

文章编号: 1674-8190(XXXX)XX-001-16

基于物理知识驱动的敏感性分析及分区代理模型优化方法

邵梦莹^{1,2}, 夏露^{1,2}, 张伟^{1,2}, 赵轲^{1,2}

(1. 西北工业大学 航空学院, 西安 710072)

(2. 飞行器基础布局全国重点实验室, 西安 710072)

摘要: 设计变量“维数灾难”问题是限制基于代理模型优化算法应用到高维气动设计的关键技术难题。为了解决维度灾难问题导致的代理模型精度下降和优化效果变差的问题,改进一种基于物理知识驱动的敏感性分区代理模型优化方法,研究不同分区设计变量对目标函数的敏感性;在序贯分区优化的基础上,以敏感性作为分区代理模型优化的顺序,开展进一步的优化设计研究。结果表明:该方法将高维设计空间分解为一系列低维子空间,可以显著提高代理模型的预测精度,实现样本的高效配置,从而实现高效的全局搜索,相较于传统代理优化方法,其建立代理模型所花费时间大幅减少,提高了代理优化方法处理高维气动设计问题的能力。

关键词: 分区优化; EGO 方法; 维数灾难; 敏感性分析; 代理模型精度

中图分类号: V211.3

文献标识码: A

DOI: 10.16615/j.cnki.1674-8190.XXXX.XX.01

Sensitivity analysis and optimization method of partition surrogate model based on physical knowledge

SHAO Mengying^{1,2}, XIA Lu^{1,2}, ZHANG Wei^{1,2}, ZHAO Ke^{1,2}

(1. School of Aeronautics, Northwestern Polytechnical University, Xi'an 710072, China)

(2. National Key Laboratory School of Aircraft Configuration Design, Xi'an 710072, China)

Abstract: The problem of "dimensionality disaster" of design variable is a key technical problem that restricts the application of current agent-based optimization algorithms. In order to solve the problem of declining accuracy and poor optimization effect of surrogate model caused by dimensionality disaster problem, a sensitivity analysis method based on physical knowledge driven partition surrogate model optimization is improved. The sensitivity of different partition design variables to the objective function is studied. On the basis of the sequential partition optimization, the sensitivity is taken as the order of the partition surrogate model optimization. The results show that the method can solute the high-dimensional design space into a series of low-dimensional subspaces, improve the prediction accuracy of surrogate model, realize the efficiency configuration, so as to realize the global search. In comparison with traditional surrogate optimization method, the time spent on establishing the surrogate model is much lower, and the ability of surrogate optimization method to solve the high-dimensional aerodynamics design problem.

Key words: zone optimization; EGO method; dimensionality disaster; sensitivity analysis; accuracy of surrogate model

收稿日期: 2024-01-23; 修回日期: 2024-05-21

基金项目: 西北工业大学翼型、叶栅空气动力学重点实验室稳定支持项目资助(614220121020128)

通信作者: 赵轲(1985-), 男, 博士, 西北工业大学副研究员。E-mail: zhaoke@nwpu.edu.cn

引用格式: 邵梦莹, 夏露, 张伟, 等. 基于物理知识驱动的敏感性分析及分区代理模型优化方法[J]. 航空工程进展, XXXX, XX(XX): 1-16.

SHAO Mengying, XIA Lu, ZHANG Wei, et al. Sensitivity analysis and optimization method of partition surrogate model based on physical knowledge[J]. Advances in Aeronautical Science and Engineering, XXXX, XX(XX): 1-16. (in Chinese)

0 引言

基于 Kriging 模型的代理优化算法中,改善期望准则的方法即高效全局优化(Efficient Global Optimization,简称 EGO)方法因其高效性和全局性以及在处理工程中优化设计问题的优异表现,近年来在航空航天等领域得到了广泛地应用^[1]。经过近几年的发展,EGO 方法在诸多方面愈加完善日趋稳定,但在进行更加精细化的气动外形优化设计时,我们需要更多的设计变量进行参数化建模,以得到更加充分的设计空间,但是面对庞大的设计变量,此时再使用常规的代理模型优化方法譬如 EGO 方法,这必然会带来代理模型优化搜索困难和代理模型精度变差等问题,这也是 EGO 方法存在的一个最大的问题——“维数灾难”。目前的 EGO 方法对于高维优化问题的处理还亟待完善,而所谓的“维数灾难”指的是随着优化参数即设计变量的数量逐渐增加,找到最优解时所需的目标函数评估次数会急速增加,并且寻找最优解的难度也会急速增加^[2]。正如前文所述,愈加精细化的气动优化设计往往伴随着愈加高维度的设计变量,这一点也是目前无法避免的问题^[3-6]。正因如此,高维问题普遍存在,EGO 方法在高维问题上的应用还亟待开发,在工程问题和学术研究上,EGO 优化方法在高维优化问题上的应用研究意义深远。

EGO 方法中的维数灾难主要体现在三个方面,1)高维数的设计变量会大大降低代理模型的精度。2)高维情况下难以搜索最优解。3)在构造 Kriging 代理模型的过程中,需要对协方差矩阵 $R_{n \times n}$ 求逆,设 n 为样本点个数,而对矩阵求逆是非常耗时的过程,它的计算复杂度大约为 $O(n^3)^{[7]}$,从复杂度公式可以看出其计算量会随着 n 的增大而迅速增加,高维数时会导致代理模型耗时甚至远多于 CFD 流场模拟的计算量耗时,致使优化算法的计算效率大幅下降。维数越高,维数灾难表现得越为明显。因此针对以上三点来解决优化算法的维数灾难问题具有重要意义^[8]。

基于以上分析,研究者利用分层优化方法实现设计空间降维,来解决“维数灾难”引起的问题。早在 2005 年陈立、Li Simon 等^[9]对于复杂设计问题将一种基于普通树结构的增强依赖分析方法作为实现分解和再分解的手段;近年来马创等^[10]针

对超声速低声爆布局问题采用了分层优化的设计方法,对分层优化方法在可信度与效率进行了相关研究;赵轲^[11]基于分区代理模型的协同优化提出了相关管理框架的构建;徐圣冠^[8]针对优化中的参变量分裂引入经济学中的 Nash 均衡论提出了 Nash-EGO 算法来解决相关的气动优化问题;孟俊晖等^[12]为了优化叶片的复合材料层合结构提出了一种基于遗传算法的分层优化方法。上述工作中均基于传统的分层优化对高维设计变量进行分解,达到了降维的目的,也对“维数灾难”问题提供了解决方案。

以上方法虽然利用分层优化的方法解决了部分问题,但是对于高维情况下的三维气动外形优化设计,如何准确获取先验设计知识等问题还亟待解决。本文基于 EGO 方法在传统分层优化上进行改进,针对在不损失优化精度的条件下对设计变量进行降维同时提高优化过程的优化效率,以 ONERA-M6 机翼气动外形为基准机翼,选取不同机翼剖面多个设计变量,对高维设计变量根据物理机理和设计经验进行基于次序的空间分区分解,开展分区代理模型优化;针对获取先验知识问题从设计变量对目标函数的敏感性进行研究,验证分区代理优化模型的实用性与高效性。

1 基于代理模型的优化设计系统

1.1 高效全局优化(EGO)方法

1.1.1 Kriging 代理模型

Kriging 代理模型最早在 1951 年由南非的 Krige^[13]提出,之后由法国地质学家 Matheron^[14]进行了进一步的完善。其插值结果定义为已知样本函数响应值的线性加权。

$$\hat{y}(x) = \sum_{i=1}^n \omega^{(i)} y^{(i)} \quad (1)$$

因此,只要能给出加权系数 $\omega = [\omega^{(1)} \omega^{(2)} \dots \omega^{(n)}]^T$ 的表达式,便可得到设计空间中任意设计方案的性能预估值。引入统计学假设,则可表达为

$$Y(x) = \beta_0 + Z(x) \quad (2)$$

式中: β_0 为全局趋势模型,是个未知常数; $Y(x)$ 为数学期望值; $Z(\cdot)$ 为均值为零、方差为 σ^2 ($\sigma^2(x) \equiv \sigma^2, \forall x$) 的静态随机过程。

在设计空间不同位置处,这些随机变量存在

一定的相关性或协方差。该协方差可表达为

$$\text{Cov}[Z(x), Z(x')] = \sigma^2 R(x, x') \quad (3)$$

式中: $R(x, x')$ 为“相关函数”。

满足如下插值条件:

$$E \left[\sum_{i=1}^n \omega^{(i)} Y(x^{(i)}) \right] = E[Y(x)] \quad (4)$$

最优加权系数由式(5)给出,式(5)的矩阵形式为

$$\begin{bmatrix} R & F \\ F^T & 0 \end{bmatrix} \begin{bmatrix} \omega \\ \tilde{\mu} \end{bmatrix} = \begin{bmatrix} r \\ 1 \end{bmatrix} \quad (5)$$

$$F = [1 \ 1 \ \dots \ 1]^T \in \mathbb{R}^n$$

$$\tilde{\mu} = \mu / (2\sigma^2)$$

$$R = \begin{bmatrix} R(x^{(1)}, x^{(1)}) & \dots & R(x^{(1)}, x^{(n)}) \\ \vdots & & \vdots \\ R(x^{(n)}, x^{(1)}) & \dots & R(x^{(n)}, x^{(n)}) \end{bmatrix} \in \mathbb{R}^{n \times n} \quad (6)$$

$$r = \begin{bmatrix} R(x^{(1)}, x) \\ \vdots \\ R(x^{(n)}, x) \end{bmatrix} \in \mathbb{R}^n$$

式中: R 为“相关矩阵”; r 为“相关矢量”。

1.1.2 改善期望准则(EI)

改善期望准则由 Jones 等^[15]于 1998 年提出。EI 最优加点策略中,假设 $y(x)$ 是一个正态随即分布模型,即 $Y \sim N(\mu, s^2)$, 其中 μ 为预测均值, s^2 为标准差。于是得到 x 处的改善函数:

$$I(x) = \max(y(x)_{\min} - Y, 0) \quad (7)$$

函数概率为

$$P(I(x)) = \Phi \left(\frac{y(x)_{\min} - Y}{s(x)} \right) \quad (8)$$

进一步得到期望为

$$E[I(x)] = \begin{cases} (y(x)_{\min} - Y) \Phi \left(\frac{y(x)_{\min} - Y}{s(x)} \right) + \\ s(x) \phi \left(\frac{y(x)_{\min} - Y}{s(x)} \right), s(x) > 0 \\ 0, s(x) = 0 \end{cases} \quad (9)$$

式中: Φ 为标准正态分布函数; ϕ 为正态概率密度函数。

式(9)中,预测点值较小和模型预测精度较低,都会导致 EI 函数值变大,使得最佳改善点偏向

此处,因此 EGO 方法具备高效性。

1.1.3 经典 EGO 算法的基本流程

经典 EGO 算法基本流程如图 1 所示。

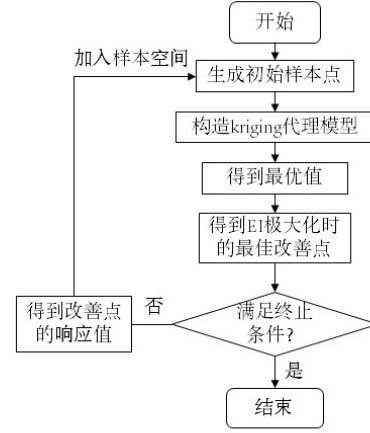


图 1 经典 EGO 算法流程图

Fig. 1 Flow chart of classic EGO algorithm

本文实验设计方法采用拉丁超立方(Latin hypercube sampling, 简称 LHS) 取样法^[16]。对于 EGO 算法中的子优化问题,本文则使用加强学习粒子群算法(Beneficial Information Reinforcement Learning Particle Swarm Optimization, 简称 BIRLPS)^[17]进行优化计算。

1.2 FFD 参数化方法

FFD 参数化方法由 Sederberg 和 Parry 于 1986 年提出^[18],其思想是仿照弹性体受外力后发生相应变形的物理现象,控制体的变形通过顶点的位移实现^[19]。FFD 参数化方法具有高度的灵活性和变形能力,不需要计算精度拟合,利用少量的设计参数就可以控制任意几何形状的变化。

FFD 参数化技术的控制示意图如图 2 所示,图中黑色圆点为相对应的控制点。




图 2 FFD 参数化方法控制示意图

Fig. 2 Control diagram of FFD parameterization method

本文对 M6 机翼整体施加了控制翼型剖面的 FFD 控制框,由于采用了基于 B 样条的 FFD 参数化方法,可能会导致算例的展向剖面几何外形和压力分布不够光滑。

1.3 流场计算

流场求解采用了基于有限体积法思想和多块结构网格求解非定常雷诺平均 N-S 方程的计算程序。

本文采用无限插值方法生成三维结构化网格,基于 CFL3D 软件进行气动特性计算,具有快速、高质量的特点,生成的 M6 机翼结构网格如图 3 所示。




图 3 三维 M6 机翼结构化网格


Fig. 3 Three-dimensional M6 wing structured grid

本文针对典型的 ONERA-M6 机翼标模进行气动算例验证,根弦长为 810.49 mm,展长为 1 196.30 mm,平均气动弦长为 646.07 mm。气动优化所采用网格应同时兼顾计算效率和计算准确性,为此,首先对 ONERA-M6 机翼标模开展了网格收敛性研究。计算采用 CFL3D 结构化网格求解器,计算状态为自由来流马赫数 $Ma = 0.8395$,迎角 $\alpha = 3.06^\circ$,雷诺数 $Re = 11.72 \times 10^6$ 。分别对应的网格量为 36 万、58 万、106 万和 209 万,其计算得到相关系数如表 1 所示,可以看出:58 万网格、106 万网格和 209 万网格得到的计算结果差别不大,36 万网格与其他网格得到的计算结果差别较为明显。综合考虑到后续优化设计,计算效率的侧重更大,因此使用 58 万网格量进行后续的优化。前述设计状态下 58 万网格量不同展向位置对应的压力分布情况与风洞试验结果的对比如图 4 所示,可以看出:二者展示的结果总体有较好的吻合,能够较为准确地捕捉激波的位置和强度,说明本文


使用的数值计算方法在求解三维飞行器气动特性时具有较高的精度,可以满足优化设计的需求。

表 1 ONERA-M6 机翼标模不同网格量参数计算结果
Table 1 Calculation results of different mesh parameters of ONERA-M6 wing standard modes


网格数量/万	C_L	C_D	C_M
36	0.28	0.021 41	0.009 60
58	0.28	0.018 99	0.010 20
106	0.28	0.018 67	0.009 96
209	0.28	0.018 64	0.009 87




(a) $\eta = 0.2$




(b) $\eta = 0.44$




(c) $\eta = 0.65$



(d) $\eta=0.8$



(e) $\eta=0.9$



(f) $\eta=0.95$

图4 ONERA-M6机翼标模不同展向位置对应的压力分布情况与风洞试验结果对比图

Fig. 4 Comparison between the pressure distribution of ONERA-M6 wing mold corresponding to different longitudinal positions and the wind tunnel test results

表2 EGO60维和EGO120维优化机翼参数比较

Table 2 Comparison of wing parameters of EGO60 and EGO120 dimensions optimization

参数	C_L	C_D	优平序号	E	厚度	t
初始	0.28	0.018 99	—	—	0.078 8,0.068 5,0.054 6,0.044 4	—
EGO60	0.28	0.015 58	79	0.000 80	0.080 6,0.068 7,0.053 3,0.045 0	25 h 13 min 20 s
EGO120	0.28	0.017 27	385	0.002 82	0.077 8,0.063 1,0.050 2,0.045 6	42 h 6 min 42 min

初始外形和两种不同维数设计变量使用 EGO 优化后的压力云图比较如图 5 所示,两种不同维数

1.4 EGO 方法优化算例

本文首先采用 EGO 方法开展了 M6 机翼气动优化设计研究,分别对 60 维设计变量和 120 维设计变量针对翼剖面进行了气动外形优化设计。其中,均采用 N-S 方程进行样本评估及定升减阻的优化设计,并加入了几何约束条件^[20]。设计状态均为:马赫数 0.839 5,迎角 3.06°,雷诺数 11.72×10^6 。设计空间范围为 ± 0.2 。机翼控制剖面均为 3 个,60 维设计变量中,每个剖面上有 20 个设计变量(上下各 10 个);120 维设计变量中,每个剖面上有 40 个设计变量(上下各 20 个)。其目标函数目标和约束条件的数学描述分别为:


$$\begin{aligned} \min C_D \\ C_L = 0.28 \\ t_{opt} \geq t_0 \end{aligned} \quad (10)$$

式中: C_D 为阻力系数; C_L 为升力系数; t_{opt} 为优化目标机翼厚度; t_0 为初始机翼厚度。


EGO 优化方法分别对 60 维和 120 维设计变量的 M6 机翼优化后的机翼和初始机翼的参数值如表 2 所示,其中,优平序号指的是优化第多少代得到最优解, E 指的是代理模型与真实值误差,也称代理模型精度,厚度指的是机翼厚度, t 指的是取样和优化所花费的时间,使用同一工作站相同核数进行优化,CPU 信息为 6248RX2,同时期只进行该优化。M6 机翼 60 维设计变量优化后,阻力系数从初始的 0.018 99 下降到 0.015 58,阻力下降了 17.9%,M6 机翼 120 维设计变量优化后,阻力系数从初始的 0.018 99 下降到 0.017 27,阻力下降了 9.1%;60 维设计变量使用 EGO 方法花费总的取样加优化时间为 25 时 13 分 20 秒,120 维设计变量使用 EGO 方法花费总的取样加优化时间为 42 时 6 分 42 秒。

设计变量使用 EGO 方法优化前后展向位置压力分布和几何外形比较如图 6 所示,可以看出:120 维设

计变量优化后的外形激波没有得到较好的消除，也就是说使用 EGO 优化方法进行气动外形优化设计时，设计变量维数对优化结果有相当大的影响，维数越高，优化搜索难度呈指数倍增长，优化结果也越差。




(a) 初始云图和 60 维 EGO 优化云图对比

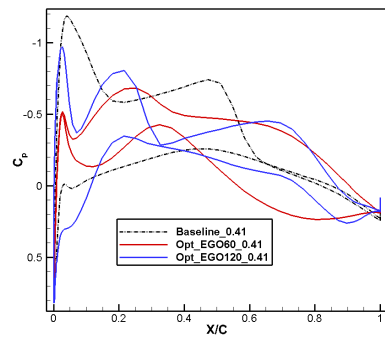


(b) 初始云图和 120 维 EGO 优化云图对比


图 5 优化机翼和初始外形压力云图对比
 Fig. 5 Comparison of pressure cloud image between optimized wing and initial profile




(b) $\eta=0.1$ 几何外形对比



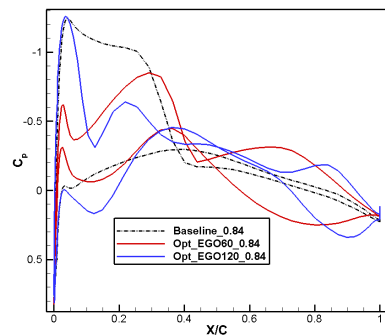
(c) $\eta=0.41$ 压力分布对比



(d) $\eta=0.41$ 几何外形对比



(a) $\eta=0.1$ 压力分布对比



(e) $\eta=0.84$ 压力分布对比


(f) $\eta=0.84$ 几何外形对比

图6 优化前后展向位置压力分布和几何外形比较
Fig. 6 Comparison of pressure distribution and geometry corresponding to different spanwise positions of optimized wings with initial conditions

两种优化算法代理模型精度对比如图7所示,图中红色曲线代表60维设计变量情况下使用EGO方法优化后的代理精度模型,蓝色曲线代表120维设计变量情况下使用EGO方法优化后的代理精度模型,可以看出:随着设计变量维数的增加,EGO方法代理模型的精度变得极差。也就是说,EGO方法在高维数设计变量问题种极易发生“维数灾难”现象,这也是本文聚焦的重点问题。




图7 代理模型精度对比

Fig. 7 Comparison of surrogate model accuracy

两种优化算法的阻力收敛曲线图如图8所示,可以看出:60维设计变量情况下EGO算法收敛得较快,而120维设计变量情况下EGO算法收敛得较慢,且得到的优化结果较之而言比较差。可以说明设计变量维数对EGO算法收敛速度也是有影响的,维数越高,收敛速度越慢,难以在一定时间内获得较好的解。




图8 阻力收敛曲线

Fig. 8 Resistance convergence curve

2 分区代理模型优化方法

本文根据物理机理和设计经验对设计变量进行空间分区分解,结合加强学习粒子群优化算法(BIRLPSO)和Kriging代理模型开展分区优化,和EGO优化算法得出的优化结果进行比较,验证分区代理模型优化的实用性和优越性;其次,对前述分区进行单独优化,测试出每个分解区域内的设计变量对目标函数的敏感性大小,再依此按照敏感性大小逐次分区优化,验证敏感性对分区优化存在一定程度上的影响。

2.1 序贯空间分区分解

为了解决维数灾难对优化造成的一系列问题,本文基于赵轲提出的分区代理模型优化方法发展了序贯分区代理模型优化方法。在构建代理模型前依据设计经验对设计变量以翼剖面为子单元进行分区分解,这样就将原始的高维设计变量问题化解成了低维优化问题,实现对设计空间维度的简约,从而提高代理模型精度及优化设计效率。物理知识驱动的基本依据是:根据机翼的流动机理,顺流流动是占据主导作用的流动,对模型的气动特性影响最大,即设计的核心是顺流向剖面的气动外形,也是影响模型气动特性的关键参数;对于展向,各剖面之间的影响属于次一级的影响参数;同时,组成翼剖面的设计变量之间相关度是最强的,可以将其归为一类设计变量。因此,本文按照顺流流动的展向方向,从翼根到翼尖为次序,将设计变量 $X=(x_1, x_2, \dots, x_n)^T$ 划分为 m 个子单元,将每一个单元作为一个分区,分别对每个

分区进行优化,在此过程中,在优化中将上一空间分区的最优解传递给下一分区,实现优中选优。翼剖面位置及分区情况如图9所示,在需要优化的翼剖面个数比较少的时候,可以每个翼剖面作为一个分区进行优化。基于空间分区的分区代理模型构建方法的基本流程如图10所示。

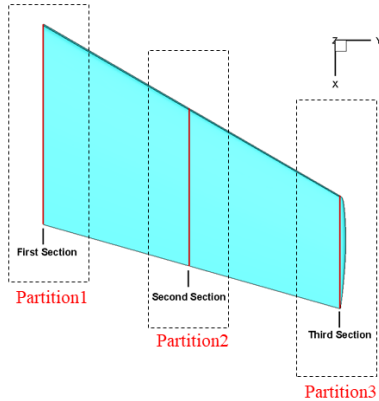


图9 M6机翼各设计控制剖面位置及分区情况
Fig. 9 Position and zoning of each design control section of M6 wing

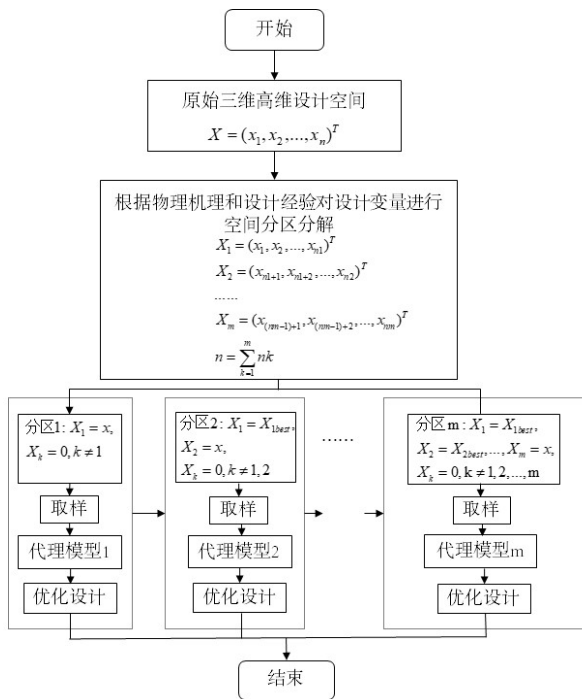


图10 序贯分区代理模型构建基本流程图
Fig. 10 Basic flow chart of sequential partition proxy model construction

2.2 基于设计变量敏感性的空间分区分解

序贯分区代理模型优化亦有其局限性,序贯分区方法高度依赖于设计者的工程经验,对于复

杂的设计问题,由于先验知识的缺乏,该方法缺乏适用性,严重影响优化设计效率和质量。因此,本文基于序贯分区分解,改进得到了基于设计变量敏感性的分区分解。即在根据物理特性和人工设计经验进行空间次序分区分解后,本文对前述中的以翼型剖面为子分区的区域单独进行优化,从优化结果得出不同分区区域设计变量对目标函数的敏感性,将敏感性作为分区次序对研究对象进行分区优化,得以验证敏感度对分区优化存在一定程度上的影响。考虑敏感性影响的分区优化流程图如图11所示。

基于设计变量敏感性的空间分区分解系统保留了序贯空间分区分解系统的优点,包括将多变量的复杂问题转化成了较为简单的若干子优化问题,进一步提高了优化效率;具有较高的代理模型精度,从而能更好的搜索到最优解,得到更好的优化设计结果等。但又不像传统序贯分区一样仅仅依据顺流方向的物理知识来判断分区后子优化问题优化先后顺序,它能够将设计变量对目标函数敏感性的高低作为依据来进行分区优化先后顺序的判断,这样就有了先验知识作为更加明确的凭据来进行气动优化设计,以此寻得最优解。

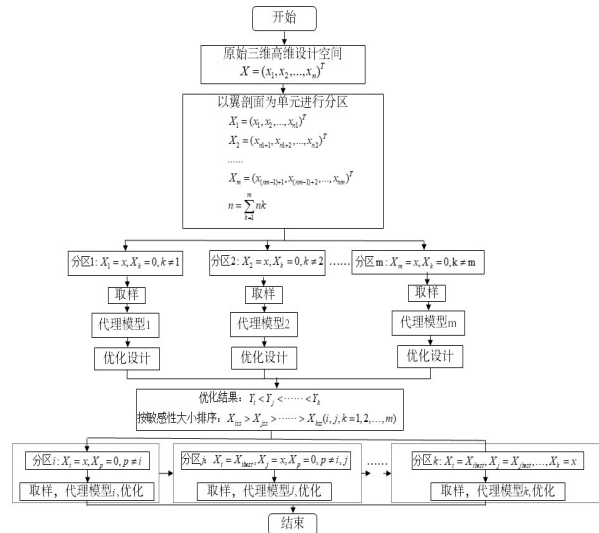


图11 考虑分区设计变量对目标函数敏感性影响的分区优化流程图
Fig. 11 Flowchart of partition optimization considering the influence of partition design variables on the sensitivity of the objective function

3 优化结果分析

3.1 序贯分区优化方法

为了验证序贯分区代理模型优化方法的可靠性,采用 1.4 节的算例进行优化设计,其中机翼控制剖面为 3 个,每个剖面上有 20 个设计变量(上下各 10 个),共 60 维设计变量。

分别使用 EGO 优化方法和序贯分区代理模型优化方法进行优化,表 3 给出了两种算法优化后的

机翼和初始机翼的参数值,表 4 给出了序贯分区优化方法的具体分区优化参数值,分区 1 至分区 3 分别是基于次序从翼根到翼尖剖面分区,EGO 优化中,阻力系数从初始的 0.018 99 下降到 0.015 58,阻力下降了 17.9%,序贯分区代理模型优化中,阻力系数从初始的 0.018 99 下降到 0.015 11,阻力下降了 20.4%;EGO 优化方法花费总的取样加优化时间为 25 时 13 分 20 秒,序贯分区优化方法花费总的取样加优化时间为 21 时 55 分 11 秒。


表 3 EGO 与序贯分区优化机翼参数比较
Table 3 Comparison of EGO and sequential partition optimized wing parameters

参数	C_L	C_D	优平序号	E	厚度	t
初始	0.28	0.018 99	—	—	0.078 8,0.068 5,0.054 6,0.044 4	—
EGO	0.28	0.015 58	79	0.000 80	0.080 6,0.068 7,0.053 3,0.045 0	25 h 13 min 20 s
PT	0.28	0.015 11	181	0.000 07	0.078 8,0.070 5,0.056 6,0.044 4	21 h 55 min 11 s


表 4 序贯分区优化具体分区参数比较
Table 4 Sequential partition optimization specific partition parameter comparison

参数	C_L	C_D	优平序号	E	厚度	t
分区 1	0.28	0.015 93	36	0.000 61	0.078 8,0.069 6,0.056 1,0.044 4	7 h 18 min 3 s
分区 2	0.28	0.015 69	180	0.000 05	0.078 8,0.071 2,0.057 6,0.044 5	7 h 18 min 2 s
分区 3	0.28	0.015 11	181	0.000 07	0.078 8,0.070 5,0.056 6,0.044 4	7 h 18 min 6 s

初始外形和两类优化后的压力云图比较如图 12 所示,两类优化方法优化前后展向位置压力分布和几何外形比较如图 13 所示,可以看出:序贯分区优化后外形的表面激波得到了更好的减弱。



(a) 初始云图和 EGO 优化云图对比



(b) 初始云图和序贯分区优化云图对比

图 12 优化机翼和初始外形压力云图对比
Fig. 12 Comparison of pressure cloud image between optimized wing and initial profile







(a) $\eta=0.1$ 压力分布对比(b) $\eta=0.1$ 几何外形对比(c) $\eta=0.41$ 压力分布对比(d) $\eta=0.41$ 几何外形对比(e) $\eta=0.84$ 压力分布对比(f) $\eta=0.84$ 几何外形对比

图 13 优化前后展向位置压力分布和几何外形比较
Fig. 13 The pressure distribution and geometry corresponding to different spanwise positions of the optimized wing are compared with the initial condition

两类优化方法代理模型精度对比如图 14 所示, 两类优化算法的阻力收敛曲线对比如图 15 所示, 可以看出: 序贯分区代理模型优化方法不仅在优化结果比 EGO 优化方法更好, 还具有较高的代理模型精度, 在降维上表现良好; 在优化效率上, 虽然 EGO 优化较快找到了设计空间范围内的最优解, 但是序贯分区优化也在 200 次以内找到了最优解, 同时还获得了更好的优化结果, 且优化所花费的时间也更短。

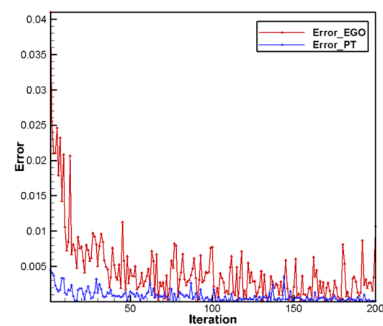




图 14 代理模型精度对比
Fig. 14 Comparison of surrogate model accuracy



(a) EGO 优化阻力收敛情况(400次)



(b) 序贯分区优化阻力收敛情况(200次)

图 15 阻力收敛曲线

Fig. 15 Resistance convergence curve

综上,序贯分区代理模型优化方法不仅能满足工程需求,还有较好的实用性。

3.2 基于设计变量敏感性的分区优化方法

在上述工作的基础上,以 M6 机翼为研究对象,依然以从翼根到翼尖共三个控制剖面将机翼划分为三个子空间单元,每个剖面 20 个设计变量,共 60 个设计变量。仅单独对每个子空间单元(剖面)进行优化,并将优化结果进行分析比较,得出每个子空间分区的设计变量对目标函数的敏感性大小,并以此为基础,进行按照敏感性大小的分区代理模型优化设计。

3.2.1 基于敏感性的分析

以 M6 机翼为原始机翼,进行了定升减阻的优化设计。设计状态和设计模型同 1.4 节所述,采用的机翼控制剖面为 3 个,60 维设计变量中,每个剖面上有 20 个设计变量(上下各 10 个)。

将从翼根到翼尖为顺序的三个剖面依次命名为第一、第二、第三剖面,按照剖面划分的子空间单元命名为分区 1、分区 2 和分区 3。单独分区优化时每个区域的优化仅使用了该分区的 20 个设计变量。表 5 给出了单独沿剖面分区优化的每个分区的具体优化参数值,分区单独优化第一剖面中,阻力系数从初始的 0.018 99 下降到 0.015 93,阻力下降了 16.1%,分区单独优化第二剖面中,阻力系数从初始的 0.018 99 下降到 0.015 83,阻力下降了 16.6%,分区单独优化第三剖面中,阻力系数从初始的 0.018 99 下降到 0.016 02,阻力下降了 15.6%。


表 5 单独沿剖面分区优化每个分区的具体优化参数比较

Table 5 Comparison of specific optimization parameters for each section optimized separately along the profile


参数	C_L	C_D	优平序号	E	厚度	t
初始	0.28	0.018 99	—	—	0.078 8,0.068 5,0.054 6,0.044 4	—
分区 1	0.28	0.015 93	36	0.000 61	0.078 8,0.069 6,0.056 1,0.044 4	7 h 18 min 29 s
分区 2	0.28	0.015 83	193	0.000 25	0.078 9,0.070 3,0.056 4,0.044 4	7 h 19 min
分区 3	0.28	0.016 02	177	0.000 54	0.078 8,0.069 0,0.054 8,0.044 5	7 h 18 min 6 s

单独沿剖面分区优化的每个分区的优化结果压力云图如图 16 所示,可以看出:优化结果最好的时分区单独优化第二剖面,次之是第一剖面,最后是第三剖面,也就是说,按照不同分区设计变量对目标函数的敏感性进行排序,应该是第二剖面分区、第一剖面分区、第三剖面分区,接下来,本文将


按照这一顺序,对 M6 机翼进行根据不同分区设计变量敏感性进行分区的分区代理模型优化设计。



(a) 初始云图和单独分区1优化云图对比



(b) 初始云图和单独分区2优化云图对比



(c) 初始云图和单独分区3优化云图对比

图 16 单独沿剖面分区优化结果压力云图对比
Fig. 16 Comparison of pressure nephogram of optimized results along individual sections

3.2.2 基于敏感性分析的优化

依然以 M6 机翼为原始机翼,进行定升减阻的优化设计。设计状态和设计模型同 1.4 节所述,采用的机翼控制剖面为 3 个,120 维设计变量中,每个剖面上有 40 个设计变量(上下各 20 个)。

分别使用序贯分区代理模型优化方法和按不同分区设计变量对目标敏感性分区代理模型优化方法进行优化,两种方法优化后的机翼和初始机翼的参数值如表 6 所示,按不同分区设计变量对目标敏感性大小分区优化方法的具体分区优化参数值如表 7 所示,分区 1 至分区 3 分别是基于次序从翼根到翼尖剖面分区,优化次序参考前述工作中不同分区设计变量对目标函数敏感性从大到小,具体次序为分区 2 至分区 1 至分区 3。EGO 优化中,阻力系数从初始的 0.018 99 下降到 0.017 27,阻力下降了 9.1%,序贯分区优化中,阻力系数从初始的 0.018 99 下降到 0.015 78,阻力下降了 16.9%,基于敏感性分区优化中,阻力系数从初始的 0.018 99 下降到 0.015 59,阻力下降了 17.9%。初始外形和三类优化后的压力云图比较如图 17 所示,三类优化方法优化前后展向位置压力分布和几何外形比较如图 18 所示,各方法优化后的翼型剖面上表面趋于平坦,使得压力恢复更加和缓,且翼型剖面超临界特征明显,有利于激波的减弱,其中,基于敏感性分区优化后外形的表面激波得到了更好的削弱。三类优化方法代理模型精度对比如图 19 所示,可以看出:基于敏感性分区优化方法能够得到比序贯分区方法和 EGO 方法更好的优化结果,同时也能保持较好的代理模型精度,也就是说,不同分区的设计变量对目标函数的敏感性大小对优化结果是有一定影响的,与按照物理特性逐次分区相比,先优化敏感度大的区域,一定程度上可以得到更好的优化结果。


表 6 序贯分区优化和按敏感性大小分区优化机翼参数比较(120 维)

Table 6 Comparison of sequential partition optimization and partition optimization of wing parameters according to sensitivity size (120 d)


参数	C_L	C_D	优平序号	E	厚度	t
初始	0.28	0.018 99	—	—	0.078 8,0.068 5,0.054 6,0.044 4	\\
EGO	0.28	0.017 27	385	0.00282	0.077 8,0.063 1,0.050 2,0.045 6	42 h 6 min 42 s
PT	0.28	0.015 78	60	0.00020	0.082 1,0.074 1,0.056 8,0.043 6	19 h 39 min 15 s
SSPT	0.28	0.015 59	179	0.00022	0.085 2,0.077 7,0.059 7,0.045 8	19 h 39 min 21 s

表7 按敏感性大小分区优化具体分区参数比较
Table 7 Comparison of specific partition parameters optimized by sensitivity size partition


参数	C_L	C_D	优平序号	E	厚度	t
分区 2	0.28	0.015 78	90	0.000 12	0.078 8, 0.069 7, 0.056 0, 0.044 4	6 h 33 min 5 s
分区 1	0.28	0.015 87	166	0.000 78	0.085 2, 0.078 4, 0.058 8, 0.044 4	6 h 33 min 2 s
分区 3	0.28	0.015 59	179	0.000 22	0.085 2, 0.077 7, 0.059 7, 0.045 8	6 h 33 min 8 s




(a) 初始云图和 EGO 优化云图对比




(b) 初始云图和序贯分区优化云图对比




(c) 初始云图和基于敏感性分区优化云图对比



(a) $\eta=0.1$ 压力分布对比



(b) $\eta=0.1$ 几何外形对比



(c) $\eta=0.41$ 压力分布对比

图 17 优化机翼和初始外形压力云图对比
Fig. 17 Pressure cloud image comparison between optimized wing and initial profile




(d) $\eta=0.41$ 几何外形对比(e) $\eta=0.84$ 压力分布对比(f) $\eta=0.84$ 几何外形对比

图 18 优化前后展向位置压力分布和几何外形比较
Fig. 18 The pressure distribution and geometry corresponding to different spanwise positions of the optimized wing are compared with the initial condition

三类优化方法的阻力收敛曲线图如图 20 所示,在优化效率上,序贯分区优化和基于敏感性分区优化都能在每轮(共三轮)200 次加点内找到最优解,而本文也对三类优化总的花费时间进行统计,部分花费时长的数值如表 6~表 7 所示,使用同一工作站相同核数进行优化, CPU 信息为 6248RX2,同时期只进行该优化,具体花费时间为: EGO 优化(120 维)取样 400 轮花费 7 h 46 min 24

s,优化(加点)400 轮花费 34 h 20 min 18 s,共花费 42 h 6 min 42 s;序贯分区优化(分 3 区,每区 40 维)每轮取样 100 轮花费 1 h 54 min 59 s,优化(加点)200 轮花费 4 h 38 min 6 s,共花费 6 h 33 min 5 s,分了三轮,一共花费 19 h 39 min 15 s;基于敏感性分区优化花费的时长同序贯分区优化。EGO 优化调用 CFD 计算 800 次,序贯分区优化和基于敏感性分区优化均调用 CFD 计算 900 次,但是 EGO 优化每次气动计算时长加上构建代理模型所需的时间大约需要 4 min 50 s,而分区优化大约需要 1 min 17 s,因此,虽然分区优化调用的 CFD 计算次数更多,但是总时长小于 EGO 优化,也就是说,在优化效率上,分区优化依然占有相当的优势,且与 60 维 M6 优化相比较之下,其维数越高,分区优化的优势更显著。而基于敏感性分区优化不仅继承了序贯分区优化的优势,又能取得更好的优化结果,是一种具有工程适用性和高效性的优化方法。






图 19 代理模型精度对比


Fig. 19 Comparison of surrogate model accuracy



(a) EGO 优化阻力收敛情况(400 次)



(b) 序贯分区优化阻力收敛情况(200次)



(c) 基于敏感性分区优化阻力收敛情况(200次)

图 20 阻力收敛曲线

Fig. 20 Resistance convergence curve

4 结 论

1) 与传统 EGO 方法相比,分区代理模型优化方法将设计空间维数降低,从而保持相对较高的代理模型精度,大幅提高优化设计效率,并得到更好的结果,此外,由于设计变量的减少,单次训练代理模型的效率大幅提升。

2) 在分区代理模型方法中,分区的优化顺序是影响优化结果的重要因素,传统序贯分区代理模型方法过于单一,对于复杂问题缺乏适用性。因此,本文改进得到了基于敏感性分析的分区代理模型方法,该方法基于分区变量敏感性的自动调整设计空间子单元的优化顺序,将其与传统序贯分区优化结果进行对比,结果表明,基于敏感性分析的分区方法能够明显提高优化设计效率和设计质量。

3) 通过 120 维的跨声速 M6 机翼设计算例,证实了基于敏感性分析的分区方法能够提升代理模

型精度,高效地搜索到理想的设计结果,一定程度上具备解决高维气动优化设计问题的能力,也为高维优化设计问题提供了解决思路。

综上,基于物理知识驱动的敏感性分区代理模型优化方法有效提高了代理模型在高维设计空间的精度和优化搜索效率,有效缓解了维数灾难问题,为高维变量气动设计问题提供了新的解决思路。

参 考 文 献

- [1] 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): 3197-225.
- HAN Zhonghua. Research progress of kriging model and agent optimization algorithm[J]. Acta Aeronautica et Astronautica Sinica, 2016, 37(11): 3197-225. (in Chinese)
- [2] 邓枫. EGO 全局优化算法及应用研究[D]. 南京: 南京航空航天大学, 2011.
- DENG Feng. Research on EGO global optimization algorithm and its application[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2011. (in Chinese)
- [3] LEDOUX S T, VASSBERG J C, YOUNG D P, et al. Study based on the AIAA aerodynamic design optimization discussion group test cases[J]. AIAA Journal. 2015, 53(7): 1910-1935.
- [4] LYU Z, KENWAY G K W, MARTINS J R R A. Aerodynamic shape optimization investigations of the common research model wing benchmark[J]. AIAA Journal. 2015, 53(4): 968-985.
- [5] KENWAY G K W, MARTINS J R R A. Multipoint aerodynamic shape optimization investigations of the common research model wing[J]. AIAA Journal. 2016, 54(1): 113-128.
- [6] JURECKA F. Robust design optimization based on metamodeling techniques[M]. Aachen: Shaker, 2007.
- [7] PRESS W H, TEUKOLSKY S A, VETTERLING W T, et al. Numerical recipes in Fortran 77[M]. 2nd ed. New York, USA: Press Syndicate of the University of Cambridge, 1997.
- [8] 徐圣冠. 面向高维优化问题的 Nash-EGO 算法及其气动应用研究[D]. 南京: 南京: 南京航空航天大学, 2018.
- XU Shengguan. Research on Nash-EGO algorithm for high-dimensional optimization problems and its aerodynamic application[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2018. (in Chinese)
- [9] CHEN L, DING Z, LI S. Tree-based dependency analysis in decomposition and re-decomposition of complex design

- problems[J]. *Journal of Mechanical Design*, 2005, 127(1): 12-23.
- [10] 马创, 黄江涛, 舒博文, 等. 超声速低声爆布局分层优化方法[J]. *航空工程进展*, 2023, 14(2): 35-43.
MA Chuang, HUANG Jiangtao, SHU Bowen et al. Supersonic low detonation hierarchical layout optimization method [J]. *Aviation engineering progress*, 2023, 14(2): 35-43. (in Chinese)
- [11] 赵轲. 基于 CFD 的复杂气动优化与稳健设计方法研究 [D]. 西安: 西北工业大学, 2015.
ZHAO Ke. Research on complex aerodynamic optimization and robust design method based on CFD [D]. Xi'an: Northwestern Polytechnical University, 2015. (in Chinese)
- [12] MENG J, HU J, XIAO H, et al. Hierarchical optimization of the composite blade of a stratospheric airship propeller based on genetic algorithm [J]. *Structural and Multidisciplinary Optimization*, 2017, 56(6): 75-88.
- [13] KRIGE D G. A statistical approach to some basic mine valuation problems on the Witwatersrand [J]. *Journal of the Southern African Institute of Mining and Metallurgy*. 1951, 52(6): 119-139.
- [14] MATHERON G M. Principles of geostatistics [J]. *Economic Geology*. 1963, 58(8): 1246-1266.
- [15] JONES D R, SCHONLAU M, WELCH W J. Efficient global optimization of expensive black-box functions [J]. *Journal of Global Optimization*. 1998, 13(4): 455-492.
- [16] YE K Q, LI W, SUDJANTO A. Algorithmic construction of optimal symmetric Latin hypercube designs [J]. *Journal of Statistical Planning and Inference*, 2000, 90(1): 145-159.
- [17] 高崇. 改进粒子群算法及其在翼型优化设计中的应用 [D]. 西安: 西北工业大学, 2017.
GAO Chong. Improved particle swarm optimization algorithm and its application in airfoil optimization design [D]. Xi'an: Northwestern Polytechnical University, 2017. (in Chinese)
- [18] SEDERBERG T, PARRY S. Free-form deformation of solid geometric models [C] // *The 13th Annual Conference on Computer Graphics and Interactive Techniques*. US: AIAA, 1986: 151-160.
- [19] 周伟. 基于 FFD 技术的飞翼布局无人机翼型优化研究 [J]. *计算机仿真*, 2022, 39(9): 74-78.
ZHOU Wei. Research on unmanned airfoil optimization of flying wing layout based on FFD technology [J]. *Computer Simulation*, 2022, 39(9): 74-78. (in Chinese)
- [20] 熊俊涛, 乔志德, 韩忠华. 基于 Navier-Stokes 方程跨声速翼型和机翼气动优化设计 [J]. *空气动力学学报*, 2007(1): 29-33, 44.
XIONG Juntao, QIAO Zhide, HAN Zhonghua. Aerodynamic optimization of transonic airfoil and wing based on Navier-Stokes equation [J]. *Journal of Aerodynamics*, 2007 (1): 29-33, 44. (in Chinese)

(编辑: 丛艳娟)