

面向变刚度复合材料筒壳高效屈曲分析的变保真度迁移学习模型

李增聪 田阔 黄蕾 王博

Variable-fidelity transfer learning model for efficient buckling analysis of variable stiffness composite cylindrical shells

LI Zengcong, TIAN Kuo, HUANG Lei, WANG Bo

在线阅读 View online: <https://doi.org/10.13801/j.cnki.fhclxb.20210604.001>

您可能感兴趣的其他文章

Articles you may be interested in

考虑制造因素的变刚度层合板的抗屈曲铺层优化设计

Layup optimization for maximum buckling load of variable-stiffness laminates considering manufacturing factors

复合材料学报. 2018, 35(4): 866–875 <https://doi.org/10.13801/j.cnki.fhclxb.20170705.001>

复合载荷作用变刚度复合材料回转壳屈曲优化

Buckling optimization of variable stiffness composite rotary shell under combined loads

复合材料学报. 2019, 36(4): 1052–1061 <https://doi.org/10.13801/j.cnki.fhclxb.20180626.004>

变刚度复合材料结构的设计、制造与分析

Design, manufacture and analysis of variable-stiffness composite structures

复合材料学报. 2017, 34(10): 2121–2133 <https://doi.org/10.13801/j.cnki.fhclxb.20170829.006>

基于自动铺放技术的高精度变刚度复合材料层合板屈曲性能

Buckling performance of high-precision variable stiffness composites laminate based on automatic placement technology

复合材料学报. 2020, 37(11): 2807–2815 <https://doi.org/10.13801/j.cnki.fhclxb.20200218.001>

碳纳米管增强型功能梯度板的屈曲预测

Buckling analysis of carbon nanotube-reinforced functionally graded composite plates

复合材料学报. 2018, 35(10): 2804–2812 <https://doi.org/10.13801/j.cnki.fhclxb.20171227.002>

变刚度复合材料开孔板拉伸行为数值模拟及试验验证

Numerical simulation and experiment validation of variable stiffness composite laminates with open holes under unidirectional tension

复合材料学报. 2018, 35(3): 599–606 <https://doi.org/10.13801/j.cnki.fhclxb.20170612.003>



面向变刚度复合材料筒壳高效屈曲分析的变保真度迁移学习模型



分享本文

李增聪¹, 田阔^{*1,2,3}, 黄蕾¹, 王博^{1,2}

(1. 大连理工大学 工业装备结构分析国家重点实验室, 大连 116024; 2. 大连理工大学 辽宁省工业装备数字孪生重点实验室, 大连 116024; 3. 大连理工大学 人工智能大连研究院, 大连 116024)

摘要: 相较于传统直线铺层设计的复合材料筒壳结构, 变刚度复合材料筒壳结构通过曲线纤维路径铺层, 可以极大地增加复合材料的设计空间, 进而获得更优的抗屈曲能力。为了准确描述曲线纤维路径, 需要针对变刚度复合材料筒壳建立精细有限元模型, 因此对屈曲分析和优化效率带来了较大的挑战。本论文以变刚度复合材料筒壳结构的线性屈曲及后屈曲承载力快速预测为目标, 提出了一种变保真度迁移学习模型的构建方法。首先, 针对变刚度复合材料筒壳结构建立合适的高保真度、低保真度模型; 然后, 基于大量低保真度样本数据作为源域样本集建立并训练深度神经网络, 得到预训练模型; 最后, 以少量高保真度样本数据作为目标域样本集对最后一层神经网络参数进行微调, 训练得到变保真度迁移学习模型。变刚度复合材料筒壳线性屈曲和后屈曲算例结果表明, 在达到相同的预测精度水平时, 变保真度迁移学习模型比直接采用高保真度样本数据构建的代理模型分别节约了 47.7% 和 62.3% 的计算成本, 验证了提出方法的高效率优势。同时, 与基于桥函数构建的变保真度代理模型和 Co-Kriging 进行比较, 所提出方法在不同高保真度、低保真度样本数据组合下均具有更优精度, 验证了提出方法的高精度优势。

关键词: 变刚度复合材料筒壳; 屈曲分析; 迁移学习; 变保真度代理模型; 深度神经网络

中图分类号: V214.4; V414.4 **文献标志码:** A **文章编号:** 1000-3851(2022)05-2430-11

Variable-fidelity transfer learning model for efficient buckling analysis of variable stiffness composite cylindrical shells

LI Zengcong¹, TIAN Kuo^{*1,2,3}, HUANG Lei¹, WANG Bo^{1,2}

(1. State Key Laboratory of Structural Analysis for Industrial Equipment, Dalian University of Technology, Dalian 116024, China; 2. Key Laboratory of Digital Twin for Industrial Equipment, Dalian University of Technology, Dalian 116024, China; 3. DUT Artificial Intelligence Institute, Dalian University of Technology, Dalian 116024, China)

Abstract: Compared with the traditional design method of composite cylindrical shells with straight fiber laminate, variable stiffness composite cylindrical shells can greatly increase the design space of composite material and thus achieve higher buckling loads by means of the curved fiber laminate. To describe the curved fiber path precisely, it is necessary to establish high-fidelity detailed finite element model for variable stiffness composite cylindrical shells. Therefore, it brings great challenges to the efficiency of buckling analysis and optimization of variable stiffness composite cylindrical shells. In this paper, a variable-fidelity transfer learning model was proposed for the fast prediction of linear buckling load and post-buckling load of variable stiffness composite cylindrical shells. Firstly, the appropriate high-fidelity model and low-fidelity model of variable stiffness composite cylindrical shells were constructed. Then, the deep neural network was established and trained with a large number of low-fidelity

收稿日期: 2021-04-25; 修回日期: 2021-05-20; 录用日期: 2021-05-27; 网络首发时间: 2021-06-05 17:34:50

网络首发地址: <https://doi.org/10.13801/j.cnki.fhclxb.20210604.001>

基金项目: 国家自然科学基金 (11902065; 11825202); 中央高校基本科研业务费 (DUT21RC(3)013)

通信作者: 田阔, 博士, 副教授, 硕士生导师, 研究方向为数据驱动的结构强度与优化设计 E-mail: tiankuo@dlut.edu.cn

引用格式: 李增聪, 田阔, 黄蕾, 等. 面向变刚度复合材料筒壳高效屈曲分析的变保真度迁移学习模型 [J]. 复合材料学报, 2022, 39(5): 2430-2440.

LI Zengcong, TIAN Kuo, HUANG Lei, et al. Variable-fidelity transfer learning model for efficient buckling analysis of variable stiffness composite cylindrical shells[J]. Acta Materiae Compositae Sinica, 2022, 39(5): 2430-2440(in Chinese).

samples as the source dataset, and the pre-trained model was obtained. Finally, the last layer was retained by fine-tuning with a small number of high-fidelity samples as the target dataset, and the variable-fidelity transfer learning model was constructed after the retraining on the pre-trained model. The example results of linear buckling and post-buckling load prediction of variable stiffness composite cylindrical shells indicate that, the computational cost of variable-fidelity transfer learning model can reduce by 47.7% and 62.3% than surrogates built by the high-fidelity samples directly when achieving similar prediction accuracy, showing the advantage of high prediction efficiency of the proposed method. Besides, compared with the variable-fidelity surrogate models built by the bridge function and Co-Kriging, the proposed method shows the best prediction accuracy with different combinations of high-fidelity and low-fidelity samples, which demonstrates the advantage of high prediction accuracy of the proposed method.

Keywords: variable stiffness composite cylindrical shell; buckling analysis; transfer learning; variable-fidelity surrogate model; deep neural network

近年来,自动纤维铺放技术^[1-2](Automated fiber placement, AFP)发展迅速,通过AFP技术可实现复合材料结构曲线纤维路径铺层,突破了传统直线铺层较为单一的设计方式,极大地增加了复合材料的设计空间。因此,变刚度复合材料受到了研究人员的广泛关注并应用于实际工程结构的设计和制造中^[3-5]。图1为罗-罗公司基于AFP技术进行变刚度复合材料的设计,并应用于航空发动机附件机匣的工程制造中。



图1 罗-罗公司采用自动纤维铺放 (AFP) 技术制造航空发动机风扇机匣^[6]
Fig. 1 Rolls-Royce aero-engine fan casing manufactured by automated fiber placement (AFP)^[6]

通过对变刚度复合材料的曲线纤维铺层方式进行优化,可使结构传力更加合理。但为了准确描述曲线纤维路径,需要针对变刚度复合材料筒壳建立精细有限元模型,导致屈曲分析和优化的计算量大幅增加。代理模型技术^[7-8]由于能显著提高工程结构的数值分析效率,被广泛应用于工程结构优化中^[9-10]。Nik等^[11]比较了不同类型代理模型在变刚度复合材料结构优化设计中的性能,并指出Kriging模型和径向基函数(Radical basis function, RBF)代理模型对于变刚度复合材料设计

具有更高的精度和稳定性。Rouhi等^[12]结合RBF代理模型与遗传算法,对变刚度复合材料筒壳结构开展多步优化并逐渐缩小设计空间,进而收敛得到优化解。Passos等^[13]基于Kriging代理模型对带开口变刚度复合材料板开展高效全局优化,有效提高了结构的抗屈曲承载能力。Ye等^[14]基于支持向量回归方法开展了变刚度复合材料结构的全局优化设计,显著提升了结构的屈曲载荷值。

变保真度代理模型(Variable-fidelity surrogate model, VFMSM)通过结合高保真度模型(High-fidelity model, HFM)的高精度和低保真度模型(Low-fidelity model, LFM)的低成本优势,有助于进一步提高代理模型的精度和计算效率,近年来得到了广泛的关注。Han等^[15-16]提出了基于分层Kriging的VFMSM以及基于Co-Kriging的VFMSM,并成功应用于飞行器设计和气动优化等领域。Zhou等^[17-18]提出了一种基于主动学习的VFMSM构造方法,并通过数值算例和工程算例验证了方法的通用性。Tian等^[19]面向多级加筋壳后屈曲优化问题构建了VFMSM,相比传统单保真度代理模型方法节省了70%的计算耗时。针对变刚度复合材料筒壳的铺层优化问题,Guo等^[20-21]基于分层Kriging建立了VFMSM,并采用高效全局优化方法(Efficient global optimization, EGO)开展优化,较传统方法显著提升了计算效率和寻优能力。综上,针对变刚度复合材料结构的分析和优化问题,学者们已开展了大量代理模型方面的相关研究,但针对此问题在VFMSM方面的研究仍处于起步阶段,具有较大的研究潜力。

针对VFMSM中HFM和LFM样本数据的结合,目前最常用的方法包括桥函数法和Co-Kriging法^[22]。桥函数法主要包括加法桥函数^[23]、乘法桥函数^[24]和混合桥函数^[25]。Co-Kriging^[26-27]为Kriging模型的扩展,通过引入LFM样本数据辅助预测HFM。

Tian 等^[19]指出对于后屈曲分析及优化这类高度非线性问题,桥函数法容易造成 VFSM 的精度不稳定。郑君^[22]指出 Co-Kriging 构建过程复杂且构造成本较高。因此,构建高精度、简便的 HFM 和 LFM 的样本数据融合方法具有重要意义。随着人工智能的飞速发展,深度神经网络(Deep neural networks, DNN)广泛应用于加筋结构优化^[28]、气动形状优化^[29]和复合材料结构设计^[30-31]。受迁移学习(Transfer learning, TL)思想的启发,本文旨在建立面向变刚度复合材料筒壳高效屈曲分析的变保真度迁移学习模型,其核心思想是基于 LFM 样本数据训练 DNN 得到预训练模型,再基于 HFM 样本数据对预训练模型进行微调(Fine-tuning),训练得到满足精度需求的变保真度迁移学习模型。

1 基于迁移学习的高效变保真度模型

1.1 传统变保真度代理模型构建方法

常用的 VFSM 构建方法主要有桥函数法和 Co-Kriging 法。桥函数法主要可以分为加法桥函数法、乘法桥函数法和混合桥函数法。其中混合桥函数法较其他两种方法适用性更广且精度更高,近年来受到了广泛的关注和应用^[25,32-33]。混合桥函数法的原理是先采用修正因子 ρ 对低保真度代理模型(Low-fidelity surrogate model, LFSM)进行缩放,以使得 LFSM 与 HFM 更为接近。于是混合桥函数 $\hat{\delta}(x)$ 可表示为

$$\hat{\delta}(x) = y_H(x_H) - \rho \hat{y}_L(x_H) \quad (1)$$

其中: x_H 表示 HFM 样本点; $y_H(x_H)$ 表示基于 HFM 计算的样本点 x_H 的响应; $\hat{y}_L$ 表示 LFSM, 由低保真度样本点训练得到; $\hat{y}_L(x_H)$ 表示基于 LFSM 预测的样本点 x_H 的响应; ρ 为修正因子, 其值可通过求解下式得到:

$$\begin{aligned} & \text{Find } \rho \\ & \min \sum_{i=1}^{n_H} [\rho \hat{y}_L(x_i) - y_H(x_i)]^2 \end{aligned} \quad (2)$$

其中: n_H 代表 HFM 样本点总数。基于混合桥函数构建的 VFSM 可表示为

$$y_{VFSM} = \rho \hat{y}_L(x) + \hat{\delta}(x) \quad (3)$$

另一种常用的 VFSM 构建方法是 Co-Kriging 法, 它原用于地质统计学插值模型, 后广泛应用于工程科学领域^[26]。Co-Kriging 是一种考虑了 LFM 样本数据的 Kriging 模型, 其通过 LFM 样本数据进行 HFM 的辅助预测, 较单保真度的 Kriging 模型具有更高的预测精度。由于 Co-Kriging 的原理和

推导过程较为复杂, 本文不再赘述, 详见文献^[26-27]。

1.2 神经网络基本原理

本节简要介绍基于自适应矩估计(Adaptive moments, Adam)算法^[34]训练 DNN 的基本原理。对于一个含 n 个隐层的神经网络, 其模型参数主要包括权值 W 和阈值 b , DNN 的第 j 层的输出可表示为

$$z^{(j)} = f(W^{(j)}z^{(j-1)} + b^{(j)}), \forall j \in \{1, 2, \dots, n\} \quad (4)$$

其中: $z^{(j)}$ 表示第 j 层的输出; $z^{(j-1)}$ 表示第 $j-1$ 层的输出; f 表示激活函数; W 代表神经网络的权值; b 代表神经网络的阈值。本文使用的是 ReLU^[35] 激活函数。

W 和 b 可统一用参数 $\theta = \{W^{(j)}, b^{(j)}\}_{j=1}^{n+1}$ 表示, θ 可以通过优化使得下式最小得到:

$$L(\theta) = \frac{1}{N} \sum_{i=1}^N L_i = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{f}(x_i; \theta))^2 \quad (5)$$

其中: $L(\theta)$ 表示模型参数为 θ 时的损失函数; (x, y) 为训练数据; $\hat{f}(x_i; \theta)$ 为 DNN 的预测结果; N 为样本点总数; L_i 表示损失函数; y_i 表示真实值。

Adam 算法迭代计算格式如下:

$$\nabla L(\theta_l) = \frac{\partial L_{il}}{\partial \theta_l} \quad (6)$$

$$m_l = \beta_1 m_{l-1} + (1 - \beta_1) \nabla L(\theta_l) \quad (7)$$

$$v_l = \beta_2 v_{l-1} + (1 - \beta_2) [\nabla L(\theta_l)]^2 \quad (8)$$

其中: l 表示迭代步数; $\nabla L(\theta_l)$ 表示损失函数的导数; m 表示偏一阶矩估计; v 表示偏二阶矩估计; β_1 和 β_2 分别表示 m 和 v 的衰减率; L_{il} 表示迭代第 l 步时的损失函数; θ_l 表示迭代第 l 步时的待求参数。Adam 算法使用移动平均值来更新模型参数:

$$\theta_{l+1} = \theta_l - \frac{\alpha m_l}{\sqrt{v_l} + \varepsilon} \quad (9)$$

其中: ε 是避免被零除的极小正数; α 表示学习率。

本文中取 $m_0 = 0$, $v_0 = 0$, $\theta_1 = \theta_0$, $\beta_1 = 0.9$, $\beta_2 = 0.999$, $\varepsilon = 10^{-8}$ 。基于 Adam 算法进行训练, 可以得到 DNN 的权值和阈值。

1.3 变保真度迁移学习模型构建方法

迁移学习是一种新颖的机器学习方法, 被广泛应用于目标检测、图像识别和语音识别等领域^[36], 其目的是将某个领域或任务上学习到的知识或模式应用到不同但相似的领域或任务中。对于给定的源域 D_s 和源任务 T_s 、目标域 D_t 和目标任务 T_t , 且有 $D_s \neq D_t$ 或 $T_s \neq T_t$, 迁移学习可以充分利用 D_s

和 T_s 的信息，从而高效地完成在 D_t 中对于 T_t 的训练。通常来说，源域 D_s 是已经完成训练、有大量数据标注的领域，即为待迁移的对象。而目标域 D_t 是最终要进行标注的对象。迁移学习的核心是利用了源域和目标域的相似性，当知识从源域传递到了目标域，就完成了迁移学习。更详尽的迁移学习内容可参考 Pan 和 Yang^[36] 的综述文章。

受迁移学习思想的启发，结合 VFSM 的构建原理，本文利用 LFM 和 HFM 的相关性，以 LFM 样本数据作为源域，HFM 样本数据作为目标域，提出了一种变保真度迁移学习模型，可以高效地完成从 LFM 到 HFM 的信息迁移。其构建过程如图 2 所示，主要包括以下三个步骤：

步骤 1：建立 HFM 和 LFM 并抽样。

根据问题属性、结构特征、分析方法，建立合适的 HFM 和 LFM，且 LFM 能反映 HFM 的大致变化趋势^[37]。基于拉丁超立方抽样 (Latin hypercube sampling, LHS) 得到 m 个 LFM 样本点和 n 个 HFM 样本点，并分别计算其响应。

步骤 2：建立预训练模型。

以 m 个 LFM 样本点作为源域样本集建立 DNN，并基于第 1.2 节中的 Adam 算法对 DNN 的权值和阈值进行训练，得到预训练模型。

步骤 3：基于 Fine-tuning 建立变保真度迁移学习模型。

对于预训练模型，DNN 的前若干层学习到的都是通用的特征 (General features)，随着网络层次的加深，后面的网络更偏重于任务特定的特征 (Task-specific feature)，且越靠近输出层，任务特

定特征越高级^[38-39]。

良好的层次结构使得 DNN 具备可迁移性，本文基于 Fine-tuning 开展迁移学习。首先，固定预训练模型的前若干层，调整最后一层神经网络的阈值和权值的学习率。其次，以 n 个 HFM 样本点作为目标域样本集，对最后一层网络进行 Fine-tuning，即通过少量的 HFM 样本点和较小的学习率对预训练模型最后一层神经网络的模型参数进行重新训练，经过 Fine-tuning 即可得到变保真度迁移学习模型。

2 算例 1：变刚度复合材料筒壳线性屈曲载荷值预测

本节开展变刚度复合材料筒壳线性屈曲载荷值预测的算例研究。第 2.1 节介绍了变刚度复合材料筒壳 HFM 和 LFM 建立方法；第 2.2 节将构建的变保真度迁移学习模型、高保真度代理模型 (High-fidelity surrogate model, HFSM)、LFSM、传统桥函数构建的 VFSM 与 Co-Kriging 进行对比与讨论。

2.1 HFM 与 LFM 模型介绍

基于参考文献 [21,40] 给出的变刚度复合材料筒壳模型参数进行建模。模型是直径为 457.2 mm、高度为 457.2 mm、单层厚度为 0.127 mm 的 16 层的复合材料筒壳，其单层材料参数如表 1 所示。变刚度复合材料筒壳设计变量与纤维路径如图 3 所示，筒壳两端载荷承受纯弯曲载荷 $M=1\text{ kN}\cdot\text{m}$ 。将变刚度筒壳均匀划分为 12 份，考虑曲线纤维在

表 1 变刚度复合材料筒壳材料属性

Table 1 Material properties of variable stiffness composite cylindrical shell

Property	Value
E_1/GPa	134
E_2/GPa	7.71
E_3/GPa	7.71
G_{12}/GPa	4.31
G_{13}/GPa	4.31
G_{23}/GPa	2.76
ν_{12}	0.301
ν_{13}	0.301
ν_{23}	0.396
Thickness of each ply/mm	0.127

Notes: E_1, E_2, E_3 —Modulus of elasticity of direction 1, direction 2 and direction 3, respectively; G_{12}, G_{13}, G_{23} —Shear elasticity of direction 12, direction 13 and direction 23, respectively; $\nu_{12}, \nu_{13}, \nu_{23}$ —Poisson's ratio of direction 12, direction 13 and direction 23, respectively.




图 2 变保真度迁移学习模型建立方法

Fig. 2 Establishment method of variable-fidelity transfer learning model




图3 变刚度复合材料筒壳纤维路径 (a) 与设计变量 (b) 示意图

Fig.3 Schematic diagram of fiber path (a) and design variables (b) of variable stiffness composite cylindrical shell

圆周上对称，故纤维的轨迹由 7 个设计变量 $T_i(i=1, 2, \cdots, 7)$ 确定， T_i 的取值范围为 $[0^\circ, 90^\circ]$ ，纤维角度变化表达式为

$$\theta(\alpha) = T_i + \frac{T_{i+1} - T_i}{\alpha_{i+1} - \alpha_i}(\alpha - \alpha_i) \tag{10}$$

其中： T_i 和 T_{i+1} 表示相邻的设计变量； α 表示当前位置所对应的圆周角； α_i 表示设计变量 T_i 对应的圆周角； $\theta(\alpha)$ 表示圆周角为 α 时的纤维角度。本算例中变刚度铺层序列定为 $[0^\circ/\theta/90^\circ/-\theta/-\theta/90^\circ/\theta/0^\circ]_s$ 。在 ABAQUS 中进行变刚度复合材料筒壳的有限元建模，参考文献 [40] 使用 S8R5 (8 节点，每个节点 5 个自由度) 的壳单元类型，采用的计算机配置为 Intel Xeon Gold 6246R@3.39GHz、128GRAM。

根据有限元网格的疏密程度确定模型的保真度，是一种有效的变刚度复合材料筒壳 HFM 和 LFM 建立方法^[41]。不同网格数量下变刚度复合材料筒壳结构屈曲载荷与计算耗时如表 2 所示，经过网格收敛性分析，本文选取网格数量为 6 000

表 2 不同网格数量下变刚度复合材料筒壳结构屈曲载荷与计算耗时

Table 2 Buckling load and computational cost with different number of elements of variable stiffness composite cylindrical shell		
Number of elements	Buckling load/(kN·m)	CPU time/s
600	97.30	28
840	95.46	37
1 000	94.46	45
1 800	93.78	65
3 600	93.22	120
6 000	93.12	190
7 500	93.09	230
—	93.10 (Rouhi ^[40])	—

Note: CPU—Central processing unit.

的有限元模型作为 HFM，选取网格数量为 600 的有限元模型作为 LFM。HFM 与 LFM 的纤维路径示意图如图 4 所示，一阶屈曲模态图 ($T_i=45^\circ (i=1, 2, \cdots, 7)$) 如图 5 所示。




图4 变刚度复合材料筒壳高保真度模型 (HFM) ((a), (b)) 与低保真度模型 (LFM) ((c), (d)) 示意图

Fig.4 Schematic diagram of high-fidelity model (HFM) ((a), (b)) and low-fidelity model (LFM) ((c), (d)) for variable stiffness composite cylindrical shell




图5 变刚度复合材料筒壳 HFM (a) 与 LFM (b) 一阶屈曲模态

Fig.5 First buckling modes of HFM (a) and LFM (b) for variable stiffness composite cylindrical shell

由图 5 可知，本算例 HFM 的线性屈曲载荷值计算结果为 93.12 kN·m (单次计算耗时为 190 s)，与 Rouhi^[40] 论文中的计算结果 93.10 kN·m 较为接近。且由图 4 可以发现，HFM 沿筒壳的圆周方向网格数量较多，纤维路径变化较为平滑，因此 HFM 计算精度较高。LFM 的计算结果为 97.30 kN·m (单次计算耗时为 28 s)，与 HFM 计算结果的误差为 4.49%，可认为 LFM 能较好地反映 HFM 的变化趋势。由图 4 可以发现，LFM 网格较为稀疏，其纤维路径变化相对粗糙，总的来说 LFM 的计算效率较高，但计算精度不如 HFM。

2.2 对比与讨论

针对第 2.1 节中建立的 HFM 与 LFM，本节开展变保真度迁移学习模型与相关代理模型的对比与讨论，代理模型的精度指标为 R^2 与 R_{RMSE} ，计算公式如下：

$$R^2 = 1 - \frac{\sum_{i=1}^K (y_i - \hat{y}_i)^2}{\sum_{i=1}^K (y_i - \bar{y})^2}$$

(11)

$$R_{\text{RMSE}} = \frac{\sqrt{\frac{1}{N} \sum_{i=1}^K (y_i - \hat{y}_i)^2}}{\sqrt{\frac{1}{N-1} \sum_{i=1}^K (y_i - \bar{y})^2}}$$

(12)

其中： K 代表测试集样本点数目； y_i 表示真实值； $\hat{y}_i$ 表示预测值； $\bar{y}$ 表示真实值的平均值。 R^2 越接近 1，模型精度越高； R_{RMSE} 越接近 0，模型精度越高。

基于 Kriging 模型分别建立 HFSM 和 LFSM，其中 HFSM 采用的 HFM 样本点数量分别为 30、90 和 180，LFSM 采用的 LFM 样本点数量分别为 200 和 300。使用额外的 100 个 HFM 样本点作为测试集，代理模型精度结果如表 3 所示。从表中可以看到，对于 HFSM，随着 HFM 样本点数目的增加，模型精度也随之增加，但计算成本也逐渐提高；对于 LFSM，当样本点增加时模型精度并未提高，说明 LFM 的误差限制了 LFSM 的精度。

表 3 变刚度复合材料筒壳算例各代理模型预测精度与计算耗时

	Kriging		RBF-VFSM		Co-Kriging		Proposed method		CPU time/min
	R^2	R_{RMSE}	R^2	R_{RMSE}	R^2	R_{RMSE}	R^2	R_{RMSE}	
30HFM	0.272	0.849	—	—	—	—	—	—	95.0
90HFM	0.691	0.548	—	—	—	—	—	—	285.0
180HFM	0.850	0.380	—	—	—	—	—	—	570.0
200LFM	0.549	0.661	—	—	—	—	—	—	93.3
300LFM	0.542	0.668	—	—	—	—	—	—	140.0
30HFM+300LFM	—	—	0.529	0.691	0.780	0.481	0.823	0.418	235.0
50HFM+300LFM	—	—	0.661	0.580	0.838	0.393	0.871	0.360	298.3

Notes: R^2 —Regression square; R_{RMSE} —Relative root mean square error; RBF-VFSM—BRF-based variable-fidelity surrogate model.

基于第 1.3 节中所提出方法建立变保真度迁移学习模型。DNN 模型的隐层数为 3，每层神经元数目为 100，训练时取学习率 $\alpha_1=1\times10^{-3}$ ，Adam 迭代步数为 1 500。进行迁移学习时迁移层的学习率为 $\alpha_2=1\times10^{-4}$ 。各代理模型的精度和计算耗时如表 3 所示，可以看到，当样本点组成为 50HFM+300LFM 时，回归系数 R^2 为 0.871，相对均方根误差 R_{RMSE} 为 0.360，精度略优于 180 个 HFM 样本点构建的 HFSM (R^2 为 0.850， R_{RMSE} 为 0.380)，但较 HFSM 节约了 47.7% 的计算耗时，验证了所提出方法具有优异的效率优势。

为了进一步验证所提出方法的精度优势，将变保真度迁移学习模型、基于桥函数法构建的 VFSM 和 Co-Kriging 进行对比。其中桥函数法采用第 1.1 节中介绍的混合桥函数，基于 RBF 代理模型构建 VFSM (RBF-VFSM)。各模型计算结果的精度和耗时如表 3 所示，预测精度对比如图 6 所示。可以看到，本文方法在不同的 HFM 和 LFM

样本数据组合下始终具有最高的精度。在样本点组成为 50HFM+300LFM 时，基于本文方法构建的变保真度迁移学习模型的 R^2 比 RBF-VFSM 和 Co-Kriging 分别提高了 31.8% 和 3.9%， R_{RMSE} 误差值比 RBF-VFSM 和 Co-Kriging 分别下降了 37.9% 和 8.4%，说明了所提出方法的高精度优势。

对于变刚度复合材料筒壳算例第二阶屈曲载荷值的预测 (30HFM+300LFM)，变保真度迁移学习模型、RBF-VFSM 和 Co-Kriging 的 R^2 分别为 0.858、0.722 和 0.828； R_{RMSE} 分别为 0.375、0.525 和 0.412。本文方法的 R^2 比 RBF-VFSM 和 Co-Kriging 分别提高了 18.8% 和 3.6%； R_{RMSE} 误差值比 RBF-VFSM 和 Co-Kriging 分别下降了 28.6% 和 9.0%，说明了所提出方法对于第二阶屈曲载荷值预测也具有适用性。

3 算例 2：含缺陷变刚度复合材料筒壳后屈曲极限承载力预测

为了进一步验证所提出方法的适用性，本节开展含缺陷变刚度复合材料筒壳后屈曲极限承载




图6 变刚度复合材料筒壳算例各代理模型回归系数 R^2 (a)和相对均方根误差 R_{RMSE} (b)预测精度
Fig. 6 Prediction accuracy of regression square R^2 (a) and relative root mean square error R_{RMSE} (b) for various surrogates of variable stiffness composite cylindrical shell

表4 含缺陷变刚度复合材料筒壳材料属性
Table 4 Material properties of variable stiffness composite cylindrical shell with imperfection

Property	Value
E_1/GPa	124.4
E_2/GPa	8.69
E_3/GPa	8.69
G_{12}/GPa	4.83
G_{13}/GPa	4.83
G_{23}/GPa	4.83
ν	0.347
Thickness of each ply/mm	0.124

力预测的算例研究。第3.1节介绍了HFM和LFM建立方法；第3.2节将构建的变保真度迁移学习模型、HFSM、LFSM、RBF-VFSM与Co-Kriging进行对比与讨论。

3.1 HFM与LFM模型介绍

基于参考文献[42-43]中给出的含缺陷变刚度复合材料筒壳模型进行建模，模型是直径为206.5 mm、高度为889 mm、单层厚度为0.124 mm的8层的复合材料筒壳，单层材料参数如表4所示。纤维的轨迹由2个设计变量 $T_i(i=1, 2)$ 确定， T_i 的取值范围为 $[0, 90^\circ]$ 。纤维角度变化表达式仍为式(10)，变刚度铺层序列定为 $[45^\circ/-45^\circ/\theta/-\theta]_s$ 。

在ABAQUS中进行有限元建模，参考文献[42]使用S4R(4节点减缩积分单元)壳单元类型。筒壳结构底端固支，顶端约束除轴向位移外的其他自由度，并将顶端面所有节点刚性耦合至参考点，在参考点上施加轴压位移载荷直至结构发生坍塌。基于显式动力学进行加载，分析时间为200 ms，加载总位移为5 mm。

不同网格数量下含缺陷变刚度复合材料筒壳后屈曲载荷与计算耗时如表5所示，经过网格收敛性分析，本文选取网格数量为28 560的有限元模型作为HFM，选取网格数量为2 600的有限元模型作为LFM。含缺陷变刚度复合材料筒壳的缺陷分布示意图如图7(c)所示，本算例将文献[43]

表5 不同网格数量下含缺陷变刚度复合材料筒壳后屈曲载荷与计算耗时
Table 5 Post-buckling load and computational cost with different number of elements for variable stiffness composite cylindrical shell with imperfection

Number of elements	Buckling load/(kN·m)	CPU time/s
2 600	75.69	72
4 000	75.27	104
7 000	74.98	176
9 600	74.65	267
15 000	73.96	505
21 600	73.50	895
28 560	71.30	1 423
—	71.20 [42]	—




图7 含缺陷变刚度复合材料筒壳 HFM (a)、LFM (b) 与缺陷分布示意图 (c)
Fig. 7 Schematic diagram of HFM (a), LFM (b) and imperfection distribution (c) of variable-stiffness composite cylindrical shell with imperfection

中的实际测量缺陷引入到有限元模型中，以生成含缺陷的有限元模型。屈曲模态图($T_1=10^\circ$, $T_2=45^\circ$)如图 8 所示，HFM 的极限承载力计算结果为 71.30 kN (单次计算耗时为 1 423 s)，与 White 等^[42]论文中的计算结果 71.20 kN 较为接近，说明 HFM




图 8 含缺陷变刚度复合材料筒壳 HFM (a) 与 LFM (b) 屈曲模态

Fig. 8 Buckling modes of HFM (a) and LFM (b) for variable stiffness composite cylindrical shell with imperfection

计算结果具有较高精度。LFM 的计算结果为 75.69 kN (单次计算耗时为 72 s)，与 HFM 的误差为 6.16%，虽精度不如 HFM，但能较好地反映 HFM 的变化趋势且具有较高的计算效率。

3.2 对比与讨论

基于第 1.3 节中所提出方法建立变保真度迁移学习模型，DNN 模型的隐层数为 5，每层神经元数目为 50，训练时取学习率 $\alpha_1=5\times10^{-3}$ ，Adam 迭代步数为 2 000，进行迁移学习时迁移层的学习率为 $\alpha_2=1\times10^{-4}$ 。构建的各代理模型的精度 (使用额外 100 个 HFM 样本点作为测试集) 和计算耗时如表 6 所示，当样本点组合为 5HFM+50LFM 时，变保真度迁移学习模型的 R^2 为 0.961， R_{RMSE} 为 0.196，精度略优于 20 个 HFM 样本点构建的 HFSM (R^2 为 0.959， R_{RMSE} 为 0.201)，且较 HFSM 节约了 62.3% 的计算耗时，验证了所提出方法的高效性。

不同样本数据组合下，变保真度迁移学习模型、RBF-VFSM 和 Co-Kriging 的计算精度和耗时如表 6 所示，各代理模型预测精度对比如图 9 所示。由表 6 可以看到，本文方法在不同的 HFM

表 6 含缺陷变刚度复合材料筒壳算例各代理模型预测精度与计算耗时

Table 6 Prediction accuracy and computational cost of various surrogates for variable stiffness composite cylindrical shell with imperfection

	Kriging		RBF-VFSM		Co-Kriging		Proposed method		CPU time/min
	R^2	R_{RMSE}	R^2	R_{RMSE}	R^2	R_{RMSE}	R^2	R_{RMSE}	
5HFM	0.744	0.503	—	—	—	—	—	—	118.6
10HFM	0.915	0.290	—	—	—	—	—	—	237.2
20HFM	0.959	0.201	—	—	—	—	—	—	474.3
50LFM	0.843	0.395	—	—	—	—	—	—	60.0
100LFM	0.842	0.395	—	—	—	—	—	—	120.0
5HFM+50LFM	—	—	0.933	0.257	0.932	0.260	0.961	0.196	178.6
10HFM+50LFM	—	—	0.946	0.231	0.956	0.208	0.972	0.167	297.2




图 9 含缺陷变刚度复合材料筒壳算例各代理模型 R^2 (a) 和 R_{RMSE} (b) 预测精度

Fig. 9 Prediction accuracy of R^2 (a) and R_{RMSE} (b) for various surrogates of variable stiffness composite cylindrical shell with imperfection

和 LFM 样本点组合下始终具有更高的精度。在样本点组成为 5HFM+50LFM 时, 变保真度迁移学习模型的 R^2 比 RBF-VFSM 和 Co-Kriging 分别提高了 3.00% 和 3.11%, R_{RMSE} 误差值比 RBF-VFSM 和 Co-Kriging 分别下降了 23.74% 和 24.62%, 说明了所提出方法较传统方法具有更高的预测精度。

4 结论

(1) 提出了一种基于深度神经网络 (DNN) 的变保真度迁移学习模型构建方法。首先建立合适的高保真度模型 (HFM) 和低保真度模型 (LFM), 再基于大量 LFM 样本数据训练 DNN 得到预训练模型, 最后基于少量 HFM 样本数据对预训练模型进行 Fine-tuning, 得到变保真度迁移学习模型。面向变刚度复合材料筒壳结构的线性屈曲和后屈曲承载力预测问题开展算例研究, 结果表明比直接采用高保真度样本点构建的代理模型分别节约了 47.7% 和 62.3% 的计算成本, 验证了所提出方法的高效性和适用性。

(2) 将变保真度迁移学习模型、桥函数方法构建的变保真度代理模型 (VFSM) 和 Co-Kriging 进行对比, 结果表明变保真度迁移学习模型在不同 HFM 和 LFM 组合下均具有更高的精度, 验证了所提出方法的高精度优势。

在后续研究中, 将开展基于变保真度迁移学习模型的缺陷敏感性分析方法, 研究并考虑变刚度复合材料筒壳制造工艺约束, 把缺陷幅度、缺陷位置等缺陷变量、工艺约束参数、铺层角度等变量协同进行训练, 探究变刚度复合材料筒壳结构对不同形状缺陷的敏感性以及工艺约束对结构设计的影响。

参考文献:

- [1] CROFT K, LESSARD L, PASINI D, et al. Experimental study of the effect of automated fiber placement induced defects on performance of composite laminates[J]. *Composites Part A: Applied Science and Manufacturing*, 2011, 42(5): 484-491.
- [2] 董安琪, 肇研, 赵新青. 自动铺放工艺制备罐外固化复合材料的力学行为[J]. *复合材料学报*, 2018, 35(5): 1095-1104.
DONG Anqi, ZHAO Yan, ZHAO Xinqing. Mechanical performance of out-of-autoclave composites manufactured by automated fiber placement[J]. *Acta Materiae Compositae Sinica*, 2018, 35(5): 1095-1104(in Chinese).
- [3] GÜRDAL Z, TATTING B F, WU C K. Variable stiffness composite panels: Effects of stiffness variation on the in-plane and buckling response[J]. *Composites Part A: Applied Science and Manufacturing*, 2008, 39(5): 911-922.
- [4] SETOODEH S, ABDALLA M M, IJSELUIDEN S T, et al. Design of variable-stiffness composite panels for maximum buckling load[J]. *Composite Structures*, 2009, 87(1): 109-117.
- [5] 孔斌, 顾杰斐, 陈普会, 等. 变刚度复合材料结构的设计、制造与分析[J]. *复合材料学报*, 2017, 34(10): 2121-2133.
KONG Bin, GU Jiefei, CHEN Puhui, et al. Design, manufacture and analysis of variable-stiffness composite structures[J]. *Acta Materiae Compositae Sinica*, 2017, 34(10): 2121-2133(in Chinese).
- [6] Rolls-Royce Engine Company. Step inside our factory of the future[EB]. (2021-01-14)[2021-04-22]. <https://www.rolls-royce.com/media/ourstories/discover/2020/step-inside-our-actory-of-the-future.aspx>.
- [7] QUEIPO N V, HAFTKA R T, SHYY W, et al. Surrogate-based analysis and optimization[J]. *Progress in Aerospace Sciences*, 2005, 41(1): 1-28.
- [8] FORRESTER A I J, KEANE A J. Recent advances in surrogate-based optimization[J]. *Progress in Aerospace Sciences*, 2009, 45(1): 50-79.
- [9] 王莉, 刘国强, 肖迎春. 基于代理模型的复合材料加筋壁板分层损伤定量监测方法[J]. *复合材料学报*, 2020, 37(2): 302-308.
WANG Li, LIU Guoqiang, XIAO Yingchun. Quantitative monitoring method for delamination damage of stiffened composite panel based on surrogate model[J]. *Acta Materiae Compositae Sinica*, 2020, 37(2): 302-308(in Chinese).
- [10] 魏星, 陈莘莘, 张洪峰, 等. 基于代理模型的指数型功能梯度板固有频率优化[J]. *复合材料学报*, 2019, 36(8): 1886-1892.
WEI Xing, CHEN Shenshen, ZHANG Hongfeng, et al. Frequency optimization of power-law functionally graded plates via surrogate model[J]. *Acta Materiae Compositae Sinica*, 2019, 36(8): 1886-1892(in Chinese).
- [11] NIK M A, FAYAZBAKSH K, PASINI D, et al. A comparative study of metamodeling methods for the design optimization of variable stiffness composites[J]. *Composite Structures*, 2014, 107: 494-501.
- [12] ROUHI M, GHAYOOR H, HOA S V, et al. Computational efficiency and accuracy of multi-step design optimization method for variable stiffness composite structures[J]. *Thin-Walled Structures*, 2017, 113: 136-143.
- [13] PASSOS A G, LUERSEN M A, STEEVES C A. Optimal curved fibre orientations of a composite panel with cutout for improved buckling load using the efficient global optimization algorithm[J]. *Engineering Optimization*, 2017, 49(8): 1354-1372.
- [14] YE F, WANG H, LI G. Variable stiffness composite material design by using support vector regression assisted efficient global optimization method[J]. *Structural and Multidisciplinary Optimization*, 2017, 56(1): 203-219.

- [15] HAN Z H, GÖRTZ S. Hierarchical kriging model for variable-fidelity surrogate modeling[J]. *AIAA Journal*, 2012, 50(9): 1885-1896.
- [16] HAN Z H, ZIMMERMAN N, GÖRTZ S. Alternative cokriging method for variable-fidelity surrogate modeling[J]. *AIAA Journal*, 2012, 50(5): 1205-1210.
- [17] ZHOU Q, SHAO X, JIANG P, et al. An active learning metamodeling approach by sequentially exploiting difference information from variable-fidelity models[J]. *Advanced Engineering Informatics*, 2016, 30(3): 283-297.
- [18] ZHOU Q, SHAO X, JIANG P, et al. An active learning variable-fidelity metamodeling approach based on ensemble of metamodels and objective-oriented sequential sampling[J]. *Journal of Engineering Design*, 2016, 27(4/6): 205-231.
- [19] TIAN K, LI Z, MA X, et al. Toward the robust establishment of variable-fidelity surrogate models for hierarchical stiffened shells by two-step adaptive updating approach[J]. *Structural and Multidisciplinary Optimization*, 2020, 61: 1515-1528.
- [20] GUO Q, HANG J, WANG S, et al. Buckling optimization of variable stiffness composite cylinders by using multi-fidelity surrogate models[J]. *Thin-Walled Structures*, 2020, 156: 107014.
- [21] GUO Q, HANG J, WANG S, et al. Design optimization of variable stiffness composites by using multi-fidelity surrogate models[J]. *Structural and Multidisciplinary Optimization*, 2021, 63(1): 439-461.
- [22] 郑君. 基于变可信度近似的设计优化关键技术研究[D]. 武汉: 华中科技大学, 2014.
- ZHENG Jun. Research on key technology of variable-fidelity approximation-based design optimization[D]. Wuhan: Huazhong University of Science and Technology, 2014(in Chinese).
- [23] CHOI S, ALONSO J J, KROO I M. Two-level multifidelity design optimization studies for supersonic jets[J]. *Journal of Aircraft*, 2009, 46(3): 776-790.
- [24] HAFTKA R T. Combining global and local approximations[J]. *AIAA Journal*, 1991, 29(9): 1523-1525.
- [25] GISELLE F G M, PARK C, KIM N H, et al. Issues in deciding whether to use multifidelity surrogates[J]. *AIAA Journal*, 2019, 57(5): 1-16.
- [26] HAN Z H, ZIMMERMANN R, GORETZ S. A new cokriging method for variable-fidelity surrogate modeling of aerodynamic data[C]. Florida: 48th AIAA Aerospace Sciences Meeting Including the New Horizons Forum and Aerospace Exposition, 2010: 1225.
- [27] 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.
- HAN Zhonghua. Kriging surrogate model and its application to design optimization: A review of recent progress[J]. *Acta Aeronautica et Astronautica Sinica*, 2016, 37(11): 3197-3225(in Chinese).
- [28] SINGH K, KAPANIA R K. Accelerated optimization of curvilinearly stiffened panels using deep learning[J]. *Thin-Walled Structures*, 2021, 161(3): 107418.
- [29] ZHANG X, XIE F, JI T, et al. Multi-fidelity deep neural network surrogate model for aerodynamic shape optimization[J]. *Computer Methods in Applied Mechanics and Engineering*, 2021, 373: 113485.
- [30] 李妙玲, 全军锋, 赵红霞. 基于遗传算法和神经网络的C/C复合材料等温CVI工艺参数优化模型[J]. 复合材料学报, 2016, 33(11): 2666-2673.
- LI Miaoling, TONG Junfeng, ZHAO Hongxia. Optimization model for isothermal CVI process parameters for C/C composites based on genetic algorithm and neural network[J]. *Acta Materiae Compositae Sinica*, 2016, 33(11): 2666-2673(in Chinese).
- [31] 王春红, 赵玲, 白肃跃, 等. 改进Back Propagation神经网络预测麻纤维/UP复合材料的界面性能[J]. 复合材料学报, 2015, 32(6): 1696-1702.
- WANG Chunhong, ZHAO Ling, BAI Suyue, et al. Prediction of bast fiber/UP composites interfacial property by improved back propagation neural network[J]. *Acta Materiae Compositae Sinica*, 2015, 32(6): 1696-1702(in Chinese).
- [32] SHU L, JIANG P, SONG X, et al. Novel approach for selecting low-fidelity scale factor in multifidelity metamodeling[J]. *AIAA Journal*, 2019, 57(12): 5320-5330.
- [33] PARK C, HAFTKA R T, KIM N H. Low-fidelity scale factor improves bayesian multi-fidelity prediction by reducing bumpiness of discrepancy function[J]. *Structural and Multidisciplinary Optimization*, 2018, 58(2): 399-414.
- [34] COURBARIAUX M, BENGIO Y, DAVID J P. Binaryconnect: Training deep neural networks with binary weights during propagations[J]. *Advances in Neural Information Processing Systems*, 2015, 28: 3123-3131.
- [35] ZOU D, CAO Y, ZHOU D, et al. Gradient descent optimizes over-parameterized deep ReLU networks[J]. *Machine Learning*, 2019, 109(6): 1-26.
- [36] PAN S J, YANG Q. A survey on transfer learning[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2009, 22(10): 1345-1359.
- [37] TIAN K, LI Z, HUANG L, et al. Enhanced variable-fidelity surrogate-based optimization framework by gaussian process regression and fuzzy clustering[J]. *Computer Methods in Applied Mechanics and Engineering*, 2020, 366: 113045.
- [38] LU J, BEHBOOD V, HAO P, et al. Transfer learning using computational intelligence: A survey[J]. *Knowledge-Based Systems*, 2015, 80: 14-23.
- [39] JANG H, PLIS S M, CALHOUN V D, et al. Task-specific fea-

ture extraction and classification of fMRI volumes using a deep neural network initialized with a deep belief network: Evaluation using sensorimotor tasks[J]. [Neuro Image](#), 2017, 145: 314-328.

[40] ROUHI M, GHAYOOR H, HOA S V, et al. Effect of structural parameters on design of variable-stiffness composite cylinders made by fiber steering[J]. [Composite Structures](#), 2014, 118(1): 472-481.

[41] LI Z C, TIAN K, LI H Q, et al. A competitive variable-fidelity surrogate-assisted CMA-ES algorithm using data mining techniques[J]. [Aerospace Science and Technology](#), 2021, 119: 107084.

[42] WHITE S C, WEAVER P M, WU K C. Post-buckling analyses of variable-stiffness composite cylinders in axial compression[J]. [Composite Structures](#), 2015, 123: 190-203.

[43] WU K, TATTING B K, SMITH B H, et al. Design and manufacturing of tow-steered composite shells using fiber placement[C]. California: 50th AIAA/ASME/ASCE/AHS/ASC Structures, Structural Dynamics, and Materials Conference, 2009: 1-18.