

引用格式: 张坤鹏, 郝鹏, 段于辉, 等. 基于深度学习的多级曲线加筋壁板布局优化设计[J]. 中国舰船研究, 2021, 16(4): 86–95.

ZHANG K P, HAO P, DUAN Y H, et al. Layout optimization design of hierarchical curvilinearly stiffened panels based on deep learning[J]. Chinese Journal of Ship Research, 2021, 16(4): 86–95.

基于深度学习的多级曲线加筋壁板布局优化设计



扫码阅读全文

张坤鹏^{1,2}, 郝鹏^{*1,2}, 段于辉^{1,2}, 刘大川^{1,2}, 王博^{1,2}, 王宇同^{1,2}

1 大连理工大学 工程力学系, 辽宁 大连 116024

2 大连理工大学 工业装备数字孪生辽宁省重点实验室, 辽宁 大连 116024

摘要: [目的] 在航空、航天、船舶等领域的结构设计中, 因结构的性能需求, 存在大量开口薄壁结构, 导致承载性能明显降低。曲线加筋方式虽然在改善开口结构的承载性能方面潜力极大, 但设计变量的激增对结构优化提出了挑战。利用数据驱动的深度学习方法, 针对含曲筋布局的开口多级加筋壁板开展优化设计。[方法] 针对开口多级曲线加筋壁板, 提出结构参数特征图像化表征方法, 建立面向结构响应特征学习的深度学习网络模型, 实现数据驱动下的结构优化设计, 并与经典的由结构数值参数构造的代理模型进行比较。[结果] 结果显示, 所提基于图像识别的结构特征学习模型的预测精度改善了约1倍; 基于学习模型开展结构的优化设计, 多级正交加筋结构的承载性能提升了10.78%, 多级曲线加筋结构的承载性能提升了18.19%。[结论] 研究表明, 对于设计变量数众多且数量动态变化的开口多级加筋壁板, 基于深度学习的结构优化方法更有效; 相较传统直筋构型, 曲筋方式能更有效地对开口结构承载性能进行补强。

关键词: 开口薄壁结构; 曲线加筋; 数据驱动; 深度学习; 优化设计

中图分类号: U661.42

文献标志码: A

DOI: 10.19693/j.issn.1673-3185.02188

Layout optimization design of hierarchical curvilinearly stiffened panels based on deep learning

ZHANG Kunpeng^{1,2}, HAO Peng^{*1,2}, DUAN Yuhui^{1,2}, LIU Dachuan^{1,2}, WANG Bo^{1,2}, WANG Yutong^{1,2}

1 Department of Engineering Mechanics, Dalian University of Technology,
Dalian 116024, China

2 State Key Laboratory of Industrial Equipment Digital Twin, Dalian University of Technology,
Dalian 116024, China

Abstract: [Objectives] Due to the functional requirements of structures, a large number of thin-walled structures with cutouts are adopted in the structural design of aviation, aerospace, shipbuilding and other fields, leading to a significant reduction in the bearing capacity of such structures. Although the curved stiffening method has great potential in improving the load-bearing performance of open structures, the sharp increase in design variables presents a challenge for structural optimization. The data-driven deep learning method is used to optimize the design of hierarchical stiffened thin-walled structures with cutouts reinforced by curvilinear stiffeners. [Methods] For structures with cutouts, the hierarchical curvilinearly stiffened method is designed, and the image representation method of structural parameters is proposed. The deep learning network model for structural response feature-learning is established to realize structural optimization design under data-driven conditions. [Results] The results show that compared with the classical surrogate models constructed by structural numerical parameters, the prediction accuracy of the proposed structural response feature-learning model based on image recognition is improved roughly twofold. In the optimization design of structures based on the learning model, the bearing capacity of hierarchical orthogonal stiffened structures increased by 10.78%, and the bearing capacity of hierarchical curvilinearly stiffened structures increased by 18.19%. [Conclusions] The results show that this deep learning-based structural optimization method is more effective for hierarchical stiffened structures with large numbers of design variables and dynamic changes in the number of design variables. Compared with traditional straightly stiffened panels, the curvilinearly stiffened panel is more effective in strengthening the bearing capacity of thin-walled structures with cutouts.

Key words: thin-walled structures with cutouts; curvilinear stiffeners; data-driven; deep learning; optimization design

收稿日期: 2020-11-17 修回日期: 2021-03-30 网络首发时间: 2022-05-01 13:47

基金项目: 国家自然科学基金资助项目(11772078, 11825202); 兴辽英才计划资助项目(XLYC1802020, XLYC1907142); 辽宁省优秀青年基金资助项目(2019-YQ-01)

作者简介: 张坤鹏, 男, 1993年生, 硕士生。研究方向: 机器学习, 结构优化设计。E-mail: zhangkp@mail.dlut.edu.cn

郝鹏, 男, 1986年生, 博士, 教授, 博士生导师。研究方向: 结构优化与可靠度评估。E-mail: haopeng@dlut.edu.cn

*通信作者: 郝鹏

0 引 言

加筋壁板由蒙皮和筋条组成, 因其结构承载效率高且抗制造缺陷能力强, 在高端装备结构中得到广泛应用^[1-3]。同时, 出于各种结构功能需求(如设置电线、管道等), 常需在加筋薄壁结构中布置开口, 这使得结构的承载效率显著降低^[4-5]。因此, 开口加筋壁板的承载性能优化设计在船舶研究具有重要意义。

在加筋薄板结构中, 常见的失效模式包括整体屈曲、筋条局部屈曲、蒙皮局部屈曲等^[6]。开口的存在会导致结构在未达到整体屈曲极限承载状态前发生局部屈曲失效。针对承载结构开口处的集中应力会引起结构发生局部失效的现象, 宋晓飞等^[7]针对水下耐压圆柱开口围栏处的应力集中问题, 开展了加筋肋板拓扑优化设计, 优化后的设计方案有效降低了开口区域的集中应力。相较于传统的直线加筋(直筋构型), 采用曲线加筋(曲筋)的薄壁结构的承载性能更强。Kapania 等^[8-10]是最早提出此类设计空间更加灵活的曲筋方式, 并研究了曲筋结构影响结构承载性能的关键因素。Wang 等^[11]提出了一种基于多尺度建模的流线型加筋路径优化方法, 结果表明, 通过优化曲筋路径, 可以大幅提高其抗屈曲性能。除常见的单级网格加筋结构, Hao 等^[12-13]提出了层级加筋优化方法, 并证明多级加筋结构相比传统单级加筋结构承载效率更高, 且对缺陷的敏感程度更低, 同时还提出了一种针对多级加筋结构屈曲分析的高效混合优化框架, 证明了具有较强的适用性。虽然已经证明曲筋结构具有较高的结构效率, 但变量数的激增为结构优化效率提出了严峻挑战。在 Hao 等^[12]关于加筋开口板的优化过程, 以及 Liu 等^[14]针对非均匀变截面筋条的优化过程中, 都需要对结构进行上万次的有限元分析调用。此外, 考虑到变量爆炸问题, Mulani 等^[9]提出的曲筋布局优化框架中所允许的最大加筋数为 6 条。因此, 如何协调分析耗时的高精度结构设计与需要调用多次分析的优化算法之间的矛盾关系, 是此类结构设计所面临的首要问题。

针对复杂结构开展优化设计时, 因设计变量与结构响应之间存在高度非线性关系, 很难基于理论或经验公式得到显式函数, 因此, 通常需要对此进行数值有限元分析。虽然利用有限元数值分析可以计算复杂的结构力学响应, 但极为耗时, 由此开展的优化设计低效且不经济。近些年, 利用物理实验、数值模拟和生活经验等数据

信息开展数据驱动优化设计^[15]成为研究热点。为了降低数值计算成本, 基于现有数据建立代理模型并结合演化类算法的方法受到研究者的广泛关注^[16-18]。代理优化方法通常利用少量的数据构造代理模型来近似代替目标和约束函数, 其中能否充分利用已有的数据构造高精度代理模型是开展优化设计的决定性因素。近年来, 以深度学习为代表的数据处理技术迅速发展, 为复杂工程结构的优化设计提供了新的机遇^[19], 作为通用的近似函数, 深度学习模型在处理高维度非线性问题中展现出了巨大的潜力。目前, 深度学习模型已被广泛应用于材料、结构的建模与设计等领域^[20-23]。Li 等^[20-21]利用微观结构图像建立了深度学习网络, 用以对结构力学性能进行预测。Sun 等^[22]利用深度神经网络(deep neural network, DNN)对流体进行了模拟, 其中 DNN 的训练过程完全是基于偏微分方程的残差最小化原理开展, 因此避免了进行昂贵的数据标记。Yao 等^[23]提出一种通用的物理引导学习算法, 基于物理先验知识, 构建了用于预测结构力学响应的数据驱动模型。Hao 等^[24]通过迁移学习并结合少量含有结构响应标签的布局图像, 得到了对曲筋布局响应的预测模型, 并进一步利用该学习模型完成了曲筋结构的布局优化设计。

本文拟针对开口多级曲筋壁板, 通过深度学习图像识别技术, 构建基于图像化表征的结构特征学习模型, 并开展主-次级筋条布局优化设计。首先, 提出基于深度学习模型开展的结构优化框架; 然后, 针对开口结构设计多级加筋组合方式, 提出结构特征图像化处理方法, 并搭建结构特征学习的深度网络模型; 接着, 对比深度学习模型与传统代理模型对结构响应预测的差异性, 并利用深度学习模型对开口结构的不同加筋方式进行优化; 最后, 对不同加筋方式的优化结果进行详细对比。

1 数据驱动的结构优化设计方法

数据驱动的结构优化设计方法根植于代理优化机制(surrogate-based optimization, SBO)。经典的代理优化机制有初始采样、构建代理模型和新样本点填充, 代理模型的预测精度对最终优化效果起着决定性作用。常见的代理模型有多项式响应面模型(polynomial response surface model, RSM)与 Kriging 模型、人工神经网络(artificial neural network, ANN)、径向基函数(radial basis function, RBF)等^[25-29]。然而, 复杂工程结构的优化设计往

往含有众多的设计变量,传统方法针对众多设计变量构造的代理模型其精度难以保证,并且无法扩展到其他相似结构性能预测中,表现出较差的泛化能力^[30]。近年来,随着卷积神经网络(convolution neural network, CNN)模型等深度学习技术的蓬勃发展,为代理优化提供了新的途径。

1.1 卷积神经网络模型

卷积神经网络(CNN)一般包含卷积层、池化层和全连接层,如图1所示,是生物学启发人工智能中应用最为成功的案例,并且也是对经典神经网络模型的进一步扩展^[31]。卷积网络中至少含有一层进行卷积运算的神经网络,卷积运算是一种数学函数运算,如式(1)所示。




图1 卷积神经网络模型结构

Fig. 1 The structure of convolution neural network model

$$s(t) = \int x(a)w(t-a)da \quad (1)$$

式中: a 和 t 为运算空间中的两点; x 为 a 的特征函数; w 为 t 与 a 两点做差的距离权重函数。在卷积网络中, x 是作为特征输入, w 作为核函数, s 作为特征映射输出。卷积运算的数学特性使得卷积

网络可以很好地处理图像数据,将图像假设为一个二维数据输入,由此针对二维数据开展的卷积运算为

$$S(i, j) = \sum_m \sum_n x(m, n)w(i-m, j-n) \quad (2)$$

式中: i 和 j 为二维空间坐标参数; (m, n) 为图像在二维空间的位置坐标点; $x(m, n)$ 为 (m, n) 位置处的图像特征输入函数; $w(i-m, j-n)$ 为对图像特征处理的核函数。

对于卷积网络,图片通过卷积层的仿射变化后,一般需在池化层中处理,池化过程是将临近区域的总体统计特征进行处理,例如最大池化^[32]、平均池化^[33]等。池化过程属于一个无限强的先验过程^[31],可极大程度地提高神经网络的统计处理效率。在卷积层和池化层之后,通常会放置几个全连接层执行高级推理。深度学习模型在训练过程中通常基于最小化损失函数原理,采用随机梯度下降(stochastic gradient descent, SGD)方法对CNN进行网络调参与优化,进而找到最优拟合参数集^[34]。

1.2 数据驱动的结构优化框架

本文将基于代理优化框架的3个基本部分来开展数据驱动的开口多级加筋壁板的优化设计,具体流程如图2所示。




图2 数据驱动的结构优化框架

Fig. 2 Data-driven structural optimization framework

优化框架的第1步是进行初始采样。设计空间由描述结构特征的设计参数确定,因此,初始采样基于设计参数进行。在获得设计参数形式的初始样本集后,进行结构参数图像化处理以获得图像集。在对数据集进行初始采样或增加新的样本点时,需要进行有限元分析(finite element analysis, FEA)或采用其他分析方法获得结构响应,这在机器学习中称为数据标记^[35]。需要说明的是,这个采样部分通常需要进行多次数值分析,是整个优化过程中最耗时的部分。

优化框架的第2步是构建代理模型,即建立

图像特征信息与结构响应标签之间的映射关系。将获得标记的图像集分为训练集和测试集,其中训练集在CNN中经过逐层降维,随着训练步数的增加,使卷积网络逐渐获得预测结构响应的能力,另外再通过测试集筛选出预测效果最好的学习模型。

优化框架的第3步是进行数据填充。基于第2步训练的学习模型,结合遗传算法^[36](genetic algorithm, GA)寻找全局最优解。相比外部循环的主优化,基于代理模型的内部优化过程称为子优化,而内循环子优化的收敛准则是达到遗传优

化算法中设置的最大代数, 不需要补充新的数据。基于学习模型寻找全局最优解, 并对该解进行有限元分析检验, 然后补充到外循环的主优化中。外循环采用最小化预测值 (minimize the predictor, MP) 加点准则^[24], 基于新形成的数据集, 再次重构学习模型并完成子优化, 如此循环达到外循环设置的最大加点迭代次数, 优化结束。

2 开口多级加筋壁板设计及图像化处理

2.1 开口多级加筋壁板设计

针对开口结构进行加筋补强设计。受 Hao 等^[12]提出的层级加筋优化方法的启发, 设计了多级曲线加筋结构, 如图 3 所示, 次级加筋采取的是易于设计制造的正交网格加筋方式, 主级筋条采取的是稀疏曲筋方式。相较于图 3(a)所示的主级采用直筋方式, 图 3(b)所示的主级加筋结构采用稀疏曲筋方式蕴含了更大的设计空间。




图 3 2 种多级加筋类型对比
Fig. 3 Comparison of two types of hierarchical stiffeners

考虑长 $L=629.6\text{ mm}$ 、高 $H=731.2\text{ mm}$ 的多级加筋结构优化算例^[24]。其中直径 $D_1=100\text{ mm}$ 的开口位于 $(-100, -100)$ 处, 直径 $D_2=160\text{ mm}$ 的开口位于 $(-100, 100)$ 处, 如图 4 所示。考虑轴剪组合载荷作用^[1], 即在加筋板结构的上、下边分别设置单位轴力和剪力, 两侧边设置为简支边界条件。材料选用铝合金 2139, 弹性模量 $E=72.5\text{ GPa}$, 泊松比 $\nu=0.33$, 材料密度 $\rho=2.8\times10^{-6}\text{ kg/mm}^3$ 。图 4 中: F_x 和 F_y 分别为 x, y 方向的作用力; u, v, w 分别为 x, y, z 方向的位移。

利用二次贝塞尔曲线函数^[24]对主级曲筋路径进行描述。该函数有 3 个控制点, 分别为起始点 $P_s(s_{ix}, s_{iy})$ 、中点 $P_m(m_{ix}, m_{iy})$ 和终点 $P_e(e_{ix}, e_{iy})$ 。曲筋路径的函数可以被定义为:

$$B(t) = (1-t)^2P_s + 2t(1-t)P_m + t^2P_e, \quad t \in [0, 1] \quad (3)$$

为了保证曲筋路径完全处于设计域内, 将 3 个控制点分别限制在区域 $x \in [-0.45L, 0.45L]$ 及 $y \in [-0.45H, 0.45H]$ 内。为了对路径进行参数优化




图 4 开口加筋板边界条件

Fig. 4 The boundary conditions of stiffened panel with cutouts

设计, 根据曲筋路径函数起止点所在边, 将曲筋路径函数分为 6 种类型。同时, 为了探究优化过程中筋条数量的影响, 将不存在筋条时定为第 7 种类型。7 种主级加筋类型如图 5 所示, 图中 T_i 表示加筋类型, i 取值为 $[1, 7]$ 。在加筋板区域内对这 7 种加筋类型随机选取 4 次, 即主级加筋条的数量在 $[0, 4]$ 内变化, 以保证次级筋条单胞具有更大的设计空间。




图 5 7 种主级加筋类型

Fig. 5 The seven types of major stiffeners

利用子空间迭代法对开口多级加筋结构的一阶临界屈曲载荷进行求解。其中, 有限元模型采用 ABAQUS 软件中的 S4R 壳单元, 蒙皮和筋条进行捆绑约束 (Tie) 设置, 这样的约束可以保证蒙皮和筋条相接处单元节点的移动与旋转自由度保持一致^[37], 并通过网格收敛性分析, 确定单元尺寸为 10 mm , 模型单元总数约为 $10\,000$ 个。

2.2 开口多级加筋结构图像化处理

开口多级加筋壁板的设计变量包括主级筋高 H_{q} 、主级筋厚 t_{q} 、次级筋高 H_{m} 、次级筋厚 t_{m} 、次级筋条横向数目 N_x 和纵向数目 N_y , 以及 4 根主级筋条的 5 个参数, 具体包含筋条类型 Case、曲线路径的起点 P_s 、曲线路径的终点 P_e 及曲线路径中点的横、纵坐标 (P_{mx}, P_{my}) , 共 26 个设计变量。

其中,筋条类型和次级横、纵向筋数目为离散变量,筋高、筋厚及筋条布局控制位置为连续变量。主级曲筋路径在 7 种路径类型中选取,由于起止点的位置不确定,故采取归一化设计变量,根据对应类型还原到实际设计域中的物理坐标,其具体变化范围如表 1 中所示。

表 1 多级加筋壁板的设计变量

设计变量	变量下限	变量上限
筋条1类型Case ₁	1	7
筋条1起点P _{s1}	0	1
筋条1终点P _{e1}	0	1
筋条1中点P _{mx1}	0	1
筋条1中点P _{my1}	0	1
筋条2类型Case ₂	1	7
筋条2起点P _{s2}	0	1
筋条2终点P _{e2}	0	1
筋条2中点P _{mx2}	0	1
筋条2中点P _{my2}	0	1
筋条3类型Case ₃	1	7
筋条3起点P _{s3}	0	1
筋条3终点P _{e3}	0	1
筋条3中点P _{mx3}	0	1
筋条3中点P _{my3}	0	1
筋条4类型Case ₄	1	7
筋条4起点P _{s4}	0	1
筋条4终点P _{e4}	0	1
筋条4中点P _{mx4}	0	1
筋条4中点P _{my4}	0	1
次级筋高H _m	6.0	12.0
主级筋高H _j	20.0	40.0
次级筋厚t _m	1.0	1.5
主级筋厚t _j	2.0	5.0
次筋横向数目N _x	7	14
次筋纵向数目N _y	7	14

对于由 26 个设计变量确定的多级曲筋壁板,需要对结构参数进行图像化表征。为了让二维图像可以更加真实地还原主、次级加筋及开口位置对结构性能的影响,在图像化结构特征处理中,利用 RGB 三通道全彩图像中的不同通道灰度值进行了组合。采用 RGB 全彩图的 3 个通道分别对不同设计参数进行表征,如图 6 所示,其中图像像素大小为 64×64×3,每个通道的灰度值为 [0, 255]。将灰度值与对应的结构响应进行归一化处理,让 R 通道的灰度值表示主、次级筋条高度值, G 通道的灰度值表示主、次级筋条厚度值, B 通道仅对开口在蒙皮中的相对位置进行表征,主、次级筋条的布局信息在各通道用线段表征。其中,主-

次级筋条的区分主要通过对应通道中线型的粗、细来表示,主级筋条线段宽是次级筋条的 3 倍。由此,开口多级加筋结构的所有结构参数均被图像化表征,在用 CNN 模型对 RGB 图像进行学习的过程中,会自动赋予主-次级不同图像描述特征 的神经元权重,进而建立多级加筋结构性能预测模型。




图 6 加筋壁板结构特征的图像化表示
Fig. 6 Image representation of structural features for stiffened panels

2.3 基于卷积神经网络的结构特征模型

为了探究采用曲筋方式的开口结构的承载性能,分别对主筋为稀疏曲筋与直筋这 2 种方式进行了对比。在图 7 所示的 4 种加筋类型中,主级直筋的起、止点及中点在一条直线上,因此直筋类型仅由 2 个设计变量控制。这 4 种加筋类型及设计变量分别为:由 8 个设计变量控制的主级直筋布局可变多级正交加筋结构;由 20 个设计变量控制的主级曲筋布局可变多级曲筋结构;由 14 个设计变量控制的主、次级布局高度/厚度可变多级正交加筋结构;由 26 个设计变量控制的主、次级布局高度/厚度可变多级曲线加筋结构。

对于由 4 种加筋开口结构生成的图像数据集,利用 CNN 模型学习结构参数与结构力学响应之间的映射关系。由于需要对三通道的全彩 RGB 图像进行学习,相比对灰度图像的学习网络^[24],该研究问题的非线性程度会增加,因此需要扩大 CNN 的结构。在深度学习框架 Tensorflow 中搭建 CNN,对 64×64×3 的加筋图像通过 3 层卷积和 3 层池化处理,实现逐层降维,最后连接 3 个全连接层。其中, CNN 中的超参数设置为:卷积核大小为 3×3,训练批输入大小为 40,训练步数为 2 000 (训练过程已收敛),激活函数为 Relu 函数,学习率为 0.001,全连接中设置 Dropout 为 0.9, CNN 内部神经元参数如图 7 所示。




图 7 基于卷积神经网络的结构特征模型

Fig. 7 The structural feature model based on CNN

3 基于深度学习的多级加筋壁板优化设计

3.1 模型预测效果对比

基于预测模型的结构优化机制,模型泛化性能至关重要。为了说明基于图像数据的 CNN 学习模型的性能,选取最常见的基于结构数值数据的 RBF 和 Kriging 模型进行了对比。

对于由 26 个设计变量确定的开口多级曲筋结构,采用拉丁超立方抽样方法均匀抽取 800 组数据作为训练集,另外抽取 200 个数据作为测试集,经过有限元数值分析,得到对应的临界屈曲载荷和质量。利用 Matlab 平台算法工具箱建立 RBF 和 Kriging 代理模型,另外通过 Tensorflow 平台建立 CNN 学习模型。选取以下指标作为模型泛化性能的评判标准。

1) 决定系数 R^2 :

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \tilde{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

2) 均方根误差 $RMSE^{[38]}$:

$$RMSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2}}{\frac{1}{n} \sum_{i=1}^n y_i} \quad (5)$$

式中: n 为测试集数量; y_i 为真实值; $\tilde{y}_i$ 为模型预测值; $\bar{y}$ 测试集中真实值的平均值。各模型的 R^2 预测效果具体结果如图 8 所示,其中横坐标为结构的真实结构响应和质量,纵坐标为模型预测值。

图中,散点相对于中间的对角线聚拢程度,是越靠近对角线表示模型预测效果越好。另外,预测模型的 $RMSE$ 越小,表明模型的预测效果越好。

几种预测模型对结构屈曲承载力和质量的预测效果 $RMSE$ 和 R^2 如表 2 所示,通过对比 3 个预测模型的 2 种评判标准 $RMSE$, R^2 及散点图可以发现:

1) 由于设计变量到结构屈曲承载力的非线性程度明显高于质量的非线性程度,因此 3 种预测模型对结构质量的预测效果比对结构承载力的预测效果好。

2) 在传统 RBF 和 Kriging 模型建模过程中,直接建立了设计参数到结构性能的两步映射关系,因无法识别不同层级筋条布局的组合特征,所以严重忽略了结构的特征信息。在基于图像数据的深度学习方法中,结构的特征化图像处理可以发掘出多级网格的布局信息特征,因此深度学习模型展现出了更好的泛化能力,预测效果改善了一倍左右。

针对开口多级曲筋壁板有限元分析形成的初始训练集,基于 CNN 模型,其对结构承载力和质量的预测存在一定的误差,但相比传统代理模型,预测精度有大幅度的改善。为了进一步提高基于 CNN 的优化设计解的可行性,结合数据驱动的优化框架,通过 MP 加点准则,逐步改善 CNN 学习模型的局部预测精度,并对每次加入的点进行有限元检验,以削弱由学习模型预测出的虚假优化解效应。

3.2 优化设计

对上述 4 种开口多级加筋结构分别进行基于 CNN 的结构质量约束下的最大屈曲承载力优化设计。优化列式如下:




图 8 结构屈曲响应及质量的模型 R^2 预测效果

Fig. 8 The R^2 effect of model prediction on structural buckling response and mass

表 2 3 种模型对结构屈曲承载力和质量的预测效果
Table 2 Predictive effects of three models on structural buckling bearing capacity and mass

模型	结构屈曲承载力预测效果		结构质量预测效果	
	$R^2/\%$	$RMSE/\%$	$R^2/\%$	$RMSE/\%$
RBF	41	25	70	15
Kriging	34	24	51	19
CNN	86	10	93	6


$$\begin{aligned} &\text{find } X = [Case_1, P_{s1}, P_{e1}, P_{m1}, \cdots, H_{tm}, H_{ij}, t_m] \\ &\max \lambda \\ &\text{s.t. } M_1 < \bar{M} \end{aligned} \tag{6}$$

式中, λ 为结构一阶临界屈曲载荷, 设计变量如表 1 所示, 约束质量 M_1 不高于 $\bar{M}$ (1.00 kg)。

利用 CNN 对图像数据集进行训练, 得到预测结构质量和屈曲承载力的学习模型, 然后结合 GA 算法进行子优化, 其中 GA 优化算法采取 Python 中的遗传算法库 Geatpy^[39], 关键参数如下: 种群数为 200 个, 遗传代数为 50 代, 交叉率为 0.8, 变异率为 0.005。将子优化 GA 得到的最优解进行有

限元检验, 并将有限元分析标记的图像扩充到初始图像集中, 继续训练新的代理模型以实现循环, 设置外循环加点步数为 50 步。

基于深度学习的 4 种开口多级加筋结构优化过程如图 9 所示。在优化迭代过程中, 由于 CNN 对结构质量预测存在误差, 经对优化解进行有限元检验, 会有一部分不满足质量约束的无效点。4 种开口加筋补强结构优化过程中的最优解如表 3 所示。结合图 9 中的最优构型及结构屈曲模态, 可以发现, 主级筋条为直线和曲线的加筋方式均有效避开了开口位置, 保证了筋条刚度的连续, 展现出了对开口结构显著的补强作用。相比直筋加筋方式, 采用曲筋方式更加灵活地调整了开口处的加筋路径, 使得开口结构发生整体屈曲模态, 从而减弱了由开口引起的局部屈曲效应。在考虑对主级加筋布局优化的基础上, 让次级布局、主次级筋高和筋厚加入数据驱动的优化框架中, 建立了主-次级加筋结构的层级优化, 从结果可以看出, 次级筋条结构的优化进一步增强了结



(a) 多级正交加筋主级直筋布局可变结构优化




图 9 4 种开口多级加筋结构优化过程

Fig. 9 Optimization process of four kinds of hierarchical stiffened structure with cutouts

表 3 4 种开口多级加筋结构优化结果

Table 3 Optimization results of four kinds of hierarchical stiffened structure with cutouts

加筋补强结构类型	筋条质量/kg	最优屈曲载荷/kN	承载性能改善/%
初始最优解	0.963	32.925	—
多级正交加筋主级直筋布局可变结构	0.988	34.698	5.38
多级曲线加筋主级曲筋布局可变结构	0.986	35.654	8.28
多级正交加筋主、次级布局高度/厚度可变结构	0.892	36.477	10.78
多级曲线加筋主、次级布局高度/厚度可变结构	0.950	38.914	18.19

构的整体承载性能,有效抑制了因开口而引起的蒙皮局部屈曲。

4 结 论

本文针对 4 种多级加筋壁板开展了优化设计。基于开口多级曲筋结构中同时存在离散和连续设计变量,并且加筋数目动态变化,传统代理优化模型的精度难以满足优化需求的问题,本文

提出了基于深度学习的开口多级加筋壁板布局优化设计方法,通过对结构特征进行图像化表征处理,并利用搭建的卷积网络模型对结构响应进行学习,建立了结构特征学习模型。利用此学习模型并结合 GA 算法,实现了数据驱动的多级加筋结构优化设计。主要得到以下结论:

1) 对于复杂结构的优化设计,基于结构图像识别的深度学习模型展现出了良好的适用性能,

特别是在传统代理模型无法处理的加筋数目动态可变的结构布局优化设计中,建立的深度学习模型相对于传统代理模型预测精度提升了一倍。其主要原因是结构的布局图像比用数值参数表征结构特征更加充分,另外,也得益于深度学习模型具有更强的泛化能力。

2) 在开口加筋结构最大承载性能优化过程中,相比传统直筋方式,采取曲筋方式能更加有效地缓解开口对结构承载性能的折减效应。在所建立的主-次级结构的层级优化方法中,提出的多级直筋结构相比初始结构其承载性能提升了10%;提出的多级曲筋结构对开口结构进一步补强,其承载性能提升了18%。

针对开口加筋结构的优化设计,本文所设计的多级曲筋方式可以有效地对开口结构进行补强,提出的深度学习方法对此类优化问题具有较强的适用性。对于不同工况下的结构优化问题,仅需对结构特征的图像化处理方式做适当调整,并根据研究问题的非线性程度,对CNN学习模型参数进行调整,即可建立结构特征图像与力学响应之间的学习模型,代替预测效果较差的传统代理模型方法,完成复杂结构的优化设计。

参考文献:

- [1] 王伟, 吴梵. 国内船舶结构稳定性研究进展 [J]. 船舶工程, 2010, 32(增刊 2): 5-9.
WANG W, WU F. Advances in stability research of domestic ship structure[J]. Ship Engineering, 2010, 32(Supp 2): 5-9 (in Chinese).
- [2] 陈彦廷, 于昌利, 桂洪斌. 船体板和加筋板的屈曲及极限强度研究综述 [J]. 中国舰船研究, 2017, 12(1): 54-62.
CHEN Y T, YU C L, GUI H B. Research development of buckling and ultimate strength of plate and stiffened panel[J]. Chinese Journal of Ship Research, 2017, 12(1): 54-62 (in Chinese).
- [3] 肖伟, 程远胜, 曾广武. 纵横加筋圆柱壳结构的多目标优化设计 [J]. 中国造船, 2004, 45(增刊 1): 106-111.
XIAO W, CHENG Y S, ZENG G W. Multi-objective optimization design of longitudinal-transverse stiffened cylindrical shell[J]. Shipbuilding of China, 2004, 45(Supp 1): 106-111 (in Chinese).
- [4] LINDGAARD E, LUND E, RASMUSSEN K. Nonlinear buckling optimization of composite structures considering "worst" shape imperfections[J]. International Journal of Solids and Structures, 2010, 47(22/23): 3186-3202.
- [5] WANG B, HAO P, LI G, et al. Determination of realistic worst imperfection for cylindrical shells using surrogate model[J]. Structural and Multidisciplinary Optimization, 2013, 48(4): 777-794.
- [6] VENKATARAMAN S, LAMBERTI L, HAFTKA R T. Challenges in comparing numerical solutions for optimum weights of stiffened shells[J]. Journal of Spacecraft and Rockets, 2003, 40(2): 183-192.
- [7] 宋晓飞, 肖伟, 何其健, 等. 加筋圆柱壳开孔围栏肘板拓扑优化设计 [J]. 中国舰船研究, 2018, 13(1): 46-52.
SONG X F, XIAO W, HE Q J, et al. Topological optimization of opening fence brackets on ring-stiffened cylindrical shell[J]. Chinese Journal of Ship Research, 2018, 13(1): 46-52 (in Chinese).
- [8] KAPANIA R K, LI J, KAPOOR H. Optimal design of unitized panels with curvilinear stiffeners[C]//AIAA 5th Aviation Technology, Integration, and Operations, 16th Lighter-Than-Air and Balloon Systems Conferences. Arlington: AIAA, 2005: 7482.
- [9] MULANI S B, SLEMP W C H, KAPANIA R K. EBF3PanelOpt: an optimization framework for curvilinear blade-stiffened panels[J]. Thin-Walled Structures, 2013, 63: 13-26.
- [10] SLEMP W C H, BIRD R K, KAPANIA R K, et al. Design, optimization, and evaluation of integrally stiffened Al-7050 panel with curved stiffeners[J]. Journal of Aircraft, 2011, 48(4): 1163-1175.
- [11] WANG D, ABDALLA M M, WANG Z P, et al. Streamline stiffener path optimization (SSPO) for embedded stiffener layout design of non-uniform curved grid-stiffened composite (NCGC) structures[J]. Computer Methods in Applied Mechanics and Engineering, 2019, 344: 1021-1050.
- [12] HAO P, WANG B, TIAN K, et al. Efficient optimization of cylindrical stiffened shells with reinforced cutouts by curvilinear stiffeners[J]. AIAA Journal, 2016, 54(4): 1350-1363.
- [13] HAO P, WANG Y T, LIU C, et al. Hierarchical non-deterministic optimization of curvilinearly stiffened panel with multicutouts[J]. AIAA Journal, 2018, 56(10): 4180-4194.
- [14] LIU D C, HAO P, ZHANG K P, et al. On the integrated design of curvilinearly grid-stiffened panel with non-uniform distribution and variable stiffener profile[J]. Materials & Design, 2020, 190: 108556.
- [15] WANG H D, JIN Y C, JAN J O, et al. Data-driven surrogate-assisted multiobjective evolutionary optimization of a trauma system[J]. IEEE Transactions on Evolutionary Computation, 2016, 20(6): 939-952.
- [16] EMMERICH M, GIOTIS A, ÖZDEMİR M, et al. Metamodel-assisted evolution strategies[C]//Parallel Problem Solving From Nature —PPSN V II. Granada: PPSN, 2002: 361-370.
- [17] JIN Y C, OLHOFFER M, SENDHOFF B. A framework for evolutionary optimization with approximate fitness

- functions[J]. *IEEE Transactions on Evolutionary Computation*, 2002, 6(5): 481–494.
- [18] JIN Y C, WANG H D, CHUGH T, et al. Data-driven evolutionary optimization: an overview and case studies[J]. *IEEE Transactions on Evolutionary Computation*, 2019, 23(3): 442–458.
- [19] FINOL D, LU Y, MAHADEVAN V, et al. Deep convolutional neural networks for eigenvalue problems in mechanics[J]. *International Journal for Numerical Methods in Engineering*, 2019, 118(5): 258–275.
- [20] LI X, LIU Z L, CUI S Q, et al. Predicting the effective mechanical property of heterogeneous materials by image based modeling and deep learning[J]. *Computer Methods in Applied Mechanics and Engineering*, 2019, 347: 735–753.
- [21] LI X, NING S W, LIU Z L, et al. Designing phononic crystal with anticipated band gap through a deep learning based data-driven method[J]. *Computer Methods in Applied Mechanics and Engineering*, 2020, 361: 112737.
- [22] SUN L N, GAO H, PAN S W, et al. Surrogate modeling for fluid flows based on physics-constrained deep learning without simulation data[J]. *Computer Methods in Applied Mechanics and Engineering*, 2020, 361: 112732.
- [23] YAO H P, GAO Y, LIU Y M. FEA-Net: a physics-guided data-driven model for efficient mechanical response prediction[J]. *Computer Methods in Applied Mechanics and Engineering*, 2020, 363: 112892.
- [24] HAO P, LIU D C, ZHANG K P, et al. Intelligent layout design of curvilinearly stiffened panels via deep learning-based method[J]. *Materials & Design*, 2021, 197: 109180.
- [25] ZHOU Z Z, ONG Y S, NGUYEN M H, et al. A study on polynomial regression and Gaussian process global surrogate model in hierarchical surrogate-assisted evolutionary algorithm[C]//2005 IEEE Congress on Evolutionary Computation. Edinburgh: IEEE, 2005: 2832–2839.
- [26] 夏志, 刘均, 程远胜. 基于代理模型的水下结构物基座阻抗特性快速预报 [J]. *中国舰船研究*, 2020, 15(3): 81–87.
- XIA Z, LIU J, CHENG Y S. Fast prediction of mechanical impedance of an underwater foundation based on surrogate models[J]. *Chinese Journal of Ship Research*, 2020, 15(3): 81–87 (in Chinese).
- [27] SUN C L, JIN Y C, CHENG R, et al. Surrogate-assisted cooperative swarm optimization of high-dimensional expensive problems[J]. *IEEE Transactions on Evolutionary Computation*, 2017, 21(4): 644–660.
- [28] 舒乐时, 周奇, 蒋平, 等. 基于序贯 Kriging 模型的潜器型线优化设计 [J]. *船舶工程*, 2016, 38(9): 43–46, 61.
- SHU L S, ZHOU Q, JIANG P, et al. Shape optimization design of submersible based on sequential Kriging model[J]. *Ship Engineering*, 2016, 38(9): 43–46, 61 (in Chinese).
- [29] MARTÍNEZ S Z, COELLO C A C. MOEA/D assisted by RBF networks for expensive multi-objective optimization problems[C]//Proceedings of the 15th Annual Conference on Genetic and Evolutionary Computation. New York: GECCO, 2013: 1405–1412.
- [30] CESA-BIANCHI N, CONCONI A, GENTILE C. On the generalization ability of on-line learning algorithms [J]. *IEEE Transactions on Information Theory*, 2004, 50(9): 2050–2057.
- [31] GOODFELLOW I, BENGIO Y, COURVILLE A. Deep learning[M]. Cambridge: The MIT Press, 2016: 201–226.
- [32] BOUREAU Y L, PONCE J, LECUN Y. A theoretical analysis of feature pooling in visual recognition[C]//Proceedings of the 27th International Conference on Machine Learning (ICML-10). Haifa, Israel: ICML, 2010.
- [33] WANG T, WU D J, COATES A, et al. End-to-end text recognition with convolutional neural networks[C]//Proceedings of the 21st International Conference on Pattern Recognition (ICPR2012). Tsukuba: IEEE, 2012: 3304–3308.
- [34] WIJNHOFEN R G J, DE WITH P H N. Fast training of object detection using stochastic gradient descent[C]//2010 20th International Conference on Pattern Recognition. Istanbul, Turkey: IEEE, 2010: 424–427.
- [35] ALPAYDIN E. Introduction to machine learning[M]. 4th ed. Cambridge: The MIT Press, 2020.
- [36] ZHANG H H, ZHANG K S. Surrogate-based optimization[M]//Real-World Applications of Genetic Algorithms. London: Imperial College Press, 2012: 343–362.
- [37] MCDONALD K, LITTLE J, PEARCY M, et al. Development of a multi-scale finite element model of the osteoporotic lumbar vertebral body for the investigation of apparent level vertebra mechanics and micro-level trabecular mechanics[J]. *Medical Engineering & Physics*, 2010, 32(6): 653–661.
- [38] HYNDMAN R J, KOEHLER A B. Another look at measures of forecast accuracy[J]. *International Journal of Forecast*, 2006, 22: 679–688.
- [39] WANG J, LIU S C, LI M C, et al. Multiobjective genetic algorithm strategies for burnable poison design of pressurized water reactor[J/OL]. *International Journal of Energy Research*. (2020-09-06). <https://onlinelibrary.wiley.com/doi/epdf/10.1002/er.5926>.