

DOI: 10.20040/j.cnki.1000-7709.2023.20230213

# 特高拱坝多参数反演的智能优化径向基函数网络模型

寇文状<sup>1</sup>, 康 飞<sup>1</sup>, 梅 智<sup>2</sup>

(1. 大连理工大学水利工程学院, 辽宁 大连 116023; 2. 中国电建集团中南勘测设计研究院有限公司, 湖南 长沙 410014)

**摘要:** 利用大坝的监测数据对大坝力学参数进行精确反演, 对于确保大坝的安全稳定运行至关重要。对此, 提出基于径向基函数(RBF)网络和人工大猩猩部队优化算法(GTO)的拱坝参数反演模型。首先, 采用 RBF 代理模型代替有限元模型, 探讨材料参数与监测点位移响应之间的关系, RBF 代理模型的采样数据由高效的拉丁超立方采样技术生成; 其次, 采用 GTO 智能优化算法, 使材料参数识别的目标函数最小。工程实例分析结果表明, RBF-GTO 模型能够在降低计算成本的同时实现高精度的混凝土特高拱坝参数反演分析。

**关键词:** 径向基函数网络; 代理模型; 位移反分析; 智能优化; 特高拱坝

**中图分类号:** TV642.4 **文献标志码:** A **文章编号:** 1000-7709(2023)11-0069-04

## 1 引言

大坝作为水利枢纽的核心建筑物, 其运行安全对于枢纽的正常运行及下游群众的财产安全至关重要。由于长期运行造成的损伤累积, 使得大坝在正常使用条件下的实际力学参数与初始设计参数不同<sup>[1]</sup>。因此, 准确识别力学参数对于评估大坝性能有重要意义。近年来, 智能优化理论已广泛应用于拱坝参数反演分析, 但在采用常规有限元模型解决实际工程问题时, 存在计算量大、难以求解等问题; 传统的优化算法在反演分析时存在收敛速度慢、易陷入局部最优等问题。为提高计算效率与反演精度, 本文将 RBF 网络与人工大猩猩部队优化算法(GTO)引入混凝土拱坝反演分析中, 通过工程实例分析验证了该方法的可行性。

## 2 基本理论

### 2.1 混凝土坝位移反分析理论

位移监测是大坝监测的常规项目, 且位移信息通常准确可靠, 因此将位移值作为反分析的目标值。在有限元方法中, 静力学问题的解方程为:

$$\mathbf{K}u = \mathbf{P} \quad (1)$$

式中,  $\mathbf{K}$  为结构整体刚度矩阵, 由单元刚度矩阵  $\mathbf{K}^e$  组成;  $u$ 、 $\mathbf{P}$  分别为节点位移阵列和结构节点力阵列。

$\mathbf{K}^e$  可表示为:

$$\mathbf{K}^e = \int_V \mathbf{B}^T \mathbf{D} \mathbf{B} dV \quad (2)$$

其中

$$\mathbf{D} = f(E, \nu)$$

式中,  $\mathbf{B}$ 、 $\mathbf{D}$  分别为应变矩阵和弹性矩阵;  $E$ 、 $\nu$  分别为材料的弹性模量和泊松比。

假设坝体和基岩为各向同性弹性材料, 基于有限元理论的混凝土坝参数反演分析数学模型可表示为:

$$\min f(\mathbf{E}) = \omega_i \sum_{i=1}^{n_p} \left( \frac{u_{i_o} - u_{i_c}}{u_{i_o}} \right)^2 \quad (3)$$

$$\text{s. t. } \mathbf{K}u = \mathbf{P} \quad (4)$$

$$\mathbf{E} = [E_1 \ E_2 \ \cdots \ E_{n_m}] \quad (5)$$

式中,  $\omega_i$  为权重系数, 通常为 1;  $n_p$  为测点个数;  $u_{i_o}$  为第  $i$  个测点的观测位移;  $u_{i_c}$  为第  $i$  个测点的计算位移;  $n_m$  为待识别的弹性模量的数量。

### 2.2 智能优化径向基网络反演模型

#### 2.2.1 径向基函数神经网络

RBF 神经网络为三层前向型网络, 其结构见图 1。

收稿日期: 2023-02-17, 修回日期: 2023-03-22

基金项目: 国家重点研发计划(2022YFB4703400); 国家自然科学基金项目(52079022, 51979027); 中央高校基本科研业务费项目(DUT21TD106)

作者简介: 寇文状(1997-), 男, 硕士研究生, 研究方向为大坝安全监测与数值分析, E-mail: kwzdlldx@163.com

通讯作者: 康飞(1982-), 男, 博士、教授、博导, 研究方向为大坝安全监测与数值分析, E-mail: kangfei@dlut.edu.cn

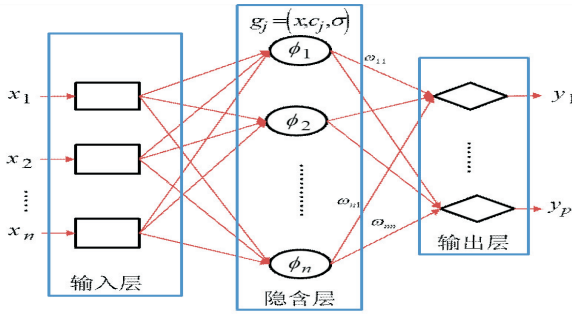


图 1 RBF 神经网络结构

Fig. 1 RBF neural network structure

在输入层神经元的个数与问题  $x = [x_1 \ x_2 \ \dots \ x_m]^T$  的维度相同。在隐含层通常采用  $g_j = (x, c_j, \sigma)$  作为高斯基函数。对隐含层输出的数据进行加权,传递给输出层,然后对处理后的数据求和得到输出值  $y = [y_1 \ y_2 \ \dots \ y_p]^T$  :

$$\begin{cases} y = \omega^T g + b \\ g_j = \exp[-\|x - c_j\|^2 / (2\sigma)^2] \end{cases} \quad (6)$$

式中,  $\omega$  为输出层的权值;  $g$  为高斯基函数;  $b = [b_1 \ b_2 \ \dots \ b_k]^T$  为输出神经元的偏移矩阵;  $x$  为输入向量;  $c_j$  为中心向量;  $\sigma$  为高斯基函数的宽度,用来调节神经元敏感性。

### 2.2.2 GTO 算法

GTO 算法<sup>[2]</sup>主要通过模拟大猩猩全体的生活行为来进行寻优,具有较强的收敛能力和鲁棒性。与大多数优化算法相比,该算法具有更精确的解和更好的收敛性。GTO 算法分为勘探和开发两个阶段。

(1) 勘探阶段。该阶段主要是对空间进行全局搜索,数学模型为:

$$G_{GX}(t+1) = \begin{cases} (U_B - L_B)r_1 + L_B & \text{rand} < p \\ (r_2 - C)X_r(t) + LH & \text{rand} \geq 0.5 \\ X(i) - L\{L[X(t) - G_{GX_r}(t)]\} + \\ r_3[X(t) - G_{GX_r}(t)] & \text{rand} \leq 0.5 \end{cases} \quad (7)$$

$$C = [\cos(2r_4) + 1](1 - I/\max I) \quad (8)$$

$$L = Cl \quad (9)$$

$$H = ZX(t) \quad (10)$$

式中,  $G_{GX}(t+1)$  为下次迭代时大猩猩个体的候选位置;  $U_B, L_B$  分别为变量的上、下限;  $C$  为维度范围值;  $X_r, G_{GX_r}$  分别为从整个种群中随机的大猩猩一员和随机选择的大猩猩候选位置;  $X(i)$  为第 1 个大猩猩位置;  $X(t)$  为大猩猩个体的当前位置;  $r_1, r_2, r_3, r_4$  为  $[0, 1]$  之间的随机值;  $I$  为当前迭代次数;  $\max I$  为最大迭代次数;  $l$  为  $[-1, 1]$  之间随机值;  $Z$  为问题维度中范围  $[-C, C]$  的随机值;  $\text{rand}$  为  $[0, 1]$  之间随机值;  $p$  为一个参数,必

须在优化操作之前给定一个值,其范围为  $[0, 1]$ 。

(2) 开发阶段。在 GTO 算法的开发阶段,采用跟随银背大猩猩和竞争成年雌性的两种行为。若  $C \geq W$ ,则选择跟随银背大猩猩机制,但若  $C < W$ ,则选择竞争成年雌性机制。 $W$  为优化操作之前要设置的参数。

若  $C \geq W$ ,其数学模型为:

$$G_{GX}(t+1) = LM[X(t) - X_{\text{SLIVERBACK}}(t)] + X(t) \quad (11)$$

$$M = \left( \left| \frac{1}{N} \sum_{i=1}^N G_{GX_i}(t) \right|^{2^t} \right)^{\frac{1}{2^t}} \quad (12)$$

式中,  $X_{\text{SLIVERBACK}}$  为银背大猩猩的最佳位置;  $N$  为大猩猩的种群规模。

若  $C < W$ ,其数学模型为:

$$G_{GX}(i) = X_{\text{SLIVERBACK}} - (X_{\text{SLIVERBACK}}Q - X(t)Q)\beta E \quad (13)$$

$$Q = 2r_5 - 1 \quad (14)$$

$$E = \begin{cases} N_1 & \text{rand} \geq 0.5 \\ N_2 & \text{rand} < 0.5 \end{cases} \quad (15)$$

式中,  $\beta$  为优化操作之前给定的参数值;  $r_5$  为  $[0, 1]$  之间的随机值。

### 2.3 基于智能算法-RBF 代理模型的反演分析步骤

基于智能算法-RBF 模型的混凝土大坝参数反演分析步骤如下。

**步骤 1** 确定问题。确定材料特性和要反演的参数。

**步骤 2** 生成样本集。先采用拉丁超立方抽样(LHS)生成参数样本集,然后根据输入的样本集进行有限元计算获得位移值。通过这种方式,获得了由参数样本和位移组成的训练集和测试集。

**步骤 3** 建立 RBF 代理模型。利用步骤 2 得到的训练集和测试集建立具有足够精度的 RBF 代理模型来代替有限元计算。

**步骤 4** 最小化目标函数值。采用智能算法结合 RBF 代理模型进行参数优化反演,获得目标函数最小值,最小目标函数值可由式(3)求出。

**步骤 5** 输出结果。当智能算法运行到最大迭代次数后,可输出反演的参数和精度。

## 3 实例应用

### 3.1 工程概况

西南某地特高双曲拱坝最大坝高为 285.5 m,坝顶高程 610.0 m,建基面最低高程为 324.5 m,拱冠顶厚 14.0 m,底厚 60.0 m,拱端最大厚度 64.0 m,坝体分为 31 个坝段。有限元模型见图 2。




图 2 拱坝整体有限元模型图

Fig. 2 Overall finite element model of arch dam

将坝体和基岩设为各项同性弹性材料, 坝体材料分为 A、B、C 三个分区, 弹性模量分别为  $E_1$ 、 $E_2$ 、 $E_3$ ; 基岩分为左岸基岩、右岸基岩和底部基岩部分, 弹性模量分别为  $E_4$ 、 $E_5$ 、 $E_6$ 。坝体材料分区见图 3。




图 3 坝体材料分区图

Fig. 3 Dam material zoning

### 3.2 计算实测位移值

选择上游水位分别为 599.76、559.44 m 两种工况, 利用 2014 年 7 月 6 日至 2018 年 8 月 31 日的监测数据, 采用多元回归法建立拱坝 #15 坝段 M1、M2、M3 和 #22 坝段 N1、N2、N4 等 6 个监测点的变形回归模型。拱坝 #15、#22 坝段变形监测点布置情况见图 4。




图 4 拱坝 #15、#22 坝段变形监测点布置情况

Fig. 4 Arrangement of deformation measuring points of arch dam sections #15 and #22

由于 #15、#22 坝段垂线监测到的坝体径向位移较大, 因此将 6 个监测点的径向位移作为研究对象。由变形回归模型分离出水压分量<sup>[3]</sup>, 得到 6 个监测点的径向位移见表 1。

### 3.3 建立 RBF 代理模型

将坝体和基岩的弹性模量范围均设定为 [15, 60] GPa。RBF 代理模型的训练样本由 LHS 生成, 样本量分别为 10D、20D、40D、60D、80D、

表 1 6 个测点的径向位移

Tab. 1 Radial displacement of 6 measuring points

测点	径向位移/m	测点	径向位移/m
M1	-25.371 8	N1	21.523 3
M2	-23.047 2	N2	-26.131 5
M3	-20.170 3	N3	-9.872 7

120D、200D ( $D=6$ ), 测试样本量设置为训练样本量的 25%。以训练样本和测试样本的均方根误差为评价指标, 不同样本量 RBF 代理模型的性能见图 5。由图 5 可知, 随着样本量的增加, 模型性能更好, 当训练样本量达到 60D (对应测试样本量为 90) 时, 模型在不损失精度的情况下具有良好的性能。因此, 选取训练样本数量为 60D 的 RBF 代理模型代替有限元计算进行反演分析。




图 5 不同样本量 RBF 代理模型的性能

Fig. 5 Performance of RBF surrogate models with different sample sizes

### 3.4 反演分析

将 RBF 代理模型分别与 GTO 算法、粒子群算法 (PSO) 及蛇算法 (SNAKE) 结合, 采用 120D 样本进行弹性模量反演分析。GTO、PSO、SNAKE 三种算法的种群大小均设置为 20, 迭代次数均为 200 次, 为避免结果的随机性, 均运行 30 次。三种算法反演出的弹性模量平均解见表 2, 30 次运算平均适应度变化曲线见图 6。基于弹性模量平均解的正分析结果见表 3, 计算位移结果与实测位移对比, 绝对误差结果见图 7。

表 2 三种算法反演出的弹性模量平均解

Tab. 2 Average solution of elastic modulus derived from three algorithms

类型	$(E_1, E_2, E_3, E_4, E_5, E_6)$ /GPa
PSO	(46.905 1, 45.204 6, 42.481 0, 30.751 6, 43.648 9, 40.855 5)
SNAKE	(53.497 9, 51.265 6, 39.457 4, 26.189 2, 35.364 5, 41.642 7)
GTO	(52.421 7, 49.396 6, 40.108 2, 26.224 4, 33.073 4, 42.367 6)

由图 6 可知, GTO 算法在迭代 100 次左右达到收敛, 收敛到  $10^{-3.3}$  量级; PSO 算法直到迭代完成都未收敛; SNAKE 算法在迭代到 140 次左右达到收敛, 收敛到  $10^{-3.3}$  量级, 表明 GTO 算法在收敛精度和速度方面优于 PSO、SNAKE 算法。由表 3、图 7 可以看出, GTO 算法的绝对误差在




图 6 30 次运算平均适应度变化曲线

Fig. 6 Average fitness change curve of 30 operations

表 3 基于弹性模量平均解的正分析结果

Tab. 3 Positive analysis results based on the average solution of elastic modulus

类型	目标值	PSO	SNAKE	GTO
$\Delta u_{M1x}/mm$	-25.371 8	-25.944 4	-24.997 3	-25.354 7
绝对误差/mm		0.572 6	0.374 5	0.017 1
$\Delta u_{M2x}/mm$	-23.047 2	-23.360 1	-22.323 6	-22.717 7
绝对误差/mm		0.312 9	0.723 5	0.329 5
$\Delta u_{M3x}/mm$	-20.170 3	-21.093 2	-20.037 2	-20.424 5
绝对误差/mm		0.922 9	0.133 1	0.254 2
$\Delta u_{N1x}/mm$	-21.523 3	-21.932 0	-21.473 9	-21.622 1
绝对误差/mm		0.408 6	0.049 4	0.098 8
$\Delta u_{N2x}/mm$	-18.691 5	-18.855 8	-18.395 3	-18.563 6
绝对误差/mm		0.164 1	0.296 2	0.127 9
$\Delta u_{N3x}/mm$	-9.872 7	-9.911 2	-9.747 8	-9.834 2
绝对误差/mm		0.038 6	0.124 9	0.038 4




图 7 绝对误差

Fig. 7 Absolute error

0.4 mm 以下,最大绝对误差为 0.329 5 mm,平均绝对误差为 0.144 3 mm;PSO 算法的绝对误差在 1.0 mm 以下,最大绝对误差为 0.929 9 mm,平均绝对误差为 0.403 3 mm;SNAKE 算法的绝对误差在 0.8 mm 以下,最大绝对误差为 0.723 5 mm,平均绝对误差为 0.283 6 mm,这表明基于 RBF-GTO 的方法比其他方法具有更高的精度,反演结果可信且合理。

## 4 结论

a. 与有限元方法相比,采用径向基函数网络代理模型可以在保证精度的同时,显著提高计算效率。

b. 在反演分析方面,GTO 算法与 PSO、SNAKE 算法相比,GTO 算法表现出更快的收敛速度和更优的反演精度。

c. 通过工程实例分析的计算结果可以看出,RBF-GTO 反演模型具有显著的工程实用性,可用于实际项目分析,性能可靠,效率高。

## 参考文献:

[1] 樊启祥,周绍武,李炳锋. 溪洛渡特高拱坝建设的岩石工程关键技术[J]. 岩石力学与工程学报,2012,31(10):1998-2015.

[2] ABDOLLAHZADEH B, SOLEIMANIAN GHAREHCHOPOGH F, MIRJALILI S. Artificial gorilla troops optimizer: A new nature-inspired metaheuristic algorithm for global optimization problems [J]. International journal of intelligent systems, 2021, 36(10): 5887-5958.

[3] 金鑫鑫,商玉洁,卢正超,等. 乌东德拱坝蓄水初期变形性状分析评价[J]. 水电能源科学,2021,39(12):112-115.

# Intelligent Optimization Radial Basis Function Network Model for Multi-parameter Inversion of Super-high Arch Dam

KOU Wen-zhuang<sup>1</sup>,KANG Fei<sup>1</sup>,MEI Zhi<sup>2</sup>

(1. School of Hydraulic Engineering, Dalian University of Technology, Dalian 116023,China;

2. PowerChina Zhongnan Engineering Corporation Limited, Changsha 410014, China)

**Abstract:** Accurate inversion of dam mechanical parameters based on dam monitoring data is crucial to ensure the safe and stable operation of the dam. This paper presented an arch dam parameter inversion model based on radial basis function (RBF) network and Artificial Gorilla Troops Optimizer (GTO). Firstly, the RBF surrogate model was used to replace the finite element model to discuss the relationship between the material parameters and the displacement response of the monitoring point. The sampling data of the RBF surrogate model was generated by the efficient Latin hypercube sampling technology. Secondly, the GTO intelligent optimization algorithm was adopted to minimize the objective function of material parameter identification. The analysis results of engineering examples show that the RBF-GTO model can achieve high-precision inversion analysis of concrete super-high arch dams while reducing the calculation cost.

**Key words:** radial basis function network; surrogate model; displacement back analysis; intelligent optimization; super-high arch dam