

## 面向抗冲击结构尺寸优化的自训练分类判断优化设计方法

王春彭, 高汝鑫, 廉艳平, 成湛山, 李明健

## A SELF-TRAINING CLASSIFICATION JUDGEMENT OPTIMIZATION METHOD FOR THE IMPACT-RESISTANT STRUCTURAL SIZE OPTIMIZATION

Wang Chunpeng, Gao Ruxin, Lian Yanping, Cheng Zhanshan, and Li Mingjian

在线阅读 View online: <https://doi.org/10.6052/0459-1879-24-057>

---

### 您可能感兴趣的其他文章

Articles you may be interested in



关注微信公众号, 获得更多资讯信息

# 面向抗冲击结构尺寸优化的自训练分类判断优化设计方法<sup>1)</sup>

王春彭 高汝鑫 廉艳平<sup>2)</sup> 成湛山 李明健

(北京理工大学先进结构技术研究院, 北京 100081)

**摘要** 抗冲击结构在军民安全领域有着广泛且重要的应用,但其优化设计因涉及极端载荷下的强非线性而面临结构响应求解耗时与灵敏度分析困难的挑战.针对该问题,本文提出了一种自训练分类判断优化设计方法.该方法采用基于支持向量机的自训练分类判断代理模型和遗传算法,求解抗冲击结构尺寸优化列式.与基于回归代理模型的传统方法不同,自训练分类判断代理模型可以减少样本集构建计算成本.同时,提出了面向分类判断代理模型的遗传算法约束处理策略及个体适应度计算方法.基于该方法开展的波纹夹芯结构抗爆性能和聚脲/陶瓷复合板抗侵彻性能优化设计,验证了其有效性和高效性.本文工作为抗冲击结构设计提供了一种新的高效优化方法,以期保障极端冲击载荷下装备结构服役性能和人员安全.

**关键词** 极端载荷, 数据驱动, 代理模型, 序列优化, 结构优化

中图分类号: O63 文献标识码: A doi: 10.6052/0459-1879-24-057

## A SELF-TRAINING CLASSIFICATION JUDGEMENT OPTIMIZATION METHOD FOR THE IMPACT-RESISTANT STRUCTURAL SIZE OPTIMIZATION<sup>1)</sup>

Wang Chunpeng Gao Ruxin Lian Yanping<sup>2)</sup> Cheng Zhanshan Li Mingjian

(Institute of Advanced Structure Technology, Beijing Institute of Technology, Beijing 100081, China)

**Abstract** Impact-resistant structures have a broad application and play a crucial role in military and civilian safety. However, such structure optimization suffers from the time-consuming issue of the structure dynamic response analysis and finds sensitivity analysis difficult due to the strong non-linearity associated with the extreme loading. In this study, a self-training classification judgment optimization method is proposed. This method utilizes a self-training classification judgment surrogate model based on support vector machines and a genetic algorithm to solve the size optimization problem of impact-resistant structures. Different from the regression-based conventional surrogate models, the self-training classification judgment surrogate model reduces the computational cost of the sample dataset. Moreover, a constraint-handling strategy and a fitness calculation method are introduced to integrate the classification judgment surrogate model into the genetic algorithm. Two examples, including the optimization of the blast-resistant corrugated sandwich structures and the penetration-resistant polyurea/ceramic composite plate, are presented to showcase the effectiveness and efficiency of the proposed method. It is expected that the proposed novel method with high efficiency

收稿, 录用, 网络版发表.

1) 国家自然科学基金 (No.11972086) 和中央高校基本科研业务费专项资金资助项目.

2) 通讯作者: 廉艳平, 教授, 主要研究方向为极端多场计算力学. E-mail: yanping.lian@bit.edu.cn

引用格式: 王春彭, 高汝鑫, 廉艳平, 成湛山, 李明健. 面向抗冲击结构尺寸优化的自训练分类判断优化设计方法. 力学学报, 待出版

Wang Chunpeng, Gao Ruxin, Lian Yanping, Cheng Zhanshan, Li Mingjian. A self-training classification judgement optimization method for the impact-resistant structural size optimization. *Chinese Journal of Theoretical and Applied Mechanics*, in press

for impact-resistant structures optimization is capable of ensuring the service performance of equipment structures and personnel safety under extreme impact loadings.

**Key words** Extreme loading, Data-driven, Surrogate model, Sequence optimization, Structure optimization

## 引言

军用和民用装备在服役过程中面临极端载荷的威胁,其防护水平很大程度上取决于结构的抗冲击性能.传统的工程经验设计方法已难以满足当前抗冲击结构的快速迭代设计与严苛性能指标等要求<sup>[1]</sup>,亟需发展有效的结构优化设计方法.然而,抗冲击结构优化问题涉及复杂动态载荷下的材料、几何和部件接触等强非线性,导致结构响应求解耗时、灵敏度求解困难<sup>[2]</sup>,给现有抗冲击结构优化设计方法带来了巨大的挑战.

目前,针对抗冲击结构的优化设计方法主要有三种.第一种方法是 Park 等<sup>[3-4]</sup>发展的等效静荷载法 (Equivalent Static Loads method, ESL);其主要思想是通过构造等效静力载荷,将复杂的非线性动力优化问题转化为经典的线弹性静力优化问题,进而开展结构优化设计. Park 等<sup>[5]</sup>采用该算法开展了单一/多种载荷下平板、米歇尔结构、燃料组件定位格架、法兰支架的优化设计.在此基础上, Lee 等<sup>[6]</sup>采用双层迭代的优化流程设计吸能盒;其在外层迭代中开展非线性动力响应分析,校核结构的性能并更新等效分析静力模型,在内层迭代中求解线弹性静力优化问题并更新外层迭代中的结构设计.然而,基于线弹性的静荷载难以充分重现结构在大变形时的动态效应,且使用线性灵敏度求解非线性优化问题所获得构型的有效性仍有待深入研究<sup>[7]</sup>.第二种方法是 Tovar 等<sup>[8]</sup>建立的混合元胞自动机法 (Hybrid cellular automation, HCA);其主要思想是将元胞自动机与有限元分析结合,基于准则法获得优化设计,具备收敛速度快的优点. Tovar 等<sup>[9]</sup>采用该方法对薄壁结构的厚度分布进行优化,以提升其耐撞性能. Gan 等<sup>[10]</sup>提出了一种将 HCA 与双向进化结构优化法相结合的拓扑优化算法,并应用于结构的耐撞性设计.刘等<sup>[11]</sup>发展了基于 HCA 的变厚度薄壁梁耐撞性优化方法,并通过设计薄壁结构的合理厚度分布以提升其侧向耐撞性能.毕等<sup>[12]</sup>基于 HCA 开展了装甲车辆底部防护组件的概念设计研究,进而从工程角度解读概念设计以获取设计原型,最后通过尺寸优

化确定加强梁的最终参数以提升其抗爆性能. Goetz 等<sup>[13]</sup>应用 HCA 研究了基于钢和铝材的复合装甲结构设计以提升其抗爆性能. Bohara 等<sup>[14]</sup>则将 HCA 与参数优化相结合,开展了轻质吸能拉胀结构 (Auxetic structures) 的设计. Francisco 等<sup>[15]</sup>利用 HCA 优化结构的截面材料布局,设计了沿厚度方向具有自由形状孔洞的抗弹钢板,并通过试验验证了结构的有效性.然而, HCA 基于应变能均匀准则开展优化设计,但特定的准则通常仅适用于特定的优化问题<sup>[7]</sup>.

相对于上述两种方法,基于代理模型的优化方法 (Surrogate-based Optimization, SBO) 应用较为广泛.其基本思想是通过构建输入与输出间的直接映射以替代优化过程中耗时的数值分析,结合相应的智能优化算法实现抗冲击结构优化设计,具有较高的优化效率<sup>[16]</sup>.目前, SBO 采用的代理模型包括多项式响应面 (Response Surface Method, RSM), 克里金模型 (Kriging Model, KG)、径向基函数 (Radial basis function, RBF)、神经网络 (Neural network, NN) 等. Wang 等<sup>[17]</sup>结合 RSM 代理模型和粒子群优化算法,开展了基于负泊松比夹芯三明治结构的抗爆车门优化设计,以提升其吸能量和轻量化水平. Cai 等<sup>[18]</sup>结合 KG 代理模型和多目标遗传算法,开展了空爆载荷下波纹夹芯板结构的尺寸优化设计以提升其抗爆性能. Cong 等<sup>[19]</sup>则采用 KG 代理模型和遗传算法,开展了爆炸载荷下军用车辆底部 V 型车体形状优化设计,在提高整车抗爆炸冲击的同时保障乘员生存的能力. Johnson 等<sup>[20]</sup>采用 RBF 代理模型和遗传算法,对军用车辆底盘截面形貌进行优化设计,以提升其在地雷爆炸荷载下的抗冲击性能. Qi 等<sup>[21]</sup>采用 NN 代理模型和多目标遗传算法,开展了考虑爆炸载荷强度变化的金属泡沫铝夹芯结构尺寸优化设计,以提高结构抗爆性能的鲁棒性. Saini 和 Shafei<sup>[22]</sup>采用 KG 与 RBF 两种代理模型和多目标遗传算法,开展了建筑物外壳中隔热板优化设计,以提高其抗冲击性能.除此之外, SBO 在舵面结构优化<sup>[23]</sup>、翼型气动外形优化<sup>[24, 25]</sup>、加筋柱壳结构优化<sup>[26]</sup>、连梁金属阻尼器优化<sup>[27]</sup>等问题中也有广泛的应用.上述

工作均采用基于回归的代理模型 (例如 KG、RSM、RBF 等) 预测极端载荷下结构力学响应物理量的具体数值, 存在样本集总体计算成本高、相应的优化复杂度高等问题。

针对上述存在的问题, 本文提出了一种自训练分类判断优化设计方法。该方法采用一种基于分类判断的代理模型和面向该代理模型的遗传算法。考虑到支持向量机 (Support Vector Machine, SVM) 是一种高效解决二分类问题的机器学习算法, 并广泛应用于模式识别、计算机视觉、自然语言处理等领域<sup>[28-29]</sup>, 本文发展了基于 SVM 的自训练分类判断代理模型。该代理模型无需预测结构防护性能的具体数值, 直接判断其是否满足指定的防护性能指标, 从而将回归预测转化为分类判断以减少样本数值分析模型计算开销和相应的优化复杂度。其中, 通过序列添加样本点迭代更新代理模型以提高其在重点区域 (例如, 最优解附近) 而非整个设计空间的近似精度, 进一步降低训练代理模型所需的样本规模, 从而提高整体优化计算效率。进一步, 提出了面向分类判断代理模型的遗传算法约束处理策略以解决分类判断代理模型无法评估不可行解违约度的问题, 并给出了个体自适应度计算方法。最后, 采用本文提出的

方法开展了波纹夹芯结构的抗爆性能、陶瓷/聚脲复合结构的抗弹性能的优化设计, 验证了其有效性和高效性。

本文章节安排如下: 第 1 章详细阐述所提出的抗冲击结构的分类判断优化设计方法; 第 2 章和第 3 章分别介绍所提出算法在波纹夹芯结构抗爆性能优化和陶瓷/聚脲复合板抗冲击性能优化的应用; 第 4 章为结论和展望。

## 1 自训练分类判断优化设计方法

自训练分类判断优化设计方法的基本思想如图 1 所示, 其求解的是面向分类判断代理模型的抗冲击结构优化列式。该方法首先基于初始小样本构建数据集, 其次采用该数据集训练基于支持向量机的分类判断代理模型, 进而通过遗传算法优化获得新一代中的最优样本点, 若该样本点不满足收敛条件则将其加入数据集以更新分类判断代理模型, 继续迭代优化直至收敛以获得最终设计构型。因此, 本节依次从相应的优化列式、自训练分类判断代理模型、面向分类判断代理模型的遗传算法 (Genetic algorithm, GA) 三部分内容, 阐述本文所提出的优化设计方法。

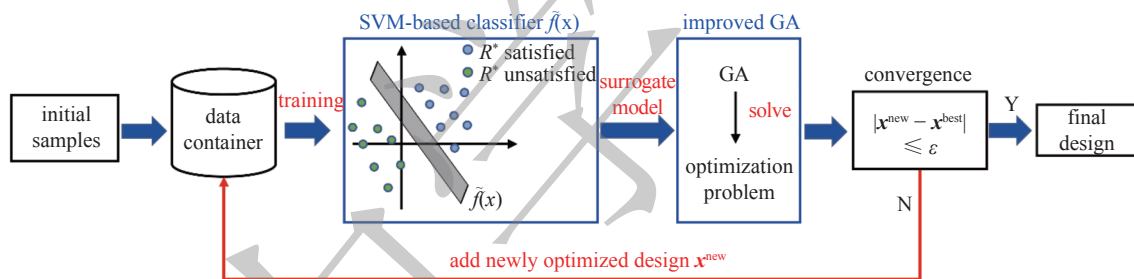


图 1 分类判断优化设计方法示意图

Fig. 1 Schematic diagram of classification judgement optimization method

### 1.1 结构优化列式

针对抗冲击结构轻量化设计问题, 建立面向分类判断代理模型的结构优化列式。为此, 首先将其转化为求解含约束的单目标优化问题, 如式 (1) 所示。其中, 以满足防护性能指标 (例如, 吸能量、剩余弹速等) 为约束, 通过优化结构几何参数实现轻量化设计的目标, 具体如下

$$\begin{aligned}
 & \text{find } \boldsymbol{x} \\
 & \text{min } M(\boldsymbol{x}) \\
 & \text{s.t. } \boldsymbol{R}(\boldsymbol{x}) \leq \boldsymbol{R}^* \\
 & \quad \boldsymbol{x}_l \leq \boldsymbol{x} \leq \boldsymbol{x}_h
 \end{aligned} \quad (1)$$

式中,  $\boldsymbol{x}$  为结构参数, 作为优化设计变量, 其上下限分别为  $\boldsymbol{x}_l$  和  $\boldsymbol{x}_h$ ;  $M(\boldsymbol{x})$  为结构质量, 作为优化目标;  $\boldsymbol{R}(\boldsymbol{x})$  和  $\boldsymbol{R}^*$  分别为结构防护性能和所要求的防护性能指标。

在分类判断优化设计算法中, 式 (2) 为待求解的结构优化列式。不同于基于回归的代理模型 (例如, 克里金法、多项式响应面模型等), 基于分类判断的代理模型仅判断结构是否满足防护性能指标, 即直接预测  $\boldsymbol{R}(\boldsymbol{x})$  是否小于  $\boldsymbol{R}^*$ 。因此, 进一步将式 (1) 改写为



$$\begin{aligned}
& \text{find } \mathbf{x} \\
& \min M(\mathbf{x}) \\
& \text{s.t. } \begin{cases} \tilde{f}(\mathbf{x}) \leq 0 \\ \mathbf{x}_l \leq \mathbf{x} \leq \mathbf{x}_h \end{cases} \quad (2)
\end{aligned}$$

其中,  $\tilde{f}(\mathbf{x})$  为分类判断代理模型的预测值, 取值为-1 或 +1, 分别表示结构满足或不满足防护性能指标. 然而, 在具体验证算例中, 结构优化列式仍采用式 (1) 描述.

## 1.2 自训练分类判断代理模型

本文采用支持向量机 (SVM) 建立上述优化列式中二分类问题的分类判断代理模型. SVM 通过找到一个决策边界将设计空间划分为两个区域, 其中满足结构防护性能指标的设计点位于一侧, 不满足防护性能指标的设计点则位于另一侧. 两个区域的边界称为决策边界<sup>[26]</sup>, 并采用  $\phi(\mathbf{x})$  表示如下

$$\phi(\mathbf{x}) = \varphi(\mathbf{x})^T * \mathbf{w} + b \quad (3)$$

式中,  $\varphi$  为核函数, 上标 T 表示转置;  $\mathbf{w}$  是权重列向量以定义决策边界的方向和位置;  $b$  为偏置项以调整决策边界的位置. 通过对不同核函数的试算对比 (参考附录 E), 本文确定的核函数为  $\varphi(\mathbf{x}) = \mathbf{x}$ , 相应的决策边界为超平面. 关于 SVM 算法的进一步介绍, 请参见附录 A.

基于所训练的 SVM, 构建本文的自训练分类判断代理模型. 为确定权重列向量和偏置项, 采用包含  $N$  对输入特征和类别标签的样本集  $X = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_N, y_N)\}$  训练 SVM. 其中, 输入特征为结构的设计参数  $\mathbf{x}$ , 而类别标签  $y$  取值为-1 或 +1. 完成训练后可获得权重向量  $\mathbf{w}$  和偏置  $b$ , 进而确定决策边界函数  $\phi(\mathbf{x})$ ; 通过符号函数  $\text{sign}$  将  $\phi(\mathbf{x})$  的值映射为-1 或 +1, 从而实现了对结构  $\mathbf{x}$  是否满足防护性能指标进行判断. 因此, 分类判断代理模型可表示为

$$\tilde{f}(\mathbf{x}) = \text{sign}(\varphi(\mathbf{x})^T * \mathbf{w} + b) \quad (4)$$

该分类判断代理模型无需预测结构防护性能 (如剩余弹速、吸能量等) 的具体数值, 因此可在样本准备过程中提前终止已违反约束的样本的数值分析模型计算, 从而降低构建样本集的总计算开销.

为进一步提高优化效率, 本文采用自适应添加样本点的方式迭代训练分类代理模型. 若式 (4) 是经一次抽样训练而获得的代理模型, 则称其为静态代理模型 (static surrogate model). 为获得高预测精度的同时具有一定的泛化能力,  $N$  需取值较大但也存在

无法确定具体数值的难题, 相应的样本集计算成本也成比例增加. 为解决该问题, 本文提出自适应添加样本点的方式迭代训练上述代理模型, 并称其为自训练分类判断代理模型. 如图 1 所示, 新样本点  $\mathbf{x}^{\text{new}}$  取自于优化设计迭代过程中产生的优异个体, 即

$$\mathbf{x}^{\text{new}} = \text{argmin} M(\mathbf{x}), \text{ s.t. } \tilde{f}(\mathbf{x}) \leq 0 \quad (5)$$

式中, “argmin”表示在满足约束条件下使  $M(\mathbf{x})$  最小的参数. 采用数值分析模型获取新样本点  $\mathbf{x}^{\text{new}}$  的标签  $y^{\text{new}}$ , 并将新样本点  $(\mathbf{x}^{\text{new}}, y^{\text{new}})$  添加到现有的样本集中, 形成新样本集  $X^{\text{new}} = \{X, (\mathbf{x}^{\text{new}}, y^{\text{new}})\}$ . 进一步, 利用新样本集  $X^{\text{new}}$  训练分类判断代理模型. 模型停止训练的条件为: 新添加样本点  $\mathbf{x}^{\text{new}}$  与现有样本集  $X$  中最优点  $\mathbf{x}^{\text{best}}$  之间相对偏差的最大值小于设定阈值  $\epsilon$ , 即

$$\max \left\{ \left| \frac{x_i^{\text{new}} - x_i^{\text{best}}}{x_i^{\text{best}}} \right|, \dots, \left| \frac{x_D^{\text{new}} - x_D^{\text{best}}}{x_D^{\text{best}}} \right| \right\} \leq \epsilon \quad (6)$$

其中,  $D$  为样本点  $\mathbf{x}$  的特征维度, 即优化设计变量的维度; 若  $x^{\text{best}}$  中含 0 分量, 则采用小值代替.

综上所述, 相对于静态代理模型, 自训练分类判断代理模型可采用较小的  $N$  值完成初始构建, 可实现对设计空间的有效取样, 并有助于提高遗传算法的优化效率.

## 1.3 面向分类判断代理模型的遗传算法

本文采用遗传算法求解 1.1 节中所提出的优化列式 (2). 为此, 需发展面向分类判断代理模型的遗传算法. 遗传算法求解过程包含约束处理、适应度计算、个体选择、交叉变异等步骤. 为避免赘述, 本节着重阐述其中与分类判断代理模型相关的内容.

在约束处理方面, 本文提出了一种处理不可行解的新策略. 对于含约束的优化问题, 通常需要将其转化为无约束优化问题以适用于遗传算法求解. 为此, 本文采用可行性准则将优化列式 (2) 转化为无约束优化问题. 该准则要求可行解始终优于任何不可行解且可行解中目标函数值较小的个体解占优, 不可行解中违反约束程度低的个体解占优. 因此, 按照传统处理方式获得的无约束优化问题为

$$\min_x F(\mathbf{x}) = \begin{cases} M(\mathbf{x}) & \text{if } \mathbf{x} \in \mathbb{N} \\ M^* + \tilde{f}(\mathbf{x}) & \text{otherwise} \end{cases} \quad (7)$$

式中,  $\mathbb{N}$  为可行域;  $M^*$  为种群内目标值最大的个体. 然而, 由式 (7) 可知, 不可行解中的个体  $\tilde{f}(\mathbf{x})$  始终为 +1, 导致无法确定占优的个体解. 为此, 本文提出采用个体

多样性代替违约度评估的策略, 以解决式 (7) 中不可行解无法确定个体占优的问题. 违约个体的多样性表示违约个体与种群内其它个体的差异, 具体计算如下

$$d(\mathbf{x}) = \frac{1}{N_p} \times \sum_{j=1}^{N_p} \sum_{i=1}^D \|x_i - x_i^j\| \quad (8)$$

式中,  $N_p$  为种群内个体总数. 考虑到多样性程度越高  $d(\mathbf{x})$  值越大, 采用  $\frac{1}{d(\mathbf{x})}$  评估违约个体的可行性, 从而可令多样性程度高的违约个体具有相对较高的可行性. 因此, 基于新的约束处理策略, 将式 (7) 改写为

$$\min_{\mathbf{x}} \tilde{F}(\mathbf{x}) = \begin{cases} M(\mathbf{x}) & \text{if } \mathbf{x} \in \mathbb{N} \\ M^* + \frac{1}{d(\mathbf{x})} & \text{otherwise} \end{cases} \quad (9)$$

在适应度计算方面, 采用基于等级划分的方法计算个体的适应度. 在优化过程中, 种群内个体表示为优化问题的一个潜在设计方案, 而适应度用以量化该方案的优劣性. 依据式 (9) 中的  $\tilde{F}(\mathbf{x})$  对个体进行排序, 进而根据排序中的个体位置确定其适应度.

具体计算如下

$$f_i = 2 - SP + (SP - 1) \times \frac{n_i - 1}{N_p - 1} \quad (10)$$

式中,  $f_i$  为第  $i$  个个体的适应度;  $n_i$  为第  $i$  个个体在种群内的排序位置;  $SP$  为选择压差.

在个体选择方面, 采用轮盘赌选择法使个体的被选择概率与其适应度成正比. 因此, 种群内第  $i$  个个体被选择的概率  $p_i$  为

$$p_i = \frac{f_i}{\sum_{i=1}^{N_p} f_i}, i = 1, 2, \dots, N_p \quad (11)$$

最后, 针对上述选出的具有较高适应度的父代, 对其进行均匀交叉和均匀变异操作, 以生成新一代种群. 通过不断重复整个进化过程, 从而提高整体适应度, 推动种群向最优解的方向演化.

#### 1.4 算法流程

本文所提出的自训练分类判断优化设计方法的计算流程如图 2 所示. 各步骤具体介绍如下:

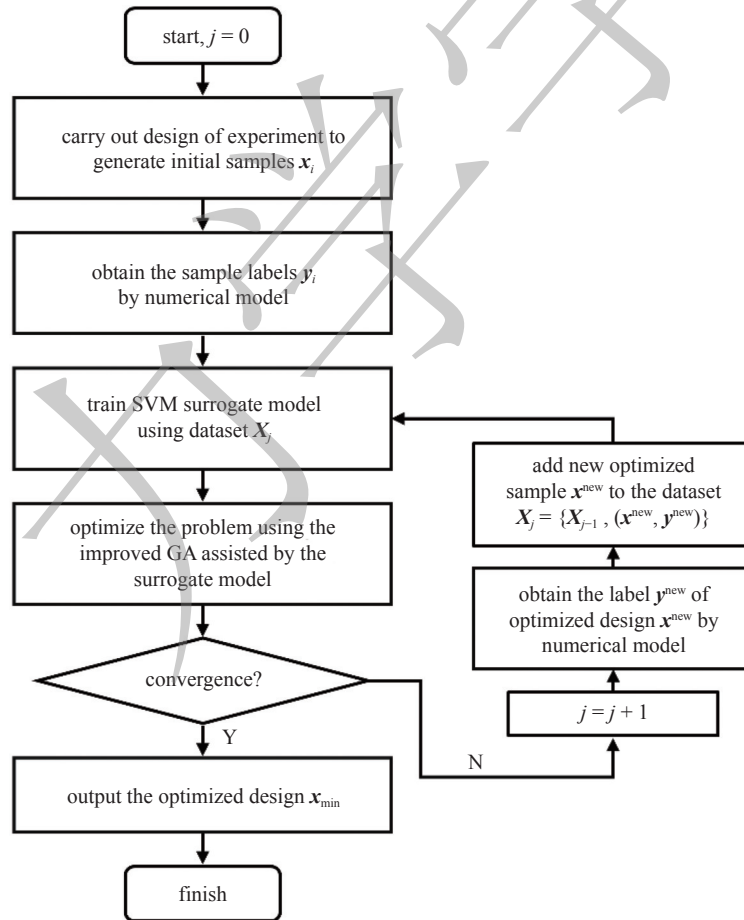


图 2 算法流程图

Fig. 2 Flow-chart of the proposed method

(1) 根据试验设计方法, 在设计空间中确定  $N$  个初始样本点  $\mathbf{x}_i$ , 此时循环次数  $j = 0$ ;

(2) 针对初始样本点开展数值分析, 获取样本标签  $y_i$ , 形成样本集  $X_j = \{(\mathbf{x}_i, y_i), \dots, (\mathbf{x}_N, y_N)\}$ ;

(3) 基于样本集  $X_j = \{(\mathbf{x}_i, y_i), \dots, (\mathbf{x}_N, y_N)\}$ , 训练分类代理模型  $\tilde{f}_j$ ;

(4) 结合分类代理模型  $\tilde{f}_j$  和遗传算法进行优化求解, 获得第  $j$  次循环的优化解  $\mathbf{x}^{\text{new}}$ ;

(5) 检查是否收敛: 若满足收敛条件, 优化停止, 输出优化设计  $\mathbf{x}_{\text{min}}$ ; 否则  $j = j + 1$ , 继续执行下一步骤;

(6) 针对新样本点  $\mathbf{x}^{\text{new}}$ , 开展数值分析获得其标签  $y^{\text{new}}$ , 并组成新样本集  $X_j = \{X_{j-1}, (\mathbf{x}^{\text{new}}, y^{\text{new}})\}$ , 然后转至步骤 (3), 继续迭代。

针对抗冲击结构优化设计, 上述优化设计方法将涉及大量几何模型生成及数值分析模型计算、代理模型更新. 为此, 本文采用 Python 语言实现上述算法和求解流程的自动化. 为验证所提出方法的有效性和高效性, 开展了波纹夹芯结构抗爆性能优化设计和陶瓷/聚脲复合板抗侵彻性能优化设计, 并分别阐述于第 2 节和第 3 节. 其中, 优化设计所需的参数设置为: SVM 代理模型的正则化系数  $C$  设为 5, 阈值  $\epsilon$  为 5%; 遗传算法中的种群数  $N_p$  设置为 50, 最大迭代步数为 500, 选择压差 SP 为 1.5, 交叉概率和变异概率分别设置为 0.5 和 0.02. 本文所有算例均在处理器为 Intel Core i9-9900 K、内存为 32 GB 的台式计算机上执行计算, 包括算例中的结构响应分析、代理模型训练以及迭代优化设计等。

## 2 波纹夹芯结构抗爆性能优化设计

### 2.1 优化问题描述

波纹夹芯结构具有优异的抗爆性能, 在军用车辆、高速列车等装备上具有广泛的应用前景. 图 3 为一典型的波纹夹芯结构, 其抗爆性能与迎爆面板厚度 ( $T_f$ )、波纹芯层厚度 ( $T_c$ )、背爆面板厚度 ( $T_b$ )、波纹芯层高度 ( $H_c$ )、波纹折边角度 ( $\phi$ ) 密切相关<sup>[28]</sup>. 因此, 本节选取上述尺寸参数作为优化设计变量, 以结构吸能量 ( $EA$ )、背板最大挠度 ( $MaxD$ ) 作为结构防护性能的评价指标, 开展波纹夹芯结构在空爆载荷下的抗爆性能优化设计. 该问题具体设置如图 3 所示, 其中波纹板长 ( $L$ ) 为 300 mm、宽 ( $W$ ) 为 288 mm, 空爆载荷为距上面板中心 100 mm




图 3 空爆载荷下波纹夹芯结构的优化设计

Fig. 3 Optimization of corrugated sandwich structure under explosive loading in the air

处圆柱形 TNT 炸药 (质量为 55 g、半径为 17.5 mm、高度为 37.2 mm). 参考文献<sup>[28]</sup> 的试验结果, 设置上述优化设计变量的取值范围, 具体如式 (12) 所示.

依据结构优化列式 (1), 上述问题的优化列式表示为

$$\begin{aligned}
 & \text{find } \mathbf{x} = \{T_f, T_c, T_b, H_c, \phi\} \\
 & \text{min } M(\mathbf{x}) \\
 & \quad EA \geq EA^* \\
 & \quad MaxD \leq MaxD^* \\
 & \quad 1 \text{ mm} \leq T_f \leq 2 \text{ mm} \\
 \text{s.t. } & \quad 0.5 \text{ mm} \leq T_c \leq 1.5 \text{ mm} \\
 & \quad 1 \text{ mm} \leq T_b \leq 2 \text{ mm} \\
 & \quad 10 \text{ mm} \leq H_c \leq 20 \text{ mm} \\
 & \quad 30^\circ \leq \phi \leq 70^\circ
 \end{aligned} \tag{12}$$

式中,  $EA^*$  和  $MaxD^*$  分别表示所要求的波纹夹芯结构吸能量、背板挠度防护性能指标, 并依据具体问题设定. 本文以文献<sup>[30]</sup> 中命名为 TZ-2 试样 (其  $T_f = T_b = 1.38 \text{ mm}$ ,  $T_c = 0.7 \text{ mm}$ ,  $H_c = 14 \text{ mm}$ ,  $\phi = 45^\circ$ ) 的吸能量和最大背板挠度值为基准, 确定  $EA^* = 580\text{J}$  和  $MaxD^* = 16 \text{ mm}$ .

### 2.2 波纹夹芯结构动态响应分析

#### 2.2.1 数值分析模型设置

本节采用商用有限元法 (Finite element method, FEM) 程序开展 304 不锈钢波纹夹芯结构在空爆炸荷载作用下的动态响应数值分析. 考虑到该问题的对称性, 采用四分之一建模, 如图 4 所示. 其中, 芯层水平段固定于上下面板, 考虑夹芯结构各部件间的



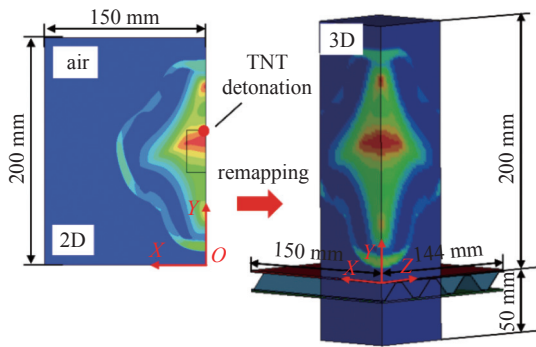


图 4 波纹夹芯结构空爆载荷下动态响应的数值计算模型

Fig. 4 Numerical simulation model for the dynamic response of corrugated sandwich structure under explosive loading in the air

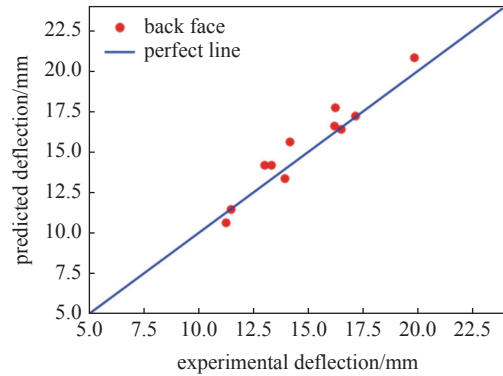
接触、结构与流体间的相互作用. 夹芯结构的对称面和外周分别设置对称边界和固支边界条件; 流体域的对称面设置对称边界条件, 其余四个表面设置无反射边界条件.

在材料域离散方面, 波纹夹芯结构采用 Belytschko-Tsay 壳单元离散, 流体域和炸药采用多物质任意拉格朗日-欧拉单元离散求解. 通过网格收敛性分析 (参见附录 B), 设置结构和空气域的单元尺寸分别为 1 mm 和 2 mm, 以兼顾数值模拟精度和计算效率. 同时, 为降低计算规模, 采用载荷映射技术实现夹芯结构与爆轰产物的相互作用计算. 其中, 首先将 TNT 炸药的爆轰问题简化为二维问题求解 (单元尺寸设为 0.3 mm), 待爆轰波前沿接近结构上表面时, 将其压力状态映射为三维求解域中 (单元尺寸设为 2 mm) 并实现其与夹芯结构的相互作用, 如图 4 所示.

在材料本构方面, 304 不锈钢材料采用 Johnson-Cook 本构模型, 其物性参数取自文献<sup>[31]</sup>并列于附录 C 表 C1, 同时采用基于等效塑性应变的失效模型, 并参考文献<sup>[32]</sup>的试验结果设为 0.42. 空气域采用空材料模型和多项式状态方程, 相关物性参数列于附录 C 表 C2. TNT 炸药初始密度为 1630 kg/m<sup>3</sup>, 爆速取值为 6930 m/s, 采用 Jones-Wilkins-Lee (JWL) 状态方程, 相关物性参数列于附录 C 表 C3.


### 2.2.2 数值分析模型验证

采用上述数值分析模型模拟了文献<sup>[28]</sup>中开展的相关试验, 以验证其计算精度. 其中, 选取爆距为 100 mm 的试验工况中 11 种不同几何参数组合下波纹夹芯结构面板背爆面中点处挠度值为参考, 将其与数值模拟预测值对比于图 5. 结果表明, 背爆面面板挠度值计算结果与试验结果相一致, 分布于斜率

图 5 结构背爆面中心挠度的试验结果<sup>[30]</sup>与数值结果对比Fig. 5 Comparison of the deflection of the rear face center between the experimental data<sup>[30]</sup> and numerical results

为 1 的基准线附近.

进一步, 图 6 对比分析了文献<sup>[30]</sup>中 TZ-2 试件变形模式试验结果与数值模拟结果. 如图 6 所示, 虽然数值模拟结果中没有复现试验结果中的波纹夹芯结构前面板的裂现象, 但所预测的前面板弯曲变形和压痕变形、波纹壁板的屈曲、背板的塑性弯曲变形与试验结果一致, 验证了数值分析模型计算精度和计算参数的可靠性.

图 6 波纹夹芯结构变形模式的数值模拟结果和试验结果<sup>[30]</sup>对比Fig. 6 Comparison of deformation patterns of the corrugated sandwich structure between the experimental data<sup>[30]</sup> and numerical results

### 2.3 代理模型构建

采用上述波纹夹芯结构数值分析模型生成训练样本集, 构建基于支持向量机的分类判断代理模型. 针对式 (12) 中几何参数取值范围, 首先采用拉丁超立方抽样方法 (Latin hypercube Sampling, LHS) 生成样本数为 30 的初始样本集  $X$ . 然后, 通过数值模拟获取样本点  $x_i$  的吸能量  $E_i$  和最大背板挠度  $MaxD_i$ ; 若  $E_i \geq 580J$  且  $MaxD_i \leq 16 mm$ , 则样本点的标签  $y_i$  设置为 -1, 否则为 1. 进而, 基于初始样本集  $X = \{(x_i, y_i), \dots, (x_N, y_N)\}$ , 分别建立针对吸能量和背板最大挠度的代理模型; 采用额外随机生成的 15 个样本校核代理模型. 其中, 针对吸能量代理模



型的分类准确性为 100%, 针对背板最大挠度代理模型的分类型准确性为 93.33%. 进一步, 在迭代优化过程中, 基于优化列式 (12) 所获得的优化设计构型  $\mathbf{x}^{\text{new}}$ , 通过数值模拟获得其相应标签  $\mathbf{y}^{\text{new}}$ , 并将  $(\mathbf{x}^{\text{new}}, \mathbf{y}^{\text{new}})$  添加到现有样本集中, 重新训练分类判断代理模型直至收敛.

## 2.4 优化结果

表 1 对比了波纹夹芯结构优化前后的结构尺寸参数与相应的抗冲击防护性能. 相比于参考结构, 优化后的结构吸能量  $EA$  增加 28.01%、背板最大挠度  $MaxD$  下降 6.52%、质量  $M$  减轻 18.85%.

图 7 对比了优化前后结构的位移云图和变形模式. 结合表 1 和图 7 所示结构变形模式可知, 陡峭 (较大的折边角度  $\phi$ ) 的波纹板芯层、较大的芯层高度  $H_c$ 、较小的芯层壁厚  $T_c$  有利于芯层塑性变形以吸能, 同时减小载荷对背板的冲击.

为验证本文所提出方法在初始样本数需求小、整体计算效率高的优势, 进一步基于静态代理模型开展了上述问题的优化设计. 为此, 分别采用 30、60、

90、120 个样本以训练获得 4 个静态代理模型. 其中, 每次试算均采用 LHS 抽样. 结果表明, 采用样本数为 120 时所训练的代理模型时, 遗传算法方可获得满足抗爆性能指标 (即  $EA \geq 580\text{J}$  和  $MaxD \leq 16\text{mm}$ ) 的结构几何参数, 相应结构重量为 511.32 g, 如表 2 所示. 然而, 自训练代理模型仅需 40 个样本 (包括 30 个初始样本和 10 个新添加样本) 就可结合遗传算法获得满足抗爆性能指标的结构 ( $EA = 722.65\text{J}$ 、 $MaxD = 15.19\text{mm}$ ), 相应结构重量为 505.34 g. 其中, 10 个新添加样本点的信息列于附录 F 表 F1. 由表 2 对比可知, 虽然基于两种代理模型训练策略优化后结构的质量、吸能量  $EA$ 、背板最大挠度  $MaxD$  相近, 但基于自训练代理模型的计算成本约为静态代理模型的 33%. 这是由于自训练代理模型通过对优化设计空间进行自适应采样, 提高对重点区域而非整个设计空间的分类精度, 因此可减少代理模型训练所需的数据集规模, 从而降低计算成本. 为此, 采用主成分分析法 (Principal Component Analysis, PCA) 在二维空间中可视化初始样本和新添加样本点的分布情况. 如图 8 所示, 采用 LHS 抽样获得的初始样本 (红色点) 均匀分布在整个设计空间中; 新

表 1 参考设计与优化后设计

Table 1 Reference and optimized designs

	Reference value	Optimized value
$T_f$ (mm)	1.38	1.00
$T_b$ (mm)	1.38	1.00
$T_c$ (mm)	0.7	0.5
$H_c$ (mm)	14.00	19.69
$\phi$ (°)	45.00	69.62
$EA$ (J)	564.54	722.65
$MaxD$ (mm)	16.25	15.19
$M$ (g)	622.75	505.34




图 7 结构的位移场对比

Fig. 7 Comparison of the displacement field between

表 2 基于不同动态代理模型的优化结果及计算开销

Table 2 Optimized results and the computational costs with different dynamic surrogate models

	Mass (g)	$EA$ (J)	$MaxD$ (mm)	Cost (h)
SVM	505.34	722.65	15.19	93.75
KG (MSP)	499.83	726.14	15.43	175.23
KG (EI)	503.59	724.09	15.88	135.97
RSM	513.89	663.82	15.76	148.39
RBFNN	500.96	733.43	15.30	164.20

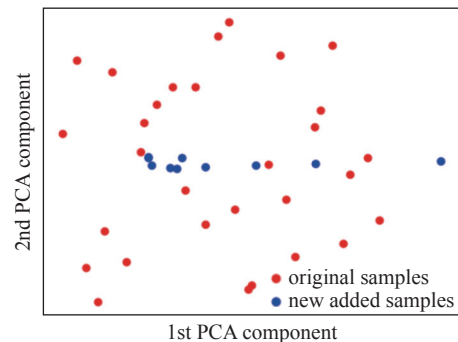


图 8 初始和新添加样本点分布的 PCA 可视化

Fig. 8 PCA visualization of the initial and newly added samples distribution

添加样本 (蓝色点) 仅分布在二维设计空间中的特定区域. 其中, 每次新加点时优化所采用的初始种群不同, 收敛阈值  $\epsilon$  设置为 1%. 该优化结果较初始种群相同且  $\epsilon$  为 5% 的优化结果提升 0.16%(参见附录 G 表 G1). 综上可得, 本文采用的自训练代理模型可减少样本量的需求, 同时有助于提升优化效率; 通过改变初始种群、减小收敛阈值的方式有助于增强所建立方法的全局搜索能力.

最后, 为验证基于分类判断代理模型的计算效率优势, 本节采用回归代理模型开展了上述问题的优化设计. 表 3 对比了基于 KG、RSM 以及 RBFNN 代理模型所得结构优化后的质量、吸能量、背板最

大挠度以及整体计算开销, 其相关参数设置和所得优化结构几何参数列于附录 D. 所有代理模型均采用最优加点 (MSP) 准则更新, KG 模型额外采用了期望提高 (EI) 准则更新, 收敛阈值  $\epsilon$  设为 1%. 由表 3 对比可知, 虽然基于 KG(MSP) 优化所得满足性能约束下的构型质量最小, 但是基于 SVM 的优化结果与其相差在 1.1% 之内且整体计算效率 (包括样本点准备、模型训练、优化设计) 较其提升了 46.50%. 这是因为分类判断代理模型仅需判断结构是否满足防护性能指标, 无需预测 EA 和 MaxD 的具体数值, 因此可在数值分析模型计算过程中提前终止已违约样本点的计算, 从而降低计算成本.

表 3 两种不同代理模型训练策略的对比

Table 3 Comparison between two different training strategies for the surrogate model

	The number of samples	Mass (g)	EA (J)		MaxD (mm)	
			FEA	Classification accuracy	FEA	Classification accuracy
Optimized design from static surrogate model	30	488.25	797.23	True	21.02	False
	60	495.16	750.48	True	16.33	False
	90	500.44	710.66	True	18.16	False
	120	511.32	709.43	True	14.87	True
Optimized design from sequential surrogate model	30 + 10	505.34	722.65	True	15.19	True

### 3 陶瓷/聚脲复合板抗侵彻性能优化设计

#### 3.1 优化问题描述

聚脲/陶瓷复合结构兼具陶瓷和聚脲材料的优异力学性能, 在新型轻质抗冲击防护结构中有重要的应用价值. 图 9 为一典型的聚脲/陶瓷层合结构, 其抗弹性能与聚脲板厚度 ( $t_p$ )、陶瓷板厚度 ( $t_c$ )、两者的层合顺序 ( $S_{ord}$ ) 密切相关. 因此, 本节选取上述几何参数作为优化设计变量, 以剩余弹速作为结构防护性能评价指标, 开展聚脲/陶瓷复合结构的抗弹性能优化设计. 该问题具体设置如图 9 所示, 聚脲

板和陶瓷板的长和宽设为 101.6 mm, 钨合金平头弹体长径比约为 1.63(长度为 10 mm、直径为 6.14 mm)、正侵彻速度为 500 m/s. 依据文献<sup>[35]</sup>中所揭示的陶瓷聚脲复合结构机理与规律, 本节设置聚脲板厚度  $t_p$  和陶瓷板厚度  $t_c$  的取值范围, 具体式 (13) 所示.

依据结构优化列式 (1), 上述问题优化列式为

$$\begin{aligned}
 & \text{find } \mathbf{x} = \{t_c, t_p, S_{ord}\} \\
 & \text{min } M(\mathbf{x}) \\
 & \text{s.t. } \begin{cases} V_{res} = V_{res}^* \\ 8 \text{ mm} \leq t_c \leq 12 \text{ mm} \\ 8 \text{ mm} \leq t_p \leq 12 \text{ mm} \\ S_{ord} = 0 \text{ or } 1 \end{cases} \quad (13)
 \end{aligned}$$

式中,  $V_{res}^*$  为所要求的剩余弹速指标, 并设置为  $V_{res}^* = 0 \text{ m/s}$ ;  $S_{ord}$  取值为 0 和 1 分别表示层合顺序为陶瓷/聚脲和聚脲/陶瓷.

#### 3.2 陶瓷/聚脲复合板抗侵彻分析

##### 3.2.1 数值分析模型设置

本节采用商用有限元程序数值模拟平头弹体正




图 9 聚脲/陶瓷复合板钨合金弹侵彻示意图

Fig. 9 Illustration of the penetration problem of polyurea/ceramic composite plate by the tungsten alloy projectile

侵彻聚脲/陶瓷层合板问题. 其中, 假设陶瓷板与聚脲板之间为理想粘结状态, 采用接触算法处理弹体与陶瓷和聚脲的相互作用以及聚脲破坏后的自接触问题. 如图 10 所示, 平头弹体和陶瓷板采用光滑粒子流体动力学法 (Smoothed-particle hydrodynamics, SPH) 离散求解, 聚脲板采用八节点六面体单元离散. 根据网格收敛性分析 (参考附录 B), 设置粒子间距为 0.8 mm, 单元尺寸为 0.8 mm, 以兼顾数值模拟精度和计算效率.




图 10 弹体侵彻下聚脲/陶瓷复合板的数值分析模型

Fig. 10 Numerical model for polyurea/ceramic composite plate under the tungsten alloy projectile penetration

在该数值模型中, 钨合金弹体采用 Johnson-Cook 材料模型和 Grüneisen 状态方程, 相关物性参数取自文献<sup>[36, 37]</sup> 并列于附录 C 表 C4; 陶瓷材料为氧化铝, 采用 Johnson-Holmquist-Ceramics 本构模型, 相关物性参数取自文献<sup>[38]</sup> 并列于附录 C 表 C5; 聚脲材料为 ESU630 D, 采用两参数 Mooney-Rivlin 本构模型, 相关物性参数取自文献<sup>[39]</sup> 并列于附录 C 表 C6. 此外, 采用最大主应变侵蚀准则模拟聚脲材料的失效, 并参考文献<sup>[39]</sup> 的实验结果设置其阈值为 0.7.

### 3.2.2 数值分析模型验证

采用上述弹体和陶瓷靶板的数值分析模型模拟了文献<sup>[40]</sup> 中开展的钨合金平头弹正侵彻纯陶瓷板试验工况. 其中, 弹体直径为 6.14 mm、长度为 20.86 mm、质量为 10.708 g, 初始侵彻速度为 903.9 m/s; 陶瓷靶板的长度和宽度均为 101.6 mm、厚度为 12.7 mm. 图 11 对比了弹体侵彻过程中陶瓷靶板的变形模式及损伤破碎过程的数值模拟结果和实验图片. 由图 11 可知, 数值模拟结果重现了实验中观察到的迎弹面处呈锥状喷射的陶瓷粉末、背弹面隆起鼓包等现象. 弹体剩余弹速数值模拟结果 675 m/s 与实验结果 682 m/s<sup>[40]</sup> 相对误差为 1.03%. 通过对比数值模拟和实验结果的靶板变形模式、剩余弹速, 间接验证了 3.2.1 节数值分析模型的计算精

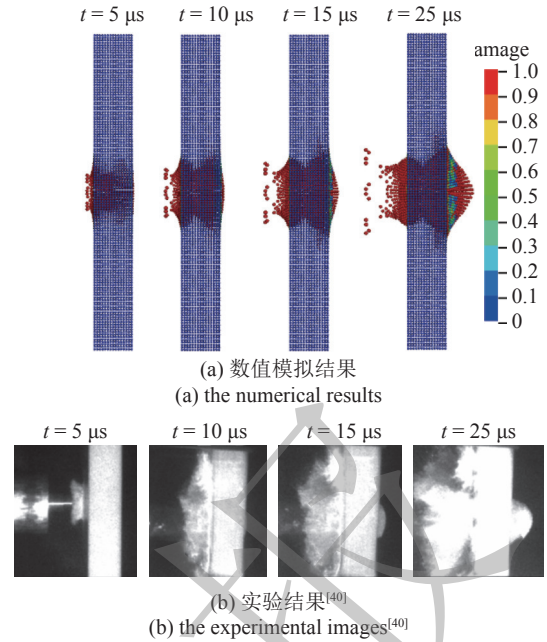


图 11 四个递增时刻的陶瓷靶板变形对比

Fig. 11 Comparison of the four snapshots of the deformed ceramic target at increasing times

度和计算参数的可靠性.

### 3.3 代理模型构建

采用 3.2.1 节弹体正侵彻靶体问题的数值分析模型生成训练样本集, 构建基于支持向量机的分类判断代理模型. 针对式 (13) 中设计变量取值范围, 首先采用 LHS 方法生成样本数为 10 的初始样本集  $X$ . 然后, 通过数值模拟获取样本点  $\mathbf{x}_i$  的剩余弹速  $V_{res}$  (若  $V_{res} = 0\text{m/s}$  时, 样本点的标签  $y_i$  设置为 -1, 否则设为 +1), 进而基于初始样本集  $X = \{(\mathbf{x}_i, y_i), \dots, (\mathbf{x}_N, y_N)\}$  建立剩余弹速的代理模型. 采用额外随机生成的 10 个样本校核代理模型的分精度, 所得剩余弹速的分类精度为 90%. 进一步, 在迭代优化过程中, 基于优化列式 (13) 所获得的优化设计构型  $\mathbf{x}^{new}$ , 通过数值分析模型获得其相应标签  $y^{new}$ , 并将  $(\mathbf{x}^{new}, y^{new})$  添加到现有样本数据集中, 迭代更新代理模型直至收敛.

### 3.4 优化结果

表 4 对比了陶瓷/聚脲复合板优化前后的尺寸参数与抗侵彻性能. 其中, 参考结构 (即  $t_c = 10\text{mm}$ ,  $t_p = 10\text{mm}$ ,  $S_{ord} = 1$ ) 被弹体击穿, 且弹体剩余速度为 188 m/s; 优化后的结构 ( $t_c = 8.88\text{mm}$ ,  $t_p = 11.98\text{mm}$ ,  $S_{ord} = 0$ ) 未被弹体击穿 ( $V_{res} = 0\text{m/s}$ ), 并且相对于参考结构减重 4.6%. 由表 4 数据可知, 将聚脲涂覆陶



表 4 弹体侵彻下的陶瓷/聚脲层合板参考结构和优化结构对比

Table 4 Comparison between the reference configuration and optimized configuration of the polyurea/ceramic composite plates under the projectile penetration

	The number of samples	Mass (g)	$t_c$ (mm)	$t_p$ (mm)	$S_{ord}$	$V_{res}$ (m/s)	
						SPH-FEM	Classification accuracy
Reference design	—	514.68	10.00	10.00	1	188	—
Optimized design from sequential surrogate model	5 + 7	491.00	8.88	11.98	0	0	True

瓷背弹面 (即  $S_{ord} = 0$ ) 并在质量最小的前提下, 聚脲板厚度接近尺寸上限 ( $t_p = 11.98 \text{ mm}$ )、陶瓷板厚度 ( $t_c = 8.88 \text{ mm}$ ) 接近下限. 这表明处于背弹面的聚脲板在提升结构抗冲击性能方面起着重要作用.

图 12 对比了两个时刻下的参考结构和优化结构弹体侵彻构型. 由图 12(a) 所示, 参考结构在弹体贯穿聚脲层后冲击陶瓷板形成的碎片向迎弹背面喷射, 不利于抵抗弹体侵彻; 由图 12(b) 所示, 优化后的结构将具有高韧性、高断裂应变特性的聚脲层置于陶瓷层背面, 破碎后的陶瓷被其包裹约束而可继续抵抗弹体侵彻以耗散更多弹体动能<sup>[35]</sup>. 因此, 优化后的陶瓷/聚脲复合结构具有较好的抗侵彻性能, 验证了本文提出算法在抗弹结构尺寸优化问题中的有效性.

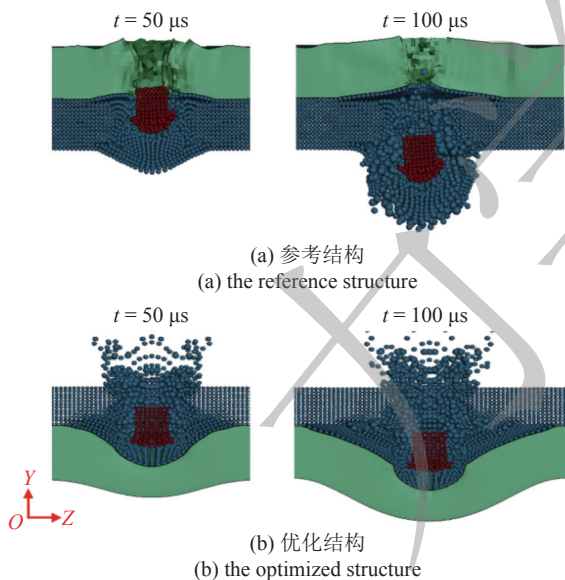


图 12 不同靶体结构的弹靶相互作用数值计算结果对比  
Fig. 12 Comparison of the numerical results of the projectile-target interaction with the target

## 4 结论与展望

针对抗爆、抗弹结构尺寸优化问题, 本文建立了一种新的高效设计方法, 自训练分类判断优化设

计方法. 该方法将支持向量机与遗传算法相结合, 采用前者构建判断结构是否满足防护性能指标的自训练分类判断代理模型, 基于后者求解所建立的面向分类判断代理模型的结构优化列式. 其中, 分类判断代理模型旨在寻找一个决策边界将优化设计空间划分为结构是否满足防护性能指标的两个区域, 无需预测防护性能的具体数值, 因此可在样本集构建过程中提前终止已违反约束样本点的计算, 从而降低计算成本. 进一步, 通过序列添加样本的方式建立自训练分类判断代理模型以实现设计空间的自适应采样, 从而避免初始训练样本集适应个数难以确定的难题; 相对于一次均匀抽样训练且关注全局预测精度的静态代理模型, 自训练分类判断代理模型所需样本集规模小、计算开销少, 并有助于提高遗传算法的优化效率. 同时, 针对遗传算法所需的约束处理问题, 提出了以多样性代替违约度评估的策略, 解决了分类代理模型无法评估不可行解违约度的问题, 进而发展了基于等级划分计算个体适应度的算法. 基于本文所提出方法, 开展了波纹夹芯结构抗爆性能优化设计, 所得优化结果在与基于静态代理模型的优化结果相近的前提下, 其计算效率是后者的 3 倍; 在与基于回归的动态代理模型的优化结果相近的前提下, 其计算效率较后者至少提升了 31%. 进一步, 采用陶瓷/聚脲复合板抗侵彻性能优化算例验证了本文算法在抗弹轻量化结构尺寸优化设计中的有效性.

本文工作为军民装备结构抗冲击性能优化设计提供了一种新的方法, 但其仍存在一些局限性. 在代理模型的自训练过程中, 新添加样本点为基于当前代理模型获得的优化解, 但其着重于优化空间的局部搜索; 如何基于分类代理模型发展可平衡优化效率和全局搜索能力的样本点添加新策略是一个重要的研究方向. 此外, 本文工作仅开展了爆轰和弹体侵彻分别作用下的抗冲击结构优化设计, 如何进一步



发展考虑爆轰波和高速破片群联合作用下的抗冲击结构优化设计仍需深入研究。

### 参 考 文 献

- Wiklo M, Holnicki-Szulc J. Optimal design of adaptive structures: Part I. *Remodeling for impact reception. Structural and Multidisciplinary Optimization*, 2009, 37: 305-318
- WANG L, SHAN S, WANG G. Mode-pursuing sampling method for global optimization on expensive black-box functions. *Engineering Optimization*, 2004, 36(4): 419-438
- Choi W S, Park G J. Structural optimization using equivalent static loads at all time intervals. *Computer methods in applied mechanics and engineering*, 2002, 191(19-20): 2105-2122
- Park G J. Technical overview of the equivalent static loads method for non-linear static response structural optimization. *Structural and Multidisciplinary Optimization*, 2011, 43: 319-337
- Ahmad Z, Sultan T, Zoppi M, et al. Nonlinear response topology optimization using equivalent static loads—case studies. *Engineering Optimization*, 2017, 49(2): 252-268
- Lee H A, Park G J. Nonlinear dynamic response topology optimization using the equivalent static loads method. *Computer Methods in Applied Mechanics and Engineering*, 2015, 283: 956-970
- Raponi E, Bujny M, Olhofer M, et al. Kriging-assisted topology optimization of crash structures. *Computer Methods in Applied Mechanics and Engineering*, 2019, 348: 730-752
- Tovar A, Patel N M, Niebur G L, et al. Topology Optimization Using a Hybrid Cellular Automaton Method With Local Control Rules. *Journal of Mechanical Design*, 2006, 128(6): 1205-1216
- Mozumder C, Renaud J E, Tovar A. Topometry optimisation for crashworthiness design using hybrid cellular automata. *International journal of vehicle design*, 2012, 60(1/2): 100-120
- Gan N, Yao S, Xiong Y, et al. A hybrid cellular automaton-bi-directional evolutionary optimization algorithm for topological optimization of crashworthiness. *Engineering Optimization*, 2018, 50(12): 2054-2070
- 刘书田, 刘杨, 童泽奇. 基于元胞自动机的变厚度薄壁梁侧向耐撞性优化设计方法 [J]. 计算力学学报, 2016, 33(4): 528-535 (A hybrid cellular automata based method of variable thickness thin-walled beam for crashworthiness optimization under lateral impact. *Chinese Journal of Computational Mechanics*, 2016, 33(4): 528-535. (in Chinese))
- 毕政, 周云波, 吴凯等. 基于拓扑优化的车辆底部防护组件改进设计. 爆炸与冲击, 2021, 41(4): 39-49 (Bi Zheng, Zhou Yunbo, Wu Kai, et al. Improved design of vehicle bottom protective components based on topology optimization. *Explosion and Shock Waves*, 2021, 41(4): 39-49 (in Chinese))
- Goetz\*, H. Tana, J. Renaud & A. Tovar. Two-material optimization of plate armour for blast mitigation using hybrid cellular automata. *Engineering Optimization*, 2012, 44(8): 985-1005
- Bohara R P, Linforth S, Nguyen T, et al. Novel lightweight high-energy absorbing auxetic structures guided by topology optimization. *International Journal of Mechanical Sciences*, 2021, 211: 106793
- Ramírez-Gil F J, Silva E C N, Montealegre-Rubio W. Through-thickness perforated steel plates optimized for ballistic impact applications. *Materials & Design*, 2021, 212: 110257
- KOZIEL S, CIAURRI D E, LEIFSSON L. Surrogate-based methods. *Computational optimization, methods and algorithms*, 2011: 33-59
- WANG C Y, ZOU S C, ZHAO W Z, et al. Multi-objective explosion-proof performance optimization of a novel vehicle door with negative Poisson's ratio structure. *Structural and Multidisciplinary Optimization*, 2018, 58(4): 1805-1822
- CAI S, ZHANG P, DAI W, et al. Multi-objective optimization for designing metallic corrugated core sandwich panels under air blast loading. *Journal of Sandwich Structures and Materials*, 2021, 23(4): 1192-1220
- CONG M, ZHOU Y, ZHANG M, et al. Design and optimization of multi-V hulls of light armoured vehicles under blast loads. *Thin-Walled Structures*, 2021, 168: 108311
- Johnson T E, Basudhar A. A metamodel-based shape optimization approach for shallow-buried blast-loaded flexible underbody targets. *International Journal of Impact Engineering*, 2015, 75: 229-240
- Qi C, Yang S, Yang L J, et al. Blast resistance and multi-objective optimization of aluminum foam-cored sandwich panels. *Composite Structures*, 2013, 105: 45-57
- Saini D, Shafei B. Design optimization of double-layered structural insulated panels for windborne debris hazard. *Composites Part B: Engineering*, 2021, 216: 108806
- 时光辉, 贾宜播, 郝文字等. 基于数据驱动的舵面结构优化设计. 力学学报, 2023, 55(11): 2577-2587 (Shi Guanghui, Jia Yibo, Hao Wenyu, et al. Optimal design of rudder structures based on data-driven method. *Chinese Journal of Theoretical and Applied Mechanics*, 2023, 55(11): 2577-2587 (in Chinese))
- 赵欢. 基于自适应多可信度多项式混沌-Kriging 模型的高效气动优化方法. 力学学报, 2023, 55(1): 223-238 (Zhao Huan. Adaptive multi-fidelity polynomial chaos-Kriging model-based efficient aerodynamic design optimization method. *Chinese Journal of Theoretical and Applied Mechanics*, 2023, 55(1): 223-238 (in Chinese))
- 邓凯文, 陈海昕. 基于差分进化和 RBF 响应面的混合优化算法. 力学学报, 2017, 49(2): 441-455 (Kaiwen Deng, Haixin Chen. HYBRID OPTIMIZATION ALGORITHM BASED ON DIFFERENTIAL EVOLUTION AND RBF RESPONSE SURFACE1. *Chinese Journal of Theoretical and Applied Mechanics*, 2017, 49(2): 441-455 (in Chinese))
- 郝鹏, 王博, 李刚, 王小军. 基于代理模型和等效刚度模型的加筋柱壳混合优化设计. 计算力学学报, 2012, 29(4): 481-486 (Hybrid optimization of grid-stiffened cylinder based on surrogate model and smeared stiffener model. *Chinese Journal of Computational Mechanics*, 2012, 29(4): 481-486 (in Chinese))
- 张喆, 欧进萍, 李冬生. 基于 Kriging 代理模型的连梁金属阻尼器性能研究与参数优化设计. 计算力学学报, 2017(2): 131-136 (ZHANG Zhe, OU Jin-ping, LI Dong-sheng. Optimal design for parameters of coupling beam metal dampers of shear walls based on Kriging surrogate model. *Chinese Journal of Computational Mechanics*, 2017(2): 131-136 (in Chinese))
- Hearst M A, Dumais S T, Osuna E, et al. Support vector machines. *IEEE Intelligent Systems and their applications*, 1998, 13(4): 18-28
- Cervantes J, Garcia-Lamont F, Rodríguez-Mazahua L, et al. A comprehensive survey on support vector machine classification: Applications, challenges and trends. *Neurocomputing*, 2020, 408: 189-215
- ZHANG P, LIU J, CHENG Y, et al. Dynamic response of metallic trapezoidal corrugated-core sandwich panels subjected to air blast loading - An experimental study. *Materials and Design*, 2015, 65: 221-230
- LEE S, BARTHELAT F, HUTCHINSON J W, et al. Dynamic fail-

ure of metallic pyramidal truss core materials - Experiments and modeling. *International Journal of Plasticity*, 2006, 22(11): 2118-2145

32 ZHANG P, CHENG Y, LIU J, et al. Experimental and numerical investigations on laser-welded corrugated-core sandwich panels subjected to air blast loading. *Marine Structures*, 2015, 40: 225-246

33 CHENG D, HUNG C, PI S. Numerical Simulation of Near-Field Explosion. *Journal of Applied Science and Engineering*, 2013, 16(1): 61-67

34 LEE E, FINGER M, COLLINS W. JWL equation of state coefficients for high explosives. Lawrence Livermore National Lab. (LLNL), Livermore, CA (United States), 1973

35 肖毅华, 吴和成. 弹体形状对陶瓷/聚脲复合板抗侵彻性能影响的数值模拟. *应用力学学报*, 2022, 38(2): 750-755 (Xiao Yihua, Wu Hecheng. Numerical simulation of effects of projectile shape on ballistic resistance of ceramic/polyurea composite plates. *Chinese Journal of Applied Mechanics*, 2022, 38(2): 750-755)

36 HOLMQUIST T J, TEMPLETON D W, BISHNOI K D. Constitutive modeling of aluminum nitride for large strain, high-strain rate, and high-pressure applications. *International Journal of Impact Engineering*, 2001, 25(3): 211-231

37 FELI S, ASGARI M R. Finite element simulation of ceramic/composite armor under ballistic impact. *Composites Part B: Engineering*, 2011, 42(4): 771-780

38 CRONIN D S, BUI K, KAUFMANN C, et al. Implementation and validation of the Johnson-Holmquist ceramic material model in LS-Dyna. //Proc. 4th Eur. LS-DYNA Users Conf. 2003, 1: 47-60

39 MOHOTTI D, ALI M, NGO T, et al. Strain rate dependent constitutive model for predicting the material behaviour of polyurea under high strain rate tensile loading. *Materials and Design*, 2014, 53: 830-837

40 NEMAT-NASSER S, SARVA S, ISAACS J B, et al. Novel ideas in multi-functional ceramic armor design. *Ceramic transactions*, 2002, 134: 511-526

附录 A 支持向量机算法简介

本文采用文献<sup>[28, 29]</sup>中所介绍的 SVM 构建分类判断代理模型. 为找到具有高分类精度的决策边界, 需使数据点到决策边界的“间隔”尽可能大, 同时满足正确分类的约束, 即

$$\begin{aligned} \min \quad & \frac{1}{2} \|\mathbf{w}'\|^2 \\ \text{s.t.} \quad & y_i * (\phi(\mathbf{x}_i)^T * \mathbf{w}' + b') \geq 1, i = 1, \dots, N \end{aligned} \quad (A1)$$

式中,  $y_i$  为样本点  $\mathbf{x}_i$  的分类标签;  $N$  为样本的个数;  $\mathbf{w}'$  为  $\frac{\mathbf{w}}{\|\mathbf{w}\|}$ ;  $b'$  为  $\frac{b}{\|\mathbf{w}\|}$ . 为提高模型处理噪声或异常值、非线性可分问题的能力, 采用松弛变量<sup>[29]</sup>以允许少量数据点偏离其正确的类别, 将式 (14) 改写为

$$\begin{aligned} \min \quad & \frac{1}{2} \|\mathbf{w}'\|^2 + C * \sum_{i=1}^N \xi_i \\ \text{s.t.} \quad & y_i * (\phi(\mathbf{x}_i)^T * \mathbf{w}' + b') \geq 1 - \xi_i \\ & \xi_i \geq 0 \end{aligned} \quad (A2)$$

式中,  $C$  为正则化参数, 较小的  $C$  值会导致模型更容忍错误分类情况, 而较大的  $C$  值则会更强调减小错误分类;  $\xi_i$  是松弛变量, 表示允许样本点  $\mathbf{x}_i$  偏离决策边界的程度.

附录 B 网格收敛性分析

在进行空爆载荷下波纹夹芯结构的动态响应分析时, 为研究网格尺寸对模拟结果的影响, 考虑了三种不同的网格划分情况. 其中, 结构和空气域网格尺寸为 0.5 mm 和 1 mm、1 mm 和 2 mm、2 mm 和 4 mm. 如表 B1 所示, 当结构和空气域的网格分别达到 1 mm 和 2 mm 时, 进一步细化网格尺寸对背板塑性变形的影响相对较小.

为分析粒子间距对弹体侵入靶板模拟结果的影响, 在建模时考虑了粒子间距为 0.6 mm、0.8 mm、1 mm 三种情况. 如表 B2 所示, 当粒子间距达到 0.8 mm 时, 进一步减小粒子间距对剩余弹速的影响较小. 因此, 采用粒子间距为 0.8 mm.

附表 B1 基于背板挠度的网格收敛性分析

Table B1 Mesh size convergence analysis based on the deflection of backplane

Structure mesh size (mm)	Air mesh size (mm)	Displacement of rear plate (mm)
2	4	12.6
1	2	15.2
0.5	1	15.8

附表 B2 粒子间距对剩余弹速的影响

Table B2 Effect of particle spacing on the residual velocity of the projectile

Particle spacing(mm)	$V_{rec}$ (m/s)
1.0	—
0.8	675
0.6	691

附录 C 材料参数

附表 C1 304 不锈钢参数<sup>[31]</sup>

Table C1 304 stainless steel material parameters

Parameters	Value
$\rho$ (kg·m <sup>-3</sup> )	7900
$A$ (Mpa)	310
$B$ (Mpa)	1000
$n$	0.65
$c$	0.07
$\epsilon_0$	1.00
$m$	1.00
$T_m$ (K)	1673
$T_r$ (K)	293

附表 C2 空气多项式状态方程参数<sup>[33]</sup>

Table C2 Parameters of the polynomial equation of state for the air

Parameters	Value
$C_0$	0
$C_1$	0
$C_2$	0
$C_3$	0
$C_4$	0.4
$C_5$	0.4
$C_6$	0
$E_0$ (kJ/m <sup>3</sup> )	$2.53 \times 10^2$

附表 C3 TNT 炸药参数<sup>[34]</sup>

Table C3 TNT material parameters

Parameters	Value
$P_{CJ}$ (GPa)	21
$A$ (GPa)	373.8
$B$ (GPa)	3.75
$R_1$	4.15
$R_2$	0.9
$\omega$	0.35
$E_0$ (kJ/m <sup>3</sup> )	$6 \times 10^6$

附表 C4 弹体的材料参数<sup>[36, 37]</sup>

Table C4 Projectile material parameters

Parameters	Value
$G$ (GPa)	124
$A$ (Mpa)	1200
$B$ (Mpa)	141
$c$	0.016
$m$	1.0
$n$	0.12
$\rho$ (kg·m <sup>-3</sup> )	17162
$C_0$ (m/s)	4029
$S_1$	1.23
$S_2$	0
$S_3$	0
$\gamma_0$	1.54
$D_1$	0
$D_2$	0.33
$D_3$	-1.5
$D_4$	0
$D_5$	0

附表 C5 氧化铝陶瓷材料参数<sup>[38]</sup>

Table C5 Alumina ceramics material parameters

Parameters	Value
$A'$	0.93
$B'$	0.31
$C'$	0
$m'$	0.6
$n'$	0.6
$H$ (GPa)	2.79
$F$ (GPa)	0.2
$p_H$ (GPa)	1.46
$D'_1$	0.005
$D'_2$	1
$k_1$ (GPa)	130.95
$k_2$ (GPa)	0
$k_3$ (GPa)	0
$\rho$ (kg/m <sup>3</sup> )	3921
$G$ (GPa)	90.16

附表 C6 ESU630 D 聚脲的工程应力-应变 (应变率 400/s)<sup>[39]</sup>

Table C6 Engineering stress-strain of ESU630 D polyurea (strain rate 400/s)

Engineering stain	Engineering stress (Mpa)
0	0
0.047	11.41
0.101	21.12
0.163	28.11
0.221	27.98
0.283	28.50
0.351	29.41
0.417	29.93
0.569	29.28
0.649	29.28
0.734	30.32
0.819	31.22
0.92	30.96
1.01	30.83

附录 D 基于回归代理模型的参数设置及优化结果

表 D1 展示了采用回归代理模型 (KG、RSM、RBFNN) 的优化结果. 其中, KG 采用高斯核函数; RSM 采用三阶多项式; RBFNN 隐藏层的神经元个数为 23.

附表 D1 基于回归代理模型的优化结果

Table D1 Optimized results with regression-based surrogate models

	KG (MSP)	KG (EI)	RSM	RBFNN
$T_f$ (mm)	1.02	1.00	1.18	1.00
$T_b$ (mm)	1.00	1.00	1.00	1.00
$T_c$ (mm)	0.5	0.5	0.5	0.5
$H_c$ (mm)	19.98	19.27	19.83	19.98
$\phi$ (°)	66.59	69.23	61.24	67.50

附录 E 核函数对模型精度的影响

支持向量机模型有多种核函数可供选择, 包括线性 (Linear)、多项式 (Poly)、高斯 (Gaussian)、双曲正切 (Sigmoid) 核函数等. 其中, 常用的核函数为线性核函数和高斯核函数. 通常采用精度测试和模型比较的方式以确定合适的核函数. 本文采用 30 个样本构建代理模型, 采用额外随机生成的 15 个样本校核基于不同核函数的模型分类精度, 所得结果列于表 E1. 结果对比表明, 基于线性核函数的分类代理模型预测精度较高. 此外, 本文选择线性核函数的另一考虑则是其具有计算效率高、不需要额外参数的优势. 相较而言, 高斯核函数可通过调节核参数以增强模型性能, 但核参数的确定需要网格搜索等方法.

附表 E1 基于不同核函数的模型分类精度对比

Table E1 Comparison of the classification accuracy of the model with different kernel functions

	The number of correct classification	
	EA	MaxD
Linear	15	14
Poly	15	13
Gaussian	13	14
Sigmoid	5	15

附录 F 代理模型迭代更新所使用的添加点信息

附表 F1 动态代理模型的添加点及其分类准确性

Table F1 The iteratively added points and their classification results from the dynamic surrogate model

Iterations	Mass (g)	EA (J)	MaxD (mm)	Correct classification
1	481.57	702.53	22.05	False
2	508.70	645.38	16.33	False
3	544.87	702.53	18.41	False
4	571.07	777.24	18.12	False
5	571.68	584.88	12.09	True
6	535.80	628.47	13.82	True
7	519.37	696.53	15.33	True
8	505.74	722.65	15.19	True
9	492.66	679.85	17.42	False
10	506.34	722.66	15.14	True

附录 G 初始种群及收敛阈值对优化结果的影响

表 G1 对比了初始种群改变前后的优化结果. 由表可知, 初始种群改变前后的优化收敛所需的加点次数分别为 4 和 10. 原因分析为, 遗传算法在相同初始种群所占据的搜索空间开始寻优, 只需代理模型在该空间具有较高的分类精度, 并且所采用的收敛阈值  $\epsilon$  为 5%, 因此优化仅少量加点便可收敛. 种群改变前后的尺寸参数变化范围在 5.7% 之内, 且优化结果较调整前提升了 0.16%. 该结果对比表明, 通过调整初始种群、收敛阈值的方式有助于增强算法的全局搜索能力.

附表 G1 初始种群改变前后的优化结果对比

Table G1 Comparison of optimized results before and after the modification of the initial population

	Before modification	After modification
$T_f$ (mm)	1.06	1.00
$T_b$ (mm)	1.00	1.00
$T_c$ (mm)	0.5	0.5
$H_c$ (mm)	19.99	19.69
$\phi$ (°)	66.14	69.62
$M$ (g)	506.16	505.34
EA(J)	726.16	722.65
MaxD (mm)	15.84	15.19
Number of Iterations	4	10