

DOI: 10.20040/j.cnki.1000-7709.2026.20251491

基于 OLHS-IAOO-KELM 的尾矿坝渗透系数反演模型及应用

管子懿^a, 沈振中^{a,b}

(河海大学 a. 水利水电学院; b. 水文水资源与水利工程科学国家重点实验室, 江苏 南京 210098)

摘要: 尾矿坝是由尾砂长期堆积而成的, 分层复杂、渗透系数不均一, 为获取能反映其整体渗透特性的代表性渗透系数, 提出一种新的反演方法。采用最优拉丁超立方抽样(OLHS)获取均布的尾矿坝渗透系数组合样本, 将其代入有限元模型进行正分析得到测点水头值样本, 两者结合构成数据集, 通过核极限学习机(KELM)建立从渗透系数到测点水头的非线性映射关系, 利用融合拉丁超立方抽样初始化种群、重心反向学习和自适应趋优边界改进的不实野燕麦优化(IAOO)算法对 KELM 的超参数进行优化, 建立了基于 OLHS-IAOO-KELM 的尾矿坝渗透系数反演模型, 并将其应用于工程实例中。通过该模型反演得到的尾矿坝渗透系数值合理, 7 个测点经渗流正分析得到的计算水头和实测水头的相对误差不超过 2.08%, 满足工程精度要求, 且尾矿坝典型断面的渗流场位势分布符合一般规律。与其他模型相比较, 该模型的反演结果误差最小。该模型的准确性和鲁棒性高, 在尾矿坝渗透系数反演中具有实用价值。

关键词: 尾矿坝; 渗透系数; 反演分析; 改进不实野燕麦优化算法; 核极限学习机

中图分类号: TV649

文献标志码: A

文章编号: 1000-7709(2026)01-0138-05

An OLHS-IAOO-KELM-Based Inversion Model for Permeability Coefficient of Tailings Dams and Its Application

GUAN Zi-yi^a, SHEN Zhen-zhong^{a,b}

(a. College of Water Conservancy and Hydropower Engineering; b. State Key Laboratory of Hydrology-Water Resources and Hydraulic Engineering, Hohai University, Nanjing 210098, China)

Abstract: Tailings dams are formed through long-term accumulation of tailings, featuring complex stratification and non-uniform permeability coefficients. To obtain representative permeability coefficients that reflect their overall permeability characteristics, a novel inversion method was proposed. Optimal Latin Hypercube Sampling (OLHS) was used to obtain uniformly distributed samples of permeability coefficient combinations for tailings dams. These samples were then input into a finite element model for forward analysis to obtain corresponding samples of water heads at monitoring points. The two sets of samples were combined to form a dataset. A nonlinear mapping relationship from the permeability coefficients to the water heads at monitoring points was established using the Kernel Extreme Learning Machine (KELM). The hyperparameters of the KELM were optimized using an Improved Animated Oat Optimization (IAOO) algorithm, which integrated Latin Hypercube Sampling for population initialization, centroid opposition-based learning, and an adaptive optimal-seeking boundary mechanism. An inversion model for the permeability coefficient of tailings dams based on OLHS-IAOO-KELM was thus established and subsequently applied to a practical engineering case. The permeability coefficient values obtained through the inversion model were reasonable. The relative errors between the calculated water heads from forward seepage analysis and the measured water heads at the seven monitoring points did not exceed 2.08%, meeting the engineering accuracy requirements. Furthermore, the potential distribution of the seepage field in a typical cross-section of the tailings dam conformed to general patterns. Compared with other models, the inversion result of the proposed model exhibited the smallest errors. The proposed model demonstrates high accuracy and robustness, and possesses practical value for the inversion of permeability coefficients in tailings dams.

Key words: tailings dam; permeability coefficient; inversion analysis; Improved Animated Oat Optimization algorithm; Kernel Extreme Learning Machine

收稿日期: 2025-08-26, 修回日期: 2025-09-21, 接受日期: 2025-09-25

基金项目: 国家自然科学基金面上项目(52179130)

作者简介: 管子懿(2000-), 男, 硕士研究生, 研究方向为水利工程渗流特性分析控制, E-mail: guanyz_hhu@163.com

通讯作者: 沈振中(1968-), 男, 教授、博导, 研究方向为工程渗流特性分析控制, E-mail: zhzhshen@hhu.edu.cn

1 引言

渗透破坏是尾矿坝失事的主要原因,因此渗流安全问题备受关注。尾矿坝的渗透系数是进行渗流计算和评价的关键参数,由于尾矿坝使用逐层堆筑的建设方法,存在分区多、渗透系数随机性强的特点,研究中常采用概化分层的方式构建模型,如陈铁亮等^[1]建立了分层的尾矿坝三维有限元模型并计算,验证了扩容工程安全可靠;王神尼^[2]基于概化分层的尾矿坝三维模型,分析了防渗措施失效的影响。然而,现有研究在确定各分层的渗透系数上存在不足,如根据工程资料直接取值,难以保证计算模型能反映尾矿坝的实际渗流特性;用人工试算法反演,效率低且精度差。当前机器学习算法在工程渗流反演中应用广泛,如邹超英等^[3]用 BP 神经网络成功反演某土石坝的渗透系数,证明方法可靠;李永超等^[4]基于支持向量机反演某心墙坝渗流参数,结果精度较高。但部分算法存在易陷入局部最优、训练效率低等缺点,针对尾矿坝反演维度高的特点,本文引入训练效率高、泛化能力强的核极限学习机(KELM)作为基础模型,结合全局搜索能力强、收敛速度快的改进不实野燕麦优化(IAOO)算法对 KELM 的核参数和正则化系数进行优化,同时使用最优拉丁超立方抽样(OLHS)生成均布的渗透系数反演数据集,构建 OLHS-IAOO-KELM 组合模型,以期对尾矿坝渗透系数实现精确反演。

2 基本原理

2.1 最优拉丁超立方抽样(OLHS)

拉丁超立方抽样(LHS)是一种高效的多元分层随机抽样技术,能以较少的样本实现高参数空间覆盖率。使用 LHS 在多维空间抽取 N 个样本点的步骤^[5]为:将每一维划分为 N 个等概率且互不重叠的区间;在每个区间内随机抽取一个值;将各维度抽取的样本值以随机顺序配对,组成 N 个样本点。

尽管 LHS 在单维上能确保均匀分布,但在多维组合时仍存在随机性。为此,最优拉丁超立方抽样(OLHS)在 LHS 的基础上引入评价函数 ϕ_p 来衡量并优化样本点的空间均匀性^[6]:

$$\phi_p = \left(\sum_{i=1}^n J_i d_i^{-p} \right)^{1/p} \quad (1)$$

式中, n 为样本点两两距离不相等的个数; J_i 为

距离等于 d_i 的样本点对数量; d_i 为第 i 个样本点对距离值; p 为 p 范数,这里取 2。

ϕ_p 越小表示空间均匀性越好。在每一维内随机交换值,接受 ϕ_p 降低的交换,重复操作直至最大迭代次数。通过 OLHS 获取均布的样本帮助改进模型的精度和泛化能力。

2.2 改进的不实野燕麦优化(IAOO)算法

2.2.1 不实野燕麦优化算法

不实野燕麦优化(AOO)算法的灵感来源于不实野燕麦种子借助芒在地面滚动和弹跳,寻找有利萌发地点^[7]。算法包含探索和利用两个阶段,探索阶段模拟种子通过风、水或动物传播,进行随机的全局搜索,利用阶段模拟种子由湿度驱动的滚动或弹射行为,进行局部寻优或脱离当前区域。通过模拟种子的三种传播方式,该算法获得强大的全局搜索能力,不易陷入局部最优。

2.2.2 初始种群优化

在元启发式算法中,若初始种群在解空间中分布的均匀性较差,会降低寻优速度和全局搜索能力,因此使用 LHS 方法替代原算法的随机初始化,增强初始种群的空间均匀性,提高算法的精度与收敛速度。OLHS 虽能生成均匀性更佳的初始种群,但其迭代优化过程计算繁琐、耗时长,综合考虑效率和效果,选择 LHS 方法。

2.2.3 重心反向学习

AOO 算法在探索阶段采用随机搜索策略,具有强大的全局搜索能力,但寻优速度较慢。对此,引入重心反向学习策略,通过在每次迭代位置更新后生成反向解扩大搜索范围,在保持全局搜索能力的同时提升收敛速度。

在 D 维空间中,包含 N 个个体的种群重心为:

$$M_j = \frac{1}{N} \sum_{i=1}^N X_{i,j} \quad j=1,2,\dots,D \quad (2)$$

$$M = (M_1, M_2, \dots, M_D) \quad (3)$$

式中, M_j 为第 j 维的种群重心; N 为个体总数; $X_{i,j}$ 为第 i 个体在 j 维的位置; M 为种群在 D 维空间的重心。

种群中个体的反向解为:

$$\overline{X}_i = 2M - X_i \quad i=1,2,\dots,N \quad (4)$$

式中, $\overline{X}_i$ 为第 i 个体的反向解; X_i 为第 i 个体的位置。

合并原始种群和反向种群,选择适应度前 50% 的个体,作为更新后的种群。

2.2.4 自适应趋优边界

原算法每次迭代有 50% 的概率执行探索阶段,若连续几轮迭代均进入探索阶段,无法进行精

细寻优。渗透系数反演问题边界狭窄,对局部寻优能力要求高,对此提出自适应趋优边界:

$$b_u^* = (b_u + X^*)/2 \quad (5)$$

$$b_l^* = (b_l + X^*)/2 \quad (6)$$

式中, b_u^* 、 b_l^* 分别为趋优上、下界; b_u 、 b_l 分别为搜索上、下界; X^* 为当前最优个体。

在每次迭代完成探索、利用阶段和重心反向学习后,将所有个体处于趋优边界外的维度拉回趋优边界内,若下一次迭代执行探索阶段,更靠近最优位置的种群有利于提高局部寻优性能。

2.2.5 IA00 性能验证

为验证 IA00 的改进效果,选取 30 维 CEC2017 测试函数的单峰函数 F_1 、 F_3 和多峰函数 F_4 、 F_5 、 F_7 、 F_9 进行测试,并与原始 A00、蜣螂优化器(DBO)、粒子群优化(PSO)、灰狼优化器(GWO)算法对比。每个算法独立运行 30 次,种群数量均为 30,迭代次数均为 500,统计寻优结果的平均值和标准差见表 1。由表 1 可看出,与原始 A00 算法相比,IA00 的收敛精度和稳定性平均提升 29.58%和 28.82%,收敛速度更快。在测试函数上,IA00 的寻优精度和稳定性均胜过其他算法,证明了改进的有效性。

表 1 不同算法在测试函数上的性能对比

Tab. 1 Performance comparison of different algorithms on test functions

函数	评价指标	IA00	A00	DBO	PSO	GWO
F_1	平均值	5.55×10^4	7.33×10^4	2.74×10^8	6.41×10^8	2.50×10^9
	标准差	2.33×10^4	2.80×10^4	1.89×10^8	1.06×10^9	1.64×10^9
F_3	平均值	3.89×10^3	2.31×10^4	9.15×10^4	6.96×10^4	6.08×10^4
	标准差	1.54×10^3	9.19×10^3	2.23×10^4	3.17×10^4	1.36×10^4
F_4	平均值	5.00×10^2	5.13×10^2	6.53×10^2	5.97×10^2	6.32×10^2
	标准差	2.18×10^1	3.00×10^1	1.58×10^2	1.80×10^2	9.67×10^1
F_5	平均值	6.08×10^2	6.27×10^2	7.51×10^2	6.29×10^2	6.26×10^2
	标准差	2.56×10^1	3.12×10^1	5.51×10^1	3.73×10^1	3.32×10^1
F_7	平均值	8.47×10^2	8.69×10^2	1.01×10^3	8.85×10^2	9.00×10^2
	标准差	3.67×10^1	4.15×10^1	7.68×10^1	5.35×10^1	3.94×10^1
F_9	平均值	2.38×10^3	3.59×10^3	6.89×10^3	3.84×10^3	2.77×10^3
	标准差	1.01×10^3	1.58×10^3	2.05×10^3	2.60×10^3	1.17×10^3

为明确各改进策略的贡献,进行消融试验,结果见表 2。由表 2 可看出,IA00 分别去除初始种群优化(IA00-A)、重心反向学习(IA00-B)和自适应趋优边界(IA00-C)后,在测试函数的平均寻优精度均有下降,证明三种改进策略均起

表 2 消融试验寻优平均值

Tab. 2 Mean fitness values of ablation experiments

算法	F_1	F_3	F_4	F_5	F_7	F_9
IA00-A	6.57×10^4	4.31×10^3	5.01×10^2	6.21×10^2	8.52×10^2	2.68×10^3
IA00-B	6.69×10^4	1.89×10^4	5.08×10^2	6.24×10^2	8.77×10^2	2.96×10^3
IA00-C	6.62×10^4	4.67×10^3	5.02×10^2	6.07×10^2	8.47×10^2	2.57×10^3

优化效果,其中重心反向学习效果最好。

2.3 核极限学习机(KELM)

核极限学习机(KELM)是极限学习机(ELM)理论的一个重要扩展,KELM通过引入核函数将低维输入数据转化至高维特征空间^[8],替代了ELM中随机生成的隐含层映射,这种方法不仅继承了ELM出色的训练效率,还克服了参数随机性导致的性能波动,从而提升了模型的稳定性和泛化能力。

传统ELM的输出计算公式为:

$$f(\mathbf{x}) = h(\mathbf{x})\beta = \mathbf{H}\beta = \mathbf{T} \quad (7)$$

式中, $\mathbf{x}$ 为输入向量; $h(\mathbf{x})$ 为隐藏层节点输出; $\mathbf{H}$ 为隐藏层输出矩阵; β 为输出权重; $\mathbf{T}$ 为目标输出矩阵。

为提高模型泛化性能,加入正则化系数,则输出权重 β 的解为:

$$\beta = \mathbf{H}^T \left(\mathbf{H}\mathbf{H}^T + \frac{\mathbf{I}}{C} \right)^{-1} \mathbf{T} \quad (8)$$

式中, $\mathbf{I}$ 为单位矩阵; C 为正则化系数。

引入高斯核函数,核矩阵 $\mathbf{\Omega}_{\text{ELM}}$ 表示为:

$$\mathbf{\Omega}_{\text{ELM}} = \mathbf{H}\mathbf{H}^T = h(\mathbf{x}_i)h(\mathbf{x}_j) = K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2/S) \quad (9)$$

式中, $\mathbf{x}_i$ 、 $\mathbf{x}_j$ 为输入向量; S 为核函数参数。

KELM模型的输出为:

$$f(\mathbf{x}) = \begin{bmatrix} K(\mathbf{x}, \mathbf{x}_1) \\ \vdots \\ K(\mathbf{x}, \mathbf{x}_n) \end{bmatrix}^T \left(\mathbf{\Omega}_{\text{ELM}} + \frac{\mathbf{I}}{C} \right)^{-1} \mathbf{T} \quad (10)$$

3 基于 OLHS-IA00-KELM 的反演模型

利用 OLHS 构造渗透系数样本,通过有限元正分析得到样本水头。使用 IA00 算法对 KELM 的正则化系数 C 和核函数参数 S 寻优,目标函数为:

$$f_1 = \sqrt{\frac{1}{nm} \sum_{i=1}^n \sum_{j=1}^m (P_{i,j} - T_{i,j})^2} \quad (11)$$

式中, n 为样本数; m 为水头测点数; $P_{i,j}$ 、 $T_{i,j}$ 分别为第 i 个样本第 j 个测点的预测值、水头值。

用最优的 C 、 S 组合训练 KELM,得到渗透系数与水头的映射关系,运行 IA00 算法反演最优渗透系数组合,适应度函数为:

$$f_2 = \sqrt{\frac{1}{m} \sum_{j=1}^m (P_j - H_j)^2} \quad (12)$$

式中, P_j 、 H_j 分别为第 j 个测点的预测值、实测水头值。

OLHS-IAOO-KELM 反演模型的主要流程见图 1。




图 1 OLHS-IAOO-KELM 反演模型流程图

Fig. 1 Flow chart of OLHS-IAOO-KELM inversion model

4 工程应用

4.1 工程概况

某湿排式尾矿库设计总库容 $9.81 \times 10^8 \text{ m}^3$ ，工程为二等尾矿库。初期坝为碾压堆石坝，坝顶标高 4 010 m，最大坝高 40 m，上下游坡比均为 1:2，上游坝坡碾压堆石上依次设置碎石层、砾石过渡层和土工膜进行防渗。堆积坝采用上游法尾砂筑坝，现高 4 100 m，平均堆积边坡 1:5。从初期坝顶至堆积坝顶每间隔 6 m 高差设置一道水平排渗层，库底设置 6 条排渗条带。典型断面(桩号 0+610)见图 2。




图 2 某尾矿坝典型断面

Fig. 2 Typical section of a tailings dam

4.2 有限元模型和计算参数

以尾矿坝范围以外 50~200 m 为截取边界，建立尾矿库三维有限元模型，见图 3。共有网格节点 24 827 个，单元 23 330 个。水头边界为库水位淹没线以下的坝面和山体，出渗边界为下游坝坡面和地表，库区地下水埋藏较深，无地表径流入




图 3 尾矿库三维有限元网格图

Fig. 3 Three-dimensional finite element mesh of the tailings pond

渗，计算期内无降水，因此不考虑入渗边界。参照尾砂沉积的一般规律及颗粒级配情况，将尾矿堆积坝分为四层：尾细砂、尾粉砂、尾粉土和尾粉质黏土，见图 4。




图 4 尾矿坝断面材料分区示意图

Fig. 4 Material zones of the tailings dam section

选取一个库水位相对稳定的观测期，在 20 d 内库水位最大变幅仅 0.34 m，期间无降雨，可认为尾矿坝渗流场达到了准稳定状态，在库水位 4 095.00 m 条件下，位于桩号 0+610 断面的七个监测点 P4、P5、P6、P7、P8、P9、P10 的实测水头分别为 4 006.61、4 013.28、4 021.56、4 030.78、4 039.65、4 047.04、4 054.04 m，依此基于 OLHS-IAOO-KELM 模型对尾矿坝各分区的渗透系数进行反演分析。

根据工程地质勘查结果和同类型工程经验，确定各材料分区的渗透系数取值见表 3。由于尾砂通常为非球状颗粒，在沉积过程中颗粒排列存在一个优势方向，水平向渗透系数大于垂直向渗透系数，4 种尾矿坝分区的渗透系数考虑为各向异性。

表 3 各材料渗透系数

Tab. 3 Permeability coefficient of materials

材料	参数状态	垂直向渗透系数 $k_v/(\text{cm} \cdot \text{s}^{-1})$	水平向渗透系数 $k_H/(\text{cm} \cdot \text{s}^{-1})$
基岩	资料取值	5.00×10^{-6}	5.00×10^{-6}
碾压堆石体	资料取值	3.00×10^{-1}	3.00×10^{-1}
土工膜	资料取值	1.00×10^{-8}	1.00×10^{-8}
排渗条带	资料取值	1.20×10^{-2}	1.20×10^{-2}
尾细砂	反演参数	$1.00 \times 10^{-3} \sim 5.00 \times 10^{-3}$	$1.10 \times 10^{-3} \sim 1.15 \times 10^{-2}$
尾粉砂	反演参数	$5.00 \times 10^{-4} \sim 1.00 \times 10^{-3}$	$5.50 \times 10^{-4} \sim 2.30 \times 10^{-3}$
尾粉土	反演参数	$1.00 \times 10^{-4} \sim 5.00 \times 10^{-4}$	$1.10 \times 10^{-4} \sim 1.15 \times 10^{-3}$
尾粉质黏土	反演参数	$1.00 \times 10^{-6} \sim 1.00 \times 10^{-4}$	$1.10 \times 10^{-6} \sim 2.30 \times 10^{-4}$
排渗垫层	资料取值	1.00×10^{-2}	1.00×10^{-2}

4.3 基于 OLHS-IAOO-KELM 模型的反演计算

利用 OLHS 方法抽取 64 组尾矿坝渗透系数组合样本，将每组样本代入有限元模型进行渗流计算，得到对应的测点位置水头值，两者结合构成数据集。其中 48 组样本作为训练集，用于 KELM 模型学习渗透系数到水头的映射关系，其余 16 组为测试集，用于检验模型的预测精度和泛化能力。使用 IAOO 算法以式(11)最小为目标对 KELM 的正则化系数 C 和核函数参数 S 寻优，设置不实野燕麦种群数量为 30，最大迭代次数为 500。寻找到最优的 C、S 组合，用其训练出最优 KELM 模型，再次运行 IAOO 算法，以式(12)为适应度函数反演渗透系数。

4.4 反演结果与分析

由 OLHS-IAOO-KELM 反演模型得到的最优渗透系数组合见表 4。由表 4 可看出,尾矿坝各分区的渗透系数均在取值范围内,初步证明该反演模型合理、可靠。

表 4 渗透系数反演值

Tab. 4 Inversion results of permeability coefficient

材料	$k_v/(\text{cm} \cdot \text{s}^{-1})$	$k_H/(\text{cm} \cdot \text{s}^{-1})$
尾细砂	1.86×10^{-3}	3.84×10^{-3}
尾粉砂	5.38×10^{-4}	1.14×10^{-3}
尾粉土	4.98×10^{-4}	9.51×10^{-4}
尾粉质黏土	2.13×10^{-5}	3.94×10^{-5}

将反演结果代入三维有限元模型进行渗流正分析,计算测点水头并与实测值对比分析,结果见表 5、图 5。

表 5 各测点水头实测值与计算值对比

Tab. 5 Comparison of monitored and calculated water heads

测点编号	实测值/m	计算值/m	绝对误差/m	相对误差 $E_r/\%$
P4	4 006.61	4 007.95	1.34	0.98
P5	4 013.28	4 016.13	2.85	2.08
P6	4 021.56	4 023.69	2.13	1.55
P7	4 030.78	4 031.62	0.84	0.61
P8	4 039.65	4 039.14	-0.51	-0.37
P9	4 047.04	4 046.38	-0.66	-0.48
P10	4 054.04	4 054.17	0.13	0.09

注: $E_r = [(H_c - H_m)/(h_u - h_d)] \times 100\%$ (H_c 为测点水头计算值; H_m 为测点水头实测值; h_u 为上游库水位; h_d 为下游地面高程)。




图 5 反演结果对比图

Fig. 5 Comparison of inversion results

由表 5、图 5 可知,测点水头反演计算值与实测值的吻合度较高,7 个测点的相对误差最大为 2.08%,最小为 0.09%,在工程误差允许范围内,体现了 OLHS-IAOO-KELM 反演模型的准确性和鲁棒性。

相应的尾矿坝典型断面(桩号 0+610)位势分布见图 6。由图 6 可看出,浸润线从上游库水开始,在尾砂堆积体中平缓下降,到达初期坝时在土工膜作用下迅速降低,通过初期坝底的基岩向下游延伸,符合尾矿坝工程规律,证明该反演模型




图 6 典型断面渗流场位势分布图(单位:m)

Fig. 6 Potential distribution in typical section

有效、可行。

为进一步验证 OLHS-IAOO-KELM 模型的性能,同时建立 DBO-KELM、GWO-KELM、PSO-KELM 和 AOO-KELM 模型对该工程问题进行反演,结果对比见表 6。由表 6 可看出,OLHS-IAOO-KELM 模型表现出最优的预测性能,其相对误差不超过 2.08%,低于其他模型,验证了该模型在渗透系数反演中的优势。

表 6 各模型反演结果

Tab. 6 Inversion results of different models

模型	误差最大的测点	最大绝对误差/m	最大相对误差/%
OLHS-IAOO-KELM	P5	2.85	2.08
DBO-KELM	P5	4.70	3.43
GWO-KELM	P5	4.51	3.29
PSO-KELM	P6	5.65	4.12
AOO-KELM	P5	3.93	2.87

5 结论

a. 针对 AOO 收敛速度慢的问题,使用 LHS 初始化种群并引入重心反向学习和自适应趋优边界进行改进。测试结果表明,IAOO 的寻优精度和稳定性提升近 30%,收敛速度更快,改进效果显著。

b. 工程实例应用结果表明,通过 OLHS-IAOO-KELM 模型反演得到的渗透系数值合理,反演计算水头与实测值最大相对误差为 2.08%,模型具有稳定性好、精度高的优点,为尾矿坝工程提供一种新的反演分析方法。

参考文献:

[1] 陈铁亮,母传伟,孙靖霄,等. 基于有限元数值模拟的尾矿库三维渗流稳定性分析[J]. 自动化应用, 2024(18): 201-206. (CHEN T L, MU C W, SUN J X, et al. 3D seepage stability analysis of tailings pond based on finite element numerical simulation [J]. Automation application, 2024(18): 201-206. (in Chinese))

[2] 王神尼. 某尾矿库渗流模拟及防渗研究[J]. 地下水, 2025, 47(4): 78-81. (WANG S N. Study on seepage simulation and seepage control of a tailings pond[J]. Ground water, 2025, 47(4): 78-81. (in Chinese))

特征点检测不一致导致,但所有试验结果误差均 ≤ 1.00 mm,验证了本文技术的适用性。

本文试验结果均有不同程度的误差,产生误差的主要原因是算法自身的假设条件引起,特征点提取时并不能保证所有特征点均是正确匹配,个别错误匹配会影响算法结果,次要原因为本文试验采用的位移计有 ± 0.007 mm 的示值误差,由于其误差值远小于试验误差,可忽略不计。但测量结果仍具有较高的精度和稳定性,满足工程监测的需要。

4 结论

a. 利用坝体表面已有物体的天然纹理特征或自然地物作为测量标识物,通过求解标识物特征点对的相对位移计算得到坝体表面沉降。具有无接触、对现场环境依赖度低等优点,尤其适用于难以布置标识物的场景。

b. 提出了一种基于简化投影模型的图像修正技术,通过推导并简化投影模型变换解决了传统投影模型的限制性,提高了其应用范围。利用远处受工程影响小的基岩作为稳定参考区域,对图像进行修正,有效提升了监测精度。

c. 试验表明,本文测量范围为 70 m,测量精度 $\leq \pm 1.00$ mm,且在不同环境下具有较好的鲁棒性,可用于实际工程中。

参考文献:

- [1] 叶肖伟,董传智. 基于计算机视觉的结构位移监测综述[J]. 中国公路学报, 2019, 32(11): 21-39. (YE X W, DONG C Z. Review of computer vision-

(上接第 142 页)

- [3] 邹超英,曾海军,江兆强. 基于 LHS-CPO-BP 神经网络的大坝渗透系数反演分析方法[J]. 价值工程, 2025, 44(4): 96-100. (ZOU C Y, ZENG H J, JIANG Z Q. Inversion analysis method of dam permeability coefficient based on LHS-CPO-BP neural network[J]. Value engineering, 2025, 44(4): 96-100. (in Chinese))
- [4] 李永超,沈振中,熊汉野,等. 基于 LHS-ISSA-SVR 的心墙堆石坝渗流参数反演方法及应用[J]. 水电能源科学, 2024, 42(7): 109-113. (LI Y C, SHEN Z Z, XIONG H Y, et al. Inversion method of seepage parameters of core rockfill dam based on LHS-ISSA-SVR and its application[J]. Water resources and power, 2024, 42(7): 109-113. (in Chinese))
- [5] 肖时辉,王峰,何柏延,等. 基于 LHS-WOA-ELM 的隧道围岩参数反演分析[J]. 矿业研究与开发, 2025, 45(3): 91-100. (XIAO S H, WANG F, HE B Y, et al. Inversion analysis on surrounding rock

based structural displacement monitoring[J]. China journal of highway and transport, 2019, 32(11): 21-39. (in Chinese))

- [2] 李艺,刘成栋,刘检生,等. 基于机器视觉的大坝表面位移智能监测方法研究[J]. 水电能源科学, 2023, 41(12): 93-96. (LI Y, LIU C D, LIU J S, et al. Dam surface displacement monitoring system based on machine vision[J]. Water resources and power, 2023, 41(12): 93-96. (in Chinese))
- [3] 许孝臣,薛磊磊,李峰,等. 机器视觉技术在大坝表面变形监测中的适用性研究[J]. 水电能源科学, 2024, 42(9): 125-129. (XU X C, XUE L L, LI F, et al. Application of machine vision technology in dam surface deformation monitoring[J]. Water resources and power, 2024, 42(9): 125-129. (in Chinese))
- [4] 李明,苏志龙,张东升. 基于仿射变换矫正相机抖动的数字图像相关测量方法[J]. 光学学报, 2021, 41(9): 0912002. (LI M, SU Z L, ZHANG D S. Methods for digital image correlation measurement with camera shake correction based on affine transformation[J]. Acta optica sinica, 2021, 41(9): 0912002. (in Chinese))
- [5] SHANTAL M, OTHMAN Z, ABU BAKAR A. A novel approach for data feature weighting using correlation coefficients and Min-max normalization[J]. Symmetry, 2023, 15(12): 2185.
- [6] PIRÓPO M, MORAES F, SANTOS F A N. Surfing on curved surfaces-the maple package surf[J]. Computer physics communications, 2020, 249: 107002.
- [7] KUO C Y, LU Y R, YANG S M. On the image sensor processing for lane detection and control in vehicle lane keeping systems[J]. Sensors, 2019, 19(7): 1665.
- [8] parameters of tunnel based on LHS-WOA-ELM[J]. Mining research and development, 2025, 45(3): 91-100. (in Chinese))
- [6] 叶鹏程,潘光,高山. 一种快速优化拉丁超立方试验设计方法[J]. 西北工业大学学报, 2019, 37(4): 714-723. (YE P C, PAN G, GAO S. Sampling design method of fast optimal Latin hypercube[J]. Journal of Northwestern Polytechnical University, 2019, 37(4): 714-723. (in Chinese))
- [7] WANG R B, HU R B, GENG F D, et al. The Animated Oat Optimization Algorithm: A nature-inspired metaheuristic for engineering optimization and a case study on Wireless Sensor Networks [J]. Knowledge-based systems, 2025, 318: 113589.
- [8] HUANG G B, ZHOU H M, DING X J, et al. Extreme learning machine for regression and multiclass classification[J]. IEEE transactions on systems, man, and cybernetics, part B (cybernetics), 2012, 42(2): 513-529.