DOI: 10.11883/bzycj-2025-0388

基于机器学习的新型多胞梯度结构设计与优化*

闫凯波[1,2], 周　鹏[1], 陆思思[1,2], 王俊杰[1], 范志伟[1]
（1. 重庆交通大学机电与车辆工程学院, 重庆 400074;
2. 重庆嘉陵特种装备有限公司, 重庆 400032）

摘要： 针对航空航天、交通运输、土木建筑等领域的碰撞防护需求, 提出一种新型多胞梯度结构管（CMGHT）设计方法: 在普通六边形管内引入正弦波纹肋板, 并融合功能梯度设计理念, 以实现结构耐撞性能的提升。首先, 构建该结构的有限元模型并开展数值模拟分析。结果显示, 在相同壁厚条件下, CMGHT 的关键吸能指标表现显著优于现有结构, 相较于普通六边形管（HT）, 其吸收能量（E_a）、比吸能（E_{sa}）、平均压缩力（$\overline{F}$）及压缩效率（η）分别提升 390%、76%、395% 和 46%; 相较于多胞六边形管（MHT）, 上述指标分别提升 121%、58%、121% 和 97%; 相较于波纹多胞六边形管（CMHT）, E_a、E_{sa}、$\overline{F}$、η 分别提升 7%、7%、8%、33%, 且初始峰值压缩力（F_{max}）降低 18%, 充分证明其吸能性能更优。随后, 以肋板与外管的几何参数为设计变量, 通过全因子试验设计生成 540 组样本, 构建支持向量机（SVM）代理模型, 并结合冠豪猪优化（CPO）算法完成模型优选, 实现对 CMGHT 耐撞性能的精准预测。最后, 采用多目标浣熊优化算法（MOCOA）进行多目标优化, 获取最优特征参数组合。优化结果表明, 相较于未经过参数优化的 CMGHT 基础模型（参数基于工程常用范围初步设定: 肋板厚度 1 mm、肋板幅值 3 mm、外管梯度厚度 0.5 mm-1 mm-1.5 mm、外管长度 33.3 mm）, 优化后结构的 E_{sa} 提高 22%, η 提升 53%, $\overline{F}$ 增强 270%, 进一步验证了设计方法的有效性。

关键词： 多胞梯度结构; 有限元分析; 机器学习; 多目标优化
中图分类号： O342　　**国标学科代码：** 13015　　**文献标志码：** A

Design and optimization of corrugated multi-cell gradient structures based on machine learning

YAN Kaibo[1,2], ZHOU Peng[1], LU Sisi[1,2], WANG Junjie[1], FAN Zhiwei[1]
（1. *School of Mechatronics & Vehicle Engineering*, *Chongqing Jiaotong University*, *Chongqing* 400074, *China*;
2. *Chongqing Jialing Special Equipment Co.*, *Ltd.*, *Chongqing* 400032, *China*）

Abstract: To address the collision protection requirements in fields such as aeronautics and space, traffic transportation, and civil construction, a novel design method for the corrugated multi-cell gradient hexagonal tube (CMGHT) was proposed. The sinusoidal corrugated ribs were introduced into a conventional hexagonal tube, integrated with the functional gradient design concept to improve the energy absorption performance of the structure. First, the finite element model of the structure was established and numerical simulation analysis was conducted. Results indicate that under the same wall thickness condition, the key energy absorption indicators of CMGHT outperform existing structures significantly. Compared with the hexagonal tube (HT), the energy absorption (E_a), specific energy absorption (E_{sa}), mean crushing force ($\overline{F}$), and crushing force efficiency (η) are improved by 390%, 76%, 395%, and 46%, respectively; Compared with the multi-cell hexagonal tube (MHT), the aforementioned indicators are increased by 121%, 58%, 121%, and 97%, respectively; Relative to a corrugated multi-cell

* 收稿日期: 2025-12-02; 修回日期: 2026-03-09
基金项目: 国家自然科学基金（52402466）; 中国博士后科学基金（2022M723001, 2022M713014）; 重庆市自然科学基金（CSTB2025NSCQ-GPX0885）; 重庆市技术创新与应用发展专项重点项目（CSTB2024TIAD-KPX0081）; 重庆市博士后研究项目（2022CQBSHTB2020）; 重庆市教育委员会科学技术研究项目（KJZD-K202400704, KJQN202400718）; 重庆交通大学研究生科研创新项目（2025S0051）
第一作者: 闫凯波（1992—　）, 男, 博士, 讲师, kaibo_yan@yeah.net
通信作者: 陆思思（1993—　）, 女, 博士, 副教授, sisi_lu2020@yeah.net

hexagonal tube (CMHT), the enhancements are 7%, 7%, 8%, and 33% respectively, while the initial peak crushing force (F_{max}) is decreased by 18%. These results fully demonstrate its superior energy absorption performance. Subsequently, the geometric parameters of the ribs and outer tube were selected as design variables. A total of 540 sample sets were generated via full factorial experimental design, and a support vector machine (SVM) surrogate model was constructed. Combined with the crested porcupine optimization (CPO) algorithm, model optimization was completed to achieve the accurate prediction of the crashworthiness indicators for CMGHT. Finally, the multi-objective coati optimization algorithm (MOCOA) was adopted for multi-objective optimization to obtain the optimal combination of characteristic parameters. The optimization results show that compared with the CMGHT basic model without parameter optimization (the parameters are initially set based on the common range of engineering: rib thickness of 1 mm, rib amplitude of 3 mm, outer tube gradient thickness of 0.5 mm-1 mm-1.5 mm, outer tube length of 33.3 mm), the E_{sa} of the optimized structure is increased by 22%, the η is increased by 53%, and the $\overline{F}$ is increased by 270%, which further verifies the effectiveness of the design method.

Keywords: multi-cell gradient structures; finite element simulation; machine learning; multi-objective optimization

近年来，随着工程结构抗冲击需求的提升，能量吸收能力与结构轻量化间的矛盾日益凸显，兼具优异力学性能的轻质结构研究迅速成为热点[1]。为提升能量吸收性能，研究者们提出了多种不同构型的能量吸收结构，如柱状结构[2]、夹层结构[3]、板状结构[4] 以及多边形结构[5] 等。早期广泛使用的传统圆管、方管及多边形管因其构型简单、易于加工和成本较低等优势，常被用作能量吸收装置。然而，这些结构内部空间未能得到充分利用，限制了其在冲击荷载下的能量吸收能力。因此，研究人员尝试在简单管状结构中增设肋板，以充分利用其内部吸能空间。特别是部分薄壁结构借鉴了生物体的形态特征，以及多孔材料中具有规则排布的微观与细观结构特点[6]，发展出一类外部为薄壁、内部由相互连接的肋板构成的结构形式，称为薄壁多胞结构。大量对比研究表明，薄壁多胞结构具有更高的比吸能和更稳定的碰撞响应[7]。Tang 等[8] 基于圆柱在吸能方面优于方柱的现象，提出了一种由同心圆柱组成、并通过径向腹板连接的新型多胞柱结构。Khanchehzar 等[9] 通过准静态横向压缩试验，研究了内置 26 根肋板的铝方管在压溃过程中加强肋对其能量吸收性能的影响。Jin 等[10] 则通过准静态轴向压缩试验，对比分析了多边形薄壁多胞结构的能量吸收行为与变形模式。

相关研究表明，增大多边形管的等效承载边长可显著提升其抗冲击性能。为此，在传统薄壁结构中引入波纹特征已成为研究热点。选择适配的波纹类型与几何参数，能有效拓展多边形管的结构受力边界，进而改善其抗冲击性能。目前，波纹结构已形成多样化形式，涵盖波纹管、凹面管、折叠管、槽纹管、波纹蜂窝结构及波纹芯夹层板等。从设计维度看，波纹的引入为结构优化提供了更丰富的调控空间，可通过参数调整实现性能定制。尽管波纹结构能有效提升吸收能量，但其制造复杂度相较于传统结构更高。不过，随着 3D 打印等先进制造技术的发展，这一局限性已逐步得到缓解，为波纹结构的工程应用奠定了基础。其中，正弦曲线与余弦曲线因参数可控性强，成为优选波纹形式——通过拓扑修改可灵活调整凹凸角、振幅及公称直径；同时，凹面结构的所有切点可约束于同一圆周，进一步简化夹层波纹管的设计与优化过程。已有学者围绕该方向开展研究，Deng 等[11] 以正弦波纹为基础，提出一种具有正弦横截面的新型周向波纹管，其横截面轮廓可通过改变振幅、基准公称直径及波纹数量实现调控，研究证实相同条件与尺寸下，薄壁正弦波纹管的性能显著优于普通圆柱；Li 等[12] 则针对具有余弦轮廓的周向波纹方管展开吸能特性研究，数值结果显示，与相同质量的传统方管相比，周向波纹方管提升了 51.62%，与相同壁厚的传统方管相比，该指标提升了 69.24%。

增大多边形管的等效承载边长虽能提升吸收能量，但会伴随初始峰值压缩力升高的问题，这一矛盾成为制约结构耐撞性能优化的关键。为解决该难题，在薄壁结构中引入梯度设计方法成为有效路径——该设计不仅能实现结构轻量化，还可显著降初始峰值压缩力，进而实现吸能性能的综合提升。梯度设计的研究已逐步深入，并取得系列进展。Baykasoglu 等[13] 通过数值模拟，系统探究了梯度壁厚对圆形铝管轴向挤压吸能特性的影响，为梯度设计的应用提供了基础数据。Xu 等[14] 针对壁厚沿纵向呈线性变化的圆形管开展实验研究，深入分析其轴向挤压与弯曲失稳模式，明确阐述了梯度壁厚设计在性能优化中的优势。在此基础上，Xu 等[15] 进一步拓展研究边界，构建多目标优化框架，成功实现圆形管最优壁厚分布

的确定，为梯度结构的工程应用提供了设计依据。

在新型吸能结构设计中，确定最优设计参数是保障其优良抗冲击性能的关键环节，而智能优化算法凭借高效求解复杂系统优化问题的优势，近年来已在该领域广泛应用且成效显著，典型算法包括灰狼优化算法、遗传算法及粒子群算法等[16]。Wang 等[17] 将改进型多目标粒子群优化算法（multi-objective particle swarm optimization, MOPSO）与广义几何分析相结合，完成双向功能梯度板的多目标优化；Miao 等[18] 采用 MOPSO，实现了多孔阵列圆管的结构优化；Li 等[19] 构建了克里金代理模型，为仿生直锥形管结构的多目标优化提供支撑；Yin 等[20] 通过多项式回归模型与 MOPSO 的融合，完成了 6 种仿生薄壁结构的优化设计；Zhang 等[21] 则结合响应面法与非支配排序遗传算法，开展了异形管的多目标优化研究。

综上，当前大多数吸能结构的设计仍主要依赖单一方法，如多胞设计、波纹设计或功能梯度设计等。此外，这些结构的参数优化过程也大多沿用传统的代理模型与优化算法。为进一步提升薄壁结构的抗冲击性能，本文融合多胞、波纹与功能梯度 3 种设计理念，构建一种集成化设计方法：首先建立不同多胞管的有限元（finite element, FE）模型并进行数值模拟，通过对比分析评估其耐撞性能；随后以新型多胞梯度结构管（corrugated multicellular gradient hexagonal tube, CMGHT）的肋板与外管几何参数为设计变量，采用全因子试验设计生成样本点，并采集相应的力学响应数据；在此基础上，构建以几何参数为输入、耐撞性指标为输出的冠豪猪算法优化的支持向量回归模型（crested porcupine optimizer optimized support vector regression model, CPO-SVR），实现对 CMGHT 吸能特性的高精度预测；最后，将 CPO-SVR 模型与多目标浣熊优化算法（multi-objective coati optimization algorithm, MOCOA）相结合，进行参数优化，从而确定 CMGHT 的最优特征参数组合。

1　多胞梯度结构设计

1.1　设计思路

设计一种可平铺拼接的吸能结构单胞元，探究其吸能性能，为胞元阵列化组合构建大尺寸吸能结构提供基础。为便于胞元组合，选择在传统六边形管（hexagonal tube, HT）的基础上进行改进，提出一种新型结构。初始 HT 内部为中空状态，无法有效利用吸能空间，造成空间浪费，因此首先通过增设肋板形成多胞六边形管（multicellular hexagonal tube, MHT）。此外，肋板边长越大，其等效承载边长相应增加，结构吸能能力也随之提升。基于此，本研究引入波纹设计，在不改变吸能空间的前提下，将直肋板优化为正弦波纹肋板，通过增大肋板等效承载边长构建波纹多胞六边形管（corrugated multicellular hexagonal tube, CMHT），同时可通过调控正弦波纹幅值，进一步增加肋板的等效承载边长，实现吸能性能的优化。尽管上述改进可以显著提升结构的吸收能量，但也可能导致初始峰值压缩力过高。为此，引入梯度设计方法，使外管厚度沿轴向自碰撞接触界面至远离碰撞界面依次增大，该设计在确保结构吸能性能的同时，能够显著降低初始峰值压缩力，由此得到新型多胞梯度结构管（CMGHT），详细设计思路如图 1 所示。

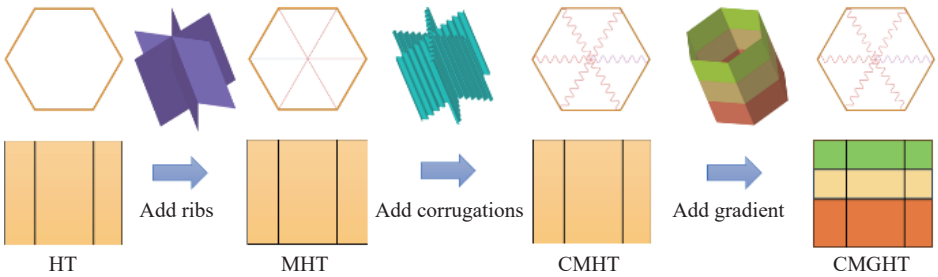

图 1　CMGHT 的构建过程

Fig. 1　The construction process of CMGHT

1.2　面外压缩性能指标

采用以下吸能指标[22] 定量分析 CMGHT 的耐撞性与吸能特性。

吸收能量 E_a 定义为结构的力（$F(x)$）-位移（x）曲线在有效压缩位移 δ 内的积分：

$$E_a = \int_0^{\delta} F(x)\mathrm{d}x \tag{1}$$

比吸能 E_{sa} 定义为结构在有效压缩位移内吸收的总能量与结构总质量 M 之比，即：

$$E_{sa} = E_a/M \tag{2}$$

初始峰值压缩力 F_{max} 指结构压缩过程中首次出现的最大载荷。

平均压缩力定义 $\overline{F}$ 为结构总吸能与有效压缩位移之比，即：

$$\overline{F} = E_a/\delta \tag{3}$$

压缩力效率 η 指压缩力在结构变形过程中的稳定性，定义为：

$$\eta = \overline{F}/F_{max} \tag{4}$$

当 η 接近 1 时，F_{max} 与 $\overline{F}$ 的偏差较小，能量吸收效率较高。

1.3　有限元模型

CMGHT 的三维建模通过 UG 软件完成，建模完成后将三维模型导入 HyperMesh 软件进行有限元前处理，具体操作包括网格划分与材料、属性设置等。如图 2 所示，该结构被置于两块刚性板之间，其中下方刚性板保持固定，上方刚性板被赋予初始运动速度以实现加载。在加载方式上，参照 Ha 等[22] 提出的方法模拟准静态（quasi-static, QS）加载过程。与传统采用 5 mm/min 的加载速度不同，本研究选用 0.4 m/s 的压缩速度——该参数调整不仅能确保 FE 模拟结果的准确性，还可大幅缩短计算耗时，为后续系列研究的高效开展提供便利。

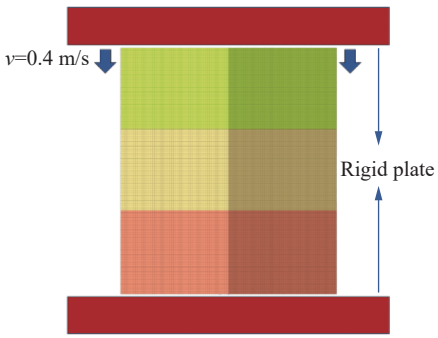

图 2　CMGHT 的有限元模型

Fig. 2　FE model of CMGHT

由于尚未见到文献中报道 CMGHT 创新结构，缺乏直接对应的实验数据用于模型验证，因此选择与文献 [23] 中 HT 的实验结果进行对比，以验证建模方法的准确性。文献 [23] 中实验样本的网格特征尺寸为 1.5 mm，结构材料选用 AA6061-O，具体材料属性如下：密度为 2 700 kg/m^3，杨氏模量为 68 GPa，泊松比为 0.33，屈服应力为 71 MPa，极限应力为 130.7 MPa，幂律指数为 0.18；FE 建模采用 LS-DYNA 中的材料模型 123。仿真模型的边界条件设置与文献 [23] 完全一致，单元类型为壳单元，所有接触部位的库仑摩擦系数取 0.15。数值分析中定义了两类接触，采用自动单面接触来模拟结构内部的自接触行为，结构与刚性平面之间则使用自动节点-表面接触进行模拟。

由图 3 可见，HT 在 FE 模拟与压缩实验中的变形模式几乎完全一致，且二者的力-位移曲线也呈现

(a) QS compression experiment[23]

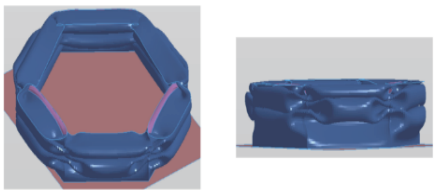

(b) FE simulation in this study

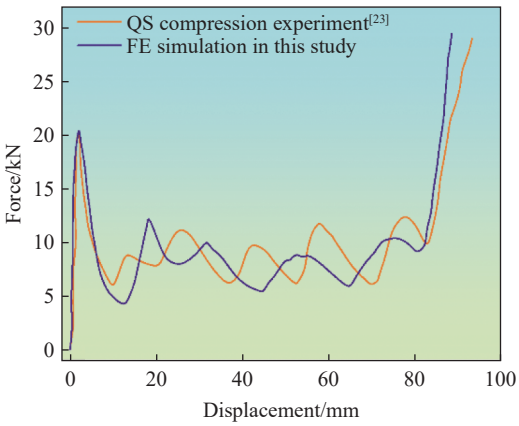

(c) Force-displacement curve

图 3　HT 的变形模式与压缩曲线对比

Fig. 3　Comparison of the deformation mode and compression curve of HT

高度吻合的特征，直观证明了仿真模型在变形行为预测上的可靠性。进一步从定量角度验证，表 1 显示，FE 模拟结果与压缩实验结果的误差在 3% 以内。结合定性与定量分析可得出结论，本文的 FE 建模方法具备较高的准确性，能够为后续 CMGHT 的性能分析提供可靠支撑。

表 1　HT 的耐撞性指标对比

Table 1　Comparison of the crashworthiness indicators of HT

方法	F_{max}/kN	E_a/kJ	$\overline{F}$/kN	η/%	E_{sa}/(J·g^{-1})
FE	20.78	0.81	9.64	46	6.982
QS[23]	20.38	0.82	9.78	47	7.086
误差	1.9%	1.3%	1.4%	2.1%	1.4%

1.4　新型多胞梯度结构耐撞性能分析

为清晰分析并验证 CMGHT 在耐撞性能上的优势，采用控制变量法构建对比模型。四种结构管（HT、MHT、CMHT、CMGHT）均使用相同材料属性，且统一壁厚参数——其中 HT、MHT、CMHT 的整体壁厚均为 1 mm，CMGHT 的中层外管与肋板壁厚同样为 1 mm。参照 Fu 等[24] 关于多胞管的 QS 压缩实验研究和 Abramowicz[25] 的薄壁管经典压溃理论，将所有管件的有效压缩行程统一选取为总长度的 70%。该取值处于薄壁结构管 70%～80% 的典型有效压缩行程区间，既能够保证结构在稳定平台段实现高效吸能，又可有效规避初始弹性变形与最终致密化阶段的无效位移。四种结构管的力学响应结果（力-位移曲线）如图 4 所示。对模拟结果作进一步分析，并将主要数据汇总于表 2 与图 5 中。

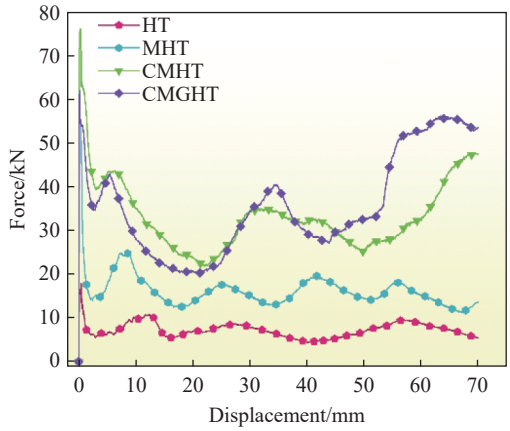

图 4　各结构管力-位移曲线图

Fig. 4　Force-displacement curves of different structural tubes

表 2　不同结构管的耐撞性指标对比

Table 2　Comparison of the crashworthiness indicators among different structural tubes

结构	F_{max}/kN	E_a/kJ	$\overline{F}$/kN	η/%	E_{sa}/(J·g^{-1})
HT	18.18	0.51	7.22	39	6.25
MHT	55.28	1.13	16.20	29	6.96
CMHT	76.20	2.33	33.25	43	10.26
CMGHT	62.27	2.50	35.75	57	10.97

分析表明，在 HT 结构基础上增设肋板而形成的 MHT 结构，其 E_a、E_{sa} 和 $\overline{F}$ 均高于 HT。将直肋板替换为波纹肋板构成 CMHT 后，相较于 MHT，其 E_a、$\overline{F}$、η 和 E_{sa} 进一步提升。因此，在 HT 结构中添加正弦波纹肋板相对于普通肋板吸能效果提升更为明显，但 F_{max} 也随之增大。最终，在 CMHT 中引入梯度设计形成的 CMGHT 结构，在所有关键耐撞性指标（包括 E_a、E_{sa}、$\overline{F}$、η 和 F_{max}）上均优于 CMHT。具体而言，CMGHT 在有效降低 F_{max} 的同时，实现了 E_a、E_{sa}、$\overline{F}$ 和 η 的全面改善，显示出更加均衡且优异的综合耐撞性。

从量化结果来看，与相同壁厚的传统 HT 结构相比，CMGHT 在 E_a、E_{sa}、$\overline{F}$ 和 η 上分别显著提升了 390%、76%、395% 和 46%；与 MHT 相比，上述指标分别提高了 121%、58%、121% 和 97%；与 CMHT 相比，CMGHT 在 E_a、E_{sa}、$\overline{F}$ 和 η 上进一步提升了 7%、7%、8% 和 33%，同时 F_{max} 降低了 18%。以上对比充分说明，CMGHT 相较于其他几种结构具有更优越的能量吸收特性。

图 6 给出了不同结构管的压缩变形，可以看出，HT、MHT、CMHT 及 CMGHT 均呈现渐进屈曲变形

模式，整体变形过程较为稳定，但不同结构的变形细节与稳定性存在显著差异。HT 增设肋板形成 MHT 后，肋板约束了外管的自由度，使结构变形稳定性明显提升——从底部最终褶皱形态可直观观察到，MHT 的最后一个褶皱长度短于 HT，且变形更规整。MHT 的直肋板改为波纹肋板形成 CMHT 后，变形过程中 CMHT 的肋板出现弯曲变形，并带动外管产生一定扭曲。这种变形特征扩大了能量耗散路径，使 CMHT 的吸收能量高于 MHT。采用梯度设计的 CMGHT，虽同样出现肋板弯曲变形，但与 CMHT 相比，其底部壁厚更大，有效抑制了外管扭曲现象，变形稳定性进一步增强；同时，CMGHT 的褶皱数量多于 CMHT，通过更多屈曲变形耗散能量，最终实现更好的吸能效果。

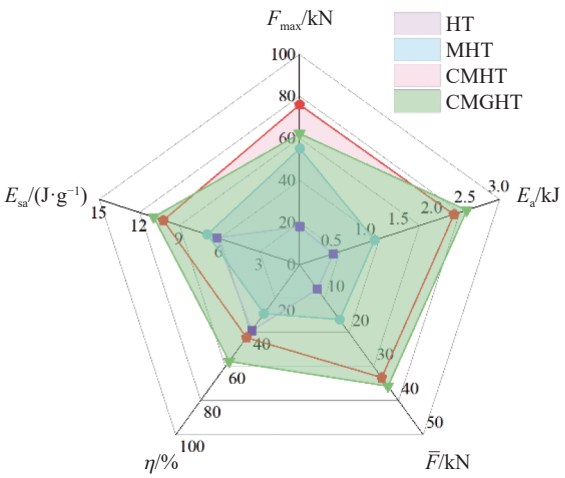

图 5　不同结构管的耐撞性指标雷达图

Fig. 5　Radar chart of crashworthiness indicators for different structural tubes

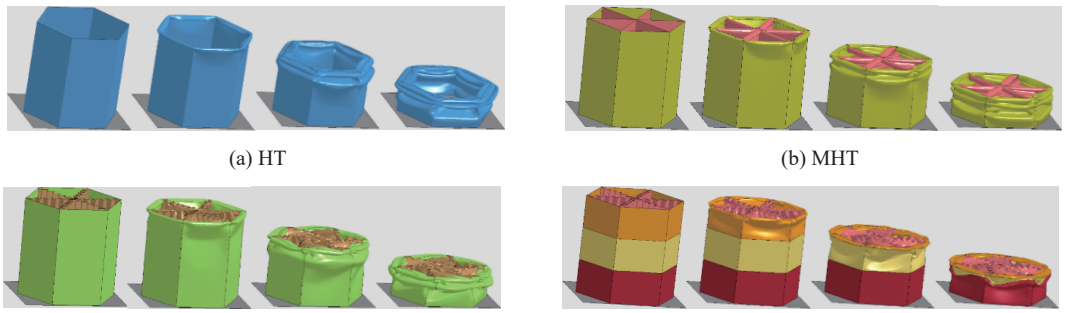

(a) HT　(b) MHT　(c) CMHT　(d) CMGHT

图 6　不同结构管的压缩变形

Fig. 6　Compressive deformation of different structural tubes

2　基于机器学习的 CMGHT 吸能特性预测

2.1　试验设计

CMGHT 的耐撞性能受多个特征参数影响，其中肋板厚度 t_r、肋板正弦波纹幅值 A、外管厚度 t_0 及不同外管长度 D 对其耐撞性能的影响尤为显著。因此，本文选取这四个参数作为关键设计变量，用于后续 CMGHT 力学响应的预测与优化分析。综合考虑轨道交通、航空航天等交通装备工程应用背景，将结构壁厚取值范围设定为 0.5～5 mm，该区间既满足结构轻量化与高比吸能的设计要求，又符合钣金成形、增材制造等主流制备工艺的加工限制[26]；同时经前期有限元试算验证，该范围可较好兼顾结构刚度、承载能力与耐撞吸能特性，属于薄壁吸能结构设计的典型工程取值区间，各参数的具体取值范围如表 3 所示。

表 3　CMGHT 参数取值范围

Table 3　Design parameter ranges for CMGHT

t_r/mm	A/mm	t_0/mm	D/mm
0.5～3	1～3	0.5～5	33.3～70

为便于后续样本选取与分析，t_r 取值从 0.5 mm 开始，取值间隔设为 0.5 mm；考虑到参数特殊性与工程实用性，A 的取值采用整数形式，具体为 1、2、3 mm；因 CMGHT 的外管含梯度设计，故将外管沿长度方向分为外管 1、外管 2、外管 3，各部分厚度取值：外管 1 为 0.5、1.0、1.5、1.0、2.0、3.0 mm；外管 2 为 1.0、1.5、2.0、2.0、3.0、4.0 mm；外管 3 为 1.5、2.0、2.5、3.0、4.0、5.0 mm；外管长度 D 控制外管 1、2、3 占总

长度的比例，外管 1 与外管 2 长度设为相同，通过外管 3 长度调节整体比例，取值为 34、40、50、60、70 mm。

基于全因子试验设计 540 组不同参数的 CMGHT，通过仿真分析获取各结构的力学响应，继而构建完整数据集。将 540 组数据按比例划分为训练集与测试集，训练集占总数据集的 80%，核心用途是对代理模型进行训练，确定模型关键参数；测试集占总数据集的 20%，主要用于验证训练后代理模型的预测准确性与运行可靠性。全因子试验设计虽可实现当前参数空间的全覆盖，但有限元单组样本仿真耗时约 2.5 h，计算成本较高；而引入机器学习模型后，单组样本预测耗时仅 0.01 s，可大幅提升预测与寻优效率。此外，若需进一步拓展参数维度（如肋板波纹形式、厚度梯度规律等），在更大参数空间内开展优化时，机器学习方法将体现出更显著的效率优势与实用价值。

2.2　CPO-SVR 代理模型

支持向量机 (support vector machine, SVM) 算法是基于统计学习理论的监督式机器学习算法[27]，核心原理是从训练样本中筛选一组最优特征子集，通过该子集构建分类超平面，实现对整个数据集的精准划分。凭借优异的学习性能，SVM 已在多领域成功应用，尤其在解决各类分类问题中表现突出[28]。相较于其他算法，SVM 具有显著优势：(1) 预测效率高，所需时间短；(2) 可通过寻求全局最优解，保障目标检测与分类准确；(3) 更擅长处理小样本、非线性及高维数据问题[29]，是线性与非线性关系建模的高效技术；(4) 相比人工神经网络等非参数方法，模型训练与计算耗时更短。鉴于 CMGHT 的力学响应与设计变量间存在强非线性关联，SVM 可通过核函数有效表征变量与结构性能间的非线性耦合关系，在有限仿真样本下仍具备优异的泛化能力与全局最优解求解特性，能充分保障预测精度。同时，有限元仿真计算耗时显著，而 SVM 兼具高效的训练与预测效率，且鲁棒性突出，可替代耗时的数值仿真支撑优化迭代过程，并能适配数据固有误差以维持模型稳定性。因此，选用 SVM 构建 CMGHT 耐撞性能预测的代理模型。

SVM 模型的性能高度依赖两个关键超参数：核参数与惩罚因子。其中，核参数决定核函数的宽度，取值适当时可在捕捉数据局部特征与维持模型全局泛化能力之间达成最优平衡；惩罚因子则用于调控误差容忍度与分类间隔的权衡关系——其值越大，模型越注重最小化训练误差，有助于降低欠拟合风险。在标准 SVM 的实现中，这两个超参数通常保持固定，难以适配不同数据集的多样化需求。为此，本研究采用冠豪猪优化算法 (crested porcupine optimizer, CPO) 对核参数与惩罚因子进行自动寻优，该算法不仅能保障模型的预测精度与泛化性能，还可显著缩短训练耗时。CPO 算法由 Abdel-Basset 等于 2024 年提出，是一种先进的元启发式优化技术，灵感源自自然界中冠豪猪的防御机制，通过模拟其四种防御策略求解复杂优化问题[30]。相较于传统优化算法，CPO 在解决 SVM 超参数优化问题时展现出三大显著优势：较快的收敛速度、卓越的全局搜索能力及优异的中小样本适应性。如表 4 所示，CPO 的平均收敛迭代次数低于主流算法，且迭代稳定后具有最低的适应度。表 5 对 CPO-SVR 预测模型超参数进行对比分析，结果显示，CPO-SVR 模型在超参数配置上表现更优，为后续力学响应预测提供可靠基础。

表 4　不同优化算法模型收敛性能对比[31-33]

Table 4　Comparison of convergence performance among different optimization algorithm models[31–33]

优化算法	平均收敛代数	适应度
遗传算法（GA）	32±8	0.142 00
粒子群算法（PSO）	18±5	0.121 00
CPO	6±3	0.019 89

表 5　SVM 与 CPO-SVR 模型的超参数

Table 5　Hyperparameters of SVM and CPO-SVR models

核心参数	SVM	CPO-SVR	搜寻范围
核参数	1.0	8.1449	[0.1,100]
惩罚因子	0.25	0.9322	[0.01,10]

采用 CPO-SVR 代理模型，对 CMGHT 的耐撞性能进行预测。模型参数设置如下：输入参数选取 4 个关键几何特征，即肋板厚度 t_r、肋板幅值 A、外管厚度 t_0 及不同外管长度 D；输出参数聚焦 3 个核心耐撞性指标，E_{sa}、$\overline{F}$ 与 F_{max}。通过该模型可建立 CMGHT 几何参数与耐撞性指标之间的精准映射关系，进而实现对其耐撞性能的快速预测与定量评估，为后续参数优化提供高效支撑。

2.3　代理模型训练及验证

平均相关系数 R^2 可以反映预测值与训练值间相关性，R^2 在 0～1 的范围内，R^2 越接近 1，模型精度越高。通常，$R^2>0.9$ 被认为具有合理的准确性[34]，其计算方式如下[35]：

$$R^2 = 1 - \sum_{i=1}^{n}(y_i - \hat{y}_i)^2 \Big/ \sum_{i=1}^{n}(y_i - \bar{y})^2 \tag{5}$$

式中：y_i 为第 i 个样本点的 FE 分析值；$\hat{y}_i$ 为对应的代理模型预测值；$\bar{y}$ 为所有样本点 FE 分析结果的平均值；n 为测试样本点的总数。

图 7 给出了 E_{sa}、$\overline{F}$ 与 F_{max} 的测试集预测结果与真实结果的对比。可直观地观察到，基于 CPO-SVR 代理模型的各指标预测值与真实值贴合度较高，误差均处于合理范围内，表明模型训练效果良好。定量验证结果进一步显示，三个指标预测结果的相关系数 R^2 均大于 0.9，充分证明该代理模型具备合理的预测准确性。值得注意的是，三者的 R^2 从大到小依次为 F_{max}、$\overline{F}$、E_{sa}，即模型对 E_{sa} 的预测效果相对最差。其原因可能是 E_{sa} 由 E_a 与结构质量共同决定，而 E_a 需通过结构力-位移曲线在有效压缩位移内的积分计算得出，积分过程中易产生误差积累，最终导致 E_{sa} 的预测误差相对更大。

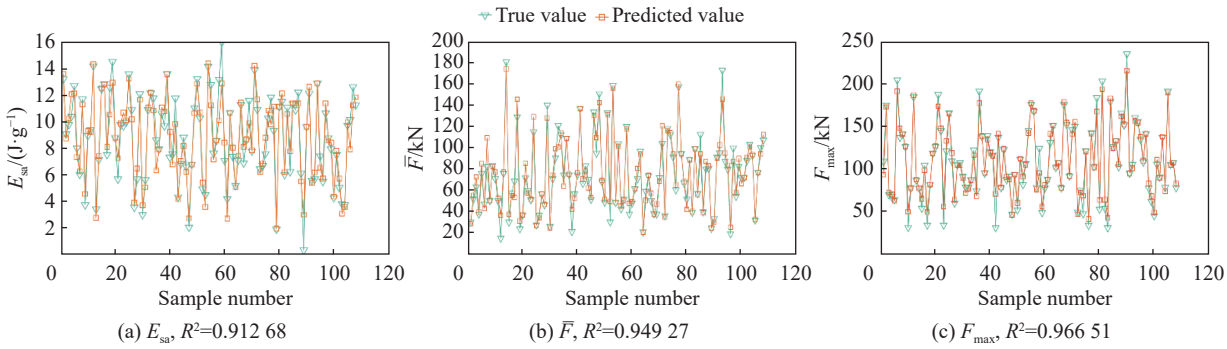

(a) E_{sa}, R^2=0.912 68　　(b) $\overline{F}$, R^2=0.949 27　　(c) F_{max}, R^2=0.966 51

图 7　测试集的预测结果对比

Fig. 7　Comparison of prediction results for test set

本文选取参数取值边界及参数范围外的部分 CMGHT 结构，利用训练完成的代理模型进行耐撞性能预测，并与有限元仿真结果对比，结果如表 6 所示。可见，当参数处于取值边界时，代理模型预测值与仿真结果之间的误差较小；当参数超出取值范围时，预测误差会有所增大，但整体误差仍小于 10%，表明模型预测结果在可控误差范围内，具有较高的预测精度与可靠性。

表 6　参数取值边界处与参数范围外 CMGHT 预测性能

Table 6　CMGHT prediction performance at the parameter boundary and beyond the parameter range

结构参数	E_{sa}/(J·g^{-1})	误差/%	F_{max}/kN	误差/%	$\overline{F}$/kN	误差/%
3.2-3-4.1-72(仿真)	18.12	7.4	251.89	5.2	208.54	6.6
3.2-3-4.1-72(预测)	16.77		238.73		194.71	
3.4-3-1-30(仿真)	13.41	1.8	181.16	5.9	110.41	5.2
3.4-3-1-30(预测)	13.16		170.44		116.20	
0.5-1-1-30(仿真)	6.78	2.3	31.17	9.2	12.67	6.5
0.5-1-1-30(预测)	6.62		34.05		13.5	
3.1-1-4.3-74(仿真)	15.09	4.9	211.02	7.2	154.7	1.9
3.1-1-4.3-74(预测)	14.34		195.82		151.71	
3-1-0.9-30(仿真)	9.99	3.2	113.01	6.5	53.81	4.9
3-1-0.9-30(预测)	9.67		105.60		56.49	

表 6（续）

Table 6 (Continued)

结构参数	E_{sa}/(J·g^{-1})	误差/%	F_{max}/kN	误差/%	$\overline{F}$/kN	误差/%
3-3-4.2-70(仿真)	16.36	3.4	244.92	0.4	193.25	3.6
3-3-4.2-70(预测)	15.81		246.14		186.11	
3-1-1-30(仿真)	10.38	9.7	117.85	4.2	57.45	2.2
3-1-1-30(预测)	11.39		122.88		56.14	
3-3-5-70(仿真)	16.17	0.3	238.62	0.4	187.2	0.5
3-3-5-70(预测)	16.12		237.59		186.2	

3　新型多胞梯度结构多目标优化

3.1　浣熊多目标优化算法

群智能算法是一类基于概率的随机搜索算法，核心机制是通过种群内个体间的相互竞争与协作，在解空间中搜索全局最优解，具备较强的鲁棒性与全局搜索能力[36]。其中，浣熊优化算法（coati optimization algorithm, COA）作为新颖的算法，在收敛速度、寻优精度与鲁棒性三个关键维度上，表现出比其他经典算法更强的优势。Mohammad 等[37] 在 51 个基准函数（CEC-2017 的 29 个+CEC-2011 的 22 个）及四个工程设计问题中，将 COA 与 11 种知名元启发式算法对比，其中与 PSO 和 GA 算法对比如表 7 所示，维度是待优化问题的决策变量数量，是衡量问题复杂程度的最核心指标之一，COA 在单模态、多模态等函数及实际问题中，均值（多次优化目标函数平均值，反映精度）均最优，标准差（反映稳定性）极小，且高维下无性能衰减；收敛速度上，迭代 500 步时 COA 均值已接近全局最优，PSO、GA 仅达其 81.3%、62.9%。综上，COA 在优化精度、稳定性、高维适配性和收敛速度上全面优于对比算法。

表 7　COA 与 PSO 和 GA 的对比[37]

Table 7　Comparison of COA, PSO, and GA[37]

对比维度	COA	PSO	GA
CEC-2017(维度为10)核心函数表现	C1(单模态)：均值为100，标准差为1.33×10^{-5} C3(单模态)：均值为300，标准差为4.64×10^{-14} C10(多模态)：均值为1 270.97，标准差为112.83	C1：均值为3 347.23，标准差为4 427.81 C3：均值为329.38，标准差为8.604 C10：均值为2 013.59，标准差为348.99	C1：均值为12 641 048，标准差为4 849 091 C3：均值为15 733.23，标准差为10 584.32 C10：均值为1 766.65，标准差为320.45
CEC-2017(维度为100)核心函数表现	C4(多模态)：均值为770.53，标准差为51.36 C6(复合函数)：均值为636.39，标准差为2.37 C8(复合函数)：均值为1 393.98，标准差为128.98	C4：均值为2 592.37，标准差为746.46 C6：均值为663.56，标准差为6.46 C8：均值为1 733.68，标准差为66.67	C4：均值为9 756.10，标准差为535.13 C6：均值为665.26，标准差为6.76 C8：均值为2 070.20，标准差为45.98
CEC-2011(实际问题)表现	C11-F1：均值为2.84，标准差为5.69 C11-F7：均值为0.75，标准差为0.12 C11-F12：均值为1 186 100，标准差为42 666.96	C11-F1：均值为19.48，标准差为6.94 C11-F7：均值为1.15，标准差为0.32 C11-F12：均值为2 428 911，标准差为176 214.5	C11-F1：均值为25.59，标准差为1.27 C11-F7：均值为1.83，标准差为0.28 C11-F12：均值为15 862 796，标准差为113 798.6
收敛速度(CEC-2017 维度为30)	迭代500步时，C10函数均值为4 032.98，接近全局最优；收敛曲线陡峭	迭代500步时，C10函数均值为228.98，仅达到COA的81.3%；前期探索缓慢	迭代500步时，C10函数均值为6 407.28，仅达到COA的62.9%；后期收敛停滞

本文选用 MOCOA 与 SVM 代理模型协同开展 CMGHT 结构耐撞性能多目标优化，是由于 MOCOA 的算法特性与 CMGHT 优化需求及 SVM 模型特点高度契合。MOCOA 能够高效平衡全局探索与局部开发能力，有效避免早熟收敛，适用于 CMGHT 中变量与性能强耦合的复杂解空间；同时可生成分布均匀的帕累托最优解集，为结构设计提供多样化决策方案。该算法可调参数少、鲁棒性强，便于工

程应用，且可与 SVM 代理模型高效联动，满足优化过程中频繁的性能评估需求。在此基础上，本文采用分阶段、分任务的算法组合策略：利用 CPO 算法实现 SVM 超参数的低维单目标优化，依托其收敛速度快、寻优精度高的优势，保证模型超参数调节的效率与准确性；利用 MOCOA 算法完成结构参数的高维多目标优化，凭借其帕累托解集均匀、鲁棒性优异的特点，实现多目标最优解的高效搜索。该组合方式可避免单一算法在跨维度优化中难以兼顾不同性能要求、易产生性能折中等问题，使各优化阶段与算法特性精准匹配，提升整体优化效果与可靠性。

COA 主要包括两个阶段，分别为模仿浣熊群对鬣蜥蜴捕猎过程的探索阶段和模拟浣熊群逃脱捕食者追捕过程的开发阶段。探索阶段在浣熊群进行捕猎时，整个群体分工明确，具备良好的团体配合与攻击策略。假设一只鬣蜥蜴正在树上休息，此时一个浣熊群打算对该鬣蜥蜴进行猎杀。首先一半的浣熊开始悄悄爬上树梢，逼迫鬣蜥蜴掉落地上。上树过程可以表示为：

$$x_i^{\mathrm{P1}}: x_{i,j}^{\mathrm{P1}} = x_{i,j} + r(y_j - Ix_{i,j}) \qquad i = 1,2,\cdots,[N/2], \qquad j = 1,2,\cdots,m \tag{6}$$

式中：P1 为探索阶段，y 为鬣蜥蜴的位置信息，r 为属于［0,1］的常数，I 为集合{1,2}中的随机整数，x 为浣熊个体位置，N 是种群规模（浣熊数量），m 为决策变量的维度（优化问题的变量个数），x_i^{P1} 为探索阶段中第 i 只浣熊的位置向量，$x_{i,j}^{\mathrm{P1}}$ 为探索阶段中第 i 只浣熊在第 j 维决策变量上的具体取值。假设鬣蜥蜴落地位置具有随机性，落地后另一半浣熊开始朝猎物移动，进行围捕猎杀。这一过程可描述为：

$$y^G: y_j^G = l_j + r(u_j - l_j) \qquad j = 1,2,\cdots,m \tag{7}$$

$$X_i^{\mathrm{P1}}: X_{i,j}^{\mathrm{P1}} = \begin{cases} x_{i,j} + r\times(y_j^{\mathrm{G}} - Ix_{i,j}) & F_{y^{\mathrm{G}}} < F_i \\ x_{i,j} + r\times(x_{i,j} - y_j^{\mathrm{G}}) & F_{y^{\mathrm{G}}} \geqslant F_i \end{cases}$$
$$i = [N/2]+1,[N/2]+2,\cdots,N, \qquad j = 1,2,\cdots,m \tag{8}$$

式中：y^{G} 为鬣蜥蜴落地后的位置，u、l 分别为决策空间（优化问题中所有合法候选解构成的集合）上界和下界，X 为浣熊种群（种群 X 是一个 $N\times m$ 的矩阵），$F_{y^{\mathrm{G}}}$ 为第 G 代迭代中鬣蜥蜴位置 y^{G} 对应的目标函数值，F_i 为第 i 只浣熊（第 i 个候选解）当前位置对应的目标函数值。

开发阶段中浣熊在遇到捕食者时，会迅速离开当前位置完成撤离，这一过程可以描述为：

$$l_j^{\mathrm{local}} = l_j/t, \quad u_j^{\mathrm{local}} = u_j/t \qquad t = 1,2,\cdots,T \tag{9}$$

$$X_i^{\mathrm{P2}}: X_{\mathrm{i,j}}^{\mathrm{P2}} = x_{i,j} + (1-2r)[l_j^{\mathrm{local}} + r(u_j^{\mathrm{local}} - l_j^{\mathrm{local}})] \qquad i = 1,2,\cdots,N, \quad j = 1,2,\cdots,m \tag{10}$$

式中：t 为当前迭代次数，T 为最大迭代次数，X_i^{P2} 为开发阶段中第 i 只浣熊的位置向量，$X_{i,j}^{\mathrm{P2}}$ 为 X_i^{P2} 的第 j 维分量，u_j^{local} 为第 j 维决策变量的局部上界。l_j^{local} 为第 j 维决策变量的局部下界。每个阶段的浣熊位置更新后都需要进行检查，以确保更新是有效的，检查方式如下：

$$x_i = \begin{cases} X_i^{\mathrm{P1,P2}} & F_i^{\mathrm{P1,P2}} < F_i \\ X_i & \text{other} \end{cases} \tag{11}$$

式中：X_i 为第 i 只浣熊更新前的原始位置，$X_i^{\mathrm{P1,P2}}$ 为第 i 只浣熊经过探索阶段或开发阶段更新后的新位置，$F_i^{\mathrm{P1,P2}}$ 为第 i 只浣熊更新后的位置 $X_i^{\mathrm{P1,P2}}$ 对应的目标函数。

与单目标优化不同，多目标优化算法的最优解不再是一个解而是一组帕累托解集，也就是说同一时间鬣蜥蜴不再是一只而是一个群体。引入 NSGA-II[38] 中的快速非支配排序与拥挤度距离计算方法，首先对种群所有个体进行两阶段的更新，更新后的浣熊称为子代个体，更新前的浣熊成为父代个体。对所有父代与子代个体一同进行快速非支配排序，并确定各等级下的非支配前沿 Q_c（c=1, 2, ⋯, K），Q_c 为一个个体集合，包含所有属于第 c 级非支配解的浣熊个体，c 为非支配前沿的等级编号，K 为当前种群中所有非支配前沿的总数量。然后计算 Q_c 中每只浣熊的拥挤度距离。最后选出新的种群，选择过程如下：

$$P^{G+1}=\begin{cases}P_0\cup\sum_{c=1}^{K}Q_c & |P_0+Q_c|\leqslant N\\ P_0\cup Q_c^{N-|P_0|} & \text{other}\end{cases}\tag{12}$$

式中：P^{G+1} 为第 G+1 代的新种群集合，包含 N 个个体，P_0 为已被选中进入下一代的个体集合，初始时为空集，$|\cdot|$ 为集合的基数，即集合中包含的个体数量，$Q_c^{N-|P_0|}$ 为从第 c 级非支配前沿中选择 $N-|P_0|$ 个个体，当集合中个体数小于 N 时，依次将 Q_c 个体前沿加入 P_0，当 $|P_0+Q_K|>N$，则根据拥挤度距离依次选出数值最大的个体，直到 P_0 中个体数为 N。

MOCOA 中，COA 的部分更新规则不再适用，其中式 (6) 中 y_j 不再代表每代中的最优个体，而代表 Q_c 中的随机个体。同时采用精英浣熊保留策略的 MOCOA 不再需要式 (11) 来检查更新后的有效性。MOCOA 的具体优化步骤如下（见图 8）：

Step 1，初始化种群，并设置超参数，包括种群规模、每个决策变量的取值上下界、最大迭代次数等；

Step 2，随机初始化所有浣熊个体信息，并计算相应的适应度值；

Step 3，对种群进行快速非支配排序，并计算个体拥挤度距离；

Step 4，随机选取 Q_c 中的个体作为 y_j，并根据式 (6)～(11) 完成浣熊个体更新；

Step 5，根据式 (12)，即精英浣熊保留策略，选出新的种群 P^{G+1}；

Step 6，检查算法是否满足终止条件，若不满足，则转 Step 4，直到满足终止条件，输出帕累托前沿。

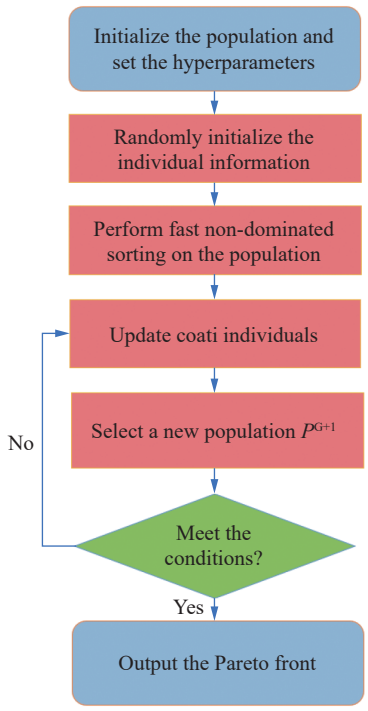

图 8　MOCOA 流程

Fig. 8　Flowchart of MOCOA.

3.2　多目标寻优结果

CMGHT 的多目标优化问题可描述为：

$$\begin{cases}\text{Find } \boldsymbol{d}[t_r,A,t_0,D]^{\mathrm{T}}\\ \min\{f_1(p),f_2(p),f_3(p)\}\\ f_1(p)=-E_{\mathrm{sa}}(p)\\ f_2(p)=F_{\max}(p)\\ f_3(p)=-\overline{F}(p)\end{cases}\quad s.t.\begin{cases}t_r\in[0.5,3.0]\,\mathrm{mm}\\ A\in[1,3]\,\mathrm{mm}\\ t_0\in[0.5,5]\,\mathrm{mm}\\ D\in[33.3,70]\,\mathrm{mm}\end{cases}\tag{13}$$

式中：$\boldsymbol{d}$ 为设计变量向量，是整个优化问题的求解对象；p 为设计点，是设计变量向量 d 的一个具体实例。

针对 CMGHT 四输入三输出的多目标优化问题，采用 MOCOA 进行求解，其核心参数种群规模 $N=100$，能够适应四输入三输出耦合系统的中等复杂度，该规模能够在设计变量空间中有效覆盖关键区域，从而规避早熟收敛。最大迭代次数 $T=200$，是根据 CMGHT 目标函数所具有的非线性特征设定的迭代次数，以确保算法能够完整经历“探索-收敛-优化”全过程，且总体计算时间处于可接受的研究周期内，较好地平衡了收敛精度与计算成本。外部存档容量（非支配排序阈值通过存档容量与拥挤度筛选协同确定）$N_{\mathrm{r}}=150$，该容量设定为大于种群规模，旨在完整保留演化过程中的精英解，避免优质方案丢失，同时适应三目标优化中非支配解的数量需求，保障解集的多样性。通过合理控制存档规模，可避免后续方案

筛选工作量过大，结合拥挤度筛选机制，进一步促进解集在目标空间中均匀分布。综上，上述参数组合在解空间覆盖度、收敛精度与计算效率之间实现了有效平衡，能够充分适应本研究优化问题的需求，从而为仿真结果的可靠性提供保障。

多目标优化得到的帕累托前沿解集如图 9 所示。从理论层面而言，所有帕累托前沿解的综合性能均优于原始解集，因此本文采用最小距离法，从三个帕累托前沿的二维平面中筛选性能最接近理想点的解，具体筛选过程如图 10 所示，通过最小距离法，先在三个不同输入参数构成的二维坐标系中筛选出理想点，再基于理想点从三维帕累托前沿解集中确定三个拐点，最终得到三个帕累托前沿最优解(见表 8)。对这三个最优解的图形分布及输出特征进行参数分析发现，尽管它们是基于不同输入参数、通过最小距离法筛选得出，但均紧密聚集在帕累托前沿的中心区域附近。这一分布特征充分验证了本文采用最小距离法筛选最优解的合理性与必要性，确保所选解具备更均衡的综合耐撞性能。

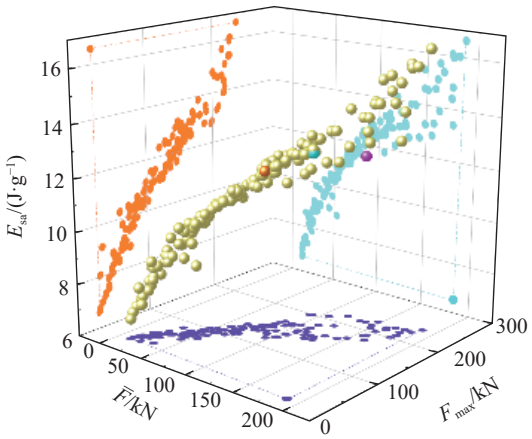

图 9　帕累托前沿解

Fig. 9　Pareto front solutions.

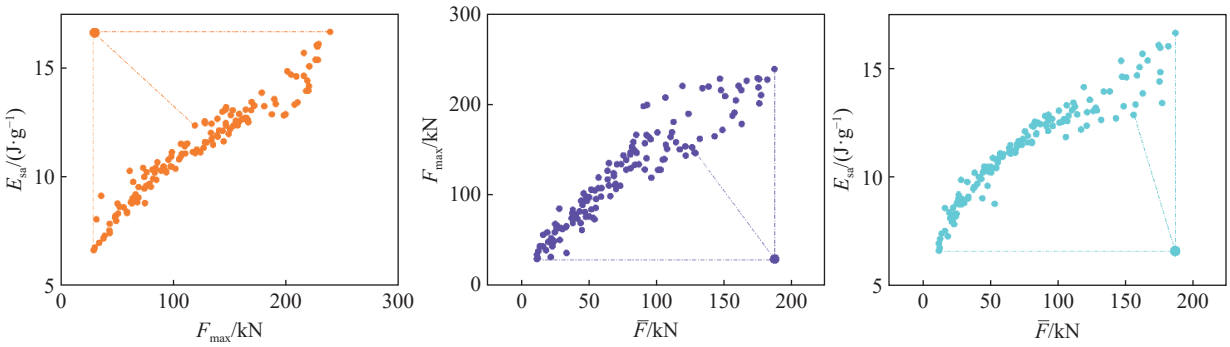

(a) E_{sa}-F_{max} Pareto front solutions　(b) F_{max}-$\overline{F}$ Pareto front solutions　(c) E_{sa}-$\overline{F}$ Pareto front solutions

图 10　帕累托解集的平面投影

Fig. 10　Plane projection of Pareto solution set

表 8　三个帕累托最优解的结构参数

Table 8　Structural parameters of three Pareto optimal solutions

解	t_r/mm	A/mm	t_0/mm	D/mm
A	3.0	3	1.5-2.2-2.4	65
B	2.5	3	0.9-2.2-5.0	48
C	3.0	3	0.5-1.8-4.1	44

3.3　多目标寻优结果分析

对三个帕累托最优解展开对比分析，从中筛选出综合性能最好的解，并通过有限元仿真验证该最优解的可靠性。需要说明的是，此前多目标优化为“四输入三输出”模式，其中三个输出参数仅包含耐撞性能指标中 E_{sa}、$\overline{F}$ 与 F_{max}，未直接纳入 E_a 与 η。由于 η 可通过帕累托前沿解集中已有的 $\overline{F}$ 与 F_{max} 计算得出，为更全面地对比三个最优解的综合性能，表 9 补充 η 指标进行分析。从表中数据对比可见，三个帕累托最优解的性能各有侧重：解 A 的 F_{max} 远小于解 B 与解 C，但 E_{sa} 与 $\overline{F}$ 也低于后两者；解 C 的 $\overline{F}$ 为三者最大，F_{max} 同样是三者中最高，且 E_{sa} 小于解 B。综合权衡耐撞性能均衡性，最终选择解 B 作为最优解——

其不仅在 E_{sa} 与 η 上表现最佳，同时 F_{max} 与 $\overline{F}$ 相较于解 A、解 C 也保持在较优水平，综合性能更均衡。为验证解 B 的可靠性，将其参数构建 FE 仿真模型结果与解 B 的预测结果进行对比，如表 10 所示，可以看出所有误差均小于 4%，证明帕累托前沿解的准确性。由上述分析结果可见，基于机器学习构建的代理模型相较传统预测模型优势显著，该类模型无需预设函数形式，可精准拟合 CMGHT “特征参数-吸能特性”间的强非线性耦合关系，同时依托正则化、交叉验证等策略有效抑制过拟合，泛化能力更优，训练完成后可快速输出预测结果，与 MOCOA 等多目标优化算法高度适配。该模型能够替代耗时的有限元数值仿真，大幅降低优化迭代的计算成本，可良好适配 CMGHT 的迭代设计需求。

表 9　三种帕累托最优解的对比

Table 9　Comparison of the three Pareto optimal solutions

解	E_{sa}/(J·g^{-1})	F_{max}/kN	$\overline{F}$/kN	η/%
A	12.35	118.92	96.3	80
B	13.06	146.03	129.1	88
C	12.86	187.11	156.2	83

表 10　模拟结果与预测结果的对比

Table 10　Comparison of the simulation and prediction results

方法	E_{sa}/(J·g^{-1})	F_{max}/kN	$\overline{F}$/kN
预测	13.06	146.03	129.1
仿真	13.33	150.81	132.1
误差	2%	3.1%	2.2%

图 11 为优化后 CMGHT 的力-位移曲线，可以看出，该结构的 F_{max} 出现在有效压缩行程末端，撞击载荷随压缩位移增大呈梯度上升趋势，此特征与管壁厚度沿压溃方向递增的梯度结构设计直接相关。该梯度设计可有效降低结构的 F_{max}，使结构的变形吸能过程更趋稳定，同时通过调控各段管材的长度与厚度参数，能够实现对有效压缩行程内压缩力变化规律的精准调控。此外，从图 12 可看出，该结构整体呈现对称且稳定的压溃变形模式，全程未出现弯曲失稳现象，变形产生的褶皱均匀分布于外管 1、2、3 的表面，进一步验证了其压缩吸能过程的稳定性。内嵌肋板则与外管形成协同变形效应，在压溃过程中随外管逐步变形并相互挤压，进一步提升了结构的整体能量吸收效率。

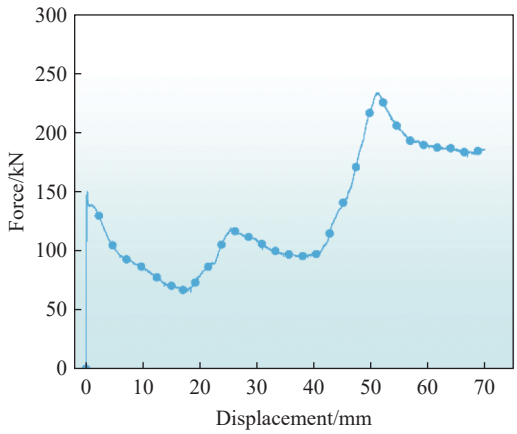

图 11　解 B 有限元仿真力-位移曲线

Fig. 11　Force-displacement curve of FE simulation for Solution B

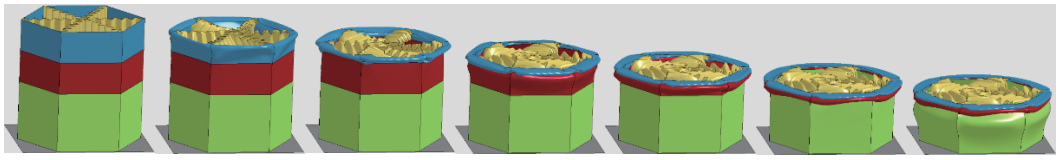

(a) Overall deformation

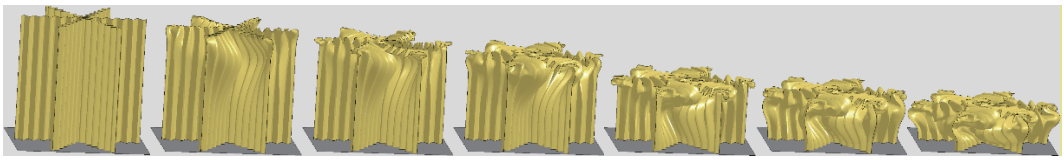

(b) Rib plate deformation

图 12　优化后 CMGHT 压缩变形

Fig. 12　Deformation sequence of the optimized CMGHT

表 11 为优化前后 CMGHT 各组件的吸能对比结果，因结构参数存在差异，直接对比各组件吸收能量无法直观体现优化后结构的吸能优势，故本文进一步分析了各组件吸收能量在 CMGHT 总吸能中的占比。由表中数据可见，优化后结构外管的吸能占比显著提升，而优化前结构的外管吸能能力未得到充分发挥。造成该现象的核心原因是，优化前外管梯度厚度分布与肋板厚度的参数组合并非最优，导致结构力-位移曲线的梯度上升效果不佳、载荷波动明显（见图 4），而优化后 CMGHT 的力-位移曲线梯度上升特性更优，载荷变化更为平缓（见图 11）。表 12 进一步给出了优化前后 CMGHT 核心吸能指标的对比结果，优化后 CMGHT 的 E_{sa} 提升 22%，$\overline{F}$ 提升 270%，η 提升 53%。核心吸能指标的大幅改善，充分验证了本文所采用的多目标优化方法的有效性，该方法可切实提升 CMGHT 的综合耐撞性能。

表 11　CMGHT 优化前后各组件吸能对比

Table 11　Comparison of energy absorption of each component before and after CMGHT optimization

对照组	外管吸能/kJ	占比/%	肋板吸能/kJ	占比/%	外管-肋板相互作用耗能/kJ	占比/%	E_a/kJ
优化前	0.59	23.6	1.80	72.0	0.11	4.4	2.50
优化后	3.25	35.1	5.61	60.7	0.39	4.2	9.25

表 12　CMGHT 基础模型与优化后 CMGHT 的耐撞性能对比

Table 12　Comparison of the crashworthiness performances between original CMGHT and optimized CMGHT

对照组	E_{sa}/(J·g^{-1})	η/%	$\overline{F}$/kN
优化前	10.96	57.41	35.7
优化后	13.33	87.59	132.1

4　结　论

本研究融合多胞、波纹与功能梯度设计理念，提出了 CMGHT 的集成设计方法，主要结论如下。

(1) 构建了不同类型多胞管的有限元模型并开展数值模拟。结果显示，CMGHT 的吸收能量、比吸能、平均压缩力和压缩力效率，与相同壁厚的 HT 相比分别提升 390%、76%、395%、46%，与 MHT 相比，分别提升 121%、58%、121%、97%，与 CMHT 相比，分别提升 7%、7%、8%、33%，同时 CMGHT 的初始峰值压缩力相比 CMHT 降低 18%。CMGHT 相较于其他吸能结构具有更优异的吸能特性。

(2) 以 CMGHT 的肋板与外管几何参数为设计变量，采用全因子试验设计生成 540 个样本点；随后构建 CPO-SVR 代理模型，以几何参数为输入、耐撞性能为输出。结果表明，该代理模型能准确预测 CMGHT 的吸能特性，为后续结构优化提供可靠基础。

(3) 将训练完成的 CPO-SVR 代理模型与 MOCOA 结合，对 CMGHT 进行多目标优化，最终得到最优特征参数。与优化前的 CMGHT 基础模型相比，优化后结构的比吸能提升 22%、压缩力效率提升 53%、平均压缩力提升 270%，综合耐撞性能显著改善。

参考文献：

[1]　朱擎, 李述涛, 陈叶青, 等. 细长薄壁弹冲击下高强钢-混凝土复合结构的厚度极限计算模型 [J]. 爆炸与冲击, 2026. DOI: 10.11883/bzycj-2025-0023.
ZHU Q, LI S T, CHEN Y Q, et al. Calculation model for the thickness limit of high-strength steel-concrete composite structures under the impact of slender thin-walled projectiles [J]. Explosion and Shock Waves, 2026. DOI: 10.11883/bzycj-2025-0023.

[2]　LIU W Y, LIN Z Q, WANG N L, et al. Dynamic performances of thin-walled tubes with star-shaped cross section under axial impact [J]. Thin-Walled Structures, 2016, 100: 25–37. DOI: 10.1016/j.tws.2015.11.016.

[3]　RONG Y, LIU J X, LUO W, et al. Effects of geometric configurations of corrugated cores on the local impact and planar

compression of sandwich panels [J]. Composites Part B: Engineering, 2018, 152: 324–335. DOI: 10.1016/j.compositesb.2018.08.130.

[4] TIWARI G, IQBAL M A, GUPTA P K. Energy absorption characteristics of thin aluminium plate against hemispherical nosed projectile impact [J]. Thin-Walled Structures, 2018, 126: 246–257. DOI: 10.1016/j.tws.2017.04.014.

[5] YAHAYA M A, RUAN D, LU G, et al. Response of aluminium honeycomb sandwich panels subjected to foam projectile impact-an experimental study [J]. International Journal of Impact Engineering, 2015, 75: 100–109. DOI: 10.1016/j.ijimpeng.2014.07.019.

[6] MOHAMMADI H, AHMAD Z, PETRŮ M, et al. An insight from nature: honeycomb pattern in advanced structural design for impact energy absorption [J]. Journal of Materials Research and Technology, 2023, 22: 2862–2887. DOI: 10.1016/j.jmrt.2022.12.063.

[7] XIANG Y F, YU T X, YANG L M. Comparative analysis of energy absorption capacity of polygonal tubes, multi-cell tubes and honeycombs by utilizing key performance indicators [J]. Materials & Design, 2016, 89: 689–696. DOI: 10.1016/j.matdes.2015.10.004.

[8] TANG Z L, LIU S T, ZHANG Z H. Analysis of energy absorption characteristics of cylindrical multi-cell columns [J]. Thin-Walled Structures, 2013, 62: 75–84. DOI: 10.1016/j.tws.2012.05.019.

[9] KHANCHEHZAR P, NIKNEJAD A, AMIRHOSSEINI S G. Influences of different internal stiffeners on energy absorption behavior of square sections during the flattening process [J]. Thin-Walled Structures, 2016, 107: 462–472. DOI: 10.1016/j.tws.2016.07.006.

[10] JIN M Z, HOU X H, YIN G S, et al. Improving the crashworthiness of bio-inspired multi-cell thin-walled tubes under axial loading: experimental, numerical, and theoretical studies [J]. Thin-Walled Structures, 2022, 177: 109415. DOI: 10.1016/j.tws.2022.109415.

[11] DENG X L, LIU W Y, JIN L. On the crashworthiness analysis and design of a lateral corrugated tube with a sinusoidal cross-section [J]. International Journal of Mechanical Sciences, 2018, 141: 330–340. DOI: 10.1016/j.ijmecsci.2018.03.001.

[12] LI Z X, YAO S G, MA W, et al. Energy-absorption characteristics of a circumferentially corrugated square tube with a cosine profile [J]. Thin-Walled Structures, 2019, 135: 385–399. DOI: 10.1016/j.tws.2018.11.028.

[13] BAYKASOGLU C, CETIN M T. Energy absorption of circular aluminium tubes with functionally graded thickness under axial impact loading [J]. International Journal of Crashworthiness, 2015, 20(1): 95–106. DOI: 10.1080/13588265.2014.982269.

[14] XU F, TIAN X, LI G. Experimental study on crashworthiness of functionally graded thickness thin-walled tubular structures [J]. Experimental Mechanics, 2015, 55(7): 1339–1352. DOI: 10.1007/s11340-015-9994-3.

[15] XU F X. Enhancing material efficiency of energy absorbers through graded thickness structures [J]. Thin-Walled Structures, 2015, 97: 250–265. DOI: 10.1016/j.tws.2015.09.020.

[16] 朱创, 丁喆, 黄垲轩. 基于智能优化算法的梯度点阵结构承载性能优化设计 [J]. 力学学报, 2025, 57(11): 2733–2745. DOI: 10.6052/0459-1879-25-256.
ZHU C, DING Z, HUANG K X. Optimization design of load-bearing performance for graded lattice structures based on intelligent optimization algorithms [J]. Chinese Journal of Theoretical and Applied Mechanics, 2025, 57(11): 2733–2745. DOI: 10.6052/0459-1879-25-256.

[17] WANG C, KOH J M, YU T T, et al. Material and shape optimization of bi-directional functionally graded plates by GIGA and an improved multi-objective particle swarm optimization algorithm [J]. Computer Methods in Applied Mechanics and Engineering, 2020, 366: 113017. DOI: 10.1016/j.cma.2020.113017.

[18] MIAO F X, JIN Y. Crashworthiness analysis and structural optimization of thin-walled circular tubes with porous arrays [J]. Structures, 2024, 70: 107811. DOI: 10.1016/j.istruc.2024.107811.

[19] LI P F, XIAO J M. Crashworthiness design and multi-objective optimization of bionic thin-walled hybrid tube structures [J]. Computer Modeling in Engineering & Sciences, 2024, 139(1): 999–1016. DOI: 10.32604/cmes.2023.044059.

[20] YIN H F, XIAO Y Y, WEN G L, et al. Crushing analysis and multi-objective optimization design for bionic thin-walled structure [J]. Materials & Design, 2015, 87: 825–834. DOI: 10.1016/j.matdes.2015.08.095.

[21] ZHANG Z Y, FENG C, ZHAO L B, et al. Crashworthiness analysis and optimization design of special-shaped thin-walled tubes by experiments and numerical simulation [J]. Thin-Walled Structures, 2024, 205: 112240. DOI: 10.1016/j.tws.

2024.112240.

[22] HA N S, LU G X. Thin-walled corrugated structures: a review of crashworthiness designs and energy absorption characteristics [J]. Thin-Walled Structures, 2020, 157: 106995. DOI: 10.1016/j.tws.2020.106995.

[23] ZHANG X, ZHANG H. Energy absorption of multi-cell stub columns under axial compression [J]. Thin-Walled Structures, 2013, 68: 156–163. DOI: 10.1016/j.tws.2013.03.014.

[24] FU J, LIU Q, LIUFU K M, et al. Design of bionic-bamboo thin-walled structures for energy absorption [J]. Thin-Walled Structures, 2019, 135: 400–413. DOI: 10.1016/j.tws.2018.10.003.

[25] ABRAMOWICZ W. The effective crushing distance in axially compressed thin-walled metal columns [J]. International Journal of Impact Engineering, 1983, 1(3): 309–317. DOI: 10.1016/0734-743X(83)90025-8.

[26] 李昊霖, 陈洪胜, 柴斐, 等. 带网格内筋铝合金壳体热旋压组织与性能 [J]. 航空学报, 2026, 47(3): 431981. DOI: 10.7527/S1000-6893.2025.31981.
LI H L, CHEN H S, CHAI F, et al. Microstructure and performance of hot spinning of aluminum alloy shell with internal grid reinforcement [J]. Acta Aeronautica et Astronautica Sinica, 2026, 47(3): 431981. DOI: 10.7527/S1000-6893.2025.31981.

[27] YANG W D, LOU Z Z, JI B. A multi-factor analysis model of quantitative investment based on GA and SVM [C]// Proceedings of 2nd International Conference on Image, Vision and Computing (ICIVC). Chengdu: IEEE, 2017: 1152–1155. DOI: 10.1109/ICIVC.2017.7984734.

[28] KAREEM F Q, ABDULAZEEZ A M. Ultrasound medical images classification based on deep learning algorithms: a review [J]. Fusion: Practice and Applications, 2021, 3(1): 29–42. DOI: 10.54216/FPA.030102.

[29] TAO P Y, SUN Z, SUN Z X. An improved intrusion detection algorithm based on GA and SVM [J]. IEEE Access, 2018, 6: 13624–13631. DOI: 10.1109/ACCESS.2018.2810198.

[30] ZHANG D K, HAN Y, WANG C L, et al. Time series prediction of tunnel surrounding rock deformation using CPO-CLA integrated model [J]. Journal of Rock Mechanics and Geotechnical Engineering, 2025, 17(12): 7915–7930. DOI: 10.1016/j.jrmge.2025.03.050.

[31] ZHENG M, LI T, SUN L P, et al. An automatic sampling ratio detection method based on genetic algorithm for imbalanced data classification [J]. Knowledge-Based Systems, 2021, 216: 106800. DOI: 10.1016/j.knosys.2021.106800.

[32] ZHANG D R, MA G, DENG Z R, et al. A self-adaptive gradient-based particle swarm optimization algorithm with dynamic population topology [J]. Applied Soft Computing, 2022, 130: 109660. DOI: 10.1016/j.asoc.2022.109660.

[33] DAS S C, KHAN M A A, SHAIKH A A, et al. Interval valued inventory model with different payment strategies for green products under interval valued Grey Wolf optimizer algorithm fitness function [J]. Egyptian Informatics Journal, 2024, 28: 100561. DOI: 10.1016/j.eij.2024.100561.

[34] TAN H L, HE Z C, LI E, et al. Crashworthiness design and multi-objective optimization of a novel auxetic hierarchical honeycomb crash box [J]. Structural and Multidisciplinary Optimization, 2021, 64(4): 2009–2024. DOI: 10.1007/s00158-021-02961-9.

[35] 范升阳, 栗建桥. 薄壁椭球壳在冲击载荷作用下的动态变形模型 [J]. 爆炸与冲击, 2025, 45(8): 083301. DOI: 10.11883/bzycj-2024-0062.
FAN S Y, LI J Q. Dynamic deformation model of thin-walled ellipsoidal shells under impact loading [J]. Explosion and Shock Waves, 2025, 45(8): 083301. DOI: 10.11883/bzycj-2024-0062.

[36] 刘苗苗, 张玉莹, 郭景峰, 等. 融合多策略改进的自适应狮群优化算法 [J]. 北京邮电大学学报, 2024, 47(1): 85–93. DOI: 10.13190/j.jbupt.2022-276.
LIU M M, ZHANG Y Y, GUO J F, et al. Improved adaptive lion swarm optimization algorithm based on multi-strategy [J]. Journal of Beijing University of Posts and Telecommunications, 2024, 47(1): 85–93. DOI: 10.13190/j.jbupt.2022-276.

[37] DEHGHANI M, MONTAZERI Z, TROJOVSKÁ E, et al. Coati optimization algorithm: a new bio-inspired metaheuristic algorithm for solving optimization problems [J]. Knowledge-Based Systems, 2023, 259: 110011. DOI: 10.1016/j.knosys.2022.110011.

[38] 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. DOI: 10.1109/4235.996017.

(责任编辑　王小飞)