

基于 RUN-XGBoost 算法的土石坝渗流预测模型

马春辉^{1,2}, 侯媛媛^{1,2}, 杨杰^{1,2}, 袁帅^{1,2}, 徐笑颜^{1,2}

(1. 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;

2. 西安理工大学水利水电学院, 陕西 西安 710048)

摘要:针对传统土石坝渗流预测模型存在局部最优、抗干扰性差和预测精度低等问题,通过 RUN 算法优化 XGBoost 算法得到 RUN-XGBoost 算法,构建了 RUN-XGBoost 模型以获得更优的土石坝渗流预测结果。该模型在种群初始化时采用 RUN 算法对 XGBoost 算法的 3 个主要参数进行改进,使预测结果有较高的有效性;通过自动寻找最优参数增进算法的整体收敛速度和预测精度,同时引入随机解,使算法能够排除局部最小值并继续搜索,从而获得全局最优结果。工程实例验证结果表明, RUN-XGBoost 模型具有简洁、高效、预测精度高、鲁棒性强等优点。

关键词:土石坝;渗流监测;RUN-XGBoost 算法;预测模型

中图分类号:TV698.1⁺2;TV641 **文献标志码:**A **文章编号:**1006-7647(2024)02-0072-07

Seepage prediction model of earth-rockfill dams based on RUN-XGBoost algorithm/MA Chunhui^{1,2}, HOU Yuanyuan^{1,2}, YANG Jie^{1,2}, YUAN Shuai^{1,2}, XU Xiaoyan^{1,2} (1. State Key Laboratory of Eco-Hydraulics in Northwest Arid Region of China, Xi'an University of Technology, Xi'an 710048, China; 2. Institute of Water Resources and Hydro-Electric Engineering, Xi'an University of Technology, Xi'an 710048, China)

Abstract: Aiming at the problems of local optimality, poor interference resistance, and low prediction accuracy of the traditional seepage monitoring model for earth-rockfill dams, through optimization of the Extreme Gradient Boosting (XGBoost) algorithm (RUN-XGBoost algorithm) by the Runge Kutta optimizer (RUN) algorithm, a RUN-XGBoost model was constructed to obtain better seepage prediction results. The RUN algorithm is applied to improve the three main parameters of the XGBoost algorithm during the initialization of the population, which gives high validity to the prediction results. The overall convergence speed and prediction accuracy of the algorithm are improved by automatic searching for the optimal parameter. A stochastic variance factor is also introduced to enable the algorithm to exclude local minima and continue the search to obtain a globally optimal result. The validation results of engineering examples show that the RUN-XGBoost model has the advantages of simplicity, high efficiency, high prediction accuracy and robustness.

Key words: earth-rockfill dam; seepage monitoring; RUN-XGBoost algorithm; prediction model

土石坝因其对不同地形条件适应能力强、施工技术简单,在世界各国坝型中的占比一直位居首位^[1],近年来,土石坝坝高更是向 300 m 级迈进,而渗流问题与土石坝的安全运行有着紧密的联系,很多土石坝的失事是由渗流稳定问题引起的^[2]。张建云等^[3]通过对 3 230 座病险水库病害问题的统计分析发现,存在渗流问题的病险水库达 2 344 座,占比 72.6%。渗流是造成土石坝溃坝事故的重要原因,而渗流监测是土石坝结构性态分析的重要内容之一^[4-5],对土石坝渗流情况和发展趋势进行安全监

控和预测预报,从而定量评价土石坝的渗流安全性态,可以有效保证土石坝安全健康运行^[6-8]。

土石坝渗流安全监控通常采用统计模型、确定性模型(有限元分析)和混合模型等,其中统计模型是一种传统的预测模型^[9],凭借成熟的理论基础在实际工程中得到广泛应用。随着机器学习和智能学习理论的发展,支持向量机、极限学习机和 BP 神经网络等基于智能算法的预测模型在大坝渗流安全监控领域得到广泛应用^[10-14]。机器学习能够建立变量间的非线性关系,提高模型预测性能。宋锦焘

基金项目:国家自然科学基金项目(52279140);陕西省自然科学基金基础研究计划一般项目(青年项目)(2023-JC-QN-0562);陕西省教育厅科研计划项目(23JY058)

作者简介:马春辉(1993—),男,讲师,博士,主要从事大坝安全监测与数值仿真研究。E-mail:shanximachunhui@foxmail.com

通信作者:杨杰(1971—),男,教授,博士,主要从事大坝安全监测与无损检测研究。E-mail:yjie9955@126.com

等^[15]针对渗流滞后效应对土石坝渗流预测模型精度的影响问题,采用麻雀搜索算法求解模型滞后效应参数和回归系数的最优值,结果表明,优化后的渗流预测模型精度较高,更接近实际情况;张乾飞等^[16-17]基于土石坝渗流的滞后性,建立了渗流优化滞后模型,研究了典型大坝的渗流性态;康飞^[18]基于差分进化算法与微粒群算法开展了大坝的安全监测以及损伤识别研究;裴亮等^[19]首次将灰色时效模型应用于高土石坝位移混合模型中,结果表明该模型模拟精度高,预测效果好,能够满足工程要求;Demianiuk 等^[20]通过不断改进现有机器学习算法或引入新的机器学习算法描述变量间的非线性关系,以达到提高模型精度的目的。但常规智能预测模型的精度较低,易出现回归错误,且当大坝遇到环境恶劣的情况时,传统模型的预测效果更差。

本文提出了一种基于优化 XGBoost 算法 (RUN-XGBoost 算法) 的土石坝渗流预测模型 (RUN-XGBoost 模型), 该模型综合了龙格-库塔优化 (Runge-Kutta optimizer, RUN) 算法和 XGBoost 算法的优势, 解决了单一模型精度不高的问题, 能有效提高单一 XGBoost 模型预测精度。

1 算法原理与模型构建

1.1 算法原理

1.1.1 XGBoost 算法原理及建模步骤

XGBoost 算法即极限梯度提升 (extreme gradient boosting) 算法^[21], 是梯度增强决策树的改进提升算法, 其算法原理如图 1 所示 (图中实线框为弱分类器, 整个虚线框构成强分类器)。XGBoost 算法优点如下: ①正则化。由于坝体渗流受多种因素影响, 正则项可以有效降低模型的方差, 使训练的模型更加

简单, 防止过拟合。②并行处理。XGBoost 算法在训练之前, 预先对渗流监测数据进行排序处理, 并保存为块结构, 在后续迭代过程中重复使用这个结构, 以减小计算量、节约时间。③降低缺失值的处理难度。对于渗流监测数据, 实际工程中一般会出现输入值缺失的情况, XGBoost 算法在构建树的节点过程中只考虑非缺失值的数据遍历, 且为每个节点增加了一个缺省方向, 当样本相应的特征值缺失时, 可以被归类到缺省方向上, 最优的缺省方向可以从数据中学到, 降低因数据缺失而造成的不稳定性。

XGBoost 算法就是学习一个新函数, 去拟合上一个函数预测的残差, 将每个函数对应的值相加得到该样本的预测值。XGBoost 模型的建模步骤如下: ①初始化每个样本的预测值; ②定义目标函数; ③简化目标函数; ④根据最优切分点划分算法建立决策树; ⑤累加决策树的预测值得到最终预测值。

本文利用 XGBoost 算法对渗流水位进行预测, 通过输入处理好的环境量因子, XGBoost 算法可对每个因子进行预测, 最终将每个因子的预测值相加即可得到最终预测值。

1.1.2 RUN 算法原理及寻优步骤

RUN 算法是 2021 年提出的一种新型智能优化算法^[22], 该算法基于龙格-库塔方法中的计算梯度搜索概念来指导寻优, 使用一组随机解搜索决策空间, 并实现适当的全局和局部搜索。采用四阶龙格-库塔方法搜索决策空间, 使 RUN 算法具有寻优能力强、收敛速度快等特点。


RUN 算法寻找更优参数的流程为: ①随机初始化数据步长、初始点位置、数值解范围并设置最大迭代次数; ②计算初始点的适应度, 并对其排序进而选择出当前最优位置; ③获得当前最优位置, 如果当前最优位置优于上一次迭代的最优位置则更新操作, 否则不进行更新操作; ④继续进行迭代操作直到满足条件为止, 最终得到全局最优位置和最优适应度值。

1.2 目标函数

目标函数是模型训练的重点, 根据计算预测值与真实值之间的误差, 并通过误差反向传播算法, 来更新模型参数。建立目标函数的过程就是寻找设计变量与目标关系的过程, 本文结合渗流监测数据特征以及 RUN 算法和 XGBoost 算法原理, 以均方误差 (MSE) 最小作为目标函数, 其函数表达为

$$F = \min \left(\frac{1}{n} \sum_{i=1}^n [y_i - f(x_i)]^2 \right) \quad (1)$$

式中: y_i 为第 i 个样本的真实值; x_i 为第 i 个样本的输入值; n 为样本数。



图例 ● 决策点 ● 符合判断条件的因子
● 不符合判断条件的因子

图 1 XGBoost 算法原理

1.3 输入数据构造

为了提高预测精度,依据土石坝渗流统计模型构建输入向量。土石坝渗流主要受到上下游水位、降水量以及时效影响,每个影响因子由若干向量组成。根据吴中如院士提出的大坝渗流安全监控模型理论,本文选用的渗流监控统计模型为^[23]

h = f_H(H_0, \bar{H}_{i-j}) + f_P(P_0, \bar{P}_{i-j}) + f_{\theta}(\theta_i, \ln\theta) = (a_0H_0 + \sum_{k=1}^n a_k \bar{H}_{i-j}) + (b_0P_0 + \sum_{k=1}^n b_k \bar{P}_{i-j}) + (c_0\theta + c_1 \ln\theta) \tag{2}

式中: h 为水位; H_0 为监测日水位; P_0 为监测日降水量; f_H, f_P, f_{θ} 分别为水位因子、降水因子和时效因子; $\bar{H}_{i-j}$ 为监测日前的第 i 日到第 j 日的平均水位; $\bar{P}_{i-j}$ 为监测日前第 i 日到第 j 日的平均降水量; θ 为时效分量,取始测日至监测日的累加日数除以 100; $a_0, a_k, b_0, b_k, c_0, c_1$ 为回归系数。

对输入因子的选取如下:①由于土石坝渗流大部分时间处于不稳定渗流状态,渗流测点水位的变化总是滞后于库水位的变化^[24],因此取监测日上游水位 H_{up0} 和监测日前 1 ~ 5、10 ~ 20、20 ~ 30、30 ~ 60 d 的上游平均水位 $H_{up1-5}, H_{up10-20}, H_{up20-30}, H_{up30-60}$ 5 个因子作为上游库水位影响因子。下游库水位变化较小,因此仅选择监测日下游水位 H_{d0} 作为影响因子。②在降雨过程中,入渗引起的渗流测点水位变化存在一定的滞后效应,因此降水因子取 $P_{1-10}, P_{10-20}, P_{20-30}$ 和 P_{30-60} ,分别对应监测日前 1 ~ 10、10 ~ 20、20 ~ 30、30 ~ 60 d 的平均降水量。③土石坝竣工蓄水后会引引起土体颗粒发生变化,这种变化对渗流的影响有一个时效过程,因此时效因子取为 $\theta, \ln\theta$ 。故模型输入层共 12 个因子,输出层仅渗流测点水位一个因子。

1.4 RUN-XGBoost 模型的构建与预测流程

XGBoost 算法适合处理非线性关系的小数据集,且处理稀疏数据能力强,模型预测值与渗流实测值的误差较小,但其调参较复杂,因此引入 RUN 算法对参数进行寻优。RUN-XGBoost 模型通过 RUN 算法优化 XGBoost 的 3 个主要参数,能有效地提高 XGBoost 算法预测精度,缩短计算时间。

RUN-XGBoost 模型构建及预测流程如图 2 所示,具体步骤如下^[25]:

步骤 1 设 S 组训练数据集为 $\{(X_k, Y_k) | k=1, 2, \dots, S\}$, 其中每个输入数据均由 m 个因子组成,即 $X_k = \{X_{k1}, X_{k2}, \dots, X_{km}\}$, 输出数据为 Y_k 。采用线性函数法对样本输入数据 $X_{kz}(z=1, 2, \dots, m)$ 进行归一化处理。

步骤 2 将数据分为训练集和测试集两部分,




图 2 RUN-XGBoost 模型构建及预测流程

采用训练集数据对模型进行训练,并评估模型的计算精度。

步骤 3 模型的主要参数包括 XGBoost 算法中的迭代次数、树的深度、学习率, RUN 算法的参数主要有初始梯度解数量、最大迭代次数。通过 RUN 算法调整 XGBoost 算法参数,循环代入步骤 2 中进行计算,当模型在训练集内的测试误差达到最小时,此迭代步的参数设置值为最优参数值。

步骤 4 用训练好的最优参数模型对测试集进行预测,并采用均方根误差(RMSE)、平均绝对误差(MAE)、相关系数(R^2) 3 个评价指标全面评估 RUN-XGBoost 模型的预测性能。

RUN-XGBoost 模型构建及预测过程中还需注意以下问题:

a. 在构建模型时首先进行数据归一化处理,归一化后再将数据分为训练集和预测集。归一化数据包含预测数据时,模型预测精度会有大幅度的提高,因为进行数据归一化处理时包含预测数据归一化结果更加合理。

b. 评价指标 R^2 越接近 1 表明预测结果越好; RMSE 能直接反映预测模型的整体误差,其值越小表明预测结果与真实值越接近; MAE 不受数据尺度的影响,其值越小表明模型的极值预测精度越高,效果越好,以此检验模型的泛化性能^[26-27]。

2 工程实例验证

2.1 工程概况

某工程为碾压式壤土心墙土石坝,坝顶长 297.36 m,宽 8 m。心墙由重、中粉质壤土与粉质黏土填筑,坝壳由砂砾石填筑。为保证大坝的安全运行,该工程布设了较为全面的安全监测系统,其中渗流测点平面布置及横剖面布置如图 3 所示。由于心

墙坝 3 种填充料渗流情况存在较大差别,为全面验证 RUN-XGBoost 模型的监测效果,选取上游测点 J1、心墙测点 HL2 和下游测点 F8 作为代表测点,选择 2010 年 1 月 25 日至 2010 年 8 月 13 日的环境量与渗流监测数据来验证模型。




图 3 大坝渗流测点布置示意图

2.2 预测结果分析

对于 J1 测点选择 198 个样本用于训练模型, 35 个样本作为测试集; HL2 测点选择 196 个样本用于训练模型, 34 个样本作为测试集; F8 测点选择 172 个样本用于训练模型, 34 个样本作为测试集。分别采用 3 个不同测点数据训练 RUN-XGBoost 模型, 验证该模型对于心墙坝典型部位的渗流预测精度。通过 RUN 算法对 XGBoost 算法的 3 个主要参数进行优化, 最优参数为训练集内的 RMSE 达到最小时所选取的参数, 优化后 3 个测点 RUN-XGBoost 模型的参数如表 1 所示。

表 1 RUN-XGBoost 模型最优参数

测点	迭代次数	树的深度	学习率
J1	99	12.9973	0.1000
HL2	99	12.9850	0.0973
F8	100	12.6824	0.0997

RUN-XGBoost 模型训练结果如图 4 所示, 可以看出 RUN-XGBoost 模型对于上游 J1 测点的训练效果最佳, 水位在 695 m 左右时训练效果较好, 水位为 704 m 左右时训练值较实测值偏小, 偏差在 0 ~ 5.52 cm 之间; HL2 测点位于心墙处, 训练效果比 J1 测点差, 水位 694 m 时训练结果较为准确, 水位 705 m 时训练值较实测值偏小, 偏差在 0 ~ 50.48 cm;

该模型对于下游 F8 测点实测数据训练效果最差, 622.8 m 为实测较高水位, 该水位处的训练值比实测值小, 622.0 m 为实测较低水位, 该水位训练值比实测值偏高, 偏差在 0 ~ 20.34 m 之间。由图 4 散点的离散程度可以明显看出越靠近下游训练效果越差, 这是由于心墙有效减小了土石坝渗流, 使得下游侧的渗流与环境量的相关性减小, 因此采用环境量作为影响因子时模型训练效果较差。




图 4 RUN-XGBoost 模型训练结果

RUN-XGBoost 模型训练集评价指标计算结果如表 2 所示, 可以直观得出 RUN-XGBoost 模型对 J1、HL2、F8 测点的相关性依次降低; HL2 和 F8 测点预测值的 RMSE 分别是 J1 测点的 73 倍和 34 倍, RUN-XGBoost 模型对 J1 测点的预测精度最佳, 且水位较低时的预测结果更准确; HL2 和 F8 测点预测值的 MAE 分别是 J1 测点的 51 倍和 16 倍, RUN-XGBoost 模型对 HL2 测点个别样本的预测结果差异较大。

表 2 RUN-XGBoost 模型训练集评价指标

测点	R^2	RMSE/m	MAE/m
J1	0.99900	0.00160	0.00176
HL2	0.98164	0.11695	0.09023
F8	0.94946	0.05456	0.02934

采用训练好的 RUN-XGBoost 模型对渗流数据进行预测, 预测结果如图 5 和表 3 所示。由图 5 和表 3 可知: ① J1 测点 RUN-XGBoost 模型预测精度最




图5 RUN-XGBoost 模型预测结果

表3 RUN-XGBoost 模型预测集评价指标			
测点	R^2	RMSE/m	MAE/m
J1	0.98281	0.50362	0.38069
HL2	0.94258	0.21046	0.07963
F8	0.86449	0.08820	0.04383

表4 7个渗流测点 RUN-XGBoost 模型训练集、预测集评价指标				
数据集	测点	R^2	RMSE/m	MAE/m
训练集	HL3	0.99883	0.00225	0.03030
	F3	0.94034	0.05380	0.04317
	F4	0.94322	0.01026	0.00754
	F7	0.95533	0.02750	0.05749
	F9	0.94201	0.05704	0.04554
	F11	0.97900	0.03864	0.03012
	F12	0.96688	0.04507	0.03280
预测集	HL3	0.96270	0.02548	0.21216
	F3	0.82213	0.02996	0.02413
	F4	0.79017	0.09405	0.06590
	F7	0.88087	0.49969	0.26341
	F9	0.81014	0.12107	0.05408
	F11	0.89320	0.07170	0.04681
	F12	0.88366	0.26449	0.11514

佳,无论是低水位还是高水位预测值均接近实测值,整体精度较高;最大绝对误差为 0.11 m,对极值预测结果准确。②HL2 测点渗流主要受上游水位影响,与输入因子具有较强相关性,因此预测结果总体精度较高,仅对个别点预测结果偏差较大,最大绝对误差为 0.55 m。③F8 测点 RUN-XGBoost 模型预测精度明显降低,个别样本点预测结果误差大,但整体预测结果准确。

为进一步验证 RUN-XGBoost 模型的可靠性,对大坝另外 7 个渗流测点进行预测分析,结果如表 4 所示。由表 4 可知,RUN-XGBoost 模型对于心墙处测点 HL3 的预测精度比 HL2 更高,最靠近下游侧的测点 F4 预测精度最低,但其相关性仍接近 0.8,误差总体较小,证明了 RUN-XGBoost 模型预测壤土心墙土石坝渗流可靠度高,鲁棒性强。

2.3 不同模型的预测精度对比

采用相同结构和参数设定的标准 XGBoost 模型、统计回归模型对相同的数据样本进行训练和仿真预测,对比 3 种模型的预测效果。图 6 为 J1、HL2、F8 测点的预测结果。

由图 6 可知:①测点越靠近下游,3 种模型的预测效果越差,这是由于下游测点渗流受上游水位变化影响较小,渗流与水位间的关系更为复杂导致的;




图6 3种模型预测结果对比

表 5 各测点不同模型评价指标

模型	R^2			RMSE/m			MAE/m		
	J1	HL2	F8	J1	HL2	F8	J1	HL2	F8
统计模型	0.856 52	0.775 61	0.471 47	0.952 21	0.621 35	0.459 82	0.645 87	0.432 86	0.235 46
XGBoost 模型	0.960 00	0.920 00	0.738 15	0.717 74	0.247 64	0.122 60	0.493 62	0.113 96	0.058 56
SSA-XGBoost 模型	0.982 68	0.939 49	0.863 78	0.505 45	0.212 04	0.084 26	0.385 02	0.089 41	0.044 68
RUN-XGBoost 模型	0.982 81	0.942 58	0.864 49	0.503 62	0.210 46	0.088 20	0.380 69	0.079 63	0.043 83

RMSE 和 MAE 都比 SSA-XGBoost 模型小。RUN-XGBoost 模型对 3 个测点的各项评价指标都最佳,模型拟合的效果最好,预测精度最高,可见对 XGBoost 模型的改进是成功的。

RUN-XGBoost 模型和 SSA-XGBoost 模型的适应度变化过程如图 7 所示,RUN-XGBoost 模型仅迭代 17 次即可寻得最优参数,而 SSA-XGBoost 模型需要迭代 38 次,在实际运行过程中 RUN-XGBoost 模型的计算速度更快。综合来看,RUN-XGBoost 模型对该土石坝渗流监测数据的预测精度高、稳定性强,满足土石坝渗流监测要求,可应用于土石坝安全监测。




图 7 RUN、SSA 算法适应度变化过程对比

3 结 语

本文针对传统的单一大坝安全预测模型存在渗流预测精度较差、稳定性差等问题,通过 RUN 算法优化 XGBoost 算法,充分发挥 XGBoost 算法计算精度高、计算速度快的特点,构建了基于 RUN-XGBoost 算法的土石坝渗流预测模型,并通过工程实例验证了该模型具有更高的预测精度和训练效率,在土石坝渗流预测中具有实用性。对土石坝而言,由于心墙的防渗效果,导致下游的渗流数据与库水位间的非线性关系变得更为复杂,表现为测点位置越偏向下游侧,其渗流监测值拟合效果越差、预测精度越差,但也从侧面证明了心墙的防渗效果良好。

参考文献:

[1] 黄昊冉,吴云星,冯春燕,等. 基于高密度电法探测与渗流监测的土石坝渗漏隐患综合研判[J]. 水力发电, 2022,48 (8) : 55-60. (HUANG Haoran, WU Yunxing, FENG Chunyan, et al. Comprehensive judgment of leakage hidden danger of embankment dam based on high-density

electrical method and seepage monitoring [J]. Water Power,2022,48(8) :55-60. (in Chinese))

[2] 苏怀智,周仁练. 土石堤坝渗漏病险探测模式和方法研究进展[J]. 水利水电科技进展,2022,42 (1) : 1-10. (SU Huaizhi, ZHOU Renlian. Research progress and prospect of earth-rockfill dam leakage detection modes and method[J]. Advances in Science and Technology of Water Resources,2022,42(1) :1-10. (in Chinese))

[3] 张建业,杨正华,蒋金平. 我国水库大坝病险及溃决规律分析[J]. 中国科学:技术科学,2017,47(12) :1313-1320. (ZHANG Jianyun, YANG Zhenghua, JIANG Jinping. An analysis on laws of reservoir dam defects and breaches in China [J]. Scientia Sinica Technologica, 2017,47(12) :1313-1320. (in Chinese))

[4] CASTRO-DOMINGUEZ Y, LI Jun, SHARMA A. SVM communications: contrast media shortage and society updates[J]. Vascular Medicine,2022,27(5) :525-527.

[5] FANG Xiao, ZENG Yajie, XIONG Feng. A review of previous studies on dam leakage based on distributed optical fiber thermal monitoring technology [J]. Sensor Review,2021,41(4) :350-360.

[6] 沈添耀,董海洲. 基于高密度电法和综合示踪法的堤坝渗漏通道联合探测方法[J]. 水利水电科技进展,2023, 43 (2) : 63-69. (SHEN Tianyao, DONG Haizhou. Combined detection method of dam leakage channels based on high-density electrical method and comprehensive tracer method [J]. Advances in Science and Technology of Water Resources,2023,43(2) :63-69. (in Chinese))

[7] 宋锦焄,袁帅,刘云贺,等. 土石坝渗流安全监控的集成学习融合模型[J]. 水力发电学报,2023,42 (5) : 107-119. (SONG Jintao, YUAN Shuai, LIU Yunhe, et al. Integrated learning fusion model for seepage safety monitoring of rockfill dams [J]. Journal of Hydroelectric Engineering,2023,42(5) :107-119. (in Chinese))

[8] 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))

- [9] LI Xing, WEN Zhiping, SU Huaizhi. An approach using random forest intelligent algorithm to construct a monitoring model for dam safety [J]. Engineering with Computers, 2021, 37(1) : 39-56.
- [10] 向镇洋, 包腾飞, 白妍丽, 等. 基于混合注意力机制和深度学习的大坝变形预测模型[J]. 水利水电科技进展, 2023, 43(2) : 96-101. (XIANG Zhenyang, BAO Tengfei, BAI Yanli, et al. Dam deformation prediction model based on mixed attention mechanism and deep learning [J]. Advances in Science and Technology of Water Resources, 2023, 43(2) : 96-101. (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] 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 Zhongru. Multiple co-linearity and uncertainty of factors in dam safety monitoring model [J]. Journal of Hydraulic Engineering, 2004, 35(12) : 99-105. (in Chinese))
- [13] 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.
- [14] 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.
- [15] 宋锦焘, 袁帅, 段梦强, 等. 基于麻雀搜索算法和滞后效应的土石坝渗流监控模型[J]. 水利水电科技进展, 2022, 42(5) : 52-57. (SONG Jintao, YUAN Shuai, DUAN Mengqiang, et al. Seepage pressure monitoring model for earth-rockfill dams based on sparrow search algorithm and hysteresis effect [J]. Advances in Science and Technology of Water Resources, 2022, 42(5) : 52-57. (in Chinese))
- [16] 张乾飞, 顾冲时, 吴中如. 基于滞后效应的土石坝渗流监控模型[J]. 水利学报, 2001, 32(2) : 85-89. (ZHANG Qianfei, GU Chongshi, WU Zhongru. Seepage flow monitoring model for rockfill-earth dams based on lag effect [J]. Journal of Hydraulic Engineering, 2001, 32(2) : 85-89. (in Chinese))
- [17] 余正源, 黄耀英, 费大伟, 等. 基于滞后效应函数的土石坝渗流统计模型分析[J]. 中国农村水利水电, 2022(6) : 227-232. (YU Zhengyuan, HUANG Yaoying, FEI Dawei, et al. An analysis of the seepage statistics model of earth-rock dams based on hysteresis effect function [J]. China Rural Water and Hydropower, 2022(6) : 227-232. (in Chinese))
- [18] 康飞. 大坝安全监测与损伤识别的新型计算智能方法[D]. 大连: 大连理工大学, 2009.
- [19] 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))
- [20] DEMIANIUK A, STEFANYSHYN D. The prognostic modelling of piezometric levels based on seepage monitoring in earthen dams [J]. MATEC Web of Conferences, 2020, 322(1) : 01047.
- [21] CHEN Tianqi, GUESTRIN C. XGBoost: a scalable tree boosting system [C] // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco: ACM, 2016: 785-794.
- [22] AHMADIANFAR I, HEIDARI A A, GANDOMI A H, et al. RUN beyond the metaphor: an efficient optimization algorithm based on Runge Kutta method [J]. Expert Systems with Applications, 2021, 181: 115079.
- [23] 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.
- [24] 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))
- [25] 马春辉, 杨杰, 程琳, 等. 基于 KPCA-RVM 的土石坝沉降预测模型研究[J]. 西北农林科技大学学报(自然科学版), 2017, 45(1) : 211-217. (MA Chunhui, YANG Jie, CHENG Lin, et al. KPCA-RVM based prediction model for settlement of earth-rockfill dam [J]. Journal of Northwest A&F University (Natural Science Edition), 2017, 45(1) : 211-217. (in Chinese))
- [26] WANG Shaowei, XU Yingli, GU Chongshi, et al. Monitoring models for base flow effect and daily variation of dam seepage elements considering time lag effect [J]. Water Science and Engineering, 2018, 11(4) : 344-354.
- [27] WEN Zhiping, FAN Zhendong, SU Huaizhi. An APPSO-SVM approach building the monitoring model of dam safety [J]. Soft Computing, 2022, 26(21) : 11451-11459.

(收稿日期: 2023 - 04 - 22 编辑: 熊水斌)