

# 基于 Kriging 代理模型优化算法的堆石坝参数反演方法

顾克, 费香泽, 刘佳龙, 张琰

(国网电力工程研究院有限公司)

**摘要:**针对堆石坝参数反演常规方法效率偏低的问题,提出了一种基于 Kriging 代理模型优化算法的堆石坝参数反演方法,该方法通过拉丁超立方抽样方法在参数空间内抽取少量的初始样本点,建立较为粗糙的 Kriging 代理模型,然后根据多种加点准则选取新的样本点更新样本集,从而获得精度更高的 Kriging 代理模型并进行寻优,直至满足收敛条件。该方法在逐步增加样本点的过程中能够使得增加的样本点落在最有潜力获得最优解的参数空间内,降低了传统代理模型样本点选取的盲目性,从而提高反演效率。工程实例验证结果表明,该方法能减少调用有限元模型计算的次数,提高代理模型抽样的分析效率,缩短参数反演的时间,提高反演分析点平均计算精度。

**关键词:**堆石坝;参数反演;Kriging 代理模型;加点准则

**Parameters inversion method for rockfill dams based on Kriging surrogate model optimization algorithm**//Gu Ke, Fei Xiangze, Liu Jialong, Zhang Yan(*State Grid Electric Power Engineering Research Institute Co., Ltd.*)

**Abstract:** To address the low efficiency of conventional methods for parameter inversion of rockfill dams, a rockfill dam parameter inversion method based on a Kriging surrogate model optimization algorithm is proposed. The method first extracts a small number of initial sample points from the parameter space using the Latin hypercube sampling method to establish a relatively coarse Kriging surrogate model. New sample points are then selected according to various infill criteria to update the sample set, thereby obtaining a higher-accuracy Kriging surrogate model to perform optimization until the convergence conditions are met. During the process of gradually adding the number of sampling points, this method can ensure that the newly added sample points fall within the parameter space with the greatest potential for optimal solutions, reducing the randomness of sample point selection of traditional surrogate models and thus improving inversion analysis efficiency. The verification results from an engineering case show that the proposed method can reduce the number of finite element model calculations, improve the sampling efficiency of the surrogate model, shorten the parameter inversion time, and enhance the average calculation accuracy at inversion analysis points.

**Key words:** rockfill dam; parameter inversion; Kriging surrogate model; infill criteria

堆石坝是目前坝工领域应用最广泛的坝型之一<sup>[1]</sup>。堆石坝的坝体变形控制是堆石坝安全运行的关键因素之一,受室内试验缩尺效应、筑坝料压实程度及运行环境等因素的影响,设计阶段确定的坝料参数与真实值往往存在一定的差异<sup>[2]</sup>,且对于建造年代久远的工程,相关数据的完整性不足,无法满足运营阶段坝体安全评价等要求。因此有必要通过其他方法获取坝料的真实参数,目前最常用的方法是通过坝体原位监测资料进行反演分析,从而获得坝料参数<sup>[3]</sup>。

堆石坝参数反演方法前期以直接法为主,其主要原理是将参数反演问题转化为优化问题,利用各种寻优方法通过大量试算来寻找使得目标函数最优的参数组合,但这种方法在试算时需要调用有限元计算模型,效率较低,且难以收敛到最优的全局解<sup>[4-6]</sup>。近年来机器学习算法在堆石坝参数反演中的应用越来越多,如误差反向传播神经网络、混合核相关向量机算法、支持向量回归和粒子群算法等。机器学习算法主要是通过参数空间内抽取一定数量的样本点进行有限元计算,建立样本点和计算结

**基金项目:**国家电网有限公司科技项目(5108-202218280A-2-301-XG)

**作者简介:**顾克(1988—),男,高级工程师,博士,主要从事抽水蓄能电站渗漏探测技术与数字化技术研究。E-mail:798161456@qq.com

**通信作者:**刘佳龙(1990—),男,高级工程师,硕士,主要从事抽水蓄能电站智能建造技术研究。E-mail:190222591@qq.com

果之间的映射关系,即代理模型,利用代理模型进行寻优,从而输出最优的反演参数<sup>[7-10]</sup>。机器学习算法虽然在参数寻优的过程中避免了调用有限元模型进行计算,但在代理模型建立过程中,由于每个参数样本点均需要进行一次有限元计算以获得参数响应信息,并且样本数量和样本点的分布情况直接关系到代理模型的精度,因此为了获得准确的反演结果,往往需要在参数空间内均匀地抽取大量的样本点,并将样本点集合分为训练集和测试集,利用训练集建立代理模型,通过测试集验证模型精度,这种做法在样本抽取的过程中存在较大的盲目性,当样本点选取恰好都是在较有潜力的区域内时效率较高,反之则会有不少样本点落在与最优解相关性不大的空间内,对这部分样本点的计算必然导致反演分析效率的降低。

针对上述问题,本文提出了一种基于 Kriging 代理模型优化算法的堆石坝参数反演方法,该方法先采用少量初始样本建立较为粗糙的 Kriging 代理模型,然后根据多种加点准则选取新的样本点加入样本集,从而获得精度更高的 Kriging 代理模型并进行寻优,直至满足收敛条件。该方法在逐步增加样本点的过程中,能够择优选取参数空间内最有潜力的区域进行抽样,降低了传统代理模型建立过程中样本点选取的盲目性,可提高反演效率。

## 1 反演方法

### 1.1 Kriging 模型

Kriging 模型是基于空间统计学的最佳线性无偏插值方法的基础<sup>[11]</sup>,其核心是利用已知离散样本点的空间相关性,对待估点进行加权线性预测。该模型通过拟合变异函数刻画样本点间的空间自相关规律,确定不同位置样本对预测点的权重,使预测值满足无偏性(预测期望等于真实值期望)与最优性(预测误差方差最小),不仅能得到连续平滑的空间预测场,还能保留区域化变量的空间结构性与随机性。

区别于传统插值(仅输出预测值)方法,Kriging 模型最核心优势是同步输出预测值与预测方差:预测方差由样本点空间分布、变异函数参数、待估点与样本距离共同决定,距离样本越近、样本越密集,预测方差越小、精度越高;远离样本区域方差增大,直观量化预测不确定性。Kriging 模型本质是兼顾插值精度与误差统计度量的空间估计方法,既能实现未知点数值拟合,又能定量评价预测可靠性,在空间插值、场重构、不确定性分析中具备不可替代的优势。

### 1.2 代理模型的优化算法

由于 Kriging 代理模型能够同时给出未知点处的预测值与预测方差,因此新增样本点优化的策略可分两类:一是在当前代理模型的预测最小值周边区域选取新的样本点。这种策略的优点在于简单实用,易于操作,在代理模型精度较高时能够快速收敛,但其缺点也很明显,即当代理模型的样本点较少、精度不高时,易于陷入局部最优,因此仅使用这种优化策略无法满足要求。二是在代理模型预测精度较差的区域内选取新的样本点,从而提高代理模型在此区域内的预测精度,获得精度更高的代理模型,这种加点策略能够使优化朝着全局最优的方向进行。本文 Kriging 代理模型采用 MSP、MSE、EI 和 PI 共 4 种加点准则对模型算法进行优化,优化算法包含了上述两种样本点的添加策略。

#### 1.2.1 MSP 加点准则

MSP 加点准则<sup>[12]</sup>直接以当前代理模型预测最小值所在点作为样本点,并添加到样本集中作为建立新代理模型的样本点,其数学表达式为:

$$x_{\min} = \arg y_{\min}(x) \quad (1)$$

式中: $x_{\min}$  为当前代理模型最小值所在点的位置坐标; $y_{\min}(x)$  为当前代理模型最小值; $\arg$  表示样本参数与目标函数值之间的映射关系,返回值为  $y_{\min}(x)$  对应的输入样本点参数。

MSP 加点准则将当前代理模型的预测最小值所在点选为新的样本点,是一种局部的加点策略,当代理模型精度足够时(代理模型的最小值点已经与全局最优点较为接近,能够较好反映全局态势),可快速提高收敛速度,但也极易陷入局部最优。

#### 1.2.2 MSE 加点准则

MSE 加点准则<sup>[13]</sup>直接以当前代理模型预测方差最大值所在点作为样本点,并添加到样本集中作为建立新代理模型的样本点,其数学表达式为:

$$x_{\text{new}} = \arg s_{\max}^2(x) \quad (2)$$

式中: $x_{\text{new}}$  为新加点; $s_{\max}^2(x)$  为预测方差最大值。

MSE 加点准则将当前代理模型给出的预测方差最大值所在点选为新的样本点,这种加点准则是全局加点策略,能够提高代理模型的全局精度,避免陷入局部最优。

#### 1.2.3 EI 加点准则

EI 加点准则函数  $E(x)$  表示某个选取样本点在该准则下的函数值,其数学表达式<sup>[14]</sup>为:

$$E(x) = \begin{cases} (y_{\min} - y(x)) \varphi\left(\frac{y_{\min} - y(x)}{s(x)}\right) + \\ s(x) \psi\left(\frac{y_{\min} - y(x)}{s(x)}\right) & s(x) > 0 \\ 0 & s(x) = 0 \end{cases} \quad (3)$$

式中: $y_{\min}$  为已有样本集中最小真实响应值; $s(x)$  为 Kriging 代理模型预测未知点处的标准差; $y(x)$  为 Kriging 代理模型未知点的预测值; $\varphi(\cdot)$  为标准正态累积分布函数; $\psi(\cdot)$  为标准正态概率密度函数。

EI 加点准则假设 Kriging 代理模型预测值服从均值为  $y(x)$ 、标准差为  $s(x)$  的正态分布,式(3)表示当前代理模型预测值与已有样本最小真实响应值之差的期望值,该期望最大值所在点即为代理模型预测值与已有样本值之差最大处的样本点,将其添加到样本集中作为建立新代理模型的样本点,以最大化改善期望。

观察式(3)可知有 2 个特点:一是函数的峰值与  $s(x)$  高度正相关,因此得到的函数最大值所在点,基本是代理模型预测方差较大区域的样本点;二是代理模型预测值小于样本最小真实响应值的区域,函数值也较大。EI 加点准则能够从全局出发在最有潜力的参数空间内选取新的样本点,因此 EI 加点准则也是一种全局加点策略,能够避免陷入局部最优。

### 1.2.4 PI 加点准则

PI 加点准则<sup>[15]</sup>与 EI 加点准则类似,也是假设 Kriging 模型预测值服从均值为  $y(x)$ 、标准差为  $s(x)$  的正态分布,PI 加点准则表达式如下:

$$P(x) = \varphi\left(\frac{y_{\min} - y(x)}{s(x)}\right) \quad (4)$$

式中: $P(x)$  为样本点的改善概率。该准则用于计算目标函数的改善概率,并将改善概率最大值所在点作为新的样本点。式(4)表示代理模型预测值小于已有样本最小值的概率,将概率最大值所在点添加到样本集中作为建立新代理模型的样本点。同样 PI 加点准则也能够从全局出发在最有潜力的参数空间内选取新的样本点,也是一种全局加点策略,能够避免陷入局部最优。

### 1.3 优化算法流程

本文对 Kriging 代理模型算法的优化体现在参数空间的全局加点阶段和局部加点阶段,在全局加点阶段利用 MSE、EI 和 PI 加点准则,确定代理模型预测方差最大值以及式(3)与式(4)最大值所在点,将其作为新的样本点加入样本集后重新构建 Kriging 代理模型;在局部加点阶段采用 MSP 加点准则,将当前代理模型最小值所在点加入样本集,重新构建 Kriging 代理模型。在全局加点阶段和局部加点阶段均使用 SFOA 算法<sup>[16]</sup>寻优。

优化算法流程如图 1 所示,其关键是全局加点和局部加点之间的切换。当全局加点阶段确定的样

本点的真实响应值小于当前样本的真实响应值时,进入局部加点阶段;在局部加点阶段,当局部样本点过于密集时,切换至全局加点。局部加点密集程度采用 Euclidean 距离  $d^{[17]}$  来判断:

$$d = \sqrt{(x_{\text{new}} - x_{\text{old}})^2} \quad (5)$$

式中: $x_{\text{old}}$  为原有样本点,当新加点与原有样本点之间的 Euclidean 距离小于一定的容差时,说明局部样本点过于密集。

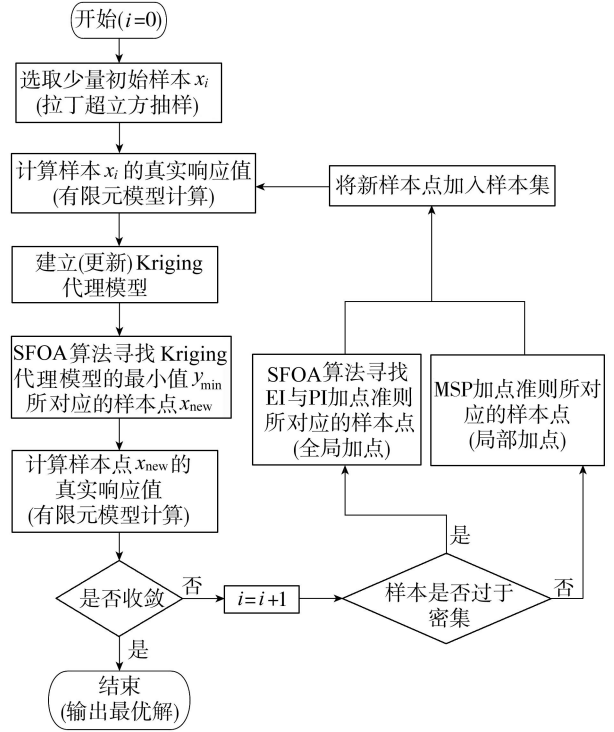


图 1 Kriging 代理模型优化算法流程

## 2 函数算例测试与验证

### 2.1 全局加点准则验证

采用一维函数验证全局加点准则,一维函数表达式如下:

$$f(x) = (6x - 2)^2 \sin(12x - 4) \quad (0 \leq x \leq 1) \quad (6)$$

初始样本点  $x = 0, 0.1, 0.2, 0.3, 0.9$ , 得到 Kriging 代理模型的预测曲线如图 2 所示,可见代理模型曲线与函数真实响应曲线在  $0.4 \sim 0.6$  和  $0.7 \sim 0.9$  之间误差较大,说明在这两个区域内需要增加新的样本点,提高精度。图 3 为 Kriging 代理模型的预测方差曲线,图 4 为 EI 和 PI 加点准则函数曲线,可知 3 条曲线的峰值位置分别在  $x = 0.68$  (预测方差),  $0.60$  (EI 加点准则函数),  $0.71$  (PI 加点准则函数) 处,均在 Kriging 代理模型预测曲线与函数真实响应曲线误差较大的区域,说明本文采用全局加点准则进行优化是合适的。

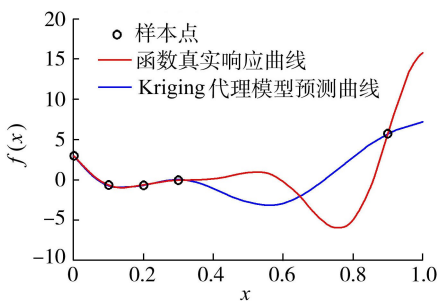


图2 一维函数真实响应曲线和 Kriging 代理模型预测曲线




图3 一维函数 Kriging 代理模型预测方差曲线




图4 EI 和 PI 加点准则函数曲线

## 2.2 多维函数测试

采用一个标准测试函数——camel6 函数来验证和演示本文 Kriging 代理模型优化算法的有效性和实施过程。二维函数的曲面形状见 <https://www.sfu.ca/~ssurjano/camel6.html>, 该函数具有 6 个极小值点, 全局的极小值为  $-1.0316$ , 函数表达式如下:

$$f(x_1, x_2) = (4 - 2.1x_1^2 + \frac{1}{3}x_1^4)x_2^2 + x_1x_2 + (-4 + 4x_2^2)x_2^2 \quad (x_1, x_2 \in [-2, 2]) \quad (7)$$

式中:  $x_1, x_2$  为 camel6 函数的自变量。

采用拉丁超立方抽样方法建立一个样本容量为 10 的初始样本集, 确定算法收敛的容差为 0.001, 样本密集程度的容差为  $0.01^{[15]}$ 。采用两种方法进行对比测试: ①方法 1 采用 SFOA 算法(粒子数 30 个)对式(7)直接寻优, 即采用直接法寻优; ②方法 2 采用拉丁超立方抽样方法抽取 50 组样本(40 组用于训练, 10 组用于验证)建立人工神经网络模型后利用 SFOA 算法寻优。图 5 为 3 种方法的寻优值收敛曲线, 本文方法仅需 10 次迭代就能满足收敛容差的

要求, 寻优值收敛至  $-1.0310$ , 而方法 1 需迭代 22 次, 每次迭代均需调用 30 次原函数计算, 才能收敛至  $-1.0316$ 。方法 1 由于是直接法寻优, 其精度较高, 但调用原函数的计算达到了 660 次, 效率较低, 而本文方法迭代 10 次, 共计新增样本点 14 个, 调用原函数计算 24 次(含初始样本 10 次), 效率有了明显提升。




图5 不同方法的收敛曲线

方法 2 建立人工神经网络模型后, 利用 SFOA 算法经过了 18 次迭收敛至  $-0.8996$ , 精度较差, 且是通过样本容量为 50 的样本集建立人工神经网络模型后寻优, 即调用了 50 次原函数计算, 效率较低的同时, 精度也较差。这说明拉丁超立方抽样虽能实现在参数空间内样本分布的均匀性和随机性, 但也不可避免地导致在最有潜力获得最优解的参数空间区域内样本数量较少, 从而使得解的精度较低; 同时由于在远离最优解的参数空间内也分布了样本点, 浪费了这部分的计算资源, 导致效率降低。图 6 为本文方法和方法 2 的样本点分布, 本文方法在总样本点较少的情况下, 在最优解区域的分布较为集中, 提高了抽样效率, 而方法 2 样本点分布均匀且随机, 盲目性较高, 方法 2 在精度和效率上均不及本文方法。




图6 二维函数算例曲面样本点分布

## 3 工程实例验证

### 3.1 工程概况

某抽水蓄能电站上水库面板堆石坝坝顶高程 1233.00 m, 最大坝高 86.00 m, 坝顶宽 10 m, 坝顶长

718.00 m, 大坝上、下游坝坡均为 1 : 1.40。坝体内部沉降观测共布置 4 个断面, 其中在最大监测断面测点布置如图 7 所示。最大监测断面处分别在高程 1 211.20 m 和 1 191.20 m 处布置了 2 套水管式沉降仪, 测点编号分别为 A1-1 ~ A1-3 和 B2-1 ~ B2-6, 共计 9 个测点。同时根据大坝填筑过程建立了有限元计算模型, 共计单元 13 111 个, 节点 14 292 个。




图 7 大坝最大监测断面测点布置(单位:m)

### 3.2 反演参数与测点选择

坝体填筑料主要包括垫层、过渡层、主堆石和次堆石。堆石料模型采用邓肯  $E-B$  模型, 共有 9 个参数, 若全部进行反演, 则待反演参数有 36 个, 因此有必要精简, 其中初始内摩擦角  $\varphi_0$ 、内摩擦角增量  $\Delta\varphi$  和土体黏聚力  $c$  一般可由试验确定, 卸载弹性模量参数  $K_{ur}$  的敏感性很低, 可不用反演<sup>[18]</sup>, 因此将切线弹性模量参数 ( $K, n$ )、破坏比 ( $R_f$ ) 和切线体积模量参数 ( $K_b, m$ ) 共 5 个参数作为待反演参数。主堆石与次堆石填筑比例较高, 对坝体变形具有决定作用, 因此必须进行反演, 而垫层与过渡层填筑比例低, 不参与反演。参考现场试验数据和类似的工程经验<sup>[19-20]</sup>, 拟定了堆石料邓肯  $E-B$  模型和坝体材料待反演参数的取值如表 1 所示, 共计 9 个待反演参数。

最大断面的 9 个测点中, 测点 A1-1 和 B2-1 均在垫层内, 由于垫层和过渡层的参数不进行反演, 且这两测点靠近上游坝面, 测值较小, 故不纳入反演测点, 因此确定反演测点为 A1-2、A1-3、B2-2 ~ B2-6。建立目标函数如下:

$$\min T(x_1, x_2, \dots, x_9) = \min \left( \frac{100}{N} \sum_{k=1}^N \left| \frac{u_k^* - u_k}{u_k} \right| \right) \quad (8)$$

表 1 待反演参数取值

材料	$K$	$n$	$R_f$	$K_b$	$m$	$\varphi_0 / (^\circ)$	$\Delta\varphi / (^\circ)$	$K_{ur}$	$c / \text{kPa}$
垫层	1 150	0.42	0.71	680	0.33	47.0	5.7	1 800	0
过渡层	1 020	0.41	0.68	620	0.28	48.0	3.5	1 500	0
主堆石	800~1 500	0.20~0.45	0.60~0.90	250~650	0.10~0.30	50.6	8.5	1 300	0
次堆石	800~1 300	0.20~0.45	0.60~0.90	250~600	0.10~0.30	45.5	8.0	1 200	0

表 2 筑坝料  $E-B$  模型反演参数

材料	$K$	$n$	$R_f$	$K_b$	$m$	$\varphi_0 / (^\circ)$	$\Delta\varphi / (^\circ)$	$K_{ur}$	$c / \text{kPa}$
主堆石	1 083.9	0.4149	0.8391	489.4	0.1962	50.6	8.5	1 300	0
次堆石	944.7	0.3888	0.8014	301.4	0.2247	45.5	8.0	1 200	0

式中:  $x_1, x_2, \dots, x_9$  为 9 个待反演参数;  $u_k^*$  为测点  $k$  的计算值;  $u_k$  为测点  $k$  的实测值;  $N$  为用于反演的测点总数。

### 3.3 反演结果分析

先采用拉丁超立方抽样方法建立 15 个初始样本, 目标函数容差设定为 5%, 样本密集度容差设定为 1%<sup>[15]</sup>, 然后进行反演。图 8 为目标函数收敛曲线, 仅迭代 9 次, 目标函数就收敛到容差范围内, 最终收敛值为 4.99%。共计新增样本点 19 个, 其中全局样本点 15 个, 局部样本点 4 个。反演确定的参数如表 2 所示。利用表 2 参数计算得到 7 个测点沉降值, 与实测值对比, 测点平均误差率为 4.99%, 最小误差率为 2.00%, 出现在测点 B2-3, 最大误差率为 11.98%, 出现在测点 B2-6。




图 8 目标函数收敛曲线

为了对比, 在参数空间内采用拉丁超立方抽样方法生成 60 个样本 (50 个用于训练, 10 个用于验证), 采用方法 2 建立神经网络模型进行反演, 其目标函数最小仅收敛至 7.33% (图 8), 说明本文方法不仅效率高, 精度也较高。本文方法使用 Kriging 代理模型配合加点准则反演堆石料邓肯  $E-B$  模型和坝体材料待反演参数, 调用有限元模型计算的次数相较于采用神经网络模型的方法 2, 由 60 次降至 34 次, 效率提升 43.3%。

## 4 结 语

为了降低堆石坝参数反演过程中调用有限元模型计算的次数, 提高反演分析效率, 本文提出了一种

基于 Kriging 代理模型优化算法的堆石坝参数反演方法,针对传统代理模型建立过程中样本选取较为盲目的问题,Kriging 代理模型不仅能够给出未知点处的预测值,还能给出预测方差,为代理模型反演分析过程中样本点选取提供了优化的思路。本文方法可先在少量初始样本的情况下,构建相对粗糙的 Kriging 代理模型,然后根据多种加点准则,在最有潜力优化的区域内添加样本点,通过几次迭代即可获得最优解。实例函数与工程实例验证结果表明,本文方法调用有限元模型计算的次数由 60 次降低至 34 次,反演分析的效率提升了 43.3%,测点平均误差率从 7.33% 降至 4.99%,精度提高了 31.9%,具有较高的适用性和有效性及较高的精度。

## 参考文献:

[1] 顾淦臣,束一鸣,沈长松. 土石坝工程经验与创新[M]. 北京:中国电力出版社,2004.

[2] 朱晟. 高面板坝堆石体的填筑质量控制指标研究与应用[J]. 岩土工程学报,2020,42(4):610-615. (Zhu Sheng. Study and application of control indices for filling quality of high concrete face rockfill dams[J]. Chinese Journal of Geotechnical Engineering,2020,42(4):610-615. (in Chinese))

[3] Zhou Wei, Li Shaolin, Ma Gang, et al. Parameters inversion of high central core rockfill dams based on a novel genetic algorithm[J]. Science China Technological Sciences,2016,59(5):783-794.

[4] Kavanagh K T, Clough R W. Finite element applications in the characterization of elastic solids[J]. International Journal of Solids and Structures,1971,7(1):11-23.

[5] 宋春晖. 地铁车站深基坑土体参数动态反演分析及变形预测[D]. 郑州:河南工业大学,2011.

[6] 向天兵. 大型地下厂房洞室群施工期动态反馈优化设计方法研究[D]. 武汉:中国科学院研究生院,2010.

[7] Yu Yuzhen, Zhang Bingyin, Yuan Huina. An intelligent displacement back-analysis method for earth-rockfill dams[J]. Computers and Geotechnics,2007,34(6):423-434.

[8] 马刚,常晓林,周伟,等. 高堆石坝瞬变-流变参数三维全过程联合反演方法及变形预测[J]. 岩土力学,2012,33(6):1889-1895. (Ma Gang, Chang Xiaolin, Zhou Wei, et al. Integrated inversion of instantaneous and rheological parameters and deformation prediction of high rockfill dam[J]. Rock and Soil Mechanics,2012,33(6):1889-1895. (in Chinese))

[9] 程欣悦,马刚,张贵科,等. 考虑监测数据时序特征和空间分布的堆石坝参数反演研究[J]. 水力发电学报,2024,43(5):54-67. (Cheng Xinyue, Ma Gang, Zhang Guike, et al. Study on parameter inversion of rockfill dams considering time series features and spatial distribution of

monitoring data[J]. Journal of Hydroelectric Engineering,2024,43(5):54-67. (in Chinese))

[10] 袁俊平,邱豪磊,胡有方,等. 土石坝力学参数反演技术研究进展与展望[J]. 水利水电科技进展,2021,41(3):1-10. (Yuan Junping, Qiu Haolei, Hu Youfang, et al. Research progress and prospects on inversion technology of mechanical parameters for earth-rockfill dams[J]. Advances in Science and Technology of Water Resources,2021,41(3):1-10. (in Chinese))

[11] Matheron G. Principles of geostatistics[J]. Economic Geology,1963,58(8):1246-1266.

[12] 周广得,吕小龙,黄丹,等. 基于 Kriging 代理模型的迭代更新高效反演方法[J]. 计算力学学报,2023,40(4):602-607. (Zhou Guangde, Lyu Xiaolong, Huang Dan, et al. Efficient iterative updating inversion method based on Kriging surrogate model[J]. Chinese Journal of Computational Mechanics,2023,40(4):602-607. (in Chinese))

[13] 勾红叶,梁浩,赵虎,等. 基于多目标并行加点映射代理模型的高速铁路桥上行车安全快速评价方法[J]. 铁道学报,2023,45(11):154-163. (Gou Hongye, Liang Hao, Zhao Hu, et al. An efficient evaluation method for running safety on high-speed railway bridges based on mapping surrogate model by multi-objective parallel infilling[J]. Journal of the China Railway Society,2023,45(11):154-163. (in Chinese))

[14] 张强,缪维跑,刘青松,等. 基于 EI 加点准则与代理模型的风力机专用翼型气动与结构优化设计[J]. 中国电机工程学报,2022,42(12):4467-4476. (Zhang Qiang, Miao Weipao, Liu Qingsong, et al. Aerodynamic and structural optimization design of dedicated airfoil of wind turbine based on EI criterion and surrogate model[J]. Proceedings of the CSEE,2022,42(12):4467-4476. (in Chinese))

[15] 余镇,樊志华,石宏雨,等. 基于代理优化算法的水下滑翔机外形优化设计[J]. 机械强度,2023,45(4):879-886. (Yu Zhen, Fan Zhihua, Shi Hongyu, et al. Shape optimization design of the underwater glider based on surrogate optimal algorithm[J]. Journal of Mechanical Strength,2023,45(4):879-886. (in Chinese))

[16] Zhong Changting, Li Gang, Meng Zeng, et al. Starfish optimization algorithm (SFOA): a bio-inspired metaheuristic algorithm for global optimization compared with 100 optimizers[J]. Neural Computing and Application,2025,37(5):3641-3683.

[17] 李正良,彭思思,王涛. 基于混合加点准则的代理模型优化设计方法[J]. 工程力学,2022,39(1):27-33. (Li Zhengliang, Peng Sisi, Wang Tao. A surrogate-based optimization design method based on hybrid infill sampling criterion[J]. Engineering Mechanics,2022,39(1):27-33. (in Chinese))

- [18] 李威,刘检生,施增强,等.基于XGBoost算法的堆石料南水模型参数反演及应用[J].水利水运工程学报,2023(3):111-120.(Li Wei, Liu Jiansheng, Shi Zengqiang, et al. NHRI model parameter inversion and application of rockfill based on XGBoost [J]. Hydro-Science and Engineering, 2023(3):111-120. (in Chinese))
- [19] 邹全程,马刚,郭承乾,等.基于多源监测数据与多目标优化的高堆石坝参数反演分析[J].武汉大学学报(工学版),2024,57(11):1539-1550.(Zou Quancheng, Ma Gang, Guo Chengqian, et al. Parameter inversion analysis of high rockfill dams based on multisource monitoring data and multi-objective optimization [J]. Engineering Journal of Wuhan University, 2024, 57(11):1539-1550. (in Chinese))
- [20] 熊健,戴宏武,肖兴军,等.河南洛宁抽水蓄能电站工程蓄水安全鉴定中南院自检报告[R].长沙:中国电建集团中南勘测设计研究院有限公司,2024.  
(收稿日期:2025-02-27 编辑:熊水斌)

(上接第41页)

- [3] 陈炼钢,施勇,钱新,等.闸控河网水文-水动力-水质耦合数学模型:II.应用[J].水科学进展,2014,25(6):856-863.(Chen Liangang, Shi Yong, Qian Xin, et al. Hydrology, hydrodynamics, water quality model for impounded rivers: II. application [J]. Advances in Water Science, 2014, 25(6):856-863. (in Chinese))
- [4] 魏祥龙,陆卫安,唐洪武,等.上海市感潮河网水质劣化机理研究[J].水资源保护,2025,41(5):319-328.(Wei Xianglong, Lu Weian, Tang Hongwu, et al. Study on the mechanisms of water quality deterioration in Shanghai City tidal river networks [J]. Water Resources Protection, 2025, 41(5):319-328. (in Chinese))
- [5] Navon I M. Data assimilation for numerical weather prediction: a review [M]//Park S K, Xu Liang. Data Assimilation for Atmospheric, Oceanic and Hydrologic Applications. Berlin Heidelberg:Springer,2009:21-65.
- [6] Nichols N K. Mathematical concepts of data assimilation [M]//Lahoz W, Khatatov B, Menard R. Data Assimilation. Berlin Heidelberg:Springer,2010:13-39.
- [7] Reichle R H. Data assimilation methods in the Earth sciences [J]. Advances in Water Resources, 2008, 31(11):1411-1418.
- [8] Lai X, Liang Q, Yesou H, et al. Variational assimilation of remotely sensed flood extents using a 2-D flood model [J]. Hydrology and Earth System Sciences, 2014, 18(11):4325-4339.
- [9] Javaheri A, Babbar-Sebens M, Miller R N, et al. An adaptive ensemble Kalman filter for assimilation of multi-sensor, multi-modal water temperature observations into hydrodynamic model of shallow rivers [J]. Journal of Hydrology, 2019, 572:682-691.
- [10] Cho K H, Pachepsky Y, Ligaray M, et al. Data assimilation in surface water quality modeling: a review [J]. Water Research, 2020, 186:116307.
- [11] Bertret V, Le Goff Latimier R, Monbet V. Data assimilation for prediction of ammonium in wastewater treatment plant: from physical to data driven models [J]. Water Research, 2025, 282:123673.
- [12] Chen Cheng, Huang Jiacong, Chen Qiuwen, et al. Assimilating multi-source data into a three-dimensional hydro-ecological dynamics model using Ensemble Kalman Filter [J]. Environmental Modelling & Software, 2019, 117:188-199.
- [13] 赖锡军,何国建.基于四维变分同化法的巢湖流域南淝河水质模拟[J].湖泊科学,2021,33(5):1458-1466.(Lai Xijun, He Guojian. Water quality modelling based on 4-dimensional variational assimilation method in the Nanfei River, Lake Chaohu Basin [J]. Journal of Lake Sciences, 2021, 33(5):1458-1466.)
- [14] Sun Mingzhuang, Li Zhili, Fu Guangtao, et al. ADAPT: a novel IoT-driven analytical data assimilation method based on phase-space tuning for long-sequence water quality forecasting [J]. Environmental Modelling & Software, 2026, 198:106882.
- [15] Lofton M E, Howard D W, Thomas R Q, et al. Progress and opportunities in advancing near-term forecasting of freshwater quality [J]. Global Change Biology, 2023, 29(7):1691-1714.
- [16] 赖锡军,傅国圣,孙波.非恒定水流计算的最优控制问题及其变分求解[J].水科学进展,2008,19(4):537-545.(Lai Xijun, Fu Guosheng, Sun Bo. Optimal control problems in unsteady flow computation and their variational solutions [J]. Advances in Water Science, 2008, 19(4):537-545. (in Chinese))
- [17] Hascoët L, Pascual V. The Tapenade automatic differentiation tool: principles, model, and specification [J]. ACM Transactions on Mathematical Software, 2013, 39(3):20.
- [18] Gilbert J C, Lemaréchal C. Some numerical experiments with variable-storage quasi-Newton algorithms [J]. Mathematical Programming, 1989, 45(1):407-435.
- [19] Li Zhijin, Wang Jinbo, Fu L L. An observing system simulation experiment for ocean state estimation to assess the performance of the SWOT mission: part 1, a twin experiment [J]. Journal of Geophysical Research: Oceans, 2019, 124(7):4838-4855.  
(收稿日期:2025-11-25 编辑:俞云利)