizer for global engineering optimization[J]. Applied Computational Intelligence and Soft Computing, 2016: 1-19.
- [19] 杨柳,徐宇昭,邓春林.高校网络舆情风险评估及预警研究[J].情报科学,2022,40(05):65-72+83.
- [20] 许露萌.基于ARIMA和改进LSTM的突发事件舆情热度预测[J].网络安全与数据治理,2023,42(03):53-57.
- [21] 马永军,郎威.基于融合注意力机制LSTM的网

络舆情趋势预测[J].计算机仿真,2023,40(01):493-498.

通讯作者 (Corresponding author) :

凌春雨 (Ling Chunyu), ORCID: 0009-0008-8214-4388, Email: 44381269@qq.com。

基金项目:

*本文系“教育部人文社会科学研究项目”基金项目 (项目编号: 21YJC710049) 的研究成果之一。

The work is supported by "Humanities and Social Science Research Project of the Ministry of Education" (Grant No. 21YJC710049).

2024年度湖南省社会科学成果评审委员会一般课题:

“多源数据融合下网络意识形态安全风险识别及治理仿真”项目编号: XSP24YBC479

作者贡献说明:

曹超, 论文选题、框架设计、论文撰写;

凌春雨, 论文指导, 框架设计;

罗方禄, 论文选题指导, 论文修改;

赵祥康, 数据获取, 数据分析。

利益冲突说明:

所有作者声明不存在利益冲突关系。

支撑数据:

支撑数据由作者自存储, E-mail: 469190629@qq.com

[1]赵祥康.Cddt-1-2023data.xlsx. 自证未偷拍仍遭曝光涉事女子已道歉微博数据.

[2]赵祥康.Cddt-2-2023data.xlsx. 川大地铁事件涉事学生被留校留党察看微博数据.

[3]赵祥康.Zwsj-data.xlsx. 知微事见热度数据.

曹超, 1993年, 硕士, 助理研究员, 研究方向: 高校网络舆情、网络意识形态; 罗方禄, 1987年, 博士, 副教授, 湖南省教育舆情与风险防控研究基地研究员, 研究方向: 国家安全、网络意识形态; 通讯作者: 凌春雨 (E-mail: 469190629@qq.com), 1977年, 硕士, 讲师, 研究方向: 高校党建。