DOI: 10.3880/j. issn. 1006 - 7647. 2023. 02. 017

大坝变形监测异常数据识别和重构模型

黎 祎1,2,3,赵二峰1,2,3,何 菁4

(1. 河海大学水文水资源与水利工程科学国家重点实验室, 江苏 南京 210098; 2. 河海大学水利水电学院, 江苏 南京 210098; 3. 河海大学水资源高效利用与工程安全国家工程研究中心, 江苏 南京 210098;

4. 南京市水利建筑工程检测中心有限公司, 江苏 南京 210036)

摘要:针对混凝土坝变形监测数据中的粗差和异常测值问题,提出了一种数据异常识别和重构模型。模型利用关联规则量化变形序列与水位序列的关联性,将监测数据输入 DBSCAN 聚类算法寻找异常点,利用关联结果将监测数据异常点分为粗差点与反映大坝性态点两类,保留反映大坝性态点,剔除粗差点,并利用改进的小波神经网络对粗差数据进行重构,保证监测序列完整性。某拱坝变形监测数据验证结果表明,该模型可以准确识别监测数据中的异常值,并能够获得更为准确的重构数据.为大坝实测性态评价提供了新的分析方法。

关键词:异常数据:数据重构:关联规则:DBSCAN 算法:小波神经网络

中图分类号:TV698.1

文献标志码:A

文章编号:1006-7647(2023)02-0109-06

Abnormal data identification and reconstruction model of dam deformation monitoring/LI Yi^{1,2,3}, ZHAO Erfeng^{1,2,3}, HE Jing⁴ (1. State Key Laboratory of Hydrology-Water Resources and Hydraulic Engineering, Hohai University, Nanjing 210098, China; 2. College of Water Conservancy and Hydropower Engineering, Hohai University, Nanjing 210098, China; 3. National Engineering Research Center of Water Resources Efficient Utilization and Engineering Safety, Hohai University, Nanjing 210098, China; 4. Nanjing Water Conservancy Construction Engineering Testing Center Co., Ltd., Nanjing 210036, China)

Abstract: Aiming at the problem of gross errors and abnormal measurements in the deformation monitoring data of concrete dams, a data anomaly identification and reconstruction model is proposed. The association rules are used to quantify the correlation between deformation sequences and water level sequences, and the monitoring data are input into the DBSCAN clustering algorithm to find the abnormal points. The association results are used to classify the data abnormal points into two categories, coarse error points and points reflecting the dam morphology. The points reflecting the dam morphology are retained and the coarse error points are eliminated, and modified wavelet neural network is used to reconstruct the coarse difference data to ensure the integrity of the monitoring sequence. The application results of an arch dam deformation monitoring data show that the model can accurately identify the abnormal values in the monitoring data and can obtain more accurate reconstructed data, providing a new analysis method for the evaluation of measured properties of a dam.

Key words: abnormal data; data reconstruction; association rules; DBSCAN algorithm; wavelet neural network

大坝运行安全监测过程中,由于结构性态变化、环境量异常、监测系统改造或系统故障等多重不确定性随机因素的作用,难免存在监测数据异常的情况^[1]。由人为误测和系统故障等造成的数据异常称为粗差,粗差的存在会严重"污染"监测数据。传统粗差判别的准则常基于统计学理论,可以采用数学模型^[13],也可以采用机器学习方法,例如:王丽蓉等^[4]利用卷积神经网络进行异常识别,解决辨别非最值异常点的问题;赵新华等^[5]将大坝监测数据进行分解与重构,引入孤立森林进行异常检测;蒋齐嘉

等^[6]提出了一种基于奇异谱分析和密度聚类算法的粗差探测法;黄成章等^[7]考虑时间和截面两个维度,提出一种混凝土坝变形监测缺失数据处理新方法,此类机器学习方法也可以用于大坝位移数据的分析与应用,具有较高的预测精度^[8-10]。尽管如此,这些方法大都着眼于时间序列内的差异,没有考虑大坝与环境量的相互作用,导致反映大坝性态的异常点被判定为误差点,造成误判。

为解决上述问题,本文采用 Apriori 关联规则考虑实测位移与环境量的关联性,通过剖析异常监测

基金项目:国家自然科学基金(U2243223, 51739003, 52079046);中央高校基本科研业务费专项(B210202017)

作者简介: 黎祎(1998—),男,硕士研究生,主要从事水工结构安全监控研究。 E-mail: 1084334829@ qq. com

通信作者:赵二峰(1986—),男,教授,博士,主要从事水工结构安全监控研究。E-mail;zhaoerfeng@ hhu. edu. cn

数据包含的信息,联合效应量和环境量实测序列的关联性准确识别异常值,建立粒子群算法改进小波神经网络的异常数据重构模型,以期提升大坝监测数据分析的有效性。

1 模型构建

1.1 监测数据粗差识别

Apriori 算法具有自动删除非频繁子集来提高效率的优势^[11],可以解析序列间的相互作用;具有噪声的基于密度的聚类方法^[6](density-based spatial clustering of applications with noise, DBSCAN)可以发现任何形状的聚类,可用于搜寻异常点。因此本文将这两种算法综合起来,进行监测数据粗差识别。

Apriori 算法根据阈值逐层搜索频繁项集,利用 Apriori 算法进行监测数据关联性分析时,需要将数据类型调整为布尔类型,即把输入的数据进行符号 化。将输入X、Y两序列用滑动窗口分段截取,对截取的子序列进行线性拟合,得到每段数据的斜率,将斜率标准化,使数值变换在[-1,1]之间,再对其进行符号化表示(子序列分别表示为 x_i 和 y_j)。输入数据长度记为L、滑动时间窗口长度记为S,截得子序列个数记为N(N=L/S)。

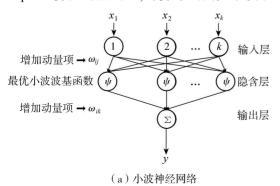
将所有子序列 x_i 与 y_j 作为项目,同一时段截取的子序列组成项目集,所有项目集组成完整事物集。根据确定的最小支持度和最小置信度,筛选出支持度大于最小支持度的频繁项集,置信度大于最小置信度的作为关联规则,记为 $x_i \rightarrow y_i$ 。单条规则的支持度和置信度计算公式如下:

$$\sup(x_i \Rightarrow y_i) = \frac{n(x_i, y_i)}{D} \tag{1}$$

$$con(x_i \Rightarrow y_i) = \frac{n(x_i, y_i)}{n(x_i)}$$
 (2)

式中: $\sup(x_i \Rightarrow y_i)$ 为单条规则的支持度; $\cos(x_i \Rightarrow y_i)$ 为单条规则的置信度; $n(\cdot)$ 为项目出现的次数;D 为项目集个数。

在 Apriori 算法的基础上,计算序列间关联度和



置信度 $^{[12]}$,找出 n 条满足关联规则要求的规则 $x_i \Rightarrow y_i$,序列间支持度和置信度计算公式如下:

$$\sup(X \Rightarrow Y) = \sum_{i=0}^{n} \sup(x_i \Rightarrow y_i)$$
 (3)

$$con(X \Rightarrow Y) = \sum_{i=0}^{n} sup(x_i \Rightarrow y_i) con(x_i \Rightarrow y_i)$$
 (4)

式中: $\sup(X \Rightarrow Y)$ 为序列间支持度; $\cos(X \Rightarrow Y)$ 为序列间置信度。关联度和置信度大于阈值时,认定序列具有强关联性。

将完成关联分析的序列输入 DBSCAN 算法进行异常值识别,强关联序列,将位移序列与环境量同时进行粗差识别;弱关联序列,将位移序列进行粗差识别。以某数据点为圆心, ε 为半径画圆,圆内存在不少于 M 个数据点,将这些数据点与其密度相连点形成一簇,并被标记,没有被标记的点为噪音点。具体过程为:①假设核心对象 q 的 ε 邻域存在点 p,则 p 到 q 直接密度可达;②假设存在一个数据链 p_1 、 p_2 、…、 p_n , p_1 =q, p_n =p,点 p_{i+1} 到点 p_i 直接密度可达,则称点 p 到点 q 密度可达;③假设数据集中一点 w,如果点 p_1 和点 q_1 到点 w 都为密度可达,则称点 p 与点 q 密度相连。依次标记,将数据点分为正常点和噪音点,如图 1 所示。两点之间的距离用欧氏距离来表示。

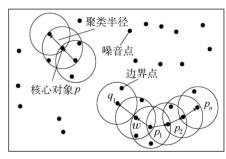


图 1 DBSCAN 算法示意图

1.2 改进的小波神经网络

小波神经网络由输入层、输出层和隐含层 3 部分组成,采用小波基函数作为 BP 神经网络的激励函数,具有较强的逼近和容错能力^[13],如图 2 所示, x_1, x_2, \dots, x_k 为小波神经网络的输入参数,k 为影响

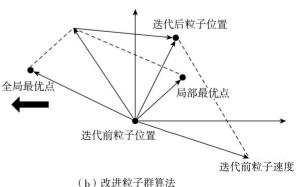


图 2 采用粒子群改进的小波神经网络结构

因子的个数,*y* 为小波神经网络的输出参数,为大坝效应量。

隐含层节点输出计算公式:

$$h_j = h \left(\frac{\sum_{i=1}^k \omega_{ij} x_i - b_j}{a_j} \right)$$
 $(j = 1, 2, \dots, K)$ (5)

式中: h_j 为隐含层第j 个节点输出值; ω_{ij} 为输入层和隐含层的连接权重; $h(\cdot)$ 为小波基函数; b_j 为小波基函数 h_j 的平移因子; a_j 为小波基函数 h_j 的伸缩因子;k 为粒子数;K 为隐含层节点数。

输出层计算公式:

$$y_k = \sum_{j=1}^K \omega_{jk} h_j \tag{6}$$

式中 ω_* 为隐含层到输出层的连接权重。

由于小波神经网络对隐含层个数十分敏感,本文采用粒子群算法^[14]寻找最优隐含层个数。粒子群算法是一种全局搜索算法,通过寻找局部最优值和全局最优值来更新各粒子的位置和速度,最终获得最优点。粒子群算法粒子位置和速度更新公式如下:

$$v_{i,m+1} = \omega v_{i,m} + c_1 r_1 (p_i - x_{i,m}) + c_2 r_2 (g - x_{i,m})$$
 (7)
$$x_{i,m+1} = x_{i,m} + v_{i,m+1}$$
 (8)

式中: ω 为惯性权重; c_1 、 c_2 为加速常数; r_1 、 r_2 为[0, 1]的随机数;v 为粒子速度;x 为粒子位置; p_i 为第 i 个粒子最佳位置;g 为全局最佳位置;m 为迭代次数。

为解决粒子群容易陷入局部最优的缺陷,本文 提出将惯性权重用非线性权重函数代替,并应用粒 子位置更新公式,这样可以有效提高全局搜索范围, 避免陷入局部最优。同时,引入全局最优和局部最 优的线性组合,解决标准粒子群算法搜索范围小的 问题。改进后的粒子群更新公式如下:

$$v_{i,m+1} = \omega(m)v_{i,m} + c_1 r_1 \left(\frac{p_i + g}{2} - x_{i,m}\right) + c_2 r_2 \left(\frac{p_i - g}{2} - x_{i,m}\right)$$
(9)

 $x_{i,m+1} = \omega(m)x_{i,m} + \begin{bmatrix} 1 - \omega(m) \end{bmatrix} v_{i,m+1} \quad (10)$ 式中 $\omega(m)$ 为关于迭代次数递减的权重函数,且 $\omega(m) \in [0,1]$,计算公式为

$$\omega(m) = \omega_1 - \frac{(\omega_1 - \omega_2)m}{M}$$
 (11)

式中: ω_1 为最大权重; ω_2 为最小权重;M 为最大迭代次数。

将小波神经网络训练的均方根误差作为粒子群 算法的适应度函数,将隐含层个数作为粒子所处位 置,寻找最优隐含层个数使得训练误差最小。

为避免梯度学习方法使得算法进化缓慢,采用增加动量项[15]提高网络学习效率。根据预测误差 e修正小波神经网络权重 ω_{ij} 和小波基函数系数 a_{j} 、 b_{j} ,加入增加动量项的公式如下:

$$\omega_{ij,m+1} = \omega_{ij,m} + \Delta \omega_{ij,m+1} + l(\omega_{ij,m} - \omega_{ij,m-1})$$
 (12)

$$a_{j,m+1} = a_{j,m} + \Delta a_{j,m+1} + l(a_{j,m} - a_{j,m-1})$$
 (13)

$$b_{j,m+1} = b_{j,m} + \Delta b_{j,m+1} + l(b_{j,m} - b_{j,m-1})$$
(14)

其中 $\Delta \omega_{ij,m+1} = - \eta \frac{\partial e}{\partial \omega_{ii,m}}$

 $\Delta a_{j,m+1} = -\eta \frac{\partial e}{\partial a_{j,m}}$ $\Delta b_{j,m+1} = -\eta \frac{\partial e}{\partial b_{j,m}}$ 式中: $\Delta \omega_{ij,m+1}$ 、 $\Delta a_{j,m+1}$ 、 $\Delta b_{j,m+1}$ 为根据网络预测误差 e

式中: $\Delta \omega_{ij,m+1}$ 、 $\Delta a_{j,m+1}$ 、 $\Delta b_{j,m+1}$ 为根据网络预测误差 e 计算得到的增加动量项; η 为学习速率;l 为输出参数个数。

1.3 异常监测数据识别和重构流程

异常监测数据识别和重构流程(图3)如下:

步骤 1 对位移实测序列 X 和水位实测序列 Y

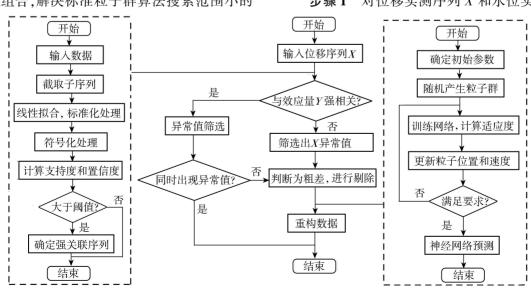


图 3 异常监测数据识别和重构流程

进行预处理,运用 Apriori 算法分析两者之间的关联 程度。

步骤2 对于与环境变量弱关联的监测数据, 运用 DBSCAN 算法对位移序列筛选出异常点. 判定 为粗差,进入步骤4进行数据重构。

步骤3 对于与环境变量强关联监测数据,将 位移序列和环境量输入 DBSCAN 算法, 若这两组序 列同时出现异常点,不予剔除;若只有位移实测序列 出现异常点,予以剔除,进入步骤4进行重构。

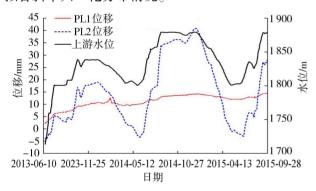
步骤4 将判定为粗差的实测数据剔除,运用 改进的小波神经网络算法对该数据点进行重构,补 齐被剔除的数据,保证监测序列的完整性。

模型验证

某混凝土拱坝位于雅砻江下游河段,选取该拱 坝 PL1、PL2、PL3 3 个测点, 检验本文提出的异常数 据识别与重构模型的有效性。

2.1 关联性分析

选取 PL1、PL2 两测点 2013 年 6 月 16 日至 2015年9月28日每天采集的数据。数据长度 L=830,设置滑动时间窗口长度 S=10,截得子序列 个数 N=83。图 4 和图 5 分别为原始数据和子序列 拟合斜率归一化分布情况。



上游水位与 PL1、PL2 测点原始数据

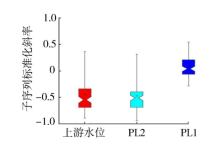


图 5 上游水位与 PL1、PL2 子序列斜率分布

由图 5 可判断上游水位和 PL2 子序列斜率分布 类似,上四分位数、下四分位数和中位数相接近,中 位数分布在-0.5 左右,PL1 与两者相差较大,中位 数分布在0左右。根据上述原理,对上游水位序列 与两测点序列进行关联性分析,设定子序列最小支 持度和最小置信度分别为 0.3 和 0.5.得到子序列 的频繁项集以及关联规则的置信度,见表1。

表 1 上游水位与 PI 2 测点子序列频繁 项集支持度与置信度

频繁项集	支持度	置信度
$x_1 \Rightarrow y_1$	0. 31	0. 96
$x_2 \Rightarrow y_2$	0. 41	0. 83

取序列支持度和置信度的阈值分别为 0.5 和 0.5。计算得水位与 PL2 测点序列间支持度为 0.71,置信度为0.895,则满足阈值要求,认为上游 水位与 PL2 测值具有强关联性。上游水位与 PL1 测点没有发现频繁项集,则为弱关联序列。

考虑温度与位移序列的关联性。坝体温度已达 到准稳定温度场,利用谐波因子代替实测温度序列, 分别考虑正弦谐波 $\sin \frac{2\pi t}{365}$ 和余弦谐波 $\cos \frac{2\pi t}{365}$ 与位 移序列的关联程度,其中 t 为监测日至始测日的累 计天数。结果显示未发现频繁项集,谐波序列与位 移序列为弱关联序列。

2.2 弱关联监测数据重构

选取 PL1 测点 2013 年 6 月 16 日至 2015 年 9 月28日的监测数据,共835个数据,上文已经确定 为弱关联序列。为了验证聚类算法对检测异常数据 的有效性,人为在100~105个数据中加入高斯白噪 声,以及在第400和第500个数据处加入异常。

将加入噪声的数据运用 DBSCAN 算法进行聚 类分析,得出的异常点判定为粗差进行重构。聚类 分析结果如图 6 所示,可以看出人为插入的异常点 都被标识出来了。

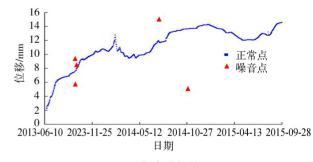


图 6 聚类分析结果

由聚类分析结果得到数据异常点,根据数据清 洗规则,剔除粗差点,并运用改进的小波神经网络进 行重构数据。采用均方根误差 RMSE 和总误差判断 网络训练效果。

采用影响因子集作为神经网络的输入层,以相 应位移值作为输出层,训练神经网络。选择 Morlet 小波、Mexico 小波、Gaussian 小波和 GGW 小波 4 种 不同的小波基函数进行预测,对比各自精度选择最 佳激励函数。比较 4 种小波基函数的训练 RMSE 如 图 7(a) 所示, GGW 小波的训练误差比其他小波都要小,则选择 GGW 小波进行下一步预测。设定粒子群个数 30,迭代 20 次,得到最优隐含层个数为 15 个。为了验证改进小波神经网络的优越性,将改进小波神经网络、传统小波神经网络以及传统 BP 神经网络^[16]进行对比,3 种神经网络训练误差的RMSE 见图 7(b),训练 100 步内改进小波神经网络 具有更高的精度,超过 100 步 3 种神经网络的精度大致相同。预测结果及误差如表 2 所示,可以得出改进小波神经网络的预测总体误差达到 1.14%,小于其他两种神经网络的误差,具有更低的预测误差。

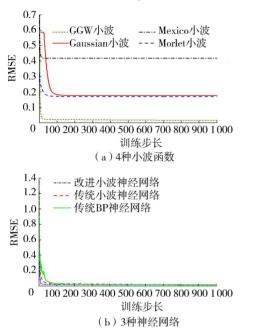


图 7 小波函数和神经网络训练的 RMSE

表 2 3 种神经网络预测结果与误差

神经网络	数据点	实际值	预测值	点误差/%	总体预测 误差/%	隐含层 节点
传统 BP 神经网络	100	7.48	7.42	6.8		
	102	7.56	7.47	8.7		
	104	7.61	7.49	11.9	7.48	15
	400	11.92	11.86	6.0		
	500	13.66	13.62	4.0		
传统小波神经网络	100	7.48	7.44	4.4		
	102	7.56	7.51	5.0		
	104	7.61	7.69	7.9	5.24	20
	400	11.92	11.85	6.3		
	500	13.66	13.63	2.6		
改进小波神经网络	100	7.48	7.48	0.2		
	102	7.56	7.58	2.1		
	104	7.61	7.61	0.4	1.14	24
	400	11.92	11.94	2.0		
	500	13.66	13.67	1.0		

经过数据重构得到新序列如图 8 所示,可见经过数据重构得到的序列更加平滑。

2.3 强关联监测数据重构

将上游水位与 PL3 测点(图9)进行关联性分

水利水电科技进展,2023,43(2) Tel:025-83786335



图 8 数据重构前后的序列

析,得到频繁项集为 $x_2 \Rightarrow y_2$,置信度为 0.878,则两序列为强关联序列。将序列输入 DBSCAN 算法进行异常值检测,检测在 2014 年 2 月 14 日、2014 年 7 月 24 日和 2015 年 8 月 10 日出现异常点,对比上游水位的原始数据,将这些异常数据进行分类,再将归为粗差的数据进行剔除重构。

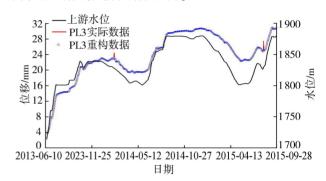


图 9 强关联序列重构结果

观察到上游水位在2014年7月16日存在突出失点,考虑环境变量作用于结构的滞后性,可以判定2014年7月24日的为反映大坝性态点,不予剔除。对比上游水位原始数据,在另外两个异常点出现时刻未出现数据异常,则认为此两异常点为粗差,予以剔除。将数据输入改进小波神经网络,输出预测值重构监测数据。2014年2月14日和2015年8月10日两个数据点重构数据分别为23.19 mm 和24.79 mm,其实际数据为24.45 mm 和26.41 mm,重构后序列如图9所示。结果显示所建模型可以将异常数据分为粗差与反映大坝性态点,准确剔除粗差,保留有用点。

3 结 语

本文建立了大坝变形监测异常数据识别和重构模型,通过 Apriori 算法解析了位移与环境量的关联性,并通过改进粒子群算法优化小波神经网络,消除了原始数据粗差的影响。某拱坝实测数据验证结果表明,在关联性分析的基础上,可以准确找出粗差点位置,同时提出的重构模型可以得到更为合适的重构点,为大坝变形监测数据异常识别与重构提供了

新的方法。

参考文献:

- [1] 丛培江. 大坝监测数据异常值的概率识别法[J]. 水电能源科学, 2005(4): 32 34. (CONG Peijiang. Probabilistic method to identify abnormal values of dam monitoring data[J]. Hydroelectric Energy, 2005(4): 32-34. (in Chinese))
- [2] 花胜强,李永红,高磊,等. 基于离差和改进的大坝变形监测粗差判别方法[J]. 水电能源科学,2020,38(6): 67-69. (HUA Shengqiang,LI Yonghong,GAO Lei,et al. A gross error discriminant method based on difference squares in dam displacement monitoring [J]. Water Resources and Power,2020,38(6):67-69. (in Chinese))
- [3] 赵泽鹏,陈建康,张瀚,等. 基于稳健估计的大坝监测数据粗差识别方法[J]. 水电能源科学,2018,36(12):68-71. (ZHAO Zepeng, CHEN Jiankang, ZHANG Han, et al. The method for gross error identification of dam monitoring data based on robust estimation[J]. Water Resources and Power,2018,36(12):68-71. (in Chinese))
- [4] 王丽蓉,郑东健. 基于卷积神经网络的大坝安全监测数据异常识别[J]. 长江科学院院报,2021,38(1):72-77. (WANG Lirong, ZHENG Dongjian. Anomaly identification of dam safety monitoring data based on convolutional neural network [J]. Journal of Yangtze River Scientific Research Institute,2021,38(1):72-77. (in Chinese))
- [5] 赵新华,范振东,何宇,等. 基于数据重构与孤立森林法的大坝自动化监测数据异常检测方法[J]. 中国农村水利水电,2021(9):174-178. (ZHAO Xinhua, FAN Zhendong, HE Yu, et al. An anomaly detection method for dam automatic monitoring data based on data reconstruction and isolated forest[J]. China Rural Water and Hydropower,2021(9):174-178. (in Chinese))
- [6] 蒋齐嘉,蒋中明,唐栋,等.基于 SSA-DBSCAN 的边坡安全监测数据粗差探测方法研究[J].长江科学院院报,2022,39(4):85-90. (JIANG Qijia, JIANG Zhongming, TANG Dong, et al. The gross error detection of slope safety monitoring data based on SSA-DBSCAN[J]. Journal of Yangtze River Scientific Research Institute,2022,39(4):85-90. (in Chinese))
- [7] 黄成章,顾冲时,何菁. 混凝土坝变形监测缺失数据处理新方法[J]. 水利水电科技进展,2022,42(2):89-94. (HUANG Chengzhang, GU Chongshi, HE Jing. A novel method for processing missing data of concrete dam deformation[J]. Advances in Science and Technology of Water Resources,2022,42(2):89-94. (in Chinese))
- [8] 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. LSTM-based deformation prediction model of concrete dams [J].
 Advances in Science and Technology of Water Resources,

- 2021,41(5):41-46. (in Chinese))
- [9] 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))
- [10] 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))
- [11] 李俊,苏怀智,周仁练. 基于关联规则的土石坝渗流推理预测方法及应用[J]. 水利水电科技进展,2019,39 (5):89-94. (LI Jun, SU Huaizhi, ZHOU Renlian. Seepage prediction method based on association rules and its application to earth-rock dams[J]. Advances in Science and Technology of Water Resources,2019,39(5):89-94. (in Chinese))
- [12] 徐搏超. 基于参数关联性的电站参数异常点清洗方法 [J]. 电力系统自动化, 2020, 44(20): 142-147. (XU Bochao. Parameter correlation based parameter abnormal point cleaning method for power station[J]. Automation of Electric Power Systems, 2020, 44(20): 142-147. (in Chinese))
- [13] 钱建国,樊意广. 基于改进小波神经网络的 GPS 高程拟合研究[J]. 大地测量与地球动力学,2022,42(3):253-257. (QIAN Jianguo, FAN Yiguang. Research on GPS height fitting based on improved wavelet neural network [J]. Journal of Geodesy and Geodynamics,2022,42(3):253-257. (in Chinese))
- [14] 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))
- [15] GRAF R, ZHU Senlin, SIVAKUMAR B. Forecasting river water temperature time series using a wavelet-neural network hybrid modelling approach [J]. Journal of Hydrology, 2019, 578;124115.
- [16] 田正宏,苏伟豪,郑祥,等. 基于 GA-BP 神经网络的碾压混凝土压实度实时评价方法[J]. 水利水电科技进展,2019,39(3):81-86. (TIAN Zhenghong, SU Weihao, ZHENG Xiang, et al. Real-time evaluation method of compaction degree for roller-compacted concrete based on GA-BP neural network [J]. Advances in Science and Technology of Water Resources,2019,39(3):81-86. (in Chinese))

(收稿日期:2022-04-03 编辑:俞云利)