

基于时空聚类 and 深度学习的混凝土坝变形异常值识别方法

宋锦焄^{1,2}, 葛佳豪^{1,2}, 杨杰^{1,2}, 徐笑颜^{1,2}, 陈家敏^{1,2}, 孟庆耀^{1,2}

(1. 西安理工大学水利水电学院, 陕西 西安 710048;

2. 西安理工大学省部共建西北旱区生态水利国家重点实验室, 陕西 西安 710048)

摘要:针对传统大坝异常值识别方法多依靠单测点模型, 未充分考虑测点间变形的时空关联特性, 易造成异常值误诊断的问题, 提出了基于时空聚类 and 深度学习的混凝土坝变形异常值识别方法。该方法利用测点间变形的时空关联特性对混凝土坝测点变形数据进行时空聚类分区, 基于新型蜜獾优化算法(HBA)与双向长短时记忆(BiLSTM)神经网络构建HBA-BiLSTM变形预测模型, 根据模型输出的变形值以及异常值判别指标识别混凝土坝变形异常值。实例验证结果表明, 该方法比传统异常值识别方法准确率更高。

关键词:混凝土坝; 变形; 异常值识别; 监控模型; 时空聚类

中图分类号: TV698.1⁺1

文献标志码: A

文章编号: 1006-7647(2024)04-0065-07

A method for identifying deformation outliers in concrete dams based on spatio-temporal clustering and deep learning/SONG Jintao^{1,2}, GE Jiahao^{1,2}, YANG Jie^{1,2}, XU Xiaoyan^{1,2}, CHEN Jiamin^{1,2}, MENG Qingyao^{1,2} (1. Institute of Water Resources and Hydro-electric Engineering, Xi'an University of Technology, Xi'an 710048, China; 2. State Key Laboratory of Eco-hydraulics in Northwest Arid Region, Xi'an University of Technology, Xi'an 710048, China)

Abstract: In order to solve the problem that traditional dam outlier identification methods mostly rely on single measuring point models and fail to fully consider the spatio-temporal correlation characteristics of deformation between measuring points, which easily leads to misdiagnosis of outliers, a method for identifying concrete dam deformation outliers based on spatio-temporal clustering and deep learning is proposed. This method utilizes the spatio-temporal correlations of deformations between measurement points to perform spatio-temporal clustering and partitioning of the deformation data from the measurement points of concrete dams. Based on the new honey badger algorithm (HBA) and the bidirectional long short-term memory (BiLSTM) neural networks, the HBA-BiLSTM deformation prediction model is established. Deformation outliers in concrete dams are identified based on the deformation values output by the established model and outlier discrimination indices. The results of case validation show that this method has higher accuracy than traditional outlier identification methods.

Key words: concrete dam; deformation; outlier identification; monitoring model; spatio-temporal clustering

安全监测是定量分析混凝土坝安全性态的重要方法^[1]。变形能够真实、直观、准确地反映混凝土坝安全性态变化, 是混凝土坝最重要的监测内容^[2-3]。然而, 受仪器故障、人为因素或其他不确定因素的影响, 采集的变形监测数据不可避免地会出现各种异常值^[4]。异常数据可能是荷载急剧变化造成的正常结构反应, 也可能是仪器故障、人为因素等造成的错误数据。因此, 混凝土坝变形异常值精准识别对大坝监测数据分析及安全评价具有重要

意义^[5]。

混凝土坝变形异常值检测方法主要包括统计检验法和数学模型法。统计检验法是根据数据本身的概率分布特征来检测异常值, 异常值的检测精度与监测数据本身的概率分布假设有关。例如: Li等^[6]结合鲁棒回归和拉依达准则构建了大坝监测数据异常识别区间; Yang等^[7]基于改进的LOF异常值检测方法和典型小概率原理建立了异常值判别标准。统计检验法仅考虑变形数据本身, 未结合混凝土坝

基金项目:国家自然科学基金青年科学基金项目(52109166); 国家自然科学基金面上项目(52279140)

作者简介:宋锦焄(1990—), 男, 副教授, 博士, 主要从事大坝安全监控与风险分析研究。E-mail: 104971@xaut.edu.cn

通信作者:葛佳豪(2000—), 男, 硕士研究生, 主要从事大坝安全监控与数值仿真研究。E-mail: g1977350261@163.com

变形输入输出关系,无法有效识别荷载快速变化引起的结构反应,容易将正常数据误诊断为异常值。数学模型法利用混凝土坝变形输入输出关系,通过基于统计模型、机器学习算法等构建的高精度变形预测模型来监控变形监测数据的变化规律,进而识别变形序列中的异常值。例如:黎祎等^[8]利用变形序列与水位序列的关联性结合 DBSCAN 聚类算法构建了异常数据识别与重构模型;Xu 等^[9]结合单测点时间序列异常检测、远程重测和环境响应突变识别方法构建了一种三阶段在线异常值识别模型。监控模型法的识别精度主要依赖于预测模型的精度,上述方法主要考虑单测点监测数据的异常值,而利用相似测点的时空关联特性去识别异常值,可以更加合理地识别混凝土坝的异常测值。

综上,考虑混凝土坝变形的时空关联特性并提出高精度的混凝土坝变形预测模型,对提升变形监测数据异常值的识别精度具有重要意义。本文在时空聚类分区基础上,提出一种融合新型优化算法和深度学习算法的混凝土坝变形异常值识别方法,并通过工程实例对该方法的识别准确率进行验证。

1 异常值识别方法

1.1 坝体测点时空聚类分区

混凝土坝变形具有显著的时空关联特性^[10-11],部分测点具有相似的变化规律及测值变化区间。混凝土坝变形时空关联特性研究的核心是测点间相关性指标的定义。根据测点变形值大小、变化幅度及变化速度定义测点间的综合距离为^[12]

$$d_c = \alpha_1 d_A + \alpha_2 d_1 + \alpha_3 d_G \quad (1)$$

式中: d_A 、 d_1 、 d_G 、 d_c 分别为测点 a 和测点 b 之间的绝对距离、增量距离、增速距离、综合距离; α_1 、 α_2 、 α_3 分别为绝对距离、增量距离、增速距离的权重,根据文献^[13],拟定 $\alpha_1 = \alpha_2 = \alpha_3 = 1/3$ 。

根据各测点之间的综合距离,采用最小离差平方和系统聚类法(Ward 聚类法)^[14]实现坝体测点变形聚类分区。Ward 聚类法的流程为:①将坝体的每个测点单独划为一类,共分为 N 类;②计算各测点之间的离差平方,选择离差平方和最小的两个测点合成一类,这时分类总数由 N 类递减为 $N-1$ 类;③计算合并后各类的离差平方,重复②,直至组合任意两类时,各类的离差平方无法继续减小,聚类终止。

1.2 变形预测模型构建

对混凝土坝测点变形数据进行时空聚类后,基于数学模型法的异常值识别方法的核心是构建一种高精度的混凝土坝变形预测模型。本文基于蜜獾优化算法(honey badger algorithm,HBA)和双向长短时

记忆(bidirectional long short-term memory,BiLSTM)神经网络构建了 HBA-BiLSTM 变形预测模型。

a. HBA。虽然深度学习算法在混凝土坝变形预测中有着广泛应用,但模型参数的选取对深度学习算法预测精度的影响显著,参数优化算法的优劣直接影响异常值识别的准确率。HBA 是由 Hashim 等^[15]提出的一种新型智能优化算法,主要通过模拟蜜獾的挖掘和寻找蜂蜜的动态搜索行为进行寻优,和传统优化算法相比,具有寻优能力强、收敛精度高、稳定性强等优点^[16]。

b. BiLSTM 神经网络。长短时记忆(LSTM)深度学习神经网络已经在大坝安全监测领域得到了广泛应用。BiLSTM 神经网络在 LSTM 神经网络基础上进行了深度改进,其主体结构由前传层和后传层组成,这两个隐藏层使 BiLSTM 神经网络能够准确地记忆所有有用的过去和未来特征,使其提取序列信息的能力在 LSTM 神经网络基础上得到进一步提升^[17]。BiLSTM 神经网络通过双向迭代进入 3 个门结构(即输入门、遗忘门和输出门)来更新细胞状态,能够解决 LSTM 神经网络仅从单向探索数据规律造成的信息挖掘能力不足问题^[18-20]。

1.3 异常值识别准则

将聚类后的变形相似测点输入 HBA-BiLSTM 模型,输出各测点变形预测值,计算出每个测点的模型预测残差,利用聚类后的相似测点间模型预测残差的相关性作为判定依据,构建基于相似测点综合残差的混凝土坝变形异常值判别指标。对于分区内某测点 i ,假设同一分区内其余的变形序列相似测点为 $1, 2, \dots, n$,通过计算其余变形测点的残差与该测点的残差之间的相关系数 $r_i (i = 1, 2, \dots, n)$,根据式(2)来构建所研究测点的综合残差指标。

$$s_{\text{综}} = w_1 s_1 + w_2 s_2 + \dots + w_n s_n \quad (2)$$

其中 $w_i = r_i / (r_1 + r_2 + \dots + r_n)$ 式中: $s_{\text{综}}$ 为综合残差; s_i 为第 i 个测点的残差; w_i 为第 i 个测点残差在综合残差中的占比。

通过融合综合残差指标和置信区间法作为异常值识别的标准,当所研究测点的监测数据序列残差大于此标准,即可识别为异常值,判别标准为

$$\begin{cases} |Y_i - Y'_i| \geq 3\sigma & \text{异常值} \\ |Y_i - Y'_i| < 3\sigma & \text{正常值} \end{cases} \quad (3)$$

式中: Y_i 为模型预测值; Y'_i 为实测值; σ 为综合残差序列的标准差。

1.4 异常值识别步骤

本文提出的混凝土坝变形异常值识别方法(以下简称“本文方法”)的识别步骤如图 1 所示,主要包含以下 5 个步骤:




图1 混凝土坝变形异常值识别方法的识别步骤

步骤1 坝体测点聚类分区。将各测点变形测值转化为综合距离属性,借助Ward聚类法实现测点的聚类分区。

步骤2 建立分区内各测点的监控模型因子集。输出变量为测点变形序列 δ ,输入变量为各变形影响因子。HBA-BiLSTM模型输入各环境因子共计10项,即 H^1 、 H^2 、 H^3 、 H^4 、 $\sin(2\pi t/365)$ 、 $\cos(2\pi t/365)$ 、 $\sin(2 \times 2\pi t/365)$ 、 $\cos(2 \times 2\pi t/365)$ 、 θ 、 $\ln\theta$ (H 为上游水深; t 为监测日至始测日的累计天数; $\theta=t/100$)。

步骤3 HBA-BiLSTM模型构建。对输入变量及实测数据进行归一化处理并划分训练集与测试集,采用HBA对BiLSTM模型进行超参数优化,基于最优超参数进行建模预测。

步骤4 采用平均绝对误差(MAE)、均方根误差(RMSE)、平均绝对百分比误差(MAPE)和决定系数(R^2)作为模型的评价指标。

步骤5 针对模型输出的分区内各测点变形值,计算出每个测点的模型预测残差,选用相同分区内不同测点间模型预测残差的相关性作为判定依据,构建基于相似测点综合残差的混凝土坝变形异常值判别标准。

为验证异常值识别方法的有效性,选取精准率 P 、召回率 R 、加权评价指标 F 等作为评价指标。

2 实例验证

2.1 工程概况

某水电站工程规模为I等大(1)型工程,其挡水建筑物为混凝土双曲薄拱坝,最大坝高250 m,坝基高程2210 m,坝顶高程2460 m,坝顶厚度10 m,正常蓄水位2452 m,相应库容10.06亿 m^3 ,坝顶中心线弧长466.63 m。该拱坝的坝体布置了7组竖线共计21个正垂线测点来监测大坝的安全状况,变形监测序列采用2012年9月14日到2021年7月9日的测值。图2为坝体正垂线测点分布图,图3为上游水位与气温时间序列过程线。由图3可知,该拱坝的上游水位在2015—2016年有小幅上升,2016年后基本稳定在较高水位运行;坝体周围的气温则呈周期性变化。




图2 坝体正垂线测点分布




图3 上游水位与气温时间序列过程线

2.2 时空聚类模型分区结果

利用变形监测数据,结合定义的3种距离计算各测点间的综合关联性指标,以此实现时空多测点聚类,得到坝体变形测点谱系聚类树状图如图4所示。以类内离差平方和为聚类分区的划分标准,将各测点划分为5个区域,如图5所示。图6为坝体各分区测点径向水平位移过程线。




图4 坝体变形测点谱系聚类树状图




图5 坝体测点 Ward 聚类分区结果




图6 坝体各分区测点径向水平位移过程线

由图6可知,每个区域内测点的径向水平位移过程线变化趋势和规律均有较高相似性,聚类结果符合拱坝变形区域分布特征。图7是基于 K 均值

聚类法的坝体测点变形分区,相比于 K 均值聚类法的聚类结果,基于Ward聚类法的分区内测点的径向水平位移过程线相似性更高。因此,Ward聚类法具有较好的聚类效果。




图7 基于 K 均值聚类法的坝体测点变形分区

本文异常值识别选取图6中的分区I作为研究对象,其余分区异常值识别方法和分区I相同。分区I中共有PL3-1、PL4-1、PL5-1等3个相似测点。如图6(a)所示,各测点的变形变化规律高度相似,选取PL4-1测点变形数据作为异常值识别对象,利用HBA-BiLSTM模型对该测点的异常值进行精准识别。

2.3 HBA-BiLSTM 模型构建与分析

2.3.1 参数优化算法对比

采用HBA对模型的超参数进行优化,同时选取其他4种群智能优化算法进行对比,包括粒子群优化算法(particle swarm optimization, PSO)^[21]、麻雀搜索算法(sparrow search algorithm, SSA)^[22]、北方苍鹰优化算法(northern goshawk optimization, NGO)^[23]和鲸鱼优化算法(whale optimization algorithm, WOA)^[24]。各算法的种群数量设置为50,最大迭代次数设置为100。

图8为5种优化算法的收敛曲线。由图8可知,相较于其他4种优化算法,HBA的收敛速度最优,收敛后的适应度也最小。因此,采用HBA优化BiLSTM模型能够有效提高该模型最优参数的获取能力。




图8 5种优化算法的收敛曲线

2.3.2 模型参数确定

为构建HBA-BiLSTM模型并测试模型预测精度,将监测数据的85%作为训练集,15%作为测试集。采用HBA对模型的隐藏节点个数、初始学习

率、最大迭代次数进行自动寻优,设定寻优范围分别为 $[10,400]$ 、 $[0.0001,0.005]$ 、 $[0,500]$,小批量尺寸设置为128。HBA 的种群数量为50,最大迭代次数为100。不同测点的参数优化结果如表1所示。

表1 模型参数优化结果

测点	隐藏节点个数	初始学习率	最大迭代次数
PL3-1	240	0.0019	242
PL4-1	210	0.0022	261
PL5-1	232	0.0036	226

2.3.3 模型预测结果分析与评价

为比较 HBA-BiLSTM 模型与传统预测模型预测精度的提升程度,将 HBA-BiLSTM 模型的预测结果与支持向量回归 (support vector regression, SVR)^[25]、LSTM、BiLSTM 等模型的预测结果和评价指标进行对比分析,并采用分区内多个测点的实测数据验证该模型的适用性。其中 LSTM 和 BiLSTM 的隐藏节点个数、初始学习率、最大迭代次数分别设置为300、0.005、400;SVR 模型的惩罚因子、核函数参数分别设置为128、0.2。不同模型预测结果评价指标如表2所示。由表2可以看出,各测点 HBA-BiLSTM 模型的 MAE、MAPE、RMSE 和 R^2 均优于 BiLSTM。以 PL3-1 为例,HBA-BiLSTM 模型预测结果的 R^2 为0.995,相比于 SVR 模型、LSTM 模型、BiLSTM 模型分别提升了0.054、0.055、0.018;而 MAE 相较于 SVR、LSTM、BiLSTM 模型减少了0.428、0.507、0.204 mm。HBA-BiLSTM 模型各项性能指标的平均精度相比于其他模型分别提高了26.02%、29.74%、16.11%。

表2 不同模型预测结果评价指标对比

测点	模型	MAE/mm	MAPE/%	RMSE/mm	R^2
PL3-1	SVR	1.364	2.43	1.558	0.941
	LSTM	1.443	2.60	1.734	0.940
	BiLSTM	1.140	2.03	1.374	0.977
	HBA-BiLSTM	0.936	1.67	1.003	0.995
PL4-1	SVR	1.296	1.97	1.652	0.909
	LSTM	1.278	1.87	1.613	0.912
	BiLSTM	1.121	1.65	1.472	0.951
	HBA-BiLSTM	0.804	1.18	0.951	0.982
PL5-1	SVR	1.542	3.35	1.842	0.908
	LSTM	1.347	3.04	1.694	0.935
	BiLSTM	0.962	2.10	1.089	0.957
	HBA-BiLSTM	0.902	1.99	1.127	0.989

图9为 PL3-1、PL4-1、PL5-1 测点不同模型的预测值与实测值的对比,可以看出,BiLSTM、LSTM 和 SVR 模型的整体变化趋势与实际变化趋势基本保持一致,但其后期预测值与实际值有较大偏差;HBA-BiLSTM 模型预测值与实测值过程线拟合程度更高,预测残差更小。




图9 各测点预测结果对比分析

综上所述,本文提出的 HBA-BiLSTM 模型具有更高的预测精度,能够更好地实现对 PL3-1、PL4-1、PL5-1 监测数据的拟合。

2.4 异常值识别

以 PL4-1 测点实测变形数据为例,选取2020年3月20日至2021年7月9日的数据序列共68组数据,为验证不同异常值识别方法的识别能力,其中人为在 PL4-1 测点的2020年7月3日、8月21日、12月18日以及2021年3月5日、5月14日共计5处随机位置加入粗差,一般粗差添加时选取2~3倍标准差作为构造粗差,本文为检验不同识别方法的高精度识别能力,选取2倍标准差作为粗差构造标准,加入粗差后的各测点径向水平位移过程线如图10所示。




图10 各测点径向水平位移过程线

根据综合残差识别准则,计算出 PL3-1、PL5-1 测点与 PL4-1 测点之间的残差相关性 r_1 、 r_2 分别为0.4205、0.3442,综合残差中 PL3-1、PL5-1 测点占比 w_1 、 w_2 分别为0.5499、0.4501,综合残差置信区

间上边界为 1.126,因此选取 1.126 作为异常值的识别阈值。根据式(3)比较得到,当 PL4-1 测点的残差大于 1.126 时,可认为数据偏差较大,属于异常值。

采用本文方法对 PL4-1 的实测数据进行异常值识别,图 11 为 PL4-1 测点异常值识别结果。由图 11 可知,本文方法能够有效地识别出监测数据序列中人工添加的异常值,同时也能识别出监测数据序列中原始的异常值,共计 10 个异常值点。




图 11 PL4-1 测点异常值识别结果

为了验证本文方法的优越性,将检测结果与拉依达准则、格拉布斯准则、基于 HBA-BiLSTM 的综合残差置信区间法和基于时空聚类 and HBA-LSTM 的综合残差置信区间法等检测结果进行对比分析。其中,拉依达准则、格拉布斯准则是经典统计检验异常值检测方法;基于 HBA-BiLSTM 的综合残差置信区间法是为对比不考虑时空聚类,直接根据单测点模型进行异常值识别的结果;基于时空聚类的 HBA-LSTM 的综合残差置信区间法则是为对比考虑时空聚类,但监控模型方法不同带来的识别结果。计算出精准率 P 、召回率 R 、加权评价指标 F 等评价指标对其结果进行对比分析评价。表 3 为 PL4-1 测点不同方法异常值识别结果评价指标。由表 3 可知,传统统计检验法拉依达准则和格拉布斯准则具有 100% 的精准率,但其召回率均不足 50%,加权评价指标较低,检测效果较差。未考虑时空聚类的基于 HBA-BiLSTM 的综合残差置信区间法和基于时空聚类 and HBA-LSTM 的综合残差置信区间法的召回率相比于拉依达准则和格拉布斯准则有了较大提升,但是精准率有所降低,检测过程中有少量的误判。本文方法综合考虑了混凝土坝变形时空聚类特性和高精度预测模型,其精准率和召回率均为

表 3 PL4-1 测点不同方法异常值识别结果评价指标

识别方法	$P/\%$	$R/\%$	$F/\%$
本文方法	100.00	100.00	100.00
拉依达准则	100.00	40.00	57.14
格拉布斯准则	100.00	20.00	33.33
基于 HBA-BiLSTM 的综合残差置信区间法	77.78	58.33	66.67
基于时空聚类 and HBA-LSTM 的综合残差置信区间法	72.73	80.00	76.19

100%,识别效果均优于其他对比方法。综上所述,本文方法在混凝土坝变形异常值识别的精度、漏判、误判等方面均具有较好的性能提升。

3 结 语

本文综合利用 Ward 聚类法、HBA 优化算法和 BiLSTM 深度学习算法,基于关联测点综合残差构建异常值识别准则,并提出了基于时空聚类 and 深度学习的混凝土坝变形异常值识别方法。通过实例分析,验证了该方法的预测精度和异常值识别准确率。基于定义的综合距离和 Ward 聚类法得到的变形分区内各测点变形规律比传统聚类法具有更高的相似性,更符合拱坝变形的区域分布特征。本文方法在精准率和召回率方面均优于经典统计检验和监控模型方法,能够更好地识别出混凝土坝变形监测数据中的异常值。本文方法考虑了多测点间的时空关联特性,不仅可用于异常值识别,还可实现大坝变形监测数据的高精度预测拟合。

参考文献:

[1] 赵二峰,顾冲时. 混凝土坝长效服役性态健康诊断研究述评[J]. 水力发电学报,2021,40(5):22-34. (ZHAO Erfeng, GU Chongshi. Review on health diagnosis of long-term service behaviors for concrete dams[J]. Journal of Hydroelectric Engineering, 2021, 40(5):22-34. (in Chinese))

[2] 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))

[3] 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.

[4] YANG Jie, QU Xudong, CHANG Meng. An intelligent singular value diagnostic method for concrete dam deformation monitoring [J]. Water Science and Engineering, 2019, 12(3):205-212.

[5] LI Bin, YANG Jie, HU Dexiu. Dam monitoring data analysis methods: a literature review[J]. Structural Control and Health Monitoring, 2020, 27(3):e2501.

[6] LI Xing, LI Yanling, LU Xiang, et al. An online anomaly recognition and early warning model for dam safety monitoring data [J]. Structural Health Monitoring, 2020, 19(3):796-809.

- [7] YANG Jie, QU Xudong, HU Dexiu, et al. Research on singular value detection method of concrete dam deformation monitoring[J]. Measurement,2021,179:109457.
- [8] 黎伟,赵二峰,何菁. 大坝变形监测异常数据识别和重构模型[J]. 水利水电科技进展,2023,43(2):109-114. (LI Yi, ZHAO Erfeng, HE Jing. Abnormal data identification and reconstruction model of dam deformation monitoring[J]. Advances in Science and Technology of Water Resources,2023,43(2):109-114. (in Chinese))
- [9] XU Ying, HUANG Huibao, LI Yanling, et al. A three-stage online anomaly identification model for monitoring data in dams[J]. Structural Health Monitoring, 2022, 21(3):1183-1206.
- [10] 李明超,任秋兵,孔锐,等. 多维复杂关联因素下的大坝变形动态建模与预测分析[J]. 水利学报,2019,50(6):687-698. (LI Mingchao, REN Qiubing, KONG Rui, et al. Dynamic modeling and prediction analysis of dam deformation under multidimensional complex relevance [J]. Journal of Hydraulic Engineering,2019,50(6):687-698. (in Chinese))
- [11] 李子阳,李涵曼,李政颢,等. 基于多测点云相似的混凝土坝变形形态关联分析[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))
- [12] 胡添翼. 基于面板数据分析方法的混凝土拱坝变形数据时空聚类模型[J]. 长江科学院院报,2021,38(2):39-45. (HU Tianyi. Spatial and temporal clustering model of concrete arch dam deformation data based on panel data analysis method [J]. Journal of Yangtze River Scientific Research Institute,2021,38(2):39-45. (in Chinese))
- [13] 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))
- [14] WARD JR J H. Hierarchical grouping to optimize an objective function[J]. Journal of the American Statistical Association,1963,58(301):236-244.
- [15] HASHIM F A, HOUSSEIN E H, HUSSAIN K, et al. Honey Badger Algorithm: new metaheuristic algorithm for solving optimization problems[J]. Mathematics and Computers in Simulation,2022,192:84-110.
- [16] 李建合,孙伟哲,苏国韶. 岩体力学参数反演的代理蜜獾优化方法[J]. 科学技术与工程,2023,23(1):376-384. (LI Jianhe, SUN Weizhe, SU Guoshao. A surrogate honey badger algorithm optimization method for back analysis of rock parameters [J]. Science Technology and Engineering,2023,23(1):376-384. (in Chinese))
- [17] 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))
- [18] 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))
- [19] 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))
- [20] 于飞,樊清川,宣敏. 基于蝗虫优化 Bi-LSTM 网络的电机轴承故障预测[J]. 电机与控制学报,2022,26(6):9-17. (YU Fei, FAN Qingchuan, XUAN Min. Motor bearing fault prediction based on grasshopper optimized Bi-LSTM network [J]. Electric Machines and Control,2022,26(6):9-17. (in Chinese))
- [21] 张石,郑东健,陈卓研. 基于改进 PSO-RF 算法的大坝变形预测模型[J]. 水利水电科技进展,2022,42(6):39-44. (ZHANG Shi, ZHENG Dongjian, CHEN Zhuoyan. Dam deformation prediction model based on improved PSO-RF algorithm [J]. Advances in Science and Technology of Water Resources,2022,42(6):39-44. (in Chinese))
- [22] XUE Jiankai, SHEN Bo. A novel swarm intelligence optimization approach: sparrow search algorithm [J]. Systems Science & Control Engineering,2020,8(1):22-34.
- [23] DEHGHANI M, HUBÁLOVSKÝ Š, TROJOVSKÝ P. Northern goshawk optimization: a new swarm-based algorithm for solving optimization problems [J]. IEEE Access,2021,9:162059-162080.
- [24] MIRJALILI S, LEWIS A. The whale optimization algorithm [J]. Advances in Engineering Software,2016,95:51-67.
- [25] CHENG Junsheng, YU Dejie, YANG Yu. Application of support vector regression machines to the processing of end effects of Hilbert-Huang transform [J]. Mechanical Systems and Signal Processing,2007,21(3):1197-1211.

(收稿日期:2023-05-22 编辑:俞云利)