

基于改进 EMD-LSTM 的混凝土坝变形预测模型

欧斌^{1,2,3}, 张才溢^{1,3}, 陈德辉^{1,3}, 王子轩^{1,3}, 杨石勇^{1,3}, 杨霖^{1,3}, 傅蜀燕^{1,2,3}

(1. 云南农业大学水利学院, 云南 昆明 650201; 2. 河海大学水灾害防御全国重点实验室, 江苏 南京 210098;

3. 云南省中小型水利工程智慧管养工程研究中心, 云南 昆明 650201)

摘要: 针对混凝土坝变形监测数据的非线性和复杂性等特征, 为提高混凝土坝变形预测的精度, 提出了一种基于改进经验模态分解(EMD)法和长短期记忆(LSTM)神经网络的混凝土坝变形预测模型。该模型采用小波阈值方法对 EMD 法分解的高频分量进行优化处理, 在去除数据噪声的同时, 尽可能保留原始数据的特征信息, 并运用 LSTM 神经网络对处理后的数据进行时序预测。实例验证结果表明, 该模型能够准确模拟坝体变形过程, 具有较高的预测精度。

关键词: 大坝变形; 经验模态分解法; 长短期记忆神经网络; 小波阈值; 预测模型

中图分类号: TV698.1⁺1

文献标志码: A

文章编号: 1006-7647(2024)06-0093-07

Deformation prediction model for concrete dams based on improved EMD-LSTM//OU Bin^{1,2,3}, ZHANG Caiyi^{1,3}, CHEN Dehui^{1,3}, WANG Zixuan^{1,3}, YANG Shiyong^{1,3}, YANG Lin^{1,3}, FU Shuyan^{1,2,3} (1. College of Water Conservancy, Yunnan Agricultural University, Kunming 650201, China; 2. The National Key Laboratory of Water Disaster Prevention, Hohai University, Nanjing 210098, China; 3. Yunnan Province Small and Medium-sized Water Conservancy Project Intelligent Management and Maintenance Engineering Research Center, Kunming 650201, China)

Abstract: Considering the characteristics of nonlinearity and complexity of concrete dam deformation monitoring data, in order to improve the accuracy of concrete dam deformation prediction, a concrete dam deformation prediction model based on the improved empirical modal decomposition (EMD) method and the long short-term memory (LSTM) neural network was proposed. This model adopts the wavelet threshold denoising method to optimize the high-frequency components decomposed by the EMD method, effectively removing the data noise while retaining the characteristic information of the original data as much as possible. The LSTM neural network was used to perform time series prediction on the processed data. The results of case validations show that this model can accurately simulate the deformation process of the dam body, demonstrating a high prediction accuracy.

Key words: dam deformation; empirical modal decomposition method; long short-term memory neural network; wavelet threshold; prediction model

混凝土坝的结构安全一直是备受关注的焦点, 布设渗流、变形、应力应变等多类型监测设备是实时掌握其运行性态的有效手段, 其中变形是混凝土坝综合性能最直观可靠的反映。因此, 构建高精度的混凝土坝变形监控模型, 有效评估大坝运行安全, 预测未来运行性态显得尤为重要。为了提高对混凝土坝变形预测的精度和可靠性, 研究者一直在探索各种数据处理方法和预测模型^[1-5]。

传统的混凝土坝变形预测方法主要基于经验公式或统计分析, 这些方法在处理复杂多变的实际数

据时显得能力不足, 预测精度和可靠性难以保证。近年来, 随着信号处理技术和人工智能技术的发展, 越来越多的研究者开始尝试将这些先进技术应用于大坝变形预测中, 以提高预测精度和效率^[6-7]。例如: 牛景太^[8]利用奇异谱分析(singular spectrum analysis, SSA)对大坝变形数据进行分解重构, 在此基础上运用基于粒子群算法优化的支持向量机(support vector machine, SVM)模型进行预测; 王浩然等^[9]利用 SSA 剔除数据噪声信息, 提取大坝变形时间序列的特征分量, 利用改进鲸鱼优化算法优化

基金项目: 国家自然科学基金项目(52069029, 52369026); 水灾害防御全国重点实验室 2023 年度“一带一路”水与可持续发展科技基金项目(2023490411); 云南省农业基础研究联合专项面上项目(202401BD070001-071)

作者简介: 欧斌(1983—), 男, 副教授, 博士, 主要从事水工程结构安全监测与病害诊断研究。E-mail: oubin@ynau.edu.cn

通信作者: 傅蜀燕(1976—), 女, 副教授, 博士, 主要从事水库安全管理与工程力学研究。E-mail: fushuyan66@163.com

的 BP (back propagation) 神经网络挖掘去噪后数据和环境量之间的复杂非线性关系。但 SVM 的预测精度比较依赖于参数选择,而 BP 神经网络容易受到局部极小值干扰,同时收敛速度也较慢,可能导致预测精度较低^[10]。随着深度学习算法在工程领域中的广泛应用,越来越多的学者将其应用于大坝安全监测领域^[11]。其中,长短期记忆(long short-term memory, LSTM)神经网络能够有效捕捉时序数据特征,被广泛应用于时序预测和建模任务中^[12-14]。

与单一方法(如 BP 神经网络、SVM 等)相比,基于分解重构的变形预测模型^[8-9]表现出更优越的性能。相关分解方法被广泛运用于大坝预测模型中,然而就位移序列分解方法而言,小波分析虽然分解彻底,但其自适应能力较弱,且分解尺度的选择较为困难,很难获得最优解^[15];而经验模态分解(empirical mode decomposition, EMD)法具有较强的自适应性和高时频分辨率,但存在模态混叠等问题^[16]。

基于上述方法的不足,为充分提取数据的有效信息,提高大坝变形预测的精度,本文采用 EMD 法提取混凝土坝变形实测数据的本征振动模态,采用小波阈值去除高频噪声,采用 LSTM 神经网络对处理后的数据进行时序预测和建模,以期提高数据处理的准确性和可靠性。

1 研究方法

1.1 EMD 法

EMD 法是一种基于数据自身的时间尺度特征进行分解的方法。它将信号分解成多个固有模态函数(intrinsic mode function, IMF),每个 IMF 具有不同的频率和振幅特征。这些 IMF 代表了信号在不同尺度下的振动特征。对于大坝变形监测数据,结构变化可能受到多种因素影响,导致不同频率和尺度上的变形振动。而 EMD 法可以有效捕捉这些变化的特征,在处理大坝变形监测数据时具有较好的吻合性^[17-18]。

EMD 法分解过程中,循环筛选的停止准则为两次相邻筛选结果的标准差在 0.2~0.3 之间,本文取 0.3 作为停止标准^[19]。

1.2 小波阈值方法

小波阈值方法是利用小波变换将信号分解为多个小波系数,然后对小波系数进行阈值处理以去除噪声^[20-21]。本文对 EMD 法分解的高频 IMF 分量应用小波阈值方法,可以有效去除高频噪声,使振动信号更加纯净和可靠。在实际大坝变形监测中,由于

步骤 1 收集大坝变形的相关数据并将其作为

环境因素和设备故障等原因可能会引入一定程度的噪声,小波阈值方法能够很好地适应这种情况,提高数据处理的准确性和稳定性。

1.3 基于小波阈值方法的改进 EMD 法

改进 EMD 法是将 EMD 法和小波阈值方法有效结合,对信号进行频率分解,并对每个 IMF 进行小波阈值处理,使得去噪更加彻底和准确。改进 EMD 法去噪的具体操作步骤为:

步骤 1 采用 EMD 法将原始监测数据进行分解,得到一系列由高到低的 IMF 分量。

步骤 2 将分解所得的高频 IMF 分量进行小波变换。对于每个高频 IMF 分量,使用选定的小波基函数进行小波变换,得到相应的小波系数。

步骤 3 对小波系数进行阈值处理以去除噪声。本文选取软阈值。

步骤 4 使用小波逆变换操作将经过阈值处理后的小波系数转换回时域,得到去噪后的高频 IMF 分量。

步骤 5 将去噪后的高频 IMF 分量与 EMD 法分解得到的低频 IMF 分量进行重构,得到 EMD 重构信号。

2 模型构建流程

本文基于改进 EMD 法和 LSTM 神经网络构建大坝变形预测模型(以下简称“改进 EMD-LSTM 模型”),用于提高大坝变形监测数据的预测精度。LSTM 神经网络是针对循环神经网络(recurrent neural network, RNN)的梯度消失问题提出的一种特殊形式。相比 RNN 只有一个状态 h , LSTM 神经网络增加了单元状态 C ,并提出了输入门、遗忘门和输出门的概念,以门的形式进行细胞状态的存储和更新,从而实现对短期输入的长期保存^[13]。LSTM 神经网络能够对处理过的数据进行时序预测和建模,帮助更好地理解数据的演变规律和趋势。在大坝变形监测数据中,变形信号往往具有明显的时序特性, LSTM 神经网络的时序建模能够更好地把握这些变化规律,从而提高数据处理的全面性和准确性^[22]。改进 EMD-LSTM 模型首先运用 EMD 法对监测数据进行分解,得到一系列 IMF。接着,对其中的高频分量采用小波阈值进行去噪处理。同时,对于低频分量,再次利用 EMD 法进行深入分析。处理后的 IMF 被重构,形成预处理后的时间序列数据集,用于 LSTM 神经网络模型(以下简称“LSTM 模型”)的训练与预测。

改进 EMD-LSTM 模型构建流程(图 1)如下: 预测模型的输入。这些数据包括时间序列和影响变




图1 改进 EMD-LSTM 模型构建流程

形的各种因素,如上下游水位和气温等。

步骤2 确定模型的输出变量为测点的变形值,输入变量为大坝统计模型中的分量因子。大坝变形是混凝土坝和基岩在荷载作用下的塑性和弹性变形的位移矢量和。坝身任意位置的位移矢量 δ 都可分解为水压分量 δ_H 、温度分量 δ_T 和时效分量 δ_θ 。大坝变形时变预测模型可以表示为

$$\delta = \delta_H + \delta_T + \delta_\theta \quad (1)$$

$$\text{其中} \quad \delta_H = \sum_{i=1}^4 a_i H^i \quad \delta_\theta = c_1 \theta + c_2 \ln \theta$$

$$\delta_T = \sum_{i=1}^{m_3} \left(b_{1i} \sin \frac{2\pi i t}{365} + b_{2i} \cos \frac{2\pi i t}{365} \right)$$

式中: H 为坝前水深; i 为年周期; m_3 为与坝型有关的系数,一般取1或2; t 为累计监测天数; a_i 、 b_{1i} 、 b_{2i} 、 c_1 、 c_2 为统计系数; $\theta = t/100$ 。

步骤3 将原始监测数据通过 EMD 法进行分解,得到5个 IMF 分量,将这些分量按照频率从高到低进行排列。对高频 IMF 进行小波阈值去噪,剔除测量误差等噪声,完成后将高频与低频 IMF 重构为降噪后的数据。

步骤4 选用 LSTM 模型作为基本模型,根据 LSTM 的基本原理,构建变形预测模型,将处理后的数据集划分为训练集和测试集,使用训练集数据进行模型训练,并使用测试集数据验证训练效果。

步骤5 通过评价指标对预测结果进行性能评价。

3 实例验证

云南省某水电站是澜沧江中游河段的大型工程,混凝土双曲拱坝最大坝高 294.5 m,正常蓄水位 1240 m。变形监测设施(正倒垂线)布置如图 2

所示。




图2 大坝垂线监测设施布置(单位:m)

根据混凝土坝的变形监控模型(式(1))可知,对于重力坝而言,变形监控模型中影响因子有9个,分别为 H^1 、 H^2 、 H^3 、 θ 、 $\ln \theta$ 、 $\sin(2\pi t/365)$ 、 $\sin(4\pi t/365)$ 、 $\cos(2\pi t/365)$ 、 $\cos(4\pi t/365)$ 。但对于拱坝而言,其变形还受到 H^4 的影响,共计10个影响因子。

在选定影响因子与效应量之后,为消除量纲与影响因子之间的数量级差异,对影响因子和效应量进行标准化处理,设置各组样本 X 的最大值和最小值为 $X_{\max}$ 、 $X_{\min}$,对其进行离差标准化处理,所得变量为 $X' = 0.15 + 0.7(X - X_{\min}) / (X_{\max} - X_{\min})$ 。

3.1 数据预处理

为验证改进 EMD-LSTM 模型的效果,选择拱冠梁 2013 年 2 月 22 日至 2014 年 11 月 30 日 A22-PL-03 测点和 2013 年 2 月 22 日至 2016 年 1 月 5 日 A22-PL-05 测点的监测数据作为样本。对监测数据采用 EMD 法进行分解,并通过小波阈值方法处理高频 IMF 分量并重构低频分量,避免传统 EMD 法引起的信号失真问题。利用去噪数据和未去噪数据分别应用 LSTM 模型进行预测,并比较不同模型的预测精度。具体参数设置如下:EMD 分解层数为5;收敛标准为标准差小于0.5时停止迭代;小波函数为

Daubechies;小波阈值选择为软阈值,阈值大小为0.1。原始监测数据及 EMD 法分解后的 IMF 如图 3~5 所示。




图 3 测点原始监测数据




图 4 A22-PL-03 测点传统 EMD 法分解的 IMF 分量

由图 3~5 可知,在 IMF2 分量中存在信噪混叠现象,原始信号的噪声基本存在于 IMF2 分量中。因此对 A22-PL-03 和 A22-PL-05 测点 IMF2 分量使用小波阈值方法去噪,使用软阈值去噪并对去噪后的监测信号进行重构,重构后的监测信号如图 6 所示。

将小波阈值方法去噪后的 IMF2 高频分量和 EMD 分解的低频分量结合进行 EMD 重构,重构后的监测信号与其他去噪方法处理后的监测信号对比如图 7 所示,为便于对比分析,选取数据波动性较大的局部区域 A、B、C、D 进行放大处理,如图 8 所示。




图 5 A22-PL-05 测点传统 EMD 法分解的 IMF 分量




图 6 小波阈值方法去噪后的 IMF2 分量

根据图 7 和图 8,小波阈值、EMD 和改进 EMD 3 种去噪方法可以有效去除监测数据中的噪声和误差,使得曲线更加平滑。小波阈值方法虽然对于波峰和波谷的去噪较为彻底,但是部分原始数据特征会损失。EMD 法去噪能够保留更多的原始数据特征,但是在波峰和波谷处可能存在一些噪声和误差。而改进 EMD 法不仅能够保留原始数据的特征,同时更细致地处理了波峰和波谷处的噪声和误差,从而达到更好的去噪效果。因此,改进 EMD 法是最优的,可以提供准确可靠的数据支撑用于后续的数据预处理和变形预测。

3.2 预测结果与分析

本文以 LSTM 模型作为基础,使用 A22-PL-03 和 A22-PL-05 测点的原始监测数据以及分别用小波阈值、EMD、改进 EMD 方法去噪后的监测数据对 LSTM 模型进行训练。采用小波阈值方法和 EMD 法去噪的模型分别称为小波阈值-LSTM 模型和




图7 不同去噪方法处理后的监测信号对比




图8 不同去噪方法处理后的监测信号局部区域对比

EMD-LSTM 模型。各模型的参数设置如下:训练集占数据集的 70%,测试集占 30%,具体为:A22-PL-03 测点 2013 年 2 月 22 日至 2014 年 6 月 7 日为训练集,2014 年 6 月 8 日至 2014 年 11 月 30 日为测试集,A22-PL-05 测点 2013 年 2 月 22 日至 2015 年 3 月 10 日为训练集,2015 年 3 月 11 日至 2016 年 1 月 5 日为测试集;输入层维度为 12;LSTM 层节点设置为 8 层;采用 Adam 梯度下降算法,最大训练次数为 400,初始学习率为 0.01,学习下降系数为 0.1。这样的参数设置可以使 LSTM 模型更好地适应监测数据的特征,从而提高预测精度。通过比较

不同预处理方法得到的模型预测结果,可以进一步验证预处理对 LSTM 模型预测精度的影响。对比分析不同模型对各测点的预测结果和预测精度,从而验证各去噪方法的预处理效果。具体的预测结果及残差如图 9 和图 10 所示。

为方便对预测结果及精度进行分析评价,本文选用平均绝对误差 (MAE)、均方根误差 (RMSE)、拟合优度 (R^2) 3 种常见且最直观的指标对模型进行评价。预测精度评价结果见表 1。

由图 9、图 10 和表 1 可知,4 种模型对于位移变化的预测整体上保持一致。其中,改进 EMD-LSTM




图9 不同模型的预测结果




图 10 不同模型的预测残差箱线图

表 1 预测精度评价指标统计

测点	预测模型	R^2	MAE/mm	RMSE/mm
A22-PL-03	LSTM	0.919	0.039	0.046
	改进 EMD-LSTM	0.958	0.029	0.033
	小波阈值-LSTM	0.918	0.038	0.045
	EMD-LSTM	0.943	0.033	0.038
A22-PL-05	LSTM	0.918	0.074	0.085
	改进 EMD-LSTM	0.969	0.041	0.052
	小波阈值-LSTM	0.928	0.067	0.068
	EMD-LSTM	0.946	0.056	0.079

模型的残差波动范围最小,表明该模型在消除噪声影响、提取大坝变形特征信号方面效果最优。

根据表 1 数据,在 A22-PL-03 测点处,采用改进 EMD-LSTM 模型进行预测其 R^2 值最大,同时 MAE 和 RMSE 值最小。相比未降噪的 LSTM 模型,该模型可以使 R^2 值提高 0.039,并且 MAE 和 RMSE 的值减小 0.01 和 0.013。与其他模型相比,该模型也具有更好的预测性能。在 A22-PL-05 测点处,改进 EMD-LSTM 模型同样展现出最佳的预测精度,表现为最大的 R^2 值和最小的 MAE、RMSE 值。

综合上述分析结果可知,改进 EMD-LSTM 模型表现最优,能够有效提高预测精度并消除噪声对信号提取的影响。

4 结 语

针对混凝土坝变形实测数据对预测模型建模的显著影响,本文提出基于改进 EMD-LSTM 的混凝土坝变形预测模型。该模型通过运用小波阈值去噪方法,对 EMD 法得到的高频分量进行精细优化,旨在有效消除数据中的噪声干扰,同时最大程度地维持原始数据的独特特征。随后,利用 LSTM 神经网络对经过处理的数据进行时间序列预测分析。实例验证结果表明,模型在保留数据原始特征的基础上,深入挖掘大坝变形及其影响因子之间的非线性函数关系,提高了传统 LSTM 模型对大坝变形预测的精度,为大坝变形高精度预测提供了新的可行性方案。

参考文献:

[1] YUAN Dongyang, WEI Bowen, XIE Bin, et al. Modified dam deformation monitoring model considering periodic component contained in residual sequence[J]. Structural Control and Health Monitoring, 2020, 27(12) : e2633.

[2] 张建中,顾冲时,袁冬阳,等. 基于优化 VMD 与 GRU 的混凝土坝变形预测模型[J]. 水利水电科技进展, 2023, 43(5) : 38-44. (ZHANG Jianzhong, GU Chongshi, YUAN Dongyang, et al. Deformation prediction model of concrete dams based on optimized VMD and GRU[J]. Advances in Science and Technology of Water Resources, 2023, 43 (5) : 38-44. (in Chinese))

[3] 刘伟琪,陈波,葛盼猛,等. 基于聚类分区和 MO-LSSVR 的高拱坝变形预测模型[J]. 水利水电科技进展, 2023, 43(2) : 102-108. (LIU Weiqi, CHEN Bo, GE Panmeng, et al. Deformation prediction model of a high arch dam based on clustering and MO-LSSVR[J]. Advances in Science and Technology of Water Resources, 2023, 43 (2) : 102-108. (in Chinese))

[4] 周兰庭,邓思源,柳志坤,等. 基于 SSA-LSTM-GF 的混凝土坝变形预测方法[J]. 河海大学学报(自然科学版), 2023, 51 (2) : 73-80. (ZHOU Lanting, DENG Siyuan, LIU Zhikun, et al. Deformation prediction method of concrete dam based on SSA-LSTM-GF[J]. Journal of Hohai University (Natural Sciences), 2023, 51 (2) : 73-80. (in Chinese))

[5] LI Yanlong, YIN Qiaogang, ZHANG Ye, et al. Deformation prediction model of concrete face rockfill dams based on an improved random forest model[J]. Water Science and Engineering, 2023, 16(4) : 390-398.

[6] 侯回位,郑东健,刘永涛,等. 基于 EEMD-SE-LSTM 的混凝土坝变形监测模型[J]. 水利水电科技进展, 2022, 42 (1) : 61-66. (HOU Huiwei, ZHENG Dongjian, LIU Yongtao, et al. Deformation monitoring model of concrete dams based on EEMD-SE-LSTM[J]. Advances in Science and Technology of Water Resources, 2022, 42(1) : 61-66. (in Chinese))

[7] 杰德尔别克·马迪尼叶提,牛志伟,李培聪,等. 基于 BIM 技术与 B/S 架构的大坝安全可视化监测系统

- [J]. 排灌机械工程学报, 2020, 38(6): 583-588. (JIEDEERBIEKE · Madiniyeti, NIU Zhiwei, LI Peicong, et al. Dam safety visual monitoring system based on BIM technology and B/S architecture[J]. Journal of Drainage and Irrigation Machinery Engineering, 2020, 38(6): 583-588. (in Chinese))
- [8] 牛景太. 基于奇异谱分析与 PSO 优化 SVM 的混凝土坝变形监控模型[J]. 水利水电科技进展, 2020, 40(6): 60-65. (NIU Jingtai. Dam deformation monitoring model based on singular spectrum analysis and SVM optimized by PSO[J]. Advances in Science and Technology of Water Resources, 2020, 40(6): 60-65. (in Chinese))
- [9] 王浩然, 钮新强, 徐利福, 等. 基于奇异谱分析和改进 WOA-BP 的大坝变形预测模型[J]. 水力发电学报, 2023, 42(11): 136-145. (WANG Haoran, NIU Xinqiang, XU Lifu, et al. Dam deformation prediction model based on singular spectrum analysis and improved whale optimization algorithm-optimized BP neural network[J]. Journal of Hydroelectric Engineering, 2023, 42(11): 136-145. (in Chinese))
- [10] 张才溢, 傅蜀燕, 欧斌, 等. 基于 APSO 和 TWSVM 的特高拱坝变形预测模型[J]. 水利水电科技进展, 2023, 43(4): 46-51. (ZHANG Caiyi, FU Shuyan, OU Bin, et al. Deformation prediction model of ultra-high arch dams based on APSO and TWSVM[J]. Advances in Science and Technology of Water Resources, 2023, 43(4): 46-51. (in Chinese))
- [11] 向镇洋, 包腾飞, 白妍丽, 等. 基于混合注意力机制和深度学习的大坝变形预测模型[J]. 水利水电科技进展, 2023, 43(2): 96-101. (XIANG Zhenyang, BAO Tengfei, BAI Yanli, et al. Dam deformation prediction model based on mixed attention mechanism and deep learning[J]. Advances in Science and Technology of Water Resources, 2023, 43(2): 96-101. (in Chinese))
- [12] 石卓, 史东华, 姚成, 等. 基于径流模数的 LSTM 模型在无资料嵌套流域的应用[J]. 河海大学学报(自然科学版), 2024, 52(3): 51-57. (SHI Zhuo, SHI Donghua, YAO Cheng, et al. Application of runoff modulus-based LSTM in ungauged nested watersheds[J]. Journal of Hohai University (Natural Sciences), 2024, 52(3): 51-57. (in Chinese))
- [13] 欧斌, 吴邦彬, 袁杰, 等. 基于 LSTM 的混凝土坝变形预测模型[J]. 水利水电科技进展, 2022, 42(1): 21-26. (OU Bin, WU Bangbin, YUAN Jie, et al. LSTM-based deformation prediction model of concrete dams[J]. Advances in Science and Technology of Water Resources, 2022, 42(1): 21-26. (in Chinese))
- [14] 康俊锋, 胡祚晨, 陈优良. 基于布谷鸟搜索算法优化 LSTM 的大坝变形预测[J]. 排灌机械工程学报, 2022, 40(9): 902-907. (KANG Junfeng, HU Zuochen, CHEN Youliang. Dam deformation prediction based on optimization of LSTM by using cuckoo search algorithm[J]. Journal of Drainage and Irrigation Machinery Engineering, 2022, 40(9): 902-907. (in Chinese))
- [15] 赵二峰, 李章寅, 袁冬阳. 基于双阶段注意力机制的大坝变形深度学习预测模型[J]. 河海大学学报(自然科学版), 2023, 51(6): 44-52. (ZHAO Erfeng, LI Zhangyin, YUAN Dongyang. Deep learning model for deformation prediction of dam based on dual-stage attention mechanism[J]. Journal of Hohai University (Natural Sciences), 2023, 51(6): 44-52. (in Chinese))
- [16] 王进花, 胡佳伟, 曹洁, 等. 基于自适应变分模态分解和集成极限学习机的滚动轴承多故障诊断[J]. 吉林大学学报(工学版), 2022, 52(2): 318-328. (WANG Jinhua, HU Jiawei, CAO Jie, et al. Multi-fault diagnosis of rolling bearing based on adaptive variational modal decomposition and integrated extreme learning machine[J]. Journal of Jilin University (Engineering and Technology Edition), 2022, 52(2): 318-328. (in Chinese))
- [17] ZHANG Caiyi, FU Shuyan, OU Bin, et al. Prediction of dam deformation using SSA-LSTM model based on empirical mode decomposition method and wavelet threshold noise reduction[J]. Water, 2022, 14(21): 3380.
- [18] ZHU Yang, GAO Yijun, WANG Zhenhao, et al. A tailings dam long-term deformation prediction method based on empirical mode decomposition and LSTM model combined with attention mechanism[J]. Water, 2022, 14(8): 1229.
- [19] 徐肖遥, 张鹏飞, 蒋剑. 基于 EMD-PSO-ELM 算法的大坝变形预测研究[J]. 软件导刊, 2020, 19(9): 1-5. (XU Xiaoyao, ZHANG Pengfei, JIANG Jian. Research on dam deformation prediction based on EMD-PSO-ELM algorithm and multi factors[J]. Software Guide, 2020, 19(9): 1-5. (in Chinese))
- [20] WEN Hongyan, YUAN Mingyue, HU Jiyuan, et al. Deformation analysis of dam with the improved wavelet threshold[J]. Applied Mechanics and Materials, 2014, 599-601: 242-247.
- [21] 石佳晨, 岳春芳, 朱明远, 等. 基于 CEEMDAN-改进小波阈值的大坝变形数据处理方法[J]. 水利水电科技进展, 2024, 44(5): 80-86. (SHI Jiachen, YUE Chunfang, ZHU Mingyuan, et al. Dam deformation data processing method based on CEEMDAN and improved wavelet threshold[J]. Advances in Science and Technology of Water Resources, 2024, 44(5): 80-86. (in Chinese))
- [22] XU Yaming, PAN Pai, XING Cheng. Dam settlement prediction based on random error extraction and multi-input LSTM network[J]. Journal of Surveying Engineering, 2022, 148(3): 1-17.

(收稿日期: 2023-10-18 编辑: 俞云利)