

张伟, 邓彬彬, 仇建春, 等. 基于 ESMD-FE-AJSO-LSTM 算法的水闸深基坑变形预测[J]. 南水北调与水利科技(中英文), 2024, 22(2): 378-387, 408. ZHANG W, DENG B B, QIU J C, et al. Deformation prediction of deep foundation pit of sluice based on ESMD-FE-AJSO-LSTM algorithm[J]. South-to-North Water Transfers and Water Science & Technology, 2024, 22(2): 378-387, 408. (in Chinese)

基于 ESMD-FE-AJSO-LSTM 算法的水闸深基坑变形预测

张伟^{1,3}, 邓彬彬², 仇建春^{3,4}, 夏国春^{1,3}, 姚兆仁¹, 刘占午¹, 朱新宇¹, 王昱锦¹

(1. 江苏省水利建设工程有限公司, 江苏 扬州 225002; 2. 张家港市长江防洪工程管理处, 江苏 苏州 215600; 3. 扬州大学水利科学与工程学院, 江苏 扬州 225100; 4. 河海大学水资源高效利用与工程安全国家工程研究中心, 南京 210098)

摘要: 水闸深基坑开挖变形具有明显的非线性和非稳定性特征, 基于此, 引入极点对称模态分解算法(extreme-point symmetric mode decomposition method, ESMD)对水闸深基坑开挖变形原型监测序列进行多模态分解, 并基于模糊熵(fuzzy entropy, FE)理论对各分解分量进行模糊多模态相空间重构, 从而有效甄别水闸基坑变形不同时间尺度有效物理特征。构建基于人工水母搜索算法(artificial jellyfish search optimizer, AJSO)优化的长短期记忆(long short-term memory, LSTM)神经网络模型, 以重构后的各重构子序列为基础进行优化训练, 并把训练后的各预测模态分量合并, 实现对水闸基坑开挖变形动态预测和分析。以张家港市十一圩江边枢纽改建工程基坑开挖变形监测为例, 采用上述方法对该枢纽工程基坑开挖过程变形进行预测和分析。结果表明: 基于 ESMD-FE-AJSO-LSTM 算法的水闸深基坑变形预测方法能够有效预测基坑开挖变形非线性特征, 相比传统 LSTM、循环神经网络(recurrent neural network, RNN)和支持向量机(support vector machine, SVM)等算法具有更高的预测精度和稳定性, 为实现对基坑开挖安全性态实时科学诊断和分析提供技术参考。

关键词: 极点对称模态分解算法; 模糊熵; 人工水母搜索算法; 长短期记忆; 水闸; 深基坑; 变形预测

中图分类号: TV698.11 **文献标志码:** A **DOI:** 10.13476/j.cnki.nsbqk.2024.0039

水闸深基坑开挖变形除受闸址区工程和水文地质条件、基坑空间尺寸、支护结构型式和工程开挖阶段等客观因素影响外, 还受现场工程机械振动、周边公共交通荷载和降雨、气温等随机环境因素影响^[1-3]。因此, 水闸深基坑开挖变形具有明显的非线性、非稳定性和不确定性特征^[4-5]。孙铁军等^[6]将灰狼优化算法与支持向量机相结合, 构建了基坑变形预测的灰狼-支持向量机回归算法(grey wolf optimizer-support vector regression, GWO-SVR)模型, 并利用主成分分析法分析了不同物理力学参数对基坑边坡变形影响的敏感性。算例分析表明, GWO-SVR 算法能够显著提高基坑边坡变形预测精度, 在众多物理力学参数中, 压缩模量和渗透系数两组参数对基坑边坡开挖变形影响最为显著。赵殿鹏等^[7]采用 BP(back propagation)神经网络模型构建了滨海

地区船闸基坑无支护条件下 3 层神经网络预测模型。算例分析表明, 该 BP 神经网络模型对滨海地区基坑变形预测具有较高的预测精度。洪宇超等^[8]采用 CNN(convolutional neural networks)神经网络对基坑变形监测数据进行多维特征提取, 并采用长短期记忆(long short-term memory, LSTM)神经网络模型对重构后的基坑变形监测数据进行训练和预测, 最后以上海云岭竖井超深基坑监测数据为例进行了案例分析, 结果表明构建的 CNN-LSTM 模型基坑变形预测精度高于仅考虑时间关联性的单一 LSTM 模型。曹净等^[9]提出了用于基坑变形预测的基于粒子群算法优化的最小二乘支持向量机(least squares support vector machines, LSSVM)和自回归移动平均模型(autoregressive moving average model, ARMA)模型(LSSVM-ARMA), 采用小波变换方法

收稿日期: 2023-08-14 修回日期: 2024-01-15 网络出版时间: 2024-03-13

网络出版地址: <https://link.cnki.net/urlid/13.1430.TV.20240312.1050.002>

基金项目: 国家自然科学基金项目(52179128; 52079120; 51579085); 扬州市“绿扬金凤”优秀博士人才项目(137012705)

作者简介: 张伟(1975—), 男, 江苏扬州人, 高级工程师, 主要从事水利工程建设、安全监测与管理研究。E-mail: 13861672099@139.com

通信作者: 仇建春(1989—), 男, 江苏扬州人, 博士, 主要从事水工结构领域研究。E-mail: qiujc@yzu.edu.cn

将水闸基坑变形序列分解为趋势性和随机性两组时间序列,并分别采用 LSSVM 和 ARMA 算法对两组序列进行预测和分析,研究结果表明 LSSVM-ARMA 模型针对基坑开挖变形具有较高的预测精度。崔春雨^[10]将遗传算法(genetic algorithm, GA)与残差神经网络模型(residual neural network, ResNN)相结合,构建了用于基坑变形预测的 GA-ResNN 模型,研究结果表明,在输入梯度变化小、数据量小的情况下,GA-ResNN 比 BP 神经网络模型的预测精度更高。

事实上,基坑开挖现场监测获得的变形监测数据是由一系列不同时间维度多模态序列叠加构成的^[11],如何对不同维度有效数据特征进行科学识别并进而有针对性地建模预测具有十分重要的意义。基于此,本文构建用于水闸深基坑开挖变形预测的 ESMD-FE-AJSO-LSTM 模型。首先,采用极点对称模态分解算法(extreme-point symmetric mode decomposition method, ESMD)对水闸基坑开挖变形进行多尺度识别和分解;接着,基于模糊熵(fuzzy entropy, FE)理论对各模态分量进行多维相空间重构,得到重构后的多个重构子序列;然后,构建基于人工水母搜索算法(artificial jellyfish search optimizer, AJSO)优化的长短期记忆(long short-term memory, LSTM)人工神经网络模型,对重构后的多个重构子序列基坑变形数据进行优化训练,得到对应各重构子序列的优化后的 AJSO-LSTM 优化模型;最后,利用优化确定后的各 AJSO-LSTM 优化模型,对各重构子序列按固定时间步长分别进行动态预测,并合成各重构子序列的预测结果,得到基坑变形的预测结果,并与传统的 LSTM、循环神经网络(recurrent neural network, RNN)和支持向量机(support vector machine, SVM)等算法进行对比分析,以验证本文方法有效性。

1 基本理论

1.1 基于极点对称模态分解

ESMD^[12-14]采用内部极点对称差值方法求解信号外包络线,与经典模态分解^[15-16]方法相似,具体步骤如下。

(1)计算原始时间序列 $x(t)$ 全部极值点,分别为 $E_i(1 \leq i \leq n)$, n 为极值点总数。计算极值序列 $E_i(1 \leq i \leq n)$ 连线中点 $F_i(1 \leq i \leq n-1)$ 。

(2)采用线性插值法计算极值序列上下限分别为 F_0 和 F_n 。采用内部极点对称差值方法对 $F_i(0 \leq i \leq n)$

计算 P 组极值曲线 $L_1, \dots, L_p(p \geq 1)$, 并计算中和极值 L^* 。

(3)计算 $x(t) - L^*$, 并重复步骤(1)~(2), 直到:

$$|L^*| \leq \varepsilon \quad (1)$$

式中: ε 为误差阈值。此时得到的 $x(t) - L^*$ 即为模态函数 M_1 。

(4)计算原始时间序列 $x(t)$ 与模态函数 M_1 差值序列 R_1 , 并对 R_1 重复步骤(1)~(3), 分别计算得到模态函数 M_2, M_3, \dots, M_n , 直到余项 R_1 极值点数不再大于设定值为止。

(5)在区间 $[K_{\min}, K_{\max}]$ 随机选取筛选次数 K , 并重复步骤(1)~(4), 得到一系列模态函数序列 M_1, M_2, \dots 。选取区间 $[K_{\min}, K_{\max}]$ 中 σ/σ_0 达到最小值时的 K_0 (其中, σ 和 σ_0 分别为差值序列 R_1 和序列 $x(t)$ 标准差), 并取 K_0 分解得到的模态函数序列 M_1, M_2, \dots 为 ESMD 算法分解得到的子模态 IMF_1, IMF_2, \dots , 式中, $\bar{X} = \sum_{i=1}^N x_i/N$ 为时间序列均值。经过上述分解, 原始时间序列 $x(t)$ 可以分解为

$$x(t) = \sum_{j=1}^n M_j + R_{es} \quad (2)$$

式中: R_{es} 为原始时间序列 $x(t)$ 经过层层分解后获得的趋势性分量。

1.2 模糊熵重构算法

采用 FE^[17-19] 理论对 N 维时间序列 X 进行相空间重构。取模式维数为 m , 构造 $N-m+1$ 个 m 维矢量 $Y(i)$ 和 $Y(j)$, 公式为

$$Y(i) = [x(i), x(i+1), \dots, x(i+m-1)] - x_0(i) \quad (3)$$

式中: $x_0(i)$ 为 m 个连续 $x(i)$ 的均值, 即 $x(i) = \frac{1}{m} \sum_{k=0}^{m-1} x(i+k)$; N 表征数据序列 $x(t)$ 长度。

取重构时间序列 $Y(i)$ 与 $Y(j)$ 之间的矢量距离为

$$d_{i,j}^m = \max_{k \in (0, m-1)} \|[x(i+k) - x_0(i)] - [x(j+k) - x_0(j)]\| \quad (4)$$

式中: $i, j = 1, 2, \dots, N-m+1$, 且 $i \neq j$, $k \in (0, m-1)$ 为随机数。取:

$$\psi^m(r) = \frac{1}{N-m+1} \sum_{i=1}^{N-m+1} \frac{1}{N-m} \sum_{j=1, j \neq i}^{N-m+1} D_{i,j}^m \quad (5)$$

式中: $D_{i,j}^m = \exp[-(d_{i,j}^m)^n/r]$, r 为相似容限度。原始时间序列模糊熵 FE 可以计算为

$$\begin{aligned} \text{Fuzzy}E_n(m, r) &= \lim_{N \rightarrow \infty} [\text{Ln}\psi^m(r) - \text{Ln}\psi^{m+1}(r)] \approx \\ &\text{Ln}\psi^m(r) - \text{Ln}\psi^{m+1}(r) \end{aligned} \quad (6)$$

1.3 基于 AJSO 优化的 LSTM 模型

AJSO 通过模拟水母群随洋流飘动及内部运动

实现目标优化, 洋流方向计算为

$$\vec{\text{trend}} = \frac{1}{n_{\text{pop}}} \sum \vec{\text{trend}}_i = \frac{1}{n_{\text{pop}}} \sum (X^* - e_c X_i) = X^* - e_c \mu \quad (7)$$

$$df = e_c \mu \quad (8)$$

式中: $\vec{\text{trend}}$ 表征洋流方向; n_{pop} 为当前水母群中水母个体总数; X^* 为当前最优水母的位置; X_i 为水母群第 i 只水母位置; e_c 为吸引力控制因子; μ 为当前水母群所有水母个体平均位置; df 为当前最优水母位置与 μ 矢量差。

水母群运动机理分为主动运动和被动运动, 被动运动表示为

$$X_i(t+1) = X_i(t) + \xi \times \text{rand}(0, 1) \times (U_b - L_b) \quad (9)$$

式中: U_b 和 L_b 分别为水母个体搜索空间上限值和下限值; ξ 为水母个体运动系数。

水母群主动运动表示为

$$\vec{\text{Step}} = X_i(t+1) - X_i(t) = \text{rand}(0, 1) \times \vec{\text{Direction}} \quad (10)$$

式中: $\vec{\text{Direction}} = \begin{cases} X_j(t) - X_i(t), f(X_j) \geq f(X_i) \\ X_i(t) - X_j(t), f(X_i) \geq f(X_j) \end{cases}$, f 为目标优化函数, X 为位置参数; $\text{rand}(0, 1)$ 为 $(0, 1)$ 内随机数。

引入时间控制机制来模拟洋流变化情况, 相应时间控制函数 $c(t)$ 表示为

$$c(t) = \left\lfloor \left(1 - \frac{t}{I_{\text{max}}} \right) \times [2 \times \text{rand}(0, 1) - 1] \right\rfloor \quad (11)$$

式中: t 为迭代次数; I_{max} 为迭代次数上限; 当 $c(t) \geq 0.5$ 时, 水母群将按照式 (15) 进行主动运动, 反之水母群按照式 (16) 进行被动运动。

当水母个体超出样本空间搜索边界时, 水母位置相应进行更改为

$$\begin{cases} X'_{i,d} = (X_{i,d} - U_{b,d}) + L_{b,d}, X_{i,d} > U_{b,d} \\ X'_{i,d} = (X_{i,d} - L_{b,d}) + U_{b,d}, X_{i,d} < L_{b,d} \end{cases} \quad (12)$$

式中: $X'_{i,d}$ 为更新后的水母位置; $X_{i,d}$ 为第 i 只水母在 d 维的位置; $U_{b,d}$ 为第 d 维分量的上限; $L_{b,d}$ 为第 d 维分量的下限。

相比 RNN 模型, LSTM 模型^[20-22] 有效避免了梯度消失问题。但是 3 种门结构的引入导致 LSTM 待确定参数较多, 传统方法多根据经验进行确定, 显然无法得到最优解。将 LSTM 模型关键最优参数(隐藏层单元数、学习率和迭代次数)作为待优化参数输入 AJSO 算法中进行智能寻优^[23-24], 基本优化过程见图 1。

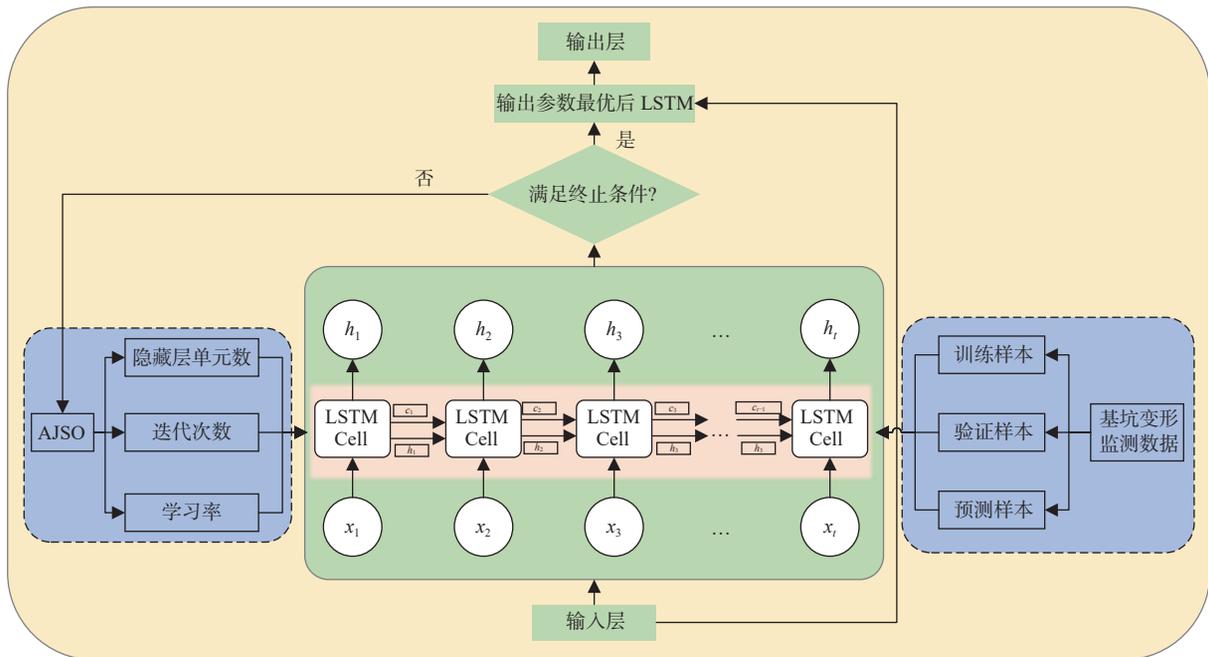


图 1 基于 AJSO 优化的 LSTM 模型训练基本流程

Fig. 1 Basic training process of LSTM model optimized with AJSO

目标优化函数定义为

$$\min E_{\text{RMS}} = \frac{1}{n} \sum_{k=1}^n \frac{|\hat{x}^{(0)}(k) - x^{(0)}(k)|}{x^{(0)}(k)} \quad (13)$$

式中: $\hat{x}^{(0)}(k)$ 为 LSTM 模型预测值; $x^{(0)}(k)$ 为实测值; n 为样本总数。

本文提出的 AJSO-LSTM 算法基本执行步骤如下:

- (1) 初始化水母种群生成, 采用 Logistic 映射方法生成原始水母种群序列为 $X^{(0)} = (x^0(1), x^0(2), x^0(3))$
- (3) 组参数分别代表隐藏层单元数、学习率和迭代次数, 并将初始参数代入 LSTM 模型。

(2)为了避免 LSTM 陷入过拟合而导致无法得到最佳预测值,将基坑变形监测数据分为训练样本(70%)、验证样本(15%)和预测样本(15%)。首先输入训练样本对 LSTM 模型进行训练(LSTM 模型在训练过程中,输入参数为基坑开挖时间和计算日期前 3 天的基坑变形值,输出参数为基坑变形计算值),并基于训练后的 LSTM 模型计算验证值和预测值,进而得到水母种群适应度值为

$$f_i = 0.5 \times \frac{1}{J} \sum_{j=1}^J \frac{|\hat{x}_i^j(j) - x_i^j(j)|}{x_i^j(j)} + 0.5 \times \frac{1}{K} \sum_{k=1}^K \frac{|\hat{x}_i^k(k) - x_i^k(k)|}{x_i^k(k)} \quad (14)$$

式中: $\hat{x}_i^j(j)$ 和 $\hat{x}_i^k(k)$ 分别为 LSTM 验证样本和训练样本输出值; $x_i^j(j)$ 和 $x_i^k(k)$ 分别为验证样本和训练样本实测值; J 和 K 分别验证样本和训练样本数据数。

(3)计算每组水母个体对应的适应度值作为当前位置的食物数量,并将食物数量最多的水母个体位置保存在实物库 F 中,记为 $F = [X^*]$ 。

(4)利用式(11)计算时间控制函数 $c(t)$,判断水母个体下一步采用的运动机理(主动运动或被动运动)。采用式(9)和式(10)对下一时刻水母位置 $X^{(i)}(t+1)$ 进行更新和迭代。

(5)判断水母个体位置是否超越搜索边界:若超过搜索边界,则按照式(12)进行更新;若没有超过搜索边界,则执行下一步。

(6)判断是否达到最大迭代次数或满足 $\min \text{avg}(e(\lambda, \varphi))$ 阈值要求:若不满足,则算法跳转至步骤(2)进行迭代;若满足条件,则结束算法,并输出最优搜索 $X^{(\text{best})} = (x^{(\text{best})}(1), x^{(\text{best})}(2), x^{(\text{best})}(3))$ 。

(7)将最优搜索参数 $X^{(\text{best})} = (x^{(\text{best})}(1), x^{(\text{best})}(2), x^{(\text{best})}(3))$ 输入 LSTM 模型,建立水闸基坑变形 AJSO-LSTM 模型。

1.4 ESMD-FE-AJSO-LSTM 算法

基于上述分析,构建的用于水闸基坑变形预测的 ESMD-FE-AJSO-LSTM 模型基本步骤(图 2)如下:

(1)采用 1.1 节所介绍的极点对称模态分解算法 ESMD^[25],将水闸深基坑变形监测数据分解为多个特征互异的子序列分量 IMF 和趋势性分量 R_{es} 。

(2)采用 1.2 节所引入的模糊熵理论,对各模态子序列分量和趋势性分量进行模糊多模态相空间重构,得到多个重构子序列。

(3)对重构后的多个重构子序列基坑变形数据进行优化训练,利用 1.3.3 节基本理论,得到对应各

重构子序列的优化后的 AJSO-LSTM 优化模型。

(4)利用优化确定后的各 AJSO-LSTM 优化模型,对各重构子序列按固定时间步长分别进行动态预测,并合成各重构子序列的预测结果,得到基坑变形的预测结果。

(5)引入如下预测精度评价指标,对 ESMD-FE-AJSO-LSTM 模型基坑变形预测精度进行评估:

$$R = \frac{\sum_{i=1}^n (S_i - \bar{S})(V_i - \bar{V})}{\sqrt{\sum_{i=1}^n (S_i - \bar{S})^2 \sum_{i=1}^n (V_i - \bar{V})^2}} \quad (15)$$

$$E_{\text{RMS}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (V_i - S_i)^2} \quad (16)$$

$$E_{\text{MA}} = \frac{1}{n} \sum_{i=1}^n |V_i - S_i| \quad (17)$$

$$E_{\text{MS}} = \frac{1}{n} \sum_{i=1}^n (V_i - S_i)^2 \quad (18)$$

式(15)~(18)中: R 为相关系数; E_{RMS} 为剩余标准差; E_{MA} 为平均绝对误差; E_{MS} 为均方误差; S_i 为水闸深基坑变形实测值; V_i 为水闸深基坑变形预测值; \bar{S} 为水闸深基坑实测变形平均值; \bar{V} 为水闸深基坑变形预测平均值。

2 案例分析

2.1 工程简介

张家港市十一圩江边枢纽工程基坑开挖分为两期实施:一期泵站节制闸段基坑周长约为 2 130 m,开挖面积约为 45 000 m²,开挖深度 5.5~11.7 m;二期套闸段基坑周长约为 1 550 m,开挖面积约为 13 100 m²,开挖深度 5.0~6.8 m。基坑支护及监测平面布置见图 3,基坑开挖典型支护剖面见图 4。为了确保基坑和周边环境安全,在开挖深度较大的套闸闸室和内外河闸首段、泵闸的泵房和进出水池段以及套闸内河引航段挡墙段采用基坑围护。其中:一期泵闸的泵房、进出水池段以及部分海漫段采用 SMW 工法桩+拉锚支护,其余部位采用大放坡开挖并设置防渗桩防渗;二期套闸闸室和内外河闸首段基坑采用 SMW 工法桩+拉森钢板桩围护,套闸内河引航段挡墙段采用钻孔灌注桩+拉锚围护,其余部位采用大放坡开挖并设置防渗桩防渗。一、二期的防渗桩和围护结构防渗帷幕共同形成封闭的截渗圈,二期套闸闸室和内外河闸首段的 SMW 工法桩

一期需打设好作为一期防渗桩。

2.2 基坑变形多模态 ESMD 分解

以该水闸深基坑 J12 测点水平变形为例,采用提出的 ESMD-FE-AJSO-LSTM 模型对其变形进行分析和预测。同时运用 AJSO-LSTM、LSTM、RNN 以及 SVM 算法对该测点水平变形进行分析和预测。

选用 2022 年 11 月 16 日—2023 年 4 月 25 日基坑变形实测值(图 5)构建 ESMD-FE-AJSO-LSTM 模型,并对 2023 年 4 月 26 日—2023 年 5 月 15 日测点水平变形进行预测和评估,验证算法的有效性。实测变形的监测频率为 1 次/d,按照 70% 训练、15% 验证和 15% 预测的比例关系划分监测数据。

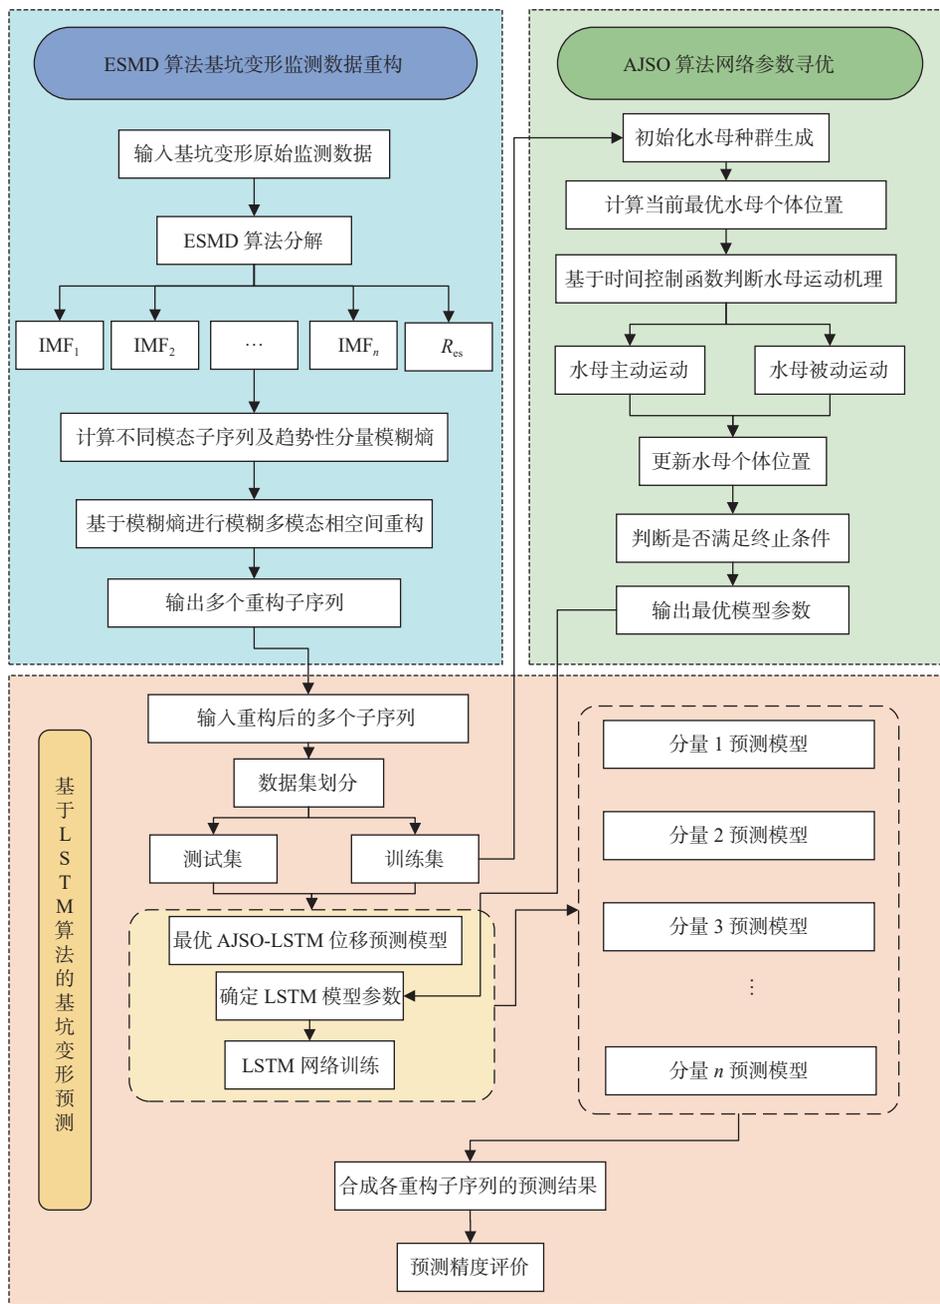


图 2 ESMD-FE-AJSO-LSTM 水闸深基坑变形预测基本流程

Fig. 2 Flow chart of deformation prediction for sluice foundation based on ESMD-FE-AJSO-LSTM

针对水闸深基坑变形监测序列非线性和非平稳特性,首先采用 ESMD 算法对其进行多尺度分解。以模态方差比率最小作为最优化分解原则,相应共获得 4 组模态分量 $IMF_1 \sim IMF_4$ 以及 1 组趋势性分量 R_{es} 见图 6。由图 6 可知,由 ESMD 算法分解出的不同特征尺度 IMF 分量在相同时刻完全体现出了不

同的振荡特性。因此,可以判断 ESMD 算法能够准确挖掘基坑开挖变形监测数据在不同特征尺度上的有效物理特征。

采用等距采样方法计算基坑开挖变形监测序列各模态平均周期,得到各尺度信号波动频率方差贡献率见表 1。该水闸深基坑开挖变形短序列波动

变化主要以模态 $IMF_1(1.71\text{ d})$ 和 $IMF_2(3.58\text{ d})$ 周期性变化为主,而长时序列波动变化最大方差贡献率

为趋势分量 $R_{es}(27.58\%)$,表明该水闸基坑变形在监测时段内具有明显的趋势性变化特性。

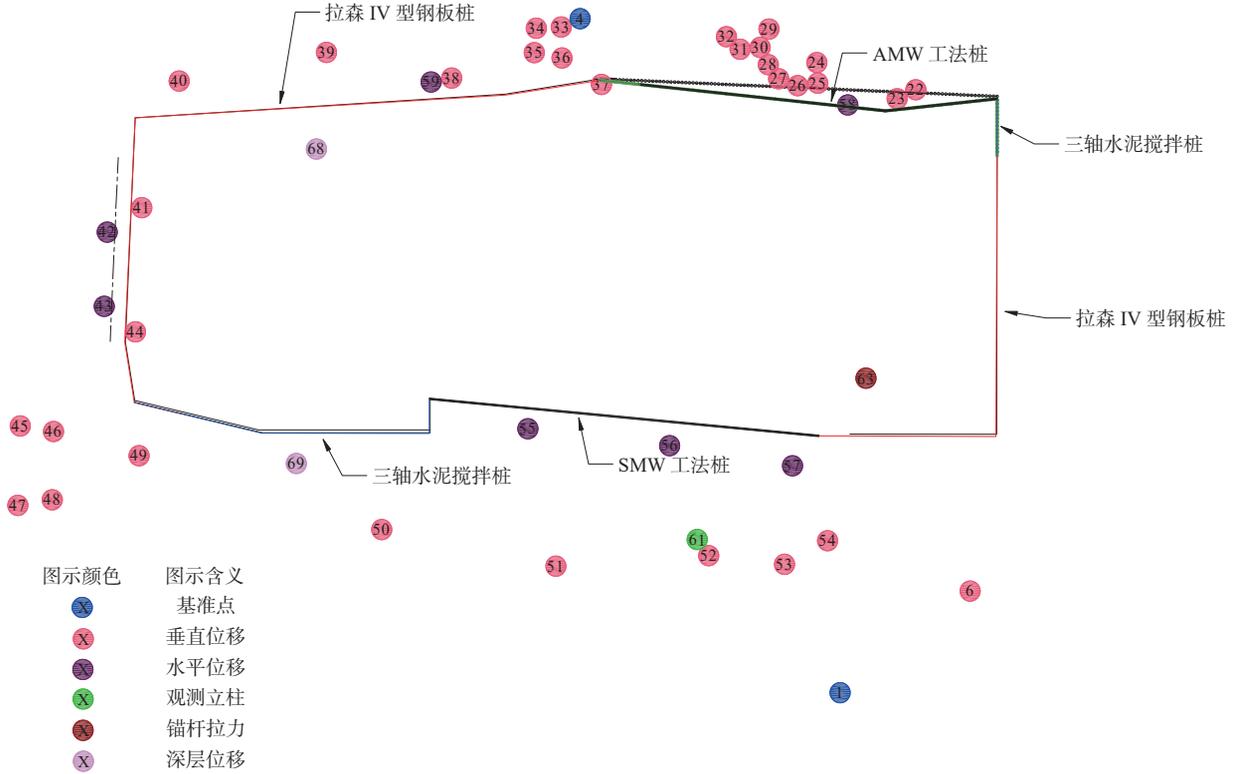


图 3 基坑支护及监测平面布置

Fig. 3 Excavation plan of foundation

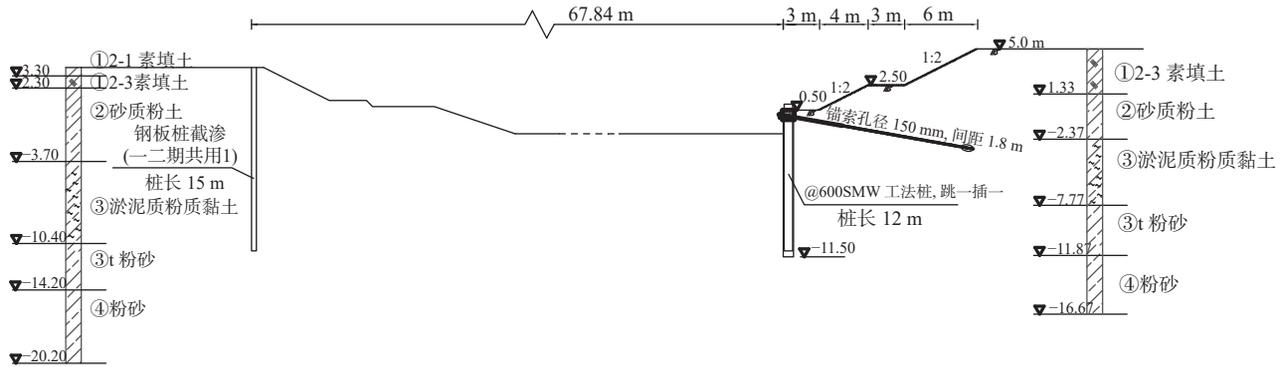


图 4 基坑开挖典型支护剖面

Fig. 4 Typical section of excavation and support for foundation pit

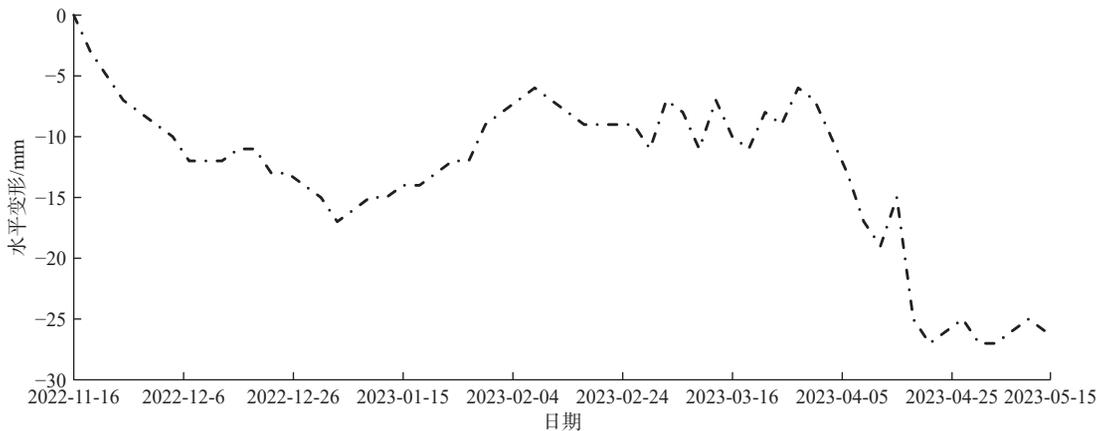


图 5 水闸基坑水平位移监测过程线

Fig. 5 Horizontal displacement monitoring process of sluice foundation ditch

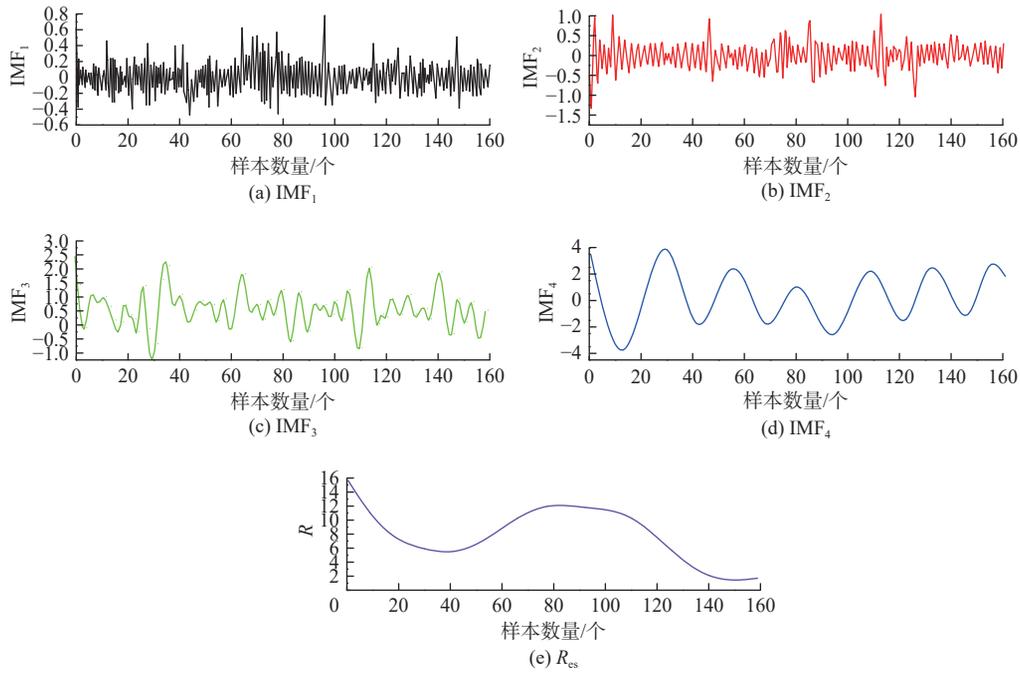


图 6 基于 ESMD 的基坑变形监测数据分解

Fig. 6 Decomposition of foundation ditch deformation monitoring data based on ESMD

表 1 基坑变形监测序列各模态分量方差贡献率

Tab. 1 Variance contribution rate of each modal component in the deformation monitoring data of sluice foundation ditch

模态分量	IMF ₁	IMF ₂	IMF ₃	IMF ₄	R _{es}
周期/d	1.71	3.58	7.22	25.58	
方差贡献率/%	23.36	12.89	19.44	16.73	27.58

2.3 基于 AJSO-LSTM 的水闸深基坑变形预测

基于式 (6), 可以分别计算得到 IMF₁~IMF₄ 和趋势性分量 R_{es} 的模糊熵为 2.78, 1.56, 0.79, 0.27 和 0.097。将上述采用 ESMD 分解得到的各模态分量经过 FE 重构后, 即可输入 AJSO-LSTM 算法进行训练, 采用 AJSO 算法对 LSTM 模型中隐藏层单元数、学习率和迭代次数共 3 组参数进行智能寻优。

待优化 LSTM 隐藏层单元数取值范围为 [2, 500], 学习率取值范围为 [0.000 1, 0.01], 迭代次数取值范

围为 [1, 1 000]; AJSO 算法种群规模^[26-27]取 100~500, 阈值 min avg[e(λ, φ)]取 0.01, 运动系数 ζ 取 0.2, 预测迭代步长为 1。当算法满足阈值要求时终止算法, 对应的超参数为优化后的 LSTM 模型参数。

在获得各重构子序列的 AJSO-LSTM 优化模型后, 对各重构子序列按固定时间步长分别进行动态预测, 并合成各重构子序列的预测结果, 得到基坑变形的预测结果。对 2023 年 4 月 26 日—5 月 15 日基坑变形进行预测, 预测步长取为 1, 相应各组模型预测成果和预测残差见图 7 和图 8。ESMD-FE-AJSO-LSTM 方法预测的水闸深基坑变形能够准确反映水闸基坑开挖实时变形趋势, 与水平变形实测值较为接近。预测成果基本位于 AJSO-LSTM、LSTM、RNN 以及 SVM 算法预测成果之间, 相比其他 4 组模型预测残差更低, 具有较高预测精度。

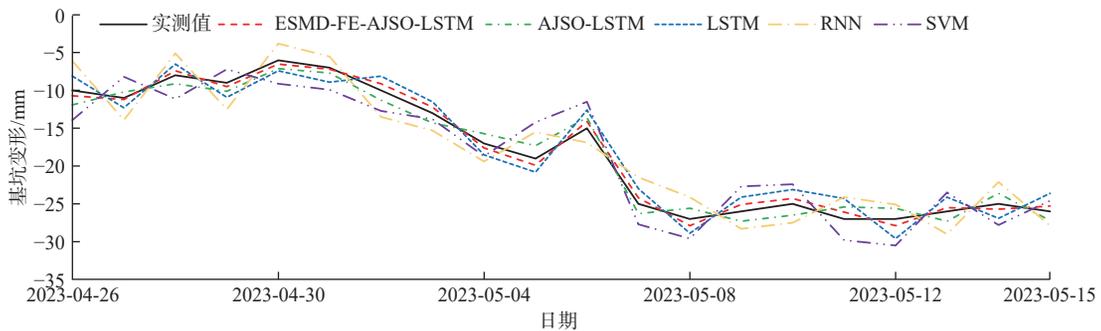


图 7 各模型预测成果对比

Fig. 7 Comparison of prediction results of each model

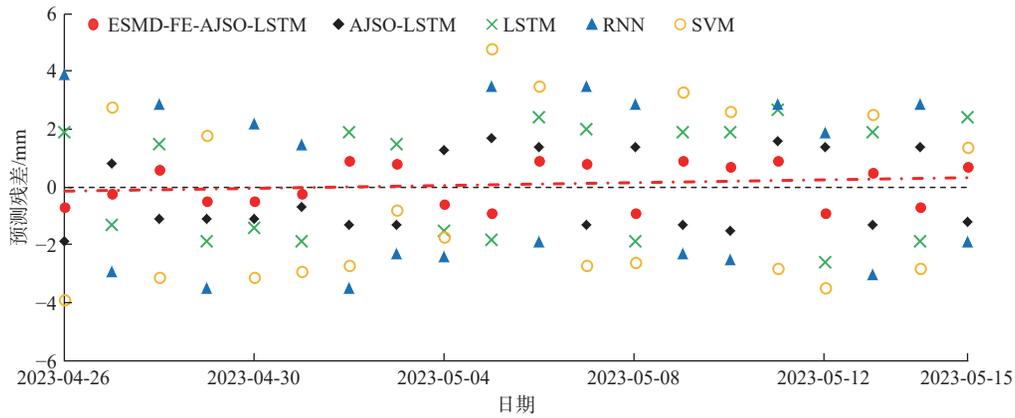


图 8 各模型预测残差

Fig. 8 Predicted residuals of each model

ESMD-FE-AJSO-LSTM 方法与其他 4 组模型预测精度评价指标统计雷达图见图 9。由图 9 可知, 相比其他算法, ESMD-FE-AJSO-LSTM 计算得到的水闸深基坑变形预算值与实测值具有更高的相关系数 R 。除平均绝对百分比误差 E_{MAP} 略差于 AJSO-LSTM 算法外, 均方根误差 E_{RMS} 、平均绝对系数 E_{MA} 以及均方误差 E_{MS} 均优于另外 4 组模型。综上所述, 本文方法可显著提高水闸深基坑开挖变形预测精度和鲁棒性。

ESMD-FE-AJSO-LSTM 方法与其他 4 组模型针对水闸深基坑变形预测残差箱线图见图 10。由图 10 可知, ESMD-FE-AJSO-LSTM 方法预测残差基本在零值均值附近波动, 整体呈正态分布, 表明 ESMD-

FE-AJSO-LSTM 方法相比其他 4 组模型具有更好的预测稳定性。

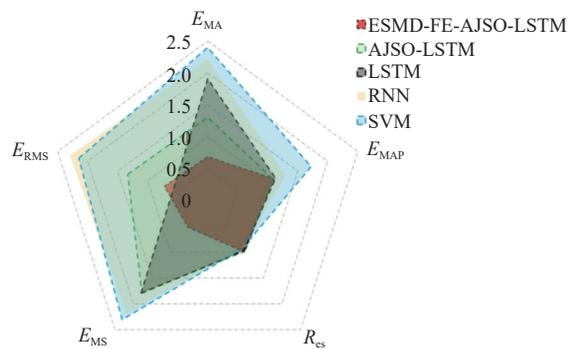


图 9 各模型预测精度评价指标雷达图

Fig. 9 Radar chart of prediction accuracy evaluation indicators for each model

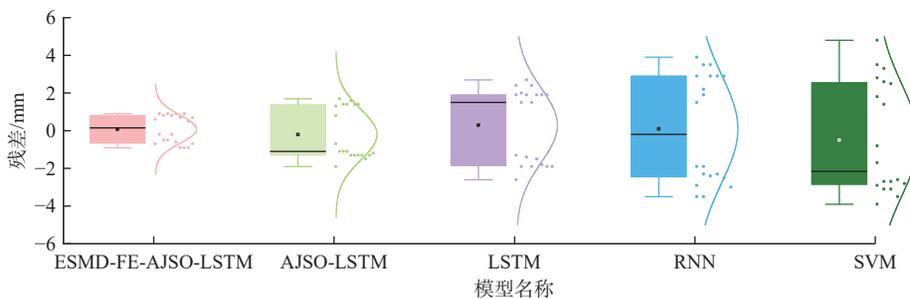


图 10 各模型预测残差箱线图

Fig. 10 Box plots of predicted residuals for each model

3 结论

水闸深基坑开挖变形具有明显的非线性和非稳定性特征。为了实现对水闸基坑开挖变形动态预测和分析, 提出了基于 ESMD-FE-AJSO-LSTM 算法的水闸深基坑变形预测方法。研究结果表明:

由 ESMD 算法分解得到的多维特征尺度分量表现出了明显不同的物理振荡特性。同时各模态方差贡献率计算结果表明, 该水闸深基坑变形短时

波动变化主要以高频模态 IMF_1 和 IMF_2 为主, 而长时波动变化主要以趋势性分量 R_{es} 为主。该分解成果与现场观测成果一致, 表明 ESMD 方法能够有效识别基坑开挖变形不同时间尺度物理特征。

ESMD-FE-AJSO-LSTM 方法对水闸深基坑变形预测精度整体在 97.63%~99.52% 范围内, 预测成果整体优于 AJSO-LSTM、LSTM、RNN 以及 SVM 算法, 具有更高的预测精度。

ESMD-FE-AJSO-LSTM 方法预测残差基本在零值均值附近波动,整体呈正态分布,表明 ESMD-FE-AJSO-LSTM 方法相比其他 4 组模型具有更好的预测稳定性和鲁棒性,科学意义和工程实践应用价值更强。

参考文献:

- [1] 张凯. 基于监测数据分析的深基坑安全评估方法研究[D]. 大连: 大连海事大学, 2022.
- [2] 朱渊. 深基坑安全监测数据分析及数值模拟研究[D]. 武汉: 长江科学院, 2021.
- [3] 仇建春, 房彬, 曹睿哲, 等. 深基坑中新型双排复合支护结构的三维空间有限元分析[J]. *南水北调与水利科技*, 2017, 15(6): 157-164. DOI: 10.13476/j.cnki.nsbdkq.2017.06.023.
- [4] ZHAO J, LI W, PENG Y L. Analysis on intelligent deformation prediction of deep foundation pits with internal support based on optical fiber monitoring and the HSS model [J] *Frontiers in Materials*, 2023(10): 1231303. DOI: 10.3389/fmats.2023.1231303
- [5] 夏曾银, 潘军, 盛鲁腾, 等. 注浆和隔离墙对基坑引发隧道变形的联合控制作用研究[J]. *水利水电技术(中英文)*, 2022, 53(9): 175-185. DOI: 10.13928/j.cnki.wrahe.2022.09.017.
- [6] 孙铁军, 李杰, 张豹, 等. 基于GWO-SVR模型的基坑边坡变形预测及敏感性分析[J]. *公路*, 2022(4): 390-395.
- [7] 赵殿鹏, 刘明维, 潘国华, 等. 基于BP神经网络的船闸基坑变形预测方法[J]. *水道港口*, 2023, 44(1): 95-102. DOI: 10.3969/j.issn.1005-8443.2023.01.013.
- [8] 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(S2): 108-111. DOI: 10.11779/CJGE2021S2026.
- [9] 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(S2): 579-586. DOI: 10.16285/j.rsm.2014.s2.021.
- [10] 崔春雨. 桩-撑支护型式下基于启发式算法的深基坑变形动态预测方法研究[D]. 济南: 山东大学, 2022.
- [11] 王景春, 宋培林, 王炳华, 等. 基于EMD-PSO-ELM的基坑变形时变序列预测研究[J]. *铁道标准设计*, 2020, 64(9): 103-108. DOI: 10.13238/j.issn.1004-2954.201909080002.
- [12] WEI C S, DU Z X, ZHOU M S, et al. Spatiotemporal analysis of groundwater storage variations based on extreme-point symmetric mode decomposition and independent component analysis in Murray-Darling basin, Australia[J]. *Hydrogeology Journal*, 2023, 31(4): 967-983. DOI: 10.1007/s10040-023-02623-8.
- [13] 武少振, 任智慧, 赵雪花, 等. 基于多模型比选耦合的降水预测[J]. *南水北调与水利科技(中英文)*, 2024, 22(1): 1-11. DOI: 13.1430.TV.20231228.0016.002.
- [14] LI G, ZHAO K, YANG H. Feature extraction method for ship-radiated noise based on extreme-point symmetric mode decomposition and dispersion entropy[J]. *Indian Journal of Geo-Marine Sciences*, 2020, 49(2): 175-183.
- [15] LEI G, YIN J, WANG W, WANG H, LIU C. Hydrological frequency analysis in changing environments based on empirical mode decomposition and metropolis-hastings sampling Bayesian models[J]. *Journal of Hydrologic Engineering*, 2023, 28(9): 0402327.
- [16] WANG P, FU H, ZHANG K. A pixel-level entropy-weighted image fusion algorithm based on bidimensional ensemble empirical mode decomposition[J]. *International Journal of Distributed Sensor Networks*, 2018, 14(12): 1550147718818755. DOI: 10.1177/1550147718818755.
- [17] 陆秋贤, 马刚, 涂孟夫. 基于IEWT-FE-BO-LSTM模型的超短期风功率预测[J]. *水电能源科学*, 2023, 41(1): 217-220. DOI: 10.20040/j.cnki.1000-7709.2023.20220494.
- [18] HESAMIAN G, AKBARI M G. Fuzzy cumulative entropy and its estimation based on fuzzy random variables[J]. *International Journal of System Science*, 2021, 53(5): 982-991. DOI: 10.1080/00207721.2021.1983064.
- [19] YU B, ZHAO X, ZHENG M, et al. Entropy on intuitionistic Fuzzy Sets and Hesitant Fuzzy Sets[J]. *Journal of Mathematics*, 2022(2022): 1585079. DOI: 10.1155/2022/1585079.
- [20] 王艺霖, 靳燕国, 陈晓楠, 等. LSTM神经网络和量纲分析法在弧形闸门过流计算中的对比[J]. *南水北调与水利科技(中英文)*, 2022, 20(3): 590-599. DOI: 10.13476/j.cnki.nsbdkq.2022.0060.
- [21] 杨婷婷, 虞佳颖, 肖姚, 等. 基于Embedding-GRU的水库水位预测模型[J]. *南水北调与水利科技(中英文)*, 2023, 21(5): 940-950. DOI: 10.13476/j.cnki.nsbdkq.2023.0100.
- [22] 岳江, 王红霞, 王馨茹, 等. 山西省7条河的流域水生态承载力评估[J]. *南水北调与水利科技(中英文)*, 2023, 21(6): 1235-1248. DOI: 10.13476/j.cnki.nsbdkq.2023.0122.
- [23] CHOU J S, TRUONG D N. Multiobjective optimization inspired by behavior of jellyfish for solving structural design problems[J]. *Chaos Solitons & Fractals*, 2020, 135: 109738. DOI: 10.1016/j.chaos.2020.109738.
- [24] 孙燕成, 陈富安. 基于PSO优化LSTM神经网络的机械臂逆运动学求解研究[J]. *电子测量技术*, 2022, 45(13): 40-45. DOI: 10.19651/j.cnki.emt.2209091.
- [25] WANG X R, LI X Y, LI ST. Point and interval forecasting system for crude oil price based on complete ensemble extreme-point symmetric mode decomposi-

- tion with adaptive noise and intelligent optimization algorithm[J]. *Applied Energy*, 2022(328): 120194. DOI: [10.1016/j.apenergy.2022.120194](https://doi.org/10.1016/j.apenergy.2022.120194).
- [26] 付荣赫,秦泰,张奇,等. 基于改进人工水母搜索算法的电液伺服系统控制研究[J]. *机床与液压*, 2023, 51(13): 34-38. DOI: [10.3969/j.issn.1001-3881.2023.13.006](https://doi.org/10.3969/j.issn.1001-3881.2023.13.006).
- [27] 孙林,蔡怡文. 卷积神经网络与人工水母搜索的特征选择方法[J]. *南京大学学报(自然科学)*, 2023, 59(5): 759-769. DOI: [10.13232/j.cnki.jnju.2023.05.004](https://doi.org/10.13232/j.cnki.jnju.2023.05.004).

Deformation prediction of deep foundation pit of sluice based on ESMD-FE-AJSO-LSTM algorithm

ZHANG Wei^{1,3}, DENG Binbin², QIU Jianchun^{3,4}, XIA Guochun^{1,3}, YAO Zhaoren¹, LIU Zhanwu¹, ZHU Xinyu¹, WANG Yujin¹

(1. Jiangsu Hydraulic Engineering Construction Co., Ltd, Yangzhou 225002, China; 2. Zhangjiagang Yangtze River Flood Control Engineering Management Office, Suzhou 215600, China; 3. College of Hydraulic Science and Engineering, Yangzhou University, Yangzhou 225100, China; 4. State Key Laboratory of Hydrology-Water Resources and Hydraulic Engineering, Hohai University, Nanjing 210098, China)

Abstract: The excavation and deformation of deep foundation pits for sluice gates were influenced by various factors, including engineering and hydrogeological conditions, spatial dimensions of the foundation pit, type of support structure, and excavation stage. Additionally, random environmental factors such as vibrations from construction machinery, loads from surrounding traffic, and weather conditions play a role. The excavation-induced deformation of these foundation pits exhibited significant nonlinearity and instability. The deformation monitoring data acquired from the excavation site of the foundation pit consist of a series of multimodal sequences across various temporal dimensions. Scientifically identifying key data features in different dimensions and subsequently modelling and predicting them in a targeted manner holds significant importance.

The extreme-point symmetric mode decomposition method (ESMD) was employed for the prototype monitoring sequences of deformation during the deep excavation of a sluice foundation pit, involving multimodal decomposition. The deformation monitoring data of the sluice foundation pit were decomposed into several distinct subsequence components, intrinsic mode functions (IMFs), and trend components (R_{es}), each exhibiting unique features. Fuzzy entropy (FE) theory was utilized, and fuzzy multimodal phase space reconstruction was applied to each modal subsequence component and trend component, resulting in multiple reconstructed subsequence components. Physically significant features of sluice foundation pit deformation at various time scales were effectively discerned through this process. Subsequently, a model was constructed based on the artificial jellyfish search optimizer (AJSO)-optimized long short-term memory (LSTM) artificial neural network. The optimization involved training on the reconstructed subsequences, yielding an AJSO-LSTM optimized model for each reconstructed subsequence. Finally, using the optimized AJSO-LSTM models, dynamic predictions were made for each reconstructed subsequence at fixed time intervals. The predicted results for each reconstructed subsequence were synthesized to obtain the overall prediction of foundation pit deformation. To evaluate the prediction accuracy of the ESMD-FE-AJSO-LSTM model for foundation pit deformation, multiple accuracy evaluation metrics were introduced.

Taking the excavation deformation monitoring of the Eleven Weir Riverbank Hub Reconstruction Project in Zhangjiagang city as an example, the methods described above are employed to predict and analyse the excavation-induced deformations in the hub project.

(下转第 408 页)