

考虑多重共线性影响的特高拱坝时空监控模型

牛景太,周 华,吴邦彬,邓志平,任长江

(南昌工程学院水利与生态工程学院,江西 南昌 330099)

摘要:为了解决特高拱坝时空监控模型中因子数目众多、因子之间存在多重共线性以及各测点之间存在空间关联性的问题,基于大坝变形原型监测资料,采用核独立分量分析(KICA)方法提取独立分量,将多个测点信息转化为少数几个综合指标;将提取的独立分量代入利用灰狼优化(GWO)算法优化的支持向量机(SVM)模型,对特高拱坝空间测点进行回归预测,构建了 KICA-GWO-SVM 特高拱坝时空监控模型。工程实例分析结果表明,KICA-GWO-SVM 特高拱坝时空监控模型与多元回归模型、BP 模型及 SVM 模型相比,其非线性表达能力强且性能良好,能够降低多重共线性对大坝变形监测的影响,对特高拱坝变形序列的拟合与预测精度高,可以更加准确全面地表征大坝整体的时空变形性态。

关键词:特高拱坝;多重共线性;时空监控模型;核独立分量分析;灰狼优化算法;支持向量机

中图分类号:TV698.1 **文献标志码:**A **文章编号:**1006-7647(2023)01-0029-07

Spatio-temporal monitoring model for super-high arch dams considering multicollinearity effects//NIU Jingtai, ZHOU Hua, WU Bangbin, DENG Zhiping, REN Changjiang(*School of Hydraulic and Ecological Engineering, Nanchang Institute of Technology, Nanchang 330099, China*)

Abstract: In order to solve the problem of large number of factors, multicollinearity between factors and spatial correlation among measuring points in the spatio-temporal monitoring model of super-high arch dams, the kernel independent component analysis (KICA) method was used to extract independent components based on the prototype monitoring data of dam deformation, and the information of multiple measuring points was transformed into a few comprehensive indicators. On this basis, the support vector machine (SVM) model was optimized by using the advantages of grey wolf optimization (GWO) algorithm with good convergence speed and solution accuracy in parameter optimization. The extracted independent components were substituted into the SVM model optimized by GWO algorithm, the regression prediction on the spatial measuring points of the super-high arch dam was performed, and the KICA-GWO-SVM spatio-temporal monitoring model for super-high arch dams was constructed. Analysis of engineering examples shows that, compared with the multiple regression model, BP model and SVM model, the KICA-GWO-SVM spatio-temporal monitoring model has strong nonlinear expression ability and good performance, which can reduce the influence of multicollinearity on dam deformation monitoring, and the fitting and prediction accuracy of the deformation sequence of super-high arch dams is excellent. It can more accurately and comprehensively grasp the overall spatio-temporal deformation behavior of the dam.

Key words: super-high arch dam; multicollinearity; spatio-temporal monitoring model; kernel independent component analysis; grey wolf optimization algorithm; support vector machine

近年来,我国特高拱坝建设发展迅速,先后建成小湾、锦屏、溪洛渡、白鹤滩等 300 m 级特高拱坝。鉴于高拱坝服役环境复杂且特高拱坝一旦失事会严重威胁下游人民群众安全以及带来巨大的社会经济财产损失,其安全稳定问题已成为当前坝工界关注的热点^[1-3]。因此,构建基于原型监测资料的特高拱坝时空监控模型,对于保证特高拱坝安全稳定运行

与长效服役具有十分关键的现实意义。

变形是最能直观反映混凝土坝运行性能的宏观效应量^[4]。大坝时空监控模型克服了传统单测点模型不能合理表征空间变形场内在联系的缺陷,成为当前众多学者竞相研究的热点。王少伟等^[5]利用主成分分析法提取高拱坝空间变形场综合效应量,有效融合了多测点变形监测数据,减少了监控模

基金项目:国家自然科学基金(51969018,51769017,52009054)

作者简介:牛景太(1977—),男,教授,博士,主要从事水工建筑物安全监控研究。E-mail:niujingtai@163.com

通信作者:吴邦彬(1986—),男,讲师,博士,主要从事水工结构工程安全监控与数值仿真研究。E-mail:wubangbin1986@126.com

型数量,并结合有限元模型对大坝变形形态进行计算分析,实现了对高拱坝变形形态的快速诊断;王娟^[6]利用 FastICA 算法,对多个测点特征信息进行提取,再利用相关向量机进行回归预测,建立了基于 FastICA-RVM 的大坝多测点监控模型。但是,大坝时空监控模型中因子数目众多,各测点之间空间关联性以及影响因子间存在严重的多重共线性,使得计算方程不能有效反映各因子对大坝位移造成的影响,很难保证时空模型的拟合精度与稳健性,影响了模型预测结果的真实合理性^[7]。特高拱坝是一个复杂的动态结构,与一般拱坝相比,其坝体结构特性和运行环境更复杂,由此决定了其变形形态更具复杂性、多样性及相关不确定性^[8-9],加之各影响因子之间的多重共线性,如何提高其时空监控模型精度问题显得尤为突出。目前常用的如多元线性回归、逐步回归等回归方法,由于其计算简单高效,常在实际工程建立预测模型时被采用^[10],然而它们不能有效解决和诠释变量中存在的多重共线性问题。近年来,随着人工智能技术高速发展,众多机器学习方法,如支持向量机(support vector machine, SVM)^[11]、人工神经网络^[12-13]、极限学习机^[14]等在大坝时空监控中得到应用,其中 SVM 通过引入核参数将非线性不可分的数据映射到高维空间,其泛化学习能力强,风险误差小,能够较好地处理高维、小样本、非线性数据。但是, SVM 模型的有效性关键在于参数的选取,因此需要找到合适的方法对 SVM 参数进行优化。为了消除多重共线性对大坝监控模型带来的不利影响,部分学者对该问题开展了研究:Chen 等^[15]考虑拱坝变形数据之间的空间关联性,提出一种多目标预测方法,用于拱坝变形的预测和异常检测;Salazar 等^[16]提出了基于增强回归树的大坝变形和渗漏模型,探索了每个预测因子的相对影响;胡德秀等^[17]建立改进的极限学习机大坝变形安全监控模型,改进后的模型较好地解决了由于训练数据存在共线性造成的计算结果较差的问题;欧斌等^[18]应用长短期记忆网络构建了混凝土坝变形预测模型,所建模型具有优秀的非线性数据分析能力;刘斌等^[19]基于五强溪水平位移原型监测资料,利用独立分量回归方法对大坝多点位移进行回归预测,相较于传统的回归方法,此方法有效解决了多测点回归预测模型中影响因子多重共线性导致的病态问题;曹延明等^[20]采用双支持向量机对高拱坝位移数据进行预测分析,并使用人工免疫算法对双支持向量机进行优化,得到了精度更高、速度更快的大坝回归预测模型,较好地处理了复杂的非线性问题。现有的研究成果虽在一定程度上削弱了多重共线性问

题的影响,但本身所存在的局限性也显而易见,特别是对于高坝大库,由于其监测点众多,数据处理量大,海量的测点之间空间关联性与影响因子的多重共线性问题尤为突出,传统时空模型无法综合考虑各测点之间的相互影响,多重共线性消除不够彻底,严重影响了模型的预测精度,因此难以全面掌握特高拱坝整体变形形态^[21]。

为有效解决多重共线性问题,合理有效地表征混凝土特高拱坝的整体变形形态,本文引入核独立分量分析(Kernel independent component analysis, KICA)方法,实现对多个测点位移数据以及影响因子的非线性提取,提取出的位移独立分量去除了冗余信息的干扰,包含了大坝多点监测数据的综合指标,可以通过对少量综合数据的分析实现多个测点的同时监控^[22]。在上述研究的基础上,利用灰狼优化(grey wolf optimization, GWO)算法在参数寻优方面具有良好收敛速度与求解精度的优点,寻求 SVM 模型中参数的最优解,将提取出的独立分量代入 GWO 算法优化的 SVM 模型,进一步对特高拱坝变形序列进行拟合与预测,从而可以获得精度更高且非线性表达能力强的 KICA-GWO-SVM 特高拱坝时空监控模型,降低多重共线性对大坝变形监测的影响,以期更加准确全面地掌握大坝整体的时空变形形态。

1 KICA-GWO-SVM 大坝时空监控模型构建

1.1 特高拱坝变形监测数据核独立分量提取

特高拱坝位移量主要受水压、温度、时效 3 类因子的影响^[23],在外部环境、材料特性以及荷载等因素共同作用之下,各影响因子之间存在较为明显的多重共线性^[24]。同时特高拱坝空间测点数量多,各测点之间也存在一定关联性的影响。KICA 方法在独立分量分析方法的基础上引入核参数,基于整个非线性函数空间来解决问题,提高了对复杂非线性问题的求解精度^[25]。因此,引入 KICA 方法可实现对多测点特征信息综合提取,进一步降维去除各影响因子间的线性相关性,降低测点间的空间关联性,为数据应用及预测分析奠定基础。

假设大坝 n 个测点形成的监测向量 $\mathbf{X}=(x_1, x_2, \cdots, x_n)$,对监测向量进行数据预处理,使监测向量成为零均值和单位方差向量。源信号 $\mathbf{S}=(s_1, s_2, \cdots, s_n)$, $\mathbf{X}$ 与 $\mathbf{S}$ 满足线性组合:

$$\mathbf{X}=\mathbf{A}\mathbf{S} \tag{1}$$

KICA 方法即是求解解混矩阵 $\mathbf{P}$,用已知的 $\mathbf{X}$ 输出估计信号 $\mathbf{Y}$:

$$Y = PX \quad (2)$$

基于上述原理,结合特高拱坝变形原型监测数据,对变形信息进行降维融合处理提取出独立分量,具体步骤如下:

- 给定 KICA 的核参数 $K(x, y)$, 分别输入环境影响因子以及大坝各测点效应量。
- 对输入数据进行中心化和白化处理。
- 利用 Cholesky 分解计算初始独立分量信号 $(y_1, y_2, \dots, y_n)$ 的中心化格莱姆核矩阵。
- 计算解混矩阵 P 的最小化对比函数。
- 给定合适的迭代步长, 计算解混矩阵 P 。
- 若迭代收敛, 则输出环境影响因子、大坝各测点效应量对应的解混矩阵 P 以及独立分量 Y , 否则重新计算。

1.2 GWO 算法优化 SVM

SVM 在解决小样本、非线性以及高维数据时具有较大优势, 且有良好的泛化能力^[26], 其具有的良好非线性分析能力能够有效解决复杂的非线性回归问题, 避免过拟合现象, 因此, SVM 在处理大坝变形预测问题时具有较大的优势, 对于大坝变形与环境量之间复杂的非线性关系, 用 SVM 模型进行回归能取得较好的预测结果^[27]。

由于 SVM 在惩罚因子 c 、核参数 σ 等参数选择方面具有较强的依赖性, 且参数的选取对 SVM 的拟合效果影响较大, 参数选择的合理性决定了 SVM 的学习泛化能力与拟合精度问题。在处理非线性问题时, SVM 核参数选取的合理性直接决定了非线性映射特征空间选取的合理性, 影响计算精度。基于以上问题, 在选取 SVM 参数时应选择最优参数, 使其能够得到良好的计算结果。

GWO 算法^[28] 基于狼群中的等级制度与灰狼捕食猎物活动, 通过由上至下依次为 α 狼、 β 狼、 δ 狼以及最底层的 ω 狼 4 个等级构成的群狼协作机制达到优化的目的, 具备全局搜索能力强、参数少、精度高的优点。考虑到 SVM 的学习能力和泛化能力受参数的影响较为显著, 鉴于 GWO 算法在参数寻优方面调整参数少、全局搜索能力强的良好性能, 通过 GWO 算法对 SVM 的惩罚因子、核参数等参数进行优化, 从而确定最佳参数。

进一步将提取出的降低多重共线性影响的独立分量数据代入 GWO 算法优化的 SVM 进行拟合预测分析, 大坝独立分量变形数据拟合预测主要步骤如下:

- 分别取前 80% 环境影响因子独立分量和效应量独立分量作为训练集, 后 20% 作为测试集。
- 设定灰狼数目、迭代次数以及初始化 α 、 β 、 δ 狼的位置, 确定需要寻优的两个参数为惩罚因子和

核参数, 并设置寻优参数的上下界。

- 计算输出最优参数分别赋给惩罚因子和核参数。
- 使用上述得到的最优参数建立优化的 SVM 模型。
- 将测试集数据导入到优化的 SVM 中进行回归预测。
- 输出预测结果, 对比效应量预测值与特征信息测试集, 并对其进行误差分析。

1.3 KICA-GWO-SVM 时空监控模型构建步骤

本文基于上述方法, 首先采用 KICA 方法实现对特高拱坝变形数据及环境影响因子的特征信息独立分量提取, 再利用 GWO 算法优化的 SVM 模型对监测数据进行非线性预测, 最终构建融合 KICA-GWO-SVM 的大坝时空监控模型。模型实现流程如图 1 所示。

2 算例验证

某水电站位于四川省境内, 总装机容量 840 万 kW, 混凝土双曲拱坝最大坝高 305 m, 坝顶高程 1 885 m, 坝顶宽度 16 m, 水库正常蓄水位 1 880 m。该特高拱坝由 26 个坝段构成, 选取 2013 年 6 月 16 日至 2015 年 9 月 28 日时段内第 5、9、11、13、16、19 坝段垂线的位移测点进行分析, 共布置 24 个监测点, 各测点位置分布如图 2 所示, 该时段内共 274 个径向位移监测数据, 水位过程线及各测点实测位移值如图 3 所示。

持续影响大坝位移的因素包括水压、温度和时效。考虑影响因素对坝体位移影响具有滞后性, 水压因子取 H 、 H^2 、 H^3 、 H^4 , H 代表坝前水深; 温度因子取 $\sin \frac{2\pi t}{365}$ 、 $\cos \frac{2\pi t}{365}$ 、 $\sin \frac{4\pi t}{365}$ 、 $\cos \frac{4\pi t}{365}$; 时效因子取 θ 和 $\ln \theta$, θ 为观测日至始测日的累计天数 t 除以 100。

首先将 24 个测点的位移数据与上述 10 个环境影响因子用 KICA 方法进行独立分量提取, 通过该模型的计算, 提取出 3 个位移独立分量, 如图 4 所示。经计算得独立分量一的贡献率为 95.12%, 独立分量二的贡献率为 3.36%, 独立分量三的贡献率为 0.99%, 其余独立分量贡献率几乎为 0, 由此可见, 提取出的这 3 个分量消除了冗余信息的干扰且融合了多测点位移监测数据 99.3% 的主要信息, 便于后续通过分析这几个包含大坝多测点数据的综合信息指标, 实现对多测点的同步监测, 从而掌握大坝整体的变形性态。经此模型提取出的环境影响因子独立分量的个数为 6 个, 经计算分析, 6 个分量也已




图1 模型构建流程




图2 大坝垂线位移测点分布(单位:m)




图3 研究时段库水位过程线及各测点实测位移值




图4 KICA方法所分离的位移独立分量

包含了原始数据 99.3% 的特征信息,通过此方法合理地选取独立分量个数,可以降低数据维数,减少噪声影响,从而消除影响因子之间的多重共线性。

将上述得到的 3 个独立分量数据分别按贡献率权重计算得一组综合数据 I_{IC} 。将环境影响因子独立分量和效应量 I_{IC} 分别作为模型的输入与输出代入模型进行拟合预测,选取监测日序的前 220 个数据作为训练样本,后 54 个数据作为预测样本,同时设置 GWO 算法参数,设置狼群总数量为 20,最大迭代次数为 50,通过训练 SVM 模型得到惩罚因子与核参数的一组最佳参数为 $c = 1.37, \sigma = 2.60$ 。经 KICA-GWO-SVM 时空监控模型计算后得到一组综合的拟合与预测结果,可以反映大坝整体的时空变形形态,如图 5 所示。

为评价 KICA-GWO-SVM 时空监控模型的性能,将其拟合与预测结果同经 KICA 处理后的多元回归 (MLR)模型、SVM 模型,BP 模型进行比较,结果如图 6




图5 KICA-GWO-SVM 模型拟合与预测




图6 I_{ic} 值拟合与预测曲线

所示,从图中可以看出,本文所建立的模型相比其他模型对表征大坝整体性态的 I_{ic} 值具有更好的拟合与预测效果。为评价 KICA 对该模型的贡献,取测点 PL11-2 作为对照,未对其监测信息进行核独立分量提取,从而建立各类模型对其实测位移进行拟合与预测,结果如图 7 所示。

通过对上述各模型的预测结果进行分析,得到模型预测残差如图 8 所示,可以看出,与其他模型相比,KICA-GWO-SVM 模型残差曲线最平滑,整体预测残差最小,由此可知,KICA-GWO-SVM 时空监控模型的预测效果最佳。

通过最后一步分析对上述各模型的拟合与预测精度进行比较,采用复相关系数 R^2 作为精度评价指标,采用均方误差 MSE、平均绝对误差 MAE、平均绝对百分比 MAPE 作为误差评价指标。

表1 各模型误差及复相关系数计算结果

模型	MAE/mm		MSE/mm		MAPE/%		R^2	
	拟合	预测	拟合	预测	拟合	预测	拟合	预测
KICA-MLR	0.1818	1.1866	0.0471	2.2900	9.24	13.13	0.9969	0.9473
KICA-BP	0.0513	0.9811	0.0042	1.4317	3.67	10.96	0.9997	0.9556
KICA-SVM	0.0620	0.9034	0.0071	1.3768	7.22	10.00	0.9995	0.9455
KICA-GWO-SVM	0.0210	0.3734	0.0011	0.2132	1.34	4.25	0.9999	0.9624
MLR	0.5375	4.5061	0.4736	30.6504	12.20	22.69		
BP	0.2242	4.3683	0.0979	26.5978	5.49	24.64		
SVM	0.2532	3.4961	0.1238	14.9707	6.44	28.58		
GWO-SVM	0.1859	2.6272	0.0773	10.3970	2.78	13.59		




图7 PL11-2 测点拟合与预测曲线




图8 各模型残差对比

各模型复相关系数拟合及预测误差分析结果见表 1。由表 1 可以看出,KICA-GWO-SVM 时空监控模型复相关系数为 0.962 4,精度最高。KICA-GWO-SVM 时空监控模型拟合与预测的 MAE 分别为 0.021 0 和 0.373 4,MSE 分别为 0.001 1 和 0.213 2,MAPE 分别为 1.34% 和 4.25%,与其他各模型相比,均为最小。未采用核独立分量提取的 PL11-2 测点较组合模型相比,误差较大,由此可验证 KICA 方法可在一定程度上削弱多重共线性问题的影响。综上,KICA-GWO-SVM 时空监控模型为特高拱坝最优监控模型,适于大坝时空监控。

3 结 语

基于原型监测数据,利用 KICA 方法融合了坝

体多测点位移监测数据,即用少数几个可以反映大坝整体性态的综合指标来代替包含冗余信息的多测点数据信息,减少了监控模型数量,便于后续通过分析这几个少量综合信息实现对大坝整体的监控,同时实现了对多个测点位移数据以及影响因子的非线性提取,达到消除各测点、各影响因子间相关性的目的。利用 GWO 算法优化 SVM 模型,将提取的独立分量代入 SVM 模型,对特高拱坝空间测点进行回归预测,构建了 KICA-GWO-SVM 特高拱坝时空监控模型。通过工程实例验证了模型的有效性。与其他模型相比,KICA-GWO-SVM 特高拱坝时空监控模型非线性表达能力强且性能良好,能够降低多重共线性对大坝变形监测的影响,对特高拱坝变形序列进行拟合与预测精度高,可以更加准确全面地表征大坝整体的时空变形性态。

参考文献:

[1] 张冲,王仁坤,汤雪娟. 溪洛渡特高拱坝蓄水初期工作状态评价[J]. 水利学报,2016,47(1):85-93. (ZHANG Chong, WANG Renkun, TANG Xuejuan. Safety evaluation of Xiluodu ultra-high arch dam during the initial impoundment period [J]. Journal of Hydraulic Engineering, 2016, 47(1):85-93. (in Chinese))

[2] 黄海兵,吴云星,谷艳昌. 应用聚类算法的大坝安全监控方法[J]. 水利规划与设计, 2021(8):122-126. (HUANG Haibing, WU Yunxing, GU Yanchang. Overview of application research on dam safety monitoring based on clustering algorithm [J]. Water Resources Planning and Design, 2021(8):122-126. (in Chinese))

[3] 赵二峰,顾冲时. 特高拱坝结构性态诊断与监控方法述评[J]. 水利水运工程学报,2022:1-12. (ZHAO Erfeng, GU Chongshi. Review on diagnosis and monitoring methods of structural behavior of superhigh arch dams [J]. Hydro-Science and Engineering, 2022: 1-12. (in Chinese))

[4] 胡江,马福恒,王春红. 特高拱坝变形监测的分区及其模型构建方法[J]. 河海大学学报(自然科学版), 2021,49(2):148-154. (HU Jiang, MA Fuheng, WANG Chunhong. Zoned deformation monitoring and its model building method for super high arch dams [J]. Journal of Hohai University (Natural Sciences), 2021, 49(2):148-154. (in Chinese))

[5] 王少伟,包腾飞,胡坤. 基于 PCA 的高混凝土坝变形空间融合监控模型[J]. 水利水电技术,2018,49(8):123-127. (WANG Shaowei, BAO Tengfei, HU Kun. PCA-based monitoring model for spatial integration of deformation of high concrete dam [J]. Water Resources and Hydropower Engineering, 2018, 49(8):123-127. (in Chinese))

[6] 王娟. 基于盲源分离和相关向量机的大坝安全监测研

究[D]. 西安:西安理工大学,2017.

[7] 徐初,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))

[8] 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))

[9] 李明超,任秋兵,沈扬. 贝叶斯框架下的大坝变形交互式时变预测模型及其验证[J]. 水利学报,2018,49(11):1328-1338. (LI Mingchao, REN Qiubing, SHEN Yang. Prediction model for interactive time series evolution and its verification of dam deformation under Bayesian framework [J]. Journal of Hydraulic Engineering, 2018, 49(11):1328-1338. (in Chinese))

[10] KANG Fei, LIU Xi, LI Junjie. Temperature effect modeling in structural health monitoring of concrete dams using kernel extreme learning machines [J]. Structural Health Monitoring, 2020, 19(4):987-1002.

[11] 魏博文,柳波,徐富刚,等. 融合 PSO-SVM 的混凝土拱坝多测点变形监控混合模型[J]. 武汉大学学报(信息科学版),2021:1-14. (WEI Bowen, LIU Bo, XU Fugang, et al. Multi-point hybrid model based on PSO-SVM for concrete arch dam deformation monitoring [J]. Geomatics and Information Science of Wuhan University, 2021:1-14. (in Chinese))

[12] 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))

[13] 李鹏鹏,苏怀智,郭芝韵,等. 基于人工蜂群算法与 Elman 神经网络的大坝变形监控模型[J]. 水利水电技术,2017,48(3):104-108. (LI Pengpeng, SU Huaizhi, GUO Zhiyun, et al. Artificial bee colony algorithm and Elman neural network-based model for dam deformation monitoring [J]. Water Resources and Hydropower Engineering, 2017, 48(3):104-108. (in Chinese))

[14] 陈优良,肖钢,胡敏,等. 极限学习机与弹性网络支持下的大坝变形预测[J]. 测绘科学,2020,45(11):20-27. (CHEN Youliang, XIAO Gang, HU Min, et al. Dam deformation prediction based on extreme learning machine and elastic network [J]. Science of Surveying and

Mapping,2020,45(11):20-27. (in Chinese))

[15] CHEN Siyu, GU Chongshi, LIN Chaoning, et al. Prediction of arch dam deformation via correlated multi-target stacking[J]. Applied Mathematical Modelling, 2021, 91: 1175-1193.

[16] SALAZAR F, TOLEDO M Á, OÑATE E, et al. Interpretation of dam deformation and leakage with boosted regression trees[J]. Engineering Structures, 2016, 119: 230-251.

[17] 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))

[18] 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))

[19] 刘斌, 戴吾蛟, 曾凡河, 等. 利用独立分量回归建立大坝多测点位移模型[J]. 大地测量与地球动力学, 2016, 36(2): 124-128. (LIU Bin, DAI Wujiao, ZENG Fanhe, et al. Modeling dam displacement of multi-points using independent component regression method[J]. Journal of Geodesy and Geodynamics, 2016, 36(2): 124-128. (in Chinese))

[20] 曹延明, 井德泉, 刘春高. 人工免疫算法优化双支持向量机在拱坝变形预测中的应用[J]. 长江科学院院报, 2019, 36(12): 54-58. (CAO Yanming, JING Dequan, LIU Chungao. Predicting arch dam displacement using twin support vector machine optimized by artificial Immune algorithm[J]. Journal of Yangtze River Scientific Research Institute, 2019, 36(12): 54-58. (in Chinese))

[21] 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))

[22] 李斌. 大坝安全监控的多测点效应量模型研究[D]. 西安: 西安理工大学, 2016.

[23] 吴中如. 水工建筑物安全监控理论及其应用[M]. 南京: 河海大学出版社, 2003.

[24] 牛景太, 姜灵, 邓志平, 等. 基于原型监测资料的特高拱坝变形实时风险率模型[J]. 水资源与水工程学报, 2021, 32(5): 166-174. (NIU Jingtai, JIANG Ling, DENG Zhiping, et al. Real-time risk rate model for deformation of ultra-high arch dams based on prototype monitoring data[J]. Journal of Water Resources and Water Engineering, 2021, 32(5): 166-174. (in Chinese))

[25] BACH F R, JORDAN M I. Kernel independent component analysis[J]. The Journal of Machine Learning Research, 2003, 3: 1-48.

[26] 王颖慧, 苏怀智. 基于 PCA-GWO-SVM 的大坝变形预测[J]. 人民黄河, 2020, 42(11): 130-134. (WANG Yinghui, SU Huaizhi. Dam deformation prediction based on PCA-GWO-SVM model[J]. Yellow River, 2020, 42(11): 130-134. (in Chinese))

[27] 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 analysis of the prediction ability of SVM-based monitoring model for concrete dam deformation[J]. Journal of Yangtze River Scientific Research Institute, 2018, 35(8): 46-50. (in Chinese))

[28] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61.

(收稿日期: 2022-09-04 编辑: 俞云利)

(上接第 21 页)

[30] LILLIEFORS H W. On the Kolmogorov-Smirnov test for normality with mean and variance unknown[J]. Journal of the American Statistical Association, 1967, 62(318): 399-402.

[31] 成静清, 宋松柏. 基于混合分布非一致性年径流序列频率参数的计算[J]. 西北农林科技大学学报(自然科学版), 2010, 38(2): 229-234. (CHENG Jingqing, SONG Songbai. Calculation of hydrological frequency parameters of inconsistent annual runoff series based on mixed distribution[J]. Journal of Northwest A&F University (Natural Science Edition), 2010, 38(2): 229-234. (in Chinese))

[32] 谷洪钦, 刘开磊, 刘玉环, 等. 综合多源不确定性的洪水概率预报试验[J]. 河海大学学报(自然科学版), 2021, 49(2): 99-104. (GU Hongqin, LIU Kailei, LIU Yuhuan, et al. Experiments on flood probability forecasting accounting for multi-source uncertainty[J]. Journal of Hohai University (Natural Sciences), 2021, 49(2): 99-104. (in Chinese))

[33] ANDRIEU C, THOMS J. A tutorial on adaptive MCMC[J]. Statistics and Computing, 2008, 18(4): 343-373.

(收稿日期: 2021-11-23 编辑: 俞云利)