

基于 M-ELM 的大坝变形安全监控模型

胡德秀¹, 屈旭东¹, 杨杰¹, 程琳¹, 常梦²

(1. 西安理工大学 水利水电学院, 陕西 西安 710048; 2. 中国水电建设集团十五工程局有限公司, 陕西 西安 710016)

摘要:针对大坝变形监测数据存在的非线性强、异常值诊断和剔除工作复杂及传统监控模型抗粗差能力差等问题, 结合稳健估计理论抗粗差性强和极限学习机在处理非线性问题方面的优势, 建立了基于稳健估计极限学习机的大坝变形安全监控模型。试验确定网络隐含层层数, 构建 4 次方损失函数, 采用加权最小二乘法计算输出权值, 实现原始监测数据的拟合和预测。以某工程大坝变形监测数据为例进行建模分析, 结果表明: 以反映模型预测精度的均方误差和平均绝对百分误差及反映模型鲁棒性的中位数绝对偏差作为评价指标, 基于稳健估计极限学习机的大坝变形安全监控模型的各项指标明显优于对比模型。

关键词:稳健估计; 极限学习机; 大坝变形; 安全监控模型; 粗差

中图分类号: TV698.1

文献标志码: A

文章编号: 1006-7647(2019)03-0075-06

A safety monitoring model of dam deformation based on M-ELM//HU Dexiu¹, QU Xudong¹, YANG Jie¹, CHENG Lin¹, CHANG Meng²(1. *Institute of Water Resources and Hydro-electric Engineering, Xi'an University of Technology, Xi'an 710048, China*; 2. *Sinohydro Engineering Bureau 15 Co., Ltd., Xi'an 710016, China*)

Abstract: Aiming at the problems of strong nonlinearity, complexity of diagnosing and eliminating abnormal values, and poor ability to resist gross errors of traditional monitoring models for the analysis of dam deformation monitoring data, a dam deformation monitoring model based on robust estimate extreme learning machine (M-ELM) was established. It combines the theory of robust estimation which has strong roughness tolerance with the extreme learning machine which has strong ability in dealing with nonlinear problems. The network number of the hidden layers was determined by tests and a fourth power loss function was built. A weighted least square method was used to calculate the output weights, and the fitting and prediction of the original monitoring data was carried out. The monitoring data of a certain dam deformation was taken as an example for modeling analysis. The mean square error and the mean absolute percentage error reflecting the prediction accuracy, and the median absolute deviation representing the model robustness were taken as the evaluation indexes. The results show that each index of the dam deformation monitoring model based on robust estimate extreme learning machine is superior to other models.

Key words: robust estimation; extreme learning machine; dam deformation; safety monitoring model; gross error

水利工程在其服役过程中不仅要承受各种动、静循环荷载及各种突发性灾害的作用, 还要承受来自恶劣环境的侵蚀与腐蚀, 导致结构服役期间局部和整体安全性能随着时间推移而逐步衰退, 因此及时准确地了解各水工建筑物的工作性态以确保其安全极为重要^[1]。依据水利工程原型监测资料, 应用统计学、工程力学、信息科学等方法建立安全监控模型对影响水利工程的各因素(特别是时效分量)进行物理解释, 定量分析评价和反馈水利工程的安全状况, 揭示建筑物的异常服役性态, 是保障工程安全的重要手段^[2]。

目前, 具有代表性的大坝变形安全监测资料分析模型主要有 4 种: 统计模型、确定性模型、混合模型及组合模型, 其中统计模型和确定性模型为技术支撑主体^[3]。

统计模型^[4-7]是指以概率论和数理统计理论为技术支撑对监测数据进行建模分析, 建立荷载集与荷载效应集之间的关系的表达式。其中最常用的是静水压力分量-温度周期分量-时间分量(hydrostatic-seasonal-time, HST)方法, 但其只考虑了静水荷载的可逆效应、温度周期荷载的可逆效应和时效不可逆效应。统计模型的缺点主要表现在: ①对大坝的工

作性态不能从力学概念上加以本质解释;②统计模型基于各变量相互独立的假设条件,未考虑因子之间的相关性,可能会导致分离变量失真;③模型不能反映变量之间的非线性关系。

确定性模型^[8-11]采用有限元法计算荷载(如水压、温度等)作用下大坝和坝基的效应场(如位移、应力场、渗流场等),然后与实测值进行优化拟合,以求得调整参数(因为大坝与坝基的平均物理力学参数、渗流参数及边界条件等的不确定性),从而建立基于物理力学本质的表达式。确定性模型的缺点主要表现在:①大坝及坝基材料参数的不确定性;②边界条件设置的不确切性;③模型简化的不精确性。

混合模型^[12-14]采用有限元法计算水压分量,其他分量采用统计模型,然后与实测值进行优化拟合。混合模型虽然从力学概念出发,提高了模型计算精度,但同时也继承了统计模型和确定性模型的固有缺陷和假设。

组合模型^[15-16]通过整合各子模型的应用条件、构模机理和出发点等多种有用信息,将多个单一模型进行非线性优化组合,达到对映射关系更加合理和全面的刻画,有效地提高拟合和预测精度,建立性能更佳的监控模型。组合模型的缺点主要表现在:①线性组合模型应对非线性问题时有可能得到不符合实际的负权重;②组合函数构造十分困难。

近年来,随着大坝安全监控、计算机、大数据、人工智能等理论与技术的发展,越来越多的数据挖掘方法被应用到水利工程安全监控建模中来,涌现出了许多智能算法监控模型^[17-20],在解决监控模型因子不确定性和非线性问题、预测精度及泛化性等方面表现出了特有的优势。

针对以往监控模型预测精度低、鲁棒性差及泛化能力弱的不足,鉴于智能算法优越的数据处理能力,本文引入机器学习浅层结构算法中的极限学习机(extreme learning machine, ELM)方法以解决大坝变形监测数据存在的因子不确定性和非线性问题。同时,针对传统监控模型抗粗差能力差等问题,引入稳健估计理论,建立了基于稳健估计极限学习机(M-ELM)的大坝变形安全监控模型,强化了模型的鲁棒性,提高了模型的预测精度及泛化性,更加接近真实地反映大坝的工作性态。

1 ELM 原理

ELM 是一种新型单隐含层前馈神经网络学习算法^[21]。传统的神经网络学习算法(如 BP 算法)需要人为设置大量网络训练参数(权值、偏置及学习率等指标),并且很容易产生迭代次数过多、学习

时间长及局部最优解等问题。相对于传统的神经网络学习算法,ELM 在算法执行过程中不需要调整网络的输入权值和偏置,只需要进行隐含层节点数的设置,并且产生唯一的最优解,在保证网络具有良好泛化性的同时,极大地提高了学习速度,广泛地被用于各种数据处理中^[22-23]。图 1 为 ELM 网络结构图。

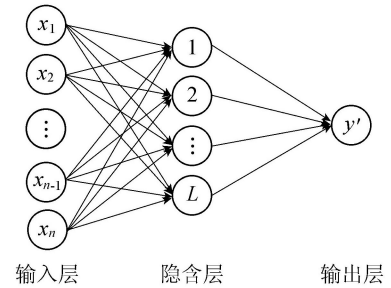


图 1 ELM 网络结构

为了在因子比较和评价的指标处理中去掉数据的量纲限制,将数据进行标准化(无量纲化)处理,以便于不同单位或量级的指标能够进行比较和加权。对于 n 个经标准化处理的数据样本 $(\mathbf{x}_i, \mathbf{y}_i)$,其中 $\mathbf{x}_i = (x_{i1}, x_{i1}, \dots, x_{ip})^T$ 为自变量样本, $\mathbf{y}_i = (y_{i1}, y_{i1}, \dots, y_{ik})^T$ 为因变量样本,对采用 l 个隐含层节点的单隐含层神经网络,设权值为 ω_i ,偏置为 b_i ,其描述可以表示为以下方程组形式:

$$\mathbf{H}_{p \times l} \boldsymbol{\beta}_{l \times k} = \mathbf{y}_{p \times k} \quad (1)$$

$$\text{其中 } \mathbf{H} = \begin{bmatrix} g(\omega_1 x_1 + b_1) & \cdots & g(\omega_l x_1 + b_l) \\ \vdots & & \vdots \\ g(\omega_1 x_p + b_1) & \cdots & g(\omega_l x_p + b_l) \end{bmatrix}_{p \times l}$$

式中: \mathbf{H} 为隐含层节点输出; $g(x)$ 为激活函数; $\boldsymbol{\beta} = (\boldsymbol{\beta}_1, \boldsymbol{\beta}_2, \dots, \boldsymbol{\beta}_l)^T_{l \times k}$ 为隐含层节点输出权重; $\mathbf{y} = (\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_n)^T_{p \times k}$ 为网络期望输出; p 为自变量数; k 为因变量数。

传统极限学习机隐含层节点输出权重采用最小二乘法进行计算,构建的损失函数为

$$Q = \sum_{i=1}^n [\mathbf{y}_i - \mathbf{H}_i \boldsymbol{\beta}]^2 \quad (2)$$

使式(2)损失函数取得最小值,计算网络参数(隐含层节点输出权重) $\hat{\boldsymbol{\beta}}$,其结果为:

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^+ \mathbf{y} = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \mathbf{y} \quad (3)$$

式中: \mathbf{H}^+ 为 \mathbf{H} 的 Moore-Penrose 广义逆。

传统的 ELM 算法的输出权重的计算采用经典的最小二乘法,当网络隐含层输出数据误差服从正态分布情况时,最小二乘估计具有最优统计性质,但实际情况往往不是这样,其对于粗差的抵抗性特别差,当输出数据存在多重共线性或粗差时就会对参数的估值产生较大的影响,计算结果也会产生严重的偏差,甚至得出错误的结论,严重影响网络训练的

精度。同时,隐含层参数的选取均采用随机生成的方法,致使每一次训练和测试结果存在一定的随机性,对于网络的稳定性产生不利的影。因此从网络学习的精度和稳健性方面考虑,ELM 算法仍有两个需要解决的固有缺陷:隐含层参数的随机选取会造成 ELM 网络训练结果有较大的不稳定性;如果训练数据存在共线性或粗差干扰,输出层权值的最小二乘法估计结果会很差^[25]。

2 M-ELM 大坝变形安全监控模型

水利枢纽工程中往往建有各类型的大坝、溢洪道、隧洞等建筑物,建筑物的安全是其挡水、泄水、放水等功能发挥的关键。为此,通过监测各种水工建筑物变形、渗流、应力等安全项目,实时监测工程安全。如何利用实测数据进行建模拟合预测分析是实现水利工程安全监控的核心基础。

本文针对 ELM 的上述固有缺陷,以水工建筑物原型监测数据为基础,建立基于稳健估计极限学习机的大坝变形安全监控模型。水工建筑物的原型监测物理量通常将荷载集称为自变量或预报因子(第 i 个样本的第 j 个预报因子表示为 x_{ij}),荷载效应集称为因变量或预报量(第 i 个样本的预报量表示为 y_i)。基于稳健估计极限学习机的大坝安全监控模型中,选取 p 个预报因子,第 i 个样本误差记为 $e_i = y_i - \sum_{j=1}^p x_{ij}^T \beta_j$,为了保证损失函数求和项均为正值,构造 4 次方损失函数:

$$Q' = \sum_{i=1}^N \rho^4(e_i) = \sum_{i=1}^N \rho^4(y_i - \sum_{j=1}^p x_{ij}^T \beta_j) \quad (4)$$

式中: ρ 为影响函数; N 为样本总数。当损失函数 Q' 取最小值时可得出隐含层权值的最优解。

首先记 $\psi(e_i) = \frac{\partial \rho(e_i)}{\partial e_i}$,则:

$$\frac{\partial \rho(e_i)}{\partial \beta} = 4\psi^3(y_i - \sum_{j=1}^p x_{ij}^T \beta_j) x_i \quad (5)$$

则可以将式(4)转化为

$$\sum_{i=1}^N \psi^3(y_i - \sum_{j=1}^p x_{ij}^T \beta_j) x_i = 0 \quad (6)$$

$$\text{即} \quad \sum_{i=1}^N x_{ij} \frac{\psi^3(e_i)}{e_i} e_i = 0 \quad (7)$$

定义权重 $w'_i = \frac{\psi^3(e_i)}{e_i}$,则式(7)可以转化为

$$\sum_{i=1}^N x_{ij} w'_i (y_i - \sum_{j=1}^p x_{ij}^T \beta_j) = 0 \quad (8)$$

法方程矩阵表达式为

$$X^T W X \beta = X^T W y \quad (9)$$

故稳健估计极限学习机的计算结果为

$$\hat{\beta} = (X^T W X)^{-1} X^T W y \quad (10)$$

M-ELM 大坝变形安全监控模型建模流程见图 2,建模步骤具体如下:

a. 选取实测监测资料作为模型训练样本和测试样本,将所有数据进行标准化,并将标准化样本数据输入到监控模型。

b. 通过试验确定隐含层节点个数,并随机选取网络参数 w_i, b_i ,选择某一无限可微函数(如 S 形函数、正弦函数和复合函数等)作为隐含层神经元激活函数,计算隐含层节点输出矩阵 H 。

c. 根据计算的隐含层节点输出矩阵 H ,利用稳健估计理论计算隐含层节点输出权重 β_i ,并进行输出节点值的计算,即为监控模型的拟合值,同时进行训练样本均方差的计算,即为训练误差。

d. 根据训练样本训练出的隐含层节点输出权重进行测试样本的预测值计算,即为监控模型的预测值,同时计算出预测值与测试样本之间的均方差,即为测试误差或预测误差。

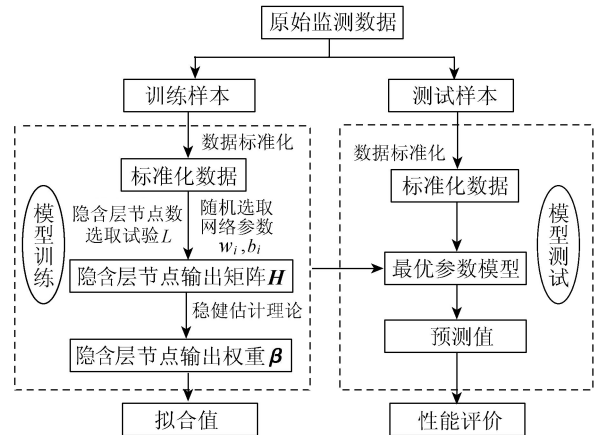


图 2 M-ELM 大坝变形安全监控模型建模流程

3 模型验证

3.1 工程简介

以某水利枢纽工程监测数据为例进行 M-ELM 大坝变形安全监控模型的应用研究。该工程大坝为壤土心墙土石坝,最大坝高 101.8 m,坝顶长度 297.36 m。大坝采用 5 个纵断面共 30 个测点监测大坝的水平位移。选取该大坝高程为 691 m 的马道旁 D7 测点 2010 年 1 月至 2014 年 5 月共 178 个样本的监测资料,主要包括该测点水平位移(向左岸为正,向右岸为负)、水库大坝上下游水位及坝址区温度等。

3.2 分析结果及对比

由于土石坝工作性态异常复杂,影响其变形的因素有坝型、剖面尺寸、筑坝材料、施工程序及质量、

坝基的地形、水库水位的变化情况等。因此本文在土石坝变形监测量的统计模型选择中,选取水位因子、温度因子及时效因子作为模型主要影响因素,构建如下土石坝水平位移的统计模型:

$$\delta = b_0 + \sum_{i=1}^4 a_{1i}(H_u - H_{u0})^i + \sum_{i=1}^4 a_{2i}(H_d - H_{d0})^i + b_1 T_i + \sum_{i=1}^2 \left(b_{1i} \cos \frac{2\pi it}{365} + b_{2i} \sin \frac{2\pi it}{365} \right) + c_1 \theta + c_2 \ln \theta \quad (11)$$

式中: b_0 为常数项; a_{1i} 、 a_{2i} 分别为上、下游因子回归系数; b_1 、 b_{1i} 、 b_{2i} 为温度因子回归系数; c_1 、 c_2 为时效因子回归系数; H_u 为上游水位,mm; H_d 为下游水位,mm; H_{u0} 、 H_{d0} 分别为始测日所对应的上、下游水位,mm; T 为气温,℃; t 为始测日至监测日的累计时间,d; θ 为相对于始测日的累计时间除以100。

为验证 M-ELM 大坝变形安全监控模型在解决大坝变形监测数据的因子不确定性、非线性及抗粗差等方面的优越性,以该水利工程大坝变形原型监测资料为基础,分别进行传统最小二乘法 OLS (ordinary least squares)、人工神经网络 ANN (artificial neural network) 及稳健估计极限学习机 M-ELM 监控模型的建立和拟合预测对比分析。

3.2.1 OLS、ANN 监控模型和分析结果

采用传统最小二乘法和人工神经网络方法进行回归计算所得出的模型拟合及残差效果示例见图3和图4。从图3和图4可以看出,OLS、ANN 监控模型在处理含有异常值的原始数据时,在异常值附近,拟合曲线虽然具有较好的拟合效果,但基本包含了全部异常值的影响,致使拟合曲线发生跳跃,出现追逐异常值的现象。同时,ANN 监控模型在图中表现出了其固有的过拟合缺陷,因此两种模型的抗粗差能力弱的弊端致使建立的大坝变形监控模型难以进行实际应用,极大地降低模型预测能力甚至得出错误的结果。

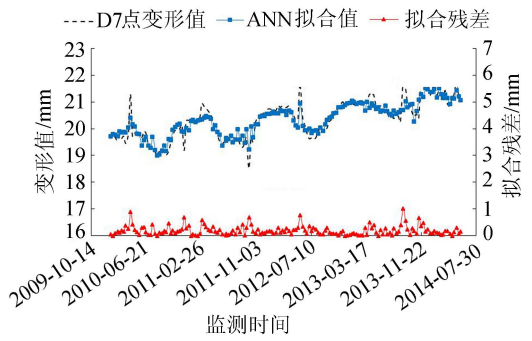


图4 ANN 监控模型拟合及残差效果

3.2.2 M-ELM 监控模型分析结果

采用 M-ELM 算法建立大坝变形监控模型时,根据训练结果的均方差进行网络隐含层节点数的选取,以确保网络训练结果的误差最小,并得到最优的网络参数。模型训练过程中拟合值与实测值均方差与隐含层节点数的关系见图5,当隐含层节点数取15时,训练结果的均方差达到最小值0.3709,因此在本次训练中选取隐含层节点数为15。同样以 D7 监测点为例,M-ELM 大坝变形监控模型分析结果见图6。从图6可以得出:①M-ELM 模型很好的抵抗了异常点对模型计算参数的影响,在异常点处不会产生追逐现象,并且具有很好的拟合效果;②拟合残差在异常值处表现出了明显的波动现象,具有良好的异常值识别能力。综合以上两点可以得出,采用 M-ELM 算法建立的安全监控模型不仅具有较高的拟合精度,同时也具有极强的粗差抵抗能力。




图5 模型训练误差与隐含层节点数的关系




图3 OLS 监控模型拟合及残差效果

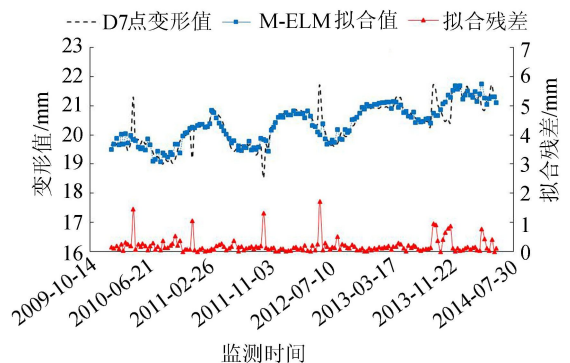


图6 M-ELM 监控模型拟合及残差效果

3.2.3 模型性能对比分析

选取该大坝相同测点 2014 年 6 月 1 日至 2014 年 12 月 11 日之间共 20 个样本作为两种模型的测试样本,以反映模型预测精度的均方误差 M_{SE} 和平均绝对百分误差 M_{APE} 及反映模型鲁棒性的中位数绝对偏差 M_{AD} 进行模型预测效果评价:

$$M_{SE} = \frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2 \quad (12)$$

$$M_{APE} = \frac{100}{n} \sum_{i=1}^n \frac{|y'_i - y_i|}{y_i} \quad (13)$$

$$M_{AD} = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \quad (14)$$

式中: y_i 为效应量实测值; y'_i 为效应量预测值。

3 种大坝变形监控模型预测结果对比如表 1 和图 7 所示(图表中将 2014 年 7 月 11 日异常值 22.378 mm 修正为 21.072 mm,预测值指标计算采用修正值)。

表 1 OLS、ANN、M-ELM 监控模型预测效果对比

模型名称	M_{SE}/mm^2	M_{AD}/mm	$M_{APE}/\%$
ANN	0.15674	0.16984	1.36705
OLS	0.23761	0.27137	1.62971
M-ELM	0.14557	0.16142	1.36833

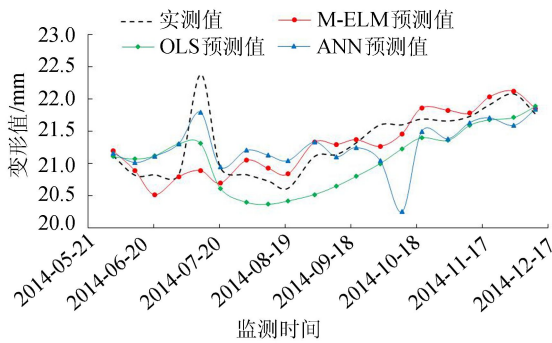


图 7 3 种模型预测值与实测值对比

从表 1 及图 7 可知, M-ELM 监控模型预测的均方误差为 0.14557、中位数绝对偏差为 0.16142、平均绝对百分误差为 1.36833, 模型精度明显优于 OLS 和 ANN 监控模型; 在异常监测值处 M-ELM 监控模型预测结果表现出了明显的鲁棒性和泛化性, 对于监测数据中的粗差具有很强的抗干扰能力, 预测值具有良好的实际参考价值, 而 OLS 和 ANN 监控模型却表现出了明显的波动现象。

4 结论

a. 针对水利工程监测数据存在的非线性、多重共线性及传统最小二乘法抗粗差能力差等问题, 将稳健估计理论引入极限学习机模型中, 建立的基于稳健估计极限学习机的大坝变形监控模型避免了过

学习现象, 具有较高的拟合和预测精度, 并且同时兼有强鲁棒性和泛化性, 其在监测数据拟合预报分析方面具有良好的实用价值。

b. 基于稳健估计极限学习机的大坝变形安全监控模型仍旧属于静态预报模型, 而且属于智能算法中的浅层结构, 在挖掘信息的内部特征来反映结构的真实性态方面还存在一定的缺陷。

c. 随着特大型水利工程建设的发展, 将在线动态学习与之结合, 建立大坝安全实时监测系统, 实现监测自动化是水利工程安全监控的发展趋势, 这些对于监测数据处理的时效性和准确性提出了更高的要求, 因此仍需进一步深度挖掘水利工程安全监测数据中的内部特征, 了解其真实的运行性态。

参考文献:

- [1] 杨令强, 马静, 高蕊. 土石坝加固前后的监测分析及监控模型[J]. 水利学报, 2015, 46(增刊1): 70-73. (YANG Lingqiang, MA Jing, GAO Rui. Monitoring analysis and monitoring model of earth rock dam before and after reinforcement [J]. Journal of Hydraulic Engineering, 2015, 46(Sup1): 70-73. (in Chinese))
- [2] 顾冲时, 吴中如. 大坝与坝基安全监控理论和方法及其应用[M]. 南京: 河海大学出版社, 2006.
- [3] 吴中如, 陈波. 大坝变形监控模型发展回眸[J]. 现代测绘, 2016, 39(5): 3-8. (WU Zhongru, CHEN Bo. Review on development of dam deformation monitoring model [J]. New Mapping, 2016, 39(5): 3-8. (in Chinese))
- [4] 胡德秀, 郭盼, 陈诗怡, 等. 基于最小截平方和估计的监测数据分析方法[J]. 数理统计与管理, 2017, 36(4): 632-640. (HU Dexiu, GUO Pan, CHEN Shiyi, et al. Analysis method of a water engineering safety monitoring data based on the least trimmed square estimation [J]. Journal of Applied Statistics and Management, 2017, 36(4): 632-640. (in Chinese))
- [5] LÉGER P, SEYDOU S. Seasonal thermal displacements of gravity dams located in northern regions [J]. Journal of Performance of Constructed Facilities, 2009, 23(3): 166-174.
- [6] 杨杰, 胡德秀, 吴中如. 大坝安全监控模型因子相关性及不确定性研究[J]. 水利学报, 2004, 35(12): 99-105. (YANG Jie, HU Dexiu, WU Zhongwu. Multiple collinearity and uncertainty of factors in dam safety monitoring model [J]. Journal of Hydraulic Engineering, 2004, 35(12): 99-105. (in Chinese))
- [7] 程琳, 徐波, 吴波, 等. 大坝安全监测的混合回归模型研究[J]. 水电能源科学, 2010, 28(3): 48-50. (CHENG Lin, XU Bo, WU Bo, et al. Research on mixed regression model of dam safety monitoring [J]. Water Resources and Power, 2010, 28(3): 48-50. (in Chinese))

- Chinese))
- [8] 陆美霞. 确定性模型在重力坝变形分析中的应用[J]. 灾害与防治工程, 2009, 16 (1) : 16-20. (LU Meixia. Application of deterministic model in deformation analysis of dam[J]. Disaster and Control Engineering, 2009, 16 (1) : 16-20. (in Chinese))
- [10] 李端有, 周元春, 甘孝清. 混凝土拱坝多测点确定性位移监控模型研究[J]. 水利学报, 2011, 42 (8) : 981-985. (LI Duanyou, ZHOU Yuanchun, GAN Xiaqing. Research on multiple points deterministic displacement monitoring model of concrete arch dam [J]. Journal of Hydraulic Engineering, 2011, 42 (8) : 981-985. (in Chinese))
- [11] 胡德秀, 米艳芳, 杨杰, 等. 突变综合评价理论在滑坡体安全分析中的应用[J]. 西北农林科技大学学报(自然科学版), 2017, 45 (5) : 228-234. (HU Dexiu, MI Yanfang, YANG Jie, et al. Application of catastrophe comprehensive assessment theory in landslide safety analysis [J]. Journal of Northwest A & F University (Natural Science Edition), 2017, 45(5) : 228-234. (in Chinese))
- [12] 许昌, 岳东杰, 董育烦, 等. 基于主成分和半参数的大坝变形监测回归模型[J]. 岩土力学, 2011, 32 (12) : 3738-3742. (XU Chang, YUE Dongjie, DONG Yufan, et al. Regression model of dam deformation monitoring based on principal components and semi-parameters[J]. Rock and Soil Mechanics, 2011, 32 (12) : 3738-3742. (in Chinese))
- [13] 裴亮, 吴震宇, 崔萌, 等. 高土石坝安全监测位移混合模型研究及应用[J]. 四川大学学报(工程科学版), 2012, 44 (增刊1) : 42-47. (PEI Liang, WU Zhenyu, CUI Meng, et al. Research and application on the displacement hybrid-model of high earth dam[J]. Journal of Sichuan University (Engineering Science Edition), 2012, 44 (Sup1) : 42-47. (in Chinese))
- [14] 刘贝贝, 张岚, 金秋. 基于位移场混合模型的棉花滩大坝弹性模量反演分析[J]. 水力发电, 2010, 36 (3) : 55-58. (LIU Beibei, ZHANG Lan, JIN Qiu. Back analysis on the elastic modulus of mianhuatan dam based on displacement field hybrid model[J]. Water Power, 2010, 36(3) : 55-58. (in Chinese))
- [15] 苏怀智, 温志萍, 吴中如, 等. 大坝安全性态的非线性组合监控[J]. 水利学报, 2005, 36 (2) : 197-202. (SU Huaizhi, WEN Zhiping, WU Zhongru, et al. Nonlinear combination monitoring of dam safety [J]. Journal of Hydraulic Engineering, 2005, 36 (2) : 197-202. (in Chinese))
- [16] 谢朋朋, 黄腾, 刘阳. 变权组合预测模型在大坝沉降监测中的应用[J]. 测绘工程, 2015, 24 (4) : 74-76. (XIE Pengpeng, HUANG Teng, LIU Yang. Application of changeable weight combination forecasting model to dam settlement predicting [J]. Engineering of Surveying and Mapping, 2015, 24 (4) : 74-76. (in Chinese))
- [17] 何自立, 杨建国, 靳国云, 等. 基于新维无偏灰色马尔可夫模型的大坝沉降预测研究[J]. 西北农林科技大学学报(自然科学版), 2013, 41 (5) : 213-218. (HE Zili, YANG Jianguo, JIN Guoyun, et al. Dam settlement prediction based on metabolism unbiased grey Markov model[J]. Journal of Northwest A & F University (Natural Science Edition), 2013, 41(5) : 213-218. (in Chinese))
- [18] WANG Ziwei, LU Xiyao, SHEN Zhehui. Application of SVM model in dam deformation prediction [J]. Modern Surveying and Mapping, 2016, 2(16) : 75-78.
- [19] 张豪, 许四法. 基于经验模态分解和遗传支持向量机的多尺度大坝变形预测[J]. 岩石力学与工程学报, 2011, 30 (增刊2) : 3681-3688. (ZHANG Hao, XU Sifa. Multi-scale dam deformation prediction based on empirical mode decomposition and genetic support vector machine [J]. Journal of Rock Mechanics and Engineering, 2011, 30 (Sup2) : 3681-3688. (in Chinese))
- [20] 张磊, 金永强, 李子阳, 等. CPSO-NN 模型在大坝安全监控中的应用[J]. 水利水电科技进展, 2008, 28 (4) : 8-10. (ZHANG Lei, JIN Yongqiang, LI Ziyang, et al. Application of CPSO-NN model in dam safety monitoring [J]. Advances in Science and Technology of Water Resources, 2008, 28(4) : 8-10. (in Chinese))
- [21] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications [J]. Neurocomputing, 2006, 70(1/2/3) : 489-501.
- [22] HUANG G B, ZHOU H, DING X, et al. Extreme learning machine for regression and multiclass classification [J]. IEEE Transactions on Systems Man & Cybernetics, 2012, 42(2) : 513-529.
- [23] HAN H G, WANG L D, QIAO J F. Hierarchical extreme learning machine for feedforward neural network [J]. Neurocomputing, 2014, 128(5) : 128-135.
- [24] 范千, 方绪华. 考虑变形因子模式下基于正则化极限学习机的大坝变形预报方法[J]. 贵州大学学报(自然科学版), 2015, 32 (6) : 57-61. (FAN Qian, FANG Xuhua. Dam deformation prediction method based on regularized extreme learning machine model under considering deformation factors mode [J]. Journal of Guizhou University (Natural Science Edition), 2015, 32 (6) : 57-61. (in Chinese))

(收稿日期: 2018-04-11 编辑: 郑孝宇)