

DOI: 10.13382/j.jemi.B2407354

基于 CoKriging 代理模型的涡流无损检测模型辅助探测概率问题的研究

包 扬 仇家豪

(南京邮电大学电子与光学工程学院、柔性电子(未来技术)学院 南京 210003)

摘要: 无损检测模型辅助探测概率问题的研究需要大量仿真数据,而高精度的物理模型计算模型响应需要大量时间,往往是无法实现的。代理模型是一种高效的数学模型,可以替代费时复杂的物理模型,广泛应用于设计优化问题。CoKriging 模型可以融合高精度和低精度的数据,融合了大量计算成本低的低精度数据和少量计算成本高的低精度数据,提高了建模效率,是一种非常有应用潜力的代理模型。文中将 CoKriging 模型应用于涡流无损检测模型辅助探测概率的研究,在有限截面线圈探测金属平板表面槽缺陷算例中,利用物理模型计算部分训练点,构建 CoKriging 模型,精度验证通过后的 CoKriging 模型可以代替物理模型进行 MAPoD 分析,通过对比物理模型计算的 MAPoD 关键参数验证 CoKriging 模型的精度和效率。结果表明,相较于 Kriging 模型,CoKriging 模型只需要更少的样本点训练模型就可以达到求解精度的要求,其构建元模型所需时间仅为 Kriging 元模型所需的 7%,提高了涡流无损检测模型辅助探测概率研究的效率。

关键词: 涡流无损检测;代理模型;Kriging 模型;CoKriging 模型;模型辅助探测概率

中图分类号: TM93 **文献标识码:** A **国家标准学科分类代码:** 510. 1040

Model-assisted probability of detection for eddy current nondestructive testing based on CoKriging surrogate model

Bao Yang Qiu Jiahao

(School of Electronic and Optical Engineering & School of Flexible Electronics (Future Technology),
Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

Abstract: The study of model assisted probability of detection in eddy current nondestructive testing requires a large amount of simulation data, while high-precision physical model calculations demand considerable time and are often impractical. The surrogate model is an efficient mathematical model that can replace time-consuming and complex physical models, and is widely used in design optimization problems. CoKriging, a model that fuses high and low-precision data, utilizes a large amount of low-cost and low-precision data, and a small amount of high-cost and high-precision data, which significantly improves the modeling efficiency over Kriging model. It is a very promising surrogate model. This article applies the CoKriging model to the study of the probability of detection aided by the eddy current nondestructive testing model. In the case of detecting groove defects on the surface of a metal plate using a finite-section coil, the CoKriging model is constructed using physical model calculations for some training points. After verifying the accuracy, the CoKriging model can replace the physical model for MAPoD analysis. By comparing the key parameters of MAPoD calculated by the physical model, the accuracy and efficiency of the CoKriging model are verified. The results show that compared with the Kriging model, the CoKriging model only requires fewer sample points to train the model to meet the defined accuracy requirements and in the best-performing example, its construction time is only 7% of that of the Kriging model, greatly improving the efficiency of the MAPoD.

Keywords: eddy current nondestructive testing; surrogate model; Kriging model; CoKriging model; model assisted probability of detection

0 引言

无损检测 (non-destructive testing, NDT) 是一个热门的研究领域,指的是在不破坏零件或系统的可用性的情况下,对材料、部件或组件的不连续、损伤(如疲劳裂纹)或特性差异进行检查、测试或评估的过程。现代无损检测系统用于制造、加工和在役检验,以确保产品的完整性和可靠性,控制制造过程,降低生产成本,并保持统一的质量水平,广泛应用于航空航天、土木工程、核工业等行业^[1]。涡流无损检测利用电磁感应原理,通过测量被检工件内感生涡流的变化来无损地评定导电材料及其工件的某些性能,具有无需接触、检测速度快,检漏率低等优点,是一种非常流行的无损检测方法^[2-4]。无损检测是保证结构安全、可靠、耐用的重要因素。因此检测概率(probability of detection, PoD)作为一种量化无损检测系统检测性能的标准工具,也变得越来越重要。

然而,要获得可靠的 PoD 是非常复杂和困难的。传统的方法是进行盲法试验或循环研究。这些试验试图在不同程度上模拟实际的检验条件,但非常耗时且成本高昂,再加上配置的复杂性不断增加,使其有时难以实现^[5]。为解决此问题,学者们提出了基于模型的 MAPoD (model assisted probability of detection) 分析思想,研究利用数值模型代替无损检测试验来获得 PoD 分析所需实验数据^[6-8]。但得出精确的 MAPoD 的关键挑战之一是计算负担,特别是一些精细复杂的数值模型的计算量很大,例如,在台式计算机上进行一次涡流模拟可能需要几个小时,而且 MAPoD 分析中不确定性传播过程要使用传统方法进行大量的模型评估,如蒙特卡罗采样,这无疑对计算能力与计算速度提出更多的挑战^[9]。尽管迄今为止计算机领域关于运算速度的摩尔定律仍然有效,但从实际来看,这种计算机运算能力的提升还无法抵消实际结构分析中的巨大运算能力要求与挑战,要在有限时间内完成 MAPoD 分析依然十分困难。

为了减轻 MAPoD 的计算负担,引入了代理模型技术,通过构建快速近似模型代替耗时的基于物理的数值模型来求解给定的计算应用^[10-12]。代理模型在无损检测可靠性计算、优化设计和灵敏度分析等方面得到了广泛运用。Du, Bao 等^[13-15]论证了 Kriging 代理模型在涡流检测系统正演问题和逆演问题中的可行性和有效性,并提出了一种自适应采样方案来生成最优数据库,以进一步降低总计算成本。Miorelli 等^[16]在使用支持向量回归代理模型解决反演问题的涡流测试案例中,MAPoD 和灵敏度分析均取得了令人满意的结果。Knopp 等^[17]成功地将基于普通最小二乘法的多项式混沌展开法引入到涡流检测系统中,高效地完成了对相对低维问题的系统可靠

性量化。这些单级建模方法的预测精度取决于训练集的精度,训练集的精度越高,数量越多,其预测的精度也越高,但大量高精度的训练集需要耗费过多的时间和计算资源。文中提出的基于多保真建模的 CoKriging 可以融合来自不同精度模型的数据,用少量获取成本高昂的高保真数据和少量到大量获取成本低的低保真数据来构建,在达到相同精度的条件下,可以显著节省计算资源和时间。

1 CoKriging 模型和 MAPoD

1.1 Kriging 模型

Kriging 也称高斯回归过程,起源于地质统计学,是一种插值方法。Kriging 将所有观测数据作为训练点,并最小化均方误差 (MSE) 来估计模型系数,表达式为^[13-15,18-21]:

$$Y(x) = \beta + Z(x) \quad (1)$$

其中, β 是未知常数,也称全局趋势模型。 $Z(x)$ 是均值为 0, 方差为 σ^2 , 协方差不为 0 的随机过程。在设计空间中,任意两点的协方差表示为:

$$\text{Cov}[Z(x), Z(x')] = \sigma^2 R(x, x') \quad (2)$$

式中: $R(x, x')$ 为相关函数。

对于一个 m 维优化问题,采样 n 个样本点 $S = [x^{(1)}, x^{(2)}, \dots, x^{(n)}]^T \in \mathbf{R}^{n \times m}$, 相应的 n 个响应为 $y_s = [y(x^{(1)}), y(x^{(2)}), \dots, y(x^{(n)})]^T \in \mathbf{R}^n$ 。

Kriging 模型对于任意设计参数样点 x 处响应的预测表达式为:

$$\hat{y}(x) = \hat{\beta} + r^T(x) R^{-1}(y_s - F\hat{\beta}) \quad (3)$$

式中:

$$\hat{\beta} = (F^T R^{-1} F)^{-1} F^T R^{-1} y_s \quad (4)$$

$$F = [1 \quad 1 \quad \dots \quad 1] \in \mathbf{R}^n \quad (5)$$

$$R =$$

$$\begin{bmatrix} R(x^{(1)}, x^{(1)}) & R(x^{(1)}, x^{(2)}) & \dots & R(x^{(1)}, x^{(n)}) \\ R(x^{(2)}, x^{(1)}) & R(x^{(2)}, x^{(2)}) & \dots & R(x^{(2)}, x^{(n)}) \\ \dots & \dots & \dots & \dots \\ R(x^{(n)}, x^{(1)}) & R(x^{(n)}, x^{(n-1)}) & \dots & R(x^{(n)}, x^{(n)}) \end{bmatrix} \in \mathbf{R}^{n \times n} \quad (6)$$

$$r = \begin{bmatrix} R(x^{(1)}, x) \\ R(x^{(2)}, x) \\ \vdots \\ R(x^{(n)}, x) \end{bmatrix} \in \mathbf{R}^n \quad (7)$$

其中, R 是所有已知样本点之间的相关函数构成的相关矩阵, r 是未知点与所有已知样本点之间的相关函数构成的相关向量。

1.2 CoKriging 模型

CoKriging 是 Kriging 的多变量版本,可以融合来自多个模型层次的信息,是 Kriging 模型利用辅助信息提高建模效率的一般扩展^[21-23]。具体来说,CoKriging 使用一个或多个低保真 (low fidelity, LF) 模型数据增强高保真 (high fidelity, HF) 模型的估计。考虑两个不同可信度的数据集,采样得到样本点为:

$$S_1 = [x_1^{(1)}, x_1^{(2)}, \dots, x_1^{(n)}]^T \in R^{n_1 \times m}, \quad (8)$$

$$S_2 = [x_2^{(1)}, x_2^{(2)}, \dots, x_2^{(n)}]^T \in R^{n_2 \times m}$$

以及相应的响应:

$$y_1 = [y_1(x_1^{(1)}), y_1(x_1^{(2)}), \dots, y_1(x_1^{(n)})]^T \in R^{n_1},$$

$$y_2 = [y_2(x_2^{(1)}), y_2(x_2^{(2)}), \dots, y_2(x_2^{(n)})]^T \in R^{n_2}$$

(9)

其中, n_1 和 n_2 分别是 HF 模型和 LF 模型的采样点个数。

和 Kriging 一样,CoKriging 将输出响应视为一个平稳的随机过程,这里用以下随机函数替换 y_1 和 y_2 为:

$$Y_1(x) = \beta_1 + Z_1(x), Y_2(x) = \beta_2 + Z_2(x) \quad (10)$$

假设 HF 模型的输出可以用 y_1, y_2 的线性组合来近似,则 CoKriging 在 x 处对 $y_1(x)$ 的预测值定义为:

$$\hat{y}_1(x) = \lambda^T y_s = \lambda_1^T y_1 + \lambda_2^T y_2 \quad (11)$$

其中, $\lambda^T = (\lambda_1^T, \lambda_2^T)$ 是权重系数向量。这里用随机变量 Y_1, Y_2 替换 y_1, y_2 为估计权重系数,使 $\hat{y}_1(x)$ 均方误差最小:

$$MSE[\hat{y}_1(x)] = E[(\lambda_1^T Y_1 + \lambda_2^T Y_2 - Y_1)^2] \quad (12)$$

在无偏约束下为:

$$E[\lambda_1^T Y_1 + \lambda_2^T Y_2] = E[Y_1] \quad (13)$$

求解此约束最小化问题时,式(5)中的 CoKriging 权值可由以下线性方程组求得^[22]:

$$\begin{bmatrix} C^{(11)} & C^{(12)} & I & \theta \\ C^{(21)} & C^{(22)} & \theta & I \\ I^T & \theta^T & 0 & 0 \\ \theta^T & I^T & 0 & 0 \end{bmatrix} \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \mu_1/2 \\ \mu_2/2 \end{bmatrix} = \begin{bmatrix} c_1(x) \\ c_2(x) \\ 1 \\ 0 \end{bmatrix} \quad (14)$$

作如下变换:

$$\tilde{\lambda}_1 = \lambda_1, \tilde{\lambda}_2 = \sigma_2/\sigma_1 \lambda_2$$

$$\tilde{\mu}_1 = \mu_1/(2\sigma_1^2), \tilde{\mu}_2 = \mu_2/(2\sigma_1\sigma_2) \quad (15)$$

可得:

$$\begin{bmatrix} R^{(11)} & R^{(12)} & I & \theta \\ R^{(21)} & R^{(22)} & \theta & I \\ I^T & \theta^T & 0 & 0 \\ \theta^T & I^T & 0 & 0 \end{bmatrix} \begin{bmatrix} \tilde{\lambda}_1 \\ \tilde{\lambda}_2 \\ \tilde{\mu}_1 \\ \tilde{\mu}_2 \end{bmatrix} = \begin{bmatrix} r_1(x) \\ r_2(x) \\ 1 \\ 0 \end{bmatrix} \quad (16)$$

在解得新的权重 $\tilde{\lambda}_1$ 和 $\tilde{\lambda}_2$ 之后,CoKriging 预测模型可写为:

$$\hat{y}_1(x) = \tilde{\lambda}_1^T y_1 + \frac{\sigma_1}{\sigma_2} \tilde{\lambda}_2^T y_2 \quad (17)$$

或矩阵形式:

$$\hat{y}_1(x) = \begin{bmatrix} r_1(x) \\ r_2(x) \\ 1 \\ 0 \end{bmatrix}^T \begin{bmatrix} R^{(11)} & R^{(12)} & I & \theta \\ R^{(21)} & R^{(22)} & \theta & I \\ I^T & \theta^T & 0 & 0 \\ \theta^T & I^T & 0 & 0 \end{bmatrix}^{-1} \begin{bmatrix} y_1 \\ (\sigma_1/\sigma_2)y_2 \\ 0 \\ 0 \end{bmatrix} \quad (18)$$

通过分块矩阵求逆可得:

$$\hat{y}_1(x) = \varphi^T \tilde{\beta} + r^T(x) R^{-1} (\tilde{y}_s - F \tilde{\beta}) \quad (19)$$

其中,

$$\varphi = \begin{bmatrix} 1 \\ 0 \end{bmatrix}, \tilde{\beta} = \begin{bmatrix} \tilde{\beta}_1 \\ \tilde{\beta}_2 \end{bmatrix} = (F^T R^{-1} F)^{-1} F^T R^{-1} \tilde{y}_s,$$

$$r = \begin{bmatrix} r_1(x) \\ r_2(x) \end{bmatrix}, R = \begin{bmatrix} R^{(11)} & R^{(12)} \\ R^{(21)} & R^{(22)} \end{bmatrix}, \quad (20)$$

$$\tilde{y}_s = \begin{bmatrix} y_1 \\ \frac{\sigma_1}{\sigma_2} y_2 \end{bmatrix}, F = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \in R^{(n_1+n_2) \times 2}$$

1.3 相关函数

相关函数表示随机向量之间的相关性,取值范围在 0 到 1 之间,仅取决于随机向量之间的空间距离。目前比较主流的相关函数形式为:

$$R(\theta, x, w) = \prod_{k=1}^m R_k(\theta_k, x_k - w_k) \quad (21)$$

其中, $\theta = [\theta_1, \theta_2, \dots, \theta_m] \in R^m$ 是距离权重(需要调优的关键参数)。这里使用高斯相关函数,其形式为:

$$R_k(\theta_k, x_k - w_k) = \exp\left[-\sum_{k=1}^m \theta_k |x_k - w_k|^2\right] \quad (22)$$

1.4 模型参数优化

构建 CoKriging 模型需要对模型中的超参数进行训练优化,一般使用极大似然法。对应的似然函数为

$$\tilde{L}(\tilde{\beta}, \sigma_1/\sigma_2, \sigma_1^2, \theta^{(11)}, \theta^{(12)}, \theta^{(22)}) =$$

$$\frac{1}{\sqrt{(2\pi\sigma_1^2)^{(n_1+n_2)} |\mathbf{R}|}} \exp\left[-\frac{1}{2} \frac{(\tilde{y}_s - F\tilde{\beta})^T R^{-1} (\tilde{y}_s - F\tilde{\beta})}{\sigma_1^2}\right] \quad (23)$$

对待估计参数求导,可以分别得到 $\tilde{\beta}, \sigma_1/\sigma_2, \sigma_1^2$ 的最优解为:

$$\tilde{\boldsymbol{\beta}} = (\mathbf{F}^T \mathbf{R}^{-1} \mathbf{F}) \mathbf{F}^T \mathbf{R}^{-1} \tilde{\mathbf{y}}_s$$

$$\frac{\sigma_1}{\sigma_2} = \left(\begin{bmatrix} \mathbf{0} \\ \mathbf{y}_2 \end{bmatrix}^T \mathbf{R}^{-1} \begin{bmatrix} \mathbf{0} \\ \mathbf{y}_2 \end{bmatrix} \right)^{-1} \begin{bmatrix} \mathbf{0} \\ \mathbf{y}_2 \end{bmatrix}^T \mathbf{R}^{-1} \begin{bmatrix} -(\mathbf{y}_1 - \mathbf{1}\tilde{\boldsymbol{\beta}}_1) \\ -\mathbf{1}\tilde{\boldsymbol{\beta}}_2 \end{bmatrix}$$

$$\sigma_1^2 = \frac{(\tilde{\mathbf{y}}_s - \mathbf{F}\tilde{\boldsymbol{\beta}})^T \mathbf{R}^{-1} (\tilde{\mathbf{y}}_s - \mathbf{F}\tilde{\boldsymbol{\beta}})^T}{n_1 + n_2} \quad (24)$$

通过上述公式,再估计超参数 $\boldsymbol{\theta}(\boldsymbol{\theta}^{(11)}, \boldsymbol{\theta}^{(12)}, \boldsymbol{\theta}^{(22)})$

$$\boldsymbol{\theta} = \operatorname{argmax} \left[-\frac{1}{2}(n_1 + n_2) \cdot \ln(\sigma_1^2) + \ln(|\mathbf{R}|) \right] \quad (25)$$

式中: $\boldsymbol{\theta}$ 无解析解形式,可采用遗传算法求得数值解。

1.5 模型验证

使用均方根误差 (root mean square error, RMSE) 和归一化均方根误差 (normalized root mean square error, NRMSE) 验证模型,公式为:

$$RMSE = \sqrt{\sum_{i=1}^{N_t} (\hat{y}_i - y_i)^2 / N_t}$$

$$NRMSE = \frac{RMSE}{\max(\hat{\mathbf{y}}) - \min(\mathbf{y})} \quad (26)$$

式中: N_t 为总测试点的个数, \hat{y}_i 和 y_i 分别为第 i 个测试点的模型预测值和实际响应值, $\max(\hat{\mathbf{y}})$ 和 $\min(\mathbf{y})$ 分别是模型预测值中的最大值和实际响应值中的最大值。

1.6 探测概率分析

线性的 \hat{a} vs. a 回归可以很好的描述模型响应 (\hat{a}) 与缺陷尺寸 (a) 之间的对数线性关系,可以表示为^[24]:

$$\ln(\hat{a}) = \beta_0 + \beta_1 \ln(a) + \gamma \quad (27)$$

其中, β_0 和 β_1 是线性回归参数,可以由最大似然法求得, γ 是服从正态分布,均值为 0,标准差为 σ_γ 的随机误差。

为了计算无损检测系统的 PoD,需要先定义一个阈值 \hat{a}_m ,当模型响应 \hat{a} 大于阈值 \hat{a}_m 时,标记为探测到缺陷。高于阈值的响应数量除以响应的总数就是 PoD。结合 \hat{a} vs. a 回归可以获得任意尺寸缺陷的 PoD,表示为:

$$\text{PoD}(a) = \Phi \left[\frac{\ln(a) - \frac{\ln(\hat{a}_m) - \beta_0}{\beta_1}}{\frac{\sigma_\gamma}{\beta_1}} \right] \quad (28)$$

式中: Φ 为标准正态分布的累积密度函数。

2 算例分析

文中选取的计算模型为有限截面线圈探测矩形金属平板表面槽缺陷。算例 1、2 中,探测线圈外径 a_1 为

18.4 mm,内径为 a_2 为 9.34 mm,厚度为 9 mm,匝数为 408,工作频率为 7 000 Hz。算例 3 中,探测线圈内径 a_1 为 6.15 mm,外径为 a_2 为 12.4 mm,厚度为 6.15 mm,匝数为 3 790,工作频率为 900 Hz。两个算例中的金属平板厚 12.22 mm,电导率为 30.6 MS/m,表面槽缺陷长度 c 为 1~5 mm,间隔为 1 mm,宽度 w 为 0.28 mm,深度 h 为 5 mm,如图 1 所示。探测线圈 x 、 y 轴位置和提高距离 l 为不确定性参数,具有经验分布,如表 1 所示。

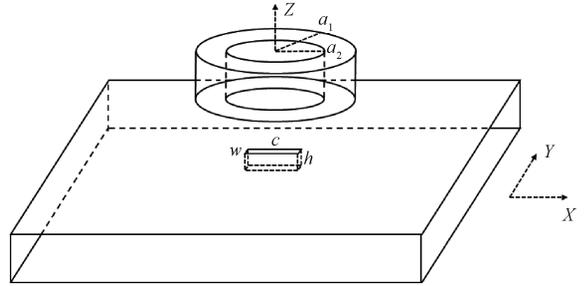


图 1 有限截面线圈探测金属平板门表面槽缺陷

Fig. 1 Detecting surface slot of the metal by coil with finite cross section

表 1 不确定性参数经验分布

Table 1 Empirical distributions for uncertain parameters

参数	算例 1	算例 2	算例 3
提高距离 l	$U(1.83, 2.23)$	$N(2, 0.7)$	$N(2, 0.5)$
x 轴位置	$N(14, 0.5)$	$U(12.5, 14.5)$	$N(9, 0.7)$
y 轴位置	$U(-1.5, 1.5)$	$U(-1.5, 1.5)$	$N(0, 0.5)$

使用拉丁超立方抽样 (latin hypercube sampling, LHS) 选取训练点,用有限元软件计算 1~5 mm 的 5 个长度的槽缺陷长度的响应值,对每个缺陷长度都构建一个代理模型。为了验证代理模型的准确度,归一化均方根误差需要小于等于 1%。达到精度要求的代理模型就可以进行 PoD 研究。使用蒙特卡洛抽样 (monte carlo sampling, MCS) 选取 1 000 个样本点,对 5 个槽裂缝长度,一共需要计算 5 000 个样本点的物理模型响应用于精度验证。

表 2 总结了 CoKriging 和 Kriging 模型对 3 个算例的计算开销。使用有限元软件中超细化网格剖分作为 HF 数据,每个样本点计算时间约为 3~4 min,粗化网格剖分作为 LF 数据,每个样本点计算时间仅需要 10 s 左右。

表 2 每个缺陷尺寸不同算例代理模型需要计算的训练点数

Table 2 Training points required for different cases of surface slots by surrogate models

参数	算例 1	算例 2	算例 3
Kriging	100	30	30
CoKriging	10+500*	10+150*	10+100*

注: * 额外使用的 LF 训练点

在所构建的代理模型达到精度要求的情况下,对于算例 1 中的每个缺陷长度, Kriging 模型需要计算 100 个 HF 训练点, 5 个缺陷长度总计算耗时 30 h 50 min, 而 CoKriging 模型只需要计算 10 个 HF 训练点和 500 个 LF 训练点, 5 个缺陷长度总耗时 12 h 40 min, 所需时间相较于 Kriging 模型节省了 58.9%。在算例 2 中, 对每个缺陷长度, Kriging 模型需要计算 30 个 HF 训练点才能使得构建的代理模型达到精度要求, 耗时 10 h, CoKriging 模型只需要计算 10 个 HF 训练点和 150 个 LF 训练点所构建的模型就可以达到精度要求, 耗时 5 h, 所需时间相较于 Kriging 模型节省 50%。在算例 3 中, 对每个缺陷长度, Kriging 模型需要计算 30 个 HF 训练点, 耗时 9 h 45 min, 而 CoKriging 模型仅需要计算 10 个 HF 训练点和 100 个 LF 训练点, 耗时 4 h 25 min, 所需时间相较于 Kriging 模型节省 54.7%。从中可以看出在满足相同精度要求的情况下, CoKriging 模型相较于 Kriging 模型需要更低的计算时间开销, 有更高的求解效率。

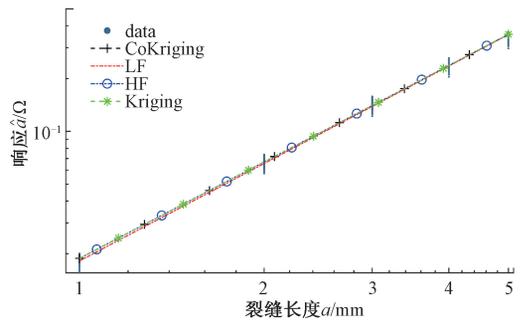
图 2 为算例 1 中模型响应的 \hat{a} vs. a 回归分析和 PoD 曲线, 检测阈值 \hat{a}_{th} 为 0.05 Ω 。由图可知 CoKriging 模型、Kriging 模型以及基于 1 000 个 HF 数据点的物理模型得到的 PoD 曲线基本重合, 而与基于 1 000 个 LF 数据点的物理模型得到的 PoD 曲线则相差较大。Kriging 模型、CoKriging 模型和基于 HF、LF 数据的物理模型得到的 PoD 关键参数 a_{50} 和 a_{90} 如表 3 所示, 由表可知基于 HF 数据点的物理模型和 Kriging 模型、CoKriging 模型预测的两个关键 PoD 指标的相对误差均小于 0.1%, 而 LF 数据和 HF 数据得到关键参数的相对误差在 1%~2%, 由结果可知所构建的 CoKriging 代理模型的精度和基于 HF 数据点的物理模型精度一致。在计算开销方面, 基于 HF 数据点的物理模型计算时间为 71 h, CoKriging 代理模型所需时间相较于基于 HF 数据的物理模型节省了 82.2%。

表 3 算例 1 的 PoD 关键指标

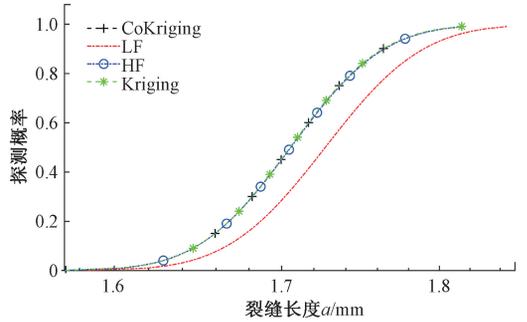
Table 3 Key PoD metrics for case 1

指标	HF	CoKriging/ $\Delta/\%$	Kriging/ $\Delta/\%$	LF/ $\Delta/\%$
a_{50}	1.705 6	1.705 2/0.02	1.713 1/0.44	1.727 0/1.26
a_{90}	1.764 5	1.763 6/0.05	1.764 4/0.10	1.789 79/1.43

图 3 为算例 2 中模型响应的 \hat{a} vs. a 回归分析和 PoD 曲线, 检测阈值 \hat{a}_{th} 为 0.05 Ω 的。由图可知 CoKriging 模型、Kriging 模型以及基于 HF、LF 数据点的物理模型得到的 PoD 曲线基本重合。Kriging 模型、CoKriging 模型和基于 HF、LF 数据的物理模型得到的 PoD 关键参数 a_{50} 和 a_{90} 如表 4 所示, 其中基于 HF 数据点的物理模型和 Kriging 模型、CoKriging 模型预测的两个关键 PoD 指标的相对误差均小于 0.5%, 由此可知所构建



(a) \hat{a} vs. a 回归分析
(a) \hat{a} vs. a regression analysis



(b) 探测概率曲线
(b) Curve of PoD

图 2 算例 1 的模型辅助探测概率测试结果
Fig. 2 Results of model assisted probability of detection for case 1

的 CoKriging 代理模型的精度和基于 HF 数据点的物理模型精度一致。在计算开销方面, 基于 HF 数据点的物理模型计算时间为 72 h, CoKriging 代理模型所需时间相较于基于 HF 数据的物理模型节省了 93.1%。

表 4 算例 2 的 PoD 关键指标

Table 4 Key PoD metrics for case 2

指标	HF	CoKriging/ $\Delta/\%$	Kriging/ $\Delta/\%$	LF/ $\Delta/\%$
a_{50}	1.697 9	1.693 9/0.23	1.695 7/0.13	1.690 8/0.41
a_{90}	1.993 6	1.994 4/0.04	1.989 4/0.21	1.983 49/0.51

图 4 为算例 3 中模型响应的 \hat{a} vs. a 回归分析和 PoD 曲线, 检测阈值 \hat{a}_{th} 为 0.7 Ω 。由图 4 可知 CoKriging 模型、Kriging 模型以及基于 HF 数据点的物理模型得到的 PoD 曲线基本重合, 而与基于 LF 数据点的物理模型得到的 PoD 曲线则相差较大。Kriging 模型、CoKriging 模型和基于 HF、LF 数据的物理模型得到的 PoD 关键参数 a_{50} 和 a_{90} 如表 5 所示, HF 数据和 Kriging 模型、CoKriging 模型在两个关键 PoD 指标上的相对误差均小于 0.2%, 而 LF 数据和 HF 数据得到关键参数的相对误差大于 2%, 由此可知所构建的 CoKriging 代理模型的精度和基于 HF 数据点的物理模型精度一致。在计算开销方面, 基于 HF 数据点的物理模型计算时间为 71.5 h, CoKriging

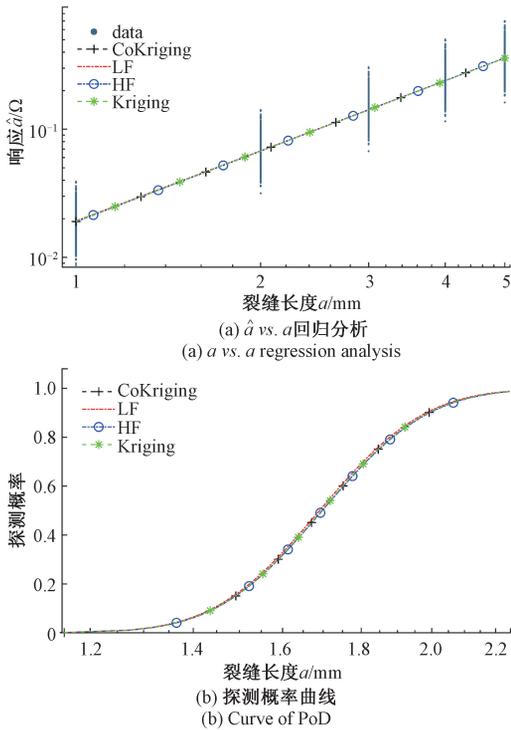


图3 算例2的模型辅助探测概率测试结果
Fig. 3 Results of model assisted probability of detection for case 2

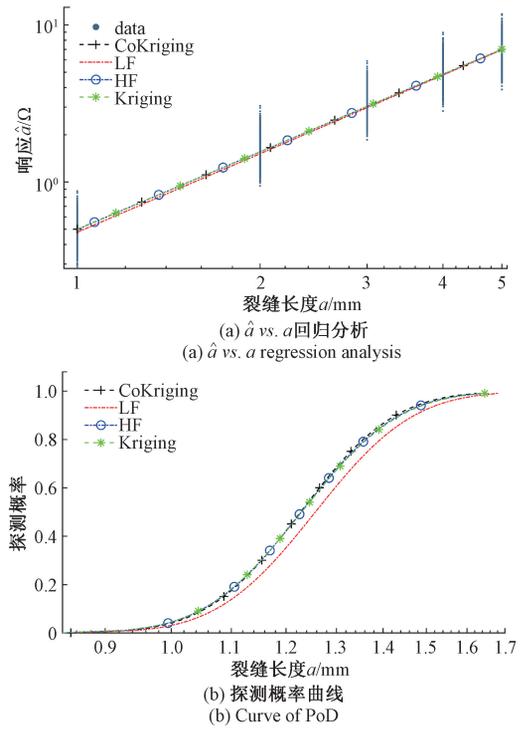


图4 算例3的模型辅助探测概率测试结果
Fig. 4 Results of model assisted probability of detection for case 3

代理模型所需时间相较于基于 HF 数据的物理模型节省了 93.8%。

表5 算例3的 PoD 关键指标
Table 5 Key PoD metrics for case 3

指标	HF	CoKriging/ Δ /%	Kriging/ Δ /%	LF/ Δ /%
a_{50}	1.229 3	1.230 1/0.06	1.231 0/0.13	1.257 1/2.27
a_{90}	1.437 0	1.439 1/0.14	1.441 4/0.30	1.471 94/2.43

3 结论

本文提出一种可以融合不同保真度模型数据的 CoKriging 代理模型,极大提升了 Kriging 代理模型的建模效率,加速了涡流无损检测模型辅助探测概率问题的研究。算例测试表明,CoKriging 模型只需要很少量的高保真数据和一些低保真数据就可以准确的预测模型响应,从而计算模型辅助探测概率的关键参数,显著降低了探测概率所需的高计算量,相比 Kriging 模型可以节省至少 50%的计算时间开销,相较于纯物理模型节省计算时间达到 80%以上。Cokriging 代理模型高效的性能使其在未来工作中可应用于无损检测逆演问题的研究。

参考文献

[1] 张智超,沈常宇,朱周洪,等. 漏磁结合涡流的非铁磁性金属材料探伤研究[J]. 仪器仪表学报, 2021, 42(4): 150-159.
ZHANG ZH CH, SHENG CH Y, ZHU ZH H, et al. Magnetic flux leakage combined with eddy current for non-ferromagnetic metal materials damage detection[J]. Chinese Journal of Scientific Instrument, 2021, 42(4): 150-159.

[2] 李开宇,高雯娟,王平,等. 冷轧带钢屈服强度的脉冲涡流检测方法研究[J]. 电子测量技术, 2021, 42(5): 71-75.
LI K Y, GAO W J, WANG P, et al. Research on pulse eddy current testing method for yield strength of cold rolled strip steel [J]. Electronic Measurement Technology, 2021, 42(5): 71-75.

[3] 周兆明,杜铁成,万夫,等. 多频涡流检测连续油管偏焊缝晶粒尺寸的试验研究[J]. 电子测量与仪器学报, 2022, 36(2): 188-195.
ZHOU ZH M, DU T CH, WAN F, et al. Experimental research on grain size of coiled tubing bias welding with multi-frequency eddy current testing [J]. Journal of Electronic Measurement and Instrumentation, 2022,

- 36(2): 188-195.
- [4] 刘正帅, 李勇, 任淑廷, 等. 构件损伤脉冲调制涡流检测探头新构型及性能综合分析[J]. 电子测量与仪器学报, 2023, 35(9): 170-178.
- LIU ZH SH, LI Y, REN SH T, et al. Novel structure and performance analysis of pulse-modulation eddy current probes for testing of damages in structural components [J]. Journal of Electronic Measurement and Instrumentation, 2023, 35(9): 170-178.
- [5] GRATIET L L, IOOSS B, BLATMAN G, et al. Model assisted probability of detection curves: New statistical tools and progressive methodology [J]. Journal of Nondestructive Evaluation, 2017, 36(1): 1-12.
- [6] ROSELL A. Efficient finite element modelling of eddy current probability of detection with transmitter-receiver sensors[J]. NDT & E International, 2015, 75: 48-56.
- [7] BAILLARGEON J, EINBINDER D, BRUZEK R, et al. Feasibility and roadmap for applying model assisted probability of detection to track inspection[C]. ASME/IEEE Joint Rail Conference, 2022.
- [8] CHEBOUT M, AZIZI H, MEKIDECHE M R. A model assisted probability of detection approach for ECNDT of hidden defect in aircraft structures [J]. Progress In Electromagnetics Research Letters, 2021, 95: 1-8.
- [9] DU X, LEIFSSON L, MEEKER W, et al. Efficient model-assisted probability of detection and sensitivity analysis for ultrasonic testing simulations using stochastic metamodeling[J]. Journal of Nondestructive Evaluation, Diagnostics and Prognostics of Engineering Systems, 2019, 2(4): 1-18.
- [10] LEE D, YOON S, PARK J, et al. Demonstration of model-assisted probability of detection framework for ultrasonic inspection of cracks in compressor blades[J]. NDT & E International, 2022, 128: 102618.
- [11] 任孟虎, 李静. 基于天幕靶与声靶的人靶参数检测及性能分析[J]. 国外电子测量技术, 2021(2): 11-15.
- REN M H, LI J. Target parameter detection and performance analysis based on sky screen and acoustic target[J]. Foreign Electronic Measurement Technology, 2021(2): 11-15.
- [12] 程健, 郭一楠, 巩敦卫, 等. 非随机替代个体选择的代理模型评价策略 [J]. 电子学报, 2009, 37 (1): 190-194.
- CHENG J, GUO Y N, GONG D W, et al. Surrogate model-based evaluation strategy with non-random selection of substituted individuals [J]. ACTA Electronica, 2009, 37(1): 190-194.
- [13] DU X, LEIFSSON L. Efficient uncertainty propagation for MAPOD via polynomial chaos-based Kriging [J]. engineering computations, 2020, 37(1): 73-92.
- [14] BAO Y. Modeling of eddy current NDT simulations by Kriging surrogate model[J]. Research in Nondestructive Evaluation, 2023, 34(3): 154-168.
- [15] MUKHERJEE S, HUANG X, UDPA L, et al. A kriging-based magnetic flux leakage method for fast defect detection in massive pipelines [J]. Journal of Nondestructive Evaluation, Diagnostics and Prognostics of Engineering Systems, 2022, 5(1): 011002.
- [16] MIORELLI R, ARTUSI X, et al. Database generation and exploitation for efficient and intensive simulation studies[C]. AIP Conference Proceedings, 2015.
- [17] KNOPP J S, ALDRIN J C, BLODGETT M P, et al. Efficient propagation of uncertainty in simulations via the probabilistic collocation method [J]. Electromagnetic Nondestructive Evaluation (XIV), 2011, 35: 141-148.
- [18] FUHG J N, FAU A, et al. State-of-the-art and comparative review of adaptive sampling methods for Kriging [J]. Archives of Computational Methods in Engineering, 2021, 28: 2689-2747.
- [19] 郭俊龙, 马立元, 李永军, 等. 基于 Kriging 代理模型的结构损伤识别新方法 [J]. 中国机械工程, 2016, 27(9): 1203-1207.
- GUO J L, MA L Y, LI Y J, et al. A new structural damage identification method based on Kriging surrogate model [J]. China Mechanical Engineering, 2016, 27(9): 1203-1207.
- [20] 戴睿, 张岳, 王惠军, 等. 基于 Kriging 模型的双十二相高速永磁发电机优化设计 [J]. 中国电机工程学报. 2022, 42(2): 818-826.
- DAI R, ZHANG Y, WANG H J, et al. Optimal design of dual 12-phase high speed permanent magnet rectified generator based on Kriging model[J]. Proceedings of the CSEE, 2022, 42(2): 818-826.
- [21] HAN Z H, ZIMMERMANN, GORTZ S. Alternative cokriging method for variable-fidelity surrogate modeling [J]. AIAA Journal, 2012, 50(5): 1205-1210.
- [22] DU X, LEIFSSON L. Multifidelity model-assisted probability of detection via CoKriging [J]. NDT & E International, 2019, 108: 102156.
- [23] NAGAWKAR J, LEIFSSON L. Applications of polynomial chaos-based CoKriging to simulation-based analysis and design under uncertainty[C]. International Design Engineering Technical Conferences and Computers and Information in Engineering Conference, 2020.
- [24] RENTALA V K, MYLAVARAPU P, GAUTAM J P. Issues in estimating probability of detection of NDT

techniques-A model assisted approach [J]. Ultrasonics, 2018, 87: 59-70.

作者简介



包扬(通信作者), 分别于 2011 年和 2014 年在南京邮电大学通信工程专业和电磁场与微波技术专业获得工学学士和工学硕士学位, 2019 年于美国爱荷华州立大学获得哲学博士学位, 现为南京邮电大学讲师, 研究方向为涡流无损检测建模

和仿真。

E-mail: brianbao@njupt.edu.cn

Bao Yang (Corresponding author) received his B. S. and M. S. degrees in Telecommunication Engineering and Electromagnetic Fields and Microwave Technology from Nanjing University of Posts and Telecommunications in 2011 and 2014,

respectively, and the Ph. D. degree in Electrical Engineering from Iowa State University in 2019. Now he is a Lecturer in Nanjing University of Posts and Telecommunications. His main research interests include modeling and simulations of eddy current nondestructive evaluation.



仇家豪, 2021 年于盐城工学院获得工学学士学位, 2024 年于南京邮电大学获得工学硕士学位, 研究方向为计算电磁学和机器学习。

E-mail: 13382066238@163.com

Qiu Jiahao received his B. Sc. degree from Yancheng Institute of Technology in 2021, and M. Sc. degree from Nanjing University of Posts and Telecommunications in 2024. His main research interests include computational electromagnetics and machine learning.