

基于改进 Kriging 模型的主动学习可靠性分析方法*

ACTIVE LEARNING METHOD BASED ON IMPROVED KRIGING MODEL FOR RELIABILITY ANALYSIS

陈哲**¹ 杨旭峰***² 程鑫²

(1. 中车株洲电力机车有限公司大功率交流传动电力机车系统集成国家重点实验室, 株洲 412001)

(2. 西南交通大学机械工程学院, 成都 610031)

CHEN Zhe¹ YANG XuFeng² CHENG Xin²

(1. CRRC Zhuzhou Locomotive Co., Ltd., the State Key Laboratory of Heavy Duty AC Drive Electric Locomotive Systems Integration, Zhuzhou 412001, China)

(2. School of Mechanical Engineering, Southwest Jiaotong University, Chengdu 610031, China)

摘要 主动学习 Kriging (ALK) 模型能够只在极限状态平面附近的狭小区域近似功能函数, 因此能够极大提高可靠性分析的效率。但是已有方法多数基于 DACE 工具箱建立 Kriging 模型, 难以获得 Kriging 模型的最优相关参数, 进而难以获得最优的训练点。引入差分进化算法, 对 Kriging 模型的相关参数进行全局搜索, 提高每次迭代 Kriging 模型的预测精度, 保证每次学习都能获得最优的训练点, 从而明显提高了基于 ALK 模型的可靠性分析方法的效率。

关键词 主动学习 Kriging 模型 差分进化算法 可靠性分析

中图分类号 TB114.3

Abstract Active learning Kriging (ALK) model is able to only approximate the performance function in a narrow region around the limit state surface. Therefore, the efficiency of reliability analysis is remarkably improved. However, most of the existing strategies build the ALK model based on a so-called DACE toolbox. DACE cannot obtain the global optimal parameter of a Kriging model and the training point chosen in each iteration cannot be the optimal one. In this paper, one famous global optimization, i.e., the differential evolution algorithm is introduced to explore the optimal parameter of Kriging model and improve the accuracy of Kriging prediction information. As a result, the training point in each iteration is guaranteed to be the global optimal one and the efficiency of ALK model is largely improved.

Key words Active learning; Kriging model; Differential evolution algorithm; Reliability analysis

Corresponding author: YANG XuFeng, E-mail: xufengyang0322@gmail.com

The project supported by the National Natural Science Foundation of China (No.51705433), and the Open Project Program of the State Key Laboratory of Heavy Duty AC Drive Electric Locomotive Systems Integration (No. 2017ZJKF04, 2017ZJKF02).

Manuscript received 20190923, in revised form 20191021.

引言

实际工程结构往往伴随着多种不确定性参数。产品在不确定性因素作用下的安全程度, 需要借助可靠性分析来获得。可靠性分析往往需要转化为大量的确定性分析。实际工程中, 每次确定性分析往往需要借助有限元分析。这使得完整的可靠性分析过程十分耗时。因此, 高效高精度的可靠性分析方法一直是科研人员的重点研究内容。目前为止, 可靠分析方法主要

分为如下三类^{[1] 2459-2468}:

(1) 近似解析法。主要包括一阶可靠性方法 (FORM) 和二阶可靠性方法 (SORM)。FORM、SORM 适用于功能函数非线性程度不高的问题, 对于此类问题, 其求解效率和精度较高。但是, 对于强非线性问题、多失效域问题, 其精度难以保证。(2) 抽样仿真方法。此类方法主要包括 Monte Carlo 方法 (MCS)、重要抽样法、子集模拟法、方向抽样法等。此类方法精度较高, 但是效率很低。(3) 基于代理模型的分析方法。

* 20190923 收到初稿, 20191021 收到修改稿。国家自然科学基金项目 (51705433), 大功率交流传动电力机车系统集成国家重点实验室开放基金 (2017ZJKF04, 2017ZJKF02) 资助。

** 陈哲, 1987 年生, 男, 汉族, 中车株洲电力机车有限公司高级工程师, 硕士。主要从事电力机车结构可靠性与系统集成的研究。

*** 杨旭峰 (通信作者), 1988 年生, 男, 汉族, 西南交通大学机械工程学院讲师, 博士。主要从事结构机构可靠性分析方法的研究。

常用的代理模型有多项式响应面^[2]、神经网络^[3]、支持向量机^[4]、Kriging 模型^[5]¹³³⁻¹⁵¹, 传统代理模型都存在如下问题: ①人为地、机械地布置训练点, 导致选取的训练点不一定是对失效概率精度影响最大的点, 从而导致训练点的增多; ②代理模型精度缺乏恰当的度量标准, 导致精度难以保证^[6]¹⁰⁹⁻¹¹⁷。针对上述问题, 一类基于主动学习 Kriging (ALK) 模型的可靠性分析方法成为当今的研究热点。

Kriging 模型的本质是高斯过程模型。利用 Kriging 模型提供的预测信息, 构建恰当的加点准则, 选取近似空间中正负号最可能被错误预测的点加入实验设计 (DoE), 即可保证最终的 Kriging 模型仅仅在功能函数正负号最可能被错误预测的区域 (而不是在整个设计空间) 对功能函数进行近似。这就是 ALK 模型应用在可靠性领域的基本思路。基于这种思路, 著名的 AK-MCS 方法^[7]¹⁴⁵⁻¹⁵⁴ 和 EGRA 方法^[1]²⁴⁵⁹⁻²⁴⁶⁸ 被提了出来。而后, 国内外学者在 AK-MCS 和 EGRA 的基础上, 对 ALK 模型进行了多方面的改进。文献^[8]¹⁵²⁻¹⁶⁵ 提出了新的、更加高效的加点准则, 文献^[9] 定义了更加合理的设计空间, 文献^[10]⁵⁰¹⁻⁵²¹ 提出了更加合理的收敛准则。文献^[11]²³⁵⁻²⁴¹ ^[12] 研究了 ALK 模型在系统可靠性和时变可靠性问题中的应用。

但是, 在 ALK 模型的构建过程中, DACE 工具箱仍然在普遍使用^[6]¹⁰⁹⁻¹¹⁷ ^[7]¹⁴⁵⁻¹⁵⁴ ^[8]¹⁵²⁻¹⁶⁵ ^[10]⁵⁰¹⁻⁵²¹。在该工具箱中, Kriging 模型的相关参数采用基于梯度的优化算法求解^[13]¹⁵²²⁻¹⁵³⁰ ^[14]³⁷³⁻³⁸⁰, 而该算法极易陷入局部最优解。这使得 Kriging 模型难以给出最优的预测均值和预测方差, 难以保证学习方程预测出最优的训练点, 进而导致 ALK 模型对训练点的浪费。因此, 本文引入一种有效的全局优化算法——差分进化算法^[15]⁹³⁻⁹⁹ ^[16]⁸³⁰⁻⁸⁴³ ^[17]³⁴¹⁻³⁵⁹ (DE), 对 Kriging 模型的最优参数进行全局搜寻, 从而进一步提高 ALK 模型的效率。

1 结构可靠性分析

假设结构的功能函数为 $G(x)$, 其中 $x = [x_1, \dots, x_d]$ 是随机变量。则结构的失效概率定义为

$$P_f = P\{G(x) < 0\} = \int_{R^D} I_F(G(x) < 0) f(x) dx \quad (1)$$

其中, $P\{\}$ 表示某一事件的概率, $f(\cdot)$ 表示变量的联合概率密度函数 (PDF), $I_F(\cdot)$ 为失效指示函数。相应地, 结构的可靠度为 $1 - P_f$ 。采用 MCS 方法, 结构的失效概率可以估计为

$$\hat{P}_f = \frac{1}{N_{MC}} \sum_{i=1}^{N_{MC}} I_F(G(x^{(i)}) < 0) \quad (2)$$

其中, $x^{(i)}$ ($i = 1, \dots, N_{MC}$) 为随机样本。该估计的变

异系数 (Cov)

$$\text{Cov}(\hat{P}_f) = \sqrt{\frac{1 - \hat{P}_f}{N_{MC} \hat{P}_f}} \quad (3)$$

Cov 表征了估计的离散程度, 较小的变异系数方能保证估计的可信性。变异系数通常需要小于 0.1^[7]¹⁴⁵⁻¹⁵⁴, 此时所需的样本个数 $N_{MC} \geq 100/P_f$ 。MCS 方法可以得到结构“准确”的失效概率, 其结果常作为检验其他方法精度的参考解, 但是需要大量的功能函数计算次数。而实际工程问题的功能函数计算往往需要借助计算费时的有限元分析, 这使得基于 MCS 的可靠性分析效率很低。采用 ALK 近似模型, 可以显著减少功能函数计算次数。

2 主动学习 Kriging 模型

Kriging 模型采用高斯过程来表示 $G(x)$ ^[7]¹⁴⁵⁻¹⁵⁴

$$G(x) = \hat{\beta} + z(x) \quad (4)$$

其中, $\hat{\beta}$ 是均值, $z(x)$ 是平稳高斯过程。 $z(x)$ 的均值为 0, 方差为 σ^2 , 自相关函数为

$$E[z(x), z(x')] = \sigma^2 R_{xx}(|x - x'|, \theta) \quad (5)$$

其中, $R_{xx}(|x - x'|, \theta)$ 是高斯相关函数, 参数为 θ (维数为 D)。

给定一个 DoE: $[x^{(1)}, x^{(2)}, \dots, x^{(m)}]^T$ 与 $\mathbf{g} = [G(x^{(1)}), G(x^{(2)}), \dots, G(x^{(m)})]^T$, 可以得到方程

(4) 的后验分布: $\hat{G}(x) \sim N(\mu_G(x), \sigma_G^2(x))$ 。Kriging 模型采用该后验分布对未知点处的响应进行预测, 预测均值

$$\mu_G(x) = \hat{\beta} + \mathbf{r}(x, \theta)^T \mathbf{R}(\theta)^{-1} (\mathbf{g} - \hat{\beta} \mathbf{1}) \quad (6)$$

预测方差

$$\sigma_G^2(x) = \sigma^2 \left[1 + \frac{(\mathbf{1}^T \mathbf{R}(\theta)^{-1} \mathbf{r}(x, \theta) - 1)^2}{\mathbf{l}^T \mathbf{R}(\theta)^{-1} \mathbf{l}} - \mathbf{r}^T(x, \theta) \mathbf{R}(\theta)^{-1} \mathbf{r}(x, \theta) \right] \quad (7)$$

其中, $\mathbf{r}(x, \theta)$ 是一个 $m \times 1$ 的向量, 其第 i 个元素 $r_i(x, \theta) = R_{xx}(|x - x^{(i)}|, \theta)$; $\mathbf{R}(\theta)$ 是一个 m 阶方阵, 其第 (ij) 个元素 $R_{ij}(\theta) = R_{xx}(|x^{(i)} - x^{(j)}|, \theta)$ 。

参数 $\hat{\beta}$ 和 σ^2 可以表达为

$$\hat{\beta} = (\mathbf{1}^T \mathbf{R}(\theta)^{-1} \mathbf{1})^{-1} \mathbf{1}^T \mathbf{R}(\theta)^{-1} \mathbf{g} \quad (8)$$

$$\sigma^2 = \frac{1}{m} (\mathbf{g} - \hat{\beta} \mathbf{1})^T \mathbf{R}(\theta) (\mathbf{g} - \hat{\beta} \mathbf{1}) \quad (9)$$

参数 θ 需要通过最大似然估计方法得到, 这就要求解下面的优化问题

$$L(\theta) = \min_{\theta} (\mathbf{R}(\theta)^{-1} \mathbf{1}^T \sigma^2) \quad (10)$$

充分利用 Kriging 模型提供的预测信息: $\hat{G}(x) \sim N(\mu_G(x), \sigma_G^2(x))$, 即可构造恰当的学习方程, 在候选空间中选出“最可能”位于极限状态平面附近 ($G(x) = 0$) 的点或 $G(x)$ 正负号最可能被错误预测的点。本文建立 ALK 模型采用“可行性期望函数”(EFF) 学习方程, 其定义为^{[1]2459-2468}

$$E_{FF}(x) = \mu_G \left[2\Phi\left(\frac{-\mu_G}{\sigma_G}\right) - \Phi\left(\frac{\varepsilon - \mu_G}{\sigma_G}\right) - \Phi\left(\frac{-\varepsilon - \mu_G}{\sigma_G}\right) \right] - \sigma_G \left[2\phi\left(\frac{-\mu_G}{\sigma_G}\right) - \phi\left(\frac{\varepsilon - \mu_G}{\sigma_G}\right) - \phi\left(\frac{-\varepsilon - \mu_G}{\sigma_G}\right) \right] + \varepsilon \left[\Phi\left(\frac{\varepsilon - \mu_G}{\sigma_G}\right) - \Phi\left(\frac{-\varepsilon - \mu_G}{\sigma_G}\right) \right] \quad (11)$$

其中, $\varepsilon = 2\sigma_G(x)$; ϕ 和 Φ 分别为标准正态分布的概率密度函数和累积分布函数(CDF)。EFF 描述了点位于 $G(x) = 0$ 附近区域的可行程度。候选点中, 使 EFF 取得最大值的点即为最优的训练点, 即

$$\mathbf{x}^{(*)} = \max_{\mathbf{x} \in \Omega_C} E_{FF}(\mathbf{x}) \quad (12)$$

其中, Ω_C 为候选点的集合。将当前最优训练点加入 DoE, 更新 Kriging 模型, 并选出新的最优训练点, 不断迭代, 即可建立 ALK 模型。最终, 可以发现所选的训练点多数集中于 $G(x) = 0$ 附近的狭小区域。ALK 模型能够仅仅在“感兴趣”的区域对目标函数进行近似, 这是其区别于其他近似模型的主要特点。

可以看到学习方程(11)强烈依赖 Kriging 模型提供的预测信息。而 Kriging 模型的参数 θ 决定了该预测信息的准确程度^{[5]133-151[13]1522-1530[14]373-380}。只有全局最优的 θ , 才能给出最准确的预测均值和预测方差, 从而保证方程(12)提供最优的训练点。但是, 已有方法仍然采用 DACE 工具箱建立 Kriging 模型^{[6]109-117[7]145-154[8]152-165[10]501-521}。在该工具箱中, Kriging 模型的参数 θ 采用基于梯度的优化算法求解^{[13]1522-1530[14]373-380}, 极易陷入局部最优解。这使得 ALK 模型每一次迭代均难以获取最优的训练点, 进而导致训练点的浪费。

3 差分进化算法

本文采用 DE 算法对方程(10)进行求解。差分进化算法于 1995 年被 Storn 和 Price 提出^{[15]93-99[16]830-843}。作为一种基于群论的智能优化算法, DE 通过三个流程不断改进种群的质量: 变异、交叉、选择。算法开始时, 需要对种群进行初始化。假设在第 t 代, 种群中包含 N 个个体: $\{\theta_{t,1}, \dots, \theta_{t,N}\}$ 。则初始化种群 ($t = 0$) 为

$$\theta_{0,i,j} = \theta_{j,\min} + \text{rand}_{i,j}(\theta_{j,\max} - \theta_{j,\min}) \quad (13)$$

其中, $\theta_{0,i,j}$ 为初始种群中 $\theta_{t,1}(t = 0)$ 的第 j 个元素; $\theta_{j,\max}$ 和 $\theta_{j,\min}$ 分别设计变量 θ 的第 j 个元素的上界和下

界; $\text{rand}_{i,j} \in [0, 1]$ 是一个均匀随机数。对于第 i 个个体 $\theta_{t,i}$, 其变异体为

$$\mathbf{v}_{t,i} = \theta_{t,r1} + \lambda(\theta_{t,r2} - \theta_{t,r3}) \quad (14)$$

其中, $[r_1, r_2, r_3]$ 是从 $[1, \dots, N]$ 中选出的两两不同的整数, 且均不等于 i ; λ 是变异系数。变异之后, $\theta_{t,i}$ 和 $\mathbf{v}_{t,i}$ 将进行交叉, 得到候选个体 $\mathbf{u}_{t,i}$

$$\mathbf{u}_{t,i,j} = \begin{cases} \mathbf{v}_{t,i,j} & \text{rand}_j \leq C_R \text{ 或 } j = j_{\text{rand}} \\ \theta_{t,i,j} & \text{其他} \end{cases} \quad (15)$$

其中, $\mathbf{u}_{t,i,j}, \mathbf{v}_{t,i,j}, \theta_{t,i,j}$ 分别为个体 $\mathbf{u}_{t,i}, \mathbf{v}_{t,i}$ 和 $\theta_{t,i}$ 的第 j 个元素; $\text{rand}_j \in [0, 1]$ 是一个均匀随机数; j_{rand} 是从 $[1, \dots, D]$ 中随机选择的整数, C_R 为交叉控制参数。而后比较 $\mathbf{u}_i$ 和 θ_i , 选择最优的个体作为下一代种群中的个体

$$\theta_{t+1,i} = \begin{cases} \mathbf{u}_{t,i} & L(\mathbf{u}_{t,i}) \leq L(\theta_{t,i}) \\ \theta_{t,i} & \text{其他} \end{cases} \quad (16)$$

不断对方程(14)~方程(16)进行迭代, 种群质量将不断改善, 最终可以从中获得全局最优的参数 θ ^{[16]830-843[17]341-359}, 建立起更加精确的 Kriging 模型。

4 算法流程

(1) 采用拉丁超立方抽样产生少量训练点。训练点数目定为 12, 样本空间为 $[F_i^{-1}(\Phi(-5)), F_i^{-1}(\Phi(5))]$ (F_i^{-1} 为第 i 个随机变量 CDF 的逆函数)^{[11]235-241}。

(2) 采用 MCS 方法根据 x 的 PDF 抽取 N_{MC} 个样本点, 作为候选点。

(3) 采用 DE 求得全局最优 θ , 建立 Kriging 模型。

(4) 采用 Kriging 模型预测所有候选点的均值和方差, 求取 EFF。从中选出最优的训练点, 记为 $\mathbf{x}^{(*)}$ 。

(5) 如果 $\max E_{FF}(\mathbf{x}^{(*)}) \leq 10^{-4}$, 转到步骤(7), 否则, 继续。

(6) 计算 $G(\mathbf{x}^{(*)})$, 将 $\mathbf{x}^{(*)}$ 加入 DoE, 转到步骤(3)。

(7) 基于 Kriging 模型的预测均值, 采用 MCS 估计失效概率 P_f 和变异系数 Cov。如果 $\text{Cov} \leq 5\%$, 输出 P_f ; 否则, 增大 N_{MC} , 回到步骤(2)。

5 算例分析

5.1 十杆桁架结构

如图 1 所示为一个十杆桁架结构^[18], 承受垂向节点载荷 P 。水平杆、垂直杆和斜杆的截面面积分别为 A_1, A_2, A_3 , 杆件的弹性模量为 E , 结构的功能函数定义为

$$G(x) = 0.06 - \Delta(x) \quad (17)$$




图 2 不同算法优化 Kriging 模型参数 θ

Fig.2 Optimization of parameter θ by different methods




图 3 不同方法 DoE 对比

Fig.3 DoE of different methods




图 4 ALK 模型学习过程(5.1 节)

Fig.4 Learning process of ALK model (Section 5.1)




图 5 非线性弹簧振子

Fig.5 A non-linear oscillator

5.2 非线性弹簧振子

如图 5 所示,一个无阻尼弹簧振子承受冲击载荷 F 的作用。其功能函数为

$$G(x) = 3r - \left| \frac{2F_1}{m\omega_0^2} \sin\left(\frac{\omega_0 t_1}{2}\right) \right| \quad (18)$$

其中, $\omega_0 = \sqrt{(c_1 + c_2)/m}$ 。该算例共有六个随机变量,详见表 3。

不同方法求解该问题所得到的结果如表 4 所示。与算例 4.1 相似,MCS、AK-MCS 和所提方法各运行 10 次,表 4 中的结果为 10 次运行的平均结果。可以看到,在相同的初始条件和收敛条件的情况下,所提方法不仅

保持了高精度,而且比 AK-MCS 节约近 40 个训练点。

表 3 弹簧振子问题的随机变量

Tab.3 Random variables of non-linear oscillator

变量 Variable	分布类型 Distribution	均值 Mean	标准差 Standard deviation
m	正态分布 Normal	1	0.05
c_1	正态分布 Normal	1	0.1
c_2	正态分布 Normal	0.1	0.01
r	正态分布 Normal	0.5	0.01
t_1	正态分布 Normal	1	0.2
F_1	正态分布 Normal	1	0.2

表 4 弹簧振子的计算结果

Tab.4 Results of non-linear oscillator

方法 Method	MCS	AK-MCS	所提方法 Proposed method
功能函数计算次数 Function evaluations	1×10^5	102.6	66.1
P_f	2.87×10^{-2}	2.85×10^{-2}	2.85×10^{-2}
Cov/%	1.84	1.85	1.85
相对误差 Relative error/%	—	0.70	0.70
可靠度 Reliability	0.971 3	0.971 5	0.971 5

图 6 给出了两种方法学习过程中预测的失效概率和 EFF 最大值的变化曲线。可以看到,随着训练点的不断添加,ALK 模型预测精度不断地提高,但是所提方法更加快速地趋近于真实解。这说明,通过对参数 θ 进行全局优化,保证了所添加训练点的全局最优性,

从而起到了对失效概率预测精度的最大改善。同时也可以看到,所提方法更快地收敛于终止条件。这体现了采用 DE 算法全局优化 Kriging 参数 θ 对主动学习过程的改善作用。




图 6 ALK 模型学习过程 (5.2 节)
Fig.6 Learning process of ALK model (Section 5.2)

5.3 曲柄滑块机构

这里考虑一个曲柄滑块机构中连杆的失稳问题^[19],如图 7 所示。在运动过程中,连杆存在失稳的可能性。因此,功能函数定义为

$$G(x)=\frac{\pi^3 E(d_2^4-d_1^4)}{64b^2}-\frac{P(b-a)}{\sqrt{(b-a)^2-e^2}-\mu e}$$

(19)

其中各个变量的详细信息参考表 5。

不同方法的计算结果如表 6 所示,所有方法均执行了 10 次,表中的数据为 10 次计算的平均值。可以看到,所提方法仍然展现了优良性能:在保证高精度的同时,减少了功能函数的计算次数。所提方法与 AK-




图 7 曲柄滑块机构
Fig.7 A crank-slider mechanism

MCS 在单次性能测试所添加的训练点如图 8 所示。在该次测试中,两种方法以相同的初始训练点、相同的候选点开始学习,AK-MCS 添加了 99 个训练点,所提方法添加了 39 个训练点。从该图可以看到,所提方法

表 5 曲柄滑块机构随机变量
Tab.5 Random variables of crank-slider mechanism

随机变量 Variable	变量含义 Meaning	变量类型 Distribution	均值 Mean	标准差 Standard variation
a/mm	曲柄长度 Length of crank	正态分布 Normal	100	1
b/mm	连杆长度 Length of connecting rod	正态分布 Normal	400	1
P/kN	外载荷 External force	正态分布 Normal	750	75
E/GPa	摇杆弹性模型 Young's modulus of connecting rod	正态分布 Normal	200	20
d_1/mm	连杆内径 Inner diameter of connecting rod	正态分布 Normal	20	1
d_2/mm	连杆外径 Outer diameter of connecting rod	正态分布 Normal	40	1
e/mm	偏心距 Offset	正态分布 Normal	125	1
μ	滑块与地面摩擦因数 Coefficient of friction between ground and slider	正态分布 Normal	0.2	0.02

表 6 曲柄滑块机构的计算结果
Tab.6 Results of crank-slider mechanism

方法 Method	MCS	AK-MCS	所提方法 Proposed method
功能函数计算次数 Function evaluations	1×10^5	121.9	51
P_f	5.19×10^{-3}	5.15×10^{-3}	5.23×10^{-2}
Cov/%	4.38	4.40	4.36
相对误差 Relative error/%	—	0.08	0.08
可靠度 Reliability	0.994 8	0.994 8	0.994 9




图 8 不同方法添加训练点对比(5.3 节)

Fig.8 Comparison of added training points
by different methods (Section 5.3)

的训练点更加靠近极限状态平面 $G(x) = 0$, 这说明所提方法的训练点更加优越。通过优化每一次迭代中 Kriging 模型的参数 θ , 可以帮助 ALK 模型获得更优的训练点, 从而显著减少训练点的数目。

6 结论

本文通过引入差分进化算法对 Kriging 模型的相关参数进行全局搜索, 从而提出了一种基于改进 Kriging 模型的主动学习可靠性分析方法, 得出如下结论:

1) 采用 DACE 工具箱建立 Kriging 模型, 难以得到全局最优的相关参数, 从而影响 ALK 模型的学习效率。

2) 采用 DE 全局优化算法搜寻最优的相关参数, 可以使 Kriging 模型提供更加精确的预测信息, 进而使 ALK 模型基于学习方程获得全局最优的训练点, 显著提高 ALK 模型的收敛速度, 减少功能函数计算次数。

参考文献 (References)

- [1] Bichon B J, Eldred M S, Swiler L P, et al. Efficient global reliability analysis for nonlinear implicit performance functions[J]. AIAA Journal, 2008, 46(10): 2459-2468.
- [2] 张春宜, 王爱华, 孙 田, 等. 基于双重响应面法的涡轮叶盘蠕变可靠性分析[J]. 机械强度, 2019, 41(4): 881-886.
ZHANG ChunYi, WANG AiHua, SUN Tian, et al. Reliability analysis of turbine disk creep based on double response surface

method[J]. Journal of Mechanical Strength, 2019, 41(4): 881-886 (In Chinese).

- [3] 赵丽娟, 范佳艺. 基于神经网络的采煤机截割部可靠性研究[J]. 机械强度, 2018, 40(4): 869-874.
ZHAO LiJuan, FAN JiaYi. Reliability research of shearer cutting part based on neural network[J]. Journal of Mechanical Strength, 2018, 40(4): 869-874(In Chinese).
- [4] 丁 飞, 王 谦, 张利蓉, 等. 支持向量机在液压支架可靠性预测中的应用[J]. 机械强度, 2017, 39(3): 603-607.
DING Fei, WANG Qian, ZHANG LiRong, et al. Application of support vector machine in reliability prediction of hydraulic support [J]. Journal of Mechanical Strength, 2017, 39(3): 603-607 (In Chinese).
- [5] Kaymaz I. Application of kriging method to structural reliability problems[J]. Structural Safety, 2005, 27(2): 133-151.
- [6] Cadini F, Santos, Zio E. An improved adaptive kriging-based importance technique for sampling multiple failure regions of low probability[J]. Reliability Engineering and System Safety, 2014 (131): 109-117.
- [7] Echard B, Gayton N, Lemaire M. AK-MCS: An active learning reliability method combining Kriging and Monte Carlo simulation[J]. Structural Safety, 2011, 33(2): 145-154.
- [8] Sun Z, Wang J, Li R, et al. LIF: A new Kriging based learning function and its application to structural reliability analysis [J]. Reliability Engineering & System Safety, 2017(157): 152-165.
- [9] Wen Z, Pei H, Liu H, et al. A sequential Kriging reliability analysis method with characteristics of adaptive sampling regions and parallelizability[J]. Reliability Engineering & System Safety, 2016 (153): 170-179.
- [10] Hu Z, Mahadevan S. Global sensitivity analysis-enhanced surrogate (GSAS) modeling for reliability analysis [J]. Structural and Multidisciplinary Optimization, 2016, 53(3): 501-521.
- [11] Yang X, Liu Y, Mi C, et al. System reliability analysis through active learning Kriging model with truncated candidate region [J]. Reliability Engineering & System Safety, 2018(169): 235-241.
- [12] Hu Z, Mahadevan S. Adaptive surrogate modeling for time-dependent multidisciplinary reliability analysis [J]. Journal of Mechanical Design, 2017, 140(2): 021401.
- [13] 陈志英, 任 远, 白广忱, 等. 粒子群优化的 Kriging 近似模型及其在可靠性分析中的应用[J]. 航空动力学报, 2011, 26(7): 1522-1530.
CHEN ZhiYing, REN Yuan, BAI GuangChen, et al. Kriging approximate model of particle swarm optimization and its application in reliability analysis[J]. Journal of Aeronautical Dynamics, 2011

- (26): 1522-1530(In Chinese).
- [14] 魏 娟, 张建国, 邱 涛. 基于改进的动态 Kriging 模型的结构可靠度算法[J]. 北京航空航天大学学报, 2019, 45(2): 373-380.
WEI Juan, ZHANG JianGuo, QIU Tao. Structural reliability algorithm based on improved dynamic Kriging model[J]. Journal of Beijing University of Aeronautics and Astronautics, 2019(45): 373-380(In Chinese).
- [15] 薛 萍, 周仁鹤, 王宏民. 差分进化算法在四旋翼飞行姿态中的应用[J]. 哈尔滨理工大学学报, 2019, 24(3): 93-99.
XUE Ping, ZHOU RenHe, WANG HongMin. Application of differential evolution algorithm in four rotor flight attitude [J]. Journal of Harbin University of Technology, 2019(24): 93-99(In Chinese).
- [16] Wang Y, Li H, Yen G G, et al. MOMMOP: multiobjective optimization for locating multiple optimal solutions of multimodal optimization problems[J]. IEEE Transactions on Cybernetics, 2015, 45(4): 830-843.
- [17] Storn R, Price K. Differential evolution-a simple and efficient heuristic for global optimization over continuous spaces[J]. Journal of Global Optimization, 1997, 11(4): 341-359.
- [18] Shayanfar M A, Barkhordari M A, Roudak M A. An efficient reliability algorithm for locating design point using the combination of importance sampling concepts and response surface method [J]. Communications in Nonlinear Science and Numerical Simulation, 2017 (47): 223-237.
- [19] Guo J, Du X. Sensitivity analysis with mixture of epistemic and aleatory uncertainties [J]. AIAA Journal, 2007, 45(9): 2337-2349.