

DOI:10.13409/j.cnki.jdpme.20240924001

# 基于 CEEMDAN-SSA-ELM-LSTM 模型的地铁 车站深基坑支护桩水平变形预测\*

刘彦伟<sup>1</sup>, 彭洁<sup>1</sup>, 任连伟<sup>2</sup>, 高保彬<sup>1</sup>, 郭佳奇<sup>2</sup>, 王泽武<sup>3</sup>, 韩红凯<sup>1</sup>

(1. 河南理工大学安全科学与工程学院, 河南 焦作 454000; 2. 河南理工大学土木工程学院, 河南 焦作 454000;  
3. 郑州地铁集团有限公司, 河南 郑州 450000)

**摘要:** 灾害监测与预测是岩土工程领域至关重要的任务之一, 但工程监测数据中的非平稳性和非线性一直是预测的难点。为应对此挑战, 引入数据驱动算法极限学习机(ELM)、长短时记忆神经网络模型(LSTM), 结合自适应噪声完备集合经验模态分解(CEEMDAN)和麻雀搜索算法(SSA), 提出了一种改进的地铁车站深基坑变形组合预测模型。首先, 通过 CEEMDAN 将支护桩水平位移序列分解为趋势项和波动项, 降低数据的非平稳性。其次, 为充分考虑分解序列差异的非线性特征, 分别采用 SSA 优化后的 ELM 和 LSTM 模型对低频趋势项与高频波动项进行预测, 并将结果叠加重构为最终预测值。最后, 以郑州市某地铁车站深基坑为例, 通过设置消融实验、对比实验和泛化性验证实验, 系统评估了模型的准确性与实用性。结果表明: 该模型在精度和稳定性方面显著优于其他模型, 其中  $R^2$  提升了 2.88%~23.62%,  $RMSE$  和  $MAPE$  分别降低了 6.63%~41.13%、8.08%~64.79%。这充分说明模型在应对数据非平稳性和捕捉非线性特征方面表现出色, 具备良好的可靠性和广泛的应用前景, 可为岩土工程中的灾害防治提供新的思路和技术支持。

**关键词:** 基坑工程; 支护桩; 变形监测; 组合预测; 深度学习

**中图分类号:** TU443 **文献标识码:** A **文章编号:** 1672-2132(2025)01-0034-13

## Forecasting of Horizontal Deformation in Retaining Piles of Subway Station Deep Foundation Pits Based on the CEEMDAN-SSA-ELM-LSTM Model

LIU Yanwei<sup>1</sup>, PENG Jie<sup>1</sup>, REN Lianwei<sup>2</sup>, GAO Baobin<sup>1</sup>, GUO Jiaqi<sup>2</sup>,  
WANG Zewu<sup>3</sup>, HAN Hongkai<sup>1</sup>

(1. School of Safety Science and Engineering, Henan Polytechnic University, Jiaozuo 454000, China;  
2. School of Civil Engineering, Henan Polytechnic University, Jiaozuo 454000, China;  
3. Zhengzhou Metro Group Co., Ltd., Zhengzhou 450000, China)

**Abstract:** Disaster monitoring and prediction are critical tasks in geotechnical engineering. However, the inherent non-stationarity and non-linearity of engineering monitoring data have long posed challenges for accurate forecasting. In response to this challenge, this study proposes an improved combination prediction model for the deformation of deep foundation pits in subway stations. The model integrates

\* 收稿日期: 2024-09-24; 修回日期: 2024-11-21

基金项目: 中国工程院院地合作项目(2023HENZDB5)、区域创新发展联合基金(AQ20230304)资助

作者简介: 刘彦伟(1975—), 男, 教授, 博导, 博士。主要从事地下工程安全与防灾减灾研究。E-mail: yanweiliu@hpu.edu.cn

通信作者: 任连伟(1980—), 男, 教授, 博导, 博士。主要从事地基基础相关的教学与研究。E-mail: renhpu@hpu.edu.cn

data-driven algorithms, including Extreme Learning Machine (ELM) and Long Short-Term Memory (LSTM) neural networks, along with Complete Ensemble Empirical Mode Decomposition with Adaptive Noise (CEEMDAN) and the Sparrow Search Algorithm (SSA). Initially, CEEMDAN was employed to decompose the horizontal displacement sequence of the retaining piles into trend and fluctuation components, thereby reducing the data's non-stationarity. Furthermore, to fully capture the non-linear characteristics of the differences among each decomposed sequence, SSA-optimized ELM and LSTM models were employed to predict the low-frequency trend component and high-frequency fluctuation component, respectively. The results were then combined to reconstruct the final prediction values. Finally, the accuracy and practicality of the model were systematically evaluated through ablation, comparative and generalization validation experiments using a deep foundation pit example in Zhengzhou subway station. The results demonstrated that the proposed model exhibited superior performance in terms of both accuracy and stability when compared to other models. The  $R^2$  improvements ranged from 2.88% to 23.62%, while the reductions in *RMSE* and *MAPE* were observed to be between 6.63% and 41.13% and between 8.08% and 64.79%, respectively. The model's efficacy in addressing data's non-stationarity and capturing nonlinear features is evident, offering high reliability and broad application prospects. The model provides novel insights to and technical support for disaster prevention in geotechnical engineering.

**Keywords:** foundation pit engineering; retaining pile; deformation monitoring; combination forecast; deep learning

## 0 引言

城市土地资源的紧张稀缺极大地促进了地下空间的开发与利用,基坑工程作为地下空间的建设基础,对地下空间的高效安全发展至关重要。然而,深大基坑工程数量日益增长的同时周边环境也变得更加复杂,这使得地下工程施工建设面临着极大的安全风险<sup>[1]</sup>。变形预测作为基坑工程防灾减灾的核心内容,其精确性和时效性直接关系到工程的安全性与稳定性<sup>[2]</sup>。然而基坑是一个受自然环境、地质条件、支护结构和人类工程活动等多种因素共同作用的多维非线性动力系统,建设过程中风险和隐患因素的大量聚集和耦合,导致安全事故频繁发生。因此,开展地铁车站深基坑施工期间的变形监测及动态预测尤为重要。

长期以来,由于变形序列具有复杂的非线性和非平稳性,导致很难对其进行准确预测。目前的预测模型主要分为正分析和反分析两大类,其中正分析是一种通过确定相应工程的本构模型和参数,选择合适的解析理论<sup>[3-4]</sup>、经验公式<sup>[5-6]</sup>或数值模拟<sup>[7-8]</sup>进行求解的方法。但是考虑到地下岩土体地质和施工现场的随机性和不确定性<sup>[9]</sup>,试图采用某种或者几种分析模型反映其力学性质是不现实的,

且部分参数多为经验取值,在一定程度上也会影响预测精度<sup>[9]</sup>。因此,以数据驱动为核心的智能算法预测已经成为新兴研究方向。作为一种反分析法,智能预测法是从大量的现场资料和实测数据出发,避开基坑变形影响因素和变形值之间的复杂非线性关系,利用智能算法分析数据在时序方面的规律和趋势,从而实现监测数据与时间映射关系的预测,因此在变形预测领域得以迅速发展<sup>[10]</sup>。

近年来,机器学习算法已被广泛应用于工程预测领域,如支持向量机(SVM)<sup>[11]</sup>、随机森林(RF)<sup>[12]</sup>、极端梯度提升(XGBoost)<sup>[13]</sup>、灰色预测<sup>[14]</sup>和极限学习机(ELM)<sup>[15]</sup>等。然而,这些算法的性能在很大程度上取决于超参数的合理设定。刘银涛等<sup>[16]</sup>研究了超参数对模型预测性能的显著影响,对比了麻雀搜索(SSA)、遗传(GA)和粒子群(PSO)三种算法对ELM模型的优化效果,结果表明SSA在提升ELM的预测精度和稳定性方面效果尤为显著。然而,以上传统机器算法更适合预测以周期性变形为主的平稳序列,且这种方法大都是静态的,无法充分捕捉基坑复杂的非线性特征。与此相比,深度学习算法能够构建并优化深层网络结构,在处理高维长时间序列时表现优越。A. Mahmoodzadeh等<sup>[17]</sup>对比了多种智能算法在隧道施工地层最大沉降预测中的性能,结果表明长短时记忆神经网络

(LSTM)和深度神经网络(DNN)等深度学习算法在考虑长期依赖关系时显著优于传统方法。部分学者<sup>[18-19]</sup>对比了神经网络在支护桩水平变形上的预测结果,发现LSTM比反向传播(BP)神经网络表现出更好的预测精度。

上述方法证实了深度学习在变形预测方面的可行性。然而,变形数据不仅具有非线性,还表现出显著的非稳态特征。若直接采用单一模型进行预测,很难达到理想的预测精度。因此,基于“分解-预测-重构”和多模型融合策略的预测方法已经逐步应用于变形预测领域。部分学者<sup>[20-22]</sup>提出了将小波变换(WT)分解算法与各种模型进行组合预测,用以弥补单一预测方法的局限性。汤俊等<sup>[23]</sup>对比了WT、经验模态分解(EMD)和自适应噪声完备集合经验模态分解(CEEMDAN)的去噪效果,结果表明CEEMDAN在处理复杂变形序列时具有更强的分解能力。Y. Cao等<sup>[24]</sup>研究了CEEMDAN与LSTM的组合预测效果,发现CEEMDAN能够有效提高模型对小样本非平稳序列的预测精度。然而现有的组合模型多未充分考虑分解后各子序列在频率、幅值和时序上的特性差异,通常采用同一模型进行预测。这种处理方式在应对多尺度、多类型数据时存在局限性,影响了模型在复杂变形预测中的鲁棒性。

为解决这一问题,本文提出了CEEMDAN-SSA-ELM-LSTM组合预测模型。首先,该模型采用CEEMDAN将位移数据分解为趋势项和波动项,以降低数据的非平稳性。接着,针对趋势项与波动项不同的非线性特性,分别采用SSA优化的ELM和LSTM进行预测,从而提高模型对多尺度特征的捕捉能力。最终,将各分量预测结果重构为完整的位移预测结果。为验证模型的有效性,本文设计了消融实验以探讨优化与分解模块对预测精度的贡献,并进一步进行了多模型对比和泛化性验证实验,以评估模型在深基坑支护桩变形预测中的优越性。研究结果可为地下工程的变形预测和控制提供一种有效的技术手段,并为施工过程中的变形管理和决策提供重要的预警和指导依据。

## 1 CEEMDAN-SSA-ELM-LSTM 组合预测模型

本文提出的CEEMDAN-SSA-ELM-LSTM组

合预测模型的具体实现流程如下:

(1) 数据预处理。为提高数据质量和预测精度,需要对缺失值和异常值进行插值或删除,数据清洗完成后开展数据归一化。

(2) 数据分解。利用CEEMDAN将预处理后的变形监测数据分解成频率不等、物理特性不同的子序列,形成趋势项位移和波动项位移。

(3) 采用SSA-ELM模型预测趋势项位移。趋势项反映了基坑位移的整体长期变形规律,呈现出明显增长趋势,波动性较弱。因此,本文采用SSA-ELM预测规律性较强的低频趋势项,通过设置SSA寻找最优的连接权重和偏置值,并使用优化好的参数构建ELM模型预测趋势项位移。

(4) 采用SSA-LSTM模型预测波动项位移。波动项位移可以描述为基坑位移受到自然条件、周边环境等短期因素扰动的结果,LSTM因其特殊的记忆单元能够有效处理波动性强、规律性差的时间序列,因此本文采用LSTM预测高频波动项。LSTM模型训练效果受到隐藏层神经元个数( $N_h$ )、学习率( $lr$ )、迭代次数( $epochs$ )和批大小( $batch-size$ )等超参数影响,需要采用SSA算法寻找LSTM模型参数的最优组合。

(5) 最后,将趋势项和波动项预测值叠加重构为最终预测值。组合模型的具体构建流程如图1所示。

### 1.1 CEEMDAN分解算法

为解决现有分解算法存在的模态混叠和白噪声残留问题,M. E. TORRES等<sup>[25]</sup>提出了一种改进算法CEEMDAN,该算法具体实现过程如下:

(1) 向原始的位移序列 $x(t)$ 加入不同幅值 $\varepsilon$ 的高斯白噪声 $\omega(t)$ ,即 $X(t) = x(t) + \varepsilon\omega_n(t)$ 。

(2) 利用EMD算法对 $X(t)$ 进行 $N$ 次重复分解得到第一个IMF分量,同时经过计算可得此时的残余信号 $r_1(t)$ 。

$$\overline{\text{IMF}}_1 = \frac{1}{N} \sum_{i=1}^N \text{IMF}_k^i(t) \quad (1)$$

$$r_1(t) = x(t) - \overline{\text{IMF}}_1 \quad (2)$$

(3) 利用同样的方法,向第一个残余信号 $r_1(t)$ 中添加高斯白噪声 $\varepsilon_1 E_1(\omega_i(t))$ ,再次进行 $N$ 次重复分解得到第二个IMF分量和残余信号。

$$\overline{\text{IMF}}_2 = \frac{1}{N} \sum_{i=1}^N E_1(r_1(t) + \varepsilon_1 E_1(\omega_i(t))) \quad (3)$$

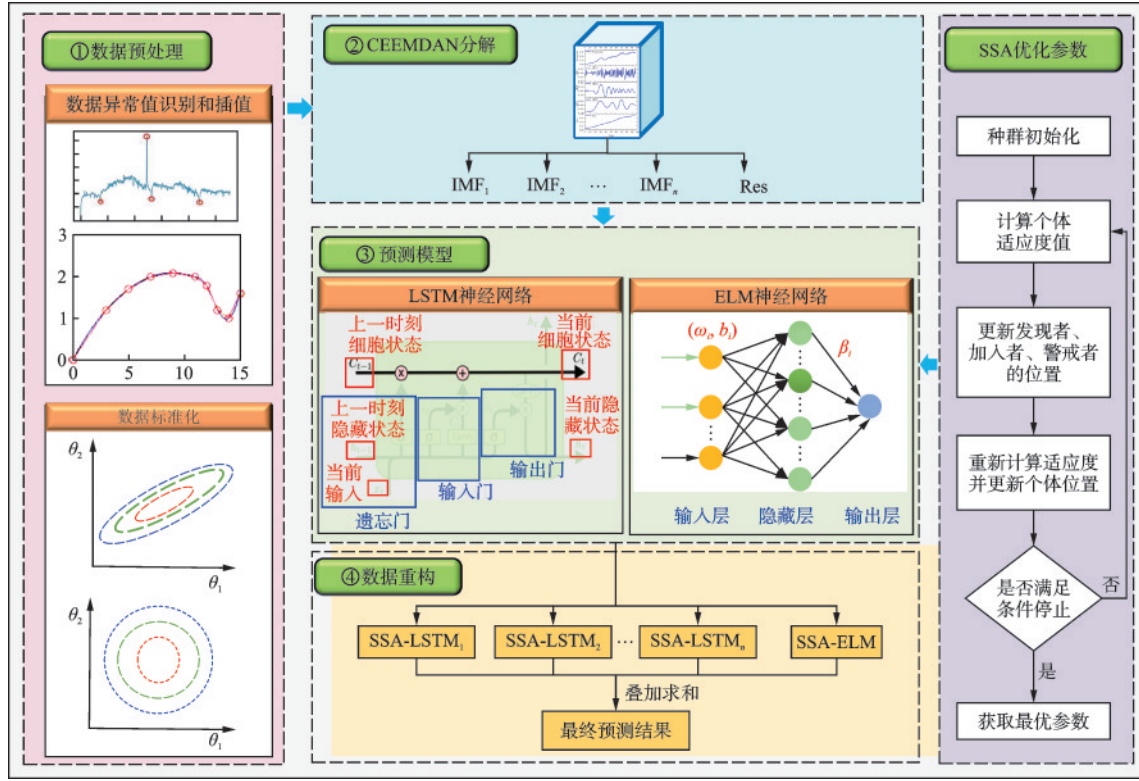


图1 CEEMDAN-SSA-ELM-LSTM模型预测流程

Fig.1 Flowchart of the CEEMDAN-SSA-ELM-LSTM forecasting process

$$r_2(t) = x(t) - \overline{\text{IMF}_2} \quad (4)$$

(4) 重复上述操作,直至残余信号变为单调函数,再也无法进行分解时即停止。此时共得到  $K$  个固有模态函数和一个最终残余量  $R(t)$ 。

$$R(t) = x(t) - \sum_{i=1}^K \overline{\text{IMF}_i} \quad (5)$$

经过 CEEMDAN 分解后,原始的基坑位移序列可以分解为一个趋势项和  $K$  个波动项,即:

$$x(t) = R(t) + \sum_{i=1}^K \overline{\text{IMF}_i} \quad (6)$$

## 1.2 SSA 优化算法

SSA 是受麻雀觅食行为启发而提出的智能优化算法<sup>[26]</sup>,其中发现者、加入者和警戒者通过不断优化个体位置以找到全局最优参数。

发现者位置转移更新公式为:

$$x_{i,j}^{(n+1)} = \begin{cases} x_{i,j}^{(n)} \cdot \exp\left(-\frac{i}{\alpha \cdot i}\right), & R_2 < S_T \\ x_{i,j}^{(n)} + Q \cdot L, & R_2 \geq S_T \end{cases} \quad (7)$$

式中,  $n$  是模型的迭代次数;  $x_{i,j}^{(n+1)}$  是第  $n+1$  次迭代时麻雀  $i$  在维度  $j$  的位置信息;  $\alpha$  是随机数;  $Q$  是服从正态分布的矩阵;  $L$  表示单位向量;  $R_2$  是警戒值;  $S_T$

是安全值。

加入者位置转移更新公式为:

$$x_{i,j}^{(n+1)} = \begin{cases} Q \cdot \exp\left(\frac{x_{\text{worst}}^{(n)} - x_{i,j}^{(n)}}{\alpha \cdot i}\right), & i > \frac{t}{2} \\ x_p^{(n+1)} + |x_{i,j}^{(n)} - x_p^{(n+1)}| \cdot A^+ \cdot L, & i \leq \frac{t}{2} \end{cases} \quad (8)$$

式中,  $x_p^{(n+1)}$  为第  $n+1$  次迭代时适应度最佳的个体位置;  $t$  为麻雀种群数量;  $x_{\text{worst}}^{(n)}$  和  $x_{i,j}^{(n)}$  分别表示最劣和最优位置;  $A$  表示矩阵。当  $i > t/2$  时,表示加入者的适应度值较低,需要转移位置觅食。

警戒者位置转移更新公式为:

$$x_{i,j}^{(n+1)} = \begin{cases} x_{i,j}^{(n)} + \beta |x_{i,j}^{(n)} - x_{b_j}^{(n)}|, & m_i \neq m_g \\ x_{i,j}^{(n)} + K \frac{|x_{i,j}^{(n)} - x_{\text{worst}}^{(n)}|}{(m_i - m_w) + \varepsilon}, & m_i = m_g \end{cases} \quad (9)$$

式中,  $x_{b_j}^{(n)}$  表示当前处在最安全的位置;  $\beta$  为步长控制参数;  $K$  为控制麻雀移动方向的参数;  $m_i$ 、 $m_g$ 、 $m_w$  分别表示当前麻雀的适应度值、全局最优和最差适应度值;  $\varepsilon$  常数用以避免分母为零。

## 1.3 ELM 极限学习机

ELM<sup>[27]</sup>具有随机初始化输入层权重和隐藏层

阈值的优势,无需迭代调整就可以得出网络输出值。

给定  $N$  组任意的样本  $(x_i, t_i) \in R^n \times R^m$ , ELM 输出函数可表示为:

$$y_j(x) = \sum_{i=1}^L \beta_i g(\omega_i \cdot x_j + b_i), j=1, 2, \dots, N \quad (10)$$

式中,  $n, L, m$  为输入层、隐藏层和输出层神经元数量;  $g(x)$  为激励函数;  $\omega_i$  表示输入层和隐藏层之间的权重;  $b_i$  表示隐藏层阈值;  $\beta_i$  表示隐藏层和输出层之间的权重。

ELM 的训练目标为实际输出值  $y_j$  和理想输出值  $t_j$  之间的差值最小, 即:

$$\sum_{i=1}^N \|y_j - t_j\| = 0 \quad (11)$$

则上述优化模型可以表示为:

$$H\beta = T \quad (12)$$

式中,  $H$  为隐含层输出矩阵;  $\beta$  为隐藏层和输出层之间的权重矩阵;  $T$  为网络输出矩阵。

求解线性方程组式得到最小二乘解:

$$\hat{\beta} = H^+ T \quad (13)$$

式中,  $H^+$  表示阵  $H$  的 Moore-Penrose 广义逆。

#### 1.4 LSTM 长短时记忆神经网络

LSTM<sup>[28]</sup> 是通过内部的遗忘门、输入门和输出门机制, 动态调整输入信息与神经元连接权重, 实现对长、短期依赖关系的有效捕捉。

遗忘门负责决定从记忆单元中丢弃的信息:

$$f_t = \sigma(W_f(h_{t-1}, x_t) + b_f) \quad (14)$$

式中,  $f_t, W_f, b_f$  是遗忘门输出值、权值和偏差;  $h_{t-1}$  是上一个输出值;  $x_t$  是当前输入值;  $\sigma$  为 Sigmoid 激活函数。

输入门负责确认记忆单元中保存的新信息:

$$i_t = \sigma(W_i(h_{t-1}, x_t) + b_i) \quad (15)$$

$$\tilde{C}_t = \tanh(W_c(h_{t-1}, x_t) + b_c) \quad (16)$$

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (17)$$

式中,  $i_t, W_i, b_i$  分别为输入门的输出值、权值和偏差;  $W_c$  和  $b_c$  是候选值的权值、偏差;  $C_{t-1}$  是  $t-1$  时刻候选值;  $\tilde{C}_t$  是细胞状态候选值。

输出门负责确定输出的信息, 其表达式为:

$$o_t = \sigma(W_o(h_{t-1}, x_t) + b_o) \quad (18)$$

$$h_t = o_t \tanh C_t \quad (19)$$

式中,  $O_t, W_o, b_o, h_t$  分别为输出层的输出值、权值、偏差和输出。

#### 1.5 模型评估指标

为了客观地评估模型的准确性和有效性, 本文采用决定系数  $R^2$ 、均方根误差  $RMSE$  和平均绝对百分比误差  $MAPE$  作为评估指标。  $R^2$  反映了预测模型的拟合程度, 其值越逼近于 1 越好;  $RMSE$ 、 $MAPE$  则是越小越好, 说明预测值与真实值误差小、预测效果好。各指标的计算公式如下:

$$R^2 = 1 - \frac{\sum_{i=1}^n (C_i - C_i')^2}{\sum_{i=1}^n (C_i - \bar{C})^2} \quad (20)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (C_i' - C_i)^2}{n}} \quad (21)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{C_i' - C_i}{C_i} \right| \times 100\% \quad (22)$$

式中,  $C_i, \bar{C}, C_i'$  分别为基坑变形数据的实测值、平均值和预测值;  $n$  为样本个数。

## 2 工程实例分析

为验证模型实用性, 以郑州市某地铁站深基坑工程作为 CEEMDAN-SSA-ELM-LSTM 预测模型的应用实例, 并将支护桩水平位移作为预测指标。

### 2.1 工程概况

郑州市某地铁站为岛式车站, 主体标准段结构为地下两层单柱两跨结构, 长、宽、高分别为 237、20.1、18 m, 采用明挖顺作法施工。图 2 为基坑平面布置示意, 从图中可以看出基坑周边环境复杂, 存在多座在建构筑物(最小距离为 29 m), 且开挖范围内存在雨水管和污水管等多种市政管线。如图 3 所示, 围护结构采用  $\Phi 1000@1500$  钻孔灌注桩+三道




图 2 基坑平面布置示意

Fig.2 Schematic diagram of the foundation pit layout




图3 基坑剖面

Fig.3 Profile of the foundation pit

钢支撑的支护体系,穿越的土层主要为粉土和黏土,场地浅部地基土体具有轻微湿陷性。因此,有必要对施工期间的基坑变形情况进行监测、预测,有利于及时调整施工工艺和支护参数,保障基坑和周边环境的安全。

## 2.2 基坑变形特征分析

支护桩水平位移是表征基坑稳定性最直观的指标,科学合理地解释其演化特征是实现基坑灾害预测预警的基础。因此,本文选择支护桩的测斜水平位移数据作为变形预测指标。该基坑共设置了22个测斜观测点,由于篇幅有限,这里以ZQT-16-01测斜点为例进行分析,如图4所示。




图4 监测点平面布置

Fig.4 Layout plan of monitoring points

在地铁车站的准备、开挖、浇筑和回填的全过程中,基坑开挖过程是事故发生最多的阶段,因此需要重点关注该阶段的施工情况。主要施工工况见表1。

基坑于2018年4月21日准备开挖,6月20日完成底板浇筑,直至6月27日开展下一步工序施工,ZQT-16-01测点的水平变形数据如图5所示。

表1 基坑主要施工阶段

Table 1 Main construction phases of the foundation pit

施工工况	时间	施工内容
工况一	4.27	架设第一道钢支撑
工况二	5.16	架设第二道钢支撑
工况三	5.16	架设第三道钢支撑
工况四	5.23	开挖至坑底,施工垫层、防水层
工况五	6.13	绑扎底板钢筋、浇筑
工况六	6.20	底板浇筑完成




图5 ZQT-16-01测点的水平变形数据

Fig.5 Horizontal deformation data of monitoring point ZQT-16-01

如图5所示,在上部土体侧向主动土压力的作用下,基坑工况一阶段的水平位移呈现三角形分布,主要原因在于第一道钢支撑未及时施加。

进入工况二初始阶段时,由于第一道支撑作用力较弱以及基坑的进一步开挖,导致桩体顶部位移仍处在加速变形阶段,变形速率为1.41 mm/d,最大位移为13.56 mm;随着第一道支撑结构的逐渐成型,变形速度明显减缓。这种缓慢的变形趋势持续到了工况四,此时的平均变形速率为0.0066 mm/d,说明第二道支撑和第三道支撑的作用明显,减缓了支护桩水平位移变化。

不同于上一阶段的稳定状态,工况五阶段顶部位移陡然增大的同时伴随着支撑轴力的持续升高,此时三个钢支撑的变化速率分别为59.19、52.01、54 kN/d。研究表明<sup>[29]</sup>缩短土体暴露时间是控制坑底施工变形的关键,因此可以看出阶段五的顶部位移异常增大就是因为前一阶段坑底土体暴露时间过长(耗时21 d)引起的。

基坑在工况六阶段完成了底板浇筑工作,此时各支撑轴力仍然处于加速增长阶段,特别是第二道

支撑的轴力于6月20日达到峰值666.7 kN。经过分析发现,这是由于坑边堆载、大型机械的停留造成的首层钢支撑偏心受力以及后续工况的滞后开展导致的。虽然最大位移值17.75 mm小于变形控制值27 mm,基坑整体处于安全状态,但仍需要采取填充垫块、重新加压等措施,确保每根支撑均达到预加轴力设计值且受力平衡,同时加强监测频率、及时开展下一步工序,以确保施工安全、稳定进行。

综上所述,基坑开挖变形监测数据表现出显著的非线性和非稳态性特征,大大增加了基坑的预测难度。

### 2.3 模型的构建与分析

这里以ZQT-16-01测点1 m深度处的实测数据为例,详细阐述CEEMDAN-SSA-ELM-LSTM组合预测模型的构建过程。旨在有效处理基坑变形监测数据中的复杂特征,从而提升预测精度和可靠性。

#### 2.3.1 数据预处理和CEEMDAN分解

基坑开挖监测时间范围为2018年4月21日至6月27日,受仪器、观测人员、天气、施工进度等因素的影响,监测时间间隔并不固定。为保证数据的一致性和模型的训练精度,本文对原始监测数据进行了插值处理。插值处理采用三次多项式插值法,将非等时距的监测数据插值为等时距数据,插值间隔设定为1 d,以便更好地捕捉数据的变化趋势。插值处理后,数据总量为62组。将插值后的数据集划分为训练集、验证集和测试集,划分比例为6:2:2,以确保模型的稳定性和泛化能力。

考虑到变形数据分布区间广,为提高计算精度,本文利用最小最大值归一化方法将数据归一化到[0,1]的范围。待预测完成后再进行反归一化处理,还原基坑变形监测数据。公式如下所示:

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (23)$$

$$x' = x_{\min} + y'_i(x_{\max} - x_{\min}) \quad (24)$$

式中, $x_i$ 表示基坑支护桩水平位移的原始序列; $x'_i$ 表示归一化处理后的序列; $x_{\max}$ 和 $x_{\min}$ 分别表示原始序列的最大值和最小值; $y'_i$ 表示测试集归一化后的位移预测序列; $x'$ 表示反归一化后得到的测试集位移预测序列。

考虑到基坑变形具有“时空效应”,为保证模型可以准确地捕捉基坑波动情况,现采用“4+1”滚动

预测的模式进行预测,即以基坑开挖过程中第 $n-3$ 、 $n-2$ 、 $n-1$ 、 $n$ 天的监测值作为输入层,对第 $n+1$ 天变形值进行预测输出。再将 $n+1$ 天预测值投入输入层对 $n+2$ 天进行预测。以此类推,不断滚动地对模型进行训练,提高模型预测精度。在此基础上开展CEEMDAN自适应分解,结果如图6所示。




图6 ZQT-16-01测点1 m深度的位移数据

Fig.6 Displacement data of monitoring point ZQT-16-01 at a depth of 1 m

从图6中可以看出,基坑位移是一种典型的混频复杂序列,经过CEEMDAN分解后,各分量相较于原始序列波形更加规整平滑,有利于根据位移分解序列曲线的不同特征采用不同模型进行预测。

#### 2.3.2 趋势项位移预测

支护桩水平位移的趋势项表现为明显的累积增长趋势,因此本文采用ELM模型对趋势项进行预测。鉴于ELM的输入层权值和隐含层阈值的随机生成可能会影响预测结果的稳定性,本文采用SSA对这两个参数进行优化。为此,需设置SSA的相关参数:麻雀种群大小为10,最大迭代次数设为30,激活函数选用sigmoid函数。

通过SSA优化,得到的最优输入层权重为[[5.48, 2.28], [-3.28, 5.53], [-4.71, -4.96], [6.41, -0.94]],以及最优隐含层偏置为[0.45, 0.88]。将优化后的权重和偏置代入公式(10)~(13),用于生成隐含层输出矩阵 $H$ ,并通过最小二乘解计算输出层权重,以获得最终的预测输出,从而实现趋势项位移的预测。

表2展示了SSA-ELM模型对趋势项位移的预测结果。结果显示,预测的最大相对误差为0.84%,最小相对误差为0.35%,误差区间仅为0.49%。该模型的 $R^2$ 高达0.994, $RMSE$ 和 $MAPE$ 分别为 $1.94e^{-5}$  mm、46.22%,表明模型能够充分学习数据特征,实现对趋势项位移的精确预测。

表2 趋势项位移预测结果

观测时间/d	真实值/mm	预测值/mm	相对误差/%
54	14.05	14.10	0.35
55	14.36	14.42	0.40
56	14.65	14.72	0.46
57	14.92	15.00	0.50
58	15.16	15.25	0.56
59	15.38	15.47	0.62
60	15.56	15.67	0.70
61	15.72	15.84	0.77
62	15.85	15.98	0.84

2.3.3 波动项位移预测

波动项  $IMF_1$  和  $IMF_2$  揭示了支护桩水平位移在不同时间尺度上的波动特性。 $IMF_1$  表现为高频、大幅波动,主要受短期内快速变化的荷载影响。分析表明,基坑开挖初期由于支撑未及时施加,导致主动土压力的迅速释放,以及施工过程中机械设备进出产生的临时荷载,均会导致支护桩水平位移中  $IMF_1$  的产生。相比之下,  $IMF_2$  的低频、小幅波动反映了相对长期荷载的影响,包括支撑逐步成型对变形的控制作用以及后续工况的滞后施工。可见,波动项的影响因素较为复杂,增加了预测难度。

然而, LSTM 模型可以直接从历史监测数据中提取复杂时序特征,能够避免显式考虑各个影响因素。同时,分解后的各分量为 LSTM 提供了更加细粒度的时序信息,使 LSTM 能够利用其长期和短期记忆机制有效捕捉关键的时序特征,从而提升对波动项位移的预测精度和稳定性。

LSTM 的预测结果对  $N_u$ 、 $lr$ 、 $epochs$  和  $batch-size$  等超参数具有高度敏感性,传统的超参数选择多数依靠人工经验,耗时且主观性较强,难以保证最佳预测效果。因此,本文采用 SSA 算法对 LSTM 模型中的超参数进行优化。LSTM 各参数取值范围设定为:  $N_u$  [2, 256]、 $lr$  [0.001, 0.2]、 $epochs$  [2, 1 000] 和  $batch-size$  [2, 128], 优化算法为 Adam, 添加 Dropout 为 0.2 以防止过拟合。SSA 算法的参数设置与 2.3.2 节一致。通过 SSA 训练得到的各子序列 LSTM 模型的超参数见表 3。

基于此,利用 SSA 优化后的 LSTM 模型对各个 IMF 分量进行预测,并将预测结果相加得到波动项的综合预测值。从图 7 可以看出,SSA 优化的 LSTM 模型在  $IMF_1$  和  $IMF_2$  的预测中均表现出良好

表3 各子序列的 LSTM 模型超参数

分量	$N_u$	$lr$	$epochs$	$batch-size$
$IMF_1$	16	0.03	1 480	64
$IMF_2$	28	0.09	964	18




图7 波动项位移预测结果

Fig.7 Prediction results of fluctuation term displacements

的拟合度。综合波动项的评价指标  $R^2$ 、 $RMSE$ 、 $MAPE$  分别为 0.947、0.045 mm、56.30%,进一步验证了 SSA-LSTM 模型在复杂波动条件下的高预测精度与稳定性。

2.3.4 最终预测结果

通过叠加重构趋势项和波动项的预测结果,得到了基坑支护桩水平位移的最终预测值,结果如图 8 所示。可以看到,测试集前期位移变化平稳,模型




图8 ZQT-16-01测点1m深度的水平位移最终预测结果

Fig.8 Final forecast results of horizontal displacement at 1 m depth for monitoring point ZQT-16-01



预测值与真实值高度一致,表现出良好的稳定性。在测试集后半段位移急剧上升的阶段,模型仍能准确捕捉非线性变化,表明其在复杂工况下的变形预测中具有较强的适应性。尽管相对误差在后期略有增加,但总体仍控制在合理范围内。

本模型的 $R^2$ 高达0.979, $RMSE$ 和 $MAPE$ 分别为0.379 mm、0.94%。这些精度指标表明,该模型不仅能够有效预测基坑支护桩水平位移的总体趋势,还具备良好的稳定性和可靠性。

## 2.4 消融实验

为探究各个模块对模型整体性能的重要性,以LSTM作为基准模型,设计了优化模块、分解模块的消融实验。为避免偶然性和主观性,以下预测结果均为10次实验结果的均值。

实验一:验证超参数优化模块对LSTM模型预测性能的增强效果。对不进行优化、进行PSO优化、进行GA优化、进行SSA优化的四种模型预测结果进行对比。本次实验均采用 $RMSE$ 作为适应度函数,LSTM、SSA参数设置与2.3.3节保持一致。PSO种群规模设为10,最大迭代次数为30,学习因子 $c_1=c_2=0.5$ ,惯性权重取0.8。GA种群规模设为10,最大迭代次数为30,交叉概率为0.5,变异概率为0.1。各模型预测评价指标见表4。

表4 优化模块消融实验各模型评价指标

Table 4 Evaluation metrics for each model of the optimization module ablation experiment

模型	$R^2$	$RMSE/mm$	$MAPE/\%$
LSTM	0.831	0.645	2.73
PSO优化	0.844	0.585	2.46
GA优化	0.850	0.594	2.74
SSA优化	0.870	0.542	2.48

从表4可以看出,不同优化算法对单一LSTM预测性能的提升程度不同,其中SSA优化效果最好, $R^2$ 提高了4.70%, $RMSE$ 和 $MAPE$ 降低了15.97%和9.16%。图9为各优化算法的适应度曲线,可以看出PSO收敛速度最快,但其适应度值也最高,主要是由于PSO处理高维、复杂问题的全局搜索能力不足,易陷入局部最优。GA则可以通过模拟自然选择和遗传学过程来提高全局搜索能力,因此稳定性强的同时收敛速度相对较慢。相比之下,SSA算法的整体收敛效果最好,在第14次迭代时就达到了最低适应度值。综上,SSA算法对提高LSTM变形预测精度提升具有显著效果。




图9 不同优化算法的适应度曲线

Fig.9 Fitness curves for different optimization algorithms

实验二:验证分解模块对LSTM模型预测性能的增强效果。对不进行模态分解、进行EMD分解<sup>[30]</sup>、进行VMD分解<sup>[31]</sup>和进行CEEMDAN分解的四种LSTM模型预测性能对比。以上模型均采用SSA优化LSTM超参数,参数设置与2.3.3节保持一致。VMD分解之前需要设置模态数 $K$ ,本文采用中心频率法确认了当 $K=6$ 时中心频率趋于稳定,因此VMD模态分解数为6。预测结果见表5。

表5 分解模块消融实验各模型评价指标

Table 5 Evaluation metrics for each model of the decomposition module ablation experiment

模型	$R^2$	$RMSE/mm$	$MAPE/\%$
不分解	0.870	0.543	2.48
EMD分解	0.887	0.635	2.78
VMD分解	0.900	0.639	2.74
CEEMDAN分解	0.922	0.521	1.75

可以看出,没有经过分解的模型预测效果最差,经过各种分解算法处理的模型性能均优于不分解模型,这说明对变形数据进行分解重构可以大大提高预测精度。其中,CEEMDAN通过引入白噪声有效减少了EMD模态混叠,且其自适应和抗干扰能力也比VMD更强,因此其预测效果最好。这表明,CEEMDAN能够高效分解非平稳的基坑变形序列,为后续预测提供了良好的基础支持。

## 2.5 不同模型对比分析

为进一步验证所提模型在基坑变形预测中的优势,现将其与两个单一典型模型和三个组合模型进行对比。单一模型分别为BP、门控循环单元网络(GRU),组合模型包含CEEMDAN-ARIMA-LSTM、CEEMDAN-SVR-LSTM、CEEMDAN-ELM-GRU。

其中,ARIMA是一种典型的时间序列统计预测模型,SVR和BP为常用的机器学习模型,GRU是预测时间序列最佳的深度学习算法之一。组合模型均采用CEEMDAN和SSA作为分解和优化算法,区别在于各子序列采用的预测模型不同,即验证ELM和LSTM模型与支护桩水平变形特征的适用性。各模型的评价指标如图10所示。

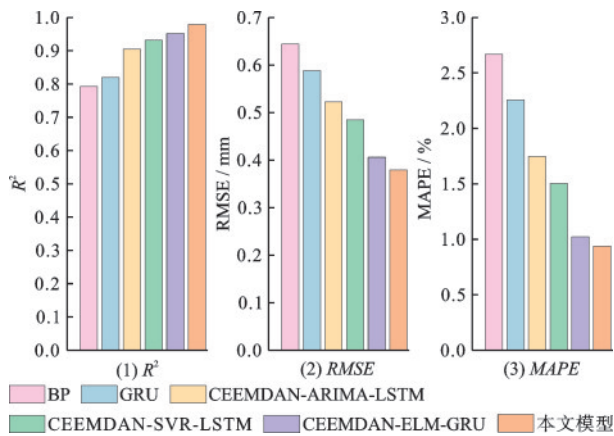


图10 不同模型的评价指标对比

从图中可知,单一典型模型与其他组合模型相比均存在一定的差距。BP是一种前馈神经网络,其各个评价指标都相对较低。与LSTM相比,GRU在短期依赖关系明显的任务中表现相对优秀,但是其在预测具有长期依赖关系的变形序列上远不如LSTM。以RMSE为例,BP比其他四项组合模型精度降低了18.86%、24.74%、36.95%、41.13%,GRU比其他四项组合模型精度降低了11.20%、17.64%、31.00%、35.58%。可见,组合模型在处理数据的非平稳性时更具优势,可以提高模型的鲁棒性和泛化能力。

以上组合模型均采用CEEMDAN分解,有效降低了数据的非平稳性。通过对比四个组合模型的评估指标可以发现,ELM和LSTM的组合模型在预测精度方面具有明显优势,相比于ARIMA-LSTM、SVR-LSTM、ELM-GRU的组合形式,本模型的 $R^2$ 分别提升了8.23%、5.17%、2.88%,RMSE分别降低了27.45%、21.78%、6.63%,MAPE分别降低了46.26%、37.55%、8.08%。

这种性能提升得益于ELM模型在处理非线性数据时的强泛化能力,能够快速适应并准确拟合长期趋势;同时,LSTM模型凭借其出色的时序记忆

能力,擅长捕捉高频波动序列中的突变和非线性特征。通过两者的协同作用,模型能够分别聚焦于趋势项和波动项的独特特性,充分挖掘变形数据的内在规律,从而显著提升整体预测性能。

## 2.6 泛化性验证

为进一步验证模型的泛化能力,本文选取了另一测点ZQT-17-01在10 m深度的变形数据进行分析。该测点位于第二道和第三道支撑之间,受基坑开挖引起的土压力变化影响,其变形特征复杂且与浅层测点数据存在显著差异。因此,对该测点的分析有助于评估模型在不同深度和复杂受力条件下的适用性。

在基坑开挖期间,通过插值处理,测点ZQT-17-01共获得55个数据点。本模型的预测结果如图11所示,图中展示了实际位移与预测位移的对比情况。可以看出,模型预测值与实际观测值高度吻合,大部分样本点分布在 $y=x$ 附近,尽管后期预测值略有偏差,但整体误差控制在合理范围内,表明模型在捕捉支护桩水平位移变化趋势上具有较高的准确性。具体而言,模型的精度 $R^2=0.957$ , $RMSE=0.428$  mm, $MAPE=1.67\%$ ,验证了模型在不同基坑环境下的有效性和泛化性。




图11 ZQT-17-01在10 m深度的水平位移真实与预测对比

## 3 结论

基坑变形的预测和控制对确保工程及周围环境的安全至关重要。针对地铁车站深基坑施工过程中因随机性引起的变形预测精度低、稳定性差的

问题,本文构建了 CEEMDAN-SSA-ELM-LSTM 组合预测模型,并在郑州市某地铁深基坑项目中开展应用,得出以下结论:

(1) SSA 优化算法显著提升了模型的预测精度、稳定性和收敛速度。与单一 LSTM 相比, $R^2$  提高了 4.70%, $RMSE$  和  $MAPE$  分别降低了 15.97% 和 9.16%,且在第 14 次迭代时就完成了收敛。这表明 SSA 通过其强大的群体合作和自适应机制能够有效搜索全局最优解,提升了深基坑变形预测的精度。

(2) CEEMDAN 分解算法在处理深基坑支护桩水平变形时,展示出卓越的模态分解能力。该算法能够有效缓解模态混叠和噪声的影响,从而削弱原始变形数据的复杂度,获得更加平滑和稳定的子序列。经过 CEEMDAN 分解后,模型的  $R^2$  高达 0.922, $RMSE$  和  $MAPE$  分别为 0.521 mm 和 1.75%,为深基坑变形的精准预测提供了可靠基础。

(3) 通过对比不同模型的预测结果,可以看出组合模型的预测效果均优于单一模型,且本文提出的组合模型在预测精度和稳定性方面均优于其他组合模型。相比于其他模型,该模型的  $R^2$  提高了 2.88%~23.62%, $RMSE$  和  $MAPE$  分别降低了 6.63%~41.13%、8.08%~64.79%。

(4) 在 ZQT-17-01 测点 10 m 深度的水平位移预测中,该模型同样展现出卓越的预测精度,进一步证明了其在不同深度及复杂基坑环境中的泛化能力和适应性。

综上所述,CEEMDAN-SSA-ELM-LSTM 组合模型充分融合了分解、优化和预测各模块的优势,能够有效应对支护桩水平变形序列中的非平稳性和非线性问题。因此,该组合模型可作为深基坑工程变形预测的一种高效、精准的工具,为岩土工程的灾害防治提供重要的技术支持。

另外,本研究尚未涵盖地表沉降、支撑轴力等监测指标的影响分析,未来的研究工作将进一步引入这些关键监测数据,以提升模型的整体预测能力。

## 参考文献:

[1] 章润红,刘汉龙,仇文岗.深基坑支护开挖对临近地铁隧道结构的影响分析研究[J].防灾减灾工程学报,2018,38(5):857-866.  
Zhang R H, Liu H L, Zhang W G. Numerical investi-

gation on tunnel responses induced by adjacent deep braced pit excavations[J]. Journal of Disaster Prevention and Mitigation Engineering, 2018, 38 (5): 857-866. (in Chinese)

[2] 程康,徐日庆,应宏伟,等.杭州软黏土地区某 30.2m 深大基坑开挖性状实测分析[J].岩石力学与工程学报,2021,40(4):851-863.

Cheng K, Xu R Q, Ying H W, et al. Performance analysis of a 30.2 m deep-large excavation in Hangzhou soft clay[J]. Chinese Journal of Rock Mechanics and Engineering, 2021, 40(4): 851-863. (in Chinese)

[3] 沈路遥,钱建固,张戎泽.挡墙水平变位诱发地表沉降的简化解析解[J].岩土力学,2016,37(8):2293-2298.

Shen L Y, Qian J G, Zhang R Z. A simplified analytical solution for ground settlement induced by horizontal movement of retaining wall[J]. Rock and Soil Mechanics, 2016, 37(8): 2293-2298. (in Chinese)

[4] 胡之锋,陈健,邱岳峰,等.挡墙水平变位诱发地表沉降的显式解析解[J].岩土力学,2018,39(11):4165-4175.

Hu Z F, Chen J, Qiu Y F, et al. Analytical formula for ground settlement induced by horizontal movement of retaining wall[J]. Rock and Soil Mechanics, 2018, 39 (11): 4165-4175. (in Chinese)

[5] Clough G W. Construction induced movements of insitu walls[J]. Geotechnical Special Publication, 1990(25): 439-470.

[6] 尚国文,李飒,翟超,等.基坑开挖与邻近地铁结构变形相关性的实测分析[J].防灾减灾工程学报,2020,40(1):107-115.

Shang G W, Li S, Zhai C, et al. Monitoring data analysis on deformation correlation between foundation pit and adjacent metro structure[J]. Journal of Disaster Prevention and Mitigation Engineering, 2020, 40(1): 107-115. (in Chinese)

[7] 陈昆,闫澍旺,孙立强,等.开挖卸荷状态下深基坑变形特性研究[J].岩土力学,2016,37(4):1075-1082.

Chen K, Yan S W, Sun L Q, et al. Analysis of deformation of deep foundation pit under excavation unloading condition[J]. Rock and Soil Mechanics, 2016, 37 (4): 1075-1082. (in Chinese)

[8] 刘天翔,朱鸿鹄,程刚,等.地下连续墙受力变形光纤监测与数值模拟研究[J].防灾减灾工程学报,2024,44(1):222-233.

Liu T X, Zhu H H, Cheng G, et al. Fiber optic monitoring and numerical simulation of stress and deformation of diaphragm wall[J]. Journal of Disaster Preven-

- tion and Mitigation Engineering, 2024, 44(1): 222-233. (in Chinese)
- [9] 张贵金, 徐卫亚. 岩土工程风险分析及应用综述[J]. 岩土力学, 2005, 26(9): 1508-1516.  
Zhang G J, Xu W Y. Summary about risk analysis of geotechnical engineering and its application [J]. Rock and Soil Mechanics, 2005, 26(9): 1508-1516. (in Chinese)
- [10] 徐长节, 李欣雨. 基于人工神经网络的深基坑支护结构侧移预测[J]. 上海交通大学学报, 2024, 58(11): 1735-1744.  
Xu C J, Li X Y. Lateral deformation prediction of deep foundation retaining structures based on artificial neural network [J]. Journal of Shanghai Jiaotong University, 2024, 58(11): 1735-1744. (in Chinese)
- [11] 许志海, 张可能, 李斌, 等. 基于SVM模型的基坑监测数据预测[J]. 工程建设与设计, 2019(13): 186-190.  
Xu Z H, Zhang K N, Li B, et al. Data prediction of foundation pit monitoring based on SVM model [J]. Construction & Design For Engineering, 2019(13): 186-190. (in Chinese)
- [12] 林楠, 张文春, 刘鹰, 等. 基于随机森林模型的季节性冻区深基坑变形预测[J]. 地下空间与工程学报, 2018, 14(增1): 357-362.  
Lin N, Zhang W C, Liu Y, et al. Prediction of deep foundation pit horizontal displacement based on random forest model in seasonal frozen region [J]. Chinese Journal of Underground Space and Engineering, 2018, 14 (Sup1): 357-362. (in Chinese)
- [13] 李鑫家, 丁智, 张霄, 等. 基于BO-XGBoost的盾构掘进地表变形预测[J]. 低温建筑技术, 2022, 44(11): 102-107.  
Li X J, Ding Z, Zhang X, et al. Surface deformation prediction of shield tunneling based on Bayesian optimization XGBoost [J]. Low Temperature Architecture Technology, 2022, 44(11): 102-107. (in Chinese)
- [14] 陈焕, 张可, 蒋一波, 等. 地铁站深基坑钢支撑体系轴力预测及安全预警模型研究[J]. 防灾减灾工程学报, 2023, 43(3): 576-587.  
Chen H, Zhang K, Jiang Y B, et al. Research on axial force prediction and safety warning model of steel bracing system in deep foundation pit of subway station [J]. Journal of Disaster Prevention and Mitigation Engineering, 2023, 43(3): 576-587. (in Chinese)
- [15] 王雪妮, 韩国锋. 地铁站深基坑的变形预测及稳定性研究[J]. 长江科学院院报, 2018, 35(10): 77-81, 87.  
Wang X N, Han G F. Application of coupling prediction model and cusp catastrophe theory to deformation prediction of deep foundation pit of subway station [J]. Journal of Changjiang River Scientific Research Institute, 2018, 35(10): 77-81, 87. (in Chinese)
- [16] 刘银涛, 任超. 基于SSA-ELM算法的基坑地表沉降预测[J]. 桂林理工大学学报, 2024, 44(3): 471-475.  
Liu Y T, Ren C. Prediction of foundation pit surface settlement based on SSA-ELM algorithm [J]. Journal of Guilin University of Technology, 2024, 44(3): 471-475. (in Chinese)
- [17] Mahmoodzadeh A, Mohammadi M, Daraei A, et al. Forecasting maximum surface settlement caused by urban tunneling [J]. Automation in Construction, 2020, 120: 103375.
- [18] 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 S J, Tan Y. Deformation prediction of foundation pit based on long short-term memory algorithm [J]. Tunnel Construction, 2022, 42(1): 113-120. (in Chinese)
- [19] 赵华菁, 张名扬, 刘维, 等. 基于神经网络算法的深基坑地连墙变形动态预测[J]. 地下空间与工程学报, 2021, 17(增1): 321-327.  
Zhao H J, Zhang M Y, Liu W, et al. Dynamic prediction of diaphragm wall deflection caused by deep excavation using neural network algorithm [J]. Chinese Journal of Underground Space and Engineering, 2021, 17 (Sup1): 321-327. (in Chinese)
- [20] 曹净, 丁文云, 赵党书, 等. 基于LSSVM-ARMA模型的基坑变形时间序列预测[J]. 岩土力学, 2014, 35(增2): 579-586.  
Cao J, Ding W Y, Zhao D S, et al. Time series forecast of foundation pit deformation based on LSSVM-ARMA model [J]. Rock and Soil Mechanics, 2014, 35 (Sup2): 579-586. (in Chinese)
- [21] 牛帅星, 李庶林, 刘胤池, 等. 基于小波变换的GAS-VM-ARMA模型在深基坑变形预测中的应用[J]. 土木与环境工程学报(中英文), 2023, 45(3): 16-23.  
Niu S X, Li S L, Liu Y C, et al. Application of GAS-VM-ARMA model based on wavelet transform in deformation prediction of deep foundation pit [J]. Journal of Civil and Environmental Engineering, 2023, 45(3): 16-23. (in Chinese)
- [22] Wei X, Cheng S, Chen R, et al. ANN deformation prediction model for deep foundation pit with considering the influence of rainfall [J]. Scientific Reports, 2023, 13(1): 22664.

- [23] 汤俊, 李垠健, 高鑫. 基于CEEMDAN的GNSS变形监测去噪方法[J]. 大地测量与地球动力学, 2021, 41(4): 408-412.  
Tang J, Li Y j, Gao X. GNSS deformation monitoring denoising method based on CEEMDAN[J]. Journal of Geodesy and Geodynamics, 2021, 41(4): 408-412. (in Chinese)
- [24] Cao Y, Zhou X, Yan K. Deep Learning neural network model for tunnel ground surface settlement prediction based on sensor data[J]. Mathematical Problems in Engineering, 2021, 1(2021): 9488892.
- [25] Torres M E, Colominas M A, Schlotthauer G, et al. A complete ensemble empirical mode decomposition with adaptive noise [C]//Prague: 2011 IEEE International Conference on Acoustics, Speech and Signal Processing. IEEE, 2011: 4144-4147.
- [26] Xue J, Shen B. A novel swarm intelligence optimization approach: sparrow search algorithm [J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.
- [27] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: Theory and applications [J]. Neurocomputing, 2006, 70(1-3): 489-501.
- [28] Hochreiter S, Schmidhuber J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780.
- [29] 刘国彬, 刘登攀, 刘丽雯, 等. 基坑坑底施工阶段围护墙变形监测分析[J]. 岩石力学与工程学报, 2007, 26(增2): 4386-4394.  
Liu G B, Liu D P, Liu L W, et al. Monitoring and analysis of lateral deformation of retaining wall during bottom excavation in deep pit [J]. Chinese Journal of Rock Mechanics and Engineering, 2007, 26 (Sup2): 4386-4394. (in Chinese)
- [30] 唐宇峰, 胡光忠, 周帅. 动态残差修正 LSTM 算法的突发性滑坡位移预测[J]. 中国安全科学学报, 2023, 33(8): 109-116.  
Tang Y F, Hu G Z, Zhou S. Displacement prediction of sudden landslide based on dynamic residual correction LSTM algorithm [J]. China Safety Science Journal, 2023, 33(8):109-116. (in Chinese)
- [31] 薛永安, 邹友峰, 陈文涛, 等. 变分模态分解与集成增强的残余变形组合预测[J]. 测绘科学, 2024, 49(7): 9-20.  
Xue Y A, Zou Y F, Chen W T, et al. Combined prediction of residual deformation in old goaf by variational modal decomposition and integrated enhancement [J]. Science of Surveying and Mapping, 2024, 49(7): 9-20. (in Chinese)

(本文编辑:张艺)