

高拱坝参数反演的 Jaya-高斯过程回归模型

马建婷¹, 康飞¹, 姜成磊², 向正林³, 王一帆¹

(1. 大连理工大学水利工程学院, 辽宁 大连 116024; 2. 吉林省水利水电勘测设计研究院, 吉林 长春 130021;
3. 南方电网调峰调频发电有限公司, 广东 广州 510630)

摘要: 为了提高高拱坝物理力学参数反演的精度及效率, 将 Jaya 智能优化方法与高斯过程机器学习理论引入大坝安全监控领域, 提出了基于 Jaya-高斯过程回归代理模型的拱坝参数反演分析方法。采用高斯过程回归代理模型代替传统的有限元计算, 并利用 3 种智能优化算法进行参数寻优。结果表明: Jaya 算法相比于 PSO 算法、GWO 算法, 不仅反演精度高、收敛速度快, 且具有很好的稳定性; 所提出反分析策略在反演用时方面比直接调用有限元计算的反分析方法节省 80% 以上。本文方法不仅能够满足计算精度要求, 且大大缩减了计算时间, 为高拱坝物理力学参数反演分析提供了一种高效的方法。

关键词: 高拱坝; 位移反分析; 高斯过程回归; 代理模型; Jaya 算法

中图分类号: TV642.4 **文献标志码:** A **文章编号:** 1006-7647(2022)04-0074-06

Jaya-Gaussian process regression model for parameter inversion of high arch dams//MA Jianting¹, KANG Fei¹, JIANG Chenglei², XIANG Zhenglin³, WANG Yifan¹ (1. School of Hydraulic Engineering, Dalian University of Technology, Dalian 116024, China; 2. Jilin Province Water Resources and Hydropower Consultative Company, Changchun 130021, China; 3. China Southern Power Grid Peak and Frequency Regulation Power Generation Co., Ltd., Guangzhou 510630, China)

Abstract: In order to improve the accuracy and efficiency for the inverse of physical and mechanical parameters of high arch dams, Jaya algorithm and Gaussian process machine learning theory were introduced into the field of dam safety monitoring, and an arch dam parameter inverse analysis method based on the Jaya-Gaussian process regression surrogate model was proposed. The Gaussian process regression surrogate model was used instead of the traditional finite element calculation, and three intelligent optimization algorithms were used to optimize the parameters. The results show that compared with PSO and GWO algorithm, Jaya algorithm not only has high inversion accuracy, fast convergence speed, and good stability, but also has good stability, and the proposed inverse analysis strategy saves more than 80% time compared with the inverse analysis method that directly calls finite element calculation. This method can not only meet the requirements of calculation accuracy, but also greatly reduce the calculation time, providing an efficient method for the inverse analysis of physical and mechanical parameters for high arch dams.

Key words: high arch dam; displacement inverse analysis; Gaussian process regression; surrogate model; Jaya algorithm

21 世纪以来,我国高拱坝建设取得了飞速发展,先后建成了小湾、锦屏一级、溪洛渡等多个特大型工程^[1-2]。正确估算坝体混凝土和坝基岩石的材料参数是进行拱坝安全评价与建立大坝安全监控模型的关键^[3]。拱坝物理力学参数反演分析是一个多参数组合的大空间搜索问题,求解算法十分重要^[4-5]。在拱坝的智能优化反演分析方面,刘耀儒等^[6]将改进的并行遗传算法用于溪洛渡拱坝位移

反演分析;李火坤等^[7]采用粒子群优化算法反演得到二滩拱坝的实际动弹性模量;Kang 等^[8]提出了一种求解反分析问题的混合单纯形人工蜂群算法;练继建等^[9]建立了反映大坝弹性模量与位移之间非线性关系的 BP 神经网络模型,并将其用于李家峡拱坝材料参数反演;Liu 等^[10]在反演过程中采用无约束拉格朗日支持向量回归来代替大型有限元计算,以获得弹性模量与变形的关系。

基金项目:国家自然科学基金(52079022);中央高校基本科研业务费专项(DUT19LK14);南方电网调峰调频发电有限公司项目(0200002019030304SG00003)

作者简介:马建婷(1997—),女,硕士研究生,主要从事大坝安全监测与分析研究。E-mail:majianting1019@163.com

通信作者:康飞(1982—),男,教授,博士,主要从事大坝安全监测与分析研究。E-mail:kangfei@dlut.edu.cn

目前的反演分析方法存在两方面不足:①基于有限元模型求解大坝静动力响应往往需要耗费大量的计算时间,对于某些大型结构甚至无法求解;②随着新型群体智能算法的提出,反演分析的精度还有待进一步提高。为此,本文将 Jaya 智能优化方法以及高斯过程回归(Gaussian process regression, GPR)理论引入大坝安全监控领域,提出了基于 Jaya-高斯过程回归代理模型的拱坝物理力学参数反演分析方法。

1 混凝土坝反演分析基本理论

对于大坝工程,建立大坝与坝基位移监控模型以后,依据正分析的结果,通过相应的理论反求大坝和地基的材料物理力学参数,即为大坝位移反演分析^[11]。若计算分析方法采用有限元法,则反演分析即为大坝的有限元模型修正。有限元模型修正是指利用静动力测试结果修改有限元模型的刚度、质量、边界条件等参数,修正后的模型不仅能够反映结构的实际状态,还可以用于损伤识别、安全评价等方面。

优化反演分析法是一种直接的反演分析方法,其适用性较强,通过建立目标函数,将反演问题转化为参数最优化问题,通过不断迭代逐次修正试算值,直至获得最佳值^[12]。静力计算采用有限元模型,基于位移监测数据分离水压分量反演坝体参数的数学模型可表达为

$$\begin{cases} \mathbf{K}\mathbf{u} = \mathbf{R} \\ \min w = \sum_{i=1}^m \left[\omega_i \left(\frac{\Delta u_{ie} - \Delta u_{in}}{\Delta u_{ie}} \right) \right]^2 \end{cases} \quad (1)$$

式中: \mathbf{K} 为刚度矩阵; \mathbf{u} 为位移向量; \mathbf{R} 为荷载向量; ω_i 为权重,通常取值为1; Δu_{ie} 为实测位移的变化值; Δu_{in} 为有限元计算得到的位移变化值; m 为测点数目。

2 基于 Jaya-高斯过程回归代理模型构建

2.1 Jaya 算法

Jaya 算法是一种新型智能优化算法,由 Rao^[13]于2016年提出。Jaya 算法设计的基本思想是群体应趋向最优解移动而远离最差解。该算法,除了常规的群体规模和搜索终止条件参数,无需输入其他特定参数;同时,更新方程只有一个,算法简单、易实现。

Jaya 算法的数学描述如下:令 $g(z)$ 为待优化的目标函数,在任意迭代次数 a 中, $\mathbf{Z}_j = (z_{b1}, z_{b2}, \dots, z_{bd})$ ($b=1, 2, \dots, N$) 为第 b 个候选解 (D 为设计变量的个数, N 为群体规模), $\mathbf{P}_b = (p_{b1}, p_{b2}, \dots, p_{bd})$ 为第 b 个候选解寻找的最优解。通过式(2)生成新的候选解,不断更新,逐渐收敛到最优解。

$$\mathbf{Z}_{a+1,b} = \mathbf{P}_{a,b} + r_1(\mathbf{Z}_{a,best} - |\mathbf{P}_{a,b}|) - r_2(\mathbf{Z}_{a,worst} - |\mathbf{P}_{a,b}|) \quad (2)$$

式中: $\mathbf{Z}_{a,best}$ 、 $\mathbf{Z}_{a,worst}$ 为第 a 次迭代整个群体中的最优解和最差解; r_1 、 r_2 为在(0,1)内的2个随机数。

2.2 GPR

GPR 最早由 Rasmussen 等^[14]提出,是一种机器学习新回归方法。其最大的优点是能够从训练数据中学习平滑参数和噪声以提供不确定性估计^[15]。

GPR 预测均值和协方差为

$$\bar{f}_* = \mathbf{K}(\mathbf{X}_*, \mathbf{X}) [\mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I}_n]^{-1} \mathbf{y} \quad (3)$$

$$\text{cov}(\mathbf{f}_*) = \mathbf{K}(\mathbf{X}_*, \mathbf{X}_*) -$$

$$\mathbf{K}(\mathbf{X}_*, \mathbf{X}) [\mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I}_n]^{-1} \mathbf{K}(\mathbf{X}, \mathbf{X}_*) \quad (4)$$

式中: \mathbf{f}_* 为预测值; \mathbf{X}_* 为测试值; \mathbf{X} 为输入值; \mathbf{y} 为输出值; σ_n^2 为方差; \mathbf{I}_n 为单位矩阵; $\mathbf{K}(\mathbf{X}, \mathbf{X})$ 为协方差矩阵,其元素为 $K_{ij} = k(x_i, x_j)$,元素 K_{ij} 为潜函数 $f(x_i)$ 和 $f(x_j)$ 的值之间的协方差。

由(3)式可知,协方差函数对 GPR 预报结果有一定的影响。因此,协方差函数的选择对于 GPR 建模的成功具有重要意义^[15]。常用的协方差函数为

$$k(\mathbf{x}, \mathbf{x}') = \sigma_f^2 \exp \left[-\frac{1}{2} (\mathbf{x} - \mathbf{x}')^T \mathbf{M} (\mathbf{x} - \mathbf{x}') \right] = \sigma_f^2 \exp \left[-\frac{1}{2} \sum_{i=1}^c \frac{(x_i - x'_i)^2}{l_i^2} \right] \quad (5)$$

式中: $k(\mathbf{x}, \mathbf{x}')$ 是在 \mathbf{x} 和 \mathbf{x}' 处计算的协方差函数; $\mathbf{M} = \text{diag}(\mathbf{I})^{-2}$; $\mathbf{l} = [l_1, l_2, \dots, l_c]^T$; \mathbf{l} 为方差尺度; σ_f^2 为信号方差。超参数的最优解通常通过牛顿法、共轭梯度法等优化方法来获得。

2.3 反演分析步骤

反演分析基本步骤如下:

步骤1 生成样本点。确定待反演区域弹性模量的取值范围,采用拉丁超立方抽样生成样本点。

步骤2 构建样本集。样本集由样本点及其各监测点的相对位移组成。采用有限元进行数值模拟,计算出各监测点的相对位移。

步骤3 建立 GPR 代理模型。利用前2步得到的训练样本集建立基于 GPR 的代理模型。

步骤4 检查 GPR 代理模型的准确性。利用步骤1和步骤2得到的测试样本,采用均方根误差(RMSE)作为样本精度的评价指标^[16],检验所建立的 GPR 代理模型的准确性。如果精度不满足,则返回到步骤1,生成更多的训练样本点,得到更准确的代理模型。

步骤5 参数优化反演。利用可代替有限元计算的 GPR 代理模型以及引入的智能优化算法进行参数优化反演,得到最优解,即为反演分析结果。

3 算例验证

某特高拱坝最大坝高 277 m,为混凝土双曲拱坝,有限元模型如图 1 所示,坝体和基础共分为 11 013 个单元,51 917 个结点。采用有限元正分析的计算结果来模拟大坝位移观测值的水压分量^[3]。选取的大坝变形监测点分别为 P_1 、 P_2 和 P_3 。选取一组弹模 $E = (E_1, E_2, E_3, E_4) = (21, 20, 13, 15)$ GPa,分别为坝体、底部基岩、左岸基岩和右岸基岩的弹性模量。求得上游水位为 820 m 和 790 m 的 2 种工况下 P_1 、 P_2 、 P_3 测点的相对水平位移分别为 16.60 mm、3.22 mm、-2.64 mm,相对垂直位移分别为 42.79 mm、45.23 mm、24.81 mm。反演时,选取坝体和基岩的弹模范围为 5~40 GPa^[16]。

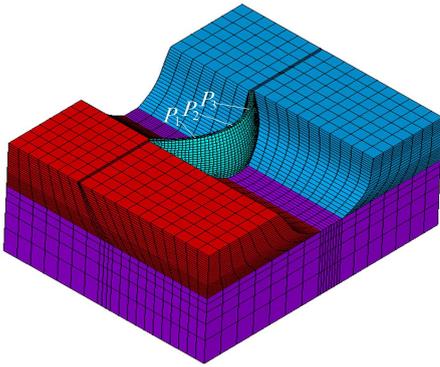


图 1 某特高坝体有限元模型

为建立 Jaya-高斯过程回归代理模型,研究了建模样本数量对精度的影响,将训练样本和测试样本(取为训练样本的 25%)的 RMSE 绘成曲线,如图 2 所示。根据图 2 可知,均方根误差呈下降趋势,样本的精度逐渐增加。当样本数量为 100D 时,均方根误差变化较小。因此,选取样本数量为 100D 的 GPR 代理模型代替有限元模型。

在该高拱坝反演分析中引入 Jaya 算法,并将它与粒子群算法^[17](particle swarm optimization, PSO)及灰狼算法^[18](grey wolf optimizer, GWO)做比较。3 种算法群体规模 $N=20$,最大迭代次数为 200,粒子群算法的其他参数参考之前的研究^[19]设置。为了避免算法的随机性,将优化算法运行 30 次^[16]。3 种算法的反演结果见表 1,最优适应值变化曲线和坝体混凝土弹性模量识别过程曲线分别如图 3、图 4 所示。

由表 1 可知,本文提出的反分析策略在该拱坝

表 1 算例 3 种算法反演结果

类型	$(E_1, E_2, E_3, E_4)/\text{GPa}$	平均相对误差 /%	$(\Delta u_{1x}, \Delta u_{1y}, \Delta u_{2x}, \Delta u_{2y}, \Delta u_{3x}, \Delta u_{3y})/\text{mm}$	绝对误差 /mm
理论值	(21, 20, 13, 15)		(16.60, 42.79, 3.22, 45.23, -2.64, 24.81)	
Jaya	(21.0505, 20.0992, 12.8199, 14.9881)	0.5504	(16.60, 42.86, 3.22, 45.19, -2.62, 24.78)	(0.00, 0.07, 0.00, 0.04, 0.02, 0.03)
PSO	(21.0505, 20.0993, 12.8199, 14.9881)	0.5505	(16.60, 42.86, 3.22, 45.19, -2.62, 24.78)	(0.00, 0.07, 0.00, 0.04, 0.02, 0.03)
GWO	(21.0933, 21.0039, 12.7358, 14.8685)	2.0932	(16.61, 42.85, 3.23, 45.11, -2.62, 24.78)	(0.01, 0.06, 0.01, 0.12, 0.02, 0.03)

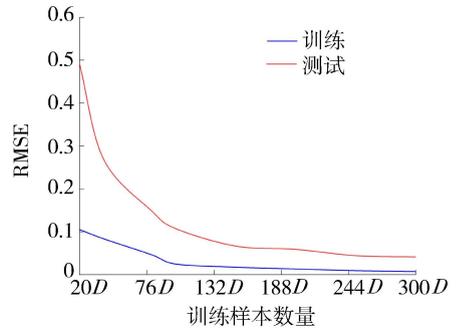


图 2 样本均方根误差趋势

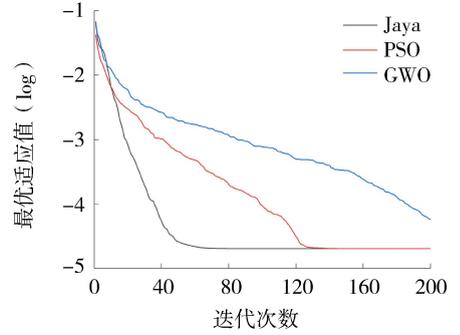


图 3 算例拱坝最优适应值变化曲线

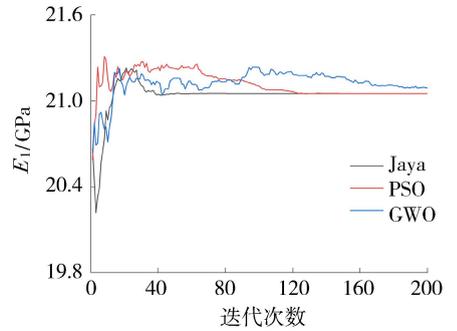


图 4 算例拱坝弹性模量 E_1 识别过程曲线

反演分析中是可行的。且 Jaya 算法比 PSO 算法、GWO 算法的精度更高。由图 3 及图 4 可知,达到收敛时,Jaya 算法的迭代次数约为 80 次,而 PSO 算法的约为 130 次,GWO 算法却始终没有达到收敛状态。此外,在 30 次的运行结果中,Jaya 算法和 PSO 算法的反演结果较为稳定,相对误差变化较小;而 GWO 算法反演结果的相对误差变化较大,最大误差为 9.3146%,最小误差为 0.4671%。

为了研究 3 种优化算法的抗噪声能力,在监测点的位移分别加 3% 的噪声,同样运行 30 次,结果见表 2。由表 2 可知,在加入 3% 噪声时,Jaya、PSO

表 2 加入 3% 噪声 3 种算法反演结果

类型	$(E_1, E_2, E_3, E_4)/\text{GPa}$	平均相对误差 /%	$(\Delta u_{1x}, \Delta u_{1y}, \Delta u_{2x}, \Delta u_{2y}, \Delta u_{3x}, \Delta u_{3y})/\text{mm}$	位移绝对误差 /mm
理论值	(21, 20, 13, 15)		(16.60, 42.79, 3.22, 45.23, -2.64, 24.81)	
Jaya	(20.4485, 20.0600, 12.4361, 14.4990)	2.6510	(17.11, 44.13, 3.32, 46.50, -2.70, 25.52)	(0.51, 1.34, 0.10, 1.27, 0.06, 0.71)
PSO	(20.4485, 20.0600, 12.4361, 14.4990)	2.6511	(17.11, 44.13, 3.32, 46.50, -2.70, 25.52)	(0.51, 1.34, 0.10, 1.27, 0.06, 0.71)
GWO	(20.4650, 20.4837, 12.4072, 14.4575)	3.2856	(17.11, 44.12, 3.33, 46.46, -2.70, 25.52)	(0.51, 1.33, 0.11, 1.23, 0.06, 0.71)

及 GWO 算法的反演结果的平均相对误差分别为 2.6510%、2.6511% 和 3.2856%，均较小。因此，在加入 3% 噪声时 3 种算法对该混凝土拱坝的反演结果是可靠的。

在反演用时方面，由表 3 可知，GPR 代理模型比有限元模型节省约 87.48% 的时间。由此可以看出，基于 Jaya-GPR 代理模型的拱坝物理力学参数反演分析方法在保持计算精度的同时，计算效率也具有较大的优势。

表 3 算例反演用时计算结果

类型	构建样本集所需的时间/s	建立 GPR 代理模型所需时间/s	运行 1 次算法反演所需时间/s	反演全部用时/s
有限元模型			112284.9	112284.9
GPR 代理模型	14034.0	11.2	13.3	14058.5

4 实例应用

以西南某高拱坝为例，该高拱坝坝顶高程 610.0m，最大坝高 285.5m，顶拱中心线弧长 681.5m，厚高比为 0.216，弧高比为 2.451。依据坝体几何参数及设计相关资料，建立有限元分析模型。其中坝基范围为：向上下游、左右岸和河床深部分别延伸 1.5 倍坝高，整个模型划分为 233 538 个单元，261 734 个结点，有限元网格如图 5、图 6 所示。边界条件定义为：坝基底部为三向固定约束，4 个侧面为法向固定约束。其中坝体混凝土和坝基的材料参数除待反演的弹性模量，其余值均采用设计值。

于拱坝左岸坝肩、5 号坝段、10 号坝段、15 号坝段、22 号坝段、27 号坝段、右坝肩拱布置 7 组 29 个正垂线测点用以监测坝体水平位移（图 7）。根据监测数据显示 7 组测线中位于坝体中心线的 15 号坝段垂

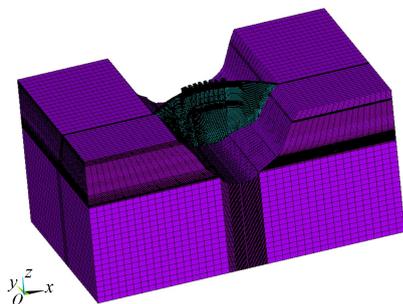


图 5 拱坝整体有限元模型

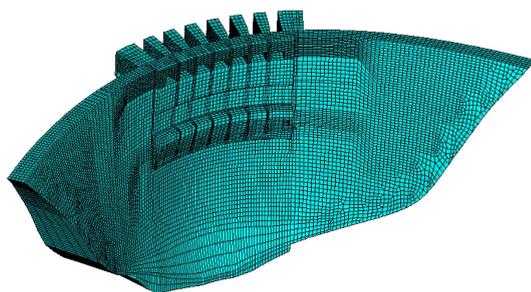


图 6 坝体有限元模型

线监测到的坝体水平位移最大，且由于切向位移较小，实际观测值的误差相对较大，因此本文将以 15 号坝段径向位移监测数据作为研究对象开展分析。

对于 15 号坝段的温度监测数据，取与它相邻的 16 号坝段布置在坝体表面的 32 个温度传感器和布置在坝体内部的 19 个应力应变传感器，温度传感器分布图如图 8 所示，从图 8 可见拱坝温度测点较多，在应用回归模型时难以考虑全部温度测点，经过分析削减以后，仍有 15 个，故考虑提取主成分的方式，采用 SPSS 软件，对 15 个已有的温度因子进行降维处理，提取前 4 个主要成分（保留温度测量信息的 90.599%）。按照传统多元回归模型的因子选择方法，最终自变量因子设计为

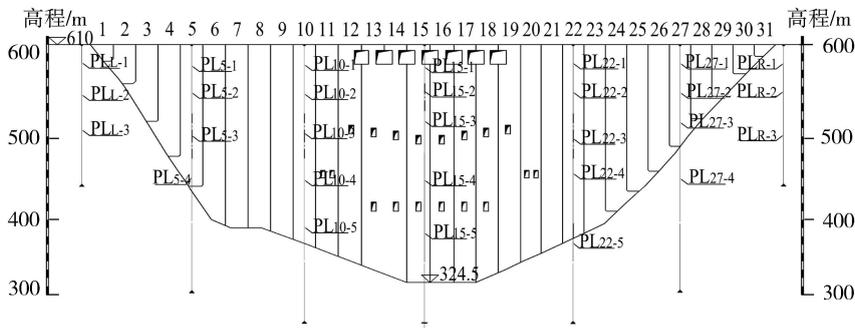


图 7 拱坝正垂线及变形测点布置

$$V = (h, h^2, h^3, h^4, T_{PC1}, T_{PC2}, T_{PC3}, T_{PC4}, -\exp(-0.5t)) \quad (6)$$

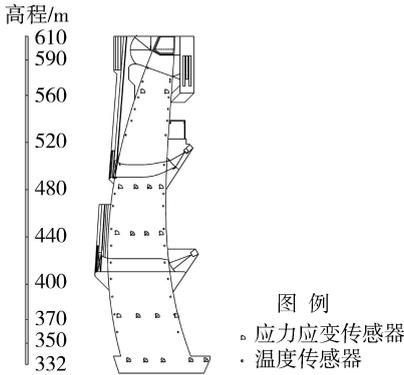


图8 拱坝温度传感器分布

式中： h 为水压因子，取上游水深； T_{PC} 为主成分分析得到的温度因子； t 为时间，取从监测日到始测日的天数除以 365。选取测点 PL₁₅₋₁ 及测点 PL₁₅₋₂ 在 2014 年 7 月 6 日至 2017 年 11 月 29 日的实测径向位移建立统计回归模型。其中实测值、拟合值及各位移分量结果如图 9 所示。为计算简便，荷载工况选取上游水位为 599.76 m 和 559.44 m 情况下的水压差值作为位移反分析的荷载条件，其计算结果是在水压荷载作用下拱坝的位移差值。

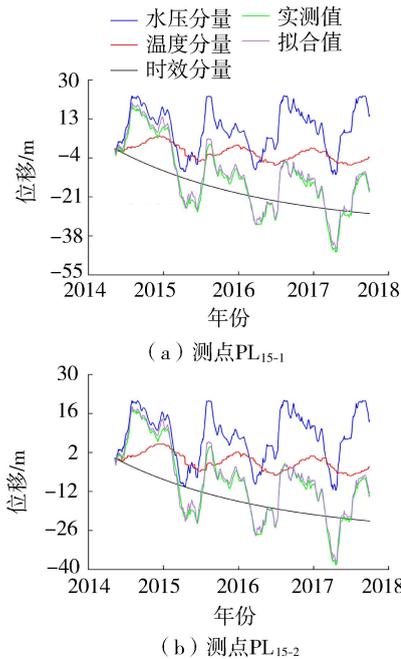


图9 拱坝 PL₁₅₋₁ 测点各位移分量分离结果

径向位移对应拱坝的极坐标系，需将其进行坐标转换，得到有限元模型坐标系下的位移值，即 $\Delta u_{15-1x} = -25.3718 \text{ mm}$ ， $\Delta u_{15-2x} = -23.0472 \text{ mm}$ 。

根据相关试验资料，混凝土和岩体弹性模量的取值范围设置为：坝体 $E_1 = 35 \sim 60 \text{ GPa}$ ，地基 $E_2 = 15 \sim 40 \text{ GPa}$ 。训练样本数量为 $100D$ ，建立 GPR 代理模型。3 种算法群体规模 $N = 20$ ，最大迭代次数为

200，每种算法随机运行 30 次^[16]。3 种算法弹性模量的反演结果见表 4，最优适应值变化曲线及弹性模量识别过程曲线分别如图 10 和图 11 所示。

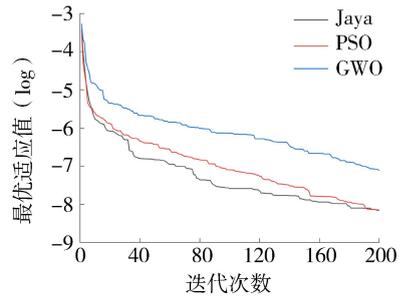


图10 实例拱坝最优适应值变化曲线

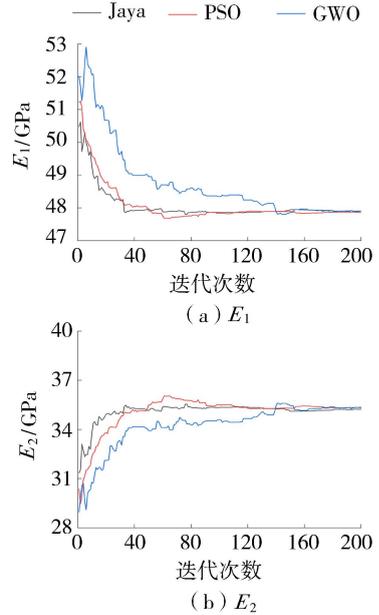


图11 实例拱坝弹性模量识别过程曲线

为了进一步验证反演结果，将上述反演结果，用有限元计算坝体测点在上游水位为 599.76 m 和 559.44 m 状态下的位移差值，并与实测位移水压分量差值进行比较。从表 4 中看出，两者接近，总体误差较小，说明反演的成果是合理的。

表4 实例3种算法反演结果

类型	$(E_1, E_2)/\text{GPa}$	$(\Delta u_{15-1x}, \Delta u_{15-2x})/\text{mm}$	绝对误差/mm
分离值		$(-25.3718, -23.0472)$	
Jaya	(47.9016, 35.2260)	$(-25.3713, -23.0467)$	(0.0005, 0.0005)
PSO	(47.8548, 35.3571)	$(-25.3711, -23.0458)$	(0.0007, 0.0014)
GWO	(47.9055, 35.2892)	$(-25.3602, -23.0363)$	(0.0116, 0.0109)

在反演用时方面，由表 5 可知，采用 GPR 代理模型相比有限元模型节省时间约 93.75%。进一步

表5 实例反演用时计算结果

模型	构建样本集所需时间	建立 GPR 代理模型所需时间	运行 1 次反演算法所需时间	反演全部用时
有限元模型			696424.1	696424.1
GPR 代理模型	43526.2	2.8	5.7	43534.7

证明了所提出的基于 Jaya-GPR 代理模型能大幅度提高体系反演分析的效率。

5 结 论

a. 高斯过程回归用于混凝土拱坝反演分析的代理模型是有效的,与有限元模型计算结果一致。

b. 与其他算法相比,Jaya 算法具有控制参数少、反演精度高、收敛速度快、稳定性好等优点。

c. 提出的基于 Jaya-GPR 代理模型的拱坝物理学参数反演分析方法能够大幅度的提高反演分析的效率,相比于基于传统有限元的反演方法,用时节省了 80% 以上。

参考文献:

[1] 王仁坤. 我国特高拱坝的建设成就与技术发展综述 [J]. 水利水电科技进展,2015,35(5): 13-19. (WANG Renkun. Review of construction achievements and technological development of super-high arch dam in China [J]. Advances in Science and Technology of Water Resources,2015,35(5):13-19. (in Chinese))

[2] 顾冲时,苏怀智,刘何稚. 大坝服役风险分析与管理研究述评 [J]. 水利学报,2018,49(1): 26-35. (GU Chongshi,SU Huaizhi,LIU Hezhi. Review on service risk analysis of dam engineering [J]. Journal of Hydraulic Engineering,2018,49(1):26-35. (in Chinese))

[3] 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))

[4] 王少伟,徐丛,苏怀智. 锦屏一级拱坝黏弹性工作性态反演分析 [J]. 水利水电科技进展,2020,40(5):62-69. (WANG Shaowei, XU Cong, SU Huaizhi. Back analysis of viscoelastic working behavior for Jinping-I Arch Dam [J]. Advances in Science and Technology of Water Resources,2020,40(5):62-69. (in Chinese))

[5] 康飞,李俊杰,许青,等. 改进人工蜂群算法及其在反演分析中的应用 [J]. 水电能源科学,2009,27(1): 126-129. (KANG Fei, LI Junjie, XU Qing, et al. Improved artificial bee colony algorithm and its application in back analysis [J]. Water Resources and Power,2009,27(1): 126-129. (in Chinese))

[6] 刘耀儒,杨强,刘福深,等. 基于并行改进遗传算法的拱坝位移反分析 [J]. 清华大学学报(自然科学版),2006,46(9): 1542-1545. (LIU Yaoru,YANG Qiang,LIU Fushen,et al. Inverse analysis of arch dam displacements using improved parallel genetic algorithm [J]. Journal of

Tsinghua University (Science and Technology),2006,46(9):1542-1545. (in Chinese))

[7] 李火坤,王刚,魏博文,等. 基于敏感性分析与粒子群算法的拱坝原型动弹性模量反演方法 [J]. 水利学报,2020,51(11): 1401-1411. (LI Huokun,WANG Gang,WEI Bowen,et al. Inversion of prototype dynamic elastic modulus of arch dam based on sensitivity analysis and particle swarm optimization [J]. Journal of Hydraulic Engineering,2020,51(11): 1401-1411. (in Chinese))

[8] KANG F, LI J, XU Q. Structural inverse analysis by hybrid simplex artificial bee colony algorithms [J]. Computers and Structures, 2009, 87(13/14):861-870.

[9] 练继建,王春涛,赵寿昌. 基于 BP 神经网络的李家峡拱坝材料参数反演 [J]. 水力发电学报,2004,23(2): 44-48. (LIAN Jijian,WANG Chuntao,ZHAO Shouchang. The convolute analysis of Lijiaxia Arch Dam material parameter based on BP Neural network [J]. Journal of Hydroelectric Engineering,2004,23(2):44-48. (in Chinese))

[10] LIU C, GU C, CHEN B. Zoned elasticity modulus inversion analysis method of a high arch dam based on unconstrained Lagrange support vector regression (support vector regression arch dam) [J]. Engineering with Computers, 2016, 33(3):443-465.

[11] 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.

[12] 许国敏. 围岩位移智能反分析在雪峰山公路隧道中的应用研究 [D]. 成都:成都理工大学,2007.

[13] RAO R. Jaya: a simple and new optimization algorithm for solving constrained and unconstrained optimization problems [J]. International Journal of Industrial Engineering Computations, 2016, 7(1):19-34.

[14] RASMUSSEN C E, WILLIAMS C K I. Gaussian processes for machine learning [M]. Cambridge (MA): The MIT Press, 2006.

[15] KANG F, LI J. Displacement model for concrete dam safety monitoring via Gaussian process regression considering extreme air temperature [J]. Journal of Structural Engineering, 2020, 146(1):05019001.

[16] 姜成磊. 基于群体智能-代理模型的高混凝土坝反演分析 [D]. 大连:大连理工大学,2019.

[17] EBERHART R, KENNEDY J. A new optimizer using particle swarm theory [C]//MHS'95. Proceedings of the Sixth International Symposium on Micro Machine and Human Science. New York:IEEE, 2002:39-43.

[18] SM A, SMM B, AL A. Grey wolf optimizer [J]. Advances in Engineering Software, 2014, 69(3):46-61.

[19] KANG F, LI J, LI J. System reliability analysis of slopes using least squares support vector machines with particle swarm optimization [J]. Neurocomputing, 2016, 209(12):46-56.

(收稿日期:2021-07-05 编辑:刘晓艳)