

# 基于机器学习的三角形波纹夹芯梁的冲击响应与设计优化\*

李栋, 张晓斌, 刘志芳\*, 雷建银

(太原理工大学航空航天学院, 山西 太原 030024)

**摘要:** 为提高三角形波纹夹芯梁在低速冲击下的性能预测精度与结构设计效率, 基于硬参数共享的多任务学习 (MTL) 框架, 构建了一种面向夹芯梁冲击响应的机器学习建模与优化流程。基于有限元模型生成样本数据集, 并参考已有实验结果对模型合理性进行校核。在此基础上训练 MTL 模型, 实现了对结构比吸能、上面板最大挠度及初始峰值载荷的同步预测。结果表明, 经贝叶斯优化后的 MTL 模型在 50 J 冲击能量条件下表现出较好的预测性能, 预测结果与有限元模拟结果吻合较好, 测试集中各输出量的决定系数均达到 0.989 以上, 验证了该模型在响应预测与工程优化分析中的有效性与可靠性。参数敏感性分析表明: 芯层胞元数量和芯层壁厚对结构刚度的影响最显著, 其次为上面板厚度, 而下面板厚度的影响相对较小; 芯层壁厚在性能提升方面存在一定的饱和阈值。结合非支配排序遗传算法 II (NSGA-II), 分别对变形特性、吸能性能及综合性能开展多目标优化分析, 获得了满足不同工程设计需求的夹芯梁最优参数构型。

**关键词:** 机器学习; 波纹夹芯梁; 冲击响应; 性能预测; 结构优化

**中图分类号:** O347; O521.9

**文献标识码:** A

夹芯梁由上下面板和中间芯层组成, 因其具有比刚度高、抗冲击性优异和吸能能力强等优点, 在航空航天、交通运输及国防军工等领域得到了广泛应用<sup>[1-2]</sup>。近年来, 随着轻量化与安全性要求的提升, 该类结构在高速列车和汽车等地面交通装备中的应用越来越多<sup>[3-4]</sup>。这是因为夹芯结构能够在减轻车体质量的同时提高吸能效率, 从而增强车辆的结构安全性, 符合未来高性能交通装备的发展趋势。

波纹夹芯梁作为典型的夹芯结构形式之一, 因其独特的几何特性和优异的力学性能而受到了广泛关注<sup>[5-6]</sup>。国内外学者通过实验和有限元模拟等方法, 对波纹夹芯结构在动态载荷下的力学响应进行了系统研究。Rubino 等<sup>[7-8]</sup>研究了芯层方向和边界条件对船用波纹夹芯梁力学性能的影响, 结果表明, 与同质量整体梁相比, 纵向芯层夹芯梁具有更优的抗冲击性能, 其中芯层压痕是主要失效模式, 边界条件通过改变面板变形形式显著影响整体响应。St-Pierre 等<sup>[9]</sup>对波纹夹芯梁的动态与准静态力学行为进行了对比研究, 验证了准静态模型在低速冲击下的适用性。Xia 等<sup>[10]</sup>结合实验、数值模拟与理论分析, 系统研究了铝合金波纹夹芯梁在纵向弯曲工况下的力学响应, 指出芯层几何参数对结构变形模式、峰值载荷及比吸能具有显著影响。

在工程研究与结构设计领域, 传统实验测试与有限元数值模拟虽能较为准确地描述结构的响应规律, 但其计算成本较高, 在涉及多参数、多工况的迭代的优化设计中, 效率问题更为突出。基于代理模型的机器学习方法展现出了显著优势, 该方法从已有数据中学习输入参数与结构响应之间的复杂关系, 可以实现性能快速预测的同时, 还能辅助完成从性能要求反推设计参数的逆向探索, 显

\* 收稿日期: 2025-12-29; 修回日期: 2026-02-13

基金项目: 国家自然科学基金 (12272254, 12372363); 山西省自然科学基金 (202203021211170)

作者简介: 李栋 (2000-), 男, 硕士研究生, 主要从事冲击动力学研究. E-mail: 1255379997@qq.com

通讯作者: 刘志芳 (1971-), 女, 博士, 教授, 主要从事冲击动力学研究. E-mail: liuzhifang@tyut.edu.cn

著提升设计效率<sup>[1, 12]</sup>。在单任务学习 (STL) 框架下, 神经网络、Kriging、支持向量回归 (SVR) 及 LightGBM 等模型已被用于结构响应预测, 并与智能优化算法相结合开展参数反演与结构优化设计。相关研究表明, 该类方法在一定范围内能够实现结构性能的快速评估。代表性工作包括: Yang 等<sup>[13]</sup>通过改进人工电场算法优化人工神经网络模型, 实现了蜂窝夹芯防爆墙抗爆性能的预测与优化。Fang 等<sup>[14]</sup>利用深度学习完成负泊松比点阵夹芯梁的逆向设计, 并通过三点弯曲实验与有限元模拟验证了其优异性能。Andika 等<sup>[15]</sup>结合有限元数据与机器学习, 对四种负泊松比夹芯板构型进行了性能优化, 结果表明胞元厚度是影响抗爆性能的关键参数。Qiu 等<sup>[16]</sup>将神经网络和麻雀搜索算法结合, 确定了船用波纹夹芯板的最优抗爆结构尺寸。Teimouri 等<sup>[17]</sup>基于实验数据训练双深度神经网络模型, 实现了夹芯梁力学性能与结构质量的联合预测与优化。

现有多数代理模型研究通常针对单一性能指标分别建立预测模型, 或在不同响应之间采用独立建模方法, 难以描述结构多响应之间的内在相关性。对于波纹夹芯梁在低速冲击作用下的动力响应问题, 比吸能、峰值载荷及变形特征等指标在物理机理上具有明显的相关性, 采用独立的单任务代理模型往往需要分别建模与调参, 在多目标优化过程中也可能引入预测不一致的问题。同时, 针对波纹夹芯梁低速冲击响应的快速预测与多目标优化研究数量仍相对有限, 且多数研究在节点位置施加载荷, 该加载方式有利于发挥结构整体刚度, 与工程实际中冲击位置随机、载荷可能作用于节点间面板区域的情况存在一定差异。

基于上述研究背景, 本文选取两相邻节点之间的中心位置作为冲击加载点, 重点分析该不利工况下波纹芯层夹芯梁的非线性动力响应。在此基础上, 引入基于硬参数共享的多任务学习 (MTL) 模型架构, 对比吸能、峰值载荷及变形响应等多个关键性能指标进行联合建模与预测。本文工作重点在于评估 MTL 框架在波纹夹芯梁低速冲击响应预测与工程优化中的适用性, 探讨其在降低多响应代理建模复杂度及提升多目标优化一致性方面的潜在优势, 从而为夹芯结构抗冲击性能的工程设计提供一种可行的建模与优化思路。

## 1 研究方法

### 1.1 研究框架

所提出的波纹夹芯结构冲击响应预测方法和分析流程的总体研究框架如图 1 所示。

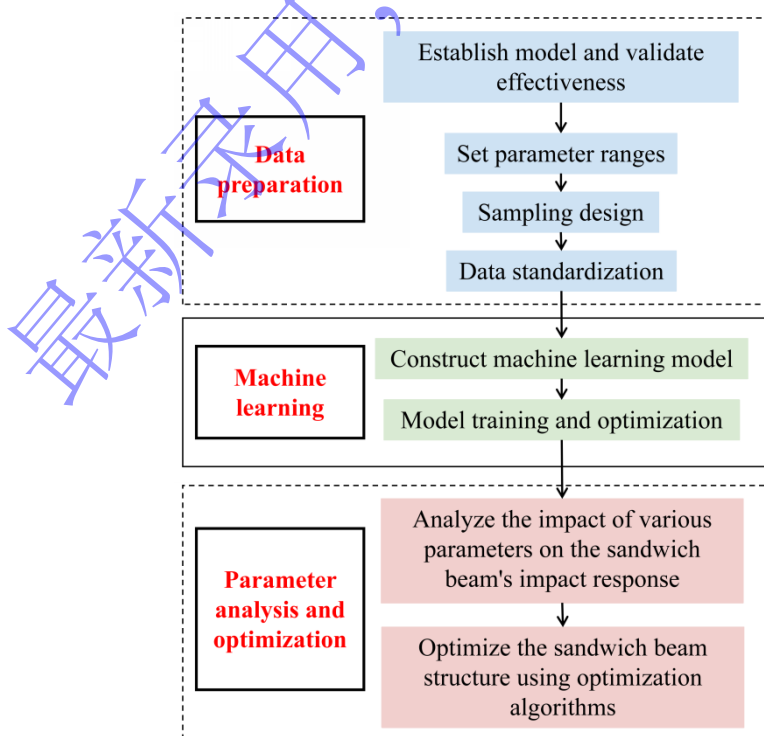


图 1 研究框架

Fig. 1 Research framework.

第一步：建立夹芯梁的有限元模型并验证其有效性。然后确定输入特征范围，采用拉丁超立方抽样（LHS）方法在该范围内生成样本数据。利用编写的 ABAQUS 脚本对样本进行有限元模拟，获得波纹夹芯梁在低速冲击下结构响应。随后，将所得的原始数据在区间[0,1]内进行归一化预处理，作为机器学习模型的输入和输出样本。

第二步：构建机器学习模型，并使用预处理后的数据对模型进行训练与测试。采用多任务学习（MTL）框架，通过贝叶斯优化算法确定模型的最优超参数，以确保训练后的 MTL 模型能够在保证预测精度的同时，具有较高的预测效率。

第三步：对 MTL 模型得到的冲击响应预测结果进行性能分析，并基于非支配排序遗传算法 II（NSGA-II）开展结构参数优化，获得抗冲击性能最优的夹芯梁设计方案。

## 1.2 波纹夹芯梁结构

夹芯梁由上、下面板及中间的三角形波纹芯层组成，具体几何构型与尺寸如图 2 所示。梁的总长度为  $L=310\text{mm}$ ，宽度  $B=40\text{mm}$ ，胞元长度  $l=100\text{mm}$ 。上、下面板厚度均为  $t_1=t_2=2\text{mm}$ ，芯层壁厚为  $t_c=1.8\text{mm}$ ，芯层高度为  $H_c=46\text{mm}$ 。三角形波纹芯层倾斜板与下面板的夹角为  $\theta=46^\circ$ 。夹芯梁两端通过螺栓固定连接，螺栓直径为  $d=12\text{mm}$ 。




图 2 波纹夹芯梁的结构示意图

Fig. 2 Schematic diagram of the corrugated sandwich beam structure.

## 1.3 拉丁超立方体采样

拉丁超立方抽样（Latin Hypercube Sampling, LHS）<sup>[18]</sup>是一种从多元参数分布中近似随机抽样的分层技术，该方法能够在保证样本覆盖均匀性的同时，有效减少实现高预测精度所需的训练样本数量。在波纹夹芯梁的冲击响应研究中，主要影响因素包括芯层胞元数量  $n$ ，上面板厚度  $t_1$ ，芯层壁厚  $t_c$  以及下面板厚度  $t_2$ 。根据各参数的取值范围，利用 LHS 生成具有代表性的样本。然后采用编写的 ABAQUS 脚本对这些样本进行有限元模拟，提取对应的结构响应数据，构建机器学习模型所需的数据集。

## 1.4 多任务学习模型

相比于单任务学习（Single Task Learning），多任务学习（Multi Task Learning, MTL）<sup>[19]</sup>能够在多个相关任务间共享从输入数据中提取的特征信息，从而提高模型的学习效率与泛化能力。该方法通过在不同任务间共享部分参数，减少了模型总参数数量，降低了过拟合风险，并提升了整体预测稳定性。

本研究采用硬参数（Hard Parameter Sharing）共享的 MTL 架构，该模型主要由输入层、共享层、私有层和输出层组成。各层神经元通过激活函数、权值和阈值相互连接，实现多目标响应的联合预测。模型结构如图 3 所示。




图 3 硬参数共享的多任务学习模型示意图

Fig. 3 Schematic diagram of a multi-task learning model with hard parameter sharing.

为提高网络训练的非线性拟合能力和收敛速度，模型采用 ReLU (Rectified Linear Unit) 函数作为激活函数：

$$\text{ReLU}(x) = \max(0, x) \quad (1)$$

在模型训练过程中，为衡量模型输出与目标输出之间的逼近精度，采用神经网络的均方误差 (Mean Square Error, MSE) 作为优化目标函数，其表达式如下：

$$L_{\text{total}} = \sum_{m=1}^M \left( K_m \cdot \frac{1}{N} \sum_{i=1}^N (y_i^{(m)} - \hat{y}_i^{(m)})^2 \right) \quad (2)$$

其中， $M$  为任务总数， $N$  为样本数量， $K_m$  为第  $m$  个任务的权重系数； $y_i^{(m)}$  和  $\hat{y}_i^{(m)}$  分别表示第  $i$  个样本在第  $m$  个任务中的真实值与预测值。本研究中各任务权重取  $K_1: K_2: K_3=1: 1: 1$ 。

### 1.5 贝叶斯优化

为获得 MTL 模型的最优超参数组合，本研究采用贝叶斯优化 (Bayesian Optimization) [20] 对模型进行自动化调参。该方法通过构建高斯过程 (Gaussian Process, GP) 代理模型对目标函数进行建模，并依据预测的不确定性自适应地选择新的采样点，从而能够以较少评估次数高效搜索全局最优解。高斯过程的一般定义形式为：

$$f(x) \sim \text{GP}(g(x), k(x, x')) \quad (3)$$

其中， $g(x)$  为均值函数，通常简化假设为常数或零函数：

$$g(x) = 0 \quad (4)$$

$k(x, x')$  为协方差函数 (核函数)，用于度量样本点  $x$  与  $x'$  之间的相关性。常用的核函数为平方指数核函数 (Squared Exponential Kernel)。其表达式如下：

$$k(x, x') = \sigma^2 \exp\left(-\frac{\|x - x'\|^2}{2b^2}\right) \quad (5)$$

其中， $\sigma^2$  为控制方差， $b$  为长度尺度参数。

### 1.6 非支配排序遗传算法 II

非支配排序遗传算法 II (Non-dominated sorting genetic algorithm II, NSGA-II) 是一种基于 Pareto 最优理论的多目标进化优化遗传算法<sup>[21]</sup>, 具有收敛速度快、全局搜索能力强和解集分布均匀等优点。在本研究中, 首先通过训练完成的 MTL 模型生成初始父代种群。然后, 利用快速非支配排序对任意两个个体  $\mathbf{x}_i$  与  $\mathbf{x}_j$  进行比较, 以实现解集的分层排序, 并通过计算拥挤度距离来衡量个体在目标空间的分布密度。在每一代进化过程中, 算法依次执行选择、交叉和变异操作, 以生成子代种群。然后使用精英保留策略, 将父代与子代种群合并后, 按照非支配层级和拥挤距离进行筛选, 最终保留最优个体群。通过不断迭代, 算法可获得一组均匀分布且互不支配的最优解, 即 Pareto 前沿 (Pareto Front)。

任意两个个体  $\mathbf{x}_i$  与  $\mathbf{x}_j$  之间的快速非支配排序可表示为:

$$\mathbf{x}_i \prec \mathbf{x}_j \Leftrightarrow \begin{cases} \forall q \in [1, Q], f_q(\mathbf{x}_i) \leq f_q(\mathbf{x}_j) \\ \exists p \in [1, Q], f_p(\mathbf{x}_i) < f_p(\mathbf{x}_j) \end{cases} \quad (6)$$

其中, 若个体  $\mathbf{x}_i$  在所有目标上均不劣于个体  $\mathbf{x}_j$ , 并且在至少一个目标上严格优于  $\mathbf{x}_j$  时, 则称个体  $\mathbf{x}_i$  支配个体  $\mathbf{x}_j$ ;  $Q$  表示目标函数的总数。

拥挤度的计算可表示为:

$$d_i = \sum_{q=1}^Q \frac{|f_q^{(i+1)} - f_q^{(i-1)}|}{f_q^{\max} - f_q^{\min}} \quad (7)$$

其中,  $f_q^{(i+1)}$  和  $f_q^{(i-1)}$  分别表示在第  $q$  目标上与个体  $i$  在第  $q$  目标上相邻的两个解的目标函数值;  $f_q^{\max}$  和  $f_q^{\min}$  分别表示当前种群在第  $q$  个目标上的最大与最小值。对于边界个体 (极端解), 其拥挤度设为无穷大, 以确保其在选择过程中被优先保留。

## 2 数据集准备

### 2.1 有限元模型

夹芯梁的有限元模型如图 4 所示。模型中, 夹具、螺栓及落锤均定义为刚体。夹芯梁通过两个 M12 螺栓固定在夹具盖板与底座之间, 并施加预紧力以模拟两端全固定的边界条件。夹芯梁的上、下面板、螺栓与夹具均采用减缩积分六面体单元 (C3D8R), 芯层采用减缩积分四边形壳单元 (S4R)。夹芯梁与落锤和单元尺寸均为 1mm, 夹具部分的单元尺寸为 2mm。

冲击载荷由直径为 20mm、质量为 9.239kg、冲击速度为  $v$  的落锤施加于夹芯梁上面板中心位置, 该位置为夹芯梁最薄弱的部分。芯层与上下板之间通过 ABAQUS 中的壳-实体耦合 (Shell-to-Solid Coupling) 约束进行连接, 以保证界面处位移连续性及各力的有效传递。落锤与夹芯梁上面板之间定义为面-面接触, 摩擦系数取 0.16<sup>[22]</sup>。除上述接触外, 其余各部件之间的相互作用采用通用接触定义。夹芯梁的有效长度为  $\lambda=200\text{mm}$ 。




图 4 波纹夹芯梁有限元模型

Fig. 4 Finite element model of the corrugated sandwich beam.

夹芯梁的上下面板与芯层均由 A6N01S-T5 铝合金材料制成，其主要材料参数如表 1 所示。材料的本构关系采用 Cowper-Symonds 动力学模型描述：

$$\sigma_y = \left[ 1 + \left( \frac{\dot{\epsilon}}{C} \right)^{\frac{1}{P}} \right] \sigma_0 \quad (8)$$


其中， $\sigma_y$  为动态屈服应力， $\sigma_0$  为静态屈服应力， $\dot{\epsilon}$  为应变率， $C$  和  $P$  为材料常数。对于铝合金材料，通常取  $C=3257.69\text{s}^{-1}$ ， $P=1.95$ 。

表 1 波纹夹芯梁材料属性<sup>[23]</sup>

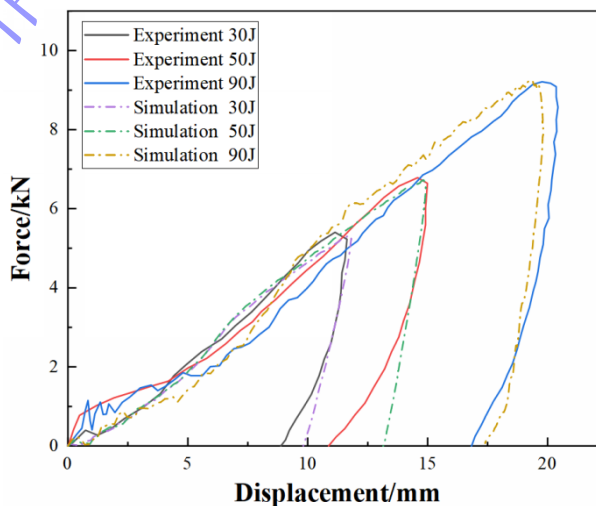
Table 1 Material properties of the corrugated sandwich beam<sup>[23]</sup>.

Material	Density ( $\text{g}\cdot\text{cm}^{-3}$ )	Young's modulus (GPa)	Yield stress (MPa)	Poisson's ratio
A6N01S-T5	2.7	69	181.91	0.33


为验证模型的可靠性，将模拟结果与文献实验结果<sup>[24]</sup>进行了对比。冲击能量为 30J、50J 和 90J，对应冲击速度分别为 2.55m/s、3.29m/s 和 4.415m/s。图 5 显示了 50J 冲击下非节点位置的变形模式及不同冲击能量下非节点和节点位置的力-位移曲线对比。结果表明，节点位置冲击时结构刚度较高、力-位移曲线迅速达到峰值，随后因芯层屈曲刚度下降；非节点位置冲击时，面板弯曲主导变形，整体刚度较低，峰值载荷较小且曲线平稳。考虑实际冲击位置的随机性，本研究选择非节点位置进行后续分析与优化。表 2 所列非节点位置的比吸能 SEA、上面板最大挠度  $\delta_{\max}$  及峰值载荷  $F_{\max}$  与实验结果较为一致，表明有限元模型能够较好地反映夹芯梁冲击响应特性，可用于后续参数分析与结构优化研究。



(a) Deformation mode under 50J impact energy.



(b) Impact force-displacement curve at non-nodal points.



(c) Impact force-displacement curve at nodal points.

图 5 模型有效性验证

Fig. 5 Validation of model effectiveness.

表 2 非节点位置冲击的实验与有限元模拟冲击响应结果对比

Table 2 Comparison of experimental and finite element simulation results for impact response at non-nodal positions.

Impact energy (J)	Experimental results			Simulation results			Mean Relative Error
	SEA(J/g)	$\delta_{\max}$ (mm)	$F_{\max}$ (kN)	SEA(J/g)	$\delta_{\max}$ (mm)	$F_{\max}$ (kN)	
30	0.201	11.56	5.31	0.208	11.84	5.43	2.72%
50	0.290	15.06	6.65	0.292	14.93	6.78	1.17%
90	0.530	20.38	9.05	0.522	19.81	9.26	2.21%

本文有限元分析中, 铝合金材料采用 Cowper-Symonds 本构模型描述应变率敏感性, 但未显式考虑波纹芯层可能发生的局部屈曲或薄壁失效。局部屈曲会改变能量耗散路径, 从而影响 SEA 预测精度。因此, SEA 计算基于整体结构响应, 可能在极薄芯层或不利加载条件下偏保守。

## 2.2 输入特征与输出

在本研究中, 芯层高度  $H_c=46\text{mm}$ , 冲击能量  $E=50\text{J}$ 。选取胞元数量  $n$ 、上面板厚度  $t_1$ 、芯层壁厚  $t_c$  以及下面板厚度  $t_2$  作为输入特征。为进一步降低模型训练过程中的误差, 额外引入芯层相对密度  $\rho_c$  作为输入参数, 其计算公式为:

$$\rho_c = \frac{2t_c}{l \sin \theta} \rho \quad (8)$$

其中,  $\rho$  为材料密度,  $l$  为芯层胞元长度,  $t_c$  为芯层壁厚,  $\theta = \arctan \frac{H_c}{l/2}$  为三角形波纹芯层倾斜板与下面板的夹角,  $H_c$  为芯层高度, 参数范围如表 3 所示。

输出特征包括夹芯梁的比吸能 (Specific Energy Absorption, SEA)、上面板最大挠度  $\delta_{\max}$  以及初始峰值载荷  $F_{\max}$ 。比吸能的计算公式为:

$$\text{SEA} = \frac{E_p}{m} \quad (9)$$

其中,  $E_p$  为结构的总吸能, 可通过载荷-位移曲线积分获得;  $m$  为结构总质量。

由于在低速冲击条件下, 夹芯梁下面板的变形较小, 故选取上面板的最大挠度  $\delta_{\max}$  作为主要分析指标, 以更准确地反映结构的变形特征。

表 3 输入特征取值范围

Table 3 Value range of input features.

Input feature	$n$	$t_1(\text{mm})$	$t_c(\text{mm})$	$t_2(\text{mm})$	$\rho_c(\text{g}\cdot\text{cm}^{-3})$
Range	2, 4, 6	1.6~2.4	0.8~1.6	1.6~2.4	0.064~0.276

使用针对离散参数的平衡拉丁超立方抽样 (LHS) 变体生成共 400 组样本, 并使用有限元模拟得到其结果, 抽样结果的样本分布如图 6 所示。随机抽取其中的 320 组样本用于模型的训练, 其余 80 组用于模型的检验。




图 6 拉丁超立方抽样样本在参数空间中的投影分布

Fig. 6 Projection distribution of Latin hypercube sampling samples in the parameter space.

### 3 结果与讨论

#### 3.1 MTL 模型预测冲击结构响应的验证

根据第 1.4 节所述方法建立多任务学习 (MTL) 模型。通过贝叶斯优化获得最优模型结构, 其中共享层设置为 1 层, 包含 64 个神经元; 私有层同样为 1 层, 每个任务包含 32 个神经元。同时为防止过拟合, 设置早停次数为 20。模型采用第 2.2 节所获得的数据集进行训练与测试。在测试集上, 输出结果的决定系数  $R^2$ 、MAE 与 RMSE 用于评估模型预测性能, 其计算公式分别为:

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (10)$$

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (11)$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (12)$$

其中,  $y_i$  为第  $i$  个样本的实际值,  $\hat{y}_i$  为预测值,  $\bar{y}$  为实际值的平均数,  $N$  为样本数量。  $R^2$  越接近 1, MAE 与 RMSE 越接近 0, 则模型性能越好。

为验证 MTL 模型的性能, 本研究将其与支持向量回归 (SVR) 模型进行了对比分析。图 7 给出了两类模型在 10 次随机数据划分下的预测结果统计差异, 并给出了各输出指标 95% 的置信区间, 结果表明, 置信区间宽度均小于 0.012, 说明两种模型均具有良好的重复性。表 4 汇总了两种模型的平均评价指标及训练与预测时间。可以看出, SVR 模型结构相对简单, 训练速度较快, 但各输出的平均  $R^2$  较低, MAE 与 RMSE 较高, 拟合能力有限; 而 MTL 模型虽然训练时间较长, 但在拟合精度方面表现更优, 能够更准确地预测夹芯梁的多项响应指标。

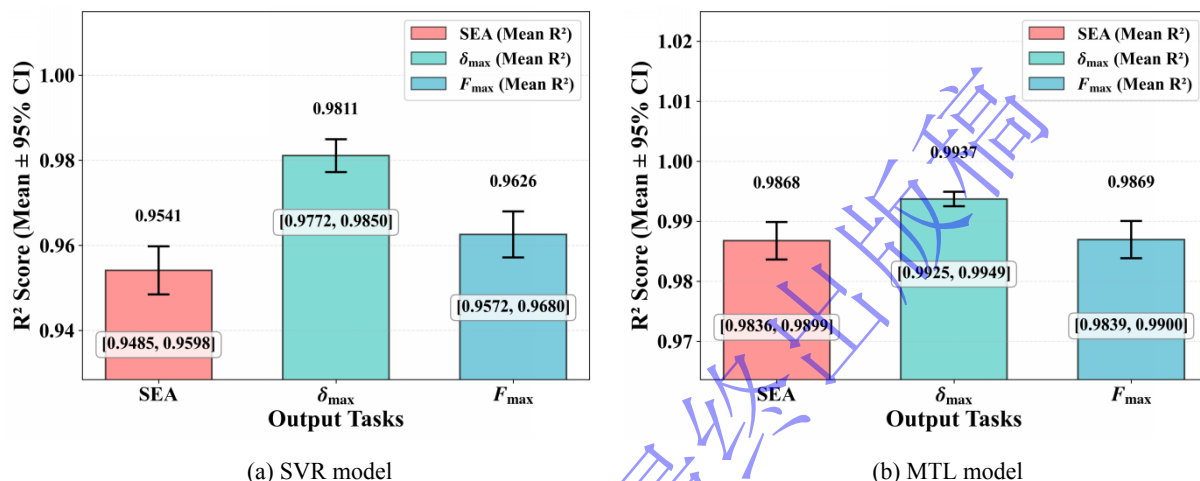


图 7 模型重复训练-测试稳定性验证与性能对比


Fig. 7 Stability verification and performance comparison through repeated training-testing of models.

表 4 SVR 与 MTL 模型性能对比

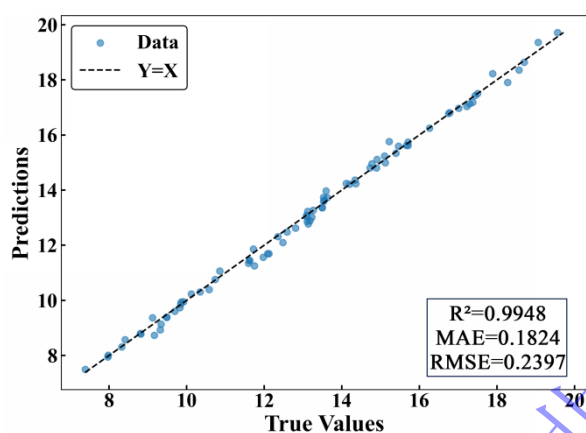
Table 4 Performance comparison between SVR and MTL models.

Model	Output	$R^2$	MAE	RMSE	Total training	Total prediction
					time(s)	time(s)
SVR	SEA	0.9541	0.0076	0.0101	0.1	0.1
	$\delta_{max}$	0.9811	0.3165	0.4015		
	$F_{max}$	0.9626	0.3593	0.4690		
MTL	SEA	0.9868	0.0048	0.0059	2.18	0.1
	$\delta_{max}$	0.9937	0.2037	0.2791		
	$F_{max}$	0.9869	0.2385	0.3124		

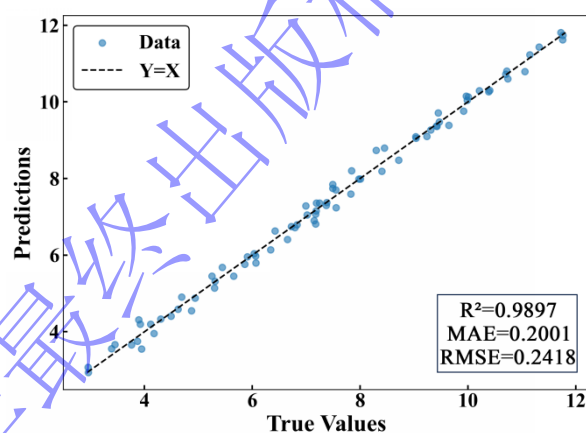
在 10 个 MTL 模型中, 选择综合性能最优的模型用于后续分析与优化。图 8 给出了该模型预测结果与有限元模拟结果的回归关系, 分别对应比吸能 SEA、上面板最大挠度  $\delta_{max}$  以及初始峰值载荷  $F_{max}$ 。结果表明, 测试集上三项输出指标的决定系数  $R^2$  分别为 0.9895、0.9948 和 0.9897, 均接近 1; MAE 与 RMSE 值均接近 0。上述结果表明, MTL 模型在预测夹芯梁冲击响应方面具有较高精度与较好的拟合能力。



(a) Specific energy absorption SEA(J/g).



(b) Maximum top plate deflection  $\delta_{\max}$  (mm).



(c) Initial peak load  $F_{\max}$  (kN).

图 8 测试样本的回归分析

Fig. 8 Regression analysis for test samples.

### 3.2 几何参数对结构响应的影响

本节基于已训练完成的多任务学习 (MTL) 模型, 分析芯层几何参数对波纹夹芯梁冲击响应特性的影响。研究选取芯层胞元数量  $n$ 、上面板厚度  $t_1$ 、芯层壁厚  $t_c$  以及下面板厚度  $t_2$  作为主要变量, 研究其对比吸能 SEA、上面板最大挠度  $\delta_{\max}$  及初始峰值载荷  $F_{\max}$  的影响规律。

#### 3.2.1 芯层胞元数量 $n$ 的影响

在保持上面板厚度  $t_1=2\text{mm}$ 、芯层壁厚  $t_c=1.2\text{mm}$  以及下面板厚度  $t_2=2\text{mm}$  不变的条件下, 利用 MTL 模型预测芯层胞元数量  $n$  (取值 2,4,6) 对波纹夹芯梁冲击响应的影响规律。

图 9(a)给出了上面板最大挠度  $\delta_{\max}$  和初始峰值载荷  $F_{\max}$  随胞元数量  $n$  变化的预测结果。可以看出, 随着  $n$  的增加,  $\delta_{\max}$  呈下降趋势, 而  $F_{\max}$  则随之升高。这主要是由于胞元数量增多导致芯层胞元间距减小且倾斜角增大, 从而使芯层密度和整体刚度提高。结构的变形模式由整体弯曲逐渐转变为局部凹陷, 如图 10 所示。刚度的增加限制了上面板的整体弯曲变形, 导致  $\delta_{\max}$  减小, 同时峰值载荷  $F_{\max}$  增大。

图 9(b)给出了夹芯梁比吸能 SEA 随胞元数量  $n$  变化的预测结果以及各组成部分吸能占比。结果表明, 上面板和芯层是主要吸能区域。整体总吸能  $E_p$  随  $n$  的增加而升高, 但比吸能 SEA 却呈下降趋势。这是因为随着  $n$  的增加, 结构的变形更趋局部化, 而结构质量的增加幅度超过了吸能能力的提升。上面板吸能占比随着  $n$  的增加先减小后增大, 芯层与下面板吸能占比则呈先增加后减小的变化规律。如图 10(a)与图 10(c)所示, 当  $n=2$  时, 芯层支撑能力较弱, 载荷主要集中在上面板, 导

致上面板吸能占比较高；而  $n=6$  时，芯层支撑能力增强，塑性变形减小，上面板吸能占比再次上升。综上可知，随着胞元数量  $n$  的增加，夹芯梁能量分配逐渐趋于优化，其中  $n=4$  时各部分吸能较为均衡，结构综合性能较优。

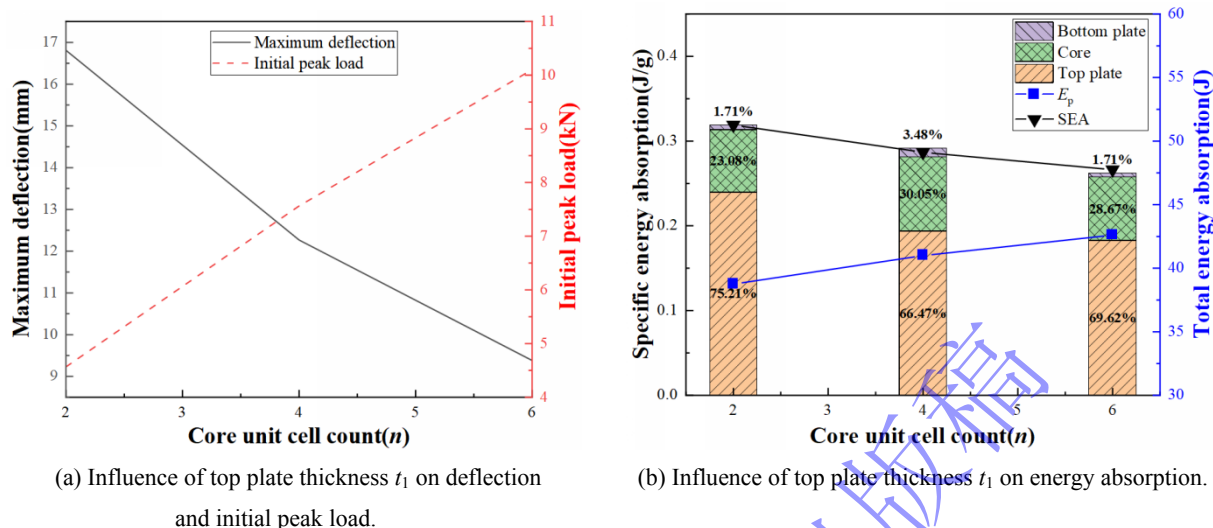


图 9 胞元数量  $n$  对夹芯梁冲击结构响应的影响

Fig. 9 The influence of the core unit cell count  $n$  on the impact structural response of sandwich beams.




图 10 胞元数量  $n$  对夹芯梁变形模式的影响

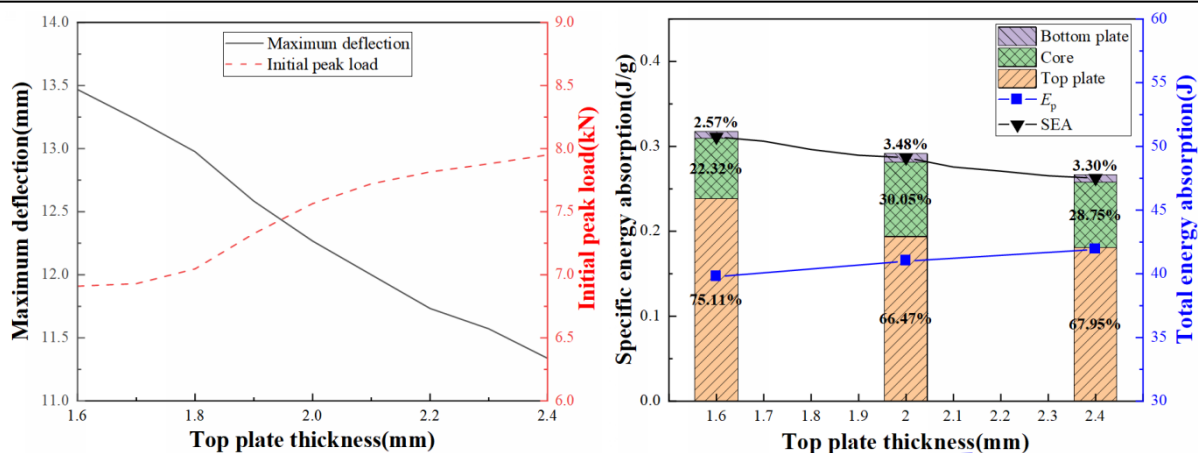
Fig. 10 The influence of the core unit cell count  $n$  on the deformation mode of sandwich beams.

### 3.2.2 上面板厚度 $t_1$ 的影响

在保持芯层胞元数量  $n=4$ 、芯层壁厚  $t_c=1.2\text{mm}$  以及下面板厚度  $t_2=2\text{mm}$  不变的条件下，利用 MTL 模型分析上面板厚度  $t_1$ （范围为  $1.6\text{mm}\sim 2.4\text{mm}$ ）对波纹夹芯梁冲击结构响应的规律。

图 11(a)给出了上面板最大挠度  $\delta_{\max}$  及初始峰值载荷  $F_{\max}$  随上面板厚度  $t_1$  变化的预测结果。结果表明，随着  $t_1$  的增加， $\delta_{\max}$  呈逐渐下降趋势，而  $F_{\max}$  则持续增大。这是由于  $t_1$  增加导致上面板的弯曲刚度提高，从而增强了其抵抗变形的能力，导致整体变形量减小，如图 12 所示。

图 11(b)给出了比吸能 SEA 随上面板厚度  $t_1$  变化的预测结果以及不同  $t_1$  下各组成部分的吸能占比变化规律。可以看出，随着上面板厚度的增加，结构的总吸能  $E_p$  随之增加。然而，由于结构质量的增长幅度更为显著，导致比吸能 SEA 呈下降趋势。上面板的吸能占比随  $t_1$  的增加呈先降低后升高的变化规律，而芯层与下面板的吸能占比则表现为先升高后降低。具体而言，当  $t_1$  较小时，上面板刚度较低，冲击点附近区域发生显著的塑性变形，导致能量主要集中在上面板局部消耗，传递至芯层和下面板的能量较少<sup>[25]</sup>，如图 12(a)所示。随着  $t_1$  的增大，上面板的塑性变形减弱，更多冲击能量能够传递至芯层和下面板，使整体结构的能量吸收更为均匀。当  $t_1$  进一步增大超过一定阈值后，上面板刚度显著提升，再次成为主要的能量吸收部件，其吸能占比随之上升。



(a) Influence of top plate thickness  $t_1$  on deflection and initial peak load. (b) Influence of top plate thickness  $t_1$  on energy absorption.

图 11 上面板厚度  $t_1$  对夹芯梁冲击结构响应的影响

Fig. 11 The influence of top plate thickness  $t_1$  on the impact structural response of sandwich beams.




图 12 上面板厚度  $t_1$  对夹芯梁变形模式的影响

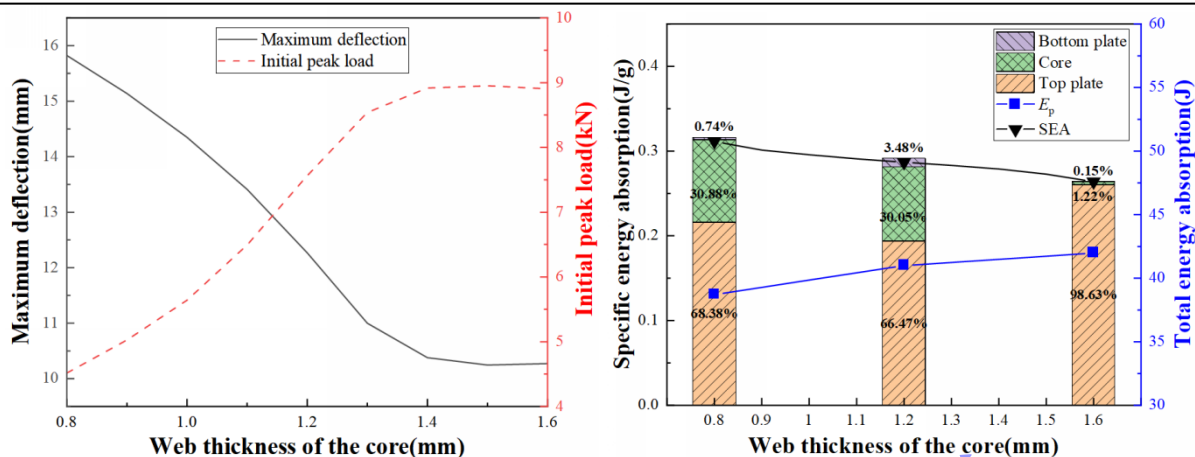
Fig. 12 The influence of top plate thickness  $t_1$  on the deformation mode of sandwich beams.

### 3.2.3 芯层壁厚 $t_c$ 的影响

在保持芯层胞元数量  $n=4$ 、上面板厚度  $t_1=2\text{mm}$  以及下面板厚度  $t_2=2\text{mm}$  不变的条件下，利用 MTL 模型研究芯层壁厚  $t_c$  (范围为  $0.8\text{mm}\sim 1.6\text{mm}$ ) 对波纹夹芯梁冲击结构响应的影响规律。

图 13(a)给出了上面板最大挠度  $\delta_{\max}$  与初始峰值载荷  $F_{\max}$  随  $t_c$  变化的预测结果。结果表明， $\delta_{\max}$  随  $t_c$  增大先逐渐减小后趋于稳定； $F_{\max}$  随  $t_c$  增大先增加后趋于稳定。这是由芯层厚度增加导致芯层密度和整体刚度升高，支撑能力增强，从而限制了上面板的变形，使  $\delta_{\max}$  降低，同时峰值载荷  $F_{\max}$  增大（如图 14(a)和 14(b)所示）。当  $t_c=1.4\text{mm}$  时，芯层塑性变形已不显著，变形模式基本稳定，进一步增加  $t_c$  对  $\delta_{\max}$  和  $F_{\max}$  影响不显著，如图 14(c)所示。

图 13(b)给出了比吸能 SEA 随芯层壁厚  $t_c$  变化的预测结果以及夹芯梁各组成部分的吸能占比随  $t_c$  的变化规律。随着  $t_c$  的增加，结构的总吸能  $E_p$  上升，但比吸能 SEA 下降。具体而言，上面板的吸能占比随  $t_c$  增加先下降后上升，芯层吸能占比呈持续下降趋势，下面板吸能占比先上升后下降。当  $t_c=0.8\text{mm}$  时，芯层支撑刚度较低，发生大范围塑性变形，吸收的能量较多，而传递给下面板的能量较少，导致下面板吸能占比低。当  $t_c=1.2\text{mm}$  时，芯层塑性变形减小，吸收能量减少；随着  $t_c$  继续增加，芯层塑性变形进一步减小（如图 14 所示），芯层吸能占比持续下降，而下面板吸能占比先升高后下降。



(a) Influence of web thickness of the core  $t_c$  on deflection and initial peak load. (b) Influence of web thickness of the core  $t_c$  on energy absorption.

图 13 芯层壁厚  $t_c$  对夹芯梁冲击结构响应的影响

Fig. 13 The influence of web thickness of the core  $t_c$  on the impact structural response of sandwich beams.




图 14 芯层厚度  $t_c$  对夹芯梁变形模式的影响

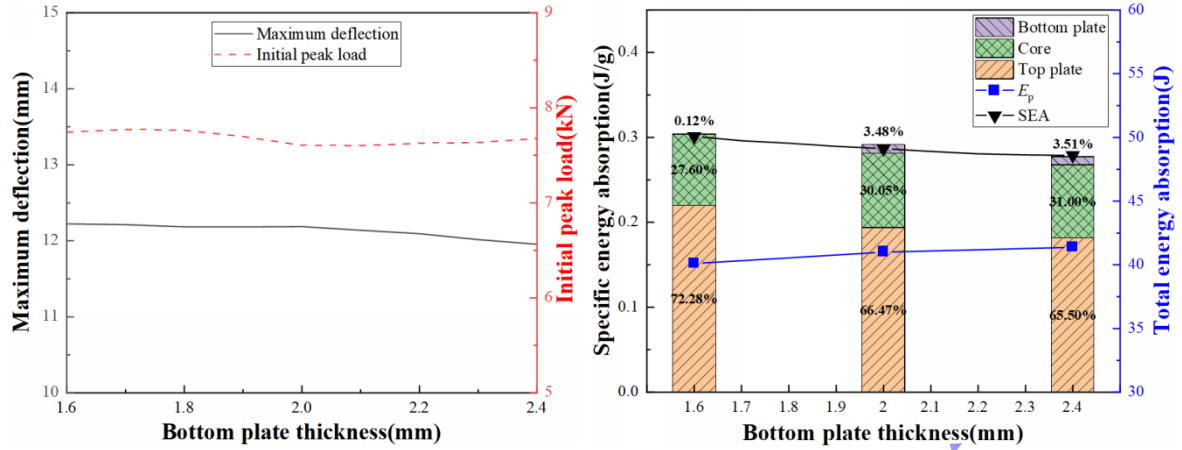
Fig. 14 The influence of web thickness of the core  $t_c$  on the deformation mode of sandwich beams.

### 3.2.4 下面板厚度 $t_2$ 的影响

在保持芯层胞元数量  $n=4$ 、上面板厚度  $t_1=2\text{mm}$  以及芯层壁厚  $t_c=1.2\text{mm}$  不变的条件下，利用 MTL 模型研究下面板厚度  $t_2$ （范围为  $1.6\text{mm}\sim 2.4\text{mm}$ ）对波纹夹芯梁冲击结构响应的影响规律。

图 15(a)给出了上面板最大挠度  $\delta_{\max}$  与初始峰值载荷  $F_{\max}$  随下面板厚度  $t_2$  变化的预测曲线。结果表明，随  $t_2$  的增加， $\delta_{\max}$  与  $F_{\max}$  基本保持不变（如图 16 所示），表明下面板厚度对  $\delta_{\max}$  和  $F_{\max}$  的影响很小。

图 15(b)给出了比吸能 SEA 随下面板厚度  $t_2$  变化的预测曲线以及夹芯梁各组成部分的吸能占比随  $t_2$  变化的情况。随  $t_2$  的增加，夹芯梁的总吸能  $E_p$  升高，但比吸能 SEA 下降。具体表现为，上面板的吸能占比下降，而芯层和下面板的吸能占比升高。这是由于下面板厚度增加导致其抗弯刚度增强，从而提高了抵抗变形的能力，芯层压缩变形更加充分。在这种情况下，芯层仍能有效传递能量，同时下面板吸收的能量增多，因此芯层与下面板的吸能占比呈上升趋势。



(a) Influence of bottom plate thickness  $t_2$  on deflection and initial peak load. (b) Influence of bottom plate thickness  $t_2$  on energy absorption.

图 15 下面板厚度  $t_2$  对夹芯梁冲击结构响应的影响

Fig. 15 The influence of bottom plate thickness  $t_2$  on the impact structural response of sandwich beams.




图 16 下面板厚度  $t_2$  对夹芯梁变形模式的影响

Fig. 16 The influence of bottom plate thickness  $t_2$  on the deformation mode of sandwich beams.

#### 4 夹芯梁结构的优化设计

MTL 模型作为一种高效的替代模型，可用于波纹夹芯梁结构的参数优化设计。为便于描述，可将训练得到的 MTL 模型表示为代理函数形式：

$$[\overline{SEA}, \overline{\delta_{\max}}, \overline{F_{\max}}] = f_{\text{MTL}}(\overline{n}, \overline{t_1}, \overline{t_c}, \overline{t_2}) \quad (13)$$

其中，

$$\begin{cases} \overline{n} = \frac{n - \min(n)}{\max(n) - \min(n)}, & \overline{t_1} = \frac{t_1 - \min(t_1)}{\max(t_1) - \min(t_1)} \\ \overline{t_c} = \frac{t_c - \min(t_c)}{\max(t_c) - \min(t_c)}, & \overline{t_2} = \frac{t_2 - \min(t_2)}{\max(t_2) - \min(t_2)} \\ \overline{SEA} = \frac{SEA^{-1}}{\max(SEA^{-1})}, & \overline{\delta_{\max}} = \frac{\delta_{\max}}{\max(\delta_{\max})}, & \overline{F_{\max}} = \frac{F_{\max}}{\max(F_{\max})} \end{cases}$$

NSGA-II 算法的参数设置如下：种群规模为 200，交叉概率为 0.9，变异概率为 0.1，最大迭代代数 100。为获得综合性能最优解，采用最小距离选择法 (The minimum distance selection method, TMDSM) 确定距离理想最优解 (Utopia Point) 最近的综合最优解 (Knee Point)，其数学表达式为 [26]：

$$D_{\min} = \sqrt{\left(\frac{\overline{\text{SEA}(x)}}{(\overline{\text{SEA}})_{\min}} - 1\right)^2 + \left(\frac{\overline{\delta_{\max}(x)}}{(\overline{\delta_{\max}})_{\min}} - 1\right)^2 + \left(\frac{\overline{F_{\max}(x)}}{(\overline{F_{\max}})_{\min}} - 1\right)^2} \quad (14)$$

#### 4.1 变形优化

为优化夹芯梁的变形性能，选取上面板最大挠度  $\delta_{\max}$  与初始峰值载荷  $F_{\max}$  作为优化目标函数，对夹芯梁的结构进行优化。芯层胞元数量  $n$ 、上面板厚度  $t_1$ 、芯层壁厚  $t_c$  和下面板厚度  $t_2$  为决策变量，优化模型可写为：

$$\min(\overline{\delta_{\max}}, \overline{F_{\max}}) = f_{\text{MTL}}(\overline{n}, \overline{t_1}, \overline{t_c}, \overline{t_2}) \quad (15)$$

$$\text{s.t.} : 0 < \overline{\delta_{\max}}, \overline{F_{\max}}, \overline{n}, \overline{t_1}, \overline{t_c}, \overline{t_2} \leq 1 \quad (16)$$

利用 NSGA-II 算法对上述模型进行求解，获得的 Pareto 前沿如图 17 所示。该解集由 100 个相互非支配的最优解组成。从图中可以看出， $\delta_{\max}$  与  $F_{\max}$  存在明显的竞争关系：当结构变形减小时，峰值载荷呈上升趋势。

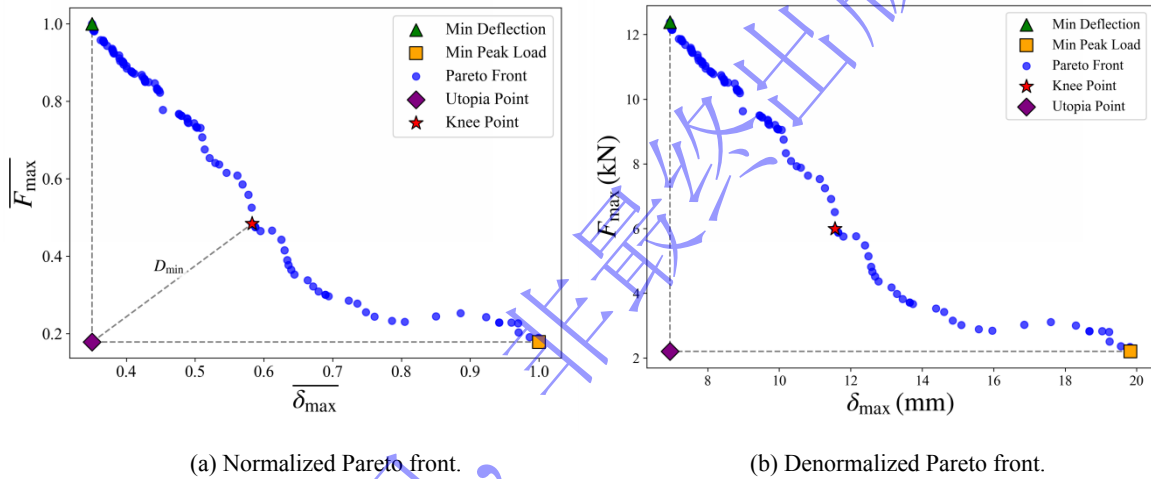


图 17 变形优化的 Pareto 解集

Fig. 17 Pareto optimal solution set for deformation optimization.

通过 TMDSM 方法确定的 Pareto 最优解 (Knee Point) 对应的结构参数为： $n=6$ ， $t_1=2.4\text{mm}$ ， $t_c=1\text{mm}$ ， $t_2=1.6\text{mm}$ ，与原始结构参数的对比如表 5 所示。相较于对照组，优化后的结构上面板挠度  $\delta_{\max}$  降低了 22.71%，初始峰值载荷  $F_{\max}$  降低了 21.35%。优化结果表明，较大的胞元数量  $n$  可减少胞元间距、提高芯层密度与刚度；较大的上面板厚度  $t_1$  可增强结构抗弯能力，从而有效抑制整体变形。而较小的芯层壁厚  $t_c$  有助于降低初始峰值载荷，较小的下面板厚度  $t_2$  则可减少结构总质量。这些参数的协调配置使夹芯梁在变形控制与载荷响应之间实现更优平衡。

表 5 变形优化结果与对照组的比较

Table 5 Comparison of deformation optimization results with those of the control group.

NO.	$n$	$t_1(\text{mm})$	$t_c(\text{mm})$	$t_2(\text{mm})$	MTL		Simulation	
					$\delta_{\max}(\text{mm})$	$F_{\max}(\text{kN})$	$\delta_{\max}(\text{mm})$	$F_{\max}(\text{kN})$
Knee Point	6	2.3	1	2	11.56	5.38	11.64	5.23
Control group	2	2	1.8	2	-	-	15.06	6.65

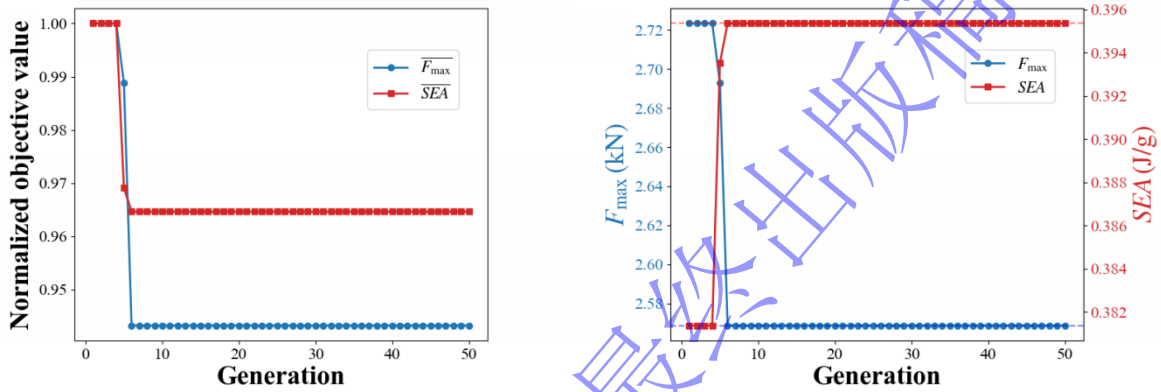
#### 4.2 吸能优化

为提高夹芯梁的吸能性能，本节以夹芯梁比吸能 SEA 和初始峰值载荷  $F_{\max}$  作为优化目标，对波纹夹芯梁的几何结构参数进行优化。芯层胞元数量  $n$ 、上面板厚度  $t_1$ 、芯层壁厚  $t_c$  和下面板厚度  $t_2$  被选为决策变量，建立的多目标优化模型可写为：

$$\min(\overline{SEA}, \overline{F_{\max}}) = f_{\text{MTL}}(\overline{n}, \overline{t_1}, \overline{t_c}, \overline{t_2}) \quad (17)$$

$$\text{s.t.} : 0 < \overline{SEA}, \overline{F_{\max}}, \overline{n}, \overline{t_1}, \overline{t_c}, \overline{t_2} \leq 1 \quad (18)$$

利用 NSGA-II 算法对上述模型进行求解。结果表明，比吸能 SEA 与初始峰值载荷  $F_{\max}$  不存在显著的冲突关系，因此 Pareto 解集迅速收敛至单一最优点。为了直观展示优化过程，采用迭代历史图描绘 Pareto 解的收敛情况，其中迭代次数调整为 50，如图 18 所示。可以观察到，算法在第 6 次迭代时即收敛至最优解，表明优化过程稳定且高效。



(a) Normalized Pareto convergence history. (b) Denormalized Pareto convergence history.

图 18 吸能优化的 Pareto 迭代图

Fig. 18 Pareto iteration plot for energy absorption optimization.

通过 TMDSM 方法确定的最优解 (Knee Point) 对应的结构参数为： $n=2$ ， $t_1=1.6\text{mm}$ ， $t_c=0.8\text{mm}$ ， $t_2=1.6\text{mm}$ ，与原始结构的对比如表 6 所示。相较于对照组，优化后结构的比吸能 SEA 提高了 30.64%，而初始峰值载荷  $F_{\max}$  降低了 59.70%，表现出显著的吸能性能提升和冲击响应优化效果。

表 6 吸能优化结果与对照组的比较

Table 6 Comparison of energy absorption optimization results with those of the control group.

NO.	$n$	$t_1(\text{mm})$	$t_c(\text{mm})$	$t_2(\text{mm})$	MTL		Simulation	
					SEA(J/g)	$F_{\max}(\text{kN})$	SEA(J/g)	$F_{\max}(\text{kN})$
Knee Point	2	1.6	0.8	1.6	0.395	2.57	0.388	2.68
Control group	2	2	1.8	2	-	-	0.297	6.65

根据第 3 节的分析中可知，随着几何参数的增大，夹芯梁质量的增长速度超过吸能的提升幅度。因此，减小几何参数尺寸使结构整体刚度降低，有助于显著减小初始峰值载荷。综上，采用较小尺寸几何参数配置的夹芯梁在吸能效率与载荷控制方面表现最优。

### 4.3 吸能与变形优化

为提高夹芯梁的综合性能，本节以比吸能 SEA、上面板最大挠度  $\delta_{\max}$  以及初始峰值载荷  $F_{\max}$  作为多目标优化指标，对波纹夹芯梁的几何结构参数进行优化。芯层胞元数量  $n$ 、上面板厚度  $t_1$ 、芯层壁厚  $t_c$  和下面板厚度  $t_2$  被选为决策变量，优化模型可表示为：

$$\min(\overline{SEA}, \overline{\delta_{\max}}, \overline{F_{\max}}) = f_{\text{MTL}}(\overline{n}, \overline{t_1}, \overline{t_c}, \overline{t_2}) \quad (19)$$

$$\text{s.t.}: 0 < \overline{\text{SEA}}, \overline{\delta_{\max}}, \overline{F_{\max}}, n, t_1, t_c, t_2 \leq 1 \quad (20)$$

利用 NSGA-II 算法求解该多目标优化问题，得到的 Pareto 前沿如图 19 所示，由 100 个相互非支配的最优解组成。

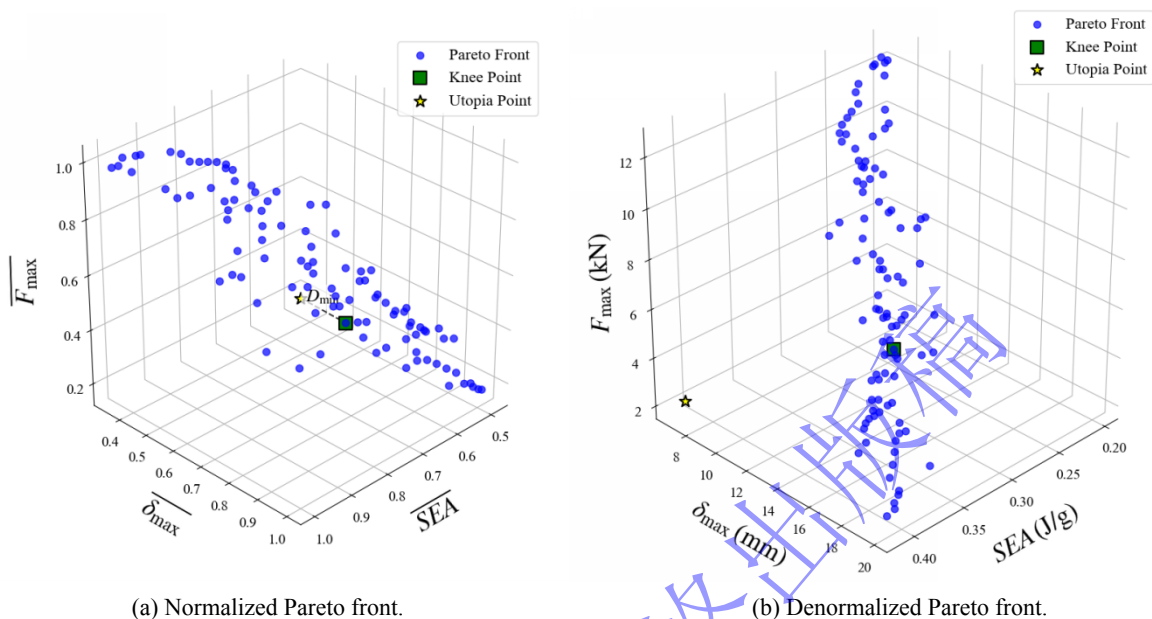


图 19 吸能与变形优化的 Pareto 解集

Fig. 19 Pareto optimal solution set for energy absorption and deformation optimization.

通过 TMDSM 方法选取的综合最优解对应的几何参数为： $n=4$ ， $t_1=2.3\text{mm}$ ， $t_c=0.9\text{mm}$ ， $t_2=1.6\text{mm}$ ，与原始结构的对比如表 7 所示。优化后结构比吸能 SEA 提高了 2.36%， $\delta_{\max}$  降低了 5.64%，初始峰值载荷  $F_{\max}$  降低了 29.92%。分析结果表明，当同时优化 SEA、 $\delta_{\max}$  和  $F_{\max}$  三个目标时，由于目标之间存在竞争关系，Pareto 前沿表明各性能提升空间有限。任何一项性能的显著提升都会以牺牲其他指标为代价。因此，在综合优化过程中采取折中策略，使各几何参数取中间值或在 Pareto 解的指导下形成折中设计方案。该方案未追求单项性能极值，而是在相互竞争的指标间实现性能的平衡优化。

表 7 吸能与变形优化结果与对照组的比较

Table 7 Comparison of energy absorption and deformation optimization results with those of the control group.

NO.	$n$	$t_1(\text{mm})$	$t_c(\text{mm})$	$t_2(\text{mm})$	MTL			Simulation		
					SEA(J/g)	$\delta_{\max}(\text{mm})$	$F_{\max}(\text{kN})$	SEA(J/g)	$\delta_{\max}(\text{mm})$	$F_{\max}(\text{kN})$
Knee Point	4	2.3	0.9	1.6	0.311	14.11	4.71	0.304	14.21	4.66
Control group	2	2	1.8	2	-	-	-	0.297	15.06	6.65

#### 4.4 可靠性验证

为排除 MTL 预测值与有限元仿真结果偶然吻合的可能性，对优化结果进行了可靠性验证。图 20 给出了各指标预测值与模拟值的相对误差和绝对误差，结果表明，所有指标的相对误差最大均未超过 5%。此外，采用 Wilcoxon 符号秩检验对三项优化指标进行统计显著性分析，结果如表 8 所示。该检验的零假设为 MTL 预测值与有限元仿真值之间无显著差异。P 值大于 0.05 表明在 0.05 显著性水平下不能拒绝原假设，即两者不存在统计显著差异。由表 8 可知，各指标的平均相对误差均在 3% 以内，且 P 值均大于 0.05，说明预测值与仿真值之间不存在统计显著差异，可以排除结果偶

然性的影响。

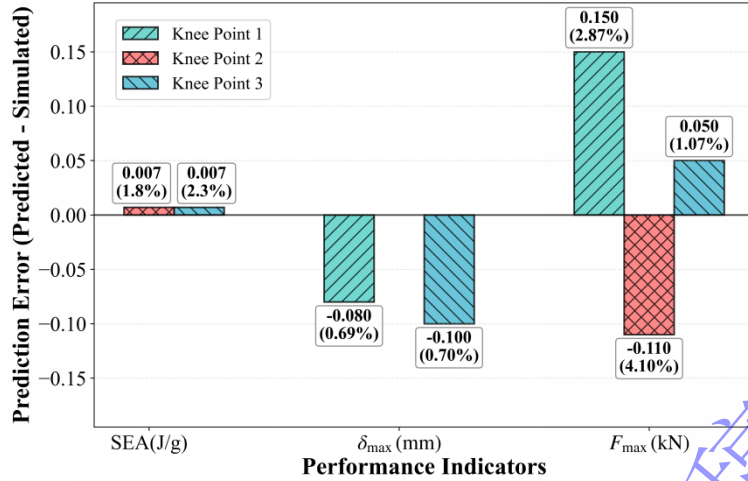


图 20 预测结果与有限元模拟结果误差

Fig. 20 Error between prediction and finite element simulation results.

表 8 统计显著性分析

Table 8 Statistical significance analysis.

Metrics	SEA	$\delta_{max}$	$F_{max}$
Mean Relative Error	2.05%	0.70%	2.68%
P-value	0.5	0.5	0.75

## 5 结 论

本研究基于硬参数共享的多任务学习 (MTL) 框架, 构建了一种预测低速冲击载荷作用下夹芯梁结构响应的机器学习建模与优化流程。采用 ABAQUS 对夹芯梁冲击过程进行数值建模与批量仿真, 所得数据用于模型训练与验证。结果表明, 该 MTL 模型在预测精度与计算效率方面均表现稳定, 可作为有限元分析 (FEA) 的有效补充, 用于夹芯梁冲击响应的快速预测评估。在此基础上, 系统分析了几何参数对冲击响应的影响规律, 并将模型应用于工程优化研究。主要结论如下:

(1) 经贝叶斯优化后的 MTL 模型在所研究的 50J 冲击工况下能够同时实现多指标预测, 其预测结果与有限元模拟保持较好的一致性, 测试集中各输出量的决定系数  $R^2$  均达到 0.989 以上, 表明该模型不仅在预测精度方面表现良好, 也可作为有限元分析的辅助工具用于响应预测与工程优化分析。

(2) 参数敏感性分析结果表明, 随着芯层胞元数量  $n$ 、上面板厚度  $t_1$ 、芯层壁厚  $t_c$  与下面板厚度  $t_2$  的增大, 比吸能 SEA 均呈下降趋势。在上面板最大挠度  $\delta_{max}$  与初始峰值载荷  $F_{max}$  的响应中,  $n$  与  $t_c$  为主要影响因素, 且  $t_c$  存在性能饱和和阈值;  $t_1$  的影响居中, 而  $t_2$  的作用相对较小。

(3) 多目标优化结果表明, 不同设计目标对应不同的最优几何参数组合。当目标为控制结构变形并降低峰值载荷时, 较大的  $n$  和  $t_1$  以及较小的  $t_c$  和  $t_2$  更为有利; 而当目标为提高比吸能并降低初始峰值载荷时, 整体较小的几何参数配置更具优势。

本研究基于机器学习对夹芯梁冲击响应及优化设计进行了预测。后续工作可重点拓展两方面: 一是引入材料非线性与损伤演化机制, 以提升模型在复杂载荷条件下的适用性; 二是扩展至多种芯层结构及多尺度夹芯体系的优化设计, 并探索与实时监测系统结合, 实现夹芯结构冲击响应的在线预测与自适应优化, 为轻量化与高性能结构设计提供支撑。

## 参考文献

- [1] ZHANG D, ZHAO Z, DU S, et al. Dynamic response of ultralight all-metallic sandwich panel with 3D tube cellular core to shallow-buried explosives [J]. *Science China Technological Sciences*, 2021, 64(7): 1371-1388.
- [2] LEVT, HANS, GOONS. Advanced sandwich structures for thermal protection systems in hypersonic vehicles: A review [J]. *Composites Part B: Engineering*, 2021, 226: 109301.
- [3] WANG J, SHI C, YANG N, et al. Strength, stiffness, and panel peeling strength of carbon fiber-reinforced composite sandwich structures with aluminum honeycomb cores for vehicle body [J]. *Composite Structures*, 2018, 184: 1189-1196.
- [4] CHAHARDOLI S, ALIA A, S. G, et al. Investigation of the bending and crushing for the light-weight structures used in vehicle's radiator [J]. *Mechanics Based Design of Structures and Machines*, 2023, 51(8): 4491-4507.
- [5] SHU C, ZHAO S, HOU S. Crashworthiness analysis of two-layered corrugated sandwich panels under crushing loading [J]. *Thin-Walled Structures*, 2018, 133: 42-51.
- [6] LIU K, ZONG S, LI Y, et al. Structural response of the U-type corrugated core sandwich panel used in ship structures under the lateral quasi-static compression load [J]. *Marine Structures*, 2022, 84: 103198.
- [7] RUBINO V, DESHPANDE V S, FLECK N A. The dynamic response of end-clamped sandwich beams with a Y-frame or corrugated core [J]. *International Journal of Impact Engineering*, 2008, 35(8): 829-844.
- [8] RUBINO V, DESHPANDE V S, FLECK N A. The three-point bending of Y-frame and corrugated core sandwich beams [J]. *International Journal of Mechanical Sciences*, 2010, 52(3): 485-494.
- [9] ST-PIERRE L, DESHPANDE V S, FLECK N A. The low velocity impact response of sandwich beams with a corrugated core or a Y-frame core [J]. *International Journal of Mechanical Sciences*, 2015, 91: 71-80.
- [10] XIA F, YU T X, DURANDET Y, et al. Triangular corrugated sandwich panels under longitudinal bending [J]. *Thin-Walled Structures*, 2021, 169: 108359.
- [11] LIU JZ, LI S, GUO J, et al. Machine learning (ML) based models for predicting the ultimate bending moment resistance of high strength steel welded I-section beam under bending [J]. *Thin-Walled Structures*, 2023, 191: 111051.
- [12] FORD E, MANEPARAMBIL K, KUMAR A, et al. Transfer (machine) learning approaches coupled with target data augmentation to predict the mechanical properties of concrete [J]. *Machine Learning with Applications*, 2022, 8: 100271.
- [13] YANG L, LIN H, WEI L, et al. Application of a novel machine learning model for the prediction and optimization of anti-blast performance of sandwich honeycomb blast walls [J]. *Ocean Engineering*, 2024, 312: 119217.
- [14] FANG X, SHEN H-S, WANG H. Three-point bending behaviors of sandwich beams with data-driven 3D auxetic lattice core based on deep learning [J]. *Composite Structures*, 2025, 354: 118751.
- [15] ANDIKA, SANTOSA S P, WIDAGDO D, et al. Design and multi-objective optimization of auxetic sandwich panels for blastworthy structures using machine learning method [J/OL] 2024, 14(23):10831.
- [16] QIU WJ, KUN L, SHUAI Z, et al. An optimisation method for anti-blast performance of corrugated sandwich plate structure based on neural network and sparrow search algorithm [J]. *Ships and Offshore Structures*, 2024, 19(8): 1028-1043.
- [17] TEIMOURI A, MAYSAM A, SAEED K, et al. Design optimization of additively manufactured sandwich beams through experimentation, machine learning, and imperialist competitive algorithm [J]. *Journal of Engineering Design*, 2024, 35(3): 320-337.
- [18] MCKAY M, BECKMAN R, CONOVER W. A comparison of three methods for selecting vales of input variables in the analysis of output from a computer code [J]. *Technometrics*, 1979, 21: 239-245.
- [19] CARUANA R. Multitask learning [J]. *Machine Learning*, 1997, 28(1): 41-75.
- [20] SNOEK J, LAROCHELLE H, ADAMS R P. Practical Bayesian Optimization of Machine Learning Algorithms[C]//BARTLETT P L, PEREIRA F C N, BURGESS C J C, et al. *Advances in Neural Information Processing Systems 25: Proceedings of the 26th Annual Conference on Neural Information Processing Systems 2012*. Red Hook, NY: Curran Associates, Inc, 2012: 2960-2968.
- [21] DEB K, PRATAP A, AGARWAL S, et al. A fast and elitist multiobjective genetic algorithm: NSGA-II [J]. *IEEE Transactions on*

- Evolutionary Computation, 2002, 6(2): 182-197.
- [22] JING L, SU X, CHEN D, et al. Experimental and numerical study of sandwich beams with layered-gradient foam cores under low-velocity impact [J]. Thin-Walled Structures, 2019, 135: 227-244.
- [23] LIU Z, YU Y, YANG Z, et al. Dynamic experimental studies of A6N01S-T5 aluminum alloy material and structure for high-speed trains [J]. Acta Mechanica Sinica, 2019, 35(4): 763-772.
- [24] YU Z, LIU K, ZHOU X, et al. Low-velocity impact response of aluminum alloy corrugated sandwich beams used for high-speed trains [J]. Thin-Walled Structures, 2023, 183: 110375.
- [25] 荣吉利, 王圣龙, 陈子超, 等. 水下爆炸冲击载荷下波纹夹芯板动态响应及结构优化设计 [J]. 北京理工大学学报自然版, 2024, 44(7): 679-691.
- RONG JL, WANG SL, CHEN ZC, et al. Dynamic response and structural optimal design of corrugated sandwich panel subjected to underwater [J]. Transactions of Beijing Institute of Technology, 2024, 44(7): 679-691.
- [26] 卢传浩, 周宇琦, 曹勇, 等. 新型梯度连续可控夹层板抗冲击性能研究及优化 [J]. 力学学报, 2024, 56(6): 1713-1726.
- LU CH, ZHOU QY, CAO Y, et al. Reserch and optimization of impact resistance of novel gradient continuous controllable sandwich panels [J]. Chinese Journal of Theoretical and Applied Mechanics, 2024, 56(6): 1713-1726.

## Impact Response and Design Optimization of Triangular Corrugated Sandwich Beams: A Machine Learning Approach

LI Dong, ZHANG Xiaobin, LIU Zhifang\*, LEI Jianyin

(School of Aerospace Engineering, Taiyuan University of Technology, Taiyuan 030024, Shanxi, China)

**Abstract:** To enhance the prediction accuracy of low-velocity impact performance and improve the structural design efficiency of triangular corrugated sandwich beams, this paper proposes a machine learning modeling and optimization process for the impact response of sandwich beams based on a hard-parameter-sharing multi-task learning (MTL) framework. A sample dataset is generated using finite element models, and the rationality of the models is validated against existing experimental results. Subsequently, an MTL model is trained to simultaneously predict the structural specific energy absorption (SEA), maximum deflection of the top panel, and initial peak load. The results show that the MTL model optimized via Bayesian optimization demonstrates strong predictive performance under a 50 J impact energy condition. The predictions align well with the finite element simulation results, with the coefficient of determination  $R^2$  for all output variables in the test set exceeding 0.989, thereby validating the effectiveness and reliability of the model in response prediction and engineering optimization analysis. Parameter sensitivity analysis reveals that the core cell count and core wall thickness have the most significant influence on structural stiffness, followed by the top panel thickness, while the bottom panel thickness has a relatively minor impact. Moreover, the core wall thickness exhibits a certain saturation threshold in terms of performance enhancement. In combination with the Non-dominated Sorting Genetic Algorithm II (NSGA-II), multi-objective optimization analysis are conducted focusing on deformation characteristics, energy absorption performance, and comprehensive performance, and yields optimal parameter configurations that meet different engineering design requirements for sandwich beams.

**Keywords:** machine learning; corrugated sandwich beam; impact response; performance prediction; structural optimization