

# 基于自适应空间映射多可信度模型的 网状天线形态机电集成优化设计

谭育正, 寇丹阳, 张树新\*

(西安电子科技大学高性能电子装备机电集成制造全国重点实验室, 陕西西安 710071)

**摘要:** 为了降低网状天线形态机电集成优化设计时的高昂分析成本, 提出了一种基于自适应空间映射的多可信度建模方法. 根据分析模型中天线桁架与索网组合结构的连接关系, 将网状天线分析模型划分为高、低可信度模型. 通过空间映射矩阵, 首先将高可信度样本映射至低可信度样本空间中, 提升高低可信度分析之间的相关性; 其次根据映射后的高可信度样本与低可信度样本建立多可信度模型; 最后将其应用于网状天线中. 相比于传统的多可信度模型, 在具有空间偏差的测试函数上, 基于空间映射的多可信度模型平均成功率提高了47.3%. 在网状天线形态机电集成优化设计应用案例中, 与传统粒子群优化 (Particle Swarm Optimization, PSO) 相比, 在保持相同计算成本的情况下, 所提方法优化结果的天线增益平均提升0.515 dB, 与利用原始多可信度模型优化相比, 优化效果平均提升0.321 dB. 通过数值实验和网状天线的形态机电集成优化设计应用测试, 验证了该方法的有效性.

**关键词:** 网状天线; 多可信度模型; 空间映射; 形态优化; 神经网络

**基金项目:** 国家自然科学基金 (No.52322507)

**中图分类号:** TN823+.27

**文献标识码:** A

**文章编号:** 0372-2112(2025)01-0051-12

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.12263/DZXB.20240506

## Integrated Structural Electromagnetic Optimization Design of Mesh Antennas Based on Adaptive Space Mapping Multi-Fidelity Model

TAN Yu-zheng, KOU Dan-yang, ZHANG Shu-xin\*

(State Key Laboratory of Integrated Electromechanical Manufacturing of High-performance Electronic Equipments,  
Xidian University, Xi'an, Shaanxi 710071, China)

**Abstract:** To reduce the high analysis costs associated with the integrated structural electromagnetic optimization design of mesh antennas, a multi-fidelity method based on adaptive space mapping has been proposed. Based on the connection relationships between the cable and trusses, the analysis models of mesh antennas are classified into high-fidelity and low-fidelity. By using a space mapping matrix, high-fidelity samples are mapping to the space of low-fidelity, thereby enhancing the correlation between high and low fidelity analyses. Subsequently, a multi-fidelity model is established using the low-fidelity samples and mapped high-fidelity. Finally, apply it to mesh antennas. Compared to traditional multi-fidelity models, the multi-fidelity model based on space mapping achieved an average success rate increase of 47.3% on test functions with space biases. In the application case of form design for mesh antennas, compare to the traditional partial swarm optimization (PSO), the optimization results have been improved by an average of 0.515 dB while maintaining the same cost. Furthermore, compared to optimizations using the traditional multi-fidelity model, the optimization result improved by an average of 0.321 dB. The effectiveness of this method has been validated through numerical experiments and practical application of integrated structural electromagnetic optimization design of mesh antennas.

**Key words:** mesh antenna; multi-fidelity modeling; space mapping; form design; neural network

**Foundation Item(s):** National Natural Science Foundation of China (No.52322507)

## 1 引言

随着空间探索、天文观测等领域的不断发展,轻质量、大口径、高收纳比以及高精度的网状反射面天线在卫星领域的应用日益广泛<sup>[1]</sup>。典型的网状天线主要由索网结构、支撑桁架、反射丝网组成<sup>[2]</sup>。为了保证反射面具有高精度和优良的电磁性能,对索网结构进行形态设计优化是实现良好电磁性能的关键<sup>[3]</sup>。索网的形态优化最初是基于固定桁架进行的<sup>[4]</sup>。随后,研究人员考虑到支撑桁架的柔性变形和非线性特性建立了桁架-索网组合结构非线性有限元模型<sup>[5]</sup>,并引入了考虑桁架变形的形态设计方法<sup>[6]</sup>。为了更加贴合工程实际,文献<sup>[7]</sup>进一步考虑了桁架与索网之间的弹性变形、热变形及其耦合效应,进行了组合结构形态设计。为了保证形态设计后网状天线较优的电性能,将天线电性能引入到形态设计中<sup>[8]</sup>。然而,这些结果表明分析越精准,迭代时间越长,其计算成本就越高<sup>[9-11]</sup>,难以适应快速产品研发的需求。

在科学领域中,机器学习作为一种快速分析的解决方法被广泛研究与应用<sup>[12]</sup>,为解决电磁学中的复杂问题提供了前所未有的精度性能和效率<sup>[13]</sup>。然而,使用机器学习需要大量的训练样本<sup>[14]</sup>,这是在特定领域内应用机器学习时面临的一个显著的限制因素。因此,多可信度模型技术和多源数据融合技术被视为降低计算成本的有效途径<sup>[15]</sup>。

多可信度模型<sup>[16-18]</sup>和迁移学习<sup>[19]</sup>已被广泛应用于气动力学<sup>[20-22]</sup>、电磁设计<sup>[23]</sup>、材料识别<sup>[24]</sup>等领域。多可信度模型的发展主要集中在基于高斯过程的多可信度模型和基于神经网络的多可信度模型<sup>[25]</sup>两方面。例如,文献<sup>[26,27]</sup>将线性多可信度关系推广至非线性。文献<sup>[28]</sup>将多可信度关系解释为线性变换与非线性变换的和。此外,空间映射作为一种多可信度模型策略,早期通过矫正低可信度模型被应用在电磁学中<sup>[29,30]</sup>。文献<sup>[31]</sup>使用了基于特征的映射,将低可信度模型进行矫正。而迁移学习一般通过域自适应<sup>[32,33]</sup>或域对齐<sup>[34]</sup>等算法进行矫正,用以提高不同域之间的相关性。迁移学习的目的是能使用以往的知识或类似的数据来帮助构建当前的模型<sup>[35]</sup>。在多可信度技术领域中,一般使用的是基于微调的迁移学习<sup>[36]</sup>。文献<sup>[37]</sup>将源域样本与目标域样本投影到公共子空间中,使用公共子空间样本和对应的目标值构建模型。

结合机器学习算法的天线设计同样也取得了相当可观的研究进展,开发了相关多可信度模型技术和迁移学习技术。在天线设计中,文献<sup>[38]</sup>结合了有限元模型和实际天线样机,使用机器学习算法将节点位置作为输入,索网调节量作为输出建立代理模型,提高了调整效率和精度。文献<sup>[39]</sup>通过本征函数对高可信度分

析进行降阶处理,建立了多可信度分析模型,并在环形阵列天线应用中进行了验证。然而,多可信度方法的实现与所采用的高、低可信度分析模型有关<sup>[40]</sup>。文献<sup>[41]</sup>根据粗、细网格划分情况建立了多可信度分析模型,通过Co-Kriging模型对多可信度进行建模,在微带贴片天线应用中进行了验证。尽管如此,对网状天线进行接近真实分析的优化过程仍然是成本巨大的一项挑战。

在实际应用中,多可信度模型技术能否有效降低计算成本取决于高、低可信度模型的成本比、相关性、样本数量以及多可信度模型的精准程度<sup>[15]</sup>。在多可信度模型中,通常假设高、低可信度模型之间是高度相关的<sup>[25]</sup>。然而,在不同领域中应用多可信度模型技术时,高、低可信度模型通常是由设计人员通过不同方式的简化得到的<sup>[41]</sup>,这些模型之间的相关性是未知的。文献<sup>[42]</sup>指出多可信度分析之间的差异不仅仅来自幅值,还有相位误差;而相位误差会使得高、低可信度分析之间的相关性减弱,会降低多可信度模型的建模精度,甚至使其失效。文献<sup>[43]</sup>通过对低可信度模型进行傅里叶展开,将得到的基函数固定,通过高可信度样本调整其幅值项对低可信度模型进行修正,虽然有效减少了偏差,但对高可信度样本数量的要求较高。文献<sup>[44]</sup>通过将高可信度样本与低可信度样本以矩阵的形式存储,通过卷积神经网络识别多可信度模型之间的关系,建立了多可信度模型,然而并没有考虑局部范围内的相关性。文献<sup>[45]</sup>将空间映射的方法应用到机翼空气动力学模型中,但由于其存在空间映射优化中的超参数,导致映射矩阵需要通过交叉验证的形式得到。

针对上述问题,本文提出了基于自适应空间映射的多可信度模型(Space Mapping-based Multi-Fidelity model, SM-MF),以解决低可信度模型与高可信度模型之间存在的相位偏差。其主要思想是通过引入相关性作为自适应因子,实现自适应空间映射技术,以减少域偏差或相位偏差,并使用投影后的新样本建立多可信度模型。根据网状天线分析模型中天线桁架与索网组合结构的连接关系,将网状天线分析模型划分为高、低可信度模型,将其应用于网状天线形态机电集成优化设计。

本文的贡献包含以下3个方面:

(1)针对高可信度模型与低可信度模型之间存在的相位偏差,提出了一种基于空间映射的多可信度模型(SM-MF)。

(2)针对网状天线,根据网状天线分析模型中天线桁架与索网组合结构的连接关系以及贴合实际工程情况的程度,建立网状天线高、低可信度分析模型。

(3)本文通过实验,将该模型应用于7个测试算例中,并且对网状天线建立了多可信度模型,依托此模型

开展了网状天线形态机电集成优化设计,仿真结果验证了所提模型的有效性.

## 2 基于自适应空间映射的多可信用度模型

值得强调的是,空间映射算法与多可信用度建模之间是相互独立的,即可以与任何类型的多可信用度模型相结合.首先介绍空间映射算法的具体实现,然后将空间映射算法与多可信用度模型结合.

对于设计变量维数为  $d$  的问题,设高、低可信用度的数据样本点集为  $D_L = \{\mathbf{x}_L, \mathbf{y}_L\}$  和  $D_H = \{\mathbf{x}_H, \mathbf{y}_H\}$ ,  $\mathbf{x}_H$  与  $\mathbf{x}_L$  分别表示为

$$\begin{cases} \mathbf{x}_H = [\mathbf{x}_H^{(1)}, \mathbf{x}_H^{(2)}, \dots, \mathbf{x}_H^{(n_H)}]^T \\ \mathbf{x}_L = [\mathbf{x}_L^{(1)}, \mathbf{x}_L^{(2)}, \dots, \mathbf{x}_L^{(n_L)}]^T \end{cases} \quad (1)$$

其中,下标“H”和“L”分别代表来自高、低可信用度模型,  $n_H$  和  $n_L$  分别代表高、低可信用度模型样本点的个数,一般在多可信用度应用中假定  $n_H \ll n_L$ . 通过对应的高低可信用度分析模型,计算得到相应的样本相应值:

$$\begin{cases} \mathbf{y}_H = [\mathbf{y}_H^{(1)}, \mathbf{y}_H^{(2)}, \dots, \mathbf{y}_H^{(n_H)}]^T \\ \mathbf{y}_L = [\mathbf{y}_L^{(1)}, \mathbf{y}_L^{(2)}, \dots, \mathbf{y}_L^{(n_L)}]^T \end{cases} \quad (2)$$

使用空间映射,将高可信用度样本投影到低可信用度样本空间中,投影表述为

$$\mathbf{x}_{\text{HSM}} = \mathbf{M}\mathbf{x}_H + \mathbf{B} \quad (3)$$

其中,  $\mathbf{x}_{\text{HSM}}$  是通过空间映射的高可信用度结果,  $\mathbf{M}$  是映射矩阵,  $\mathbf{B}$  是偏移向量. 将投影后的高可信用度样本组合成变换后的高可信用度样本集  $D_{\text{HSM}} = \{\mathbf{x}_{\text{HSM}}, \mathbf{y}_H\}$ . 通过求解式(4)中的优化问题计算出  $\mathbf{M}$  和  $\mathbf{B}$ :

$$\begin{aligned} & \text{find } \mathbf{M}, \mathbf{B} \\ & \text{min Cost} \\ & \text{s.t. } \mathbf{M}_{\text{BL}} \leq \mathbf{M} \leq \mathbf{M}_{\text{BH}} \\ & \quad \mathbf{B}_{\text{BL}} \leq \mathbf{B} \leq \mathbf{B}_{\text{BH}} \end{aligned} \quad (4)$$

其中,  $\mathbf{M}_{\text{BH}}$  和  $\mathbf{M}_{\text{BL}}$  分别是映射矩阵的上下界,  $\mathbf{B}_{\text{BH}}$  和  $\mathbf{B}_{\text{BL}}$  分别是偏移向量的上下界. 根据文献[45], Cost 可以表述为

$$\begin{aligned} \text{Cost} = & \sum_{i=1}^{n_H} (\mathbf{y}_H(\mathbf{x}) - \mathbf{y}_{L, \text{HSM}}(\mathbf{M}\mathbf{x} + \mathbf{B}))^2 \\ & + \lambda (\|\mathbf{M} - \mathbf{M}_0\|_2 + \|\mathbf{B} - \mathbf{B}_0\|_1) \end{aligned} \quad (5)$$

其中,  $\mathbf{M}_0$  和  $\mathbf{B}_0$  是正则化矩阵和正则化向量的名义值.

在此引入了高低可信用度模型之间的物理先验,即高低可信用度分析模型之间的偏差不会太大. 并且,对偏差  $\mathbf{B}$  使用  $L_1$  范数,对旋转矩阵使用  $L_2$  范数,会导致数值不平衡,在高低可信用度模型相关性较高时,会倾向旋转而不是平移. 此外,第一项中  $n_H$  会因为高可信用度样本

数量增加导致损失不平衡. 为此,将 Cost 的具体表述改写为

$$\text{Cost} = \frac{\sum_{i=1}^{n_H} (\mathbf{y}_H - \mathbf{y}_{L, \text{HSM}})^2}{n_H} + \lambda \|\mathbf{M} - \mathbf{I}\|_2 + \beta \mathbf{B}^T \mathbf{B} \quad (6)$$

其中,  $\mathbf{y}_{L, \text{HSM}}$  代表在样本点为  $\mathbf{x}_{\text{HSM}}$  上对应的最近的  $\mathbf{x}_L$  的低可信用度分析结果,采用最近的点是因为即使在初始采样中,  $\mathbf{x}_{\text{HSM}}$  与  $\mathbf{x}_L$  为嵌套采样即  $\mathbf{x}_{\text{HSM}} \subset \mathbf{x}_L$ , 在通过空间映射后  $\mathbf{x}_{\text{HSM}}$  也不一定属于  $\mathbf{x}_L$  的子集,低可信用度可以避免在空间映射阶段产生大量的预测需求. 后两项是根据高、低可信用度之间的相关性构建的正则化项,  $\|\mathbf{M} - \mathbf{I}\|_2$  为  $\mathbf{M}$  减单位矩阵  $\mathbf{I}$  的 Forbenius 范数,  $\lambda$  与  $\beta$  分别是控制映射矩阵和偏移向量正则化的系数,在实际应用中并没有很多高可信用度样本可供交叉验证,  $\lambda$  与  $\beta$  实际上代表了高低可信用度模型之间的差异. 在此方法中,选用高低可信用度模型数据之间的相关系数  $\rho$  作为一种自适应的超参数设置,具体表示如下:

$$\begin{aligned} \beta &= \text{RELU}(\rho) \\ \lambda &= |\rho| \end{aligned} \quad (7)$$

其中,相关系数  $\rho$  的计算表示如下:

$$\rho = \frac{\sum (\mathbf{y}_H^i - \bar{\mathbf{y}}_H)(\mathbf{y}_L^i - \bar{\mathbf{y}}_L)}{\sqrt{\sum (\mathbf{y}_H^i - \bar{\mathbf{y}}_H)^2 \sum (\mathbf{y}_L^i - \bar{\mathbf{y}}_L)^2}} \quad (8)$$

其中,  $\bar{\mathbf{y}}_H$  与  $\bar{\mathbf{y}}_L$  分别是高、低可信用度样本均值.

通过将高可信用度样本  $\mathbf{x}_H$  映射至接近低可信用度样本  $\mathbf{x}_L$  的空间,其本质上就实现了增加高、低可信用度函数之间的相关性.

上面描述的空间映射方法(SM)可以集成到现有的多可信用度模型中,通过将空间映射与基于高斯过程的多可信用度模型和基于神经网络的多可信用度模型相结合,开发了基于空间映射的高斯过程多可信用度模型(SM-MF-GP)和基于空间映射的神经网络多可信用度模型(SM-MF-NN). SM-MF-GP的具体表述为

$$Y_H(\mathbf{x}) = \rho Y_L(\mathbf{M}\mathbf{x} + \mathbf{B}) + \delta(\mathbf{x}) \quad (9)$$

或是使用神经网络模型,本研究中使用的是基于迁移学习的多可信用度神经网络模型. 神经网络可表示为

$$Y(\mathbf{x}, \mathbf{W}) = (\psi_{l_i} \circ \mathbf{W}_{l_i}) \circ \dots \circ (\psi_{l_0} \circ \mathbf{W}_{l_0}) \circ \mathbf{x} \quad (10)$$

其中,  $\mathbf{x}$  作为输入,  $Y(\mathbf{x}, \mathbf{W})$  作为输出,  $\psi_{l_i}$  和  $\mathbf{W}_{l_i}$  代表第  $l_i$  层的激活函数和权重偏差矩阵,共有  $l_i$  层,权重偏差矩阵包括权重矩阵和偏差向量,所有的可训练参数用  $\mathbf{W}$  表示;  $\circ$  代表操作符组合;  $\mathbf{W}$  的学习是通过最小化损失函数来实现的. 在这项工作中,使用了均方损失函数. 通常这种微调的多可信用度模型首先使用低可信用度数据集对参数进行训练,然后对底层的参数采用较小的学习

率,靠近输出层的参数采用较大的学习率.训练低可信度神经网络的损失函数可表示为

$$\mathcal{L}_L = \frac{1}{n_L} \sum_{i=1}^{n_L} (y_L^i - Y_L(\mathbf{x}_L^i, W))^2 \quad (11)$$

通过最小化式(11)得到  $W_L$ . 将  $W_L$  作为模型初始值,使用经过空间映射的高可信度数据集进行训练,训练高可信度神经网络的损失函数可表示为

$$\mathcal{L}_H = \frac{1}{n_H} \sum_{i=1}^{n_H} (y_H^i - Y_H(\mathbf{x}_{HSM}^i, W))^2 \quad (12)$$

根据上文描述,可将基于空间映射的多可信度模型 SM-MF 总结如下.

#### 算法 1 SM-MF 算法

输入:低可信度数据集  $D_L$ ,高可信度数据集  $D_H$ ,正则化因子,所选用的多可信度模型(GP/NN)

输出:多可信度模型

1. 初始化  $M$  和  $B$
2. 通过求解式(6)的优化问题,计算得出最优  $M$  以及  $B$
3. 利用最优的  $M$  和  $B$ ,根据式(3)求得变换后的高可信度样本集
4. IF 选用基于 GP 的多可信度模型, THEN
5. 通过式(9)构建多可信度模型
6. END IF
7. IF 选用基于 NN 的多可信度模型, THEN
8. 通过式(10)和式(11)构建多可信度模型
9. END IF

### 3 网状天线的多可信度模型建立

桁架结构、索网结构和反射丝网共同组成网状天线结构,如图 1 所示.为了提高分析速度,一般假设桁架为固定不变的.然而,对于大型实际天线结构而言,这种方法的分析精度较低.为了更贴近实际的变形情况,需要考虑桁架的变形和桁架的随机装配误差<sup>[38]</sup>.近年来,人们对于可展开网状天线结构的预应力设计和找形方法已经进行了大量的研究<sup>[9]</sup>,随着研究越发贴近实际工程应用,分析真实情况时必须考虑众多复杂因素,这不可避免地增加了分析成本,加长了研制周期.

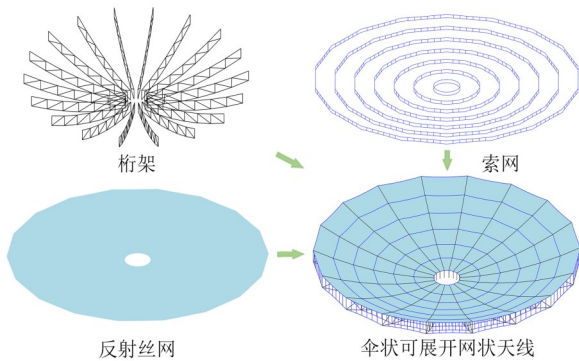


图 1 伞型网状天线结构示意图

为了验证 SM-MF 方法,考虑到接近实际物理系统以及索网与桁架的连接关系,将桁架-索网组合结构看作是高可信度模型,在此分析模型中考虑桁架-索网的耦合变形.将纯索网结构看作是低可信度模型,即桁架为绝对刚体,索网结构满足自平衡.基于此,分别为周边桁架式网状天线和伞型网状天线建立高、低可信度分析模型,如图 2 所示.

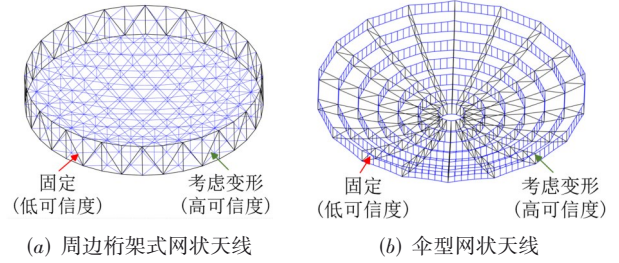


图 2 周边桁架式网状天线与伞型网状天线的高可信度分析与低可信度分析划分示意图

### 4 实验结果与分析

为了验证所提出的 SM-MF 算法的有效性,本研究采用 7 个多可信度测试函数和 2 个网状天线应用案例进行了测试.在数值实验中,通过 7 个测试函数对所提出方法进行全测试,并将 SM-MF 与单可信度方法(单可信度高斯过程模型 S-GP、单可信度神经网络模型 S-NN)、传统多可信度方法(包括基于高斯过程的多可信度模型(MF-GP)、基于神经网络的多可信度模型(MF-NN)以及基于迁移学习的多可信度模型(FT-NN))进行对比分析,以验证算法的有效性.在 4.2 节中,将所提出的 SM-MF 应用于周边桁架式网状天线和伞型网状天线中,验证方法对于网状天线的适用性.

为消除实验设计(Design Of Experiments, DOE)的影响,使用了均方误差(Mean Square Error, MSE)、决定系数(R-squared,  $R^2$ )以及成功率(Success Rate, SR)作为评价指标,以评估所提出方法的性能. MSE 和  $R^2$  的公式如下:

$$\text{MSE} = \frac{\sum (y_i - \hat{y}_i)^2}{n} \quad (13)$$

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (14)$$

$$\text{SR} = \frac{\sum_{i=1}^{N_{\text{run}}} T_i}{N_{\text{run}}} \quad (15)$$

其中,  $T_i$  代表在第  $i$  次 DOE 中是否成功拟合,  $N_{\text{run}}$  代表 DOE 的总次数.  $T_i$  具体表述为

$$T_i = \begin{cases} 0, & R^2 < t \\ 1, & R^2 \geq t \end{cases} \quad (16)$$

其中,  $t$  作为成功阈值, 其根据函数的非线性程度而定.

### 4.1 多可信度函数测试

在本节中, 表 1 列出了具有不同非线性程度和不同维度的 7 个数学算例, 这些示例用于验证所提出方法的有效性. 为了探索采用多可信度方法在构建高可信度代理模型上的实用性, 首先使用表 1 中的一个简单的偏移多可信度测试函数(测试函数 2)来构建多可信度模型. 图 3 展示了随着偏移量(Shift)变化, 多可信度模型成功率的变化情况, 其中定义成功的阈值  $t$  为 0.9, 高可信度样本数量为 3, 在相同偏差下使用拉丁超立方实验设计(Latin Hypercube Sampling, LHS), 并且重复实验次数  $N_{\text{run}}$  采用 300 次.

结果显示, 在高可信度样本数量相同的情况下, 即便低可信度与高可信度样本之间只存在简单的空间偏移, 这种偏移依然会对构建多可信度模型的成功率产生影响, 并且观察到成功率随着偏移量的增大而降低.




图 3 成功率(SR)随偏移量(Shift)变化曲线图

为了克服这种相位偏差的挑战, 采用了 SM-MF 算法. 图 4 对比展示了表 1 中测试函数 1 在应用 SM-MF 模型、传统多可信度模型以及仅依赖高可信度样本的代理模型后的对比曲线.

表 1 多可信度测试函数

序号	可信度	函数表达式	范围
1	低可信度	$Y_L(x) = \sin^2(2\pi x) + x^2 + \sin(7\pi x)$	$x \in [0, 1]$
	高可信度	$Y_H(x) = 1.2 \sin^2(2\pi(1.1x + 0.02)) + 1.05x(1.1x + 0.02) + 1.495 \sin(7\pi(1.1x + 0.02))$	
2	低可信度	$Y_L(x) = \sin(8\pi x)$	$x \in [0, 1]$
	高可信度	$Y_H(x) = \sin(8\pi x + \text{shift}) \quad \text{shift} = \pi/10$	
3	低可信度	$Y_L(x) = \sin(8\pi x)$	$x \in [0, 1]$
	高可信度	$Y_H(x) = (x - \sqrt{2})(\sin(8\pi x))^2$	
4	低可信度	$Y_L(x) = 0.5(6x - 2)^2 \sin(12x - 4) + 10(x - 0.5) - 5$	$x \in [0, 1]$
	高可信度	$Y_H(x) = (6x - 2)^2 \sin(12x - 4)$	
5	低可信度	$Y_L(x) = \begin{cases} 0.5(6x - 2)^2 \sin(12x - 4) + 10(x - 0.5) - 5 \\ 0.5(6x - 2)^2 \sin(12x - 4) + 10(x - 0.5) - 2 \end{cases}$	$x \in [0, 0.5]$
	高可信度	$Y_H(x) = \begin{cases} 2(0.5(6x - 2)^2 \sin(12x - 4) + 10(x - 0.5) - 5) - 20x + 20 \\ 2(0.5(6x - 2)^2 \sin(12x - 4) + 10(x - 0.5) - 5) - 20x + 24 \end{cases}$	
6	低可信度	$Y_L(x) = \cos(15x)$	$x \in [0, 1]$
	高可信度	$Y_H(x) = x \exp(y_L(1.3x - 0.2)) - 1$	
7	低可信度	$Y_L(x) = 0.8y_h(x) - \sum_{i=1}^{19} 0.4x_i x_{i+1} - 50$	$x \in [-3, 3]$
	高可信度	$Y_H(x) = (x_1 - 1)^2 + \sum_{i=2}^{20} (2x_i^2 - x_{i-1})^2$	

在结果分析中可见, 在使用 6 个高可信度样本进行预测时, 由于低可信度函数与高可信度函数之间存在相位偏差, 导致了多可信度模型预测在  $[0.5, 1]$  区间内相较于真实函数产生较大偏移. 然而, SM-MF 通过识别这种偏移差异, 能够建立较为准确的多可信度模型. 在图 5 中展示了图 4 中 3 种预测模型的傅里叶变换对比曲线, 考虑到低阶频率成分的影响较为显著, 展示的结果

仅包括前 7 阶频率成分.

3 种预测结果的傅里叶变换分析显示, 通过 SM-MF 方法得到的结果在低阶频率与高可信度函数的吻合度更高. 在前 5 阶的相位图中, SM-MF 的结果与高可信度傅里叶变换结果几乎完全重叠. 这一分析揭示了通过 SM-MF 减少相位误差, 有助于帮助建立更高精度的多可信度模型.


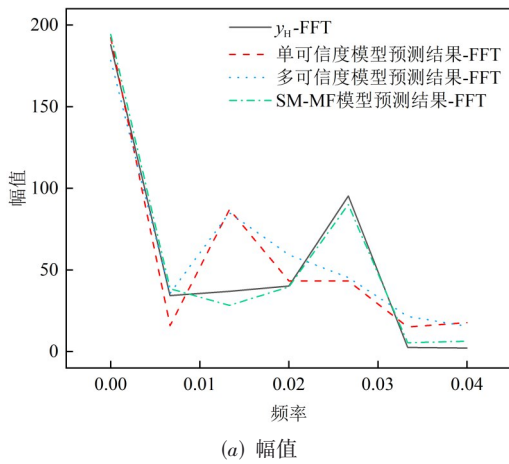



图4 单可置信度模型、多可置信度模型与SM-MF模型预测结果和高可置信度函数对比曲线



(a) 幅值



(b) 相位

图5 单可置信度模型、多可置信度模型与SM-MF模型的傅里叶变换对比曲线

为了评估模型在不同场景下基于高可置信度样本信息的性能,本研究针对表1中的测试函数1,进行了29组不同规模的高可置信度样本数量的实验.在这一过程中,使用的多可置信度模型为基于高斯过程的多可置信度模型.对每一种DOE的尺寸,采用LHS采样方法重复300次,旨

在评估输入空间中高可置信度样本点分布的稳定性.在所有实验组中,低可置信度样本点的数量保持50个.图6和图7展示了随着高可置信度样本点数量变化,RMS和 $R^2$ 的箱线图以及均值变化曲线.

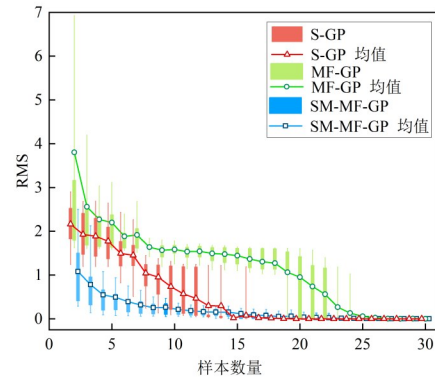


图6 S-GP、MF-GP方法以及SM-MF-GP在不同样本数量下经过300次随机DOE实验后的RMS箱线图及其均值变化曲线




图7 S-GP、MF-GP方法以及SM-MF-GP在不同样本数量下经过300次随机DOE实验后的 $R^2$ 箱线图及其均值变化曲线

从结果分析可见,仅用高可置信度样本的代理模型,在样本数量大约为15个时达到预期精度.然而,由于高可置信度函数与低可置信度函数之间存在相位偏差,导致了多可置信度高斯过程(MF-GP)模型需要大约25个高可置信度样本才能达到预期精度.结果说明,在存在相位偏差的情况下,使用多可置信度模型技术并不能提升模型的预测精度.通过使用SM-MF-GP模型,在高可置信度样本量在5~15之间时,可以显著提升多可置信度模型的预测精度,并且在高可置信度样本量大于15时,与仅用高可置信度样本的模型预测精度相当.尽管在高可置信度样本量小于5时,SM-MF-GP相较于其他两种方法可以提升预测精度,但其精度极度依赖于高可置信度样本点的分布情况.

为了展示SM-MF在更广泛的多可置信度模型应用中的适用性,将SM-MF与神经网络中的多可置信度方法结合(SM-MF-NN),并与原始多可置信度方法进行比较.图8呈现了单可置信度高斯过程模型(S-GP)、多可置信度高斯过程模型(MF-GP)、标准多可置信度神经网络模

型(MF-NN)、基于迁移学习的多可信度模型(FT-NN)、基于空间映射的多可信度高斯过程模型(SM-MF-GP)和基于空间映射的多可信度神经网络模型(SM-MF-NN)在成功率上的比较结果。

结果表明,相比于传统的多可信度模型和仅依赖高可信度数据的方法,采用SM-MF方法能够显著降低对高可信度样本的需求量.无论是采用高斯过程模型还是神经网络作为基础的多可信度模型,使用SM-MF方法后,成功率表现都相当.在未采用SM-MF方法的情况下,基于神经网络的多可信度模型展现出最优的性能.然而,当高可信度样本数量有限时,基于迁移学习的方法与仅使用高可信度样本的代理模型在样本使用量上相近,而基于高斯过程的多可信度模型由于空间偏差的影响,需要更多的高可信度样本才能达到预期的精度.为了展示SM-MF方法在各种测试场景中的

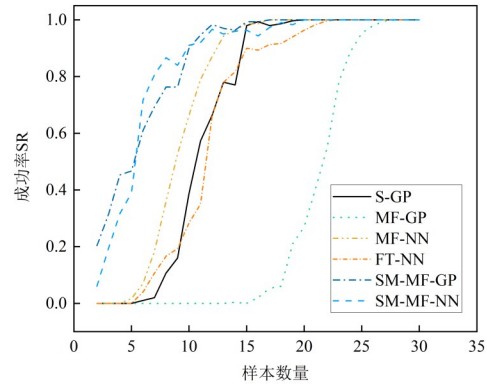


图8 S-GP、MF-GP、MF-NN、FT-NN、SM-MF-GP、SM-MF-NN 随高可信度样本数量变化的成功率比较

有效性,表2列出了表1中所有测试函数在存有少量高可信度样本时,采用不同方法达到的成功率。

表2 S-GP、S-NN、MF-GP、FT-NN、MF-NN、SM-MF-GP以及SM-MF-NN在表1中7个测试函数的成功率

序号	阈值 $t$	$N_H$	$N_L$	指标	S-GP	S-NN	MF-GP	FT-NN	MF-NN	SM-MF-GP	SM-MF-NN
1	0.7	2	50	SR	0.01	0	0	0.04	0.07	0.61	<b>0.72</b>
2	0.9	6	50	SR	0	0	0.15	0.33	0	<b>0.84</b>	0.36
3	0.7	15	50	SR	0	0	<b>0.48</b>	0	0.18	0.47	0.18
4	0.7	6	50	SR	0.24	0	0.49	0	0	<b>0.50</b>	0
5	0.7	6	50	SR	0.06	0.11	<b>0.40</b>	0	0	<b>0.40</b>	0
6	0.7	8	50	SR	0.29	0.06	0	0.08	0.38	0.30	<b>0.64</b>
7	0.7	500	1500	SR	0	0	<b>0.90</b>	0	0	<b>0.90</b>	0.23

在表2中,由于测试函数1、2和6存在较明显的相位偏差,在这3个测试函数上的成功率相较于传统多可信度方法提升了47.3%,证明了通过使用SM-MF方法能够显著提高在具有相位偏差的多可信度函数上构建多可信度模型的成功率.而对于测试函数3、4和5,由于其高可信度与低可信度之间无明显偏移,使用SM-MF-GP与MF-GP所得结果接近.由于测试函数的非线性,导致使用神经网络的多可信度建模的成功率低于使用高斯过程模型的多可信度建模.测试函数7是一个20维的非线性函数,通过使用多可信度高斯过程,能够有效提升其建模的成功率.在这7个算例中,基于神经网络的多可信度建模通常需要更多的高可信度样本.然而在高可信度样本量足够大时,基于神经网络的多可信度模型能够提供比基于高斯过程的多可信度模型更高的成功率和更优的精度。

在图9中,为了探究使用相关系数作为空间映射的损失函数的超参数是否合理,对测试函数1进行了不同超参数的实验,每个实验重复运行300次.可以看到, $\lambda$ 的选取是较为敏感的,其中白色的“.”是高低可信度模型之间真实的相关性系数,而白色的“x”是在一次实验中根据少量高可信度样本点映射后得到的相关性系




图9 超参数敏感性分析图

数.结合表2,验证了利用相关性系数来决定超参数 $\lambda$ 和 $\beta$ 的合理性。

#### 4.2 网状天线多可信度模型测试

所采用网状天线的结构参数如表3所示.天线工作在12 GHz,初级方向图选用两参数口径场分布函数:


$$10^{ET/20} + (1 - 10^{ET/20}) \left( 1 - \frac{x^2 + y^2}{(D/2)^2} \right),$$

其中ET为边缘锥削,


$D$ 为投影面口径. 由于反射面天线具有圆周对称几何特征, 采取的设计点为竖索的 15 个变量, 见图 10. 周边桁架式网状天线输出值为主轴方向  $\theta$  在  $-1.3^\circ$ 、 $-1^\circ$ 、 $0^\circ$ 、 $1^\circ$ 、 $1.3^\circ$  下的增益值, 伞型网状天线输出值为主轴方向  $\theta$  在  $-0.45^\circ$ 、 $-0.35^\circ$ 、 $0^\circ$ 、 $0.35^\circ$ 、 $0.45^\circ$  下的增益值, 见图 11. 首先通过使用拉丁超立方设计对低可信度采样 2 000 个点, 高可信度采样 100 个点, 测试集采样 2 000 个点. 为了使得函数的输入值和输出值分布方差较小, 对输入值进行归一化处理, 对除  $\theta$  角度在  $0^\circ$  下的增益值加 20. 所采用的测试集是在高可信度分析中随机采取 2 000 个样本点. 简单起见, 本文统一采用几何光学法对其电性能进行求解.

表 3 天线几何与结构参数

	名称	伞型网状天线	环形桁架式网状天线
反射面	投影面口径	6 m	2 m
	焦距	3 m	1 m
	中心轮廓直径	0.5 m	—
馈源	工作频率	12 GHz	12 GHz
	边缘锥削	-10 dB	-10 dB
桁架	支撑肋截面尺寸	2 mm × 3 mm	2 mm × 3 mm
	肋宽	3 mm	3 mm




(a) 周边桁架式网状天线




(b) 伞型网状天线

图 10 选取网状天线设计点示意图



(a) 周边桁架式网状天线



(b) 伞型网状天线

图 11 网状天线电性能输出值选定示意图

表 4 展示了在测试集上, 周边桁架式网状天线和伞型网状天线在不同可信度模型方法下的 MSE 结果. 这些结果表明, 在只有少量高可信度样本的情况下, 基于空间映射的多可信度模型能够显著提升预测精度. 对于周边桁架式网状天线和伞型网状天线, 仅使用高可信度样本进行建模时, 其最佳精度所对应的 MSE 分别为  $6.66 \times 10^{-2}$  和  $1.72 \times 10^{-1}$ ; 而采用多可信度建模, 其精度最高可达到  $3.10 \times 10^{-3}$  和  $4.25 \times 10^{-2}$ . 当采用基于空间映射的多可信度方法时, 其最佳精度为  $3.48 \times 10^{-5}$  和  $4.23 \times 10^{-3}$ . 相较于原始多可信度模型, 其 MSE 降低了 1~2 个数量级. 这些结果进一步验证了所提出的基于空间映射的多可信度方法的有效性.

为了体现与传统粒子群优化 (Particle Swarm Optimization, PSO) 方法以及基于传统代理模型的对比, 分别用图 12 和图 13 展示在相同成本下的周边桁架式网状天线和伞型网状天线的优化结果. 表 5 为网状天线优化后主轴方向  $\theta=0^\circ$  时的增益值. 可以从图 11 和表 5 中看出, 通过使用 SM-MF 方法, 在相同成本下, 相较于不使用代理模型的优化结果, 周边桁架式网

状天线主轴方向  $\theta=0^\circ$  时,增益从  $-1.395$  dB 提升到  $-0.941$  dB,伞型网状天线主轴方向  $\theta=0^\circ$  时,增益从  $-0.938$  dB 提升到  $-0.363$  dB,优化效果平均提升  $0.515$  dB. 相比原始多可信度或单可信度最优模型,优化效果平均提升  $0.321$  dB. 在优化后的增益曲线中可以看到,

单可信度代理模型由于模型精度低导致了优化结果不可靠,SM-MF 方法能够显著提升其分析精确度,从而使得优化结果与实际分析值接近,优化效果提升,验证了 SM-MF 多可信度方法在网状天线优化中的有效性.

表 4 周边桁架式网状天线以及伞型网状天线多可信度模型在测试集上的 MSE

模型	指标	$N_H$	$N_L$	S-GP	S-NN	MF-GP	FT-NN	MF-NN	SM-MF-GP	SM-MF-NN
周边桁架式网状天线	MSE	100	2000	33.74	$6.66 \times 10^{-2}$	$5.91 \times 10^{-2}$	$3.10 \times 10^{-3}$	$1.87 \times 10^{-2}$	$2.59 \times 10^{-2}$	$3.48 \times 10^{-5}$
伞型网状天线	MSE	100	2000	6.37	$1.72 \times 10^{-1}$	5.25	$4.25 \times 10^{-2}$	$8.92 \times 10^{-2}$	5.57	$4.23 \times 10^{-3}$

表 5 网状天线优化结果

单位: dB

模型	指标	高可信度 PSO 优化结果	基于 S-NN 优化结果	基于 MF-NN 优化结果	基于 SM-MF 优化结果
周边桁架式网状天线	Gain	-1.395	-1.266	-2.148	<b>-0.941</b>
伞型网状天线	Gain	-0.938	-2.128	-0.679	<b>-0.363</b>

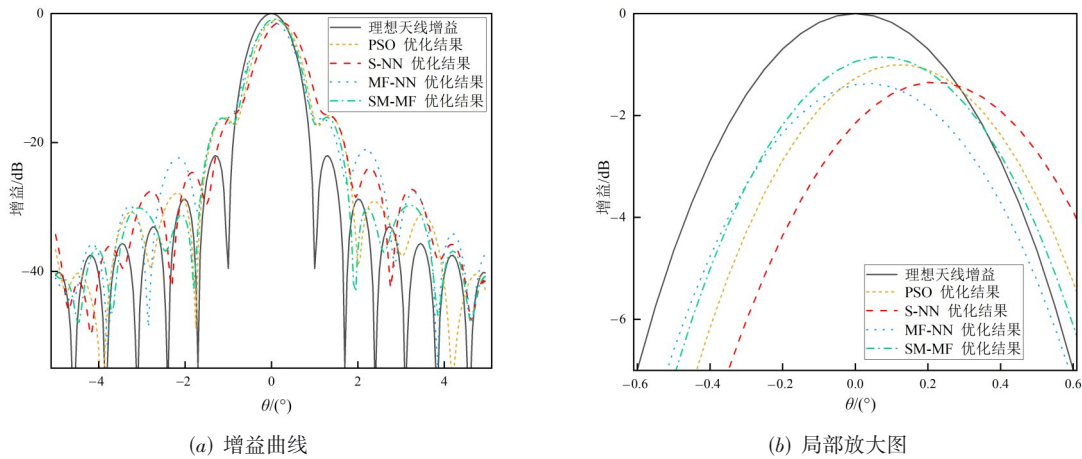


图 12 周边桁架式网状天线应用不同优化方法优化后的结果

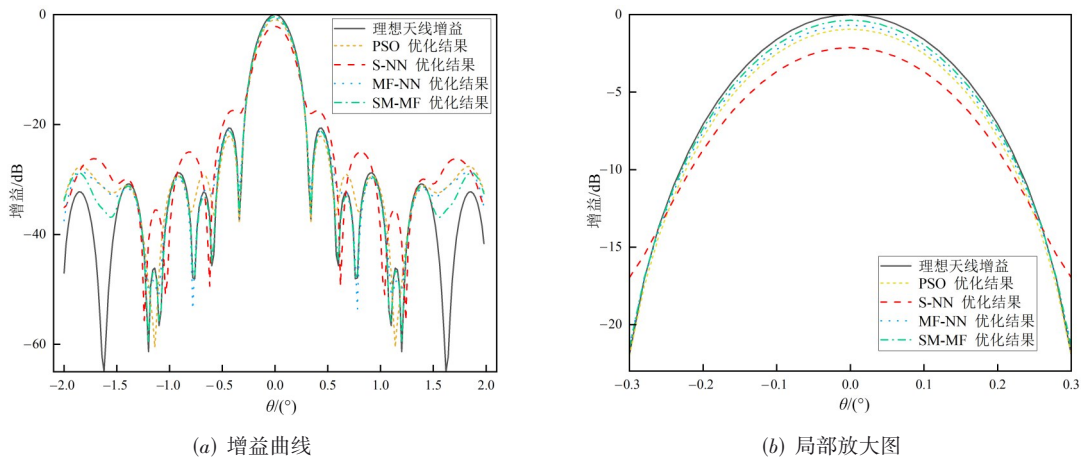


图 13 伞型网状天线应用不同优化方法优化后的结果

### 5 结论

针对网状天线形态机电集成优化设计的高昂分析

与优化成本问题,在高、低可信度模型之间存在空间偏差的情况下,为了提高多可信度代理模型方法的精度

和成功率,本文提出了一种新颖的基于自适应空间映射的多可信度模型方法,并将其应用在典型网状天线形态机电集成优化设计上.该方法能够与现有的各种多可信度建模方法相结合.在经过空间映射校正后的样本上应用不同的多可信度模型方法,能有效提升多可信度精度和成功率.通过对7个具有不同维度、不同非线性程度以及不同程度的空间偏差的数学算例进行测试.结果表明,在存在空间偏差的测试函数中,相较于原始多可信度模型,本方法的建模成功率提升47.3%;在没有空间偏差的测试函数中,建模成功率与原始多可信度模型相当.根据网状天线分析模型中天线桁架-索网组合结构的连接关系以及贴合实际工程情况的程度,将网状天线分析模型划分为高、低可信度分析模型.利用划分的高、低可信度分析模型建立基于自适应空间映射的多可信度模型,所得多可信度模型的均方误差(MSE)与原始多可信度方法相比显著降低了一个数量级,通过使用所得多可信度模型进行优化,结果相较于未使用多可信度模型平均提升0.515 dB,相较于原始多可信度模型平均提升0.321 dB,这进一步验证了基于空间映射的多可信度模型的有效性.

#### 参考文献

- [1] 马小飞, 李洋, 肖勇, 等. 大型空间可展开天线反射器研究现状与展望[J]. 空间电子技术, 2018, 15(2): 16-26.  
MA X F, LI Y, XIAO Y, et al. Development and tendency of large space deployable antenna reflector[J]. Space Electronic Technology, 2018, 15(2): 16-26. (in Chinese)
- [2] DUAN B Y, ZHANG Y Q, DU J L. Large Deployable Satellite Antennas: Design Theory, Methods and Applications[M]. Singapore: Springer, 2020.
- [3] WANG X Y, CAI J G, YANG R G, et al. Form-finding of deployable mesh reflectors using dynamic relaxation method[J]. Acta Astronautica, 2018, 151: 380-388.
- [4] BEL HADJ ALI N, RHODE-BARBARIGOS L, SMITH I F C. Analysis of clustered tensegrity structures using a modified dynamic relaxation algorithm[J]. International Journal of Solids and Structures, 2011, 48(5): 637-647.
- [5] LIU R W, GUO H W, LIU R Q, et al. Design and form finding of cable net for a large cable-rib tension antenna with flexible deployable structures[J]. Engineering Structures, 2019, 199: 109662.
- [6] YUAN S C, YANG B G, FANG H F. Form-finding of large deployable mesh reflectors with elastic deformations of supporting structures[C]//2018 AIAA Spacecraft Structures Conference. Reston: AIAA, 2018: 248-262.
- [7] NIE R, HE B Y, YAN S Z, et al. Optimization design method for mesh reflector antennas considering the truss deformation and thermal effects[J]. Engineering Structures, 2020, 208: 110253.
- [8] ZHANG S X, DU J L, DUAN B Y, et al. Integrated structural-electromagnetic shape control of cable mesh reflector antennas[J]. AIAA Journal, 2015, 53(5): 1395-1399.
- [9] ZHANG S X, CAO Z, ZHANG S J. Form-finding design optimization method of cable mesh reflectors based on a weighting surface accuracy with electromagnetic performance[J]. Structural and Multidisciplinary Optimization, 2023, 66(3): 65.
- [10] LIU J S, HOLLAWAY L. Integrated structure-electromagnetic optimization of large reflector antenna systems[J]. Structural Optimization, 1998, 16(1): 29-36.
- [11] ZHANG S X, DUAN B Y. Integrated structural-electromagnetic optimization of cable mesh reflectors considering pattern degradation for random structural errors[J]. Structural and Multidisciplinary Optimization, 2020, 61(4): 1621-1635.
- [12] BAKER N A, ALEXANDER F, BREMER T, et al. Workshop Report on Basic Research Needs for Scientific Machine Learning: Core Technologies for Artificial Intelligence[R]. Washington, DC (United States): USDOE Office of Science (SC), 2018.
- [13] MASSA A, MARCANTONIO D, CHEN X D, et al. DNNs as applied to electromagnetics, antennas, and propagation—A review[J]. IEEE Antennas and Wireless Propagation Letters, 2019, 18(11): 2225-2229.
- [14] GOODFELLOW I, BENGIO Y, COURVILLE A. Deep Learning[M]. Cambridge: MIT Press, 2016.
- [15] PEHERSTORFER B, WILLCOX K, GUNZBURGER M. Survey of multifidelity methods in uncertainty propagation, inference, and optimization[J]. SIAM Review, 2018, 60(3): 550-591.
- [16] PARK C, HAFTKA R T, KIM N H. Remarks on multi-fidelity surrogates[J]. Structural and Multidisciplinary Optimization, 2017, 55(3): 1029-1050.
- [17] GUO M W, MANZONI A, AMENDT M, et al. Multi-fidelity regression using artificial neural networks: Efficient approximation of parameter-dependent output quantities[J]. Computer Methods in Applied Mechanics and Engineering, 2022, 389: 114378.
- [18] ZHANG Y Y, GONG Z Q, ZHOU W E, et al. Multi-fidelity surrogate modeling for temperature field prediction using deep convolution neural network[J]. Engineering Applications of Artificial Intelligence, 2023, 123: 106354.

- [19] ZHUANG F Z, QI Z Y, DUAN K Y, et al. A comprehensive survey on transfer learning[J]. *Proceedings of the IEEE*, 2021, 109(1): 43-76.
- [20] 唐志共, 朱林阳, 向星皓, 等. 智能空气动力学若干研究进展及展望[J]. *空气动力学学报*, 2023, 41(7): 1-35.  
TANG Z G, ZHU L Y, XIANG X H, et al. Some research progress and prospect of intelligent aerodynamics[J]. *Acta Aerodynamica Sinica*, 2023, 41(7): 1-35. (in Chinese)
- [21] 赵欢, 高正红, 夏露. 基于新型多可信度代理模型的多目标优化方法[J]. *航空学报*, 2023, 44(6): 126962.  
ZHAO H, GAO Z H, XIA L. Novel multi-fidelity surrogate model assisted many-objective optimization method[J]. *Acta Aeronautica et Astronautica Sinica*, 2023, 44(6): 126962. (in Chinese)
- [22] 赵欢. 基于自适应多可信度多项式混沌-Kriging 模型的高效气动优化方法[J]. *力学学报*, 2023, 55(1): 223-238.  
ZHAO H. Adaptive multi-fidelity polynomial chaos-Kriging model-based efficient aerodynamic design optimization method[J]. *Chinese Journal of Theoretical and Applied Mechanics*, 2023, 55(1): 223-238. (in Chinese)
- [23] ZHANG J W, WEI Z, WU W Q, et al. A novel learning scheme for inversely-designing bonding wire with multi-fidelity data fusion[C]//2023 International Applied Computational Electromagnetics Society Symposium (ACES-China). Piscataway: IEEE, 2023: 1-3.
- [24] BALDAN M, DI BARBA P, NACKE B. Magnetic properties identification by using a bi-objective optimal multi-fidelity neural network[J]. *IEEE Transactions on Magnetics*, 2021, 57(6): 6000304.
- [25] GISELLE FERNÁNDEZ-GODINO M, PARK C, KIM N H, et al. Issues in deciding whether to use multifidelity surrogates[J]. *AIAA Journal*, 2019, 57(5): 2039-2054.
- [26] PERDIKARIS P, RAISSI M, DAMIANOU A, et al. Non-linear information fusion algorithms for data-efficient multi-fidelity modelling[J]. *Proceedings of the Royal Society A*, 2017, 473(2198): 20160751.
- [27] ZHANG Y M, KIM N H, PARK C, et al. Multifidelity surrogate based on single linear regression[J]. *AIAA Journal*, 2018, 56(12): 4944-4952.
- [28] MENG X H, KARNIADAKIS G E. A composite neural network that learns from multi-fidelity data: Application to function approximation and inverse PDE problems[J]. *Journal of Computational Physics*, 2020, 401: 109020.
- [29] BANDLER J W, CHENG Q S, NIKOLOVA N K, et al. Implicit space mapping optimization exploiting preassigned parameters[J]. *IEEE Transactions on Microwave Theory and Techniques*, 2004, 52(1): 378-385.
- [30] 李平宇, 臧恒, 王康. 基于空间映射法的微带滤波器设计方法[J]. *雷达与对抗*, 2023, 43(4): 32-35, 48.  
LI P Y, ZANG H, WANG K. Design of a microstrip filter based on space mapping[J]. *Radar & ECM*, 2023, 43(4): 32-35, 48. (in Chinese)
- [31] WANG Y T, LI K P, LI Q Y, et al. Multi-fidelity information fusion with hierarchical surrogate guided by feature mapping[J]. *Knowledge-Based Systems*, 2023, 275: 110693.
- [32] PENG X C, BAI Q X, XIA X D, et al. Moment matching for multi-source domain adaptation[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2019: 1406-1415.
- [33] MANCINI M, PORZI L, BULÒ S R, et al. Boosting domain adaptation by discovering latent domains[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 3771-3780.
- [34] SUN B C, FENG J S, SAENKO K. Return of frustratingly easy domain adaptation[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2016, 30(1): 2058-2065.
- [35] 吴天舒, 尹宏鹏, 赵丹丹, 等. 基于迁移学习的零样本故障诊断[J]. *电子学报*, 2023, 51(9): 2572-2577.  
WU T S, YIN H P, ZHAO D D, et al. Zero sample fault diagnosis based on transfer learning[J]. *Acta Electronica Sinica*, 2023, 51(9): 2572-2577. (in Chinese)
- [36] 吴军君, 王涛, 王英楷, 等. 基于迁移学习的LiPON制备工艺模拟优化[J]. *电子学报*, 2023, 51(3): 687-693.  
WU J J, WANG T, WANG Y K, et al. Transfer-learning-based virtual process optimization for LiPON[J]. *Acta Electronica Sinica*, 2023, 51(3): 687-693. (in Chinese)
- [37] 蒋晓玲, 吴映波, 陈蒙, 等. 基于跨域结构保持投影的异构在线多源迁移学习方法[J]. *电子学报*, 2023, 51(8): 1983-1994.  
JIANG X L, WU Y B, CHEN M, et al. Heterogeneous online multi-source transfer learning with cross-domain structure preserving projection[J]. *Acta Electronica Sinica*, 2023, 51(8): 1983-1994. (in Chinese)
- [38] REN Z W, DU J L, BAO H, et al. Shape adjustment for uncertain mesh reflectors using machine learning[J]. *International Journal of Mechanical Sciences*, 2023, 244: 108082.
- [39] SENDREA R E, ZEKIOS C L, GEORGAKOPOULOS S V. A multi-fidelity surrogate optimization method based on analytical models[C]//2021 IEEE MTT-S International Microwave Symposium (IMS). Piscataway: IEEE, 2021: 70-73.
- [40] PIETRENKO-DABROWSKA A, KOZIEL S. Low-cost

and precise automated re-design of antenna structures using interleaved geometry scaling and gradient-based optimization[J]. Knowledge-Based Systems, 2024, 284: 111296.

- [41] PIETRENKO-DABROWSKA A, KOZIEL S. Antenna modeling using variable-fidelity EM simulations and constrained co-Kriging[J]. IEEE Access, 2020, 8: 91048-91056.
- [42] LEE S, DIETRICH F, KARNIADAKIS G E, et al. Linking Gaussian process regression with data-driven manifold embeddings for nonlinear data fusion[J]. Interface Focus, 2019, 9(3): 20180083.
- [43] MENG X H, WANG Z C, FAN D X, et al. A fast multi-fi-

delity method with uncertainty quantification for complex data correlations: Application to vortex-induced vibrations of marine risers[J]. Computer Methods in Applied Mechanics and Engineering, 2021, 386: 114212.

- [44] CHEN J, GAO Y, LIU Y M. Multi-fidelity data aggregation using convolutional neural networks[J]. Computer Methods in Applied Mechanics and Engineering, 2022, 391: 114490.
- [45] TAO S Y, APLEY D W, CHEN W, et al. Input mapping for model calibration with application to wing aerodynamics[J]. AIAA Journal, 2019, 57(7): 2734-2745.

### 作者简介



**谭育正** 男,1998年2月出生于内蒙古自治区呼伦贝尔市.现为西安电子科技大学机电工程学院博士研究生.主要研究方向为网状天线、机器学习.

E-mail: tyz0225@foxmail.com



**寇丹阳** 男,1999年8月出生于陕西省商洛市.现为西安电子科技大学机电工程学院博士研究生.主要研究方向为阵面天线变形监测和主动调整.

E-mail: 563377251@qq.com



**张树新** 男,1987年3月出生于河北省深州市.现为西安电子科技大学教授,博士生导师,国家优秀青年基金获得者,电子装备机电耦合实验室国家级科研平台副主任.主要研究方向为柔性可展开天线/结构机电耦合、机电集成设计与制造等.中国电子学会会员编号:E190013497M.

E-mail: zhangshuxindd@126.com