

基于 EEMD-AFSA-CNN 的混凝土坝变形预测模型

付思韬^{1,2}, 赖宇杰¹, 顾冲时^{1,2}, 顾昊^{1,2}

(1. 河海大学水利水电学院; 2. 河海大学水灾害防御全国重点实验室)

摘要:为解决混凝土坝原型监测数据存在噪声干扰,用于变形预测的智能算法超参数众多且调优困难等问题,提出了基于集合经验模态分解(EEMD)-人工鱼群算法(AFSA)-卷积神经网络(CNN)的混凝土坝变形预测模型。该模型利用 EEMD 对原始变形数据进行分解获取本征模态函数(IMF),采用小波阈值去噪方法对含噪 IMF 分量进行去噪处理并对各分量进行重构,并基于 AFSA 优化 CNN 模型的超参数,将重构后的数据用参数寻优后的 CNN 模型进行训练,并将训练好的模型用于预测。某特高拱坝实例验证结果表明,与 CNN、极限学习机(ELM)、反向传播(BP)神经网络等模型进行对比,该模型在混凝土坝变形预测中具有更高的精度和更强的稳定性。

关键词:混凝土坝变形预测;集合经验模态分解;人工鱼群算法;卷积神经网络;小波阈值去噪

Concrete dam deformation prediction model based on EEMD-AFSA-CNN//Fu Sitao^{1,2}, Lai Yujie¹, Gu Chongshi^{1,2}, Gu Hao^{1,2}(1. College of Water Conservancy and Hydropower Engineering, Hohai University; 2. The National Key Laboratory of Water Disaster Prevention, Hohai University)

Abstract: In order to solve the issues of noise interference in the prototype monitoring data of concrete dams and the difficulty in optimizing the numerous hyperparameters of intelligent algorithm used for deformation prediction, a concrete dam deformation prediction model is proposed based on the ensemble empirical mode decomposition (EEMD), artificial fish swarm algorithm (AFSA) and convolutional neural network (CNN). This model uses EEMD to decompose the original dam deformation data to obtain the intrinsic mode function (IMF), and utilizes the wavelet threshold denoising method to denoise the noisy IMF components and reconstruct the components. The hyperparameters of the CNN model are optimized using the AFSA, and the reconstructed data is trained with the optimized CNN model. The trained model is subsequently used for prediction. The validation results from a case study of a high arch dam show that, compared with models such as CNN, extreme learning machine (ELM) and back propagation (BP) neural network, the proposed model exhibits higher accuracy and stronger stability in concrete dam deformation prediction.

Key words: concrete dam deformation prediction; ensemble empirical mode decomposition; artificial fish swarm algorithm; convolutional neural network; wavelet threshold denoising

水库大坝对调控水资源时空分布、优化水资源配置、防洪减灾具有重要意义,也是国民经济的重要基础设施^[1-4]。据 2013 年《第一次全国水利普查公报》,全国共有水库 98 002 座(不含港澳台地区)。混凝土坝作为一种常见的坝型,整体性强、强度高、耐久性好,在大型水利工程建设中得到广泛采用,其安全稳定运行意义重大,安全监测在混凝土坝运行服役过程中必不可少。

变形监测是混凝土坝安全监测的关键一环,是混凝土坝结构性态变化的最直观表征^[5-7]。埋在坝体内部的变形监测设备会由于设备故障、读数或

记录错误等原因产生误差,使变形监测数据产生噪声,对混凝土坝的变形预测产生影响。因此,有必要对变形监测数据进行去噪处理。Ghimire 等^[8]和 Xiang 等^[9]分别将机器学习与小波变换、经验模态分解(EMD)相结合,取得了不错的预测效果;欧斌等^[10]将大坝变形数据进行 EMD 分解,并对分解的本征模态函数(IMF)进行小波阈值去噪,对去噪后的数据用长短期记忆(LSTM)网络进行训练和预测,提高了数据处理和预测的准确性及可靠性;刘思敏等^[11]基于 EMD 和径向基函数对大坝变形进行预测,取得了较好的预测精度。但是,小波变换对变形

基金项目:国家自然科学基金项目(52379122);中央高校基本科研业务费专项资金项目(B230201011)

作者简介:付思韬(2001—),男,硕士研究生,主要从事水工结构安全监控研究。E-mail:1416937196@qq.com

通信作者:顾昊(1990—),男,副教授,博士,主要从事水工结构安全监控研究。E-mail:gao@hhu.edu.cn

序列的分解效果严重依赖小波基函数的选择,EMD在分解过程中会出现模态混叠现象和端点效应。为解决上述问题,Wang等^[12]通过在原始信号中加入白噪声后再进行EMD分解,有效地解决了EMD的模态混叠现象;Sun等^[13]在对谷幅收缩变形序列进行集合经验模态分解(EEMD)的基础上,参考小波阈值去噪方法,对分量进行间隔阈值去噪;侯回位等^[14]构建了一种基于EEMD与样本熵重构的LSTM模型,比EMD-LSTM等其他模型获得了更好的预测精度。

去噪后的混凝土坝变形数据可以更好地进行建模和预测。传统的大坝变形预测模型有统计模型、确定模型和混合模型^[15-16]。随着计算机技术的发展,机器学习、神经网络等被广泛用于混凝土坝变形的预测,常见的有极限学习机(ELM)、支持向量机、反向传播(BP)神经网络、循环神经网络、卷积神经网络(CNN)等。这些模型在训练和预测过程中含有众多超参数,参数的设定决定了模型预测效果的好坏。为了降低人为调参对模型预测效果带来的不确定性,许多研究者将优化算法与神经网络相结合对大坝变形进行预测。高睿颖等^[5]将蛸螂优化算法与基于双重注意力机制的门控循环单元(DA-GRU)相结合,比单独使用门控循环单元(GRU)模型的预测效果更好;杨霖等^[17]先用独立主成分分析法去除监测数据中的噪声,再将粒子群优化算法与CNN模型相结合,预测效果较仅用CNN模型有明显提高;Bui等^[18]在对某水电站大坝变形预测时,用冠状病毒优化算法对LSTM模型的隐藏层数目、学习率、正则化系数进行寻优,与支持向量机、随机森林、多层感知机神经网络等单一模型相比,预测效果更好。

本文针对混凝土坝变形监测序列存在的噪声干扰问题,用EEMD方法对变形序列进行分解,在对含噪分量进行小波阈值去噪的基础上将各分量进行重构,对重构后的变形序列用CNN模型进行训练和预测,同时针对预测过程中超参数众多、人工赋值不确定性大等问题,引入人工鱼群算法(artificial fish algorithm,AFSA)对CNN模型超参数进行寻优,从而构建EEMD-AFSA-CNN模型,并与单一的CNN、ELM、BP神经网络模型(以下简称“BP模型”)进行对比,以验证模型的有效性。

1 模型构建

1.1 EEMD联合小波阈值去噪

EEMD是一种自适应的信号处理方法,它是EMD的一种改进方法,能很好地解决EMD在分解过程中的模态混叠问题。EEMD的原理如下:①在

原始信号 $y_0(t)$ 中分别加入 N 次等长度、平均值为0、振幅标准差是固定值的高斯白噪声 $w_i(t)$,得到新信号 $y_i(t)$;②每加入一次噪声后对信号进行EMD分解,得到各阶IMF和残值;③对分解 N 次的对应各阶IMF和残值进行总体平均运算。

混凝土坝变形时间序列作为原始信号经过EEMD分解后得到频率逐渐减小的各IMF分量信号,计算各IMF分量与原始变形的皮尔逊相关系数,对相关性较差的IMF分量进行小波阈值去噪。当相关系数小于0.2时,表明该IMF分量与原始变形序列的相关性较差,噪声含量较多^[3]。

小波阈值去噪主要是针对小波系数进行处理,通过设定阈值来去除信号中的噪声或者提取信号中的有用成分。该方法具有良好的时频分析特性,广泛应用于数据的降噪处理。

对去噪后各IMF分量和残值进行重构得到新的混凝土坝变形序列。为了评价去噪效果,用信噪比和均方根误差(RMSE)作为指标,信噪比越大、RMSE越小,说明去噪效果越好。

1.2 AFSA

AFSA是在动物群体智能行为研究的基础上提出的一种新型优化算法,该算法根据鱼群最密集的水域营养最丰富这一特点来模拟鱼群的觅食行为而实现寻优。算法主要利用鱼的觅食、聚群、追尾和随机这4种基本行为,采用自上而下的寻优模式从构造个体的底层行为开始,通过鱼群中各个体的局部寻优,达到在群体中凸显全局最优值的目的。

AFSA寻优的步骤如下:①初始化设置,包括种群规模、每条人工鱼的初始位置、人工鱼的视野、步长、拥挤度因子和重复次数;②计算初始鱼群各个体的适应度值,取最优人工鱼状态及其值赋予公告牌;③对每个个体进行评价,对其要执行的行为进行选择,包括觅食、聚群、追尾和随机行为;④执行人工鱼的行为,更新位置,生成新鱼群;⑤评价所有个体。若某个体适应度值优于公告牌,则将公告牌更新为该个体;当公告牌上最优解在误差范围内或者达到迭代次数上限时算法结束,否则转步骤③。

1.3 CNN

CNN是一种专门用于处理具有网格结构的深度学习模型,它能够通过层次化的方式自动学习图像特征。在混凝土坝变形预测中,通过运用CNN核心的卷积层、池化层、激活函数、全连接层等,可以很好地学习水压、温度、时效等特征因子与大坝变形之间的复杂关系,从而对变形进行预测。

为了取得理想的训练和预测结果,需要对CNN

模型中的学习率和正则化系数进行寻优。AFSA 以预测结果的准确率为适应度函数,不断搜索和更新鱼的最佳位置,从而得到最佳的模型训练结果。

1.4 大坝变形预测步骤

用 EEMD-AFSA-CNN 模型对大坝变形预测的流程见图 1,具体步骤如下:

步骤 1 数据去噪。获取混凝土坝原始变形数据,用 EEMD 联合小波阈值方法对原始变形数据进行分解和去噪,对去噪后的分量进行重构,得到去噪后的混凝土坝变形数据。

步骤 2 特征因子处理。对水压、温度、时效等影响混凝土坝位移的特征因子进行归一化处理,并将去噪后的变形数据按 8 : 2 的比例划分为训练集和验证集。

步骤 3 模型训练与预测。用 AFSA 对 CNN 模型中的学习率和正则化系数等超参数进行寻优,将寻优结果导入到 CNN 模型中,设定卷积核的数目、大小、步长等参数,对数据进行训练和预测。

步骤 4 模型预测性能评价。用决定系数 (R^2)、RMSE、平均绝对误差 (MAE) 和平均绝对百分误差 (MAPE) 共 4 个指标对模型的预测性能进行评价。

2 工程实例验证

2.1 工程概况

某特高拱坝位于雅砻江干流下游河段,坝顶高程为 1885.0m,坝基最低建基面高程为 1580.0m,最大坝高为 305.0m,共 26 个坝段。布置在坝顶和坝基的正倒垂线组用于监测拱坝的变形情况,各测点布置情况如图 2 所示。选取 PL16-4 和 PL16-5 两个测点进行分析,这两个测点的变形监测时间为 2013 年 12 月 7 日到 2018 年 12 月 31 日,将该区间变形监测数据以 8 : 2 的比例划分训练集和验证集,两测点的实测位移及水位过程线如图 3 所示。

2.2 变形监测数据去噪

对 PL16-4、PL16-5 测点变形监测数据进行 EEMD 分解,结果如图 4 所示,两测点均分解得到 6 个 IMF 分量,其中最后一个为残值(该项为趋势项,幅值均为正值,无法再进行 EMD 分解)。计算 IMF1~IMF6 与原始数据的皮尔逊相关系数,结果如表 1 所示,PL16-4 测点的 IMF1、IMF2 和原始数据的相关系数小于 0.2,PL16-5 测点的 IMF1、IMF1、IMF3

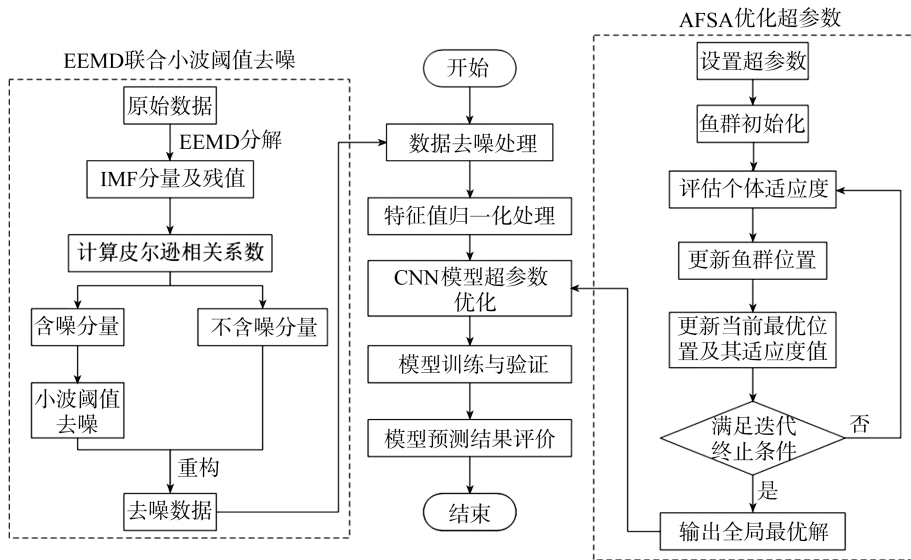


图 1 EEMD-AFSA-CNN 模型预测流程




图 2 拱坝测点布置示意图(单位:m)

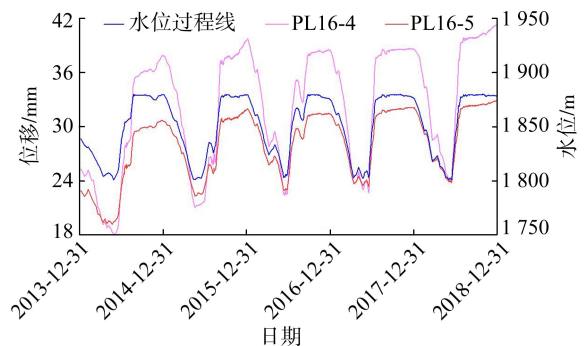




图 3 两测点实测位移及水位过程线



(a) PL16-4测点



(b) PL16-5测点

图4 两测点变形监测数据 EMD 分解结果

和原始数据的相关系数小于 0.2, 分别对这些分量进行小波阈值去噪。

表1 两测点 IMF 分量与原始数据的皮尔逊相关系数

测点	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6
PL16-4	0.0383	-0.0468	0.2172	0.3362	0.3801	0.8358
PL16-5	0.0077	0.0576	0.1636	0.4162	0.2972	0.8840

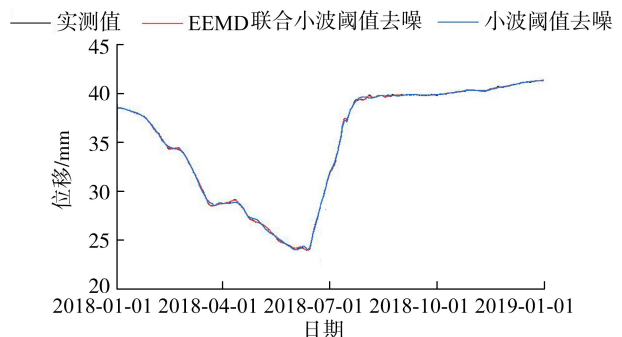
去噪过程中,小波基函数选择 db4,分解层数选择 4,阈值类型选择 sqtwolog,阈值选择软阈值。去噪后,对各 IMF 分量进行重构,得到新的大坝变形序列。将 EEMD 联合小波阈值去噪结果与仅用小波阈值去噪所得结果进行对比,并计算信噪比和 RMSE,结果如表 2 和图 5 所示。从表 2 和图 5 可以看出,两测点 EEMD 联合小波阈值去噪所得的数据更平滑,信噪比更高, RMSE 更小。这说明该方法在去噪的同时能更好地保留原始数据的特征,可以更好地表征大坝变形行为。

表2 两测点变形监测数据去噪评价指标对比


测点	去噪方法	信噪比/dB	RMSE/mm
PL16-4	小波阈值去噪	48.82	0.13
	EEMD 联合小波阈值去噪	60.57	0.03
PL16-5	小波阈值去噪	54.06	0.06
	EEMD 联合小波阈值去噪	58.12	0.04

2.3 数据处理

根据大坝变形统计模型可知,影响大坝变形的环境因子主要是水压、温度、时效。对于拱坝而言,取 10 个影响因子,其中,水压因子有 4 个: $H - H_0$ 、



(a) PL16-4测点



(b) PL16-5测点

图5 两测点变形监测数据去噪效果对比

$H^2 - H_0^2$ 、 $H^3 - H_0^3$ 、 $H^4 - H_0^4$,温度因子用简谐波替代,共有 4 个: $\frac{\sin 2\pi t}{365} - \frac{\sin 2\pi t_0}{365}$ 、 $\frac{\cos 2\pi t}{365} - \frac{\cos 2\pi t_0}{365}$ 、 $\frac{\sin 4\pi t}{365} - \frac{\sin 4\pi t_0}{365}$ 、 $\frac{\cos 4\pi t}{365} - \frac{\cos 4\pi t_0}{365}$,时效因子有 2 个: $\theta - \theta_0$ 、 $\ln \theta - \ln \theta_0$ 。其中 H 、 H_0 分别为监测日和始测日的坝前水深; t 、 t_0 分别为监测日和该监测

时段第1天至始测日的累计天数; θ, θ_0 分别为 t, t_0 除以 100。为了消除各因子之间数量级的差异,对所有因子进行归一化处理。

PL16-4 和 PL16-5 测点分别有 1 320 组和 1 339 组数据,将 PL16-4 测点的前 1 056 组数据作为训练集,后 264 组数据作为验证集;将 PL16-5 测点的前 1 071 组数据作为训练集,后 268 组数据作为验证集,把划分好的去噪后的变形数据与归一化后的特征因子组成数据集导入模型进行训练和预测。

2.4 模型建立与参数寻优

用 EEMD-AFSA-CNN 模型对拱坝变形进行训练和预测,设置人工鱼的数目为 20,人工鱼的最大视力为 0.1,拥挤度因子为 0.6,人工鱼的最大运动步长为 0.001;设置 CNN 模型的训练周期为 50,批大小为 32,卷积核尺寸为 3×3 ,数目为 32,采用最大值池化。初始化鱼群,设置 CNN 模型初始学习率为 0.001,正则化系数为 0,学习率的寻优范围为 $[0.0001, 0.1]$,正则化系数的寻优范围为 $[0, 0.1]$,以训练结果的 MAPE 为适应度函数,在迭代过程中,当 MAPE 最小时,超参数达到最优。经过 AFSA 的不断迭代寻优,CNN 模型的最优学习率和最优正则化系数 PL16-4 测点分别为 0.009 7 和 0.030 5,PL16-5 测点分别为 0.008 2 和 0.034 6。

2.5 模型预测与结果分析

将 EEMD-AFSA-CNN 模型的预测结果与 CNN、ELM、BP 模型的预测结果进行对比,结果如图 6 所示。从图 6 可以看出,EEMD-AFSA-CNN 模型对两

测点的变形拟合效果最好,最接近真实值。4 个模型均能很好地预测大坝变形的趋势,但 EEMD-CNN 模型有过拟合现象,ELM 和 BP 模型会因超参数设定不佳陷入局部最优从而出现每隔一段时间产生突跳点的情况。

从表 3 可以看出,BP 模型对两个测点的变形预测效果明显差于另外 3 个模型,其 R^2 、MAE、RMSE、MAPE 都远高于另外 3 个模型。对于 PL16-4 测点,EEMD-AFSA-CNN 模型预测结果与 EEMD-CNN、ELM 相比, R^2 分别提高了 0.002 7 和 0.015 8,MAE 分别下降了 16.78% 和 32.12%,RMSE 分别下降了 12.53%、41.26%,MAPE 分别下降了 59.69% 和 31.56%。对于 PL16-5 测点,EEMD-AFSA-CNN 模型预测结果与 EEMD-CNN、ELM 相比, R^2 分别提高了 0.033 2 和 0.025 6,MAE 分别降低了 52.96% 和 30.10%,RMSE 分别降低了 51.81% 和 46.91%,MAPE 分别降低了 52.07% 和 36.97%。这进一步说明 EEMD-AFSA-CNN 模型对大坝变形的预测效果优于其他模型,预测精度更高,稳健性和泛化性更强。

表 3 各模型评价指标对比

测点	模型	R^2	MAE/ mm	RMSE/ mm	MAPE/ %
PL16-4	EEMD-AFSA-CNN	0.991 2	0.524 9	0.603 8	1.54
	EEMD-CNN	0.988 5	0.630 7	0.690 3	3.82
	ELM	0.975 4	0.773 3	1.027 9	2.25
	BP	0.940 8	1.442 7	1.564 9	23.01
PL16-5	EEMD-AFSA-CNN	0.990 0	0.310 2	0.341 8	1.04
	EEMD-CNN	0.956 8	0.659 5	0.709 3	2.17
	ELM	0.964 4	0.443 8	0.643 8	1.65
	BP	0.822 2	1.387 7	1.439 0	14.85

3 结 语

本文构建了 EEMD-AFSA-CNN 模型,该模型利用 EEMD 联合小波阈值去噪方法对原始变形数据进行降噪处理,既保留了拱坝原始的变形特征又较好地消除了监测数据中的噪声;采用 AFSA 优化算法对初值和参数设置的要求不高,全局寻优能力强,与 CNN 相结合,通过优化 CNN 模型中的学习率、正则化系数等超参数,避免了人工赋值的不确定性,提高了 CNN 模型的特征提取能力和训练效率。某特高拱坝工程实例验证结果表明,与传统的单一模型 CNN、ELM、BP 等模型相比,EEMD-AFSA-CNN 模型预测精度和适用性明显提升,具有较好的预测效果和适用性。

参考文献:

- [1] 顾冲时,苏怀智,刘何稚. 大坝服役风险分析与管理研究述评 [J]. 水利学报, 2018, 49 (1): 26-35. (Gu Chongshi, Su Huaizhi, Liu Hezhi. Review on service risk analysis of dam engineering [J]. Journal of Hydraulic

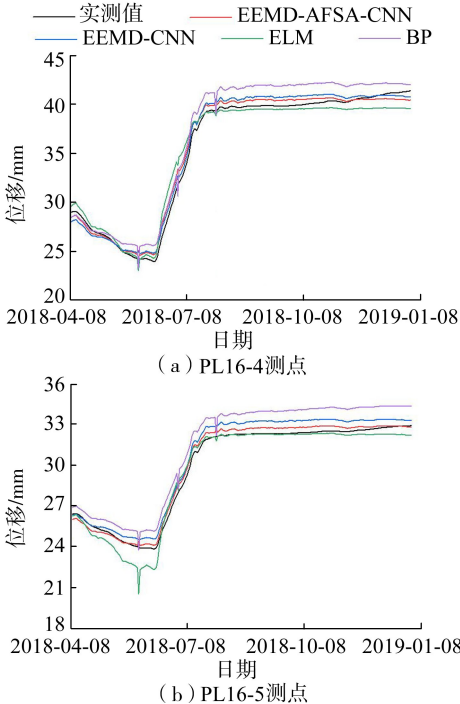


图 6 各模型预测结果对比

- Engineering, 2018, 49(1): 26-35. (in Chinese))
- [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] 宋蕾, 雷兆星. 基于 Inception 模块与改进 GRU 的混凝土坝变形预测模型[J]. 水利水电科技进展, 2024, 44(6): 100-105. (Song Lei, Lei Zhaoxing. Concrete dam deformation prediction model based on Inception module and improved GRU [J]. Advances in Science and Technology of Water Resources, 2024, 44(6): 100-105. (in Chinese))
- [4] 常留红, 朱勇, 曾子彬, 等. 基于 PCA-AVOA-LightGBM 的混凝土坝应力预测模型[J]. 河海大学学报(自然科学版), 2025, 53(5): 127-135. (Chang Liuhong, Zhu Yong, Zeng Zibin, et al. Stress prediction model of concrete dam based on PCA-AVOA-LightGBM [J]. Journal of Hohai University (Natural Sciences), 2025, 53(5): 127-135. (in Chinese))
- [5] 高睿颖, 顾冲时, 王岩博, 等. 基于 DBO-DA-GRU 的大坝变形预测模型[J]. 水电能源科学, 2024, 42(9): 134-138. (Gao Ruiying, Gu Chongshi, Wang Yanbo, et al. Dam deformation prediction model based on DBO-DA-GRU [J]. Water Resources and Power, 2024, 42(9): 134-138. (in Chinese))
- [6] 刘相杰, 刘小生, 张龙威. 基于二次模态分解和深度学习的大坝变形预测模型[J]. 水利水电科技进展, 2024, 44(3): 101-106. (Liu Xiangjie, Liu Xiaosheng, Zhang Longwei. Dam deformation prediction model based on quadratic modal decomposition and deep learning [J]. Advances in Science and Technology of Water Resources, 2024, 44(3): 101-106. (in Chinese))
- [7] 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))
- [8] Ghimire S, Deo R C, Raj N, et al. Wavelet-based 3-phase hybrid SVR model trained with satellite-derived predictors, particle swarm optimization and maximum overlap discrete wavelet transform for solar radiation prediction [J]. Renewable and Sustainable Energy Reviews, 2019, 113: 109247.
- [9] Xiang Yu, Gou Ling, He Lihua, et al. A SVR-ANN combined model based on ensemble EMD for rainfall prediction[J]. Applied Soft Computing, 2018, 73: 874-883.
- [10] 欧斌, 张才溢, 陈德辉, 等. 基于改进 EMD-LSTM 的混凝土坝变形预测模型[J]. 水利水电科技进展, 2024, 44(6): 93-99. (Ou Bin, Zhang Caiyi, Chen Dehui, et al. Deformation prediction model for concrete dams based on improved EMD-LSTM [J]. Advances in Science and Technology of Water Resources, 2024, 44(6): 93-99. (in Chinese))
- [11] 刘思敏, 徐景田, 鞠博晓. 基于 EMD 和 RBF 神经网络的大坝形变预测[J]. 测绘通报, 2019(8): 88-91. (Liu Simin, Xu Jingtian, Ju Boxiao. Dam deformation prediction based on EMD and RBF neural network [J]. Bulletin of Surveying and Mapping, 2019(8): 88-91. (in Chinese))
- [12] Wang Tong, Zhang Mingcai, Yu Qihao, et al. Comparing the applications of EMD and EEMD on time-frequency analysis of seismic signal [J]. Journal of Applied Geophysics, 2012, 83: 29-34.
- [13] Sun Mengcheng, Xu Weiya, Wang Huanling, et al. A novel hybrid intelligent prediction model for valley deformation: a case study in Xiluodu Reservoir Region, China [J]. Computers, Materials & Continua, 2021, 66(1): 1057-1074.
- [14] 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))
- [15] 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))
- [16] 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.
- [17] 杨霖, 傅蜀燕, 吴曹东, 等. 基于 ICA-PSO-CNN 的大坝变形预测研究[J]. 华北水利水电大学学报(自然科学版), 2025, 46(3): 10-16. (Yang Lin, Fu Shuyan, Wu Caodong, et al. Dam deformation prediction based on ICA-PSO-CNN [J]. Journal of North China University of Water Resources and Electric Power (Natural Science Edition), 2025, 46(3): 10-16. (in Chinese))
- [18] Bui K T T, Torres J F, Gutiérrez-Avilés D, et al. Deformation forecasting of a hydropower dam by hybridizing a long short-term memory deep learning network with the coronavirus optimization algorithm [J]. Computer-Aided Civil and Infrastructure Engineering, 2022, 37(11): 1368-1386.

(收稿日期: 2024-12-04 编辑: 熊水斌)