

文章编号: 1000-8055(2023)07-1604-11

doi: 10.13224/j.cnki.jasp.20220740

基于 POD-PCE-Kriging 模型的航空发动机 高维多目标优化

马 跃^{1,2}, 郭明明^{1,2}, 孙博伦³, 田 野^{1,2}, 宋文艳³, 乐嘉陵^{1,2}

- (1. 西南科技大学 信息工程学院, 四川 绵阳 621010;
2. 中国空气动力研究与发展中心 高超声速冲压发动机技术重点实验室, 四川 绵阳 621000;
3. 西北工业大学 动力与能源学院, 西安 710129)

摘 要: 针对于传统的航空发动机燃烧室设计过程计算周期长, 加工和试验成本高, 制约发动机设计周期的问题, 基于航空发动机燃烧室模型, 结合 POD-PCE-Kriging(本征正交分解-多项式混沌展开-Kriging)模型和粒子群优化(PSO)算法开展了燃烧性能代理模型的构建和多目标优化设计。通过试验, 应用 POD-PCE-Kriging 模型预测结果与一维程序计算结果进行对比分析, 针对于燃烧效率和总压损失预测值的方均根误差分别为 0.006 3% 和 0.122 7%。对设计变量参数开展寻优, 并对获取的 Pareto 最优解集进行了分析, 为满足性能指标的先进航空发动机燃烧室设计提供了物理见解, 可以快速准确获得满足最优性能的设计参数, 缩短航空发动机的研制周期。

关 键 词: 航空发动机燃烧室设计; 代理模型; POD-PCE-Kriging 模型; 粒子群优化算法; 多目标优化

中图分类号: V231

文献标志码: A

High-dimensional multi-objective optimization of aero-engine based on POD-PCE-Kriging model

MA Yue^{1,2}, GUO Mingming^{1,2}, SUN Bolun³, TIAN Ye^{1,2},
SONG Wenyan³, LE Jialing^{1,2}

- (1. School of Information Engineering,
Southwest University of Science and Technology, Mianyang Sichuan 621010, China;
2. Science and Technology on Scramjet Laboratory,
China Aerodynamics Research and Development Center, Mianyang Sichuan 621000, China;
3. School of Power and Energy, Northwestern Polytechnical University, Xi'an 710129, China)

Abstract: In view of the traditional aero-engine combustor design process with long calculation cycle, high processing test and cost which restricts the engine design cycle, based on the aero-engine combustor model, POD-PCE-Kriging (proper orthogonal decomposition-polynomial chaotic expansion-Kriging) model and particle swarm optimization (PSO) algorithms were combined to construct the combustion performance surrogate model and carry out multi-objective optimization design. Through the test, the predicted results of POD-PCE-Kriging model were compared with the calculated results of one-dimensional program, and the root mean square errors of the predicted values of combustion efficiency and

收稿日期: 2022-09-29

基金项目: 四川省科技计划项目(2023YFG0336)

作者简介: 马跃(1999—), 男, 博士生, 研究方向为航空发动机优化设计与智能调控。

通信作者: 田野(1987—), 男, 副研究员, 博士, 研究方向为超燃冲压发动机燃烧组织技术。E-mail: tianye@cardc.cn

引用格式: 马跃, 郭明明, 孙博伦, 等. 基于 POD-PCE-Kriging 模型的航空发动机高维多目标优化[J]. 航空动力学报, 2023, 38(7): 1604-1614.

MA Yue, GUO Mingming, SUN Bolun, et al. High-dimensional multi-objective optimization of aero-engine based on POD-PCE-Kriging model[J]. Journal of Aerospace Power, 2023, 38(7): 1604-1614.

total pressure loss were 0.006 3% and 0.122 7%, respectively. Optimization search was carried out for the design variables, and the obtained Pareto optimal solution set was analyzed to provide physical insight into the design of advanced aero-engine combustor to meet the performance specifications, which can quickly and accurately obtain the design parameters to meet the optimal performance and accelerate the development cycle of aero-engine.

Keywords: aero-engine combustor design; surrogate model; POD-PCE-Kriging model; particle swarm optimization algorithm; multi-objective optimization

随着航空发动机技术的发展与创新,缩短发动机的设计周期和计算时长已成为目前研究的重要组成部分。发动机燃烧室作为航空发动机的三大核心部件之一,对设计研制周期和设计效果的要求则更高。而在目前的燃烧室设计中,基本都是依靠 CFD 数值模拟或者风洞试验,依据已有的数理模型公式进行计算和评估。模型和方法的高复杂度导致了计算周期过长,具有较大的计算成本。近年来,降低计算成本,提高优化效率,使用代理模型近似目标量已经被国内外学者广泛研究。主要是采取数据驱动的建模方法,根据选取的设计变量和与之对应的数值计算或真实试验结果所构成的样本数据库,进行拟合、回归、特征学习等。构建可以高度近似真实数理模型的代理模型,给定输入参数可以快速准确得到相应输出参数,以此来替代设计过程中复杂且耗时的计算和分析。在当前研究中常用的代理模型主要包括多项式响应面、移动最小二乘、径向基函数、人工神经网络、支持向量机、Kriging(高斯回归过程)等。

2015 年, Ogawa^[1] 结合计算流体力学和进化算法,在多项式、Kriging 等多种代理建模的辅助下,对来流马赫数为 7.6 下,超声速燃烧冲压发动机进气道初始压缩后,马赫数为 5.7 的横流燃油喷射进行了多目标优化,相关研究加速了超燃冲压发动机设计。2019 年, Taghavi 等人^[2] 使用了非线性自回归网络、多层感知器和径向基函数 3 种机器学习方法,建立了多输入单输出代理模型来预测发动机运行时的燃烧状态。2019 年, Tejero 等学者^[3] 结合代理建模和数值模拟,针对航空发动机短舱设计开发了一个新的框架。与传统方法相比,该算法成功地识别了最优机舱设计,计算成本与原来相比降低了 25%。2020 年, Du 等人^[4] 应用分层 Kriging 优化了火箭发动机的结构动力学,构建了发动机结构参数设计变量与模态频率特性之间的关系,并用于辅助发动机优化设计,取得了较高精度。2021 年, Poggi 等学者^[5] 开发了适用于模拟空气动力学性能和辐射噪声的

代理模型,数值研究表明,代理模型能够准确重现螺旋桨的空气动力学性能和辐射噪声。2021 年, Song 等人^[6] 提出了分解协同时变 Kriging 代理模型(DCTKS)。通过对多种代理模型构建方法的比较,证明了所提出的 DCTKS 在概率蠕变疲劳寿命评估的效率和准确性方面具有计算优势,提高了建模精度和仿真效率。2021 年, Tejero 等学者^[7] 基于代理模型方法对非轴对称航空发动机短舱进行设计和研究。为了减少计算费用,研究了一系列基于代理的适应方法。相对于优化循环中全数值模拟的传统方法,适应方法确定了可接受的设计空间,总计算成本降低了 65%。

从上述研究现状分析,应用代理模型辅助发动机的优化设计取得了较好的发展。但航空发动机燃烧室存在工况变化大、非线性特征显著、工作环境恶劣等特点,传统的设计方法计算量较大,设计周期较长,不能满足性能参数实时预测,因此应用代理模型辅助航空发动机燃烧室设计具有较好的优势。

本文以航空发动机燃烧室为研究对象,选取来流参数、主要几何参数及油气分布可控参数等多维设计变量,使用拉丁超立方抽样方法,完成输入参数空间的样本抽取。数据预处理后,应用西北工业大学自主设计的一维数值计算程序计算燃烧效率及总压损失等燃烧性能参数,完成数据样本集构建。其次,基于 POD-PCE-Kriging(本征正交分解-多项式混沌展开-Kriging)方法,在输入和输出参数之间建立代理模型,快速准确地对给定设计参数下的燃烧性能参数进行预测,替代传统的 CFD 数值模拟计算燃烧性能的方法。在此基础上,应用多目标 PSO(粒子群优化)方法,在满足燃烧效率不小于 99% 及总压损失不大于 4% 的指标下,进一步开展设计变量的参数寻优研究,获取 Pareto 最优解集进行分析,指导燃烧室的优化设计,加速航空发动机的研制进展。以解决现有燃烧室设计方法计算复杂耗时、设计周期长、设计成本大等问题。

1 燃烧室模型及数据获取

1.1 高性能一维设计方法的可靠性验证

为快速完成燃烧室相关参数计算,西北工业大学与俄罗斯喀山航空大学联合开展了航空发动机燃烧室一维计算方法的研究,联合开发了一套航空发动机燃烧室模型的一维计算程序。并以双旋流燃烧室为对象,通过试验结果与三维数值计算结果进行对比验证一维数值计算的可靠性。之后采用两种不同的一维计算模型(Case1、Case2),将一维计算结果和经可靠性验证的三维数值计算结果对比,进而验证一维计算方法的结果一致性。

在燃烧室三维计算与试验的对比中,图 1 为三维速度场计算结果与粒子图像测速仪(PIV)试验测量结果对比云图,图中 $V_x/V_{\max}$ 为速度场中 X 向速度与最大速度的比值。通过与 PIV 测量结果对比,可看出三维数值模拟云图与试验测量结果速度场分布趋势基本一致。




图 1 双旋流燃烧室主燃孔中心截面轴向速度分布数值模拟与试验结果对比

Fig. 1 Comparison between numerical simulation and test results of axial velocity distribution on the center section of the main combustion hole in a twin-swirl combustor

之后结合一维设计程序,分别采用一维计算方法 Case1、Case2 和 CFD 三维计算,得到了针对沿轴向(X)流量分配的对比,如图 2 所示。可以看出,在三维计算中主燃孔处的进气量略小于一维计算结果。




图 2 双旋流燃烧室沿轴向流量分配对比
Fig. 2 Comparison of axial flow distribution in twin-swirl combustor

表 1 为两种一维计算方法与三维计算得到的燃烧室出口燃气总温。Case1 计算结果与三维出口总温值基本相同。

表 1 双旋流燃烧室出口总温计算结果对比
Table 1 Comparison of the calculated results of total temperature at the outlet of the twin-swirl combustor

计算方法	燃烧室出口总温/K
一维计算(Case1)	1 721.3
一维计算(Case2)	1 773.4
CFD 三维计算	1 720.9

表 2 为一维计算方法 Case1、Case2 与 CFD 三维计算所得的性能参数对比。其中在三维计算结果中,燃烧效率略低于一维计算结果。Case1 计算所得的总压恢复系数接近三维计算结果。

表 2 双旋流燃烧室性能参数对比
Table 2 Comparison of performance parameters of twin-swirl combustor

性能参数	一维计算 (Case1)	一维计算 (Case2)	CFD 三维计算
燃烧效率	0.999 4	0.999 4	0.997 4
总压恢复系数	0.960 1	0.956 5	0.960 4

综合上述列举的燃烧室流动参数及燃烧性能参数对比分析可知,所采用的一维计算方法与三维计算具有较好的一致性。证明了一维计算方法

能较好地计算燃烧室内的性能参数, 计算结果准确度较高, 具有一定的可行性。更详细的方法描述可参考文献 [8]。

1.2 航空发动机高性能燃烧室设计

本论文的研究对象为某型同心分级燃烧室。该燃烧室所满足的设计条件见表 3, 其结构示意图如图 3 所示。根据设计要求计算燃烧室的总体结构参数和流量分布, 并在此基础上开展燃烧室各部件的设计和计算工作。最后, 得到燃烧室的初步设计方案, 经过数值模拟及试验验证, 已经验证了这个结构能够满足一定的性能指标要求, 更详细的设计参数可参考文献 [9]。

表 3 燃烧室设计要求

Table 3 Combustor design requirements

参数	设计状态	慢车状态
进口总温/K	850	492.9
油气比	0.043 0	0.010 6
燃烧效率	>0.99	>0.98
总压损失	<0.06	<0.07
出口温度分布系数(OTDF)	<0.20	
出口径向温度分布系数(RTDF)	<0.12	




图 3 燃烧室结构示意图

Fig. 3 Schematic diagram of the structure of the combustor

在同心分级燃烧室模型的基础上, 根据自主设计的航空发动机燃烧室模型的一维程序计算结果开展代理模型构建。选取目标参数为燃烧效率 η 和总压损失 Δp , 选取设计参数为进口总温 T_1 、进口总压 p_1 、进口流量 $\dot{m}_1$ 、油气比 φ 、主燃孔数量 (单头部单壁面) N_m 、主燃孔直径 D_m 、每排冷却孔数量 N_c 以及冷却孔直径 D_c 共 8 个参数, 设计变量的详细说明如表 4 所示。

燃烧室的代理模型设计算法流程主要有以下几部分, 首先在 8 变量空间进行拉丁超立方抽样, 得到输入参数的样本数据。之后使用自主设计的航空发动机燃烧室模型一维程序进行计算, 得到样本参数对应的燃烧效率和总压损失, 数据预处理之后构建完成样本数据集。之后基于 POD-

表 4 设计变量

Table 4 Design variable

设计变量	数值范围
进口总温 T_1 /K	427.55~1 070.33
进口总压 p_1 /kPa	500~3 200
进口流量 $\dot{m}_1$ /(kg/s)	19.01~82.398
油气比 φ	0.010 6~0.043 0
主燃孔数量 N_m /个	2~4
主燃孔直径 D_m /mm	12.1~16.8
每排冷却孔数量 N_c /个	10~20
冷却孔直径 D_c /mm	0.5~1.5

PCE-Kriging 模型的方法建立 8 个输入参数(设计参数)和 2 个输出参数(目标参数)之间的映射关系以替代变量之间的复杂模型, 即完成针对于航空发动机燃烧室的代理模型的构建。最后基于 PSO 算法, 结合代理模型完成设计参数寻优, 得到最优构型。

2 方 法

2.1 POD-PCE-Kriging 燃烧性能代理模型设计

POD-PCE-Kriging 算法模型主要基于 Kriging 模型。Kriging 模型将未知函数看成是某个静态随机过程的具体实现, 包含了回归部分和相关部分, 其中的相关部分可以被视作随机高斯过程的实现, 并且对非线性程度较高的问题具有良好的拟合效果。Kriging 模型以已知点处样本信息的动态构造为基础, 同时拥有全局和局部的统计特征。采用 POD 算法 [10-12] 对原始样本进行降维和重构, 减小样本计算损耗, 提取核心信息, 滤去边缘信息, 将经过 POD 算法处理过后的数据作为 PCE-Kriging 模型的样本输入。PCE-Kriging 模型 [13-14] 主要使用 PCE 模型 [15] 替代原本 Kriging 模型中常用的回归部分, 使得在回归部分精度提高的同时, 大大减少了估计参数的数量。上述整体构成 POD-PCE-Kriging 算法模型。

为方便模型描述, 设自变量参数为进口总温 x_1 、进口总压 x_2 、进口流量 x_3 、油气比 x_4 、主燃孔数量 x_5 、主燃孔直径 x_6 、每排冷却孔数量 x_7 以及冷却孔直径 x_8 , 因变量参数为燃烧效率 η 和总压损失 Δp 。则输入样本数据集为 $X = [x^1, x^2, x^3, \dots, x^m]^T$, m 为样本数, 其中每个输入样本参数 $x^i = [x_1^i, x_2^i, x_3^i, \dots, x_8^i]$, n 为维度数。则输出样本参数为 $Y = [y^1, y^2, y^3, \dots, y^m]^T$, 针对于本研究则可为燃烧效率 $\eta = [\eta^1, \eta^2, \eta^3, \dots, \eta^m]^T$ 和总压损失 $\Delta p = [\Delta p^1,$

$\Delta p^2, \Delta p^3, \dots, \Delta p^m]^T$ 。

POD方法的核心是寻找 n 维场量空间 $\{\mathbf{x}_n \in \Omega\}$ 的一组“最优”正交基 $\{\mathbf{U}_1, \mathbf{U}_2, \mathbf{U}_3, \dots, \mathbf{U}_n\}$ 。假设 $\mathbf{x}_n$ 可由若干正交基近似, 则 $\mathbf{x}_n$ 可用这组“最优”正交基 $\{\mathbf{U}_1, \mathbf{U}_2, \mathbf{U}_3, \dots, \mathbf{U}_n\}$ 近似表示:

$$\mathbf{x}_n = \sum_{i=1}^n (\alpha_i \mathbf{U}_i) \quad (1)$$

式中 $\mathbf{U}_i$ 为 $\mathbf{x}_n$ 的特征向量或基向量; α_i 为 $\mathbf{U}_i$ 的相关系数。若“最优”正交基所组成的正交空间的维度小于原始空间, 则上述近似过程可描述为对样本空间进行降维, 之后再对样本进行近似重构, 则

$$\mathbf{x}_n = \sum_{i=1}^r (\alpha_i \mathbf{U}_i) \quad (r < n) \quad (2)$$

其中 r 为降维后的维度数。之后进行样本数据的中心化处理。则得到新的中心化样本数据集:

$$\tilde{\mathbf{X}} = \{\tilde{\mathbf{x}}_1, \tilde{\mathbf{x}}_2, \tilde{\mathbf{x}}_3, \dots, \tilde{\mathbf{x}}_n\} = \{\mathbf{x}_1 - \bar{\mathbf{x}}_1, \mathbf{x}_2 - \bar{\mathbf{x}}_2, \mathbf{x}_3 - \bar{\mathbf{x}}_3, \dots, \mathbf{x}_n - \bar{\mathbf{x}}_n\} \quad (3)$$

其中 $\tilde{\mathbf{X}}$ 为中心化样本数据集, $\tilde{\mathbf{x}}_n$ 为针对于任一维度的中心化样本, $\bar{\mathbf{x}}_n$ 为任一维度的样本均值, 之后进行奇异值分解(SVD):

$$\tilde{\mathbf{X}} = \mathbf{U} \mathbf{\Lambda} \mathbf{V}^T \quad (4)$$

其中 $\mathbf{\Lambda} = \{\lambda_1, \lambda_2, \dots, \lambda_n\}$, 为协方差矩阵由大至小排列的特征值组成的向量。对于 r 的取值, r 应当小于 n , 减小特征向量空间的规模, 但应尽可能更精确地逼近原数据空间。 r 的选取可用以下方式确定:

$$I = \sum_{i=1}^r \lambda_i^2 / \sum_{i=1}^n \lambda_i^2 \quad (5)$$

其中 λ 为 $\tilde{\mathbf{X}}$ 协方差矩阵由大至小排列的特征值向量, 满足 $\lambda_1 > \lambda_2 > \dots > \lambda_n$ 。则最终的 POD 模型为

$$\mathbf{X}_{re} = \bar{\mathbf{X}} + \sum_{i=1}^r (\alpha_i \mathbf{U}_i) \quad (6)$$

Kriging 模型引入统计学假设: 将未知函数看成是某个静态随机过程的具体实现。

$$\hat{\mathbf{y}}(\mathbf{X}) = \mathbf{F}(\boldsymbol{\beta}, \mathbf{X}) + \mathbf{Z}(\mathbf{X}) \quad (7)$$

其中 $\mathbf{F}(\boldsymbol{\beta}, \mathbf{X})$ 指回归部分, 代表 $\hat{\mathbf{y}}(\mathbf{X})$ 的数学期望值。而回归部分主要使用 PCE 模型替代原本 Kriging 模型中常用的回归部分, 为标准正交多项式的加权和, 对于任一样本, 表示为以下 PCE。

$$f(\boldsymbol{\beta}, \mathbf{X}) = \sum_{a \in \mathbf{N}^n} (\beta_a f_a(\mathbf{X})) \quad (8)$$

其中 $\{\beta_a, a \in \mathbf{N}^n\}$ 为多变量标准正交多项式 $f_a(\mathbf{X})$ 的系数, $a = \{a_1, \dots, a_n\}$ 为下标, n 为输入变量维度。 $f_a(\mathbf{X})$ 与输入变量 $\mathbf{X}$ 的概率分布一致, 可通过正交多项式张量乘积得到, 即 $f_a(\mathbf{X}) = \prod_{i=1}^n f_{a_i}^{(i)}(x_i)$, 其中 $f_{a_i}^{(i)}$ 为第 i 个变量的第 a_i 阶多项式。

而 PCE 的核心在于通过式(8)中的一系列无限项多项式来代替数值模型, 因此需要一个截断方案。则截断集合为 $A^{n,p} = \{a \in \mathbf{N}^n : |a| \leq p\}$, 其中 p 为多项式阶数的最大值。集合 A 的项数为 $P_A = |A^{n,p}| = \frac{(n+p)!}{n!p!}$ 。则对于 m 个样本, 回归部分 $\mathbf{F}(\boldsymbol{\beta}, \mathbf{X})$ 可写为

$$\mathbf{F}(\boldsymbol{\beta}, \mathbf{X}) = [f(\boldsymbol{\beta}, \mathbf{x}^1), f(\boldsymbol{\beta}, \mathbf{x}^2), \dots, f(\boldsymbol{\beta}, \mathbf{x}^m)]^T \quad (9)$$

$\mathbf{Z}(\mathbf{X})$ 称为随机模型, 表示平稳随机过程, 代表回归模型近似目标函数的系统偏差, 其满足以下条件:

$$\begin{cases} E[\mathbf{Z}(\mathbf{X})] = 0 \\ \text{cov}[\mathbf{z}(\mathbf{x}^i), \mathbf{z}(\mathbf{x}^j)] = \boldsymbol{\Sigma}^2 \mathbf{R}(\theta, \mathbf{x}^i, \mathbf{x}^j) \end{cases} \quad (10)$$

式中 $\boldsymbol{\Sigma}^2$ 代表方差; $\mathbf{R}(\theta, \mathbf{x}^i, \mathbf{x}^j)$ 是假定的关于超参数的相关函数, 表示任意两点的空间相关程度。常用的相关函数形式有高斯相关函数, 则相关函数 $\mathbf{R}$ 的空间距离函数可表示为

$$\mathbf{R}(d_n, \theta_n) = \exp \left(- \sum_{h=1}^n \theta_h |x_h^i - x_h^j|^2 \right) \quad (11)$$

其中 $i, j = 1, 2, \dots, m$, $d_k = |x_h^i - x_h^j|$, θ_k 表示模型的超参数。

之后根据最优线性无偏估计要求, 使用最小二乘估计法、拉格朗日乘数法和最大似然估计法, 可求解得到模型的未知参数:

$$\begin{cases} \hat{\boldsymbol{\beta}} = (\mathbf{F}^T \mathbf{R}^{-1} \mathbf{F})^{-1} \mathbf{F}^T \mathbf{R}^{-1} \mathbf{Y} \\ \hat{\boldsymbol{\Sigma}}^2 = \frac{(\mathbf{Y} - \mathbf{F} \hat{\boldsymbol{\beta}})^T \mathbf{R}^{-1} (\mathbf{Y} - \mathbf{F} \hat{\boldsymbol{\beta}})}{m} \end{cases} \quad (12)$$

而超参数 θ 可通过求解以下无约束最优化问题得到

$$E_{ml} = \underset{\theta}{\operatorname{argmax}} \left[-\frac{1}{2} (n \ln \hat{\boldsymbol{\Sigma}}^2 + \ln |\mathbf{R}|) \right] \quad (13)$$

2.2 PSO 多目标优化设计

2.2.1 多目标优化模型设计

发动机燃烧室设计所涉及的目标参数为燃烧效率 η 和总压损失 Δp , 其中燃烧效率 η 应尽可能大,

保证 $\eta \geq 99\%$, 总压损失 Δp 应尽可能小, 保证 $\Delta p \leq 4\%$ 。

按照多目标最小优化的模型构建, 优化模型可以描述为

$$\begin{cases} \max -\eta(T_t, p_t, \dot{m}_{in}, \varphi, N_m, D_m, N_c, D_c) \\ \min \Delta p(T_t, p_t, \dot{m}_{in}, \varphi, N_m, D_m, N_c, D_c) \end{cases} \quad (14)$$

$$\text{s.t.} \begin{cases} T_t \in [427.55, 1070.33] \\ p_t \in [500, 3200] \\ \dot{m}_{in} \in [19.01, 82.398] \\ \varphi \in [0.0106, 0.0430] \\ N_m \in [2, 4] \\ D_m \in [12.1, 16.8] \\ N_c \in [10, 20] \\ D_c \in [0.5, 1.5] \end{cases} \quad (15)$$

不同于单目标优化问题的最优选取, 本文所涉及的多目标优化问题^[16-18]包含两个相互冲突的优化目标, 目标参数燃烧效率 η 和总压损失 Δp 两者难以达到同时最优, 因此在优化过程中只能权衡两个冲突目标而达到 Pareto 最优, 最终得到一个包含多个元素的最优解集(即 Pareto 解集)。Pareto 的相关定义主要如下:

Pareto 支配: 对于多目标最小优化问题的两个可行解 $\mathbf{x} = (x_1, x_2, \dots, x_n)$ 和 $\mathbf{y} = (y_1, y_2, \dots, y_n)$, 若 $\mathbf{x}$ 关于所有目标优化的函数值都小于等于 $\mathbf{y}$, 且至少有一个目标上的函数严格小于 $\mathbf{y}$, 即

$$\begin{aligned} \forall i \in \{1, 2, \dots, m\}, \quad f_i(\mathbf{x}) \leq f_i(\mathbf{y}) \\ \exists j \in \{1, 2, \dots, m\}, \quad f_j(\mathbf{x}) < f_j(\mathbf{y}) \end{aligned} \quad (16)$$

则称 $\mathbf{x}$ Pareto 支配 $\mathbf{y}$, 并记为 $\mathbf{x} < \mathbf{y}$ 。

Pareto 最优解: 给定一个集合 $\Gamma \in \mathbf{R}^n$, 若 $\mathbf{x} \in \Gamma$, 且集合 Γ 中不存在其他的元素 $\mathbf{x}' \in \Gamma$, 使得 $f(\mathbf{x}') < f(\mathbf{x})$ 成立, 则 $\mathbf{x}$ 是关于集合 Γ 的最优解。若给定多目标优化题 $\min \mathbf{F}(\mathbf{x})$, $\mathbf{x}^*$ 为 $\min \mathbf{F}(\mathbf{x})$ 可行域 Ω 中的最优解, 则称 $\mathbf{x}^*$ 是 $\min \mathbf{F}(\mathbf{x})$ 的 Pareto 最优解。

Pareto 最优解是可行区域上“不坏”的解, 所以又称作非支配解或非劣解。

Pareto 最优解集: 给定多目标优化问题 $\min \mathbf{F}(\mathbf{x})$, P_s 是 $\min \mathbf{F}(\mathbf{x})$ 所有 Pareto 最优解的集合, 即

$$P_s = \{\mathbf{x}^* \in \Omega \mid \neg \exists \mathbf{x} \in \Omega : \mathbf{x} < \mathbf{x}^*\} \quad (17)$$

Pareto 前沿: Pareto 最优解集在目标空间的映射被称作 Pareto 前沿, 即

$$F_P = \{f(\mathbf{x}) = [f_1(\mathbf{x}), \dots, f_m(\mathbf{x})] \mid \mathbf{x} \in P_s\} \quad (18)$$

2.2.2 PSO 优化算法

PSO 算法^[19-22]是进化算法的一个重要分支,

其基本思想是模拟鸟类群体行为。PSO 算法局部搜索效率高, 收敛快, 具有很好的全局和局部搜索性能, 拥有进化计算和群智能的特点。且需要设置、调整的参数少, 实现简洁, 在函数优化、模式分类等工程领域都得到了广泛应用。

PSO 算法可描述为: 设粒子群在一个 n 维空间中搜索, 由 m 个粒子组成种群 $\mathbf{X} = \{\mathbf{x}^1, \mathbf{x}^2, \dots, \mathbf{x}^m\}$, 其中的每个粒子所处的位置 $\mathbf{x}^i = [x_1^i, x_2^i, \dots, x_n^i]$ 都表示问题的一个解, 粒子通过不断调整自己的位置 $\mathbf{x}^i$ 来搜索新解。每个粒子都能记住自己搜索到的最优解, 记作 p_{id} , 以及整个粒子群经历过的最优的位置, 即目前搜索到的最优解, 记作 p_{gd} 。此外每个粒子都有一个速度, 记作 $\mathbf{V}^i = [v_1^i, v_2^i, \dots, v_n^i]$ 。当两个最优解都找到后, 每个粒子根据式(19)和式(20)来更新自己的速度和位置。

$$\begin{aligned} v_d^i(t+1) = wv_d^i(t) + \varphi_1 r_1 [p_{id} - x_d^i(t)] + \\ \varphi_2 r_2 [p_{gd} - x_d^i(t)] \end{aligned} \quad (19)$$

$$x_d^i(t+1) = x_d^i(t) + v_d^i(t+1) \quad (20)$$

式中 $v_d^i(t+1)$ 表示第 i 个粒子在 $t+1$ 次迭代中第 d 维上的速度, w 为惯性权重, φ_1 、 φ_2 为加速常数, r_1 、 r_2 为 $0 \sim 1$ 的随机数。

结合本文情况, 使用 PSO 算法构建了一个 8 维的解域空间, 在 8 维空间中的点的位置 $\mathbf{x}^i$ 即为寻优过程的解, 其各维度上的分量 $x_1^i, x_2^i, \dots, x_8^i$ 即为各个设计参数的解值。PSO 算法的基本流程如图 4 所示。




图 4 PSO 算法流程图

Fig. 4 PSO algorithm flow chart

3 结果及分析

3.1 基于 PCE 的全局灵敏度分析

首先,进行全局灵敏度分析,研究输入设计参数对输出目标参数的影响效果。基于 PCE 开展了全局灵敏度分析,得出对于燃烧效率 η 而言,油气比 φ 的灵敏度指标最大,对燃烧效率的影响是最主要的,其次是进口总压 p_t ,之后是进口总温 T_t 和进口流量 $\dot{m}_m$,其余 4 个参数对燃烧效率基本无影响。

对于总压损失 Δp 而言,进口总压 p_t 的灵敏度指标最大,对总压损失的影响是最主要的,其次是进口流量 $\dot{m}_m$,之后是油气比 φ 和进口总温 T_t ,其余 4 个参数对总压损失的影响较小。燃烧效率和总压损失的全局灵敏度分析情况如图 5 所示。




图 5 燃烧效率及总压损失全局灵敏度分析结果图

Fig. 5 Global sensitivity analysis of combustion efficiency and total pressure loss

同时,在本文研究的构型和来流条件下,从物理角度开展分析。针对于燃烧效率参数:随着油气比和进口流量的增大,会增加燃烧室内可燃气质量分数以及燃烧室内的气体掺混均匀程度,进而增加燃烧反应的速率,提高燃烧效率;当进口总压增加,气体动能随之增加,从能量转化角度而言,燃烧效率得到提高。随着进口总温的增大,燃烧室内的温度也会增大,燃烧反应的速率

会加快,进而提高燃烧效率。

针对于总压损失参数:当进口总压增加时,会增加流体在流道内的阻力,增大能量损失,进而增大总压损失;当进口流量增加时,同样会增加气体流速和流量,从而增加流体在流道内的阻力,增大能量损失,进而增大总压损失;随着油气比的增大,导致油气混合物的黏度增加,从而增加流体的阻力,增大总压损失;随着进口温度的增加,导致气体的体积增加及密度降低,使得压力减小及流量增加,进而增大总压损失。

3.2 基于 POD-PCE-Kriging 的燃烧性能代理模型结果分析

依据文中第 2 节所推导论证的模型和方法开展试验过程,主要进行了航空发动机燃烧室模型燃烧性能参数的样本采集,开展了 POD-PCE-Kriging 代理模型的搭建预测。

首先,基于拉丁超立方抽样并预处理之后的 91 组样本数据,通过西北工业大学自主设计的航空发动机燃烧室模型的一维程序计算得到样本数据对应的目标优化参数计算结果,进而完成样本数据集的构建。之后进行 POD-PCE-Kriging 代理模型的参数估计,得到关于目标优化参数燃烧效率 η 和总压损失 Δp 的代理模型。

之后使用 20 组新数据作为测试集进行 POD-PCE-Kriging 模型的预测检验,并与常用的三次多项式模型、人工神经网络(ANN)模型(基于 ANN 算法针对于燃烧效率和总压损失分别构建两个燃烧性能代理模型,其中每个 ANN 模型由包含输入层、隐藏层和输出层在内的 4 层神经网络构成。输入层包含 8 个输入节点,分别对应 8 个输入设计参数。输出层包含 1 个输出节点,对应燃烧效率或总压损失,并且使用 Adam 优化器进行训练)和基本 Kriging 模型的预测结果进行对比。使用方均根误差作为评判各个模型预测误差的标准,模型的方均根误差越小,则模型预测效果越好。

如图 6 所示,针对于燃烧效率,4 个模型使用新数据集进行预测,三次多项式模型的方均根误差为 0.015 0%,ANN 模型的方均根误差为 0.107 0%,Kriging 模型的方均根误差为 0.004 5%,POD-PCE-Kriging 模型的方均根误差为 0.006 3%,表明 4 个代理模型均可以较好地表征原模型,但针对于燃烧效率参数,Kriging 模型预测的方均根误差最小,POD-PCE-Kriging 模型次之,均优于三次多项式模型和 ANN 模型。





图 6 代理模型燃烧效率预测对比图

Fig. 6 Comparison of predictions of surrogate models on combustion efficiency

如图 7 所示, 针对于总压损失, 4 个模型使用 20 组测试数据集进行预测, 三次多项式模型的方均根误差为 0.162 8%, ANN 模型的方均根误差为 0.303 2%, Kriging 模型的方均根误差为 0.087 9%, POD-PCE-Kriging 模型的方均根误差为 0.122 7%, 表明 4 个代理模型同样可以较好地表征原模型, 但针对于总压损失参数, Kriging 模型预测的方均根误差最小, POD-PCE-Kriging 模型次之, 均优于三次多项式模型和 ANN 模型。





图 7 代理模型总压损失预测对比图

Fig. 7 Comparison of predictions of surrogate models on total pressure loss

此外, 进行大量试验并记录模型预测的计算时间, 得到 Kriging 模型和 POD-PCE-Kriging 模型针对于 20 组测试数据的平均预测时长。Kriging 模型预测的平均时长为 1.314 ms, POD-PCE-Kriging 模型预测的平均时长为 1.066 ms。表明使用 POD 算法对样本数据集进行降维重构后, 可以较好地表征原数据空间, 提炼更为关键的样本信息, 滤去边缘信息, 同时一定程度上减小了计算损耗, 在面对庞大数量的参数预测中更可以展现模型的快速性, 预测精度也并未有较大幅度的降低。

3.3 基于 PSO 的燃烧室高维多目标优化分析

基于 POD-PCE-Kriging 代理模型开展针对于目标优化参数燃烧效率 η 和总压损失 Δp 的航空发动机燃烧室构型参数优化。如图 8 所示是多目标优化为燃烧效率和总压损失的 Pareto 最优解集在目标空间内的映射, 即 Pareto 前沿。每一个点即代表一个 Pareto 解的目标函数值, 表示在目标参数限定范围内, 当确定一个目标参数的取值时, 另一个参数没有更优的选择, 该取值即为最优值。该 Pareto 前沿表征了两个存在冲突关系的目标参数——燃烧效率和总压损失的限定范围内的最优






图 8 目标空间的 Pareto 前沿


Fig. 8 Pareto frontier in the target space



(a) 油气比和进口流量



(b) 油气比和进口总压



(c) 油气比和进口总温


图9 燃烧效率随影响参数变化情况图

Fig. 9 Variation of combustion efficiency with influential parameters


取值,其解为最优解。

如图9分别显示了燃烧效率 η 与油气比 φ 、进口流量 $\dot{m}_{in}$ 、进口总压 p_t 、进口总温 T_t 的关系,图中实心点表示 Pareto 最优解集在设计空间中的分布,圆圈分别表示解集在各个面的投影。3幅图都表明燃烧效率主要受油气比的影响。其中,随着油气比的增大,燃烧效率显著增加,在相对较大的油气比时,燃烧效率在其最大值附近趋于平缓。随着进口总压、进口流量和进口总温的增大,燃烧效率同步增大。此外,在变量参数的设定范围内,油气比在 0.025~0.043;进口流量大于 40 kg/s,进口总压为 1 500~3 000 kPa,进口总温为 600~1 000 K 时,几个主要影响参数相互作用,使燃烧效率容易出现较大情况。

如图10分别显示了总压损失 Δp 与油气比 φ 、进口流量 $\dot{m}_{in}$ 、进口总压 p_t (kPa)、进口总温 T_t 的关系,3幅图都表明总压损失主要受进口总压的影响。其中,随着进口总压的增大,总压损失显著增大,在相对较大的进口总压时,总压损失在其



(a) 进口总压和进口流量



(b) 进口总压和进口总温




图 10 总压损失随影响参数变化情况图

Fig. 10 Variation of total pressure loss with influential parameters

最小值附近趋于平缓。随着进口流量、油气比和进口总温的减小,总压损失同步减小。此外,在变量参数的设定范围内,进口总压小于 1 000 kPa,进口流量在 20~25 kg/s,进口总温小于 700 K,油气比大约在 0.02 时,几个主要影响参数相互作用,Pareto 解集中更容易得到总压损失较小的点。

4 结 论

本论文创新性地针对于某型航空发动机燃烧室模型,根据航空发动机燃烧室模型的一维程序计算结果,基于数据驱动开展了基于 POD-PCE-Kriging 模型的代理模型构建和基于 PSO 算法的多目标设计优化。

1) 根据航空发动机燃烧室高性能燃烧的优化设计需求,确定来流参数、主要几何参数组织及油气分布可控参数等多维设计变量,使用拉丁超立方抽样完成样本采集,使用航空发动机燃烧室模型的一维程序计算得到目标参数值,完成燃烧室多个性能参数数据库的建立。

2) 在基本的 Kriging 方法的基础上,创新性地提出一种基于 POD-PCE-Kriging 方法的燃烧室性能预测模型。模型与三维计算相比,可快速对给定设计参数下的燃烧性能参数进行预测。根据试验结果,表明了该代理模型可以很好地近似原计算模型,证明了方法的预测快速性和计算准确性。但由于一维计算与三维计算相比普遍存在偏差,故代理模型预测结果较于三维计算结果仍存在误差,无法准确模拟真实物理情况。

3) 在此基础上,应用多目标 PSO 方法,在满

足燃烧效率不小于 99% 及总压损失不大于 4% 的指标下,进一步开展设计变量的参数寻优研究。最终得到一个包含多个元素的 Pareto 解集,完成了参数的优化选择。此外,对获取的 Pareto 最优解集进行分析,得到了对设计目标影响较大的关键设计因素和设计参数对目标参数的具体影响状态,指导燃烧室的优化设计,加速航空发动机的研制进展。

参考文献:

- [1] OGAWA H. Physical insight into fuel-air mixing for upstream-fuel-injected scramjets via multi-objective design optimization[J]. *Journal of Propulsion and Power*, 2015, 31(6): 1505-1523.
- [2] TAGHAVI M, GHAREHGHANI A, NEJAD F B, et al. Developing a model to predict the start of combustion in HCCI engine using ANN-GA approach[J]. *Energy Conversion and Management*, 2019, 195: 57-69.
- [3] TEJERO F, MACMANUS D G, SHEAF C. Surrogate-based aerodynamic optimisation of compact nacelle aero-engines[J]. *Aerospace Science and Technology*, 2019, 93: 105207.1-105207.13.
- [4] DU D, HE E, LI F, et al. Using the hierarchical Kriging model to optimize the structural dynamics of rocket engines[J]. *Aerospace Science and Technology*, 2020, 107: 106248.1-106248.10.
- [5] POGGI C, ROSSETTI M, BERNARDINI G, et al. Surrogate models for predicting noise emission and aerodynamic performance of propellers[J]. *Aerospace Science and Technology*, 2022, 125: 107016.1-107016.12.
- [6] SONG L K, BAI G C, FEI C W. Dynamic surrogate modeling approach for probabilistic creep-fatigue life evaluation of turbine disks[J]. *Aerospace Science and Technology*, 2019, 95: 105439.1-105439.14.
- [7] TEJERO F, CHRISTIE R, MACMANUS D, et al. Non-axisymmetric aero-engine nacelle design by surrogate-based methods[J]. *Aerospace Science and Technology*, 2021, 117: 106890.1-106890.14.
- [8] 刘重阳, 钟华贵, 宋文艳, 等. 燃烧室空气流量分配试验方法模拟分析与优化[J]. *航空动力学报*, 2019, 34(8): 1652-1662.
LIU Chongyang, ZHONG Huagui, SONG Wenyan, et al. Simulation analysis and optimization on test method of combustor airflow distribution[J]. *Journal of Aerospace Power*, 2019, 34(8): 1652-1662. (in Chinese)
- [9] 熊师航, 宋文艳, 梅宇莉. 航空发动机燃烧室一维计算方法研究[C]//第五届冲压发动机内外流耦合流动研讨会. 山东威海: 中国空气动力学会, 2021: 745-755.
- [10] GRADER M, YIN Z, GEIGLE K P, et al. Influence of flow field dynamics on soot evolution in an aero-engine model combustor[J]. *Proceedings of the Combustion Institute*, 2021, 38(4): 6421-6429.
- [11] KEAN K, SCHIENER M. Error analysis of supremizer pressure recovery for POD based reduced-order models of the time-dependent navier-stokes equations[J]. *SIAM Journal on Numerical Analysis*, 2020, 58(4): 2235-2264.
- [12] DE CILLIS G, CHERUBINI S, SEMERARO O, et al. POD-based analysis of a wind turbine wake under the influence of tower and nacelle[J]. *Wind Energy*, 2021, 24(6): 609-633.
- [13] KERSAUDY P, SUDRET B, VARSIER N, et al. A new surrogate modeling technique combining Kriging and polynomial chaos ex-

- pansions: application to uncertainty analysis in computational dosimetry[J]. *Journal of Computational Physics*, 2015, 286: 103-117.
- [14] NAGAWKAR J, LEIFSSON L T, DU X. Applications of polynomial chaos-based cokriging to aerodynamic design optimization benchmark problems[R]. AIAA 2020-0542, 2020.
- [15] ZHANG Wei, WANG Qiang, ZENG Fanzhi, et al. An adaptive sequential enhanced PCE approach and its application in aerodynamic uncertainty quantification[J]. *Aerospace Science and Technology*, 2021, 117: 106911.1-106911.17.
- [16] AMANI E, AKBARI M R, SHAHPOURI S. Multi-objective CFD optimizations of water spray injection in gas-turbine combustors[J]. *Fuel*, 2018, 227: 267-278.
- [17] SABOOHI Z, OMMI F, AKBARI M J. Multi-objective optimization approach toward conceptual design of gas turbine combustor[J]. *Applied Thermal Engineering*, 2019, 148: 1210-1223.
- [18] AMRIT A, LEIFSSON L, KOZIEL S. Fast multi-objective aerodynamic optimization using sequential domain patching and multifidelity models[J]. *Journal of Aircraft*, 2020, 57(3): 388-398.
- [19] CHENG Shixin, ZHAN Hao, SHU Zhaoxin, et al. Effective optimization on Bump inlet using meta-model multi-objective particle swarm assisted by expected hyper-volume improvement[J]. *Aerospace Science and Technology*, 2019, 87: 431-447.
- [20] TAO Jun, SUN Gang, WANG Xinyu, et al. Robust optimization for a wing at drag divergence Mach number based on an improved PSO algorithm[J]. *Aerospace science and technology*, 2019, 92: 653-667.
- [21] MAHMOODABADI M J, BABAK N R. Robust fuzzy linear quadratic regulator control optimized by multi-objective high exploration particle swarm optimization for a 4 degree-of-freedom quadrotor[J]. *Aerospace Science and Technology*, 2020, 97: 105598.1-105598.13.
- [22] MI Baigang, CHENG Shixin, LUO Yu, et al. A new many-objective aerodynamic optimization method for symmetrical elliptic airfoils by PSO and direct-manipulation-based parametric mesh deformation[J]. *Aerospace Science and Technology*, 2022, 120: 107296.1-107296.21.

(编辑: 陈 越)