

基于 EEMD-SE-LSTM 的混凝土坝变形监测模型

侯回位, 郑东健, 刘永涛, 黄寒冰

(河海大学水利水电学院, 江苏 南京 210098)

摘要: 为提高混凝土坝变形监测数据的预测精度, 构建了一种基于集成经验模态分解 (EEMD) 与样本熵重构 (SE) 的长短期记忆网络 (LSTM) 预测模型。模型利用 EEMD 对原始数据序列进行分解, 并计算每个分量序列的样本熵, 以原始序列样本熵作为基准进行重构, 再对重构后的各序列建立 LSTM 模型进行预测, 最后把各预测值叠加以得到最终预测结果。以某混凝土拱坝为例, 将该模型预测结果与 EMD-LSTM、LSTM 和 SVM 模型的预测结果进行对比, 结果表明 EEMD-SE-LSTM 模型具有更高的预测精度, 在混凝土坝的变形预测中具备更好的可行性与优越性。

关键词: 集成经验模态分解; 长短期记忆神经网络; 样本熵; 变形预测; 混凝土坝

中图分类号: TV698.1 **文献标志码:** A **文章编号:** 1006-7647(2022)01-0061-06

Deformation monitoring model of concrete dams based on EEMD-SE-LSTM//HOU Huiwei, ZHENG Dongjian, LIU Yongtao, HUANG Hanbing (*College of Water Conservancy and Hydropower Engineering, Hohai University, Nanjing 210098, China*)

Abstract: To improve the prediction accuracy of concrete dam deformation monitoring data, a long and short-term memory network (LSTM) prediction model was constructed based on integrated empirical mode decomposition (EEMD) and sample entropy reconstruction (SE). In this model, EEMD is firstly used to decompose the original data sequence, and the sample entropy of each component sequence is then calculated. The sample entropy of the original sequence is used as the reference for reconstruction, and then the LSTM model is established to predict the reconstructed sequences. Finally, the predicted values are superimposed to obtain the final prediction result. Taking a concrete arch dam as an example, the prediction results of the EEMD-SE-LSTM model were compared with those of EMD-LSTM, LSTM and SVM models. The results show that the EEMD-SE-LSTM model has higher prediction accuracy and better feasibility and superiority in the prediction of concrete dam deformation.

Key words: ensemble empirical mode decomposition; long short-term memory network; sample entropy; deformation prediction; concrete dam

变形是坝体结构受到多种环境荷载的作用以及自身材料性能的影响而不可避免发生的物理偏移, 能够最直接可靠地反映混凝土坝的工作性态, 是衡量坝体结构安全的重要指标^[1-3]。因此, 有必要根据混凝土坝变形监测资料建立精准、高效的预测模型, 及时有效地掌握坝体结构的变形状态, 预测未来的变形趋势, 为工程长期预报和安全决策提供依据^[4]。

常用于混凝土坝变形监控的模型有统计模型、确定性模型和混合模型^[5]等, 其中统计模型^[6]因其函数表达式简单, 模型结构易识别的特点被广泛地应用于混凝土坝安全监控领域中。然而, 传统的统计模型对复杂的非线性关系考虑不足, 对多重共线性问题不敏感^[7], 其预测精度较差且缺乏相应的外

延预报能力。近年来, 随着人工智能算法的迅速发展, 神经网络、支持向量机^[8]等机器学习算法也被运用到混凝土坝的变形预报工作中。贾强强等^[9]利用基于小生境技术改进的思维进化算法来加快 BP 神经网络的最优权值和阈值的搜索, 以避免陷入局部最优; 钱秋培等^[10]将支持向量机和粒子群算法相结合, 建立的预测模型能很好地考虑多种环境因素的非线性相关, 具有不错的预测精度。这些机器学习算法虽然在提升模型预测精度上有所提高, 但由于混凝土坝变形的时间序列非平稳、非线性特点, 也存在着不足, 首先 BP、SVM 模型均属于静态的前馈非循环模型, 对随时间动态变化的混凝土坝变形监测序列预测的能力有所欠缺, 未能考虑时序信息

在时间维度上的关联性,而长短期记忆网络(long short-term memory, LSTM)^[11-13]是一种深度神经网络模型,能够平衡数据的时序性与非线性关系,考虑时序信息重要程度的变化,适合对动态非线性的时间序列进行拟合预测;其次混凝土坝变形序列的非平稳性对于模型的构建及其泛化能力的强弱有着较大影响,上述模型均未把变形序列的非平稳性纳入考虑,而 EEMD 作为一种非平稳数据处理方法^[14],能够根据其本身的特性,将其分解成多个平稳的数据序列。

基于此,本文利用 EEMD 来把非平稳的混凝土坝变形序列分解为多个平稳的子序列,同时考虑到各子序列之间的相关性,采用样本熵理论^[15-17]对各子序列进行重构处理,并选用基于记忆架构的 LSTM 来保证模型的预测能力,构建一种 EEMD-SE-LSTM 组合模型应用于混凝土坝的变形预报中,并以某混凝土拱坝实测数据进行算例分析。

1 基本理论

1.1 集成经验模态分解

经验模态分解(EMD)是一种自适应信号时频处理方法,特别适合非平稳信号的分析处理。EMD 可以将原始信号分解成一系列本征模态分量 IMF,但得到的 IMF 分量通常会出现尺度混合现象,会造成 IMF 分量的不精确,而集成经验模态分解(EEMD)通过往原始信号加入白噪声很好地避开了 EMD 分解时的尺度混合问题^[18],由于零均值噪声的特性,噪声经过多次的平均计算后会相互抵消,这样集成均值的计算结果就可以直接视作最终结果,其基本原理如下。

a. 将 N 个等长白噪声信号 $w_i(t)$ 加入原始信号 $X(t)$,即

$$X_i(t) = X(t) + w_i(t) \quad (1)$$

b. 对新信号 $X_i(t)$ 进行 EMD 分解,得到各阶 IMF 分量:

$$X_i(t) = \sum_{j=1}^m C_{ij}(t) + R_i(t) \quad (2)$$

c. 利用白噪声频谱均值为零的特点,将上述各分量求均值得到最终的分解结果如下:

$$C_j(t) = \frac{1}{N} \sum_{i=1}^N C_{ij}(t) \quad (3)$$

$$R(t) = \frac{1}{N} \sum_{i=1}^N R_i(t) \quad (4)$$

式中: $X_i(t)$ 为第 i 次加入白噪声后的信号; $w_i(t)$ 为第 i 次加入的白噪声; $C_{ij}(t)$ 为第 i 次加入白噪声后分解出的第 j 个 IMF 分量; $R_i(t)$ 为第 i 次加入白噪

声后分解得到的残余分量; m 为每次分解得到的 IMF 分量个数; $C_j(t)$ 为集成平均后的第 j 个 IMF 分量; $R(t)$ 为最终残余分量。

1.2 样本熵

将原始变形序列经 EEMD 分解成若干个 IMF 分量后,为了能减小模型的计算量,考虑各 IMF 分量间的相关性,挖掘出同类序列的特征,引入样本熵的概念,对这些 IMF 分量采用样本熵估值后重构。样本熵作为一种时间序列复杂性的度量方法,其目的是检测时间序列中新的子序列产生概率。现假设一长度为 L 的时间序列 $x = \{x_1, x_2, \dots, x_L\}$,按序号组成一组维数为 m 的向量序列 $\{X_{m,1}, X_{m,2}, \dots, X_{m,L-m+1}\}$,其中 $X_{m,i} = \{x_i, x_{i+1}, \dots, x_{i+m-1}\}$,这些向量表示从第 i 点开始的 m 个连续的 x 的值;定义向量 $X_{m,i}$ 与 $X_{m,j}$ 之间的距离 $d[X_{m,i}, X_{m,j}]$ 为两者对应元素中最大差值的绝对值;对于给定的 $X_{m,i}$,统计 $X_{m,i}$ 与 $X_{m,j}$ 之间距离小于或等于容限 r 的 j ($1 \leq j \leq L-m, j \neq i$) 的数目,并记作 B_i 。对于 $1 \leq i \leq L-m$,定义

$$B_i^m(r) = \frac{1}{L-m-1} B_i \quad (5)$$

$$B^m(r) = \frac{1}{L-m} \sum_{i=1}^{L-m} B_i^m(r) \quad (6)$$

式中: $B^m(r)$ 为两个序列在相似容限 r 下匹配 m 个点的概率; $B_i^m(r)$ 为 B_i 与 $L-m-1$ 的比值。

再把维数增加到 $m+1$,重复上面的步骤得到:

$$A_i^m(r) = \frac{1}{L-m-1} A_i \quad (7)$$

式中 A_i 为向量 X_i 与 X_j 在 $m+1$ 维时满足容限要求的总个数。

同理,定义两序列在匹配 $m+1$ 个点的概率 $A^m(r)$ 的计算式:

$$A^m(r) = \frac{1}{L-m} \sum_{i=1}^{L-m} A_i^m(r) \quad (8)$$

因此,样本熵定义如下:

$$S_E(m, r) = \lim_{L \rightarrow \infty} \left\{ -\ln \left[\frac{A^m(r)}{B^m(r)} \right] \right\} \quad (9)$$

当 L 为有限值时,用下式来估计:

$$S_E(m, r) = -\ln \left[\frac{A^m(r)}{B^m(r)} \right] \quad (10)$$

式中: m 为维数,常取值为 1 或 2; r 表示相似度阈值,通常取原始序列的 10% ~ 25% 的标准差。本文选取的维数是 $m=2$,以原始序列标准差的 20% 作为容限 r 的取值。

1.3 LSTM 模型

对经样本熵重构后的分量建立 LSTM 模型,充分考虑历史有效信息的影响,以提高变形预测的

精度。

LSTM 模型是一种特殊的递归神经网络模型,通过引入“门”的机制,采用记忆单元来代替传统神经网络隐含层的神经单元,用于解决梯度消失或爆炸问题,从而使得网络可以学习长期依赖信息。其记忆单元结构如图 1 所示,核心思想是引入细胞状态的连接,然后使用遗忘门、输入门和输出门等结构来控制细胞状态,实现信息的添加或删除。

遗忘门的作用是控制细胞状态中信息的取舍:

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (11)$$

输入门的作用是更新细胞状态中的信息:

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (12)$$

$$\tilde{C}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (13)$$

输出门控制着哪些信息需要输出:

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (14)$$

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (15)$$

$$h_t = o_t \tanh C_t \quad (16)$$

式中: f_t 、 i_t 、 o_t 分别为遗忘门、输入门与输出门; W_f 、 U_f 为遗忘门的权重系数; W_i 、 U_i 、 W_c 、 U_c 为输入门的权重系数; W_o 、 U_o 为输出门的权重系数; b_f 为遗忘门的偏置系数; b_i 、 b_c 为输入门的偏置系数; b_o 为输出门的偏置系数; C_t 、 h_t 分别为 t 时刻细胞状态和隐藏单元状态, σ 为 sigmoid 激活函数,取值范围为 $[0, 1]$; $\tanh$ 为双曲正切激活函数,取值范围为 $[-1, 1]$ 。

2 EEMD-SE-LSTM 组合预测模型

结合各方法的优势,构建 EEMD-SE-LSTM 混凝土坝变形预测模型,从更加全面的角度来提高混凝土坝的变形预测精度,其流程如下:

步骤 1 利用 EEMD 把混凝土坝的原始变形序列 $X(t)$ 分解为多个平稳的子序列。

$$X(t) = X_1(t) + X_2(t) + \cdots + X_k(t) + R(t) \quad (17)$$

式中 k 为分解出的子序列个数。

步骤 2 计算各子序列、余量 R 以及原始序列 $X(t)$ 的样本熵,当分量样本熵大于原始序列样本熵

时,对其不作处理,当分量小于原始序列样本熵时,对其进行合并,得到重构后的分量。

$$X(t) = C_1(t) + C_2(t) + \cdots + C_p(t) \quad (18)$$

步骤 3 确定各重构分量的时间阶数,即用当前时刻前多少期的历史数据来作为网络模型的输入来进行训练与预测。

步骤 4 时间阶数确定后,对各重构分量分别建立 LSTM 预测模型,设各分量的预测值为 $y_1, y_2, \cdots, y_p$,得到最终的预测值 y 。

$$y = y_1 + y_2 + \cdots + y_p \quad (19)$$

式中 p 为重构后的子序列个数。

选取均方根误差 (RMSE) 和平均绝对误差 (MAE) 作为模型预测效果的评判标准。

3 实例分析

3.1 数据处理

以某混凝土拱坝为例,由于该坝岸坡坝段基础周围的地质条件比较差,有必要对该处测点进行监控以分析对坝体变形的影响,故选取岸坡坝段某正垂测点的坝体变形监测资料作为样本来进行建模分析,分析时段取为 2013 年 5 月 1 日至 2019 年 4 月 30 日。原始数据采样的间距为 1 d,但由于实际观测过程中会存在一些数据的缺失,无法形成连续的逐日序列,现将取样的时间分辨率调整为 5 d。对每个 5 d 的数据取平均值,第一个 5 d 为 2013 年 5 月 1—6 日,依次往下,构成序列。

3.2 EEMD 分解与 SE 重构

针对原始数据的非平稳特性,用 EEMD 对数据进行特征分解,分解时加入白噪声组数为 300 组,噪声误差为 0.2,分解结果如图 2 所示。可以看出,原始序列被分解成了 7 个本征模态分量和 1 个残余分量,各个尺度的特征被很好地从原始序列中分解出来。

计算各分量以及原始序列的样本熵值,依照样本熵值对各分量进行重构,各序列样本熵值得到 $X_1 \sim X_7$ 样本熵值分别为 1.790、0.976、0.566、0.304、0.065、0.035 和 0.031,原始序列样本熵值为 0.268。




图 1 LSTM 记忆单元结构




图2 EEMD分解出的分量

前4个分量的熵值均大于原始序列的熵值,所以不对其进行合并;后4个分量的熵值小于原始序列熵值且复杂度差异也很小,对其进行重构合并,重构后的分量见图3。

3.3 时间阶数的确定

时间阶数的选择会直接影响到模型的预测结果,当其过大时,会增加计算量,过小又会导致信息重合。基于此,利用相关研究成果^[19-23],分析各分量序列的相关性,计算其自相关系数,当相关系数大于0.8时,认为具有较强的关联,再根据具有强相关性时的滞后期数来确定时间阶数。经计算,时间阶数确定为2。




图3 样本熵重构后的分量

3.4 LSTM 模型预测

对每个重构分量建立 LSTM 预测模型,由于时间阶数确定为2,因此以第1、2组的历史变形量作为输入,来预测第3组的变形,然后以第2、3组的变形来预测第4组的变形,依次对后续变形值进行预测。

3.5 预测结果分析

为验证 EEMD-SE-LSTM 模型在混凝土坝变形预测中的有效性和优越性,将其预测效果与 EMD-LSTM、LSTM、SVM 等模型进行对比。

a. 通过改变训练集的长度来分析各模型对时间序列的整体感知力,模型的预测结果见表1。随着训练集长度的增加,EEMD-SE-LSTM 与 LSTM 模型的预测精度越来越高,这说明模型具有良好的时间序列感知力,能够从较长的训练集中提取更多的有效信息以提高预测精度,但 LSTM 模型有滞后效应,导致预测误差都比较大。而 EMD-LSTM 与 SVM 模型的预测精度在训练集长度占比小于80%时都

表1 不同训练长度占比下各模型预测效果

模型	RMSE/mm				MSE/mm			
	60%	70%	80%	90%	60%	70%	80%	90%
EEMD-SE-LSTM	0.06	0.53	0.49	0.43	0.56	0.47	0.43	0.34
EMD-LSTM	0.81	0.63	0.62	0.67	0.69	0.53	0.52	0.64
LSTM	1.06	0.96	0.89	0.83	0.87	0.79	0.75	0.68
SVM	1.31	1.18	1.14	1.30	1.15	1.04	1.03	1.24

有一定程度的提高,但在长度占比达 90% 时,精度却有所下降,说明两模型的时间序列感知力存在局限性。在同一训练集长度下,EEMD-SE-LSTM 模型的预测精度最高,验证了其在混凝土坝变形预测中的优越性。

b. 为更直观体现模型的预测效果,以训练集长度占比为 70% 的情况为例进行分析。从图 4 看出,SVM 模型的预测效果较差,可能是 SVM 模型不能很好地挖掘时序在时间维度上的关联性;LSTM 模型的预测出现滞后现象,虽然拟合曲线贴近实测曲线,但可信度较低;EMD 使得 LSTM 的滞后效应减弱,但其分解时尺度混合的影响降低了模型的预测精度;EEMD 作为 EMD 的改进,降低了尺度混合对分解的影响,提高了模型的预测精度。




图 4 各模型预测结果

图 5 是各模型预测残差对比,可以看出 EEMD-SE-LSTM 模型的预测残差相较于其他模型基本在 ± 0.5 mm 范围波动,这表明 EEMD-SE-LSTM 模型预测的精确性和平稳性都更高。由表 2 可知,EEMD-SE-LSTM 模型的 RMSE 与 MAE 相较于其他模型都有显著地减小,其中 RMSE 分别降低了 15. 87%、44. 79% 与 55. 08%,MAE 分别降低了 11. 32%、40. 51% 与 54. 81%,这表明 EEMD-SE-LSTM 模型很




图 5 各模型预测残差对比

表 2 各模型评价指标

模型	RMSE/mm	MAE/mm
EEMD-SE-LSTM	0.53	0.47
EMD-LSTM	0.63	0.53
LSTM	0.96	0.79
SVM	1.18	1.04

好地提高了变形预测的精度。

4 结 论

a. 通过横向比较,EEMD-SE-LSTM 模型能够更好地拟合混凝土坝变形监测序列,充分考虑变形序列在时间上的关联性,预测精度高,鲁棒性强。

b. 通过纵向比较,EEMD-SE-LSTM 模型有效地减弱了 LSTM 模型的滞后效应,这使得模型的预测具有更高的可信度及可靠性,同时 EMD 分解时的尺度混合问题也得到了解决,明显地提高了预测精度,从而在大坝管理上的应用及可操作性更强。

c. 通过不同训练集长度下模型预测效果的比较,EEMD-SE-LSTM 模型能从更长的训练集中提取更多的有效信息以达到更好的预测效果,具备不错的时序感知能力。

d. 由于变形受多种因素共同作用,单一考虑历史效应量的影响有所欠缺,在后续研究中,还需考虑水位、温度等其他环境量的影响。

参考文献:

[1] ZHAO Erfeng, WU Chengqing. Unified egg ellipse critical threshold estimation for the deformation behavior of ultrahigh arch dams [J]. Engineering Structures, 2020, 214:110598.

[2] 胡德秀,屈旭东,杨杰,等. 基于 M-ELM 的大坝变形安全监控模型[J]. 水利水电科技进展, 2019, 39(3): 75-80. (HU Dexiu, QU Xudong, YANG Jie, et al. A safety monitoring model of dam deformation based on M-ELM [J]. Advances in Science and Technology of Water Resources, 2019, 39(3): 75-80. (in Chinese))

[3] CHEN Bo, HUANG Zishen, BAO Tengfei, et al. Deformation early-warning index for heightened gravity dam during impoundment period[J]. Water Science and Engineering, 2021, 14(1): 54-64.

[4] SU Huaizhi. Wavelet support vector machine-based prediction model of dam deformation [J]. Mechanical Systems and Signal Processing, 2018, 110:412-427.

[5] 吴中如. 水工建筑物安全监控理论及其应用[M]. 北京: 高等教育出版社, 2003.

[6] 李雪红,顾冲时,徐洪钟. 混凝土坝变形的灰色回归时序模型[J]. 河海大学学报(自然科学版), 2002, 30(6): 116-119. (LI Xuehong, GU Chongshi, XU Hongzhong. Grey regression-time series model of concrete dam deformation[J]. Journal of Hohai University (Natural Science Edition), 2002, 30(6): 116-119. (in Chinese))

[7] 田菊飞,苏怀智. 基于随机森林算法的大坝应力预测模型的构建及其应用[J]. 水电能源科学, 2018, 36(5): 54-56. (TIAN Jufei, SU Huaizhi. Construction and application of dam stress prediction model based on

- stochastic forest algorithm[J]. Water and Power Energy Science,2018,36(5):54-56. (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. Deformation monitoring model of concrete dam based on singular spectrum analysis and PSO optimization SVM [J]. Progress in Science and Technology of Water Resources and Hydropower,2020,40(6):60-65. (in Chinese))
- [9] 贾强强,苏怀智,郭芝韵,等. 基于 NMEA-BP 大坝变形监测模型研究[J]. 水利水电技术,2018,49(1):70-74. (JIA Qiangqiang, SU Huaizhi, GUO Zhiyun, et al. Research on dam deformation monitoring model based on NMEA-BP [J]. Water Resources and Hydropower Technology,2018,49(1):70-74. (in Chinese))
- [10] 钱秋培,崔伟杰,包腾飞,等. 基于 SVM 的混凝土坝变形监控模型预测能力实例分析[J]. 长江科学院院报,2018,35(8):46-50. (QIAN Qiupei, CUI Weijie, BAO Tengfei, et al. Case study on prediction ability of concrete dam deformation monitoring model based on SVM [J]. Journal of Yangtze River Scientific Research Institute,2018,35(8):46-50. (in Chinese))
- [11] 胡安玉,包腾飞,杨晨蕾,等. 基于 LSTM-Arima 的大坝变形组合预测模型及其应用[J]. 长江科学院院报,2020,37(10):64-68. (HU Anyu, BAO Tengfei, YANG Chenlei, et al. Combined prediction model of dam deformation based on LSTM-ARIMA and its application [J]. Journal of Yangtze River Scientific Research Institute,2020,37(10):64-68. (in Chinese))
- [12] 岳明哲,陈旭东,李俊杰. 基于 CNN-LSTM 的混凝土坝渗流预测[J]. 水电能源科学,2020,38(9):75-78. (YUE Mingzhe, CHEN Xudong, LI Junjie. Seepage prediction of concrete dam based on CNN-LSTM [J]. Water and Power Energy Science,2020,38(9):75-78. (in Chinese))
- [13] 王亦斌,孙涛,梁雪春,等. 基于 EMD-LSTM 模型的河流水量水位预测[J]. 水利水电科技进展,2020,40(6):40-47. (WANG Yibin, SUN Tao, LIANG Xuechun, et al. River water level prediction based on EMD-LSTM model [J]. Advances in Science and Technology of Water Resources and Hydropower,2020,40(6):40-47. (in Chinese))
- [14] WANG T,ZHANG M,YU Q. Comparing the applications of EMD and EEMD on time-frequency analysis of seismic signal[J]. Journal of Applied Geophysics,2012,83(2):29-34.
- [15] 刘永涛,郑东健,孙雪莲,等. 基于 EEMD-RVM 的土石坝渗流量时间序列预测模型[J]. 水利水电科技进展,2021,41(3):89-94. (LIU Yongtao, ZHENG Dongjian, SUN Xuelian, et al. Time series prediction model of seepage flow of an earth-rock dam based on EEMD-RVM [J]. Advances in Science and Technology of Water Resources,2021,41(3):89-94. (in Chinese))
- [16] 赵辉,华海增,王红君,等. 基于 LCD-SE-IWOA-KELM 的短期风电功率区间预测[J]. 电测与仪表,2020,57(21):77-83. (ZHAO Hui, HUA Haizeng, WANG Hongjun, et al. Short-term wind power interval prediction based on LD-SE-IWOA-KELM [J]. Electrical Measurement & Instrument,2020,57(21):77-83. (in Chinese))
- [17] LIU H, CHEN C, TIAN H, et al. A hybrid model for wind speed prediction using empirical mode decomposition and artificial neural networks [J]. Renewable Energy,2012,48:545-556.
- [18] 李丹丹. 基于集合经验模态分析的滚动轴承故障特征提取[D]. 合肥:安徽农业大学,2013.
- [19] 孙红果,邓华. 样本自相关系数与偏自相关系数的研究[J]. 蚌埠学院学报,2016,5(1):35-39. (SUN Hongguo, DENG Hua. Study on autocorrelation coefficient and partial autocorrelation coefficient of samples [J]. Journal of Bengbu University,2016,5(1):35-39. (in Chinese))
- [20] 顾昊,曹文翰,汪程,等. 混凝土坝服役性能监测效应量安全监控指标拟定方法[J]. 水利水电科技进展,2021,41(1):30-34. (GU Hao, CAO Wenhan, WANG Cheng, et al. Safety monitoring index determination for monitoring effect quantity of concrete dams in service [J]. Advances in Science and Technology of Water Resources,2021,41(1):30-34. (in Chinese))
- [21] 徐韧,苏怀智,杨立夫. 基于 GP XGBoost 的大坝变形预测模型[J]. 水利水电科技进展,2021,41(5):41-46. (XU Ren, SU Huaizhi, YANG Lifu. Dam deformation prediction model based on GP-XGBoost [J]. Advances in Science and Technology of Water Resources,2021,41(5):41-46. (in Chinese))
- [22] 李子阳,李涵曼,李政懿,等. 基于多测点云相似的混凝土坝变形性态关联分析[J]. 水利水电科技进展,2021,41(6):13-17 (LI Ziyang, LI Hanman, LI Zhengxie, et al. Correlation analysis of deformation behavior of concrete dams based on similarity of multi-point cloud [J]. Advances in Science and Technology of Water Resources,2021,41(6):13-17. (in Chinese))
- [23] 周兰庭,柳志坤. 大坝变形实测数据的多重分形特征解析方法[J]. 水利水电科技进展,2021,41(6):18-24. (ZHOU Lanting, LIU Zhikun. Multifractal feature analysis method for measured data of dam deformation [J]. Advances in Science and Technology of Water Resources,2021,41(6):18-24. (in Chinese))

(收稿日期:2020-11-07 编辑:骆超)