

DOI:10.19344/j.cnki.issn1671-5276.2025.02.038

基于 Kriging 模型的参数不确定性模型修正

许泽伟

(西安铁路职业技术学院, 陕西 西安 710026)

摘 要:提出一种不确定性模型修正方法对结构中参数和响应的概率分布情况进行准确估计,使得模型修正更具有实际意义。采用拉丁超立方抽样方法对参数统计矩(均值、标准差)进行抽样获取样本点,利用多项式混沌展开模型快速计算响应统计矩的优势对每一组样本点输出响应统计矩进行计算。以参数的统计矩为输入,结构响应统计矩为输出构建 kriging 模型,建立描述参数不确定性与响应不确定性之间的函数关系式。以 kriging 模型输出与实测数据差为目标函数,使用蚁狮算法进行迭代优化寻求最佳解。该方法通过 3 自由度弹簧质量块系统和三维桁架进行验证,所得响应统计矩接近实测数据,验证了方法的可行性。

关键词:不确定性模型修正;多项式混沌展开;kriging 模型;参数统计矩;蚁狮优化算法

中图分类号:TP183 **文献标志码:**B **文章编号:**1671-5276(2025)02-0196-05

Model Updating with Parameter Uncertainty Based on Kriging Model

XU Zewei

(Xi'an Railway Vocational & Technical Institute, Xi'an 710026, China)

Abstract: An uncertainty model updating method is proposed to accurately estimate the probability distribution of parameters and responses, making the model updating more practical. The Latin hypercube sampling method is applied to sample the parameter statistical distance (mean and standard deviation), and the polynomial chaotic expansion model is used to calculate the response statistical distance of each group of sample points. The kriging model is built with the statistical distance of parameters as the input and the statistical distance of structural response as the output, and the functional relationship between parameter uncertainty and response uncertainty is established. The difference between the output of kriging model and the measured data is taken as the objective function, and iterative optimization is conducted by ant lion optimizer algorithm for the optimal solution. The method is verified by 3-DOF spring mass block system and 3-D truss, and the response statistical distance obtained is close to the measured data, which verifies the feasibility of the proposed method.

Keywords: model updating with uncertainty; polynomial chaotic expansion; kriging model; parameter statistical distance; ant lion optimizer algorithm

0 引言

模型修正一般分为确定性模型修正方法和不确定性模型修正方法两种。确定性模型修正方法在进行修正时认为待修正参数是一个确定的数值,但在实际工程中,设备长期处于外界环境,受到诸多因素的影响,从而影响结构参数。结构参数的不确定性量化在实际工程中,尤其是后期进行设备健康监测时至关重要。依照参数不确定性推算结构输出响应不确定性称为不确定性量化,而不确定性模型修正方法是一个不确定性量化的逆过程,其本质是通过结构响应的不确定性反演参数的不确定性。

不确定性模型修正方法始于 20 世纪 70 年代,发展至今已衍生出了 3 种比较主流的修正框

架,即贝叶斯方法、摄动方法和蒙特卡罗方法^[1]。方圣恩等^[2]使用响应面模型和蒙特卡罗模拟对参数概率特性进行了统计;秦仙蓉等^[3]利用 kriging 作为替代模型结合蒙特卡罗抽样对岸桥模型进行了随机模型修正,使用替代模型虽然在一定程度上减轻了计算负担,但对于复杂的结构而言,大量样本所造成的高计算量高时间耗费依旧是一个需要攻克的难题。

多项式混沌展开 (polynomial chaos expansion, PCE) 模型是一种概率框架下的正交多项式参数化数学模型,该模型将响应统计矩分解为单随机变量统计矩和多项式混沌展开系数组合的形式,通过简单运算即可得到结构输出响应统计矩^[4], PCE 模型被广泛应用在不确定性量化中,如动力特性不确定性分析等。同时,也有学者将 PCE 模

作者简介:许泽伟(1996—),男,山西大同人,助教,硕士,研究方向为复杂结构有限元模型修正,921080492@qq.com。

型用于不确定性模型修正上。方圣恩等^[5]利用随机响应面快速计算响应统计特性的优势进行了参数不确定性估计;WU 等^[6]使用多项式混沌展开构造的替代模型,在贝叶斯框架下对反应堆模型进行逆不确定性量化,准确计算了不确定参数的均值和方差。

不确定性模型修正方法通过构建一个反问题来计算不确定性参数的概率分布,概率分布可以用统计矩(均值和标准差)进行描述。本文提出直接使用参数统计矩作为输入,以结构响应统计矩作为输出构建 kriging 模型,结构响应统计矩采用 PCE 模型进行快速计算。以统计矩作为模型输入输出,直接建立参数不确定性和结构响应不确定性关系的函数表达式,避免了繁琐的参数特征值统计过程,提高了不确定性模型修正时的效率。方法通过 3 自由度弹簧质量块系统和三维桁架进行了验证。

1 参数不确定性模型修正理论

1.1 参数不确定性模型修正理论

Kriging 模型是一种统计代理模型,它使用一个估计过程,通过选择方差最小样本值的加权平均值来提供良好的假设^[7]。对于一组给定的 n 个 m 维样本点输入 $\mathbf{X} = [x_1, x_2, \dots, x_n]^T$ 和对应的响应输出 $\mathbf{Y} = [y_1, y_2, \dots, y_n]^T$, Kriging 模型的数学表达式为

$$y(x_i) = \sum_{l=1}^p \beta_l f_l(x_i) + z(x_i) = \mathbf{f}^T(x_i) \boldsymbol{\beta} + z(x_i) \quad (1)$$

式中: $\boldsymbol{\beta} = [\beta_1 \ \beta_2 \ \dots \ \beta_p]^T$ 为回归系数; $\mathbf{f}(x_i) = [f_1(x_i) \ f_2(x_i) \ \dots \ f_p(x_i)]^T$ 为变量 x 的多项式函数; $z(x)$ 为协方差非 0 的随机分布,服从正态分布 $N(0, \sigma^2)$, 其协方差如下:

$$C_{ov}[z(x_i), z(x_j)] = \sigma^2 R(x_i, x_j), \quad i, j = 1, 2, \dots, n \quad (2)$$

式中: σ^2 为 $z(x)$ 的方差; x_i 和 x_j 为任意样本点; $R(x_i, x_j)$ 是相关函数,表示样本点的空间相关性,其表达式为

$$R(x_i, x_j) = \prod_{k=1}^m R_k(\theta_k, d_k) \quad (3)$$

式中: $d_k = \theta_k |x_i^k - x_j^k|$; x_i^k 和 x_j^k 为样本点 x_i 和 x_j 的第 k 个分量; m 为变量个数; θ_k 为相关系数。

样本点相关函数矩阵如式(4)所示。

$$\mathbf{R} = \begin{bmatrix} R(x_1, x_1) & \dots & R(x_1, x_n) \\ \vdots & & \vdots \\ R(x_n, x_1) & \dots & R(x_n, x_n) \end{bmatrix} \quad (4)$$

采用最大似然估计方法训练模型构建参数,样本点的似然函数如式(5)所示。

$$L = \frac{1}{(2\pi\sigma^2)^{n/2} |\mathbf{R}|^{1/2}} \exp \left[-\frac{(\mathbf{Y} - \mathbf{F}\boldsymbol{\beta})^T \mathbf{R}^{-1} (\mathbf{Y} - \mathbf{F}\boldsymbol{\beta})}{2\sigma^2} \right] \quad (5)$$

式中: $|\mathbf{R}|$ 为相关矩阵的行列式; $\mathbf{Y}$ 为样本点响应组成的列向量; $\mathbf{F}$ 为样本点组成的向量矩阵。

$\boldsymbol{\beta}$ 和 σ^2 的最小二乘估计分别如式(6)和式(7)所示。

$$\hat{\boldsymbol{\beta}} = (\mathbf{F}^T \mathbf{R}^{-1} \mathbf{F})^{-1} \mathbf{F}^T \mathbf{R}^{-1} \mathbf{Y} \quad (6)$$

$$\hat{\sigma}^2 = \frac{(\mathbf{Y} - \mathbf{F}\hat{\boldsymbol{\beta}})^T \mathbf{R}^{-1} (\mathbf{Y} - \mathbf{F}\hat{\boldsymbol{\beta}})}{n} \quad (7)$$

联立式(5)一式(7),忽略常数项并取对数,得最大似然估计如式(8)所示。

$$\ln(L) \approx -\frac{n}{2} \ln(\hat{\sigma}^2) - \frac{1}{2} \ln |\mathbf{R}| \quad (8)$$

式中 $\hat{\sigma}^2$ 和 $\mathbf{R}$ 为 θ_k 的函数。

Kriging 模型构造完成后,对于任意待测点 x_0 ,其响应值 $\hat{y}(x_0)$ 如式(9)所示。

$$\hat{y}(x_0) = \mathbf{f}^T(x_0) \hat{\boldsymbol{\beta}} + \mathbf{R}^T(x_0) \mathbf{R}^{-1} (\mathbf{Y} - \mathbf{F}\hat{\boldsymbol{\beta}}) \quad (9)$$

1.2 多项式混沌展开

多项式混沌展开^[8]是一种齐次混沌方法,由 Cameron-Martin 定理衍生出来,因其在响应统计矩计算方面的巨大优势被广泛用于不确定性量化等诸多领域,一般用来解决当变量服从高斯分布时的不确定性量化问题。

多项式混沌展开式一般为

$$\begin{aligned} Y(\boldsymbol{\theta}) = & \alpha_0 + \sum_{i_1=1}^{\infty} H_1(\zeta_{i_1}(\boldsymbol{\theta})) + \\ & \sum_{i_1=1}^{\infty} \sum_{i_2=1}^{i_1} \alpha_{i_1, i_2} H_2(\zeta_{i_1}(\boldsymbol{\theta}), \zeta_{i_2}(\boldsymbol{\theta})) + \\ & \sum_{i_1=1}^{\infty} \sum_{i_2=1}^{i_1} \sum_{i_3=1}^{i_2} \alpha_{i_1, i_2, i_3} H_3(\zeta_{i_1}(\boldsymbol{\theta}), \zeta_{i_2}(\boldsymbol{\theta}), \zeta_{i_3}(\boldsymbol{\theta})) + \dots \end{aligned} \quad (10)$$

式中: $\boldsymbol{\theta}$ 为随机变量; $H_n(\zeta_{i_1}, \zeta_{i_2}, \dots, \zeta_{i_n})$ 表示阶数为 n 的正交多项式。

为了便于统计矩计算,上述方程简写为

$$y(x) = \sum_{i=0}^{\infty} \alpha_i H_i(\zeta_i(\boldsymbol{\theta})) = \alpha_0 + \alpha_1 \tau_1(x) + \dots + \alpha_i \tau_i(x) \quad (11)$$

多项式混沌展开由系数确定,采用概率配点法和回归方法来确定多项式系数。配点选取一般为更高一阶的 hermit 多项式的根,选取时尽可能接近高概率点,并且包含原点。配点个数一般选取为待定系数个数的 2 倍。确定好配点后,计算出对应的响应。接下来,系数求解变为最小二乘法拟合下的系数求解。

多项式系数确定之后,就可以求解响应的统计矩,响应统计矩由下式计算。

$$\mu^i = \int y^i(x) p(x) dx \quad (12)$$

1 阶统计矩即均值如下:

$$E(y) = \mu_1 = E(\alpha_0 + \alpha_1 \tau_1(x) + \dots + \alpha_i \tau_i(x)) = \alpha_0 + \alpha_1 E(\tau_1(x)) + \dots + \alpha_i E(\tau_i(x)) = \alpha_0 \quad (13)$$

2 阶统计矩即方差如下:

$$D(y) = \mu^2 = E(y^2) - E(y)^2 = E(\alpha_0 + \alpha_1 \tau_1(x) + \dots + \alpha_i \tau_i(x))^2 - \alpha_0^2 = \alpha_1^2 + \alpha_2^2 + \dots + \alpha_i^2 \quad (14)$$

1.3 蚁狮优化算法

陈承滨等^[9]提出了蚁狮优化算法(ant lion optimizer algorithm, ALO),其灵感来源于蚁狮独特的捕猎行为,有着较好的寻优能力。

ALO 算法模拟了蚁狮捕获蚂蚁的过程。规定蚂蚁在搜索空间内移动,而蚁狮可以通过设置陷阱捕捉蚂蚁并变得更灵敏。算法设置随机行走来模拟蚂蚁的觅食行动,如下式所示。

$$X(t) = [0, \text{cumsum}(2r(s_1)-1), \dots, \text{cumsum}(2r(s_n)-1)] \quad (15)$$

式中: cumsum 为叠加求和; n 是迭代的最大次数; s 为随机游走的步长; $r(s)$ 为随机函数,定义如下:

$$r(s) = \begin{cases} 1, & \text{rand} > 0.5 \\ 0, & \text{rand} \leq 0.5 \end{cases} \quad (16)$$

式中 rand 为在区间 $[0, 1]$ 内均匀分布产生的随机数。

式(17)描述蚂蚁的随机位置受陷阱的影响。

$$\begin{cases} c_i^t = A_{\text{ntlion}_j}^t + c^t \\ d_i^t = A_{\text{ntlion}_j}^t + d^t \end{cases} \quad (17)$$

式中: c^t 为第 t 次迭代中所有变量的最小值; d^t 为第 t 次迭代中所有变量的最大值; c_i^t 为第 i 蚂蚁所有变量的最小值; d_i^t 为第 i 蚂蚁所有变量的最大值; $A_{\text{ntlion}_j}^t$ 为所选的第 j 个蚁狮在第 t 次迭代时的位置。

为了更好地模拟蚁狮的狩猎能力,ALO 算法引入了轮盘赌策略,根据优化过程中的适应度来

选择蚁狮。根据轮盘赌方法,蚁狮能够根据自身的适应度来建造陷阱,而蚂蚁则需要进行随机移动。当蚁狮发现陷阱中有蚂蚁,就会从陷阱中心向外射出沙子防止蚂蚁逃走。为了模拟这种行为,蚂蚁游走的球面半径会逐渐减小,描述方程为

$$\begin{cases} c^t = \frac{c^t}{I} \\ d^t = \frac{d^t}{I} \end{cases} \quad (18)$$

式中: I 为一个比率, $I = 10^w \frac{t}{T}$; t 为当前迭代次数;

T 为最大迭代次数; w 为基于当前迭代定义的常数,通过调节 w 可以调节搜索的精度。

捕猎的最后阶段是当一只蚂蚁到达陷阱底部被蚁狮捕获。同时,蚁狮会修正自己的位置以便于更容易捕获猎物,在这方面提出了下列公式:

$$A_{\text{ntlion}_j}^t = A_{\text{nti}}^t, \quad f(A_{\text{nti}}^t) > f(A_{\text{ntlion}_j}^t) \quad (19)$$

式中: A_{nti}^t 为第 t 次迭代时第 i 个蚂蚁的位置; f 为适应度函数。

每一次迭代后,选择适应度最好的蚁狮作为精英蚁狮。迭代过程中,蚂蚁围绕蚁狮随机游走,描述方程为

$$A_{\text{nti}}^t = \frac{R_A^t + R_E^t}{2} \quad (20)$$

式中: R_A^t 为第 t 次迭代时选择的蚁狮; R_E^t 为第 t 次迭代时围绕精英蚁狮的随机位置。

2 不确定性模型修正方法

不确定性模型修正以参数统计矩(均值、标准差)样本点为 Kriging 模型输入,并使用多项式混沌展开模型对每一组样本点参数统计矩进行响应统计矩计算,将对应的响应统计矩(均值、标准差)作为 Kriging 模型输出,构建出参数统计矩和输出响应统计矩之间关系的函数表达式。

传统计算结构响应概率分布的方法是蒙特卡罗模拟方法(MCS)。MCS 方法通过对不确定性参数进行大规模采样,计算样本点输出结构响应,统计其概率分布特性,此方法耗费成本极高。本文采用多项式混沌展开模型对结构输出响应统计矩进行快速计算,解决了在进行不确定性模型修正时计算响应概率统计时高成本高耗时的难题,提高了修正效率。

模型修正的本质是一个函数寻优的过程,在修正时以实测响应统计矩与 Kriging 模型响应统计矩之差为目标函数,目标函数为

$$f_{\min} = \sum_{i=1}^m \left(\frac{y_i^{\text{Kriging}} - y_i^{\text{exp}}}{y_i^{\text{exp}}} \right)^2 \quad (21)$$

式中: y_i^{Kriging} 表示 Kriging 模型计算出的响应统计矩; y_i^{exp} 表示实测响应统计矩; m 为模态阶数。

确定好目标函数之后,以目标函数最小化为宗旨进行迭代寻优。修正步骤流程如图 1 所示。




图 1 修正步骤流程图

3 算例验证

3.1 自由度弹簧质量块系统

3 自由度弹簧质量块系统如图 2 所示。确定参数为 $m_i = 1.0 \text{ kg} (i = 1, 2, 3)$, $k_3 = k_4 = 1.0 \text{ N/m}$, $k_6 = 3.0 \text{ N/m}$; 其余未知参数均服从高斯正态分布, 均值和标准差为 $\mu_{k1} = \mu_{k2} = \mu_{k5} = 1.0 \text{ N/m}$, $\sigma_{k1} = \sigma_{k2} = \sigma_{k5} = 0.2 \text{ N/m}$; 未知参数的初始估计值为 $\mu_{k1} = \mu_{k2} = \mu_{k5} = 2.0 \text{ N/m}$, $\sigma_{k1} = \sigma_{k2} = \sigma_{k5} = 0.3 \text{ N/m}$ 。




图 2 3 自由度系统

有研究表明当样本数据为 10 000 时, 所得的样本响应统计数据较为稳定。本次试验根据参数概率分布随机抽取 10 000 个样本点进行蒙特卡罗模拟获得系统的响应统计矩, 表 1 给出了系统响应统计矩数值。

表 1 系统响应统计矩

阶数	均值/Hz	标准差/Hz	变异系数/%
1	0.953 0	0.094 3	9.89
2	3.995 3	0.332 1	8.31
3	8.009 3	0.142 1	1.78

参数均值修正时的迭代收敛如图 3 所示。由图 3 可知, 蚁狮算法在进行 40 次迭代时开始收敛, 在 100 次迭代后参数趋于稳定状态, 稳定收敛。




图 3 待修正参数均值迭代收敛图


从表 2 和表 3 以及图 4 散点图可以看出: 修正后的前 3 阶特征值范围与试验值基本吻合, 均值误差在 0.11%~0.53%, 标准差误差在 0.007%~3.642%, 修正精度较好。

表 2 系统参数均值修正前后对比

参数	试验值/ (N/m)	初始值/ (N/m)	误差/%	修正	误差/%
k_1	1.0	2.0	100	0.996 7	0.30
k_2	1.0	2.0	100	1.005 3	0.53
k_3	1.0	2.0	100	0.998 9	0.11

表 3 系统参数标准差修正前后对比

参数	试验值/ (N/m)	初始值/ (N/m)	误差/%	修正	误差/%
k_1	0.2	0.3	50	0.201 5	0.747 8
k_2	0.2	0.3	50	0.192 7	3.642 3
k_3	0.2	0.3	50	0.199 9	0.007 2



(a) 试验值和初始估计特征值散点图




图 4 散点图

3.2 三维桁架

用三维空间桁架来进行进一步的验证。模型总质量 54 kg, 跨度 2 800 mm, 节间长度 400 mm, 共 7 节。主桁中心距 360 mm, 桁高 270 mm, 跨高比为 10, 材料的泊松比为 0.3。

考虑到弹性模量以及密度的不确定性, 假设服从高斯分布的随机变量, 桁架的弹性模量均值为 190 GPa, 密度的均值为 7 800 kg · m⁻³, 变异系数为 1%。有限元模型如图 5 所示。




图 5 三维桁架有限元模型

为了提高数据的准确性, 本次以实测参数统计矩为概率分布进行 2 000 次随机抽样并进行有限元模型分析, 统计桁架的频率概率分布作为实测数据。表 4 为实测频率统计特征值。

表 4 桁架频率统计值

阶数	均值/Hz	标准差/Hz	变异系数/%
1	66.022 0	0.469 3	0.710 8
2	135.892 1	0.965 8	0.710 7
3	196.420 9	1.395 7	0.710 5
4	236.353 8	1.679 5	0.710 6

采用第 2 节所述的方法进行不确定性模型修正, 获得修正后的参数统计特征值如表 5 所示。

数据显示弹性模量关于均值和标准差修正后误差分别为 1.1% 和 0.84%, 密度修正后误差分别为 1.03% 和 1.32%, 可以看出在该方法下参数的均值和标准差和实测值间的误差很小, 从而证明该方法的有效性。由表 6 可知, 在对频率均值进行修正后, 本文方法的修正误差精度在 0.04%, 表明该方法的修正精度很高, 效果很好。表 7 显示了频率标准差修正后的数据, 修正后的误差为 3.4%。

表 5 参数统计特征值与估计值

项目	实际值		修正值	
	弹性模量/GPa	密度/(kg · m ⁻³)	弹性模量/GPa	密度/(kg · m ⁻³)
均值	190.00	7 800	187.91	7 720
标准差	1.900	78.00	1.884	79.03

表 6 实测以及修正后频率均值

阶数	实测值/Hz	修正值/Hz	误差/%
1	66.022 0	66.049 8	0.042 1
2	135.892 1	135.949 4	0.042 2
3	196.420 9	196.503 3	0.041 9
4	236.353 8	236.453 1	0.042 0

表 7 频率标准差的实测与修正值

阶数	实测值/Hz	修正值/Hz	误差/%
1	0.469 3	0.485 5	3.452
2	0.965 8	0.999 4	3.479
3	1.395 7	1.444 4	3.490
4	1.679 5	1.738 0	3.483

4 结语

本文考虑到在实际工程结构中存在的参数不确定性现象, 从而提出一种不确定性模型修正方法。利用多项式混沌展开在响应统计矩计算快的优势, 结合 Kriging 模型, 直接构建出描述参数不确定性和结构响应不确定性关系的函数关系式。通过 3 自由度弹簧质量块系统和三维桁架数值仿真算例进行了验证。验证结果表明: 参数的统计矩(均值和标准差)均能很好地进行预测, 并且预测响应数值和实际响应数值差距较小; 同时能够较好地反映实际状况。通过上述算例, 该方法得到了有效的验证。

(下转第 232 页)

高频工件识别效果的影响;然后针对工件类间差异小的特点,采用弱监督区域检测模块搜索和定位有区别的局部图像;最后结合分支融合模块使网络有效地权衡工件的全局特征和局部特征。实验结果表明:与原始的 ResNet50 网络相比,本文算法对高频工件识别准确率提高了 14.5 个百分点,具有更强的特征提取能力。此外,与多种图像识别算法相比,本文算法对高频工件识别准确率均有一定程度的提升。实验结果证明了本文算法的有效性。未来可进一步探索更高效的网络结构和识别算法。

参考文献:

- [1] ZHOU JZ, WEN X. Research on influencing factors and multiple driving paths of intelligent transformation in China's manufacturing industry [J]. Journal of Computational Methods in Sciences and Engineering, 2021, 21(5): 1561-1573.
- [2] 李昌明,李东年,陈成军,等. 基于卷积神经网络与虚拟训练集的零件识别[J]. 组合机床与自动化加工技术, 2021(8): 40-43.
- [3] 张科研,孙继旋,庞启硕. 工件形状的激光雷达三维扫描识别方法[J]. 激光杂志, 2021, 42(5): 133-137.
- [4] MARCATO M. The Made in China 2025 amid hyperglobalization: upgrading, intangible assets, and internationalization strategies [J]. Economia e Sociedade, 2022, 31: 355-384.
- [5] 杨涛,欧阳,苏欣,等. 联合损失监督的高频工件深度学习识别算法[J]. 机械制造与自动化, 2023, 52(1): 30-33, 47.
- [6] DUAN S L, YIN C C, LIU M M. Recognition algorithm based on convolution neural network for the mechanical parts [C]//International Workshop of Advanced Manufacturing and Automation. Singapore: Springer, 2019: 337-347.
- [7] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [8] GAI R L, CAI J R, WANG S Y. Research review on image recognition based on deep learning[J]. Journal of Chinese Computer Systems, 2021, 42(9): 1980-1984.
- [9] 李奇,王宇钢. 基于分块 PCA 和 SVM 的零件识别分类系统[J]. 机械工程与自动化, 2021(4): 21-23, 26.
- [10] CORTES C, VAPNIK V. Support-vector networks[J]. Machine Learning, 1995, 20(3): 273-297.
- [11] 张鹏飞,石志良,李晓焄,等. 基于深度学习的主轴承盖分类识别算法[J]. 图学学报, 2021, 42(4): 572-580.
- [12] 杨乐,甘忠,李义龙,等. 基于改进卷积神经网络的零件识别[J]. 仪表技术与传感器, 2022(5): 82-87.
- [13] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016: 2818-2826.
- [14] CHOLLET F. Xception: deep learning with depthwise separable convolutions[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA: IEEE, 2017: 1800-1807.
- [15] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016: 770-778.
- [16] WANG Q, HUANG W, XIONG Z T, et al. Looking closer at the scene: multiscale representation learning for remote sensing image scene classification[J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(4): 1414-1428.

收稿日期:2023-07-10

(上接第 200 页)

参考文献:

- [1] 王佐才,丁雅杰,戈壁,等. 桥梁结构非线性模型修正研究综述[J]. 交通运输工程学报, 2022, 22(2): 59-75.
- [2] 方圣恩,林友勤,夏樟华. 考虑结构参数不确定性的随机模型修正方法[J]. 振动·测试与诊断, 2014, 34(5): 832-837, 973.
- [3] 秦仙蓉,詹澎明,赵书振,等. 基于替代模型的岸桥随机有限元模型修正[J]. 振动与冲击, 2020, 39(1): 43-48.
- [4] 林光伟,张熠. 不同结构复杂度下结合集成学习的模型修正方法[J]. 工程力学, 2022, 39(增刊1): 153-157.
- [5] 方圣恩,张秋虎,林友勤,等. 参数不确定性估计的随机响应面模型修正方法[J]. 振动工程学报, 2016, 29(4): 594-602.
- [6] WU X, KOZLOWSKI T. Inverse uncertainty quantification of reactor simulations under the Bayesian framework using surrogate models constructed by polynomial chaos expansion[J]. Nuclear Engineering and Design, 2017, 313: 29-52.
- [7] 韩忠华. Kriging 模型及代理优化算法研究进展[J]. 航空学报, 2016, 37(11): 3197-3225.
- [8] 平梦浩,张文华,唐亮. 不确定性结构的非高斯模态参数模拟方法[J]. 华南理工大学学报(自然科学版), 2024, 52(9): 81-92.
- [9] 陈承滨,余岭,潘楚东,等. 基于蚁狮优化算法与迹稀疏正则化的结构损伤识别[J]. 振动与冲击, 2019, 38(16): 71-76, 99.

收稿日期:2024-10-16