第39卷第4期　　计 算 力 学 学 报　　Vol. 39, No. 4
2022 年 8 月　　Chinese Journal of Computational Mechanics　　August 2022

DOI:10.7511/jslx20201201001

基于 POD-RBF 代理模型的迭代更新反演方法

吕小龙，　黄　丹*，　姜冬菊

(河海大学 力学与材料学院,南京 211100)

摘　要:针对常规的水工大坝等大型工程结构参数反演需要耗费大量有限元正分析机时的问题,建立了具有较好反演精度和泛化性能的 POD-RBF 代理模型和快速迭代更新反演算法。基于有限元分析获得足量数据样本,利用 POD 提取本征向量,并使用 RBF 方法进行插值得到有限元模型的代理模型;同时结合粒子群算法的全局寻优能力和高斯-牛顿法的快速局部收敛优势,建立了一种新的高效率迭代反演方法,并应用于混凝土大坝分区弹性模量反演。结果表明,该方法适用于大坝等大体积混凝土结构的力学参数反演。同时,相较于传统的单一反演方法,该方法在反演效率和反演精度两方面均显示出优势。

关键词:代理模型;POD-RBF;参数反演;粒子群算法;高斯-牛顿法

中图分类号:O346.1　　**文献标志码**:A　　**文章编号**:1007-4708(2022)04-0506-06

1 引　言

水工大坝等大体积混凝土工程结构的材料参数对其健康和安全状态的监测起着十分重要的作用,但结构内部的材料参数往往难以直接得到,于是通过位移等可观测量来反演坝体材料参数便成为一种广泛使用的途径。然而,现有的大量大体积结构材料参数反演方法往往需要通过有限元等数值方法进行大规模正分析,且正分析耗时量随着待反演参数的增加呈几何式增长。对于复杂的大体积结构,甚至可能导致较多参数反演问题的正分析环节难以施行。通过建立代理模型以取代大量的有限元计算,可以花费很少的时间获得足够精度的响应值,因而广泛应用于结构优化、可行性分析和预测反演等问题中[1]。

Bhosekar 等[2]对各种常见代理模型的构建、应用及优势进行了总结。代理模型本质上是输入和输出之间的一种映射关系,常见的映射模型包括多项式模型[3]、Kriging 插值模型[4,5]、径向基函数模型[6-8]以及人工神经网络模型[9,10]等。其中采用本征正交分解 POD(Proper Orthogonal Decomposition)和径向基函数 RBF(Radial Basis Functions)插值相结合构建的代理模型,能同时保证较高的拟合精度和插值精度[11],适用于大体积结构的模拟预测。本文研究思路即来自于此。此外,为了在保证反演精度的前提下尽可能降低有限元正分析计算量,本文结合粒子群算法的全局寻优能力和高斯-牛顿法的局部快速收敛能力,构建了一种组合式的迭代更新反演模型,并通过典型大体积混凝土大坝的分区弹性模量反演验证其反演精度和计算效率。

2 代理模型构造及原理

2.1 本征正交分解(POD)

POD 是统计学上用来分析数据的常用方法[12],在数据科学领域也称为主成分分析。以典型水工大坝为例,考虑将大坝分成 p 个弹模分区,设置 n 组弹模样本得到弹模参数样本矩阵 $\mathbf{X}=[\boldsymbol{x}^1,\boldsymbol{x}^2,\cdots,\boldsymbol{x}^n]$,其中 $\boldsymbol{x}^i(i=1,2,\cdots,n)$ 为包含一组弹模值的列向量。在相同荷载作用下,其分区弹模不同的取值对应不同的位移响应,设位移响应矩阵为 $\mathbf{Y}=[\boldsymbol{y}^1,\boldsymbol{y}^2,\cdots,\boldsymbol{y}^n]$,其中 $\boldsymbol{y}^i(i=1,2,\cdots,n)$ 为 m 维位移响应列向量,表示在一组分区弹模值下大坝上 m 个测点的位移测值所组成的列向量,称之为快照(Snapshot),n 为样本数量。POD 的关键目的就是找出这些快照的内在联系,提取数据的主要特征,进而对数据进行降维。对 $\mathbf{Y}$ 进行奇异值分解

$$\mathbf{Y}=\boldsymbol{\Phi}\cdot\boldsymbol{\Lambda}\cdot\mathbf{V}^{\mathrm{T}} \tag{1}$$

收稿日期:2020-12-01;**修改稿收到日期**:2021-04-09.

基金项目:国家重点研发计划(2018YFC0406703);国家自然科学基金(12072104;51679077;11932006)资助项目.

作者简介:黄　丹*(1979-),男,博士,教授
(E-mail:danhuang@hhu.edu.cn)

式中　$\boldsymbol{\Phi}=[\boldsymbol{\varphi}_1,\boldsymbol{\varphi}_2,\cdots,\boldsymbol{\varphi}_m]$（$\boldsymbol{\varphi}_i\subset\mathbf{R}^m$，$i=1,2,\cdots,m$）为 $\mathbf{Y}$ 的左奇异向量，$\mathbf{V}=[\boldsymbol{v}_1,\boldsymbol{v}_2,\cdots,\boldsymbol{v}_n]$（$\boldsymbol{v}_i\subset\mathbf{R}^n$，$i=1,2,\cdots,n$）为 $\mathbf{Y}$ 的右奇异向量，$\boldsymbol{\Lambda}$ 为 m 行 n 列的对角矩阵，其对角线上的每个元素 λ_i（$i=1,2,\cdots,\min(m,n)$）为 $\mathbf{Y}$ 的奇异值，即协方差矩阵 $\mathbf{Y}^{\mathrm{T}}\mathbf{Y}$ 的特征值的平方根。对大部分情况，奇异值 λ_i（$i=1,2,\cdots,\min(m,n)$）从大到小衰减的速度很快，前几个奇异值的总和通常就能占到所有奇异值总和的 90%以上，即

$$\sum_{i=1}^{k}\lambda_i\Big/\sum_{j=1}^{n}\lambda_j\geqslant 90\% \tag{2}$$

根据奇异值分解的性质，原数据 $\mathbf{Y}$ 在左奇异向量 $\boldsymbol{\varphi}_i$（$i=1,2,\cdots,n$）上的投影是最大的，因此，以前 k 阶左奇异向量为基向量便能够包含 $\mathbf{Y}$ 的绝大部分信息。由于 k 通常远小于 n，故原数据在保留绝大部分信息的前提下得到了大幅降维。以前 k 阶左奇异向量为基向量，任意弹模参数样本 $\boldsymbol{x}$ 对应的位移响应向量 $\mathbf{y}(\boldsymbol{x})$ 可以近似表示其线性组合为

$$\hat{\mathbf{y}}(\boldsymbol{x})=\overline{\boldsymbol{\Phi}}\cdot\boldsymbol{\alpha}(\boldsymbol{x}) \tag{3}$$

式中　$\hat{\mathbf{y}}(\boldsymbol{x})$ 为 $\mathbf{y}(\boldsymbol{x})$ 的近似，$\overline{\boldsymbol{\Phi}}$ 为截取前 k 阶左奇异向量组成的矩阵，$\boldsymbol{\alpha}(\boldsymbol{x})$ 是位移响应向量在基向量上的组合系数，包含 k 个元素。由此可见，通过 POD 分解后，对于任意参数样本的预测只包含 k 个待定系数，提高了模型预测的稳定性。组合系数 $\boldsymbol{\alpha}(\boldsymbol{x})$ 可通过下述径向基插值模型求得。

2.2　径向基函数（RBF）模型

RBF 是一种常用的多变量函数插值基函数，其一般形式可记为

$$\hat{\mathbf{y}}(\boldsymbol{x})=\sum_{i=1}^{n}w_i\boldsymbol{f}(\boldsymbol{r}^i) \tag{4}$$

式中　w_i 为权值系数，$\boldsymbol{r}^i=\|\boldsymbol{x}-\boldsymbol{x}^i\|$ 为任意参数样本点 $\boldsymbol{x}$ 与已有样本点的欧氏距离，$\boldsymbol{f}(\cdot)$ 为径向基函数，常用的径向基函数有

Thin-platesplines 函数：

$$\boldsymbol{f}(\boldsymbol{r})=\boldsymbol{r}^2\ln\boldsymbol{r} \tag{5}$$

Inverse multiquadric 函数：

$$\boldsymbol{f}(\boldsymbol{r})=(\boldsymbol{r}^2+c^2)^{-1/2} \tag{6}$$

以及高斯函数：

$$\boldsymbol{f}(\boldsymbol{r})=\exp(-\boldsymbol{r}^2/c^2) \tag{7}$$

式(6,7)的 c 为一个大于零的常数，称为平滑系数，其值越大，函数值变化越平缓，反之越陡峭。综合已有工作比较，本文采用 inverse multiquadric 函数作为径向基函数，平滑系数 $c=0.5$。

将所有已知样本参数点和对应的位移响应代入插值式(4)中，并写成矩阵形式

$$\begin{bmatrix}y^1\\y^2\\\cdots\\y^n\end{bmatrix}=\begin{bmatrix}f_{11}&f_{12}&\cdots&f_{1n}\\f_{21}&f_{22}&\cdots&f_{2n}\\\cdots&\cdots&\cdots&\cdots\\f_{n1}&f_{n2}&\cdots&f_{nn}\end{bmatrix}\cdot\begin{bmatrix}w_1\\w_2\\\cdots\\w_n\end{bmatrix} \tag{8}$$

式中　$f_{ij}=f(\|\boldsymbol{x}^i-\boldsymbol{x}^j\|)$（$i,j=1,2,\cdots,n$）。若已知参数样本点中不存在重复样本点，则方程(8)右侧方阵可逆，故可求出权值系数 w_i。

2.3　形成 POD-RBF 代理模型

根据 RBF 插值方法，可对方程(3)的组合系数 $\boldsymbol{\alpha}(\boldsymbol{x})$ 进行插值，即

$$\boldsymbol{\alpha}_i(\boldsymbol{x})=\sum_{j=1}^{n}w_{ij}\boldsymbol{f}(\boldsymbol{r}^i)\quad(j=1,2,\cdots,k) \tag{9}$$

或矩阵形式

$$\boldsymbol{\alpha}(\boldsymbol{x})=\mathbf{W}\cdot\boldsymbol{f}(\boldsymbol{r}) \tag{10}$$

式中　$\mathbf{W}$ 为 w_{ij} 组成的系数矩阵，$\boldsymbol{f}(\boldsymbol{r})$ 为 $f(\boldsymbol{r}^i)$ 组成的列向量。将式(10)代入式(3)，并应用已有的所有样本点得到

$$\mathbf{Y}=\overline{\boldsymbol{\Phi}}\cdot\mathbf{W}\cdot\mathbf{F} \tag{11}$$

由于 $\overline{\boldsymbol{\Phi}}^{\mathrm{T}}\cdot\overline{\boldsymbol{\Phi}}=\mathbf{I}$，且 $\mathbf{F}$ 可逆，故方程两边同时左乘 $\overline{\boldsymbol{\Phi}}^{\mathrm{T}}$、右乘 $\mathbf{F}^{-1}$ 便得

$$\mathbf{W}=\overline{\boldsymbol{\Phi}}^{\mathrm{T}}\cdot\mathbf{Y}\cdot\mathbf{F}^{-1} \tag{12}$$

即可求得系数矩阵 $\mathbf{W}$。

由式(3,10,12)可得 POD-RBF 代理模型

$$\hat{\mathbf{y}}(\boldsymbol{x})=\overline{\boldsymbol{\Phi}}\cdot(\overline{\boldsymbol{\Phi}}^{\mathrm{T}}\cdot\mathbf{Y}\cdot\mathbf{F}^{-1})\cdot\boldsymbol{f}(\boldsymbol{r}) \tag{13}$$

3　迭代更新反演算法

参数反演精度在一定程度上依赖于代理模型的精度，但在全局上构建高精度的代理模型，需要通过大量的有限元正分析获取足够多的样本点，这往往需要极大的计算消耗。若只在待反演参数点的附近布置较密的样本点，而在其他地方稀疏取样，使得代理模型仅在局部具有相对高的精度，便能够通过较少的样本点获得尽可能高的反演精度。

粒子群算法 PSO（Particle Swarm Optimization）是一种基于群体的随机优化算法[13,14]，具有较好的全局寻优能力，但因为其随机性，在局部的收敛速度较慢。基于梯度信息的高斯-牛顿法虽然容易陷入局部极小，对初值的选取要求较高，但其在局部区域往往比粒子群等启发式算法具有更快的收敛速度以及求解精度。因此将两者结合起来，便能够在一定程度上同时保证全局最优性、局部精度和收敛效率。

对于大多数参数反演问题，待反演参数总是落在参数空间的局部区域，而在全域构建高精度的代

理模型则需要消耗大量的计算机时。为此本节构建了一种基于代理模型的迭代更新反演算法，能够在提高反演效率的同时获得更高的精度。

迭代更新反演的步骤如下。

(1) 在全域稀疏采样以尽可能广地覆盖参数空间，通过有限元等数值方法获得相应的位移响应，得到初始样本集 S_0。

(2) 根据样本集 S_0 建立代理模型。此时的代理模型虽然精度不高但能反映总体特征。

(3) 基于 PSO 算法的全局寻优能力找到一个极值点 $\boldsymbol{x}^0$ 作为反演结果。由于代理模型的精度较低，反演出的结果通常和真实值也有较大的差距。

(4) 计算反演参数下的位移响应，迭代更新。若计算出的位移与实测位移差距较大，则将此反演参数和有限元计算的位移响应作为新的样本对加入到初始样本集 S_0 中，得到新的样本集 S_1。

(5) 使用增加样本点后的样本集 S_1 重新构建代理模型。此模型将具有在 $\boldsymbol{x}^0$ 附近更高的精度。由于已通过 PSO 算法找到全局最优的局部区域，此时可以改用局部收敛速度更快的高斯-牛顿法继续反演，这样能够在提高反演速度和精度的同时避免 PSO 算法每次都进行全局搜索带来的不稳定性。

基于 POD-RBF 代理模型结合 PSO 算法和高斯-牛顿法的迭代更新反演算法具体流程如图 1 所示。

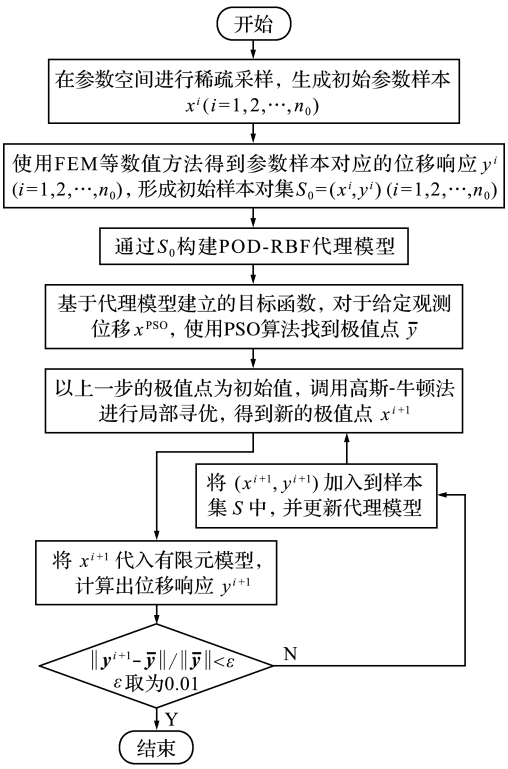

图 1 迭代更新反演算法流程

Fig. 1 Flowchart of iterative updating inversion algorithm

4 算例分析

4.1 模型概况

以某水工混凝土重力坝坝段为例，开展分区弹模反演分析。坝高 100 m，坝底宽 60 m，取坝段厚度为 25 m。将大坝混凝土按照浇筑龄期分为 3 个弹性模量分区，如图 2 所示，各分区弹性模量 $E_i=26\sim38$ GPa($i=1,2,3$)，泊松比设为常数 0.167。大坝受坝前 100 m 高水头静水压力和自重作用。通过分区弹模在弹模区间内随机取值得到多个参数样本$[E_1^j,E_2^j,E_3^j]$($j=1,2,\cdots,n$，n 为样本数)。应用有限元进行正分析可以得到参数样本对应的位移响应$[y_1^j,y_2^j,\cdots,y_m^j]$，$m$ 为位移分量个数，本算例选择所有的节点位移作为样本位移响应，故 m 为有限元模型的自由度数，m 值为 2376。

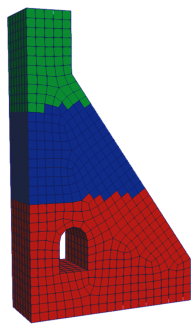

图 2 混凝土大坝有限元模型

Fig. 2 Finite element model of a concrete dam

4.2 有限元代理模型

代理模型的精度一定程度上取决于样本数量，充足的样本集有利于构造高精度的代理模型，但相应地也会消耗更多机时。因此，选取合适的样本数量以更经济的方式构建代理模型是十分重要的。

本节分别选取了不同数量的样本集来构建代理模型，并统计了代理模型对测试样本的计算位移和对应的有限元计算位移之间的平均相对误差，结果如图 3 所示。可以看出，针对本算例的有限元模型，当选取样本数量小于 9 时，样本数量的增加对代理模型精度的提升作用明显，而当样本数量大于 9 之后，样本数量的进一步增加并不能再显著提升代理模型的精度。因此本算例选取 9 个样本作为初始样本集。

在对位移响应矩阵进行奇异值分解时，其前几阶奇异向量包含了绝大多数特征信息，通常只需提取前几阶就足以获得较高精度。在本算例中，对 9 个样本组成的位移矩阵进行分解，得到其前五个奇异值列入表 1。

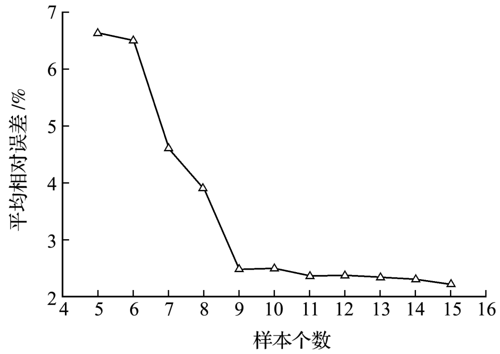

图 3　不同样本个数下 POD-RBF 模型的平均相对误差
Fig. 3　Average relative error of the POD-RBF model under different sample numbers

表 1　位移响应矩阵奇异值
Tab. 1　Eigenvalues of displacement matrix

	1	2	3	4	5
奇异值	66.03	20.78	5.85	1.69	0.27
累计占比/%	69.72	91.65	97.83	99.62	99.91

由表 1 可知，位移矩阵前 3 阶奇异值占总奇异值比重已达 95%以上。截取不同个数奇异向量作为基向量进行插值引起的平均相对误差如图 4 所示。代理模型的平均相对误差的变化趋势与奇异值的变化趋势相反，这表明随着奇异值占比的增加，模型精度相应提高，当使用前 3 阶奇异向量构建代理模型时，代理模型相对误差已降至接近最低水平。

4.3　迭代更新反演结果

基于 POD-RBF 代理模型，对于一个给定位移 $\bar{y}$（包含 2376 个值），以及对应的真实弹模[26.429，29.130，32.580] GPa，通过图 1 所示流程进行反演。同时，基于 POD-RBF 代理模型，使用 PSO 算法进行无迭代更新的反演。粒子群粒子规模设置为 200，迭代步数通过测算固定为 50。反演结果列入表 2，其中 n 为样本个数，e 为反演弹模与真实弹模的平均相对误差。由表 2 可知，随着样本数的增加，采用迭代更新策略的反演方法的反演结果在收敛速度和求解精度上都要优于无迭代更新的反演结果。

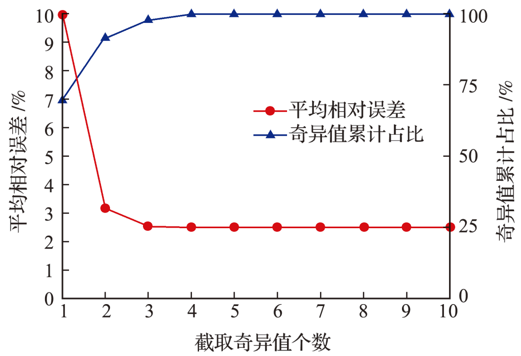

图 4　平均相对误差和奇异值占比随截取奇异值个数的变化
Fig. 4　Mean relative error and the proportion of singular values vary with the number of truncated singular values

为验证本文反演方法的高效性，将文献[15]的基于 BP 神经网络的直接反演方法加入进行对比。本文 BP 神经网络的隐含层神经元个数取为 10，激活函数为 Sigmoid 函数。两种方法的反演结果列入表 3，由表 3 可知，与 BP 直接反演方法相比，基于 POD-RBF 代理模型的迭代更新反演方法在反演精度和稳定性上表现都要更优。

表 2　迭代更新与无迭代更新反演结果对比
Tab. 2　Results of iterative updating inversion and non-iterative updating inversion

n	迭代更新反演弹模				无迭代更新反演弹模			
	E_1/GPa	E_2/GPa	E_3/GPa	e/%	E_1/GPa	E_2/GPa	E_3/GPa	e/%
9	30.757	27.17	32.147	9.34	29.246	32.204	35.626	10.11
10	29.093	27.298	30.591	7.43	29.486	28.477	35.920	8.96
11	26.087	27.898	31.438	3.36	29.342	29.909	33.256	6.05
12	27.005	27.949	32.088	2.75	29.620	29.599	31.053	6.99

表 3　迭代更新反演与 BP 直接反演结果对比
Tab. 3　Results of iterative updating inversion and BP direct inversion

n	迭代更新反演弹模				BP 直接反演弹模			
	E_1/GPa	E_2/GPa	E_3/GPa	e/%	E_1/GPa	E_2/GPa	E_3/GPa	e/%
9	30.757	27.170	32.147	9.34	28.358	27.007	29.697	7.96
10	29.093	27.298	30.591	7.43	27.031	27.562	33.246	3.53
11	26.087	27.898	31.438	3.35	26.057	27.516	30.400	5.36
12	27.005	27.949	32.088	2.74	28.412	20.009	32.300	18.28
13	26.881	29.465	33.145	1.56	24.714	27.757	36.299	8.45
14	26.674	28.416	32.957	1.65	26.350	29.284	32.731	0.44
15	26.501	29.002	31.700	1.74	24.683	31.948	35.471	8.61
16	26.027	28.974	32.214	1.10	26.270	29.584	34.070	3.06

5 结 论

本文针对大型复杂结构参数反演时通常耗费大量正分析机时的问题，尝试构建本征正交分解（POD）结合径向基函数（RBF）的代理模型，并结合粒子群算法（PSO）的全局寻优能力和高斯-牛顿法（GNM）的快速局部收敛特性，开展兼具精度和效率的迭代更新反演算法探索，并应用于典型混凝土重力坝坝段的分区弹性模量反演。

通过比较不同样本数量下代理模型的精度，在确保代理模型准确性的基础上可选取合适的样本数量，有效降低代理模型的计算机时消耗。

典型算例分析表明，基于本文方法，可先使用相对较少的样本数量构建相对粗糙的代理模型，然后在反演过程中不断在全局最优点附近加入新样本更新代理模型，有针对性地提高代理模型的局部精度。通过结合粒子群算法的全局寻优能力和高斯-牛顿法局部快速收敛能力，可用相对较少的迭代步获得足够高的反演精度。

参考文献（References）：

[1] Razavi S, Tolson B A, Burn D H. Review of surrogate modeling in water resources[J]. *Water Resources Research*, 2012, **48**(7): W07401.

[2] Bhosekar A, Ierapetritou M. Advances in surrogate based modeling, feasibility analysis, and optimization: A review[J]. *Computers & Chemical Engineering*, 2018, **108**: 250-267.

[3] Chen J H, Xia B Z, Liu J. A sparse polynomial surrogate model for phononic crystals with uncertain parameters[J]. *Computer Methods in Applied Mechanics and Engineering*, 2018, **339**: 681-703.

[4] Rogers A, Ierapetritou M. Feasibility and flexibility analysis of black-box processes. Part II: Surrogate-based flexibility analysis[J]. *Chemical Engineering Science*, 2015, **137**: 1005-1013.

[5] Zhong W M, Qiao C, Peng X, et al. Operation optimization of hydrocracking process based on Kriging surrogate model[J]. *Control Engineering Practice*, 2019, **85**: 34-40.

[6] Müller J, Paudel R, Shoemaker C A, et al. CH_4 parame-ter estimation in CLM4.5bgc using surrogate global optimization[J]. *Geoscientific Model Development*, 2015, **8**(10): 3285-3310.

[7] Wang Z L, Ierapetritou M. A novel feasibility analysis method for black-box processes using a radial basis function adaptive sampling approach[J]. *AIChE Journal*, 2017, **63**(2): 532-550.

[8] 殷 红，崔 攀，彭珍瑞. 基于径向基函数的频响函数模型修正[J]. 计算力学学报，2020，**37**(4)：417-423. (YIN Hong, CUI Pan, PENG Zhen-rui. Model updating of frequency response function based on radial basis function[J]. *Chinese Journal of Computational Mechanics*, 2020, **37**(4): 417-423. (in Chinese))

[9] Pan I, Babaei M, Korre A, et al. Artificial Neural Network based surrogate modelling for multi-objective optimisation of geological CO_2 storage operations[J]. *Energy Procedia*, 2014, **63**: 3483-3491.

[10] Henao C A, Maravelias C T. Surrogate-based superstructure optimization framework[J]. *AIChE Journal*, 2011, **57**(5): 1216-1232.

[11] 梁国贺. 时空全域代理模型及大坝参数反演应用[D]. 清华大学，2017. (LIANG Guo-he. Global Surrogate Model with Temporal-spatial Basis and Its Application in Parameter Inversion of Dam[D]. Tsinghua University, 2017. (in Chinese))

[12] Marquez A, Oviedo J J E, Odloak D. Model reduction using proper orthogonal decomposition and predictive control of distributed reactor system[J]. *Journal of Control Science and Engineering*, 2013, **2013**: 763165.

[13] Wang D S, Tan D P, Liu L. Particle swarm optimization algorithm: An overview[J]. *Soft Computing*, 2018, **22**(2): 387-408.

[14] Magrenan A A, Argyros L. A *Contemporary Study of Iterative Methods*[M]. London, United Kingdom: Academic Press, 2018.

[15] 金长宇，马震岳，张运良，等. 神经网络在岩体力学参数和地应力力场反演中的应用[J]. 岩土力学，2006，**27**(8)：1263-1266，1271. (JIN Chang-yu, MA Zhen-yue, ZHANG Yun-liang, et al. Application of neural network to back analysis of mechanical parameters and initial stress field of rock masses[J]. *Rock and Soil Mechanics*, 2006, **27**(8): 1263-1266, 1271. (in Chinese))

Iterative updating inversion method based on POD-RBF surrogate model

LÜ Xiao-long，　HUANG Dan*，　JIANG Dong-ju
(College of Mechanics and Materials，Hohai University，Nanjing 211100，China)

Abstract：To address the high computation workload in finite element analysis in the general inverse analysis of large engineering structures like hydraulic dams，a precise and robust POD-RBF surrogate model and an iterative updating inversion algorithm were constructed. Based on the data samples obtained from the finite element method，we can interpolate eigenvectors abstracted by POD method using RBF to get a surrogate model of the finite element model. Combining the global optimization ability of particle swarm optimization algorithm and the fast local convergence advantage of Gauss-Newton method，a new efficient iterative inversion method was established and applied to the zonal elastic modulus inversion of a concrete dam. The results shown the applicability of this method for mechanical parameter inversion of large concrete structures such as dams. Meanwhile，compared with traditional methods，this inverse framework consisting of the POD-RBF surrogate model and the iterative updating method can get good performance both on the inversion accuracy and the efficiency of computation.

Key words：surrogate model；POD-RBF；parameter inversion；PSO；Gauss-Newton method

引用本文/Cite this paper：
吕小龙，黄　丹，姜冬菊. 基于POD-RBF代理模型的迭代更新反演方法[J]. 计算力学学报，2022，**39**(4)：506-511.
LÜ Xiao-long，HUANG Dan，JIANG Dong-ju. Iterative updating inversion method based on POD-RBF surrogate model[J]. *Chinese Journal of Computational Mechanics*，2022，**39**(4)：506-511.