

采用动态交互作用分析的叶轮机械优化算法研究

汪祺能, 宋立明, 郭振东, 李军, 丰镇平

(西安交通大学能源与动力工程学院, 710049, 西安)

摘要: 针对当前基于代理模型的优化算法因遭遇“维度灾难”而难以开展叶轮机械高维优化的难题,提出了自适应厘清变量间关系的动态聚合全局优化算法。该算法能在不消耗额外样本的条件下获取设计变量间的交互信息,并基于该信息一方面将高维问题分解为多个低维问题,实现高维问题的高效优化,另一方面为后续知识挖掘提供信息基础。在完成典型30维函数算例测试后,利用所提出的算法完成了包含28个设计变量的Rotor 37叶栅气动优化与设计空间知识挖掘。结果表明,优化后,Rotor 37叶栅设计工况效率相对参考设计提高了1.69%,且变工况性能相对参考设计亦有不同程度提高。在获得最优解的同时,所提出的算法还厘清了Rotor 37叶栅设计空间各变量间交互作用关系。进一步,结合算法所揭示的变量交互作用进行知识挖掘与CFD验证,证明对分离线附近型线进行微调可有效降低激波与边界层相互作用,从而提高跨声速叶栅的气动性能。由此,所提出的算法在求解高维大资源叶轮机械优化设计问题上的适用性和有效性得到验证。

关键词: 叶轮机械;代理模型优化算法;轴流压气机;优化设计;知识挖掘

中图分类号: TK421.4 **文献标志码:** A

DOI: 10.7652/xjtuxb202307013 **文章编号:** 0253-987X(2023)07-0139-12

Study on Turbomachinery Optimization Algorithm Based on Dynamic Interaction Analysis

WANG Qineng, SONG Liming, GUO Zhendong, LI Jun, FENG Zhenping

(School of Energy and Power Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: Due to the curse of dimensionality, it is difficult to perform high-dimensional optimization of turbomachinery with current surrogate-based optimization algorithm. To address the problem, a dynamic aggregation global optimization algorithm, which adaptively clarifies the variable interactions, was proposed. The proposed algorithm obtains the information on interactions between design variables without consuming additional samples. Based on this information, the high-dimensional problem is decomposed into multiple low-dimensional problems for efficient optimization. In addition, such information also serves as the basis for subsequent knowledge mining. After finishing the test on a 30-dimensional mathematical benchmark problem, the proposed algorithm is used for optimization and design space knowledge mining of the Rotor 37 compressor blade with 28 design variables. After optimization, the isentropic efficiency of Rotor 37 blade is increased by 1.69% at design condition; the aerodynamic performance of optimized design at off-design condi-

收稿日期: 2022-10-07。 作者简介: 汪祺能(1997—),男,博士生;郭振东(通信作者),男,助理教授。 基金项目: 国家科技重大专项资助项目(2019-II-0008-0028);中国航空发动机集团产学研合作项目(HFZL2021CXY004);秦创原引用高层次人才创新创业人才项目(QCYRCXM-2022-210)。

网络出版时间: 2023-01-11

网络出版地址: <https://kns.cnki.net/kcms/detail/61.1069.T.20230110.1409.001.html>

tions is also improved. While obtaining the optimal solution, the proposed algorithm also reveals the interactions among variables in the design space of Rotor 37 blades, and knowledge mining and CFD verification are further carried out based on the variable interactions revealed. It shows that, the fine tuning of the profile near the separation line will effectively reduce the interactions between the shock waves and boundary layer, thus improving the aerodynamic performance of the transonic blade. Therefore, the applicability and effectiveness of the proposed algorithm in optimization of expensive high-dimensional turbomachinery design are well demonstrated.

Keywords: turbomachinery; surrogate-based optimization; axial flow compressor; optimization design; data mining

压气机等叶轮机械内部流动复杂,对其进行精细化设计时需考虑的参数变量众多,且输入设计变量与输出性能之间函数关系无法显式表达,采用 CFD 等数值方法进行性能评估较为耗时,是典型的高维大资源黑盒子问题^[1]。

针对叶轮机械设计优化高维大资源黑盒子特点,研究人员开展了大量研究。针对大资源问题特点,将代理模型优化算法(SBO)引入叶轮机械设计优化过程^[2]。该类算法通过建立输入设计变量与输出目标性能之间近似函数关系,以代替耗时的 CFD 性能评估,利用较少的计算成本即可获得满足设计要求的最优解,因而近年来获得广泛关注。例如,郭振东等基于高效全局优化(EGO)算法实现了跨声速压气机叶片设计优化^[3];黄松等基于代理模型和鲸鱼算法完成了对可控扩散叶型压气机叶片的优化^[4];王加浩等基于多项式响应面完成了离心风机叶片的优化^[5];王啸宸等基于多种代理模型的组合模型完成了多级压气机的优化设计^[6]。

值得注意的是,SBO 算法在有效提升叶轮机械设计优化效率的同时,面临着“维数灾难”的问题,即随着设计变量个数的增加,大多数 SBO 算法获得最优解所需的性能评估次数呈指数增加。有研究者指出,常用 SBO 算法最适用于求解 15 维及以下的问题,而对于更高维度的优化问题求解,SBO 算法的优化效率将显著下降^[7]。

针对优化中所遇到的“维数灾难”问题,提出了智能分解优化算法(IDO)^[8]。IDO 算法首先依据变量间交互关系将高维设计空间分解为若干低维子空间,进而在各低维子空间开展设计优化,由此可有效降低优化设计空间的复杂程度,将棘手的高维设计优化问题变得可解。但是,一次性地精确完成子空间分解通常需耗费大量样本。以常用的摄动法为例^[9],由于分析每两个变量间的交互关系都需要进行一组独立的采样^[10],对于 d 维设计空间分解则需

$d(d-1)/2$ 组不同的样本。因此,IDO 算法能显著提升性能评估省时的高维问题的设计优化效率,但难以求解耗时的典型叶轮机械设计优化问题。

另一方面,在研究如何高效求解叶轮机械大资源问题的同时,亦有研究者针对叶轮机械黑盒子问题特点开展深入研究。例如,郭振东等结合 Kriging 代理模型与总变差分析技术、自组织图等,建立了通用的叶轮机械设计空间知识挖掘框架^[3],用于厘清 19 维设计空间中对压气机叶栅性能影响显著的设计变量及其作用规律。李琛玺等对 26 维高压比离心进行了优化与知识挖掘,利用总变差分析等技术分别识别出对气动和强度性能影响显著的设计变量^[11]。秦瑞鸿等对 26 维离心压气机设计空间进行知识挖掘,成功识别出压气机宽工况和窄工况运行所对应的子空间及相关对性能影响显著的设计参数^[12]。进一步,Baert 等在性能评估非常耗时的情况下,开展了基于迭代的设计空间知识挖掘与优化,即将上一轮优化设计空间知识挖掘获取的变量交互作用信息用于下一轮优化过程,由此成功完成了 55 维乃至更高维设计空间的螺旋桨叶型设计优化^[13]。

受到 Baert 等开展的迭代式设计空间知识挖掘与设计优化工作的启发,本文提出了新的 IDO 算法用于叶轮机械设计,并将其命名为动态聚合代理模型优化(DA-EGO)算法。与传统 IDO 算法在优化前一次性确立子空间分解方案不同,DA-EGO 算法在每一轮优化迭代中均开展变量交互作用分析,并且结合上一轮优化的最优解性能提升情况,确定下一轮优化迭代时各子设计空间的分解方法,从而在优化迭代过程中不断优化子空间分解方案,以突破传统 IDO 算法难以用于求解大资源问题的困境。如此往复,在优化结束时,DA-EGO 算法不仅可得到设计空间全局最优解,还能较为准确地获取各变量交互作用关系。这对于厘清设计空间特征、更深入的理解最优解性能提升的本质原因具有重要帮助。

1 DA-EGO 算法

针对高维叶轮机械设计优化问题面临的“维数灾难”难题,本文提出了基于动态交互作用分析的 DA-EGO 算法。该算法基于变量交互作用分析在迭代过程中不断优化子空间的分解方案,实现优化与设计空间知识挖掘的深度融合,在获得最优设计的同时提取设计空间有用信息。

1.1 动态交互作用分析方法

如前文所述,交互作用分析的成本过高是 IDO 算法难以用于大资源工程优化的最主要原因。为了降低交互作用的分析成本,本文提出了动态交互作用分析方法,分为变量组合筛选、建模和确认 3 个步骤。图 1 为动态交互作用的分析过程,图中 $x_1 \sim x_6$ 为问题所包含的 6 个自变量。




图 1 动态聚合算法交互作用分析流程

Fig. 1 DA-EGO interaction analysis process

以下式所示问题为例,对交互作用过程进行介绍

$$f(x) = x_1^2 + (x_2 - x_3)^2 + (x_3 - x_4)^2 + (x_5 + x_6)^2 \quad (1)$$

(1) 变量组合筛选。高维问题变量间关系复杂,难以一次性厘清。变量组合筛选的目的是选择出本轮优化需要分析的若干组交互关系。基于所有已评估样本,使用基于混沌多项式模型(PCE)^[14]的敏感度分析方法,获得变量两两之间敏感度值估计值 $S_{ij}^{PCE} (1 \leq i < j \leq D)$,计算方法如下

$$S_{ij}^{PCE} = \int_0^1 \int_0^1 \hat{f}_{ij}^2(x_i, x_j) dx_i dx_j / (\int_{D_X} \hat{f}^2(x) dx - \hat{f}_0^2) \quad (2)$$

式中: $\hat{f}$ 、 $\hat{f}_0$ 和 $\hat{f}_{ij}$ 分别为由 PCE 模型估计得到的问

题对象本身,问题均值和 Sobol 分解后代表 i, j 变量的函数项。在所有的 $D(D-1)/2$ 个组合中,筛选出其中 Sobol 敏感度最大的 $[D/3]$ 个组合,记录为 $I_S = (x_1^1 x_1^2, x_2^1 x_2^2, \dots, x_{[D/3]}^1 x_{[D/3]}^2)$,此处 D 表示原问题的维度。图 1 中椭圆框线内的虚线箭头即表示筛选出的变量组合。值得注意的是,有限样本下高维代理模型精度不足会导致交互效应分析出现误差,所以选择的准确性还有待后续确认。本文通过开源程序 UQlab 建立 PCE 模型^[15],其中选择的基函数为 Legendre 多项式。

(2) 子空间建模。为确定变量组合筛选得到的变量组合的正确性,需建立其对应子空间的模型,具体步骤如下。在筛选出的变量组合 $x_i x_j$ 对应的子空间中进行采样,在计算子空间样本值时,子空间样本值与原函数样本值的关系如下

$$f_{\text{sub}}(x_i, x_j) = f(x_1^*, \dots, x_i, \dots, x_j, \dots, x_D^*) \quad (3)$$

在 D 个原函数变量中,变量 x_i, x_j 的取值与子问题一致,而其余 $D-2$ 个变量的值用当前已评估最优样本的对应变量取值来代替。随后,使用这些样本建立 Kriging 模型^[16]。由于子问题设计空间维度低,仅需要较少的样本即可建立精度较高的 Kriging 代理模型,用于甄别变量组合的正确性。

(3) 交互关系确认。根据建立的子空间 Kriging 代理模型进行摄动法交互分析,确认筛选出的组合 $x_i x_j$ 是否具有交互关系。摄动法分析如下

$$H_{ij} = \frac{\Delta}{Nh^2(\max(\hat{F}) - \min(\hat{F}))} \quad (4)$$

$$\Delta = \sum_{k=1}^{N_{\text{test}}} | \hat{F}(x_{k,1}, x_{k,2}, \dots, x_{k,i} + h, \dots, x_{k,j} + h, \dots, x_{k,d}) - \hat{F}(x_{k,1}, x_{k,2}, \dots, x_{k,i} + h, \dots, x_{k,j}, \dots, x_{k,d}) - \hat{F}(x_{k,1}, x_{k,2}, \dots, x_{k,i}, \dots, x_{k,j} + h, \dots, x_{k,d}) + \hat{F}(x_{k,1}, x_{k,2}, \dots, x_{k,i}, \dots, x_{k,j}, \dots, x_{k,d}) |$$

式中: H_{ij} 表示变量 x_i, x_j 间的交互关系程度; $\hat{F}$ 表示代理模型; N, h 等参数取值与文献[17]保持一致。如果 $H_{ij} \geq 0.2$,可以确认交互关系存在, $x_i x_j$ 间的交互作用将被记录到交互数据表中。图 1 中,被错误筛选出的变量 $x_1 x_2$ 间的交互关系在确认环节被剔除,由此提升了交互作用分析的精度。

随着上述 3 个步骤的循环进行,变量间的交互关系被逐渐挖掘出来,聚合成多个簇。如图 1 所示,在经过了两轮循环后,利用子空间中的 Kriging 代理模型,可以准确识别原函数设计空间各变量交互作用关系。

1.2 DA-EGO 流程

图 2 为 DA-EGO 算法的框架图,该算法主要分为高维空间分解、子空间优化和子空间知识挖掘 3 个部分,上文所述的动态交互作用分析方法的 3 个步骤也依次地融合在这 3 个部分中。




图 2 DA-EGO 算法框架图

Fig. 2 Framework of DA-EGO algorithm

(1)高维空间分解。首先,基于所有已评估样本完成上文所述的变量组合筛选步骤(第一轮迭代需要对整个设计空间进行少量的均匀采样),获得的 $[D/3]$ 个组合记为 $I_s = (x_1^{s1} x_1^{s2}, x_2^{s1} x_2^{s2}, \dots, x_{[D/3]}^{s1} x_{[D/3]}^{s2})$ 。在之前优化中已经确认有交互关系并记录了变量组合记为 $I_c = (x_1^{c1} x_1^{c2}, x_2^{c1} x_2^{c2}, \dots, x_i^{c1} x_i^{c2})$ 。 I_s 是候选的交互变量组合的集合,在每一轮优化中更新, I_c 是确认有交互关系的变量组合的集合,在整个优化中不断积累增加。根据上述两个数据集合来完成本轮优化的空间分解,具体步骤如下。

步骤 1 将 D 个变量依次分到 D 个簇中,完成初始化分组,变量 x_k 属于第 k 个簇($k=1, \dots, D$)。

步骤 2 对于 I_c 中的变量组合,将变量 x_k^{c1} 和 x_k^{c2} 所属的簇合并($k=1, \dots, l$),完成后得到初步分解方案。

步骤 3 对于 I_s 中的变量组合,依次将变量 x_k^{s1} 和 x_k^{s2} 所属的簇合并($k=1, \dots, [D/3]$),如果合并后簇中包含的变量个数大于 6,则跳过该变量组,完成后得到最终分解方案。

步骤 4 从所有已评估样本中选择最优样本作为空间分解的核心点。子空间内样本只有其所属的变量

发生变化,其余变量的值保持与核心点相同。

(2)子空间优化。EGO 算法在基于 Kriging 代理模型选择新的加点样本时,通常使用 EI(expected improvement)准则^[18]来平衡局部搜索和全局探索之间的关系。EI 准则的计算方法如下

$$EI(x) = \int_{-\infty}^{f_{\min}} (Y(x) - f_{\min}) dY =$$

$$(f_{\min} - \hat{y}(x)) \Phi\left(\frac{f_{\min} - \hat{y}}{s}\right) + s \varphi\left(\frac{f_{\min} - \hat{y}}{s}\right) \quad (5)$$

式中: $\Phi(\cdot)$ 和 $\varphi(\cdot)$ 分别表示高斯分布累积函数和密度函数; $f_{\min}$ 表示评估样本的最小值; $\hat{y}$ 、 $\hat{s}$ 分别表示模型的均值、标准差的估计值。

EGO 算法进行优化加点的过程也是其所使用的 Kriging 代理模型精度不断提升的过程,因此不需要额外的样本,子空间的优化过程即是动态交互作用分析的子空间建模过程。本文设置 EGO 算法的初始采样数为 $5d$,最大迭代次数为 $6d$, d 为子空间维度。

(3)子空间知识挖掘。首先基于所得的 Kriging 模型上述交互关系确认步骤。随后,将确认后的交互关系记录到交互数据表中,即将变量对加入集合 I_c 中。在一轮循环的最后,所有子空间优化得到的最优解被组合起来,生成一个新的样本并获取其评估值,并将产生的样本都记录到样本数据表中。

综上所述,动态交互作用分析方法的 3 个步骤分别融合到了 DA-EGO 算法的 3 个主要部分中。高维空间分解利用了变量组合筛选和历史积累交互信息来降低优化难度;子空间优化的过程同时也实现了子空间的精确建模;子空间知识挖掘包含了交互关系确认和子优化结果的组合。各部分充分体现了优化与交互作用分析相互促进的关系,二者在数据上共用样本数据,在顺序上交替进行完成,在机理上相互促进,提高了优化的效率和分析的精度。

2 DA-EGO 算法函数测试

为验证 DA-EGO 算法性能,首先选用两个函数算例对 DA-EGO 算法优化性能进行测试,并将其与最新提出的代理模型辅助进化 IKAEA 算法^[19]以及经典的进化 DE 算法^[20]、遗传 GA 算法^[21]等进行性能对比。此外,本节还对 DA-EGO 算法识别的变量交互作用的准确性进行验证。

2.1 测试函数与测试方案

利用文献[22]中的两个 30 维测试函数 F_{CEC1} 和 F_{CEC9} 进行测试。其中,函数 F_{CEC1} 为可分函数,函数 F_{CEC9} 为不可分函数,相应表达式如下

$$\begin{cases} \mathbf{F}_{\text{CEC1}}(\mathbf{x}) = 10^{-5} \sum_{i=1}^D (10^6)^{\frac{i-1}{D-1}} \mathbf{z}_{\text{sft}}^2(x_i), \\ x_i \in [-10, 10] \\ \mathbf{z}_{\text{sft}} = (\mathbf{x} - \mathbf{O})[\mathbf{P}] \end{cases} \quad (6)$$
$$\begin{cases} \mathbf{F}_{\text{CEC9}}(\mathbf{x}) = 10^{-5} \sum_{i=1}^D (10^6)^{\frac{i-1}{D-1}} \mathbf{z}_{\text{rot}}^2(x_i), \\ x_i \in [-10, 10] \\ \mathbf{z}_{\text{rot}}[1 + 5n:5 + 5n] = \mathbf{z}_{\text{sft}}(\mathbf{x})[1 + 5n:5 + 5n]\mathbf{M}, \\ n = 0, 1, 2 \\ \mathbf{z}_{\text{rot}}[1 + 5n:5 + 5n] = \mathbf{z}_{\text{sft}}(\mathbf{x})[1 + 5n:5 + 5n], \\ n = 3, 4, 5 \end{cases} \quad (7)$$

式中： $[\cdot]$ 表示选择目标向量中对应 $[\cdot]$ 内向量中指定索引位置的元素； $\mathbf{O}$ 为偏移参数； $\mathbf{P}$ 为重排序参数； $\mathbf{M}$ 为通过旋转来产生变量间交互关系的单位正交矩阵^[22]。对于 5 种不同的算法，每个算法在相同初始条件下独立进行 20 次优化，各算法初始样本数均为 50。

2.2 DA-EGO 算法的函数测试结果

以 1 500 个样本作为终止条件，利用 DA-EGO 算法、IKAEA 算法等对 CEC1 函数和 CEC9 函数进行 10 次优化，得到的平均收敛曲线如图 3 所示，对应 10 次优化统计结果如表 1 所示。




图 3 函数算例平均收敛曲线对比图

Fig. 3 Comparison of average convergence curves

表 1 函数算例测试结果

Table 1 Test results of function examples


测试函数	算法	最优值	
		均值	标准差
CEC1	DA-EGO	1.795×10^{-8}	8.534×10^{-9}
	DE	13.38	3.782
	GA	7.826	3.882
	IKAEA	0.778 1	0.613 5
CEC9	DA-EGO	1.032	1.039
	DE	48.48	8.039
	GA	10.07	5.631
	IKAEA	2.619	1.235

由图 3 可见，对于变量可分函数 CEC1，本文所提出的基于动态交互作用分析的 DA-EGO 算法优化收敛速度明显优于 IKAEA 算法及传统进化 DE 算法。对于复杂的变量不可分函数 CEC9，DA-EGO 算法同样以最快速度获得性能最优的解。进一步，由表 1 易见，DA-EGO 算法 10 次优化所得到的最优解不仅平均值最小，其所对应的均方根误差亦远小于其他同类比较算法。以上结果表明，DA-EGO 算法具有优越的全局收敛性能，且健壮性较好。


2.3 动态交互作用分析结果验证

与 IKAEA 算法、DE 算法等常规优化算法不同，DA-EGO 算法在得到最优解的同时，还可获得各变量交互作用关系，这对于厘清设计空间特征、更深入地理解工程优化问题最优解性能提升的本质原因具有重要的意义。本节基于式(7)所示测试算例，验证 DA-EGO 算法所得到的变量交互作用关系的准确性。

图 4 展示了以 1 500 个样本和 3 000 个样本为终止条件时，DA-EGO 算法所获取的变量组合。作为对比，图 4 亦展示了基于 PCE 的一次性敏感性分析方法得到的变量组合。



(a)1 500 个样本



(b) 3 000 个样本

图 4 交互作用分析结果示意图

Fig. 4 The results of interaction analysis

算例中共包含 3 组变量组合, 即 $\{x_9, x_{14}, x_{17}, x_7, x_{11}\}$ 、 $\{x_3, x_{16}, x_{24}, x_1, x_{20}\}$ 和 $\{x_{28}, x_2, x_{10}, x_8, x_{21}\}$, 在图 4 中利用虚线方框进行表示。与此同时, DA-EGO 算法所识别的变量组合采用阴影方框所连成的区域进行表示; 而基于 PCE 的一次性敏感性分析方法得到的变量组合用圆形表示, 其中圆的大小则表示各变量交互作用关系的强弱。

如图 4(a) 所示, 以 1 500 个样本作为终止条件, DA-EGO 算法成功识别出变量组合 $\{x_9, x_{14}, x_{17}, x_7, x_{11}\}$ 、 $\{x_{16}, x_{24}\}$ 和 $\{x_{28}, x_2, x_{10}, x_8\}$, 而基于 PCE 的一次性敏感性分析仅能识别少数变量间两两交互作用, 如 $\{x_9, x_{17}\}$ 、 $\{x_9, x_7\}$ 、 $\{x_3, x_{16}\}$ 、 $\{x_{28}, x_8\}$ 等, 且其中不乏错误的变量分组如 $\{x_9, x_8\}$ 、 $\{x_{20}, x_8\}$ 等。进一步, 当采用 3 000 个样本作为终止条件时, DA-EGO 算法能完全正确的识别式(7)中所有变量交互作用组合, 而基于 PCE 的一次性敏感性分析方法依然无法识别 $\{x_9, x_{11}\}$ 、 $\{x_{28}, x_{21}\}$ 等变量交互作用组合。

以上测试表明, 相比于一次性敏感性分析方法, DA-EGO 算法所采用的动态交互分析策略能更加准确的识别原问题设计空间各变量交互作用关系。

3 压气机叶片优化设计及知识挖掘

利用 DA-EGO 算法, 本文对 Rotor 37 叶栅进行设计优化与知识挖掘, 以进一步验证所提出的方法的正确性和有效性。

3.1 问题描述

压气机是燃气轮机的重要部件, 其性能优劣直接影响燃气轮机的效率、功率和可靠性^[23]。扩压流动对于压气机叶片型线造型十分敏感, 且型线随叶

高变化幅度大, 压气机的优化设计具有较大的难度^[24]。本次优化的对象是带有完整实验数据的压气机叶片 Rotor 37, 该叶片由 NASA Glenn 中心的 Reid 和 Moore 设计并完成测试^[25]。

优化设计的目标是最大化等熵效率, 同时以罚函数的形式约束设计点的质量流量与总压比, 相应优化模型数学表达式如下

$$\begin{cases} \max f_{\text{obj}}(\mathbf{x}_{\text{des}}) = \max \eta_{\text{is}}(\mathbf{x}_{\text{des}})/p(\mathbf{x}_{\text{des}}) \\ \text{s. t. } 0.98m(\mathbf{x}_{\text{ref}}) \leq m(\mathbf{x}_{\text{des}}) \leq 1.02m(\mathbf{x}_{\text{ref}}) \\ \quad 0.98\epsilon(\mathbf{x}_{\text{ref}}) \leq \epsilon(\mathbf{x}_{\text{des}}) \leq 1.02\epsilon(\mathbf{x}_{\text{ref}}) \end{cases} \quad (8)$$

式中: η_{is} 表示等熵效率; $p(\mathbf{x}_{\text{des}})$ 为罚函数; m 表示质量流量; ϵ 表示总压比; 下标 des 表示设计值; 下标 ref 表示参考值。

本文基于非均匀有理 B 样条造型技术^[26]对叶片截面型线及积叠线进行参数化造型, 具体流程如图 5 所示。首先, 选取 0%、25%、50%、75%、100% 叶高截面型线进行参数化, 其中每个截面在吸力面选择 5 个可调控制点进行微调。其次, 在完成各型面参数化造型后, 利用非均匀有理 B 样条曲线对其空间积叠线进行拟合, 并选取 2 个周向控制点和 1 个轴向控制点对空间积叠线进行调整。在完成上述截面型线与空间积叠线的调整后, 利用蒙面法生成新的三维几何造型。基于上述参数化方法, 本次压气机叶片优化共 28 个设计变量, 相应变量定义与变化范围如表 2 中所示, 其中 c_{ax} 表示轴向弦长。叶片截面控制点的可调范围具有中间大、前尾缘小的特点。




图 5 Rotor 37 叶片优化参数化方法示意图

Fig. 5 Optimization parameterization method of Rotor 37 blade

3.2 计算模型

本文优化使用的计算模型的进出口边界条件与网格生成参数参照文献[3]进行设置。表 3 所示为 Rotor 37 的相关设计参数, 在后续优化中设置进口边界的总温总压如表 3 所示, 入口气流角度沿轴向, 设置出口平均背压为 115 kPa 不变^[27,25]。

表 2 设计变量定义与范围

Table 2 Definition and range of design variables

物理含义	变量符号	变量范围
叶顶截面周向平移距离	x_1	$[-10\%c_{ax}, 10\%c_{ax}]$
中间截面周向平移距离	x_2	$[-15\%c_{ax}, 15\%c_{ax}]$
叶顶截面轴向平移距离	x_3	$[-10\%c_{ax}, 10\%c_{ax}]$
不同叶高截面控制点 1 移动距离	$x_4, x_9, x_{14}, x_{19}, x_{24}$	$[-0.6\%c_{ax}, 0.6\%c_{ax}]$
不同叶高截面控制点 2 移动距离	$x_5, x_{10}, x_{15}, x_{20}, x_{25}$	$[-1.2\%c_{ax}, 1.2\%c_{ax}]$
不同叶高截面控制点 3 移动距离	$x_6, x_{11}, x_{16}, x_{21}, x_{26}$	$[-1.5\%c_{ax}, 1.5\%c_{ax}]$
不同叶高截面控制点 4 移动距离	$x_7, x_{12}, x_{17}, x_{22}, x_{27}$	$[-1.2\%c_{ax}, 1.2\%c_{ax}]$
不同叶高截面控制点 5 移动距离	$x_8, x_{13}, x_{18}, x_{23}, x_{28}$	$[-0.6\%c_{ax}, 0.6\%c_{ax}]$

表 3 Rotor 37 几何与工况参数

Table 3 Geometry and design condition parameters

参数	数值
设计转速/($r \cdot \min^{-1}$)	17 188.7
叶片数	36
展弦比	1.19
叶顶间隙/mm	0.356
入口总温/K	288.15
入口总压/Pa	101 325

在优化中,通过软件 Numeca Autogrid5 生成网格,网格划分采用 H-O-I 网络结构,设置近壁面第一层网格厚度为 0.003 mm;计算求解通过 Numeca Fine/Turbo 模块完成,其中湍流方程采用 Spalart-Allmaras 模型,壁面均设为绝热光滑壁面。本文优化所使用的结构化网格的节点数为 365 321,网格无关性验证的结果展示在图 6 中。





图 6 网格无关性分析


Fig. 6 Grid independence analysis

在完成计算模型的构建后,计算评估了 Rotor 37 参考叶型在不同工况下的流动性能。CFD 计算结果与实验结果进行了对比见图 7,易见 CFD 计算结果与实验结果在趋势上吻合良好,由此验证了本

文使用的 CFD 计算方法精度较高,可用于 Rotor 37 叶片的气动优化设计。



(a)效率和流量的关系



(b)压比和流量的关系

图 7 实验与数值计算特性曲线对比

Fig. 7 Experimental and CFD result comparison

3.3 Rotor 37 叶片优化结果分析

为验证 DA-EGO 算法在工程算例中的有效性,采用与数值算例相同的对比算法,对 Rotor 37 叶片在相同的初始条件下独立进行 5 次优化。每次优化所允许的 CFD 计算总数为 1 000 次,相关优化结果如表 4 所示,其中的平均出口气流角为出口气流方向与额线的夹角。表 4 中 4 种算法均能不同程度地

提升 Rotor 37 气动效率,其中以本文所提出的 DA-EGO 算法得到的优化解性能提升最为明显;与此同时,DA-EGO 算法 5 次优化得到的最优解方差最小,由此进一步验证了本算法的有效性。为验证优化的气动性能,选取 DA-EGO 算法 5 次优化获得的中位数结果展开具体分析。图 8 展示了 90%叶高相对马赫数云图,图 9 展示了叶片吸力面及端壁表面极限流线分布。从图中易见,优化叶栅 90%叶高激波位置向下游倾斜(见图 8),与之对应,优化叶栅吸力面激波与边界层相互作用导致的分离区域减少(见图 9(b)区域 A),叶顶出口回流区几乎不可见(区域 B)。上述现象表明,使用 DA-EGO 算法所获得的最优设计相对参考设计的气动性能明显提升。




图 8 优化前后 90%叶高截面相对马赫数云图
Fig. 8 Relative Mach number contour at 90% span before and after optimization

表 4 不同算法优化设计结果

Table 4 Optimization results of different algorithms

算法	等熵效率/%		总压比		质量流量/(kg · s ⁻¹)		平均出口	平均效率
	均值	标准差	均值	标准差	均值	标准差	气流角/(°)	提升/%
参考设计	85.39		2.039 5		20.624 0		49.63	
DA-EGO	87.07	0.461	2.054 8	0.019	20.964 7	0.051	49.99	1.69
IKAEA	86.65	5.384	2.050 3	0.071	20.884 1	0.232	49.94	1.26
GA	86.73	2.375	2.048 9	0.037	20.878 5	0.135	49.95	1.34
DE	86.45	2.825	2.048 5	0.077	20.828 6	0.187	49.85	1.06




图 9 叶片吸力面及端壁表面极限流线
Fig. 9 Limiting streamlines at suction surface and end wall

图 10 展示了优化前后的变工况特性曲线。优化后,DA-EGO 算法得到的最优设计在整个工况范围内等熵效率均明显提升,且近失速工况范围有所增加,如图 10(a)所示。与此同时,最优设计总压比相对于参考设计亦有所提升。以上结果表明,采用 DA-EGO 得到的最优设计相对参考设计在优化工况和变工况条件下性能均得到明显提升。




图 10 Rotor 37 优化结果特性曲线对比图
Fig. 10 Comparison of characteristic curves

3.4 Rotor 37 叶片设计空间知识挖掘

如前所述,基于动态交互作用分析,DA-EGO 算法在得到设计空间最优解的同时,还能较为准确地获取各变量交互作用关系。本节将基于 DA-EGO 算法得到的变量交互作用关系,对 Rotor 37 叶栅设计空间进行知识挖掘,以更加深入理解最优解性能提升的本质原因。

图 11 给出了 Rotor 37 叶栅 28 维设计空间各变量所在几何位置。其中, x_1 和 x_2 为中间截面和顶部截面弯参数, x_3 为顶部截面掠参数,其余变量为不同截面型线控制点变量。采用 DA-EGO 算法,得到如下变量交互作用组合,即 $\{x_1, x_3, x_6, x_{16}, x_{21}, x_{28}\}$ 、 $\{x_{12}, x_{14}\}$ 、 $\{x_{20}, x_{23}\}$ 等。限于篇幅,下文将主要对变量组合 $\{x_1, x_3, x_6, x_{16}, x_{21}, x_{28}\}$ 进行详细分析。




图 11 28 维设计空间各变量几何位置

Fig. 11 Locations of design variables in 28-dimensional optimization space

图 12 展示了变量组合 $\{x_1, x_3, x_6, x_{16}, x_{21}, x_{28}\}$ 所对应的几何位置及叶栅壁面极限流线。从中易见,变量 x_6, x_{16}, x_{21} 和 x_{28} 位于激波与边界层交互作用所产生的分离线附近, x_1 和 x_3 分别为叶片三维空间积叠所对应的弯参数和掠参数。就叶片基元流动情况而言,调整 x_6, x_{16}, x_{21} 和 x_{28} 将分别对叶根截面、50%叶高截面和 75%叶高和叶顶截面激波附近的型线进行光顺,以降低基元方向激波与边界层相互作用造成的流动损失。进一步,将变量 x_6, x_{16}, x_{21} 和 x_{28} 进行联调,则有利于优化各基元流动在激波位置附近区域的径向匹配情况。另一方面,弯参数 x_1 和掠参数 x_3 主要用于调整叶栅通道内径向载荷的分布情况,将弯掠参数与各截面激波附近位置控制点(x_6, x_{16}, x_{21} 和 x_{28})联调,则有望优化叶栅通

道内三维流动的流向和径向匹配情况,以进一步提升压气机叶栅气动性能。




图 12 识别出的变量交互作用
Fig. 12 Detected variable interactions

结合上述 DA-EGO 算法所揭示的变量交互作用关系分析结果,对优化叶栅型线变化与性能改善情况进行对比分析。图 13 展示了优化前后各截面型线,其中,叶片的最大厚度位置的内切圆也绘制在图中。对比发现,优化前后叶片的最大厚度变化较小,最大厚度所在位置向尾缘移动。与交互作用变量 x_6, x_{16}, x_{21} 和 x_{28} 所能调控的区域相对应,优化叶栅各截面型线主要在中部区域进行了调整(见图 13),该区域正好与激波打在叶栅吸力面的位置相对应(见图 9)。与此同时,最优设计三维叶片呈现前掠与前弯复合结构(见图 9)。在各截面激波附近型线光顺和弯掠造型共同作用下,叶栅通道内激波向下游方向偏移(见图 8),吸力面中间区域及顶部区域流动分离区域明显减少(见图 9)。对应的,在优化工况及变工况条件下,优化叶栅等熵效率得到明显提升,而对应总压比亦有些许增加(见图 10)。




图 13 优化前后不同叶高截面型线对比
Fig. 13 Section profiles before and after optimization

上述型线特征变化与叶栅性能改善的对比分析

结果可进一步总结为跨声速叶栅的设计准则,即跨声速叶栅设计与性能提升,可重点围绕激波与边界层交互作用生成的分离线附近区域型面调整展开,通过对该区域型线进行光顺,并结合弯、掠等技术精细化调整叶栅通道内三维流动的匹配情况,实现在不降低跨声速压气机叶栅压比的情况下显著降低叶栅内部流动损失。

为了验证从变量交互关系知识中提炼出的设计准则的正确性,直接使用该准则对参考 Rotor 37 叶片进行调整。该过程即对 5 个分离线附近的截面控制点参数和 2 个弯掠设计变量的取值进行调整。所得的基于知识挖掘的设计结果的等熵效率为 86.22%,较原始设计提升了 0.83%,可见基于所得设计准则的调整效果较为显著。调整后叶型在设计工况下的质量流量为 20.846 kg/s,总压比为 2.055,均处于约束范围内。图 14 展示了参考叶型、DA-EGO 优化叶型和基于知识挖掘得到的叶型的气动性能沿叶高的分布情况。从图中可以看出,基于知识挖掘的设计与优化设计的效率提升明显的区域相同,但幅度稍小。上述结果都证明了上文设计准则的有效性。




图 14 优化设计与参考设计气动性能沿叶高分布

Fig. 14 Aerodynamic performance of optimized and reference design along the span

综合上述分析,本文所提出的 DA-EGO 算法不仅能有效提升叶栅性能,还可用于揭示叶栅性能提升的本质原因,这对于高效求解叶轮机械设计这一大资源黑盒子问题具有重要的理论意义和工程实用价值。

4 结 论

针对叶轮机械设计优化高维大资源黑盒子的特点,本文提出了基于动态交互作用分析的代理模型

优化 DA-EGO 算法,并将其应用于跨声速压气机叶栅设计优化过程。主要得到以下结论。

(1) 基于动态交互作用分析,在优化过程中将高维设计空间分解为若干低维子空间进行求解,本文所提出的 DA-EGO 算法可有效降低高维问题求解的难度,将基于代理模型的优化算法拓展用于求解 30 维乃至更高维度的叶轮机械设计优化问题。

(2) 与传统设计优化算法不同,本文所提出的 DA-EGO 算法在获得最优解的同时可厘清设计空间各变量交互作用关系,从而为进一步知识挖掘、提取设计空间有用信息奠定基础。

(3) 通过对典型 30 维数值算例测试,证明本文提出的 DA-EGO 算法相对最新提出的同类优化算法收敛速度更快,且优化解性能更优。与此同时,通过与原函数表达式进行对比发现,DA-EGO 算法能成功识别设计空间各变量交互作用关系。

(4) 利用 DA-EGO 算法对跨声速压气机叶栅进行设计优化,所获得的最优设计相对参考设计的气动性能在优化工况和变工况条件下性能均得到明显提升。更为关键的是,DA-EGO 算法在优化结束时成功识别出对叶栅气动性能影响显著的变量组合,进而帮助设计人员对设计空间进行知识挖掘,厘清了压气机叶栅性能提高的本质原因,提炼了设计信息。由此,进一步验证了所提出的算法用于求解具有高维大资源黑盒子特点的叶轮机械优化问题的适用性。

参考文献:

- [1] HE Wanxin, LI Gang, NIE Zhaokun. An adaptive sparse polynomial dimensional decomposition based on Bayesian compressive sensing and cross-entropy [J]. Structural and Multidisciplinary Optimization, 2022, 65(1): 26.
- [2] 席光, 王志恒, 王尚锦. 叶轮机械气动优化设计中的近似模型方法及其应用 [J]. 西安交通大学学报, 2007, 41(2): 125-135, 184.
XI Guang, WANG Zhiheng, WANG Shangjin. Aerodynamic optimization design of turbomachinery with approximation model method [J]. Journal of Xi'an Jiaotong University, 2007, 41(2): 125-135, 184.
- [3] 郭振东, 宋立明, 李军, 等. 基于子元模型的全局优化与设计空间知识挖掘方法 [J]. 推进技术, 2015, 36(2): 207-216.
GUO Zhendong, SONG Liming, LI Jun, et al. Meta-model-based global design optimization and exploration method [J]. Journal of Propulsion Technology, 2015,

- 36(2): 207-216.
- [4] 黄松, 阳诚武, 韩戈, 等. 采用鲸鱼算法的可控扩散叶型优化设计 [J]. 西安交通大学学报, 2020, 54(3): 49-57.
HUANG Song, YANG Chengwu, HAN Ge, et al. Optimal design of a controlled diffusion airfoil with the whale algorithm [J]. Journal of Xi'an Jiaotong University, 2020, 54(3): 49-57.
 - [5] 王加浩, 刘小民, 田晨晔, 等. 多翼离心风机双圆弧叶片的参数优化设计及气动性能分析 [J]. 西安交通大学学报, 2022, 56(3): 94-104.
WANG Jiahao, LIU Xiaomin, TIAN Chenye, et al. Parametric optimization design of double-circular arc blade used in multi-blade centrifugal fan and its aerodynamic analysis [J]. Journal of Xi'an Jiaotong University, 2022, 56(3): 94-104.
 - [6] 王啸宸, 李雪松, 任晓栋, 等. 多级压气机通流与CFD一体化优化设计方法 [J]. 清华大学学报(自然科学版), 2022, 62(4): 774-784.
WANG Xiaochen, LI Xuesong, REN Xiaodong, et al. Integrated through-flow and CFD optimization design method of multi-stage compressors [J]. Journal of Tsinghua University(Science and Technology), 2022, 62(4): 774-784.
 - [7] SHAN Songqing, WANG G G. Metamodeling for high dimensional simulation-based design problems [J]. Journal of Mechanical Design, 2010, 132(5): 051009.
 - [8] CHEN Wenxiang, WEISE T, YANG Zhenyu, et al. Large-scale global optimization using cooperative coevolution with variable interaction learning [M]//SCHAEFER R, COTTA C, KOŁODZIEJ J, et al. Parallel Problem Solving from Nature, PPSN XI. Heidelberg, Berlin, Germany: Springer, 2010: 300-309.
 - [9] FRIEDMAN J H, POPESCU B E. Predictive learning via rule ensembles [J]. The Annals of Applied Statistics, 2008, 2(3): 916-954.
 - [10] OMIDVAR M N, YANG Ming, MEI Yi, et al. DG2: a faster and more accurate differential grouping for large-scale black-box optimization [J]. IEEE Transactions on Evolutionary Computation, 2017, 21(6): 929-942.
 - [11] 李琛玺, 王静, 宋立明, 等. 高压比离心叶轮气动强度多学科优化与知识挖掘 [J]. 西安交通大学学报, 2017, 51(5): 102-111.
LI Chenxi, WANG Jing, SONG Liming, et al. Aero-mechanical multidisciplinary optimization and knowledge discovery of high pressure ratio centrifugal impeller [J]. Journal of Xi'an Jiaotong University, 2017, 51(5): 102-111.
 - [12] QIN Ruihong, JU Yaping, SPENCE S, et al. Meta-model-driven data mining model to support three-dimensional design of centrifugal compressor stage [J]. Journal of Turbomachinery, 2021, 143(12): 121013.
 - [13] BAERT L, DUMONT C, BEAUTHIER C, et al. Multidisciplinary design of a low-noise propeller: part II efficient aero-acoustic-mechanical design methodology exploiting surrogate models in an adaptive design space [C]//ASME Turbo Expo 2020: Turbomachinery Technical Conference and Exposition. New York, NY, USA: ASME, 2020: V02DT38A023.
 - [14] WIENER N. The homogeneous chaos [J]. American Journal of Mathematics, 1938, 60(4): 897-936.
 - [15] MARELLI S, SUDRET B. UQLab: a framework for uncertainty quantification in Matlab [C]//Vulnerability, Uncertainty, and Risk: Quantification, Mitigation, and Management. Reston, VA, USA: ASCE, 2014: 2554-2563.
 - [16] 韩忠华. Kriging 模型及代理优化算法研究进展 [J]. 航空学报, 2016, 37(11): 3197-3225.
HAN Zhonghua. Kriging surrogate model and its application to design optimization: a review of recent progress [J]. Acta Aeronautica et Astronautica Sinica, 2016, 37(11): 3197-3225.
 - [17] KANG K, LEE I. Efficient high-dimensional meta-modeling strategy using recursive decomposition coupled with sequential sampling method [J]. Structural and Multidisciplinary Optimization, 2021, 63(1): 375-390.
 - [18] PICKETT B, TURNER C J. A review and evaluation of existing adaptive sampling criteria and methods for the creation of NURBs-based metamodels [C]//ASME 2011 International Design Engineering Technical Conferences and Computers and Information in Engineering Conference. New York, NY, USA: ASME, 2011: 609-618.
 - [19] ZHAN Dawei, XING Huanlai. A fast kriging-assisted evolutionary algorithm based on incremental learning [J]. IEEE Transactions on Evolutionary Computation, 2021, 25(5): 941-955.
 - [20] STORN R, PRICE K. Differential evolution: a simple and efficient heuristic for global optimization over continuous spaces [J]. Journal of Global Optimization, 1997, 11(4): 341-359.
 - [21] DEB K. An introduction to genetic algorithms [J]. Sadhana, 1999, 24(4): 293-315.
 - [22] TANG Ke, LI Xiaodong, SUGANTHAN P N, et al. Benchmark functions for the CEC'2010 special session and competition on large-scale global optimization

- [EB/OL]. [2022-08-12]. http://al-roomi.org/multimedia/CEC_Database/CEC2010/LargeScaleGlobalOptimization/CEC2010_LargeScaleGO_TechnicalReport.pdf.
- [23] 宋立明, 李军, 丰镇平, 等. 三维跨声速压气机叶栅多目标气动优化设计 [J]. 工程热物理学报, 2007, 28(2): 223-225.
- SONG Liming, LI Jun, FENG Zhenping, et al. Multi-objective optimization design of the 3D transonic compressor cascade [J]. Journal of Engineering Thermophysics, 2007, 28(2): 223-225.
- [24] 陈玲, 据亚平, 李震, 等. 多级轴流压气机末级串联静子三维优化设计与分析 [J]. 西安交通大学学报, 2023, 57(1): 164-174.
- CHEN Ling, JU Yaping, LI Zhen, et al. Three-dimensional design optimization and analysis for last stator of multi-stage axial flow compressor [J]. Journal of Xi'an Jiaotong University, 2023, 57(1): 164-174.
- [25] SUDER K L. Experimental investigation of the flow field in a transonic, axial flow compressor with respect to the development of blockage and loss [EB/OL]. (1996-10-01) [2022-08-12]. <https://ntrs.nasa.gov/citations/19970001675>.
- [26] 周岳琨, 王建新, 管继伟, 等. 汽轮机叶片设计和几何成型方法综述 [J]. 汽轮机技术, 2001, 43(4): 198-202.
- ZHOU Yuekun, WANG Jianxin, GUAN Jiwei, et al. A summary about turbine blade design and molding method [J]. Turbine Technology, 2001, 43(4): 198-202.
- [27] AMERI A A. NASA rotor 37 CFD code validation glenn-HT code [C]//47th AIAA Aerospace Sciences Meeting including The New Horizons Forum and Aerospace Exposition. Reston, VA, USA: AIAA, 2009: AIAA 2009-1060.

(编辑 杜秀杰)