爆 炸 与 冲 击
Explosion and Shock Waves

DOI：10.11883/bzycj-2025-0288

数据驱动点阵超材料多目标优化设计*

肖李军[1,3]，朱艳林[1]，石高泉[2]，李依男[1]，李润枝[1]，惠旭龙[3]，张瑞刚[2]，宋卫东[1]

（1.北京理工大学爆炸科学与安全防护全国重点实验室，北京 100081；
2.晋西工业集团有限责任公司，山西 太原 030027；
3.中国飞机强度研究所，强度与结构完整性全国重点实验室，陕西 西安 710065）

摘 要：桁架类点阵超材料是一类超轻质承载吸能材料，在冲击防护领域具有广阔的应用前景。然而，由于点阵超材料细观构型参数空间庞大，且构型参数与力学响应之间存在复杂的非线性关系，其性能优化面临巨大挑战。针对上述问题，基于桁架类点阵超材料的细观结构特征，提出了一种高效的快速数字化建模方法，并利用 Python 脚本驱动 Abaqus 仿真软件，实现了材料的批量化建模与仿真分析。在此基础上，通过有限元数值模拟建立了不同构型点阵超材料的准静态压缩性能数据集，并利用实验验证了数据集的可靠性。随后，训练了一个人工神经网络（Artificial Neural Network， ANN）模型作为代理函数，并将其嵌入非支配排序遗传算法（Non-dominated Sorting Genetic Algorithm II，NSGA-II），对点阵超材料开展多目标优化设计，获得了具有高承载能力、高吸能特性以及兼顾承载吸能性能的点阵超材料构型。研究结果表明，融合机器学习技术与有限元仿真，可有效降低优化设计的计算成本，为复杂点阵超材料的快速性能优化与定制化设计提供技术支撑。

关键词：点阵超材料；机器学习；遗传算法；多目标优化；增材制造

中图分类号：TQ028.1　　**国标学科代码：**13015　　**文献标识码：**A

Data-driven multi-objective optimization for lattice-based metamaterials

XIAO Lijun[1,3]，ZHU Yanlin[1]，SHI Gaoquan[2]，LI Yinan[1]，LI Runzhi[1]，HUI Xulong[3]，ZHANG Ruigang[2]，SONG Weidong[1]

(*1. State Key Laboratory of Explosion Science and Technology, Beijing Institute of Technology, Beijing 100081, China;*
2. Jinxi Industries Group Co.，Ltd, Taiyuan 030027, Shanxi, China;
3. National Key Laboratory of Strength and Structural Integrity, Aircraft Strength Research Institute of China, Xian 710065, Shanxi, China)

Abstract: Strut-based lattice metamaterials represent a class of ultra-lightweight, load-bearing, and energy-absorbing materials with broad application prospects in fields such as impact protection, aerospace engineering, and lightweight structural design. Owing to their unique periodic architectures and adjustable meso-structural parameters, these materials exhibit exceptional

*收稿日期：2025-09-01；　修回日期：2025-11-24；
基金项目：国家自然科学基金（12372349, 12172056, 12572429, 12002049）；爆炸科学与安全防护全国重点实验室自主课题（YBKT25–05）；强度与结构完整性全国重点实验室开放基金（LSSIKFJJ202404009）
第一作者：肖李军（1991－ ），男，博士，副教授. E-mail: xljbit@bit.edu.cn；
通信作者：宋卫东（1975－ ），男，博士，教授. E-mail: swdgh@bit.edu.cn。

mechanical tunability and multifunctional potential. However, due to the vast parameter space of mesoscopic configurations, and the highly nonlinear relationship between the structural geometry and the mechanical response, the optimization of mechanical performance for lattice metamaterials remains a formidable challenge. Based on the meso-structural characteristics of strut-based lattice metamaterials, an efficient rapid digital modeling method was proposed. A Python script combined with Abaqus software was utilized for the rapid modeling of truss lattice metamaterials and fast calculations about the mechanical properties of the metamaterials. Based on the calculation results, a machine learning dataset was constructed. Three types of truss lattice structures were randomly selected and additively manufactured. Quasi-static compression tests on these three lattice structures were conducted using a universal testing machine to verify the accuracy of the dataset. Subsequently, an Artificial Neural Network (ANN) was trained to rapidly predict the mechanical properties of the truss lattice metamaterials. Focusing on the load-bearing capacity, energy absorption capability, and the concurrent optimization of both, a Non-dominated Sorting Genetic Algorithm II (NSGA-II) was employed. The well-trained ANN served as a surrogate model embedded within NSGA-II. Lattice configurations that exhibited high load-bearing capacity and superior energy absorption characteristics were generated by the optimization process. These configurations also achieved a balance between load-bearing and energy-absorption performance, facilitating the optimization design of truss lattice metamaterials. Additionally, simulation validations confirmed the reliability of the optimization outcomes, demonstrating the effectiveness of integrating ANN with evolutionary algorithms for the advanced design of metamaterials. By integrating machine learning with numerical simulations, the computational cost of optimization design was effectively reduced, offering support for the rapid performance optimization and customized design of complex lattice metamaterials.

Keywords: Lattice metamaterial; Machine learning; Genetic algorithm; Multi-objective optimization; Additive manufacturing

点阵超材料是由基本晶胞单元周期性排列构成的多孔结构，其力学性能主要取决于晶胞构型。这类材料通常具备超轻质、高强度、高刚度及高能量吸收率等优异特性[1-5]，可被广泛应用于航空航天、兵器工业和交通运输等领域。依据结构特征，点阵超材料可分为二维[6-8]和三维结构[9-11]。其中，三维桁架式点阵超材料为开孔结构，具有制备工艺简便、设计自由度大等优势[12]，在极低相对密度下展现出优异的承载吸能性能[13-14]，成为轻质防护材料结构设计领域的研究热点。

目前，国内外研究人员主要通过实验测试、理论解析和数值模拟相结合的方法，大量开展了点阵超材料力学性能与结构设计方面的研究。Tancogne-Dejean 等[15]通过试验和数值模拟，分析了八面体点阵超材料的单轴静动态压缩性能，发现其比吸能是相对密度的单调递增函数，且优于传统蜂窝材料；Epasto 等[16]研究了低速冲击下菱形十二面体点阵超材料的动力学行为，发现其力学性能随胞元尺寸的增加而降低；Wang 等[17]设计了多种胞元复合的点阵超材料，结合理论分析，阐明了不同几何参数对复合点阵超材料力学性能的影响机制，并通过实验和数值模拟验证了理论分析的准确性。然而，实验经济与时间成本高、传统有限元分析效率低、周期性假设受限等问题，制约了大规模复杂点阵结构的设计优化[18-20]。

随着计算机硬件的进步以及机器学习算法的快速发展，数据驱动方法为研究点阵超材料细观结构与其力学响应之间的复杂关系提供了新的选择[21,22]。Peloquin 等[23]提出了一个机器学习框架，基于基体材料力学参数与结构的孔隙率，成功预测了 3D 打印 gyroid 点阵超材料的轴向拉伸性能；Glaesener 等[24]构建了一种机器学习模型，仅根据桁架点阵超材料的力学响应，就可以预测制备过程中的几何缺陷情况，从而为设计制备具有更优异力学性能的桁架点阵超材料提供了依据；Yu 等[25]将双相异构点阵超材料表示为 4×4 的矩阵，通过构建 ANN 模型，实现了对点阵超材料空间特征的读取、力学响应的预测以及定制化逆向设计。尽管目前关于数据驱动点阵超材料优化设计已有不少研究，但很多基于机器学习设计点阵超材料的方法都缺少优化目标作为导向，一般点阵超材料的样本空间是巨大的，人为设计的目标变量数值无法实现最优设计，且人为设计的目标变量数值不一定合理。

基于此，本文利用大规模数值模拟构建了不同细观结构点阵超材料的力学响应数据集，并通过实验验证了数据集的可靠性。在此基础上，构建了人工神经网络模型，并将其作为多目标遗传优化算法的代理函数，开展不同目标性能的点阵超材料优化设计。

1 数据集构建与实验验证

1.1 点阵超材料的建模与制备

桁架点阵超材料由杆单元以及相邻的节点连接而成。为实现对不同构型点阵超材料的批量化建模与数值模拟，本文采用八节点立方体作为晶胞的 1/8 单元，通过调控节点间杆件的连接模式生成不同的晶胞构型。节点两两连接最多可形成 28 种杆件组合，经三坐标平面镜像操作后，即可构建完整的点阵超材料晶胞结构（具体建模流程见图 1(a)-(d)）。在基于随机连接规则生成晶胞构型的过程中，部分组合可能会形成孤立杆件或局部非连通的几何结构，为避免此类不完整构型对后续仿真和优化结果的影响，在建模阶段剔除存在孤立杆件、非连通节点或其它不符合结构完整性要求的构型，确保最终结构库仅包含拓扑完整、可实际制备的桁架点阵结构。为平衡轻量化与打印可行性，限定 1/8 单元内杆件数量≤9 根，相对体积分数≤0.15，由此形成千万量级的结构样本空间。此外，采用 4×4×4 晶胞布局，以平衡计算效率与研究需求。

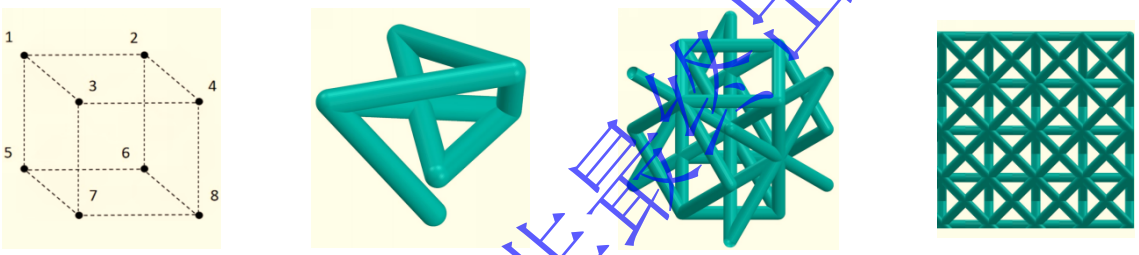

(a) RVE (b) Randomly Generate (c) Mirror (d) Array

图 1 点阵超材料建模过程

Fig.1 Modeling process of lattice metamaterial

实验所需点阵超材料试样采用光固化成型技术制备，所使用的增材制造设备为 Form3 桌面级立体光刻打印机。该设备的激光器功率为 250 mW，光斑直径为 0.085 mm，工作温度设定为 35 ℃，XY 平面分辨率达到 0.025 mm。为了提高成型精度，打印层厚设置为 0.05 mm。此外，为满足设备工艺要求，设计的点阵超材料晶胞尺寸为 15 mm，晶胞内杆件直径为 1.5 mm。

1.2 准静态压缩实验

为验证数值仿真数据集的准确性，采用电子万能试验机（SUNS, UTM5004）对所制备的点阵超材料试样开展准静态压缩实验。点阵试样高度为 60 mm，实验加载应变率设定为 0.001 s^{-1}，对应的加载速度为 3.6 mm/min，加载至试样被完全压实。实验过程中，利用压头上部的传感器记录压头的加载力与位移，从而可以计算出点阵超材料压缩过程的名义应力应变曲线。同时，利用工业相机记录试样变形的全过程，用于与数值模拟结果进行对比分析。

1.3 数值模拟分析

1.3.1 基体材料力学性能与材料模型

本文选用具有一定强度且韧性较好的 Tough-2000 树脂材料作为点阵超材料的基体材料，材料密度为 1110 kg/m^3。为获得其力学性能参数用于数值模拟，根据 ASTM-D638-14 标准直接打印制备了板状试样，并利用材料试验机开展准静态拉伸实验。图 2 给出了实验所得基体材料的名义应力应变曲线和真实应力应变曲线，可以确定其弹性模量为 1051 MPa，泊松比设定为 0.3。此外，选用各向同性塑

性强化模型描述材料的塑性行为，基于材料的真实应力-应变曲线，提取有效塑性应变与应力数据点，直接导入 ABAQUS 中用于后续模拟计算。

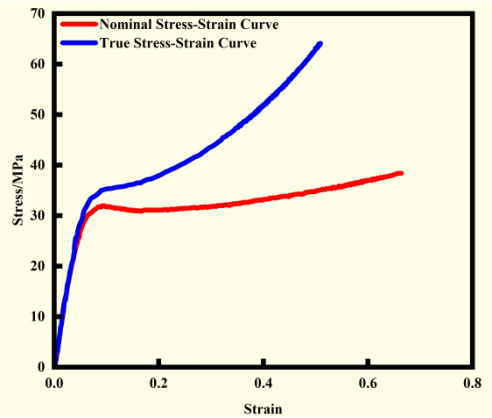

图 2 Tough2000 的拉伸应力应变曲线

Fig.2 Tensile stress-strain curves of Tough2000

1.3.2 结构建模与仿真

本研究基于 ABAQUS 平台构建梁单元有限元模型，用于模拟点阵超材料在准静态压缩载荷下的力学响应，并生成机器学习所需的数据集。根据 1.1 节描述的建模方法，利用 Python 脚本随机生成了超过 20,000 组点阵结构。每组结构采用一个 28 维的二元（0-1）向量进行编码，其中“1”表示杆件存在，“0”表示杆件缺失。

所建立的有限元模型包括加载平台、点阵试样和支撑平台（如图 3）。其中，上、下平台均设置为刚体，并通过其中心参考点施加载荷与边界条件；考虑到梁单元在模拟恒定杆径结构方面的高效性和准确性，采用线性梁单元（B31）构建点阵结构模型，杆径设定为 1.5 mm，该单元类型能够考虑剪切变形的影响。模型中的接触定义采用通用接触，法向行为定义为“硬接触”， 切向行为则采用摩擦系数为 0.2 的罚函数定义。经网格敏感性分析，确定加载平台的单元尺寸为 8 mm，点阵杆件的单元尺寸为 1 mm。压缩过程中，固定下平台，上平台以 1 m/s 的速度沿 Z 轴负方向移动施加载荷，计算采用 ABAQUS/Explicit 求解器。依据 Sigit 等[26]的研究，当模型总动能远小于总内能，且不同加载速率下的力-位移曲线无明显差异时，可忽略应变率效应的影响。因此，采用显式算法，并通过提高加载速度的方式模拟准静态过程是可行的。

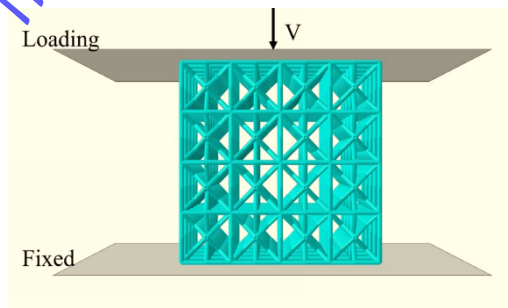

图 3 点阵超材料有限元模型

Fig.3 Finite element model of lattice metamaterial

模型参数设定完成后，使用 Python 脚本中的循环结构遍历所有随机生成的 20,000 余组桁架点阵超材料，依次执行其准静态压缩过程的有限元仿真计算。所有仿真计算结束后，遍历各模型对应的计算任务结果文件，提取其压缩过程中的应力-应变曲线及变形模式数据。

1.4 仿真结果可靠性验证

仿真结果的准确性对于基于数值模拟构建神经网络数据集至关重要。为验证仿真方法的有效性，本文从数据集中随机选取了三种点阵结构（Lattice-A，Lattice-B，Lattice-C，如图 4 所示）进行准静态压缩实验。通过系统对比实验与仿真获得的应力-应变曲线及变形模式，验证仿真结果的可靠性。

图 4 展示了实验与仿真获得的应力-应变曲线对比结果。可见，两者均呈现出线性段、平台段和密实段三个典型阶段，整体趋势高度一致。在初始线性阶段，仿真与实验所得的弹性模量和初始峰值应力十分吻合，实验曲线略高，可能与实验试样中残留树脂或局部缺陷等因素有关，而仿真模型未考虑此类影响。进入屈服与平台阶段后，两者曲线的波动趋势相近。此外，实验曲线进入密实阶段的时间明显早于仿真结果，主要与梁单元无法充分模拟真实结构中杆件间存在的接触效应有关。

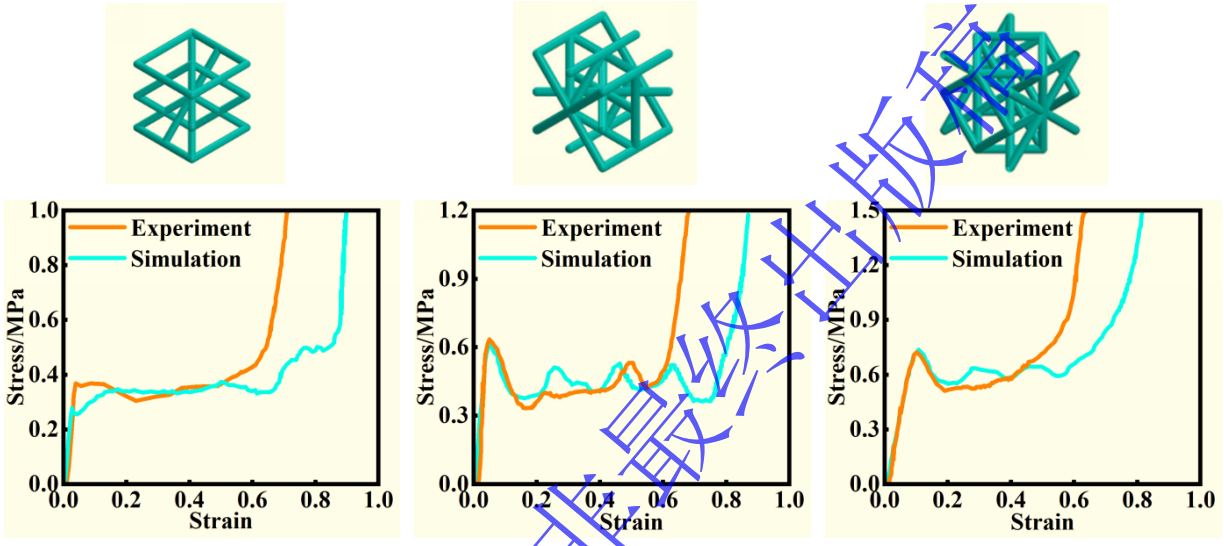

(a) Lattice-A (b) Lattice-B (c) Lattice-C

图 4 实验所得曲线和模拟所得曲线的对比

Fig.4 Comparison of experimentally obtained and simulated curves

图 5 对比了实验与仿真获得的试样变形模式，同样可发现仿真与实验表现出良好的一致性。加载初期试样变形均匀，随着载荷增大，试样中的局部压溃现象逐渐显现。此外，实验中观察到的杆件弯曲、节点扭转及局部集中变形等特征，均在仿真中准确复现。因此数值模拟在应力-应变响应和变形模式方面与实验结果高度吻合，有效验证了仿真模型的可靠性，为后续神经网络预测奠定了坚实基础。

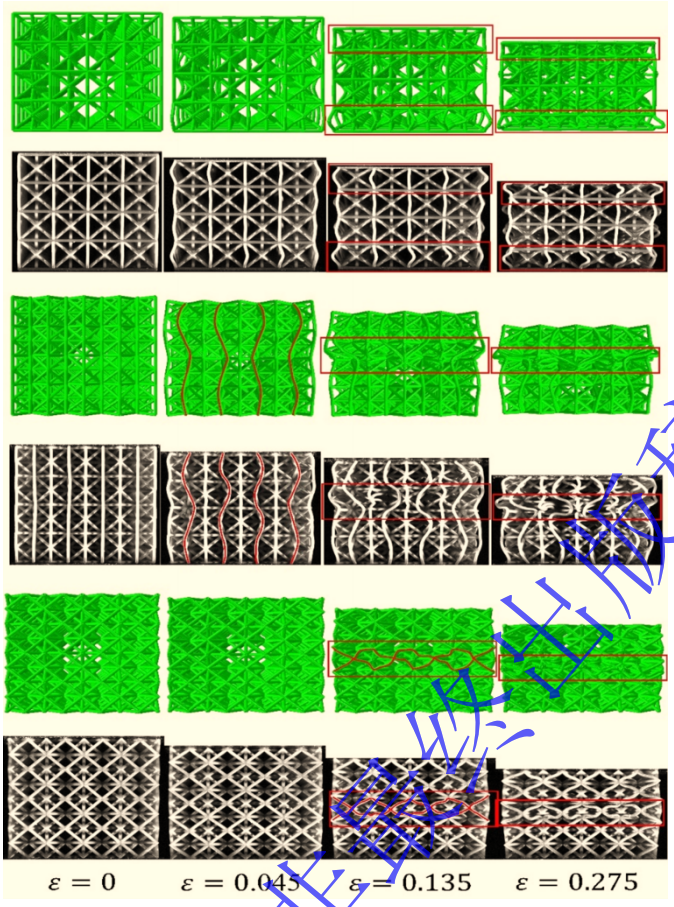

图 5 实验变形模式和数值模拟变形模式的对比

Fig.5 Comparison of deformation modes obtained from experiments and numerical simulations

2 数据驱动模型

2.1 人工神经网络

ANN 是一种模仿生物神经系统结构和功能建立的计算模型，在机器学习与人工智能领域应用广泛。ANN 通常由大量互联的人工神经元组成，通过调整网络连接权重，学习复杂的非线性关系。本节拟采用 ANN 建立点阵超材料细观拓扑结构参数与其力学响应之间的非线性映射关系，并将此 ANN 模型作为代理模型嵌入后续优化算法，最终实现点阵超材料细观结构的多目标优化设计。

2.2 ANN 模型的训练

为简化 ANN 对点阵构型的识别与学习，将每种点阵超材料构型表示为一个 28 维的数字向量。向量中各元素与晶胞内特定杆件的位置一一对应：元素取值为 1 表示该位置存在杆件，取值为 0 则表示杆件缺失。开展力学性能的优化设计前，需明确表征点阵超材料性能的关键参数。本研究选取轴向压缩状态下的弹性模量（E）、屈服强度（σ_Y）、吸能密度（Energy Absorption，EA）和应力软化系数（ϕ）作为优化目标。其中，弹性模量与屈服强度分别对应应力-应变曲线中弹性段的斜率和初始峰值应力，可直接获取。吸能密度的计算公式如下：

$$\mathrm{EA}=\int_0^{\varepsilon}\sigma(\tau)d\tau \tag{1}$$

其中，σ 为压缩过程中的应力，ε 为积分截止应变。Yu 等[25]的研究表明，桁架类点阵超材料在压缩试验中通常于 $\varepsilon = 0.65$ 达到密实阶段，但采用梁单元模型开展有限元仿真时，由于无法准确描述杆件间的接触，得到的密实应变约为 $\varepsilon = 0.8$。因此，本文将积分截止应变统一设为 0.6，以更接近实际情况。应力软化系数（ϕ）的计算公式为：

$$\phi = \frac{\sigma_{peak}}{\sigma_{valley}} \tag{2}$$

式中，σ_{peak}和σ_{valley}分别为应力-应变曲线平台段的峰值应力和谷值应力。应力软化系数（ϕ）用于表征材料的应力稳定性，当ϕ接近于 1 时，表示峰谷应力差异较小，即材料在屈服后未出现明显的应力软化现象。此外，ANN 拟合非线性关系的准确性高度依赖于训练集的规模。为充分训练 ANN，本文选取了前述数据集中的 19,688 组数据作为训练集，其占样本空间比例约为 0.17%，属于小样本训练范畴。同时，选取剩余的 1,035 组数据作为测试集，以评估 ANN 模型的训练效果。

基于 PyTorch 构建的 ANN 具体结构如图 6 所示，由一个输入层、一个输出层和多个隐藏层组成，其中隐藏层负责提取并表达输入数据的深层特征。输入层含 28 个神经元，对应点阵超材料晶胞中杆件的数字化表示，每个隐藏层包含 64 个神经元；输出层设有 4 个神经元，分别对应预测点阵超材料的 EA、E、σ_Y 和 ϕ。各层后均采用 LEAKRULE 激活函数，其可表示为：

$$\text{LEAKRULE} = \begin{cases} x, & if\ x \geq 0 \\ \alpha x, & others \end{cases} \tag{3}$$

上式中的 α 取值为 0.01。训练的批次大小设置为 64，每次训练都打乱顺序，增加训练的随机性。选择 Adam 优化器和均方误差（Mean Squared Error，MSE）损失函数来引导 ANN 的训练，Adam 优化器的学习率为 0.001，MSE 的具体公式如下所示：

$$\text{MSE} = \frac{1}{N}\sum_{i=1}^{N}\left(y_i - \hat{y}_i\right)^2 \tag{4}$$

其中 y_i、$\hat{y}_i$分别为真实值和预测值，测试数据集的损失函数值越小，说明神经网络的训练效果越好。

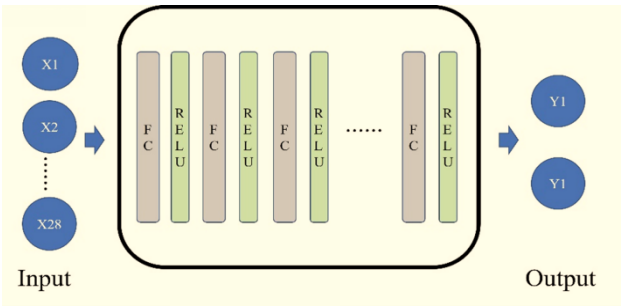

图 6 人工神经网络

Fig.6 Artificial neural networks

2.3 ANN 模型的训练结果

图 7 展示了损失函数随迭代次数的变化趋势。可以发现，随着迭代次数的增加，训练集和测试集的损失值逐步降低。当迭代次数达到 45 次后，训练集的损失函数继续下降，而测试集的损失函数下降速率明显放缓，并与训练集损失函数之间的差距逐渐增大，表明 ANN 开始过拟合，此时可停止训练。此外，研究采用平均绝对误差（Mean Absolute Error，MAE）和 MSE 评估 ANN 模型的预测效果，MAE 的计算公式为：

$$\mathrm{MAE}=\frac{1}{N}\sum_{i=1}^{N}\left|y_i-\hat{y}_i\right| \tag{5}$$

其中 y_i 和$\hat{y}_i$和 $\bar{y}$ 分别表示真实值和预测值，MAE 的计算公式见式(5)。表 1 列出了 MAE 和 MSE 的计算结果，表明模型的预测误差较低。此外，图 8 展示了 ANN 预测值与仿真结果的回归关系图，预测点基本均匀分布在 $y=x$ 参考线两侧，证明了模型具有较高的预测精度。综合上述结果可知，ANN 可有效拟合点阵超材料细观构型与其弹性模量、屈服强度、吸能密度及应力软化系数之间的复杂映射关系，可作为可靠的代理模型用于后续优化设计。

表 1 ANN 的训练误差

Table 1 ANN training error

Model	MAE	MSE
ANN	0.3771	0.5803

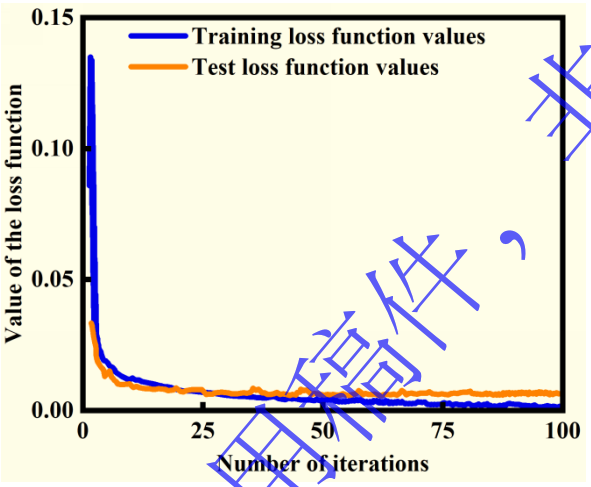

图 7 ANN 训练过程中损失函数的变化趋势

Fig.7 The trend of the loss function during ANN training

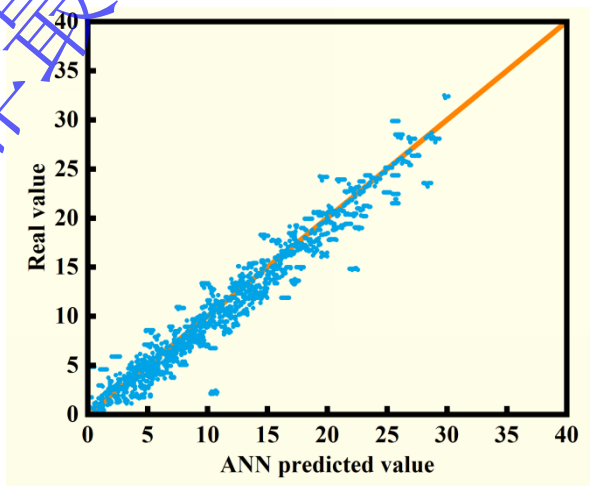

图 8 ANN 预测值与真实值之间的线性关系

Fig.8 Linear relationship between ANN predicted values and true values

3 桁架点阵超材料的多目标优化设计

3.1 优化算法

本研究采用 NSGA-Ⅱ进行多目标优化，该算法能高效地在高维搜索空间中探索全局帕累托最优解集。针对多目标优化问题，需首先明确优化目标函数，其一般数学表达形式为[27]：

$$\begin{cases} \min/\max f_m(x), & m = 1,2...M \\ s.t.\ \ x_{i\min} \le x_i \le x_{i\max}, & i = 1,2,...n \\ \quad h_j(x) = 0, & j = 1,2...J \\ \quad g_k(x) \ \ge \ 0, & k = 1,2...K \end{cases} \tag{6}$$

其中，$f_m(x)$ 表示 M 个待最大化或最小化的目标函数；x 为 n 个决策变量；$h_j(x)$ 和 $g_k(x)$ 分别表示 J 个等式约束和 K 个不等式约束。多目标优化问题的求解结果通常形成一个解集，称为 Pareto 最优解集。如图 9 所示，目标函数 f_1 与 f_2 均需向最小化方向优化。对于任意两个解 A 和 B：若 B 在至少一个目标上优于 A，且在其他目标上不劣于 A，则称 B 支配 A（或 A 被 B 支配）；若 B 在某一目标上优于 A 而 A 在另一目标上优于 B，则 A 与 B 互不支配；若存在解 C 在所有目标上均优于 A 和 B，则 C 同时支配 A 和 B。若某些解（如 D、E）在所有目标上均不被其他任何解支配，则它们构成 Pareto 最优解集，其对应的目标函数值集合在目标空间中形成 Pareto 前沿[27]。

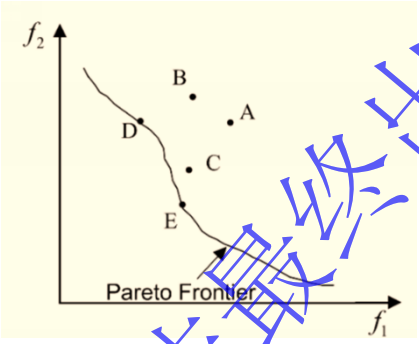

图 9 Pareto 前沿示意图

Fig.9 Schematic diagram of Pareto front

具体优化流程如图 10 所示：首先，基于训练好的 ANN 模型随机生成初始种群，并进行非支配排序与等级划分，等级越低表示优化性能越优；随后计算个体拥挤度，用于衡量其在目标空间的分布密度，在相同等级下，优先选择拥挤度较大的个体以保持多样性；通过非支配等级与拥挤度选择父代，执行交叉与变异操作生成子代；父代与子代合并后重新排序，形成新一代种群。迭代上述过程，直到满足终止条件，最终提取非支配等级最低的个体构成 Pareto 最优解集。

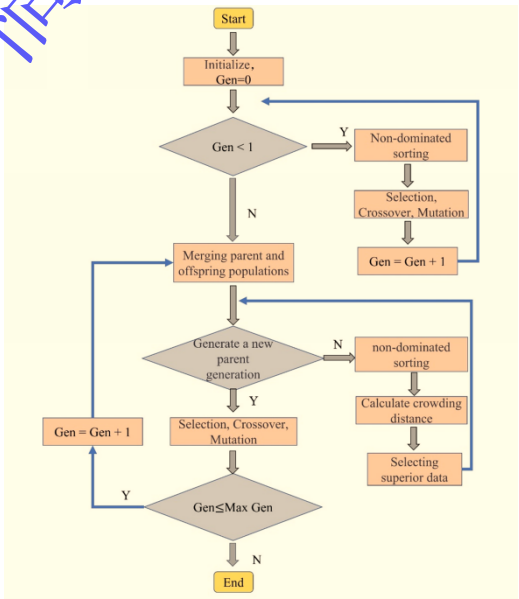

图 10 NSGA-Ⅱ多目标优化流程图

Fig.10 NSGA-II multi-objective optimization flowchart

3.2 承载型点阵超材料优化设计

在准静态压缩过程中，弹性模量（E）和屈服强度（σ_Y）可有效反映点阵超材料的承载性能，二者数值越大，结构的承载能力越强。因此，以弹性模量和屈服强度为双目标函数，开展点阵超材料的多目标优化，其优化问题可表述为：

$$\begin{cases} f_1 = \min[-\sigma_Y(X)] \\ f_2 = \min[-E(X)] \\ s.t.\ X = [x_1, x_2, x_3 \ldots x_n], \quad n = 28 \\ x_i = 0 \text{ or } 1, \quad i = 1,2 \ldots 28 \\ sum[x_1, x_2, x_{3\ldots} x_n] \le 9 \end{cases} \tag{7}$$

为实现弹性模量与屈服强度的双目标最大化，对上述两参数取负值，坐标轴取负号仅用于算法最小化处理，将其转化为最小化问题。优化变量为一个长度 28 的 0-1 向量，用于表征点阵超材料 1/8 晶胞中杆件的组合方式，同时限定杆件数量不超过 9 根。优化过程中设置种群规模为 100，变异概率为 0.5，迭代次数为 500。最终获得的 Pareto 最优解集如图 11 所示，其中横轴为屈服强度，纵轴为弹性模量。图 12 给出了 Pareto 最优解集对应的点阵胞元构型。

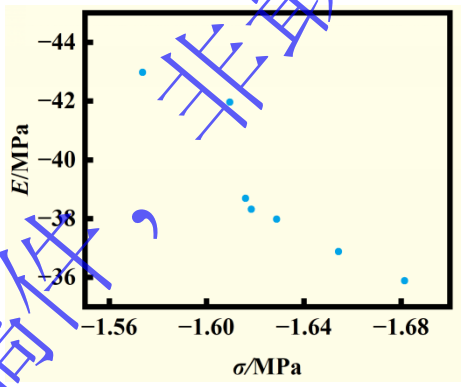

图 11 承载型点阵超材料优化设计的 Pareto 前沿

Fig.11 Pareto front for optimization design of load-bearing lattice-based metamaterials

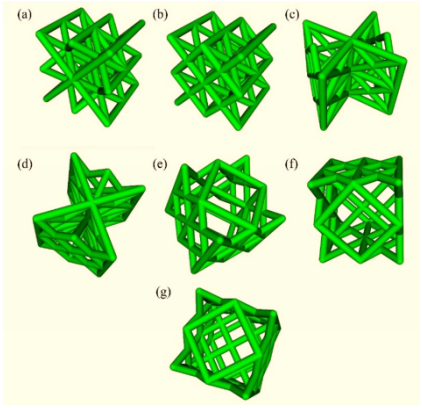

图 12 承载型点阵超材料的优化胞元构型

Fig.12 Optimized unit cell configurations of load-bearing lattice-based metamaterials

为验证优化结果的准确性，进一步对优化构型进行了准静态压缩仿真，计算其弹性模量和屈服强度，并与 ANN 预测值以及训练集中的最大值进行对比（图 13）。如图 13(a) 所示，屈服强度的预测值与仿真值吻合良好，误差较小；图 13(b) 显示，弹性模量的最大预测误差为 8.7%。该误差主要源于优化结构的弹性模量接近或超出训练集边界，而边界样本不足导致 ANN 预测精度下降。尽管如此，整体预测误差仍在可接受范围内。此外，优化后的超材料构型展现出更强的承载能力。 如图 13 所示，优化所得 A、B 构型（图 13）的弹性模量与屈服强度均超出训练集上限值约 10%，充分证明了优化策略的有效性。

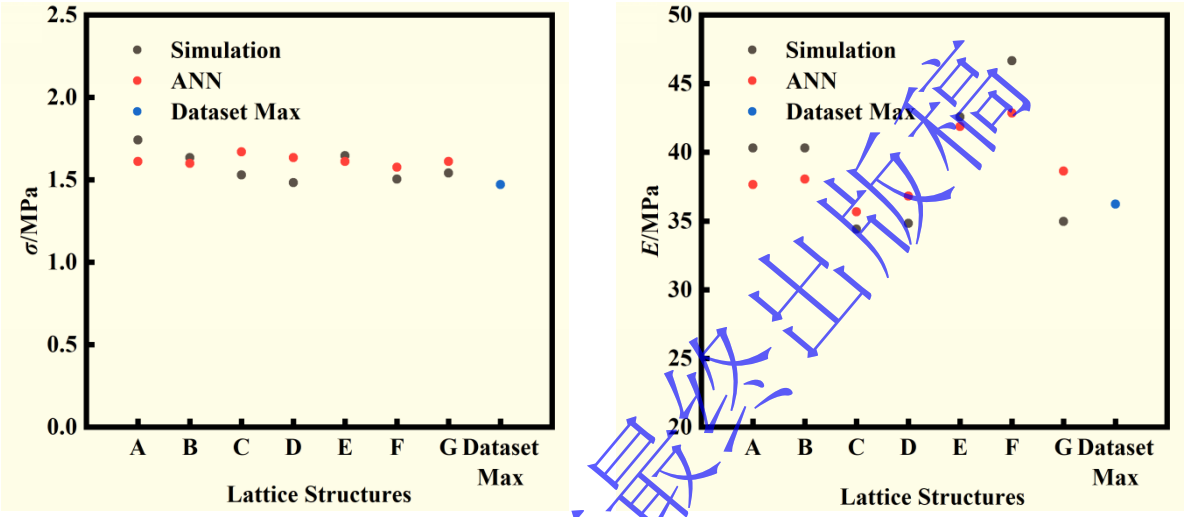

(a) Yield Strength (b) Young's Modulus

图 13 承载型点阵超材料优化设计的仿真验证结果

Fig.13 Simulation-based verification results for optimization design of load-bearing lattice-based metamaterials

3.3 吸能型点阵超材料优化设计

材料的吸能密度和应力软化系数可以反应出其在受压缩过程中的吸能能力以及吸能稳定性。因此，本节以点阵超材料准静态压缩过程中的吸能密度和应力软化系数为目标函数进行双目标优化，该双目标优化问题可以表示为：

$$\begin{cases} f_1 = \min[-EA(X)] \\ f_2 = \min[\phi(X)] \\ s.t.\ X = [x_1, x_2, x_3 \ldots x_n], \quad n = 28 \\ x_i = 0 \text{ or } 1, \quad i = 1,2 \ldots 28 \\ sum[x_1, x_2, x_3 \ldots x_n] \le 9 \end{cases} \tag{8}$$

上式中对吸能密度先取负值，然后再求解最小值，即可使总吸能朝着大的方向优化；对应力软化系数则直接求其最小值即可。优化目标的自变量与上一节相同，均是长度为 28 的向量。

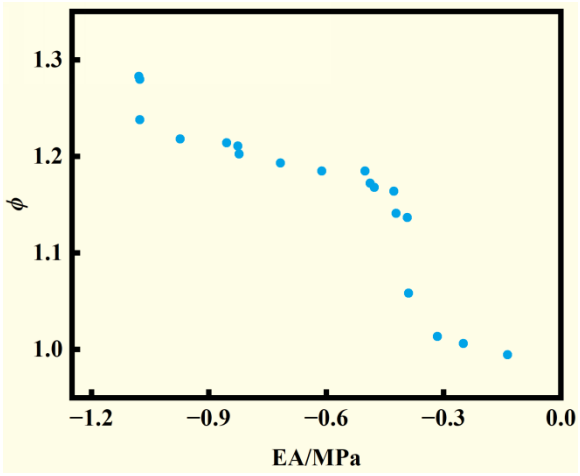

图 14 吸能型点阵超材料优化设计的 Pareto 前沿

Fig.14 Pareto front for optimization design of energy-absorbing lattice-based metamaterials

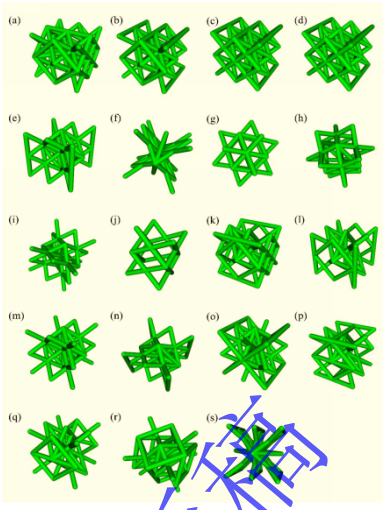

图 15 吸能型点阵超材料的优化胞元构型

Fig.15 Optimized unit cell configurations of energy-absorbing lattice-based metamaterials

最终优化所得的 Pareto 最优解集如图 14 所示，其对应的点阵超材料构型展示于图 15。为验证优化结果的准确性，本节同样对优化结构进行了准静态压缩仿真，计算了结构的吸能密度与应力软化系数，并与测试数据集中的最大总吸能和最小应力软化系数进行对比（图 16）。结果显示：图 16(a)中神经网络预测的吸能密度与有限元仿真结果高度吻合，误差较小；图 16(b)中部分结构的应力软化系数预测值存在显著偏差（最大误差约 25%），但多数结构误差控制在 10%以内，处于可接受范围。综合来看，Pareto 解集中的 D 结构表现突出，其吸能密度超出数据集最大吸能值 17%，而应力软化系数仅偏离数据集最小值约 4%。

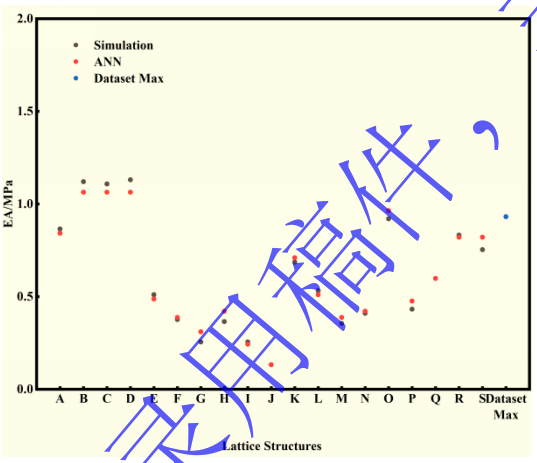

(a) Energy Absorption

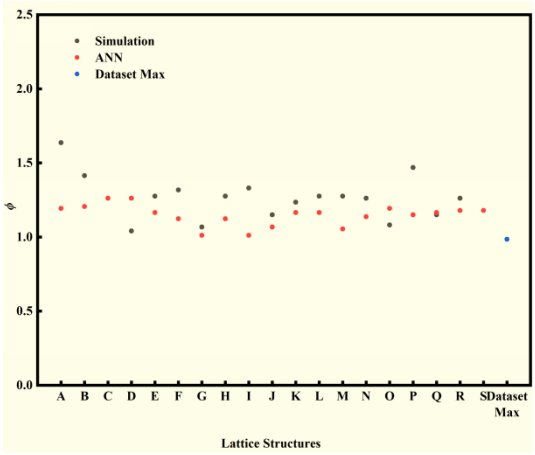

(b) Stress softening coefficien

图 16 吸能型点阵超材料优化设计的仿真验证结果

Fig.16 Simulation-based verification results for optimization design of energy-absorbing lattice-based metamaterials

3.4 兼顾承载和吸能的点阵超材料优化设计

点阵超材料的吸能密度和弹性模量分别可以反应出其在受压缩过程中的吸能能力和承载能力。吸能密度越大，桁架点阵超材料的吸能能力越强；弹性模量越大，材料的承载能力越强。基于屈服强度仅反映材料初始峰值承载能力，而弹性模量本身即为结构抵抗变形的能力，能更全面体现结构整体刚度与载荷承受能力，因此，本节以桁架点阵超材料准静态压缩过程中的吸能密度和弹性模量

为目标函数进行双目标优化，以设计出能量吸收高且承载能力强的桁架点阵超材料构型。该双目标优化问题可以表示为：

$$\begin{cases} f_1 = \min[-E(X)] \\ f_2 = \min[-EA(X)] \\ s.t.\ X = [x_1, x_2, x_3 \ldots x_n], \quad n = 28 \\ x_i = 0 \text{ or } 1, \quad i = 1,2 \ldots 28 \\ sum[x_1, x_2, x_3 \ldots x_n] \le 9 \end{cases} \tag{9}$$

上式中对吸能密度和弹性模量分别先取负值，然后再求解最小值，即可使吸能密度和弹性模量朝着大的方向优化。

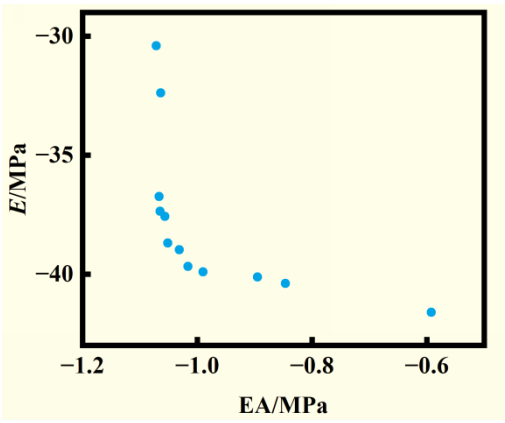

图 17 兼顾承载吸能点阵超材料优化设计的 Pareto 前沿

Fig.17 Pareto front for optimization design of lattice-based metamaterials with both high energy absorption and load bearing capacity

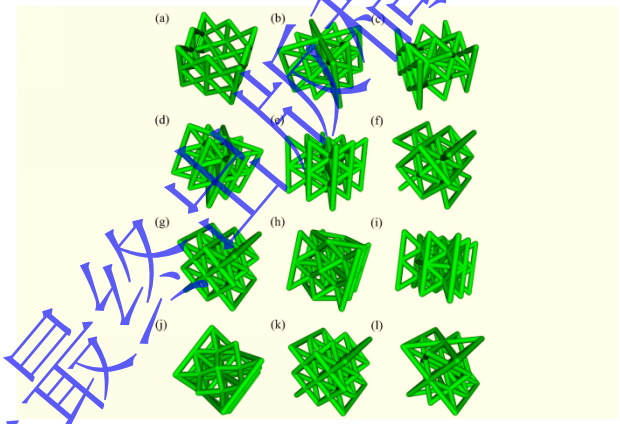

图 18 兼顾承载吸能点阵超材料的优化胞元构型

Fig.18 Optimized unit cell configurations of lattice-based metamaterials with both high energy absorption and load bearing capacity

图 17 展示了优化所得 Pareto 最优解集，其对应构型如图 18 所示。为验证其准确性，同样对优化结构进行准静态压缩仿真，计算吸能密度与弹性模量，结果见图 19。图 19(a)表明，部分结构的吸能密度预测值略低于仿真结果（最大误差约 10%），主要源于数据集中边界样本不足，导致 ANN 在高吸能区间预测偏保守；但值得注意的是，所有优化结构的吸能密度均超越数据集中的最大值，达到设计目标。图 19(b)显示弹性模量预测最大误差约 8%，精度总体良好，且优化结构模量同样超过数据集最大值。综合来看，所得构型在吸能/承载性能上均优于原始数据集，成功实现双性能协同优化设计。

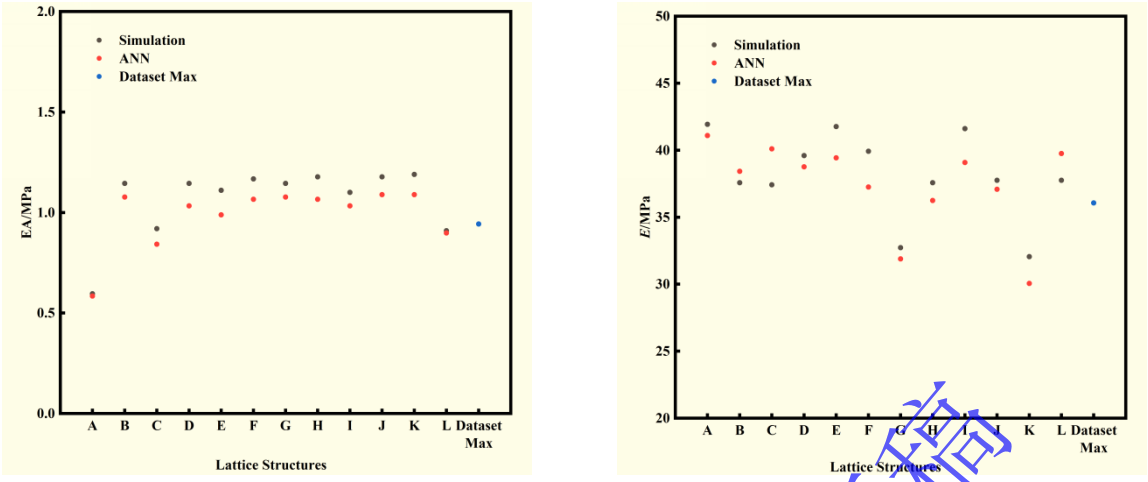

(a) Energy Absorption　　(b) Young's Modulus

图 19 兼顾承载吸能点阵超材料优化设计的仿真验证结果

Fig.19 Simulation-based verification results for optimization design of lattice-based metamaterials with both high energy absorption and load-bearing capacities

为验证优化结果可靠性，从图 19 随机选取结构(e)（记为 Lattice-(e)）进行样品制备与实验测试，实验与仿真结果如表 2 所示。数据表明，实测弹性模量与吸能密度均稍高于仿真预测值，但误差均控制在 10%以内，表明优化结果具有较高可信度。图 20(a)呈现了实验和仿真所得 Lattice-(e)的变形演化过程，可以看出，仿真与实验的变形模式高度一致，加载初期试样变形均匀，继而第一层和第四层胞元率先压溃，验证了结果的可靠性。图 20(b)中数值模拟所得应力应变曲线与实验结果也较为吻合，进一步验证了仿真预测的准确性及优化方法的可靠性。

表 2 Lattice-(e)的实验、仿真结果对比

Table 2　Comparison of experimental and simulation results of Lattice-(e)

	弹性模量/MPa	吸能密度/MPa
仿真	42.2244	1.1029
实验	43.4396	1.2082
相对误差	2.8%	8.7%

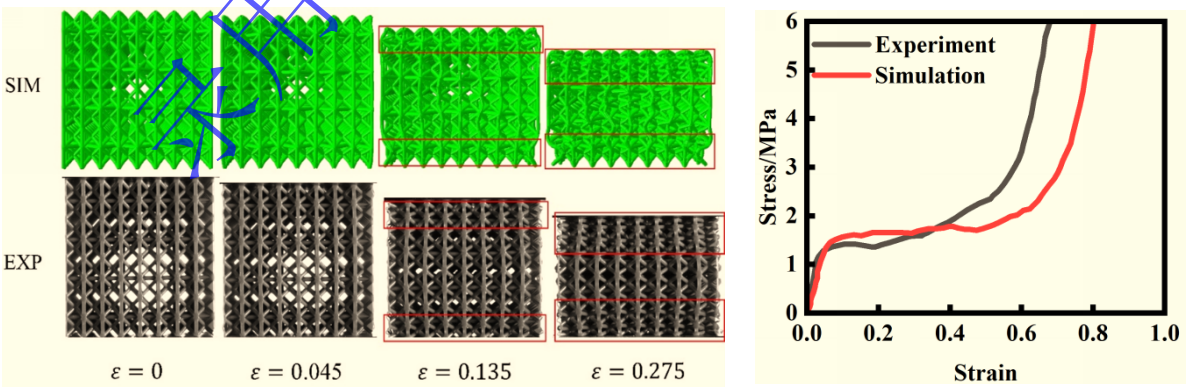

(a) Comparison of experimental and simulated deformation modes　　(b) Stress-Strain Curve

图 20 Lattice-(e)的实验与仿真力学响应对比：（a）变形模式；（b）应力应变曲线

Fig.20 Comparison of experimental and simulated mechanical responses of Lattice-(e): (a) deformation mode; (b) stress-strain curve

4 结 论

本研究以桁架类点阵超材料为对象，提出了不同构型点阵超材料的快速建模与仿真方法，并利用数值模拟构建了机器学习所需数据集，结合 ANN 与 NSGA-Ⅱ优化算法开展了点阵超材料特征力学参数的多目标优化设计，主要成果如下：

（1）基于 Python 脚本和 Abaqus 仿真软件，随机生成了 2 万余种不同构型的点阵超材料晶胞结构库，通过批量化数值模拟构建了点阵超材料力学响应数据集，并通过实验验证了数据集的可靠性。

（2）基于点阵超材料的数字化模型构建了 ANN，实现了点阵超材料晶胞构型与其准静态压缩工况下弹性模量、屈服强度、吸能密度和应力软化系数之间复杂非线性关系的拟合。

（3）将 ANN 作为 NSGA-Ⅱ优化算法的代理函数，分别选取弹性模量、屈服强度、吸能密度和应力软化系数作为优化目标，实现了承载型、吸能型以及兼顾承载吸能的点阵超材料优化设计。

参考文献

[1] Chougrani L, Pernot J P, Véron P, et al. Lattice structure lightweight triangulation for additive manufacturing [J]. Computer-Aided Design, 2017, 90: 95-104. DOI:10.1016/j.cad.2017.05.016.

[2] Yin S, Guo W, Wang H, et al. Strong and tough bioinspired additive-manufactured dual-phase mechanical metamaterial composites [J]. Journal of the Mechanics and Physics of Solids, 2021, 149: 104341. DOI:10.1016/j.jmps.2021.104341.

[3] Portela C M, Greer J R, Kochmann D M. Impact of node geometry on the effective stiffness of non-slender three-dimensional truss lattice architectures [J]. Extrem. Mech. Lett. 22 (2018) 138–148. DOI:10.1016/j.eml.2018.06.004.

[4] Ling C, Cernicchi A, Gilchrist M D, et al. Mechanical behaviour of additively-manufactured polymeric octet-truss lattice structures under quasi-static and dynamic compressive loading [J]. Materials & Design, 2019, 162: 106-118. DOI:10.1016/j.matdes.2018.11.035.

[5] Yin H, Zhang W, Zhu L, et al. Review on lattice structures for energy absorption properties [J]. Composite Structures, 2023, 304: 116397. DOI:10.1016/j.compstruct.2022.116397.

[6] Nazir A, Abate K M, Kumar A, et al. A state-of-the-art review on types, design, optimization, and additive manufacturing of cellular structures [J]. The International Journal of Advanced Manufacturing Technology, 2019, 104(9-12): 3489-3510. DOI:10.1007/s00170-019-04085-3.

[7] Hu L L, Zhou M Z, Deng H, et al. Dynamic crushing response of auxetic honeycombs under large deformation: theoretical analysis and numerical simulation [J]. Thin-Walled Structures, 2018, 131: 373-384. DOI:10.1016/j.tws.2018.04.020.

[8] Zhang D, Fei Q, Liu J, et al. Crushing of vertex-based hierarchical honeycombs with triangular substructures [J]. Thin-Walled Structures, 2020, 146: 106436.6. DOI:10.1016/j.tws.2019.106436.

[9] Nečemer B, Glodež S, Novak N, et al. Numerical modelling of a chiral auxetic cellular structure under multiaxial loading conditions [J]. Theoretical and Applied Fracture Mechanics, 2020, 107: 102514. DOI:10.1016/j.tafmec.2020.102514.

[10] Andrew J J, Schneider J, Ubaid J, et al. Energy absorption characteristics of additively manufactured plate-lattices under low-velocity impact loading [J]. International Journal of Impact Engineering, 2021, 149: 103768. DOI:10.1016/j.ijimpeng.2020.103768.

[11] Miralbes R, Ranz D, Pascual F J, et al. Characterization of additively manufactured triply periodic minimal surface structures under compressive loading[J]. Mechanics of Advanced Materials and Structures, 2022, 29(13): 1841-1855. DOI:10.1080/15376494.2020.1842948.

[12] Ma Q, Yan Z, Zhang L, et al. The family of elastically isotropic stretching-dominated cubic truss lattices [J]. International

Journal of Solids and Structures, 2022, 239: 111451. DOI:10.1016/j.ijsolstr.2022.111451.

[13] Maconachie T, Leary M, Lozanovski B, et al. SLM lattice structures: Properties, performance, applications and challenges [J]. Materials & Design, 2019, 183: 108137. DOI:10.1016/j.matdes.2019.108137.

[14] Mora S, Pugno N M, Misseroni D. 3D printed architected lattice structures by material jetting[J]. Materials Today, 2022, 59: 107-132. DOI:10.1016/j.mattod.2022.05.008.

[15] Tancogne-Dejean T, Spierings A B, Mohr D. Additively-manufactured metallic micro-lattice materials for high specific energy absorption under static and dynamic loading [J]. Acta Materialia, 2016, 116: 14-28. DOI:10.1016/j.actamat.2016.05.054.

[16] Epasto G, Palomba G, D'Andrea D, et al. Ti-6Al-4V ELI microlattice structures manufactured by electron beam melting: Effect of unit cell dimensions and morphology on mechanical behaviour [J]. Materials Science and Engineering: A, 2019, 753: 31-41. DOI:10.1016/j.msea.2019.03.014.

[17] Wang S, Ma Y, Deng Z, et al. Two elastically equivalent compound truss lattice materials with controllable anisotropic mechanical properties[J]. International Journal of Mechanical Sciences, 2022, 213: 106879. DOI:10.1016/j.ijmecsci.2021.106879.

[18] DONDA K, BRAHMKHATRI P, ZHU Y, et al. Machine learning for inverse design of acoustic and elastic metamaterials [J]. Current Opinion in Solid State and Materials Science, 2025, 35: 101218. DOI:10.1016/j.cossms.2025.101218.

[19] XU W, LIU C, GUO Y, et al. Problem-Independent Machine Learning (PIML) enhanced 3D lattice composite structures optimization via moving morphable components approach [J]. Composite Structures, 2025, 369: 119330. DOI:10.1016/j.compstruct.2025.119330.

[20] Zhao S, Zhao Z, Yang Z, et al. Functionally graded graphene reinforced composite structures: A review [J]. Engineering Structures, 2020, 210: 110339. DOI:10.1016/j.engstruct.2020.110339.

[21] Zhang X, Song Z, Li Y, et al. Generative inverse design of metamaterials with customized stress-strain response [J]. International Journal of Mechanical Sciences, 2025, 306: 110875. DOI:10.1016/j.cma.2018.10.046.

[22] Sepasdar R, Karpatne A, Shakiba M. A data-driven approach to full-field nonlinear stress distribution and failure pattern prediction in composites using deep learning [J]. Computer Methods in Applied Mechanics and Engineering, 2022, 397: 115126. DOI:10.1016/j.cma.2022.115126.

[23] Peloquin J, Kirillova A, Rudin C, et al. Prediction of tensile performance for 3D printed photopolymer gyroid lattices using structural porosity, base material properties, and machine learning [J]. Materials & Design, 2023, 232: 112126. DOI:10.1016/j.matdes.2023.112126.

[24] Glaesener R N, Kumar S, Lestringant C, et al. Predicting the influence of geometric imperfections on the mechanical response of 2D and 3D periodic trusses [J]. Acta Materialia, 2023, 254: 118918. DOI:10.1016/j.actamat.2023.118918.

[25] Yu G, Xiao L, Song W. Deep learning-based heterogeneous strategy for customizing responses of lattice structures [J]. International Journal of Mechanical Sciences, 2022, 229: 107531. DOI:10.1016/j.ijmecsci.2022.107531.

[26] Santosa S P, Wierzbicki T, Hanssen A G, et al. Experimental and numerical studies of foam-filled sections [J]. International journal of impact engineering, 2000, 24(5): 509-534. DOI:10.1016/S0734-743X(99)00036-6.

[27] LE V T, DINH D M, TRAN V C, et al. Modelling, analysis, and multi-objective optimization of single weld bead characteristics in wire arc additive manufacturing of Inconel 625 based on machine learning and NSGA-II [J]. Materials Today Communications, 2025, 49: 113831. DOI:10.1016/j.mtcomm.2025.113831.

（责任编辑　爆炸与冲击）