

DOI: 10. 20040/j. cnki. 1000-7709. 2023. 20222486

# 基于多目标优化的 WOA-BPNN 高拱坝变形模量反演分析

刘欣航<sup>1</sup>, 娄一青<sup>2</sup>, 郑东健<sup>1</sup>

(1. 河海大学水利水电学院, 江苏 南京 210098; 2. 温州市水利电力勘测设计院有限公司, 浙江 温州 325002)

**摘要:** 随着大坝服役年限的增加, 根据原型观测资料对坝体和坝基的力学参数进行反演十分必要, 目前大坝反分析模型仍以坝体实测位移场监控模型为主, 其只能反映宏观上坝体和坝基的位移变化规律, 而忽视了微观上大坝应变场和应力场的变化规律。因此, 通过同时考虑大坝位移监测数据及大坝应变监测数据, 提出了一种基于 MOEA/D 和 WOA-BPNN 的高拱坝力学参数反演模型, 并采用某拱坝坝体位移测点及应变测点, 对拱坝坝体混凝土及基础岩体的力学参数进行了反演分析。结果表明, 最终反演结果更加准确、合理。

**关键词:** 高拱坝; 参数反演; 机器学习; 多目标优化; 有限元

**中图分类号:** TV311

**文献标志码:** A

**文章编号:** 1000-7709(2023)10-0096-04

## 1 引言

近年来, 在大坝力学参数反演分析中, 以神经网络为代表的近似反演方法逐渐发展起来<sup>[1]</sup>, 韩峰等<sup>[2]</sup>针对坝基岩体力学参数试验值与实际不符的问题, 利用 PSO 算法结合有限元软件对坝基力学参数进行了反演分析, 结果显示反演效率较高; 胡清义等<sup>[3]</sup>利用在线支持向量机及有限元模型对拱坝坝体坝基变形模量进行反演分析, 结果准确、可靠; 李宗樾等<sup>[4-6]</sup>针对大坝位移响应模型复杂及力学参数试验值与实际不符的难题, 基于统计模型和有限元法反演得到坝体坝基力学参数; 刘西等<sup>[7-9]</sup>针对常规反演算法收敛慢、精度差等问题, 提出利用 Jaya 智能优化方法、GRU-WPA 法、烟花算法、IAGA-BP 算法进行大坝力学参数反演, 有效提高了计算精度。已有研究方法在大坝力学参数反演过程中得到了广泛应用, 但均只考虑了大坝单一监测项目, 由于大坝变形监测项目的多样性, 只考虑单一监测项目并不能全面反映大坝结构变形。因此, 黎维业等<sup>[10]</sup>针对单一监测项目可能存在局限性等问题, 提出基于多目标优化算法 NSGA-II 利用大坝位移测值及应变测值进行大坝参数反演, 但算法计算复杂度过高, 只能选取多种监测项目单一测点, 并未对

大坝整体变形场进行建模分析。因此, 本文提出 MOEA/D 的 WOA-BPNN 的反演方法, 综合考虑大坝监测系统位移和应变, 提出利用 WOA-BPNN 方法构建大坝变形模量一位移、变形模量一应变的代理模型构建目标函数, 结合多目标优化算法 MOEA/D, 反演得出大坝力学参数, 通过与实测位移资料 and 传统机器学习方法进行对比, 验证该方法在大坝力学参数反演中的结果更合理。

## 2 力学参数反演方法

### 2.1 代理模型的构建

基于 WOA-BPNN 方法构建拱坝的变形模量一位移、变形模量一应变的代理模型, 以代替繁琐耗时的有限元模型计算, 模型构建完成后可用于 MOEA/D 算法目标函数的构建。WOA 算法<sup>[11]</sup>(Whale Optimization Algorithm)为生物启发类算法, BPNN(BP 神经网络)是一种按误差反向传播训练的多层前馈网络, 其主要原理是在得到神经网络的预测结果后, 如果其预测值与实际值存在误差, 通过梯度下降, 既反向求导, 评估神经网络超参数对误差的影响, 同时设置学习率用来更新神经网络的权重和阈值, 以达到指定目标, 由于坝体系统复杂的非线性映射关系, 神经网络

**收稿日期:** 2022-11-25, **修回日期:** 2023-01-18

**基金项目:** 国家自然科学基金项目(52179128)

**作者简介:** 刘欣航(1999-), 男, 博士研究生, 研究方向为水工结构安全监测, E-mail: 1524932075@qq.com

**通讯作者:** 郑东健(1965-), 男, 教授、博导, 研究方向为水工结构安全监测, E-mail: zhengdj@hhu.edu.cn

拓扑结构可设置多层。本文通过经验公式及试算法确定神经网络架构后,将神经网络的初始权重及阈值作为寻优参数送入 WOA 算法中进行寻优,最终输出的最优个体作为神经网络的初始权重及阈值,用此方法构建神经网络可有效降低训练时间,节约训练成本。

## 2.2 多目标优化算法 MOEA/D

MOEA/D 算法<sup>[12]</sup> (Multi-object Evolution Algorithm Based on Decomposition)将多目标优化问题转化为一系列单目标优化子问题或多目标的子问题,同时对这些子问题进行优化,在优化过程中利用相邻的几个子问题的信息进行优化。从而向整个 Pareto 前沿逼近。

针对一个多目标优化问题,具体数值视代理模型而定,为具体监测项目测点差值;目标即让所有  $f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_i(\mathbf{x})$  尽可能同时接近实际值  $y_1, y_2, \dots, y_i$ , 即尽可能让目标函数  $F_1, F_2, \dots, F_i$  同时接近理想点  $Z_1, Z_2, \dots, Z_i$ , 本文目标函数的理想点均为 0, 即:

$$(F_1(\mathbf{x}) = f_1(\mathbf{x}) - y_1, \dots, F_i(\mathbf{x}) = f_i(\mathbf{x}) - y_i) \quad (1)$$

式中,  $i$  为目标函数的维度,  $i = 2$  (位移、应变);  $f_i(\mathbf{x})$  为构建的代理模型;  $\mathbf{x}$  为一组决策变量, 为大坝分区变形模量及六维向量;  $y_i$  为实际值。

设置样本数为  $j = 100$ , 首先生成与种群数目  $j$  相同的均匀分布的权重向量  $\lambda^j = (\lambda_1^j, \lambda_2^j, \dots, \lambda_i^j)$ , 且  $\sum_{i=1}^m \lambda_i^j = 1$ , 同时利用式(2)计算同一组权重向量下目标函数的切比雪夫距离  $D_{\text{Chess}}$ :

$$D_{\text{Chess}} = \max_{1 \leq i \leq m} \{ \lambda_i^j | F_i(\mathbf{x}) - Z_i | \} \quad (2)$$

随后对于每个个体进行更新迭代, 根据与其他权重之间的欧氏距离, 选取指定数目的相邻个体, 采用遗传算子进行交叉变异。交叉算子  $\gamma$  为:

$$\gamma = \begin{cases} (2p_{\text{ro}})^{1/3} & p_{\text{ro}} \leq 0.5 \\ [2(1-p_{\text{ro}})]^{-1/3} & p_{\text{ro}} \geq 0.5 \end{cases} \quad (3)$$

$$\begin{cases} \tilde{x}_j = 0.5 [(1+\gamma)x_j + (1-\gamma)x_i] \\ \tilde{x}_i = 0.5 [(1-\gamma)x_j + (1+\gamma)x_i] \end{cases} \quad (4)$$

式中,  $p_{\text{ro}}$  为交叉概率;  $x_i, x_j$  分别为参与交叉的两个个体;  $\tilde{x}_i, \tilde{x}_j$  为参与交叉之后的两个全新个体。

变异算子  $\gamma'$  为:

$$\gamma' = \begin{cases} (2p_{\text{ro}})^{1/6} - 1 & p_{\text{ro}} \leq 0.5 \\ 1 - (2p_{\text{ro}})^{1/6} & p_{\text{ro}} \geq 0.5 \end{cases} \quad (5)$$

$$\tilde{x}'_j = x'_j + \gamma' \quad (6)$$

式中,  $x'_j$  为参与变异的个体;  $\tilde{x}'_j$  为参与变异之后

的全新个体。

在获取最新个体后, 更新全局最优。满足结束要求后, 所得解集即为帕累托最优解集。

## 2.3 决策目标

通过 MOEA/D 算法迭代后, 生成帕累托最优解集, 并非唯一解, 因此需进行方案决策, 在实际工程中, 大坝坝体坝基材料参数设计定值往往具有参考意义, 在决策过程中应将其考虑进去。因此, 可结合实际材料参数偏离设计材料参数的实际程度, 构建偏离函数来评价具体偏离程度:

$$\min \left\{ \text{Dec} = \sqrt{\sum_{j=1}^m \left( \sum_i^6 \frac{x_i - x_i^L}{x_i^H - x_i^L} \right) (F_j(\mathbf{x}) - Z_j)^2} \right\} \quad (7)$$

式中,  $x_i$  为帕累托最优解集中某一解的第  $i$  分量, 即第  $i$  个材料分区取值;  $x_i^L, x_i^H$  分别为第  $i$  个材料分区设计值下限、上限。

## 2.4 反演分析步骤

根据资料, 建立考虑拱坝复杂地质构造的数值仿真模型。并确定拱坝反演区域变形模量取值范围, 采取拉丁超立方采样生成样本点, 并利用有限元软件 Abaqus 构建样本集。将其划分训练集、验证集; 送入神经网络进行训练, 并通过 WOA 优化算法优化神经网络, 将训练好的神经网络作为代理模型。通过代理模型构造多目标优化算法的目标函数, 代入多目标优化算法 MOEA/D, 得到帕累托最优解集, 最终决策出最优解。

## 3 实例应用

某水电站为混凝土双曲薄拱坝, 体型为抛物线双曲变厚拱坝, 坝顶高程 343 m, 坝底高程 235 m, 最大坝高 108 m, 水库正常蓄水位 340 m, 死水位 290 m。

坝体水平位移监测项目包括坝顶和坝体下游面测点交会法观测项目和垂线水平位移观测项目等。大坝监测仪器布置见图 1。图 1 中, PL 为正垂线, IP 为倒垂线; 正垂线位于坝顶、307 m 高程廊道、272 m 高程廊道及基础廊道之间, 倒垂线位于建基面附近, 锚固点深入建基面 55 m, 应变计为五向应变计, 由于应变计 5 方向测量的是上下游方向上的应变, 因此本次反演均采用应变计的 5 方向分量进行计算, 具体见图 1。

### 3.1 计算模型

三维模型以坝顶拱圈上游侧中点为坐标原点, 模拟范围为向上游、下游分别延伸 1.5 倍坝高, 左右岸以坝顶拱圈左右两端节点为起点延长




图1 大坝监测仪器布置图

Fig. 1 Dam monitoring equipment layout

至 1.5 倍坝高, 坝底以下 1 倍坝高, 模型共有 96 331 个节点, 106 384 个单元。为保证坝基计算结果的准确性, 模型模拟了拱坝坝基左右两岸共六条主要断层, 见图 2。




图2 有限元整体图及断层分布图

Fig. 2 Finite element global map and fault distribution map

通过采取水位相差较大的 2 d 的位移增量和应变增量进行反演。分别为 2021-05-24 (高水位), 水位为 339.46 m; 2021-04-14 (低水位), 水位为 298.74 m。

### 3.2 回归模型构建

在水压力、扬压力、泥沙压力和温度等荷载作用下, 对大坝任一点产生的变形矢量  $\theta$ , 可分解为水压分量、温度分量和时效分量。选取 2019~2022 年的大坝监测数据构建回归模型, 有效分离监测数据的水压分量、温度分量和时效分量。对于监测数据中的部分突变点, 由于突变数据较少, 所以进行了手动删除。

### 3.3 反演材料参数区间确定

拱坝主体混凝土采用 C20 混凝土, 根据相关规范及工程经验, 将材料变形模量反演区间向上拓宽 1.5 倍, 确定最终反演区间为 20~35 GPa; 坝基多为微风化—新鲜岩体, 从上往下可依次分为三层, 根据相关设计报告, 并结合具体工程地质情况, 适当拓宽反演区间, 确定最终反演区间分别为微风化下部晶屑凝灰熔岩为 8~12 GPa、微风化晶屑凝灰熔岩为 13~17 GPa、新鲜岩体为 18~22 GPa。

### 3.4 样本集构建及网络训练

通过拉丁超立方采样法形成参数样本, 已知

神经网络输入向量为六维, 输出向量为五维和二维, 根据经验公式和试算法确定神经网络拓扑结构为 5-11-15-5 和 5-11-15-2。划定 95% 的样本为训练样本, 5% 为测试样本, 隐含层函数为 Relu, 最大迭代次数为 100 次, 构建好神经网络后送入 WOA 算法优化初始阈值和权重, 种群数量为 50, 最大迭代次数为 1 000, 得到初试权重和阈值后送入样本进行训练, 得到最终的代理模型。

### 3.5 多目标优化算法参数设置

构建好代理模型和目标函数后, 进行多目标优化算法参数设置, 利用 MOEA/D 算法进行优化, 设置初始种群数为 100, 迭代次数为 80, 计算完成后, 共输出 61 个解为 Pareto 解, Pareto 图见图 3。




图3 Pareto 最优前沿图

Fig. 3 Pareto optimal frontier diagram

### 3.6 反演结果分析

#### 3.6.1 反演结果

通过 MOEA/D 算法迭代, 采用本文决策方法, 获得最终选取的力学反演结果见表 1。由表 1 可知, 坝体坝基最终反演参数均位于反演取值范围内, 并符合相关物理规律。

表1 变形模量最终反演取值

Tab. 1 Final inversion value of deformation modulus GPa

| 材料分区         | 反演取值  | 材料分区        | 反演取值  |
|--------------|-------|-------------|-------|
| 坝高 235~271 m | 22.73 | 微风化下部晶屑凝灰熔岩 | 11.17 |
| 坝高 271~308 m | 24.21 | 微风化晶屑凝灰熔岩   | 14.96 |
| 坝高 308~343 m | 24.20 | 新鲜岩体        | 20.33 |

将反演取值代入有限元软件中进行计算, 可得最终的反演差值。

#### 3.6.2 反演方法对反演精度的影响

与传统的机器学习反演方法不同, 本文主要采用基于 MOEA/D 的多目标优化算法同时优化大坝的位移目标函数和应变目标函数, 在尽量满足大坝位移目标函数的前提下, 拟合大坝应变增量, 实现多重监测数据的利用。为评价与传统方法的不同, 将 WOA 与 BPNN 相结合, 对比使用多目标优化算法前后大坝位移反演差值和应变反演差值精度的变化 (差值即为水位相差较大工况下所选测点的位移增量及应变增量), 具体见表 2。其中, 反演差值 1 为本文所提方法计算所得反演差值, 反演差值 2 为 WOA 算法与 BPNN 相结合所得反演差值。

表 2 反演差值精度对比

Tab. 2 Comparison of inversion difference accuracy

| 测点     | PL8   | PL5   | PL4  | PL3   | IP3  | S8-15 | S8-25  |
|--------|-------|-------|------|-------|------|-------|--------|
| 实际差值   | 17.12 | 13.38 | 7.77 | 15.95 | 1.41 | -8.50 | -21.25 |
| 反演差值 1 | 12.05 | 11.15 | 9.05 | 12.19 | 2.05 | -5.58 | -22.79 |
| 反演差值 2 | 9.12  | 8.18  | 8.31 | 10.58 | 1.97 | -4.72 | -19.28 |

由表 2 可知,运用多目标优化算法所得的反演插值总体精度上升了 46.35%,在应变差值方面,对于本文两个应变测点,精度分别提升了 10.12%、2.02%。

## 4 结论

a. 基于多目标优化算法的反演方法,综合考虑了大坝位移测点和应变测点,反演计算所得的大坝位移增量和应变增量与实测增量基本吻合,虽部分测点有所差距,但总体趋势相同;通过 Abaqus 有限元模型计算,确定大坝工作性态良好。

b. 基于多目标优化算法的反演方法,与传统机器学习反演方法相比,反演所得大坝力学参数更能反映大坝实际工作状态,且由于其考虑了大坝应变测点数据,在位移测点反演精度变化不大的情况下,其在应变位移测点反演精度方面有一定程度的提高。

### 参考文献:

- [1] 梁国贺. 时空全域代理模型及大坝参数反演应用 [D]. 北京:清华大学, 2017.
- [2] 韩峰, 徐磊, 张太俊. 坝基岩体力学参数的 PSO-ABAQUS 联合反演 [J]. 河海大学学报(自然科学

版), 2013, 41(4): 321-325.

- [3] 胡清义, 朱喜, 田功臣. 构皮滩拱坝坝体与坝基变形模量反演分析 [J]. 武汉大学学报(工学版), 2021, 54(9): 801-809.
- [4] 李宗樾, 程井, 张枝阳, 等. 基于有限元法的高拱坝分区变形模量反演分析 [J]. 三峡大学学报(自然科学版), 2018, 40(4): 1-5.
- [5] 刘毅, 高阳秋晔, 张国新, 等. 锦屏一级特高拱坝工作性态仿真与反演分析 [J]. 水利水电技术, 2017, 48(1): 46-51.
- [6] 袁占荣, 周天宇, 吕维娟, 等. 龙羊峡重力拱坝运行期变形与应力反演分析 [J]. 水力发电, 2022, 48(9): 62-66, 107.
- [7] 刘西, 康飞, 李俊杰. 基于智能参数反演的混凝土坝位移监控指标拟定 [J]. 水电能源科学, 2022, 40(7): 111-114, 97.
- [8] 张进, 牛志伟, 齐慧君, 等. 基于烟花算法的重力坝坝基模量在线反演分析 [J]. 水电能源科学, 2021, 39(1): 96-100.
- [9] 赵英华, 李同春, 程井, 等. 基于统计模型及有限元法的重力坝变形模量反演 [J]. 水电能源科学, 2015, 33(12): 96-100.
- [10] 黎维业, 吴震宇. 基于 PSO-BPNN 和多目标优化的混凝土坝参数反演 [J]. 中国农村水利水电, 2023(3): 229-234.
- [11] MIRJALILI S, LEWIS A. The whale optimization algorithm [J]. Advances in engineering software, 2016, 95: 51-67.
- [12] ZHANG Q, LI H. MOEA/D: A multiobjective evolutionary algorithm based on decomposition [J]. IEEE Transactions on evolutionary computation, 2007, 11(6): 712-731.

## Inversion Analysis of High Arch Dam Mechanical Parameters Based on Multi-objective Optimization Strategy and WOA-BPNN

LIU Xin-hang<sup>1</sup>, LOU Yi-qing<sup>2</sup>, ZHENG Dong-jian<sup>1</sup>

(1. College of Water Conservancy and Hydropower Engineering, Hohai University, Nanjing 210098, China; 2. Wenzhou Water Conservancy and Electric Power Survey and Design Assembly Company Ltd., Wenzhou 325002, China)

**Abstract:** With the increase of the service life of the dam, inversion analysis of dam mechanical parameters based on the prototype monitoring data is necessary. At present, the dam inversion analysis model is still mainly based on the dam displacement monitoring data, which can only reflect the dam displacement law at the macroscopic level, while the change law of the strain field and stress field of the dam is ignored from the mesoscopic perspective. Therefore, a high arch dam mechanical parameter inversion model based on WOA-BPNN and MOEA/D was proposed, which consider both the dam displacement monitoring data and the dam strain monitoring data. The mechanical parameter inversion analysis of the arch dam was carried by the dam's displacement data and strain data. The results show that the inversion parameter is more accurate and reasonable.

**Key words:** high arch dam; parameter inversion; machine learning; multi-objective optimization; finite element