

马雪利,姚华彦,朱勇超,等.组合机器学习模型基坑沉降变形预测方法研究[J].辽宁工程技术大学学报(自然科学版),2025,44(2): 186-193.DOI:10.11956/j.issn.1008-0562.20240110

MA Xueli, YAO Huayan, ZHU Yongchao, et al. Research on foundation pit settlement deformation prediction method based on combined machine learning model[J]. Journal of Liaoning Technical University (Natural Science), 2025, 44(2): 186-193. DOI: 10.11956/j.issn.1008-0562.20240110

组合机器学习模型基坑沉降变形预测方法研究

马雪利, 姚华彦*, 朱勇超, 汪明武, 成潇博, 朱艺媛

(合肥工业大学 土木与水利工程学院, 安徽 合肥 230009)

摘要:为实现基坑地表沉降高精度预测,采用卷积神经网络、BP神经网络和长短期记忆神经网络算法构建基坑沉降变形基础预测模型,基于熵值法和CRITIC权重法建立组合预测模型,并以基坑变形监测数据为基础,对单一预测模型和组合预测模型的预测精度进行评估。研究表明:与单一预测模型相比,熵值法组合预测模型的平均绝对误差最大降低91.80%,均方误差最大降低99.40%,平均绝对百分比误差最大降低91.50%;CRITIC法组合预测模型的平均绝对误差最大降低86.04%,均方误差最大降低98.19%,平均绝对百分比误差最大降低85.52%,组合预测模型比单一预测模型的性能更优。研究结果可为提高基坑地表沉降预测精度及保障基坑施工安全提供参考。

关键词: 基坑; 组合预测; 机器学习; 熵值法; CRITIC法

中图分类号: TU433

文献标志码: A

文章编号: 1008-0562(2025)02-0186-08

Research on foundation pit settlement deformation prediction method based on combined machine learning model

MA Xueli, YAO Huayan*, ZHU Yongchao, WANG Mingwu, CHENG Xiaobo, ZHU Yiyuan
(School of Civil Engineering, Hefei University of Technology, Hefei 230009, China)

Abstract: Foundation pit excavation will cause the surrounding soil to settle, and may even cause disasters such as cracks in adjacent buildings or underground pipelines, so it is of great significance to predict the deformation of foundation pit in advance for the safety of foundation pit engineering. In order to achieve high-precision prediction of foundation pit surface settlement, this paper utilized convolutional neural network (CNN), BP (back-propagation) neural network and long short term memory (LSTM) neural network algorithms to construct a foundation pit settlement deformation prediction model. Based on the entropy method and the CRITIC weight method, three machine learning algorithms were combined to establish a combinatorial prediction model. Based on the foundation pit deformation monitoring data, the accuracy of the single prediction model and the combined prediction model used in this paper was evaluated. The results show that compared with the prediction model of a single machine learning algorithm, the average absolute error of the combined entropy method prediction model is reduced by 90.79%, the mean square error by 99.44%, and the average absolute percentage error by 90.33%. The average absolute error of the combined prediction model of the CRITIC method was reduced by 86.40%, the mean square error was reduced by 98.31%, and the average absolute percentage error was reduced by 84.94%. The combined prediction model proposed in this paper has better prediction performance than that of the single model, and the research is of great significance to improve the prediction accuracy of foundation pit surface settlement and ensure the safety of foundation pit construction.

Keywords: foundation pit; fusion prediction; machine learning; entropy method; CRITIC method

收稿日期: 2024-04-26 修回日期: 2024-06-26 接受日期: 2024-07-12 责任编辑: 黄琦

基金项目: 国家自然科学基金项目(42104019); 长三角科技创新共同体联合攻关课题(2022CSJGG1205)

作者简介: 马雪利(2000-),女,安徽阜阳人,硕士研究生,主要从事多源数据融合及深度学习方面的研究。E-mail: 1628624710@qq.com

通信作者: 姚华彦(1979-),男,湖北罗田人,博士,副教授,主要从事岩土工程稳定性分析与城市地下空间开发利用方面的研究。

E-mail: yaohuayan@hfut.edu.cn

0 引言

随着城市化进程的推进,基坑工程向更深、更复杂的趋势发展,深基坑开挖必然引起地表沉降。在施工活动以及周边环境的干扰下,地表沉降监测数据常存在一定误差。如何有效地利用历史数据建立可靠的预测模型,并对未来地表沉降进行精准预测,对于指导基坑施工、保障既有建筑和基础设施的安全运营意义重大^[1-3]。

随着人工智能技术的发展,基于神经网络的多种算法被广泛应用于基坑、隧道、大坝的变形预测研究。为克服传统预测方法难以全面利用监测数据、分析因素单一及简化假设等缺陷,学者们将神经网络理论引入地表沉降预测,例如BP神经网络模型^[4-7]、自回归模型^[8]、MMF模型^[9]、支持向量机^[10]等,并在实际应用中取得了较好的成效。随着基坑施工方法和技术的不断发展,地表沉降的波动日益严重,线性模型和传统方法已无法满足精准预测需求。近年来,新兴的深度学习模型,例如长短时记忆神经网络^[11-12]、卷积神经网络^[13]等,已应用于地表沉降预测,且预测性能较好。通过组合不同模型和方法,可改善预测能力,提高预测精度。文献[14]~文献[17]研究表明,组合预测模型的预测精度优于任意单一预测模型的预测精度,具有更好的实际应用价值。

为克服单一预测模型在适应性、预测精度和稳定性等方面的缺陷,本文以沈阳市沈河区方家栏车站为研究对象,结合卷积神经网络(convolutional neural network, CNN)、BP(back-propagation)神经网络、长短期记忆(long short term memory, LSTM)神经网络三种算法模型,基于熵值法和CRITIC法建立组合预测模型,并对基坑施工引起的周边地表沉降进行预测分析。通过与实测沉降值对比,结合多个指标评估组合预测模型的精度和可靠性,为机器学习模型在基坑周围地表沉降方面的预测提供参考。

1 地表沉降预测模型

基坑地表变形是一种具有时序动态特性的复杂多变动态函数。与传统的数值分析法和解析法相比,机器学习在数据预测方面表现出色,具有

较强的容错能力和较快的预测识别速度。机器学习是多元非线性动力学系统,可灵活方便地对多成因的复杂未知系统进行高度建模,实现对深基坑周边地表沉降变形的预测^[18]。在基坑沉降预测时,不同神经网络模型优势各异:CNN能有效捕捉沉降数据在空间的特征;传统BP神经网络具备强大的非线性拟合能力,但无法考虑监测点之间的空间关系,可能影响预测精度;LSTM神经网络克服了传统循环神经网络在学习长期依赖关系时的梯度问题,但与组合模型相比,单一LSTM模型在处理复杂数据时表现不佳。

单一模型简介如下。

(1) 卷积神经网络

CNN是一种前馈神经网络^[19],它通过卷积和池化操作提取数据之间的相互关系,并使用少量参数来表示数据的空间特征。其中,卷积层通过设置卷积核对输入数据进行离散卷积运算,提取空间特征;池化层通过取最大值或平均值等操作对卷积核内的数据进行降采样,去除冗余信息并保留关键特征。CNN可根据内核大小,从输入的时间序列数据中提取有用特征。本文通过MATLAB建立CNN预测模型,卷积核大小为 3×1 ,池化深度为2,采用ReLU函数作为激活函数。迭代次数为800,初始学习率为0.005,学习率下降因子为0.1,经过600次训练后,学习率为0.0005。

(2) BP神经网络

BP神经网络是一种多层前馈神经网络,包括输入层、隐含层和输出层,具有泛化能力强等特点^[20]。本文通过MATLAB软件的newff函数创建一个前向反馈神经网络,利用train函数进行神经网络的模型训练。将数据集作为输入,基坑地表变形作为输出,进行模型的训练和学习。为防止陷入死循环,保证预测精度,结合工程实际,设置BP神经网络预测模型的隐含层节点数为5,误差阈值为 6×10^{-6} ,学习率为0.01,迭代次数为1400。训练过程中神经网络的权值和偏置会不断更新,误差逐渐减小。

(3) 长短期记忆神经网络

HOCHREITER等^[21]提出的LSTM是递归神经网络(RNN)的变形。SHERSTINSKY^[22]对LSTM

进行了改进。LSTM构建了专门的记忆存储单元,通过时间反向传播算法对数据进行训练,可解决RNN存在的梯度消失及无长期依赖的问题。假设输入LSTM的时间序列为 $X=\{x_1, x_2, \dots, x_t\}$,其中, x_t 为输入第 t 个细胞的时间序列。上一个细胞的输出 h_{t-1} 和状态 c_{t-1} ,输出为当前细胞的输出 h_t 和状态 c_t ^[23]。输入门、遗忘门、输出门和中间向量分别为

$$i_t = \sigma(W_i x_t + U_i h_t), \quad (1)$$

$$f_t = \sigma(W_f x_t + U_f h_t), \quad (2)$$

$$o_t = \sigma(W_o x_t + U_o h_t), \quad (3)$$

$$\tilde{c}_t = \tanh(W_c x_t + U_c h_t), \quad (4)$$

式(1)~式(4)中: $\sigma(\cdot)$ 为激活函数; W_i 、 W_f 、 W_o 、 W_c 均为输入过程的权重矩阵; U_i 、 U_f 、 U_o 、 U_c 均为状态转移权重矩阵; $\tanh(\cdot)$ 为双曲正切函数^[24]。

第 j 个LSTM的单元时间 t 的记忆单元 c_t^j 为

$$c_t^j = i_t^j \tilde{c}_t + f_t^j c_{t-1}^j, \quad (5)$$

式中: i_t^j 、 f_t^j 分别为第 j 个单元的输入门、遗忘门; c_{t-1}^j 为上一个时刻神经元的输出。

记忆单元更新后,当前隐层为

$$h_t^j = o_t^j \tanh(c_t^j), \quad (6)$$

式中, o_t^j 为第 j 个单元的输出门。

通过MATLAB软件建立LSTM预测模型,时间步长为1,隐含层神经元个数为4,输入层和输出层均设1个节点。在模型训练环节,采用自适应矩估计(Adam)算法。为防止模型出现过拟合问题,在训练过程中学习率逐渐递减。初始学习率为0.005,学习率下降因子为0.1,最大迭代次数为1200,并将数据归一化至[0,1]区间。

2 组合权重算法模型

通过对CNN、BP神经网络和LSTM进行加权可得到组合预测模型,确定组合权重是构建组合机器学习模型的核心^[25]。组合预测模型的建立方法较多,例如等权组合法、非线性组合法等。本文采用熵值法和CRITIC权重法构建组合预测模型,并采用3种单一预测模型对基坑地表沉降进行预测,假设 $y(t)(t=1,2,\dots,n)$ 为第 t 期基坑地表沉降的实际监测值; $\hat{y}_i(t)$ 为第 i 个($i=1,2,3$)预测模型对第 t

期地表沉降变形的预测值; w_i 为第 i 个单一预测模型对基坑地表沉降变形预测的权重,满足

$$\sum_{i=1}^n w_i = 1 \quad w_i \geq 0. \quad (7)$$

利用确定的权重对各单一预测模型的预测结果进行加权处理,得到该时刻的预测沉降值为

$$\hat{y}(t) = \hat{y}_1(t)w_1 + \hat{y}_2(t)w_2 + \hat{y}_3(t)w_3. \quad (8)$$

2.1 权重确定

(1) 熵值法

熵值法根据评价指标的离散程度确定权重^[26],则第 i 个模型预测的 t 时刻基坑变形量的指标值比重为

$$\rho_i = \frac{\hat{y}_i(t)}{\sum_{t=1}^k \hat{y}_i(t)}, \quad (9)$$

式中, k 为时刻。

第 i 个模型的熵值为

$$\alpha_i = -\frac{\sum_{t=1}^k \rho_i}{\ln k}. \quad (10)$$

第 i 个模型的差异性系数为

$$\gamma_i = 1 - \alpha_i. \quad (11)$$

则权重为

$$w_i = \frac{\gamma_i}{\sum_{i=1}^3 \gamma_i}. \quad (12)$$

(2) CRITIC权重法

CRITIC权重法通过对比度和矛盾性对指标进行权重计算。假设数据集由 n 个数据样本构成,在此数据集的基础上定义 m 个指标,相应的数学描述如下。

用标准差来表示单一预测模型的对比度,即

$$\sigma_i = \sqrt{\frac{\sum_{t=1}^m (\hat{y}_i(t) - y(t))^2}{m-1}}. \quad (13)$$

设模型 i 与其余模型的矛盾性为

$$f_i = \sum_{j=1}^3 (1 - \gamma_{ij}), \quad (14)$$

式中, γ_{ij} 为指标 i 与指标 j 的相关系数,采用皮尔逊相关系数。

设模型 i 信息承载量为

$$C_i = \sigma_i f_i. \quad (15)$$

信息承载量越大,则权重 w_i 越大,满足

$$w_i = \frac{C_i}{\sum_{i=1}^3 C_i}. \quad (16)$$

2.2 预测流程

将CNN、BP神经网络、LSTM三种预测模型通过熵值法和CRITIC法确定权重,建立组合预测模型。组合预测模型的基坑地表沉降变形预测流程见图1。




图1 组合预测模型的基坑地表沉降变形预测流程

Fig.1 prediction process of ground settlement deformation of foundation pit based on combined prediction model

3 工程实例评估

3.1 工程概况

方家栏车站为沈阳市沈河区地铁3号线一期工程中间车站,位于方兴路与方和路交口,住宅区、公园与东塔机场交界处,沿方和路设置,车站附近建筑物、管线较多,施工环境非常复杂。为保证开挖过程中基坑本身及周围建筑物安全,在施工过程中,将基坑以及 $2H$ (H 为基坑开挖深度)范围内的建筑物作为施工监测和保护的对象。车站主体结构的施工采用明挖法,基坑长为257.7 m,标准段开挖宽为20.8 m,深为16.99 m。基坑内支

撑为混凝土支撑+钢管支撑,首道支撑为混凝土支撑,尺寸为800 mm×800 mm,水平间距为6 m。第二、三道钢支撑采用直径为609 mm、壁厚 t 为16 mm的钢管,水平间距为3 m。采用DS05水准仪进行监测,按国家一等水准测量技术要求作业,监测内容主要包括深层土体水平位移、围护桩桩顶水平位移以及竖向位移、地表沉降以及周围建筑沉降。基坑四周设有沉降测点,选取距坑边7 m处的监测点数据进行分析。基坑监测点剖面位置见图2。




图2 基坑监测点剖面位置(单位:m)

Fig.2 section position of foundation pit monitoring point (unit: m)

3.2 基坑地表沉降预测

(1) 模型构建

为便于数据分析和模型测试,在方家栏车站基坑的整个施工期内,对基坑地表沉降进行监测。选取2022年2月28日—2022年11月15日18断面DBC4002监测点处的232组数据进行分析预测。该时段数据完整包含了DBC4002监测点附近基坑开挖前、开挖过程中的地表沉降值。开挖一段时间后,基坑地表沉降在第56~77期变形规律明显,累计沉降量逐渐增大;在第138~156期,地表沉降不断增大最终趋于稳定;基坑开挖完成后,地表沉降逐渐趋于稳定。为分析基坑开挖过程中预测模型对不同阶段的适应性,选取基坑开挖过程中沉降规律较明显的两个阶段进行研究:第1阶段选取第56~72期为训练样本,第73~77期为测试样本;第2阶段选取第138~151期为训练样本,第152~156期为测试样本。

训练样本确定后,利用MATLAB 软件进行编程,确定各预测模型算法,并通过实测数据进行模型测试。选择CNN、BP神经网络和LSTM预测模型进行训练与变形预测,利用熵值法和CRITIC权重法确定各模型权重,通过式(8)得到组合预测模型的预测值。不同方法下各预测模型的权重见表1。

表 1 不同方法下各预测模型的权重
Tab.1 weight of each prediction model under different methods


方法	阶段	CNN	BP神经网络	LSTM
熵值法	1	0.353 3	0.134 2	0.512 5
	2	0.403 0	0.187 3	0.409 7
CRITIC法	1	0.170 9	0.095 6	0.733 5
	2	0.121 7	0.793 2	0.085 1

(2) 预测结果


DBC4002 监测点处地表沉降实测值与预测值见图3。由图3可知,数据未发生突变时,各预测模型的预测值均与实测值较为接近。数据发生突变时,各预测模型的预测值与实测值存在较大差异。第2阶段第153~154期,LSTM模型预测结果

误差较大,这是因为数据发生突变,模型在训练数据时发生过拟合,使得模型在预测训练样本以外的数据时出现偏差,预测效果不佳。相比之下,采用熵值法与CRITIC权重法构建的组合模型,其预测精度较高。

各预测模型预测结果与实测数据的相对误差见表2。由表2可知,CNN的最大相对误差为3.69%,最小相对误差为-0.79%,平均相对误差为1.35%。BP神经网络的最大相对误差为0.32%,最小相对误差为-2.18%,平均相对误差为-1.02%。LSTM的最大相对误差为1.54%,最小相对误差为-7.89%,平均相对误差为-2.03%。熵值法组合预测模型的最大相对误差为1.08%,最小相对误差为-0.95%,平均相对误差为-0.06%。CRITIC权重法组合预测模型的最大相对误差为1.75%,最小相对误差为-1.08%,平均相对误差为0.28%。对比可知,CNN和BP神经网络的平均相对误差较小,LSTM在第2阶段的预测结果出现较大偏差,基于熵值法、CRITIC权重法构建组合模型,其预测偏差较小,整体表现更为稳定。



(a) 第1阶段



(b) 第2阶段

图3 DBC4002监测点处地表沉降实测值与预测值

Fig.3 measured and predicted values of surface settlement at DBC4002 monitoring sites

各模型针对地表沉降预测的相对误差分布情况见图4。由图4可知,CNN在第1阶段预测效果较差,LSTM在第2阶段预测效果较差。在第1阶段预测中,熵值法组合模型的预测相对误差有4期在 $\pm 1\%$ 以内;CRITIC权重法组合模型的预测相对误差有3期在 $\pm 1\%$ 以内。在第2阶段预测中,熵值法组合模型的预测相对误差均在 $\pm 1\%$ 以内;CRITIC权重法组合模型的预测相对误差有4期在 $\pm 1\%$ 以内。整体来看,单一预测模型和组合预测

模型的预测结果与实际监测值相比均存在一定误差。这是由于预测模型需利用前期实际监测数据构建训练样本,对模型进行训练后预测后期变形。基坑地表沉降受基坑施工方式、降雨、周边环境等因素的影响,当地表沉降出现突变时,预测模型无法准确描述这种变化对变形的影响。此外,变形的实际监测值在监测条件、天气情况等多种因素的影响下,变形监测结果也存在一定误差,导致模型预测值与实际监测值出现偏差。

表 2 各预测模型预测结果与实测数据的相对误差

Tab.2 relative error between the predicted results of each prediction model and the measured data

阶段	监测期数	实测 沉降/mm	CNN		BP 神经网络		LSTM		熵值法 组合模型		CRITIC 权重法 组合模型	
			预测值 /mm	相对 误差/%	预测值 /mm	相对 误差/%	预测值 /mm	相对 误差/%	预测值 /mm	相对 误差/%	预测值 /mm	相对 误差/%
1	73	-7.26	-7.450 7	2.63	-7.283 4	0.32	-7.317 4	0.79	-7.287 1	0.37	-7.337 0	1.06
	74	-7.35	-7.479 6	1.76	-7.294 7	-0.75	-7.282 3	-0.92	-7.280 7	-0.94	-7.317 2	-0.45
	75	-7.49	-7.711 2	2.95	-7.446 3	-0.58	-7.512 3	0.30	-7.499 2	0.12	-7.540 0	0.67
	76	-7.54	-7.818 2	3.69	-7.534 6	-0.07	-7.656 0	1.54	-7.621 7	1.08	-7.672 1	1.75
	77	-7.62	-7.586 5	-0.44	-7.518 2	-1.34	-7.674 5	0.72	-7.547 3	-0.95	-7.644 5	0.32
2	152	-12.39	-12.292 7	-0.79	-12.317 8	-0.58	-12.259 0	-1.06	-12.336 6	-0.43	-12.292 9	-0.78
	153	-12.74	-12.640 9	-0.78	-12.503 4	-1.86	-12.387 1	-2.77	-12.655 1	-0.67	-12.602 5	-1.08
	154	-13.04	-13.266 0	1.73	-12.828 7	-1.62	-12.502 2	-4.12	-13.093 0	0.41	-13.147 8	0.83
	155	-13.54	-13.777 8	1.76	-13.245 1	-2.18	-12.604 2	-6.91	-13.582 2	0.31	-13.613 1	0.54
	156	-13.76	-13.897 6	1.00	-13.545 9	-1.56	-12.674 0	-7.89	-13.776 3	0.12	-13.750 7	-0.07




图 4 各模型地表沉降预测相对误差的分布

Fig.4 distribution of relative error of surface subsidence prediction of each model

3.3 预测模型性能评估

为定量全面地评价预测效果,采用平均绝对误差 E_{EMA} 、均方误差 E_{EMS} 和平均绝对百分比误差 E_{EMAP} 来评估各模型的预测精度^[23,27],分别为

$$E_{\text{EMA}} = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n}, \tag{17}$$

$$E_{\text{EMS}} = \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}, \tag{18}$$

$$E_{\text{EMAP}} = \frac{\sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right|}{n} \times 100\%, \tag{19}$$

式 (17) ~ 式 (19) 中: n 为监测期数; y_i 为实测沉降值; $\hat{y}_i$ 为预测沉降值。

根据式 (17) ~ 式 (19), 计算得到各预测模

型的评估结果,见表 3。不同阶段各模型预测精度对比见图 5。

表 3 各预测模型的评估结果

Tab.3 evaluation results of each prediction model

评估 指标	阶段	CNN	BP 神经网络	LSTM	熵值法 组合模型	CRITIC 权重法 组合模型
E_{EMA}/mm	1	0.171	0.046	0.064	0.052	0.063
	2	0.160	0.206	0.609	0.050	0.085
E_{EMS}/mm	1	0.036	0.003	0.005	0.004	0.006
	2	0.029	0.048	0.497	0.003	0.009
$E_{\text{EMAP}}/\%$	1	2.295	0.613	0.853	0.695	0.850
	2	1.211	1.599	4.551	0.387	0.659

由表 3 和图 5 可知,与 CNN、BP 神经网络、LSTM 模型相比,在第 1 阶段,熵值法组合模型 E_{EMA} 、 E_{EMS} 和 E_{EMAP} 的最大减小量分别为 69.59%、88.89% 和 69.72%;在第 2 阶段,熵值法组合模型

E_{EMA} 、 E_{EMS} 和 E_{EMAP} 的最大减小量分别为 91.80%、99.40% 和 91.50%。与 CNN、BP 神经网络、LSTM 模型相比,在第 1 阶段,CRITIC 权重法组合模型 E_{EMA} 、 E_{EMS} 和 E_{EMAP} 的最大减小量分别为 63.16%、83.33% 和 62.96%;在第 2 阶段,CRITIC 权重法组合模型 E_{EMA} 、 E_{EMS} 和 E_{EMAP} 的最大减小量分别为 86.04%、98.19% 和 85.52%。通过对比可知,与 CNN、BP 神经网络、LSTM 模型相比,熵值法组合模型、CRITIC 权重法组合模型可降低 E_{EMA} 、 E_{EMS} 和 E_{EMAP} ,提高预测精度。




图5 不同阶段各模型预测精度对比

Fig.5 comparison of prediction accuracy of each model at different stages

综合来看,熵值法组合模型和CRITIC法组合模型在基坑变形预测方面表现更优,特别是在降低预测的系统性偏差及提高预测准确性方面,明显优于单一模型。由于基础模型的选择对组合模型预测精度的影响较大,如何合理确定基础预测模型尚需进一步研究完善。

4 结论

针对基坑开挖引起的地表沉降问题,以CNN、BP神经网络、LSTM模型为基础,基于熵值法和CRITIC权重法构建基坑地表沉降组合模型,结合沈阳方家栏车站基坑实际地表沉降监测数据,通过评价指标验证组合模型精度,得到如下结论。

(1) 基于熵值法和CRITIC权重法的组合预测模型,能够实现对单一模型(CNN、BP神经网络和LSTM)优势的有机整合,显著提高基坑地表沉降的预测精度。

(2) 与单一模型相比,基于熵值法、CRITIC权重法构建的组合模型,其平均绝对误差、均方误差和平均绝对百分比误差均显著降低,预测性能优越,对提升基坑施工安全性和风险控制水平具有重要的参考价值。

深基坑变形是一个已知与未知、规律性与随机性并存的现实问题。本文选取的3种单一模型相对基础,在未来研究中,可针对实际问题选取其他更为合适的模型,进一步优化预测模型,为基坑地表沉降的高精度预测提供更为可靠的方法支持。

参考文献(References):

- [1] WANG P, MA S Y, YUE Z W, et al. A theoretical study on the spatial effect of water-rich foundation pit instability failure[J]. AIP Advances, 2021, 11(1): 015049.
- [2] YANG W L, HU Y, HU C, et al. An agent-based simulation of deep foundation pit emergency evacuation modeling in the presence of collapse disaster[J]. Symmetry, 2018, 10(11): 581.
- [3] LIU L L, WU R G, CONGRESS S S C, et al. Design optimization of the soil nail wall-retaining pile-anchor cable supporting system in a large-scale deep foundation pit[J]. Acta Geotechnica, 2021, 16(7): 2251-2274.
- [4] 贺志勇, 郑伟. 基于BP神经网络的深基坑变形预测[J]. 华南理工大学学报(自然科学版), 2008, 36(10): 92-96.
- [5] HE Zhiyong, ZHENG Wei. Deformation prediction of deep foundation pit based on BP neural network[J]. Journal of South China University of Technology (Natural Science Edition), 2008, 36(10): 92-96.
- [6] 刘聪, 贺跃光, 邵磊森. 基于MATLAB工具箱的基坑深层水平位移神经网络预测[J]. 矿冶工程, 2016, 36(5): 27-29.
- [7] LIU Cong, HE Yueguang, SHAO Leisen. Neural network prediction for horizontal displacement of deep foundation by MATLAB toolbox[J]. Mining and Metallurgical Engineering, 2016, 36(5): 27-29.
- [8] 宋楚平. 一种改进的BP神经网络深基坑变形预测方法[J]. 土木工程与管理学报, 2019, 36(5): 45-49, 55.
- [9] SONG Chuping. Improved BP neural method for deformation

- predication of deep excavation[J]. Journal of Civil Engineering and Management, 2019, 36(5): 45-49, 55.
- [7] OUYANG X, NIE J W, XIAO X. Study of improved grey BP (back propagation) neural network combination model for predicting deformation in foundation pits[J]. Buildings, 2023, 13(7): 1682.
- [8] 肖武权, 冷伍明. 软土路基沉降实时建模动态预测[J]. 岩土力学, 2005, 26(9): 1481-1484.
- XIAO Wuquan, LENG Wuming. Real-time modeling and dynamic predicting of soft soil roadbeds[J]. Rock and Soil Mechanics, 2005, 26(9): 1481-1484.
- [9] 王军保, 刘新荣, 李鹏, 等. MMF模型在采空区地表沉降预测中的应用[J]. 煤炭学报, 2012, 37(3): 411-415.
- WANG Junbao, LIU Xinrong, LI Peng, et al. Study on prediction of surface subsidence in mined-out region with the MMF model[J]. Journal of China Coal Society, 2012, 37(3): 411-415.
- [10] 谭鹏, 曹平. 基于灰色关联支持向量机的地表沉降预测[J]. 中南大学学报(自然科学版), 2012, 43(2): 632-637.
- TAN Peng, CAO Ping. Predicting surface settlement of tunnel using grey relational-support vector machine[J]. Journal of Central South University (Science and Technology), 2012, 43(2): 632-637.
- [11] LI H L, ZHAO Z Z, DU X. Research and application of deformation prediction model for deep foundation pit based on LSTM[J]. Wireless Communications and Mobile Computing, 2022, 2022: 9407999.
- [12] 张生杰, 谭勇. 基于LSTM算法的基坑变形预测[J]. 隧道建设(中英文), 2022, 42(1): 113-120.
- ZHANG Shengjie, TAN Yong. Deformation prediction of foundation pit based on long short-term memory algorithm[J]. Tunnel Construction, 2022, 42(1): 113-120.
- [13] 洪宇超, 钱建固, 叶源新, 等. 基于时空关联特征的CNN-LSTM模型在基坑工程变形预测中的应用[J]. 岩土工程学报, 2021, 43(增刊2): 108-111.
- HONG Yuchao, QIAN Jiangu, YE Yuanxin, et al. Application of CNN-LSTM model based on spatiotemporal correlation characteristics in deformation prediction of foundation pit engineering[J]. Chinese Journal of Geotechnical Engineering, 2021, 43(Suppl.2): 108-111.
- [14] YUAN Z, GAO L, CHEN H J, et al. Study on settlement of self-compacting solidified soil in foundation pit backfilling based on GA-BP neural network model[J]. Buildings, 2023, 13(8): 2014.
- [15] ZHANG Q, MA Y N, ZHANG B, et al. Time series prediction on settlement of metro tunnels adjacent to deep foundation pit by clustering monitoring data[J]. KSCE Journal of Civil Engineering, 2023, 27(5): 2180-2190.
- [16] HAN Y L, WANG Y, LIU C Y, et al. Application of regularized ELM optimized by sine algorithm in prediction of ground settlement around foundation pit[J]. Environmental Earth Sciences, 2022, 81(16): 413.
- [17] LIU Y H, FENG X. Research on prediction of ground settlement of deep foundation pit based on improved PSO-BP neural network [C]//2021 5th International Conference on Water Conservancy, Hydropower and Building Engineering, May 28, 2021, Qingdao, China, EDP Sciences, 2021: 1-4.
- [18] 葛长峰, 胡庆兴, 李方明. 人工神经网络在预测深基坑周边地表沉降变形中的应用研究[J]. 防灾减灾工程学报, 2008, 28(4): 519-523.
- GE Changfeng, HU Qingxing, LI Fangming. A study on application of artificial neural network in prediction of ground surface settlement around deep foundation pit[J]. Journal of Disaster Prevention and Mitigation Engineering, 2008, 28(4): 519-523.
- [19] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [20] RUMELHART D E, DAVID E, MCCLELLAND J L, et al. Parallel distributed processing: explorations in the microstructure of cognition [M]. Cambridge: MIT Press, 1986: 282-285.
- [21] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780.
- [22] SHERSTINSKY A. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network[J]. Physica D: Nonlinear Phenomena, 2020, 404: 132306.
- [23] 徐厚生, 郭佳丽. 结合时间注意力机制的Bi-GRU-Atten的短时交通流预测[J]. 辽宁工程技术大学学报(自然科学版), 2023, 42(6): 763-768.
- XU Housheng, GUO Jiali. Short-term traffic flow forecast based on Bi-GRU-Atten algorithm with multi-layer time attention mechanism[J]. Journal of Liaoning Technical University (Natural Science), 2023, 42(6): 763-768.
- [24] 陈万志, 李昊哲, 刘恒嘉, 等. 融合LSTM和优化SVM的风力发电机组故障预测方法[J]. 辽宁工程技术大学学报(自然科学版), 2022, 41(4): 379-384.
- CHEN Wanzhi, LI Haozhe, LIU Hengjia, et al. Wind turbine fault prediction method based on LSTM and optimized SVM[J]. Journal of Liaoning Technical University (Natural Science), 2022, 41(4): 379-384.
- [25] 王飞. 基坑变形组合预测分析及安全性评价[J]. 隧道建设(中英文), 2019, 39(2): 204-210.
- WANG Fei. Combined prediction analysis and safety evaluation of foundation pit deformation[J]. Tunnel Construction, 2019, 39(2): 204-210.
- [26] 李振华. 融合人工智能算法的铁路路基沉降预测方法[J]. 铁道建筑, 2023, 63(2): 123-128.
- LI Zhenhua. Prediction method of railway subgrade settlement based on artificial intelligence algorithm[J]. Railway Engineering, 2023, 63(2): 123-128.
- [27] 芦志凡, 赵倩. 基于ICEEMDAN-DCN-Transformer的短期电力负荷预测[J]. 沈阳工业大学学报, 2024, 46(4): 388-396.
- LU Zhifan, ZHAO Qian. Short-term power load forecasting method based on ICEEMDAN-DCN-Transformer[J]. Journal of Shenyang University of Technology, 2024, 46(4): 388-396.