

DOI:10.19344/j.cnki.issn1671-5276.2025.06.029

基于多策略改进的混合元模型全局优化算法及工程应用

李江涛¹, 李海波², 张赫桐², 任晋宇³

(1. 国网内蒙古东部电力有限公司, 内蒙古自治区 呼和浩特 010010;

2. 国网赤峰供电公司, 内蒙古自治区 赤峰 024000;

3. 南京航空航天大学 能源与动力学院, 江苏 南京 210016)

摘要:为更好地解决高度非线性和计算密集型的工程优化问题,首次提出一种基于多策略改进的混合元模型全局优化算法(MS-HAM)。在优化方法中提出一种分层设计空间更新方法和不同的采样大小策略来提高性能。通过关键区域更新策略将设计空间划分为关键区域和普通区域,关键区域根据搜索结果自适应更新,以提高结果的精度和收敛速度。在优化的不同阶段采用粗糙采样策略和密集采样策略以提高搜索效率,避免结果过早聚集在较小的设计空间中。通过对比多种不同变量基准优化问题的优化方法,验证优化算法的有效性。将 MS-HAM 优化方法应用于实际工程作业车臂架的设计参数优化。结果表明:所提出的 MS-HAM 算法在优化计算密集型问题方面具有较高的精度和效率,可广泛应用于工程优化领域。

关键词:MS-HAM 算法;工程作业车;结构优化

中图分类号:TH123 **文献标志码:**A **文章编号:**1671-5276(2025)06-0157-07

Hybrid Metamodel-based Global Optimization Algorithm Enhanced by Multi-strategy Improvement and Its Engineering Applications

LI Jiangtao¹, LI Haibo², ZHANG Hetong², REN Jinyu³

(1. State Grid Inner Mongolia Eastern Electric Power Company Limited, Hohhot 010010, China;

2. State Grid Chifeng Power Supply Company, Chifeng 024000, China;

3. School of Energy and Power Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract:In order to improve highly nonlinear and computation-intensive engineering optimization, this paper initiates a novel Multi-strategy enhanced hybrid metamodel-based global optimization algorithm (MS-HAM), which incorporates a hierarchical design space update approach and variable sampling size strategies to enhance performance. A key region update strategy divides the design space into key and common regions, and the key region is adaptively updated based on search results to improve accuracy and convergence speed. Coarse and dense sampling strategies are employed at different stages of optimization to enhance search efficiency and prevent premature convergence within a limited design space. The effectiveness of the optimization algorithm is validated by comparing it against existing methods on three benchmark optimization problems with varying numbers of variables. The MS-HAM optimization method is applied to optimize the design parameters of a real-world engineering case study involving a workover rig arm. The results demonstrate that the proposed MS-HAM algorithm exhibits high accuracy and efficiency in optimizing computationally intensive problems, suggesting its broad applicability in engineering.

Keywords:MS-HAM algorithms; construction work vehicle; structural optimization

0 引言

随着科学技术的发展,在工程设计中,为了降低成本和时间,物理实验越来越广泛地被计算机模拟所取代^[1]。例如,福特汽车公司通过应用计算机辅助工程技术模拟碰撞可以节省大量资金,但一次仿真需要 24 h 以上,仿真次数达到 100 次就需要花费 3 个月^[2]。然而,为了获得更精确的

仿真模型和优化结果,“黑匣子”计算模型正变得越来越耗时。因此,可以得出结论,需要越来越多的计算机资源来完成基于“黑箱”计算机分析的优化设计^[3]。同时,由于大部分工程设计的优化问题是高阶非线性多峰函数,可行设计空间是非凸的^[4],当需要进行大量的函数评估时,传统的优化算法很难解决工程问题。

在过去的几十年里,人们开发了许多性能良

基金项目:江苏省自然科学基金项目(BK20231448)

第一作者简介:李江涛(1981—),男,黑龙江富锦人,高级工程师,硕士,研究方向为智能制造、结构优化,1102835496@qq.com。

好的新型优化算法,有效地解决了许多被认为很难甚至不可能解决的工程优化问题^[5]。梅潇等^[6]采用多目标粒子群算法并通过 Python 语言编程对高空作业车臂架进行优化。官凤娇等^[7]将有限元参数化建模技术和微型多目标遗传算法结合进行优化设计。曾卉帆等^[8]使用 Kriging 代理模型和 NSGA-II 算法进行多目标优化。KAR 等^[9]提出了一种基于引力搜索算法和粒子群算法的有效混合方法;胡瑜等^[10]将响应曲面法和数值模拟方法结合对涡旋管分离器结构进行优化;WANG 等^[11]提出一种引入动态感知概率、莱维飞行策略以及变异更新机制的改进乌鸦搜索算法,这些算法均被应用于求解工程优化问题。基于元模型的全局优化方法是目前最重要的优化算法之一,许多学者对元模型的建模方法进行了详细的研究。为了提高不同问题的精度和效率,GU 等^[12]提出了一种混合自适应元建模方法(HAM),将 RBF、QF 和 kriging 方法 3 种元模型集成到 HAM 中^[13-15]。刘基盛等^[16]基于 PR 模型、Kriging 模型和 RBF 模型创建了多代理模型优化算法,利用在线驱动方法、模型管理策略获得了高精度的预测模型,并与多种经典优化算法对比验证,结果表明其能高效求解较大规模优化问题。叶鹏程等^[17]提出一种混合元模型自适应空间探索优化方法,通过加权叠加 3 种元模型构建出混合元模型,再采用自适应空间探索方法提高预测精度,该方法在优化效率和全局收敛性方面有很好的性能表现。阮志新等^[18]选取多项式响应面模型和神经网络模型两者的优势进行组合,得到一个精度更好的近似模型,结合 NSGA-II 算法实现了对座椅骨架综合性能的提升。

为了更好地解决工程优化问题,本文首次提出一种基于多策略改进的混合元模型全局优化算法(MS-HAM)。该算法通过引入分层设计空间更新方法和不同阶段的采样大小策略,准确、高效地进行全局最优搜索。

1 MS-HAM 算法

在分层设计空间更新方法中,关键区域会根据当前最小结果自适应地构建和更新,以此划分设计空间。通过提出不同阶段的采样大小策略,它将在迭代开始时应用粗糙的采样策略,以避免在小的设计空间中过早地聚集“关键”点。在其迭代的后期阶段,将采用密集采样策略以搜索全局最优。两种策略相结合使得当前最小值将逐渐

逼近全局最小值,最终找到全局最优值。

1.1 MS-HAM 的一般程序

以下步骤描述了本工作中提出的 MS-HAM 算法的一般程序。

1) 利用拉丁超立方抽样技术生成 m 个初始点,然后通过耗时的仿真程序计算相应的响应,得到初始 m 个“关键”点对应的函数值^[19]。需要注意的是,在这一步中,构建每个目标函数的完整二次元模型所需的最小样本点数为 $(n+1)(n+2)/2$,其中 n 表示变量数。

2) 利用上一步中获得的“关键”点,分别构建 3 种不同且复杂的元模型(Kriging 模型 $f(x)$, RBF 模型 $g(x)$ 和 QF 模型 $h(x)$)。按照函数值对“关键”点进行排序,根据排序后的点划分初始关键区域,设计空间剩余区域为普通区域。

3) 分别在关键区域和普通区域中通过拉丁超立方抽样技术生成 N 个样本点,并通过应用步骤 2) 中构建的 3 个元模型分别获得“普通”点的函数值。在不同的阶段采取不同的采样大小策略,具体细节将在下一节中详细讨论。

4) 根据相应的目标函数值,对步骤 3) 中获得的“普通”点按升序排序。将 $f(x)$ 、 $g(x)$ 、 $h(x)$ 计算出的前 n 个“普通”点分别放入集合 A 、集合 B 、集合 C 中。普通区域内,将 $f(x)$ 、 $g(x)$ 、 $h(x)$ 计算出的前 n 个“普通”点分别放入集合 K 、集合 L 、集合 M 中。

5) 在集合 A 、 B 、 C 中,可能会出现设计变量相同的“普通”样本点,当某一样本点在 3 个集合中均出现则放入集合 D ,即 $D=A \cap B \cap C$,当某一样本点出现在两个集合中放入集合 (E, F, G) ,即 $E=(A \cap B)-D$, $F=(B \cap C)-D$, $G=(A \cap C)-D$,当某一样本点只出现在一个集合中放入集合 (H, I, J) ,即 $H=A-(D \cap E \cup G)$, $I=B-(D \cap E \cup F)$, $J=C-(D \cap G \cup F)$ 。二维空间中 3 个元模型的划分设计空间如图 1 所示。




图1 二维空间中3个元模型的设计空间划分

6) 根据 $D-J$ 以及 $K-M$ 每个集合中“普通”点的个数分别计算权重,根据每个子组的权重选择最重要的“普通”点,这些新选择出的“普通”点将更新为“关键”点。

7) 合并所有的“关键”点,应用原始模型计算这些“关键”点的值,判断是否满足收敛条件,满足则结束迭代。若不满足,则用新的“关键”点分别更新 3 个元模型,并重复步骤 2)~步骤 6),直

至目标函数值满足式(1)或循环迭代达到设置的最大迭代次数。

$$|\bar{F}_i - \bar{G}_i| \leq \varepsilon \quad (1)$$

式中: $\bar{F}_i$ 是最后一次迭代生成的“关键”点中 5 个最小目标函数值的平均值; $\bar{G}_i$ 是所有“关键”点中 5 个最小目标函数值的平均值。本工作中 ε 设为 0.001。

MS-HAM 算法流程如图 2 所示。




图 2 算法流程图

1.2 分层设计空间更新策略

通过提出分层设计空间更新策略可以自适应地移动和缩放设计空间中的关键区域,同时也可以搜索整个设计空间。关键区域更新方法的一般流程如下。

1) 根据对应的目标函数值按升序选择前 k 个“关键”点。 k 等于优化问题中变量的个数。每个维度的 k 个“关键”点之间的最大值和最小值分别定义为上界和下界,这些值被用来构造初始的关键区域。

需要注意的是为了防止过早陷入局部最优,当构建初始重要区域时及后续更新关键区域时,需要检测关键区域任一变量的宽度是否达到整个设计空间的 10%,若小于 10% 则将其扩展到 10%,如式(2)所示。

$$\begin{cases} x_i^l = x_i^* - 5\%d_i & i = 1, 2, \dots, n \\ x_i^u = x_i^* + 5\%d_i & i = 1, 2, \dots, n \end{cases} \quad (2)$$

式中: d_i 、 x_i^* 分别为当前重要区域中第 i 个变量的长度、当前最优值; x_i^u 和 x_i^l 分别为新生成的重

要区域中第 i 个变量的上界和下界。

2) 在迭代过程中根据以下情况生成新的关键区域。

如果当前最优在步骤 1) 中得到的关键区域内,则新生成的关键区域的大小应减小到之前大小的一半,并且当前最优位于新生成的重要区域的中心。新生成的重要区域的边界如式(3)所示。

$$\begin{cases} d_i = x_i^u - x_i^l \\ x_i^l = x_i^* - \frac{1}{4}d_i \\ x_i^u = x_i^* + \frac{1}{4}d_i \end{cases} \quad (3)$$

式中 x_i^u 、 x_i^l 分别为当前重要区域中第 i 个变量的上界和下界。

如果当前最优位于步骤 1) 中得到的关键区域的边界上或者位于关键区域外,则新生成的关键区域大小与前一个相同,且当前最优仍然位于新生成的重要区域的中心,则新生成的关键区域的边界如式(4)所示。

$$\begin{cases} d_i = x_i^U - x_i^L \\ x_i^L = x_i^* - \frac{1}{2}d_i \\ x_i^U = x_i^* + \frac{1}{2}d_i \end{cases} \quad (4)$$

1.3 多阶段采样策略

根据 MS-HAM 的搜索策略,元模型在迭代开始时精度不够,模型的精度随着迭代而提高。为了在不降低精度的前提下提高算法的效率,本文首先提出了不同的采样大小策略。为了避免“关键”点在优化开始时过早地聚集在一个小的设计空间中并导致元模型的精度无法提高,在迭代开始时应用了粗糙抽样策略,其中样本点的数量 N_1 由设计变量的数量自适应地确定。由于元模型的精度提高,在迭代的后期阶段应用密集采样策略来搜索全局最优。由于元模型在迭代后期的精度足够高,因此密集采样策略的应用也可以显著提高搜索精度。密集抽样策略

中的样本点数 N_2 也是由优化问题中的设计变量数自适应确定的, N_2 通常是 N_1 的 10 倍。参考式(1), 当 $|\bar{F}_i - \bar{G}_i| < 0.1$ 时, 进入密集采样阶段。

2 数值样例

1) Himmelblau 函数(HM)是一个 2 变量基准优化问题。可描述为式(5), 已知 HM 函数的最小值为 0。

$$\begin{cases} f(x) = (x_1^2 + x_2 - 11)^2 + (x_1 + x_2^2 - 7)^2 \\ x_1, x_2 \in [-6, 6] \end{cases} \quad (5)$$

2) Hartman 函数(HN)是一个 6 变量基准优化问题。如式(6)所示, 已知 HN 函数的最小值为 -3.322。

$$\begin{cases} f(x) = - \sum_{i=1}^4 c_i \exp \left[- \sum_{j=1}^n a_{ij} (x_j - p_{ij})^2 \right] \\ x_j \in [0, 1], j = 1, \dots, n \end{cases} \quad (6)$$

$$\text{式中: } c_i = [11.233, 2]; [a_{ij}]_{j=1, \dots, 6} = \begin{bmatrix} 10 & 3 & 17 & 3.5 & 1.7 & 8 \\ 0.05 & 10 & 17 & 0.1 & 8 & 14 \\ 3 & 3.5 & 1.7 & 10 & 17 & 8 \\ 17 & 8 & 0.05 & 10 & 0.1 & 14 \end{bmatrix};$$

$$[p_{ij}]_{j=1, \dots, 6} = \begin{bmatrix} 0.1312 & 1.1696 & 0.5569 & 0.0124 & 0.8283 & 0.5886 \\ 0.2329 & 0.4139 & 0.8307 & 0.3736 & 0.1004 & 0.9991 \\ 0.2348 & 0.1451 & 0.3522 & 0.2833 & 0.3047 & 0.6650 \\ 0.4047 & 0.8828 & 0.8732 & 0.5743 & 0.1091 & 0.0381 \end{bmatrix}。$$

3) 16 变量基准优化问题(F16)。已知 16 变量函数的最小值为 25.877, 如式(7)所示。

$$\begin{cases} f(x) = \sum_{i=1}^{16} \sum_{j=1}^{16} a_{ij} (x_i^2 + x_i + 1) (x_j^2 + x_j + 1) \\ x_i, x_j \in [-1, 1], i, j = 1, 2, \dots, 16 \end{cases} \quad (7)$$

为了评估算法的准确性, 本文将不同优化方

法的搜索结果与本工作中已知的最小值进行比较。由于相同的优化方法在不同的运行中可能会得到不同的优化结果, 因此在本工作中对同一问题进行了 10 次运行, 并计算所有指标的平均值, 以进行公平的比较。表 1 比较了不同函数下不同优化方法的平均最优小值、黑箱函数评估(NFE)和迭代次数(NIT)。

表 1 不同优化算法针对不同函数的优化结果

优化算法	2 变量 HM 函数, 最小值为 0			6 变量 HN 函数, 最小值为 -3.322			16 变量 F16 函数, 最小值为 25.877		
	Minimum/AVE.	NIT/AVE.	NFE/AVE.	Minimum/AVE.	NIT/AVE.	NFE/AVE.	Minimum/AVE.	NIT/AVE.	NFE/AVE.
GA	0.000 0	51.0	1 020.0	-3.277	64.0	1 280.0	27.489	84.6	1 692.0
MPS	0.038 8	16.1	57.0	-3.288	100.8	929.9	33.808	131.8	3 298.2
Kriging	0.003 5	7.9	63.3	-3.165	19.2	142.4	31.567	58.7	418.9
RBF	1.037 9	39.6	290.0	-3.043	28.4	208.8	31.019	92.2	655.4
QF	12.252 9	258.8	1 819.6	-2.813	25.0	193.0	26.137	35.4	255.8
HAM	0.005 3	11.3	81.2	-3.307	20.7	132.0	26.336	43.2	250.6
MS-HAM	0.000 0	10.2	150.4	-3.310	11.4	256.3	25.992	15.4	230.5

从表1中可以看出,对于2变量问题,虽然MS-HAM的NFE次数更多,但与MPS、Kriging和HAM相比,它能获得更准确的结果。MS-HAM算法的NIT值和NFE值均小于GA算法,但均能求出精确的全局最小值。由此可见,所提出的MS-HAM算法在求解2变量问题的最优解方面具有良好的准确性和效率。

对于6变量问题,GA、MPS、HAM和MS-HAM的搜索结果非常接近已知的小值,尽管没有找到确切的全局最小值。MS-HAM算法的最小值与已知最小值最接近,且MS-HAM算法的NIT值和NFE值均小于GA算法和MPS算法。尽管MS-HAM算法的NFE值大于HAM算法,但MS-HAM算法得到的优化结果更精确,所需的NIT值更少。

对于16变量优化问题,由表1可以看出,QF、HAM和MS-HAM找到的最小值都接近全局最小值,但MS-HAM算法的NIT值和NFE值均小于QF和HAM算法。通过与GA和MPS对比,MS-HAM算法可以获得更精确的最优结果,并且所需的NIT值和NFE值较小。虽然MS-HAM比QF和HAM需要更多NFE,但MS-HAM可以得到更准确的结果。由此可见,在保持较低的NIT值和NFE值水平的情况下,MS-HAM方法可以得到更精确的16变量优化问题的最优结果。

通过对不同问题下不同优化方法的对比分析,可以总结出本文提出的MS-HAM算法在不同变量问题下都能很好地解决问题,在精度和计算效率之间取得了很好的平衡。为了验证其有效性,本文提出的优化方法将在第3节中应用于实际工程问题。

3 工程作业车臂架的设计优化

臂架是工程线杆作业车重要的受力机构,其力学特性对作业车的整体可靠性与安全性有着重大影响,实现臂架优化设计可以提升车辆的工作效率,并降低生产成本。由于臂架实际模型较大,每次优化仿真耗时长,所以有必要使用一种优化算法去尽可能确定最优的设计,从而提升设计效率。本节首先根据三维模型建立臂架有限元模型,进行仿真分析,确定模型可靠性;然后采用DOE设计方法^[20],选取影响臂架力学性能的主要参数,得到了不同参数组合下的数据结果,最后选取DOE分析的数据结果作为初始样本点,使用MS-HAM算法进一步优化并确定臂架截面最优

参数组合,实现工程作业车臂架的轻量化设计,为工业结构设计提供新的思路。

本文研究对象为某型线杆作业车的臂架主体,其主要由两节臂架组成,均为矩形截面,一节臂长7 220 mm,二节臂长6 000 mm,一节臂连接底座,重物悬挂在二节臂顶端,一节臂、二节臂之间由滑动配合支撑连接。两节臂材料均为Q550D,材料密度为7 850 kg/m³,泊松比为0.3,弹性模量为210 000 MPa,屈服强度为550 MPa,抗拉强度为700 MPa。本文设置的工况是线杆作业车工作时的典型工况,二节臂相对于一节臂伸出2 750 mm,臂架相对于水平地面仰角为30°,吊挂重物质量为2 t。典型工况如图3所示。




图3 工程作业车典型工况示意图

考虑到线杆作业车臂架实际设计的结构布置和制造工艺,本文选取一节臂4个面和二节臂的厚度为设计变量,分别为一节臂底板厚度 T_1 、一节臂左侧板厚度 T_2 、一节臂右侧板厚度 T_3 、一节臂顶板厚度 T_4 和二节臂厚度 T_5 ,具体如图4所示。




图4 设计变量示意图

本研究的目的是确保线杆作业车臂架部分在不失效的情况下,通过优化臂架截面的厚度,来减小臂架部分的自质量,从而提高线杆作业车的性能和经济性。所以优化设计的数学模型可以表示为

$$\begin{cases} \min M_{\text{obj}} \\ \text{s.t.} \\ 0 \leq f_{\text{max}} \leq [f] \\ 0 \leq \sigma_{\text{max}} \leq [\sigma] \\ 4 \leq T_1 \leq 8, 4 \leq T_2 \leq 8 \\ 4 \leq T_3 \leq 8, 4 \leq T_4 \leq 8 \\ 4 \leq T_5 \leq 12 \end{cases} \quad (8)$$

首先通过 DOE 分析选取了 23 组样本点,并通过耗时仿真模拟得到每组样本点对应的函数值,以 23 组样本数据为初始样本点分别运用 HAM 算法和 MS-HAM 算法进行优化。优化的结果如表 2 所示。表中列出了两种算法所取得的最优变量值以及所对应的评价指标。由于两种优化

算法分别获得了最优结构,因此本文也研究了不同优化结果的性能,对优化后的臂架重新建模进行有限元分析,验证结果的可靠性。图 5 和图 6 为 MS-HAM 算法优化后的结构分析云图,可以证明设计的合理性。从表 2 结果可以看出,HAM 和 MS-HAM 算法都显著降低了臂架的整体质量,并保证了安全性能。MS-HAM 需要 19 次迭代和 363 次功能评估才能获得优化结果,而 HAM 需要 25 次迭代和 407 次功能评估才能实现最优设计。结果表明,MS-HAM 不仅搜索的最优设计减少的质量更多,而且 MS-HAM 算法花费了更少的函数评估和迭代次数,求解精度更高。由此可见,在保证效率的前提下,采用 MS-HAM 方法可以得到更精确的优化结果。

表 2 工程作业车臂架参数优化结果对比

项目	T_1/mm	T_2/mm	T_3/mm	T_4/mm	T_5/mm	f_{max}/mm	$\sigma_{\text{max}}/\text{MPa}$	M/kg	N_{NIT}	N_{NFE}
初始值	6	6	6	6	9	96.7	219.3	846.4	—	—
HAM	7.8	5.4	7.7	7.4	5.7	93.4	253.9	775.3	25	407
MS-HAM	6.7	7.4	7.4	5.7	5.5	89.6	239.7	765.8	19	363




图 5 优化后应力云图




图 6 优化后位移云图

4 结语

1) 本文首次提出了一种多策略改进的混合元模型全局优化方法来解决高度非线性和复杂的工程问题。提出了新的分层空间更新方法和不同阶段的采样大小策略,提高了精度和效率。根据搜索结果自适应划分设计空间,在优化的不同阶段采用粗糙采样策略和密集采样策略,以提高搜索

效率和模型精度。

2) 基于 2 变量、6 变量和 16 变量的基准优化问题,通过对比 3 种全局优化方法和 3 种不同的基于单元模型的优化方法,验证了 MS-HAM 的有效性。对不同优化方法针对不同优化问题的优化结果、NIT 和 NFE 进行了详细的比较和研究。结果表明,针对不同变量的优化问题 MS-HAM 方法均可以获得较高的精度和效率。

3) 将所提出的 MS-HAM 应用于实际工程作业车臂架的设计参数优化。结果表明,在满足要求的前提下,线杆作业车的臂架质量得到了显著降低。MS-HAM 的最优结果与 HAM 算法相比,MS-HAM 算法得到的优化结果更精确,效果更好。研究表明,本文提出的 MS-HAM 算法对高度非线性、计算量大的工程问题具有较好的优化效果,可广泛应用于结构的研究与开发。

参考文献:

- [1] 徐博,韩晓霞,董颖超,等. 自适应状态转移模拟退火算法及其应用[J]. 计算机应用研究, 2024, 41(1): 150-158.
- [2] 林成龙,马义中,肖甜丽. 基于均值改进控制策略的昂贵约束并行代理优化算法[J]. 控制理论与应用, 2021, 38(6): 707-718.
- [3] YU X B, CAO J, SHAN H Y, et al. An adaptive hybrid algorithm based on particle swarm optimization and

- differential evolution for global optimization [J]. The Scientific World Journal, 2014, 2014(1): 215472.
- [4] 王万良, 李伟琨, 臧泽林, 等. 基于混合选择的多目标进化算法及其在优化设计问题中的应用[J]. 计算机集成制造系统, 2020, 26(7): 1802-1813.
- [5] 袁钰婷, 高岳林, 左汶鹭. 渐进式分组狩猎的灰狼优化算法及其工程应用[J]. 计算机应用研究, 2024, 41(5): 1409-1419.
- [6] 梅潇, 刘超. 基于多目标粒子群算法的平衡式变幅臂架系统优化设计[J]. 起重运输机械, 2020(20): 192-200.
- [7] 官凤娇, 韩旭, 周长江, 等. 基于微型多目标遗传算法的布料机臂架结构优化[J]. 湖南大学学报(自然科学版), 2008, 35(11): 26-31.
- [8] 曾卉帆, 滕儒民, 王殿龙, 等. 基于代理模型的破拆机器人臂架结构优化设计[J]. 现代制造工程, 2023(3): 63-69.
- [9] KAR D, GHOSH M, GUHA R, et al. Fuzzy mutation embedded hybrids of gravitational search and particle swarm optimization methods for engineering design problems [J]. Engineering Applications of Artificial Intelligence, 2020, 95: 103847.
- [10] 胡瑜, 王锁芳, 梁晓迪. 基于响应曲面法的涡旋管分离器结构优化[J]. 机械制造与自动化, 2024, 53(3): 166-171.
- [11] WANG Y H, Gao L. Improvement of crow search algorithm and its application in engineering constrained optimization problems [J]. Computer Integrated Manufacturing Systems, 2021, 27(7): 1871-1883.
- [12] GU J, LI G Y, DONG Z. Hybrid and adaptive meta-model-based global optimization [J]. Engineering Optimization, 2012, 44(1): 87-104.
- [13] DAMMAK K, BAKLOUTI A, EL HAMI A. Optimal reliable design of brake disk using a Kriging surrogate model [J]. Mechanics of Advanced Materials and Structures, 2022, 29(28): 7569-7578.
- [14] YANG H, LU F S, GUO H W, et al. Design of a new N-shape composite ultra-thin deployable boom in the post-buckling range using response surface method and optimization [J]. IEEE Access, 2019, 7: 129659-129665.
- [15] RASHKI M, AZARKISH H, ROSTAMIAN M, et al. Classification correction of polynomial response surface methods for accurate reliability estimation [J]. Structural Safety, 2019, 81: 101869.
- [16] 刘基盛, 计良, 李威, 等. 基于多代理模型的离心叶轮高效优化设计方法[J]. 中国机械工程, 2023, 34(8): 899-907.
- [17] 叶鹏程, 潘光, 鲁江峰. 混合元模型自适应空间探索优化方法及应用[J]. 哈尔滨工程大学学报, 2021, 42(7): 1039-1047.
- [18] 阮志新, 陈超, 詹腾, 等. 基于组合代理模型的汽车座椅性能多目标优化[J]. 机械设计, 2024, 41(11): 136-143.
- [19] 季宁, 张卫星, 于洋洋, 等. 基于最优拉丁超立方抽样方法和 NSGA-II 算法的注射成型多目标优化[J]. 工程塑料应用, 2020, 48(3): 72-77.
- [20] 李卫民, 付松松, 孙洪哲. 基于 DOE 的流道结构优化设计[J]. 机械设计, 2024, 41(12): 77-83.

收稿日期: 2024-08-30

(上接第 99 页)

- [3] LEISHMAN B A, CUMPSTY N A, DENTON J D. Effects of bleed rate and endwall location on the aerodynamic behavior of a circular hole bleed off-take[J]. Journal of Turbomachinery, 2007, 129(4): 645-658.
- [4] LEISHMAN B A, CUMPSTY N A, DENTON J D. Effects of inlet ramp surfaces on the aerodynamic behavior of bleed hole and bleed slot off-take configurations[J]. Journal of Turbomachinery, 2007, 129(4): 659-668.
- [5] LEISHMAN B A, CUMPSTY N A. Mechanism of the interaction of a ramped bleed slot with the primary flow[J]. Journal of Turbomachinery, 2007, 129(4): 669-678.
- [6] 顾杨, 崔健, 夏联, 等. 压气机带静叶优化的引气试验研究[J]. 燃气涡轮试验与研究, 2004, 17(4): 15-19.
- [7] 邓峰, 顾春伟, 薛耀华, 等. 压气机级间抽气的数值模拟[J]. 工程热物理学报, 2008, 29(1): 40-42.
- [8] 赵斌, 李绍斌, 李秋实, 等. 引气提升轴流压气机性能的数值研究[J]. 航空动力学报, 2011, 26(2): 262-271.
- [9] 沙心国, 严明, 刘政良. 高负荷多级轴流压气机级间引气数值模拟[J]. 航空动力学报, 2013, 28(11): 2483-2494.
- [10] 晏松, 楚武利. 引气对跨声速压气机稳定性的影响[J]. 动力工程学报, 2020, 40(2): 123-130, 137.
- [11] 刘宝杰, 庄昕伟, 安广丰, 等. 级间引气对多级轴流压气机性能和流场影响的低速实验研究[J]. 推进技术, 2022, 43(7): 141-148.
- [12] 郑健生, 丁骏, 隋永枫, 等. 工业燃机轴流压气机级间非均匀引气的数值仿真[J]. 风机技术, 2023, 65(3): 14-19.
- [13] 明亮, 冯昊天, 刘家兴, 等. 级间引气条件下轴流压气机特性预测方法[J]. 航空发动机, 2023, 49(5): 34-39.
- [14] 航空发动机设计手册总编委会. 航空发动机设计手册: 第 8 分册[M]. 北京: 航空工业出版社, 2000.
- [15] 翟志龙, 曹传军, 姜逸轩. 级间引气对多级轴流压气机性能的影响[J]. 航空发动机, 2023, 49(1): 62-67.

收稿日期: 2024-05-06