基于鸽群搜索策略的代理模型结构优化方法

曹瑞¹, 刘燕斌^{2,3*}, 沈海东², 徐亮¹, 陆宇平¹

1. 南京航空航天大学自动化学院, 南京 210016;

2. 南京航空航天大学航天学院, 南京 210016;

3. 北京航空航天大学虚拟现实技术与系统国家重点实验室, 北京 100191

* E-mail: nuaa_liuyanbin@139.com

收稿日期: 2019-08-11; 接受日期: 2019-10-09; 网络版发表日期: 2020-05-13

国家自然科学基金(批准号: 11572149)和虚拟现实技术与系统国家重点实验室开放基金(编号: VRLAB2018C04)资助项目

摘要 针对高超声速飞行器系统间耦合严重、设计变量多, 在大样本下高超声速飞行器代理模型结构难以确定的问题, 本文采用鸽群算法的优化思想提出一种代理模型结构优化方法. 该方法可以自主搜索到满足精度和预测性能要求的多项式代理模型结构. 通过比较分析, 该方法的性能优于Davidson提出的遗传规划算法. 进而将其应用于高超声速飞行器全局气动数据拟合和控制器设计, 仿真结果表明通过该方法获得的预测数据误差小于5%, 具有好的拟合效果, 能够满足工程应用要求.

关键词 代理建模, 高超声速飞行器, 飞行控制, 优化设计, 鸽群算法

1 引言

目前, 数值优化在飞行器气动设计^[1]中发挥着越来越重要的作用, 使用计算流体动力学(computational fluid dynamics, CFD)计算高保真度的飞行器流体力学在飞行器的气动设计中得到了广泛的应用. 然而, 飞行器气动设计的主要挑战与优化过程的计算成本有关, 当需要大量昂贵的CFD模拟时, 计算成本可能令人望而却步. 因此, 发展高效的气动模型优化方法具有重要意义. CFD驱动数值优化方法可以分为两类: 基于梯度方法^[2]和无梯度方法. 基于梯度的方法通常非常有效, 但是解决方案的最优性对初始设置非常敏感, 并且该方法常陷入局部极小值^[3]. 飞行器气动模型

优化问题通常是多模态的^[4], 此时无梯度的全局寻优方法就具有重要的意义. 然而, 如果使用高保真CFD进行功能评估, 随着设计变量数量的增加, 采用遗传算法(genetic algorithms, GAs)或粒子群算法(Particle swarm optimization, PSO)等全局优化方法的计算成本会大幅度提高.

近年来, 随着飞行器空气动力学的发展, 通常在设计分析和优化中引入代理模型, 以解决复杂目标函数、约束条件、气动设计空间的高维性和计算负担等带来的挑战. 高维气动设计问题需要花费大量的时间、昂贵的计算模拟或物理试验, 来评估复杂的目标函数和约束条件, 以便对飞行器设计问题进行分析 and 优化. 特别是对于吸气式高超声速飞行器, 与常规飞

引用格式: 曹瑞, 刘燕斌, 沈海东, 等. 基于鸽群搜索策略的代理模型结构优化方法. 中国科学: 技术科学, 2020, 50: 1612–1624

Cao R, Liu Y B, Shen H D, et al. Optimization algorithm of the surrogate model structure based on pigeon swarm search strategy (in Chinese). Sci Sin Tech, 2020, 50: 1612–1624, doi: [10.1360/SST-2019-0277](https://doi.org/10.1360/SST-2019-0277)

行器相比,其采用了超燃冲压发动机、机体/发动机一体化等先进技术.这使飞行器各个子系统之间存在深层次的相互作用,比如气动和推进系统的强耦合、气动-弹性结构以及气动-热之间的相互作用^[1],这些特性导致大包线飞行的气动特性变化复杂^[5,6],并且新型飞行器对飞行仿真、动力学分析和系统设计过程均需要高可信度的非线性气动模型^[7~11].因此,对于高超声速飞行器而言,在概念研究和初步设计阶段引入满足一定精度要求的气动代理模型^[12]进行分析和设计变得十分必要.

目前对多项式代理模型的结构优化方法研究较少,研究多集中于代理模型建立方法筛选、改进等方面.传统多项式代理模型建立过程中,代理模型的结构是预先确定的,然后使用优化技术(通常是最小二乘法)为确定的模型结构找到最佳系数,以逼近真实数据.传统的建模方法在对高超声速飞行器建立全局非线性拟合多项式时会遇到很多问题.首先,拟合变量维数多.由于高超声速飞行器各结构之间耦合较深,会导致在建立飞行器气动代理建模时有较多的变量参与,如速度、高度、迎角、舵面偏转角、弹性结构参数、发动机结构参数等.其次,模型结构不确定.所以,建立合理的代理模型异常困难^[13~15],并且耗时巨大.

很多研究者采用逐步回归的方法^[16,17]选择多项式模型结构,然而最小平方问题中产生的回归量具有很大的相关性,例如相同变量构成的线性和立方项总是高度相关,这种情况将导致参数估计出现病态,从而使得参数估计结果不准确.文献^[18]基于多变量正交多项式,确定高超声速飞行器气动代理模型形式.但是最后代理模型结构复杂,不适用于先进控制方法的应用. Davidson等人^[19]利用Koza等人^[20,21]提出的遗传规划进行函数拟合,用于寻找一个与数据有很好响应关系的多项式结构.但是,该方法需要事先定义规则基和使用树的概念,较为复杂.

本文主要目的是提出一种新的代理模型结构优化方法,以确定合适的飞行器多项式代理模型结构.为了实现这一目标,采用了一个可以评估代理模型准确性的准则——惩罚预测值(penalized predictive score PPS).然后介绍基于该评价准则的代理模型结构优化方法.所提出的结构优化方法可以在保证满足模型精度要求的同时尽可能地简化模型,从而提高飞行器在概念设计和控制设计时的效率.基于该方法得到的代

理模型也可以分析对气动影响较大的因素,进而确定相应气动力/力矩的关键影响因素,更有利于明确飞行器设计时关注的主要因素.本文提出的方法所执行的任务与Davidson的遗传规划方法相似,但要比遗传规划算法更简单. Davidson通过对Colebrook-White公式的多项式拟合验证了他的方法.本文通过使用提出的代理模型结构优化方法对Colebrook-White公式进行拟合,并与Davidson的拟合结果进行比较,验证了本文提出方法的有效性.最后,对高超声速飞行器全局气动系数进行拟合,并分别基于飞行器真实模型和建立的代理模型设计跟踪控制器,通过仿真验证了建立的代理模型可以很好地用于控制系统设计,进一步证明了优化设计方法的有效性.

2 代理模型结构优化算法

2.1 算法优化函数

通过使用特定的目标函数,设计代理模型优化方法可以对代理模型进行快速优化,得到合适的代理模型.为了筛选出满足复杂要求的代理模型,其优化目标不可能是单一目标,而是多种优化信息的合理融合.本文综合对代理模型精度、预测性和平滑性要求,提出了惩罚预测值作为优化函数.下面将对其进行具体介绍.

2.1.1 优化函数定义

评估代理模型的准确性非常具有挑战性,最好使用一个独立的集合来评估给定方法的预测能力.但是,这样的方法在计算上非常昂贵.此外,还可以通过计算设计点上的误差来估计误差.但是均方误差(mean-square error, MSE)较小并不意味着具有良好的预测能力.因此,通常使用交叉验证(cross-validation CV)^[22]或引导算法^[23]等重复采样技术进行验证.这种技术可以减少估计的偏差.然而,它们不能防止模型参数化过度.本文将引入一个准则来完成这项评估工作.这个准则称为惩罚预测值.它由以下3个部分组成.

(1) 内部精度:在设计点上使用MSE.

(2) 预测能力:采用10折交叉验证预测误差平方和(将数据集分成10份,轮流将其中9份做训练,1份做验证.10次结果的均值作为对算法精度的估计).

(3) 粗糙惩罚项:使用弯曲能量泛函^[24](bending

energy functional, BEF). 粗糙惩罚法其实是为了克服最小二乘法不稳健而引入的一个方法. 其基本原理是在最小二乘的基础上增加一个粗糙惩罚项作为平滑函数.

包含评价代理模型精度、预测能力和平滑性的惩罚预测值数学模型如式(1)所示.

$$\text{PPS}(m, Z_n) = \frac{\alpha \widehat{\mathfrak{R}}_{l_2, Z_n(m)}}{a} + \frac{\beta \widehat{\mathfrak{R}}_{10-CV(m)}}{b} + \frac{\gamma E_n(m)}{c}, \quad (1)$$

其中, $\widehat{\mathfrak{R}}_{l_2, Z_n(m)}$ 表示MSE, $\widehat{\mathfrak{R}}_{10-CV(m)}$ 表示10折交叉验证预测误差平方加和, $E_n(m)$ 为一个粗糙惩罚项. 此外, α, β, γ 为正实数的权重. 由于对于代理模型的要求首先是保证内部精度, 然后是预测能力, 最后是对代理模型平滑性的要求, 所以在权值选取时会有所侧重. 为方便起见, 三者的权值以倍数方式进行选取, 在此采用 $\alpha=2\beta$ 和 $\beta=2\gamma$ 的形式.

2.1.2 内部精度

令 $\Omega=[0,1]^d$ 是 d 维的参数空间, $\mathbf{X}_n=(x_1, \dots, x_n)^T \in \Omega_n$ 和 $\mathbf{Y}_n=(y_1, \dots, y_n)^T \in R^n$ 构成一组设计点 $Z_n=(X_n, Y_n)$, 其中 $y_i=f(x_i)$, $i=1, \dots, n$, 并且 f 是复杂的评估函数. 在设计样本 Z_n 的基础上, 采用代理模型 $\widehat{m} \mid Z_n \in \Omega^R$ 替代函数 f .

内部精度通常是基于一个对比函数(或损失函数)来测量预测模型和真实模型之间的误差. 一个典型的损失函数选择是平方误差 $l_2(x, y)=(x-y)^2$. MSE的积分形式是整个参数空间误差二范数 l_2 .

$$\mathfrak{R}_{l_2, Z_n}(m) = \int_{\Omega} l_2(\widehat{m} \mid Z_n(x), f(x)) dx. \quad (2)$$

由于 f 是未知的, 所以只能近似估计代理模型预测精度. 理想情况下, 是通过一组额外的点来评估代理模型的预测性能. 然而, 采用这样的方式需要生成额外的集合, 这在计算上是昂贵的. 因此, 可以使用与设计点集相关的经验分布以判断代理模型的预测性能. 式(3)为在设计点集上预测模型和真实模型的均方误差, 也是对式(2)中定义的 $\mathfrak{R}_{l_2, Z_n(m)}$ 的经验近似.

$$\begin{aligned} \widehat{\mathfrak{R}}_{l_2, Z_n}(m) &= \frac{1}{n} \sum_{i=1}^n l_2(\widehat{m} \mid Z_n(x_i), y_i) \\ &= \frac{1}{n} \sum_{i=1}^n (\widehat{m} \mid Z_n(x_i) - y_i)^2. \end{aligned} \quad (3)$$

注意, 在设计点集上计算MSE是对整个设计空间误差的有偏估计. 事实上, 对于任何插值代理模型 $\widehat{m}$,

有 $\widehat{\mathfrak{R}}_{l_2, Z_n(m)} = 0$. 但是这并不一定意味着代理模型适合整个实际的函数空间, 所以还需要对代理模型的预测能力提出要求.

2.1.3 预测能力

通常采用验证集(设计点集外的样本数据)对预测能力进行评估. 这是因为使用设计点来估计误差会得到比较满意的结果^[25]. 但是, 使用验证集会增加成本. 因此, 使用交叉验证^[22]和引导算法^[23]等重复采样技术对预测误差进行估计十分方便. 重复采样技术通过采用设计点的子集来构建多个子代理模型进行误差估计. 在本文提出的算法中, 采用 k 折交叉验证的计算误差表示代理模型预测能力. k 折交叉验证是将数据分成 k 个子集. 每个子集都扮演验证集的角色, 其余 $k-1$ 个子集作为训练集一起使用. 如果 k 是折叠次数, 对于 $i=1, 2, \dots, k$, 设 $Z(i) \in \mathcal{Z}(Z_n)$ 是 Z_n 的子集, 即 $\cup_{i=1}^k Z(i) = Z_n$. 式(4)为 k 折交叉验证的误差的表达式, 通过第 i 次折叠 $Z(i)$ 中一个点的损失来估计 l_2 误差, 并与在剩余折叠 $(Z_n \setminus Z(i))$ 上建立的代理模型的预测结果进行比较.

$$\mathfrak{R}_{k-CV}(m) = \frac{1}{n} \sum_{i=1}^k \sum_{(x', y') \in Z^{(i)}} l_2(\widehat{m}_{|Z_n \setminus Z^{(i)}}(x'), y'). \quad (4)$$

当且仅当 $x \in Z_n$ 并且 $x \notin Z^{(i)}$, 其中 $z \in Z_n \setminus Z(i)$.

Queipo等人^[26]指出交叉验证的主要优势在于它提供了一个早期的无偏估计. 此外, Kohavi^[27]研究了大量数据集上的交叉验证和引导算法的性能, 并推荐使用10折交叉验证. James等人^[28]指出 $k=5$ 或 $k=10$ 的 k 折交叉验证产生的测试误差估计值不受过高的偏差和方差影响. 根据上述研究结果, 在算法中采用10折交叉验证的计算误差表征代理模型预测能力.

2.1.4 平滑性

对于代理模型而言更关注的是平滑性, 而不是结构复杂性. 例如, Nguyen等人^[29]引入了线性参考模型准则, 通过计算预测值与局部线性模型 $\widehat{l}_{lm}$ 之间的偏差来对代理模型的平滑性进行评估. 式(5)为采用线性参考模型准则计算模型平滑性的表达式.

$$\mathfrak{R}_{\text{LRM}}(m) = \frac{1}{N} \sum_{k=1}^N l_2 \left(\widehat{m} \mid_{Z_n(x^{(k)})}, \widehat{l}_{lm}(x^{(k)}) \right). \quad (5)$$

从计算方面上讲, 式(5)需要构造一个德劳内三角

测量以计算 $\hat{f}_{m^*}$. 然而此准则对于具有高维设计变量的函数计算成本太高. 为简化计算成本, 可采用代理模型粗糙惩罚项——弯曲能量泛函^[24]对代理模型进行预测. 弯曲能量泛函是以二阶偏导数为基础的惩罚项, 对于 d 维空间, 粗糙惩罚度 E_n 是Hessian平方项的积分值.

$$E_n(\hat{f}) = \int_{\Omega} \sum_{i=1}^d \sum_{j=1}^d \left(\frac{\partial^2 \hat{f}}{\partial x_i \partial x_j} \right)^2 dx. \quad (6)$$

在惩罚预测标准的选择中, 若计算器的计算效率较高, 则可以用线性参考模型准则^[29]代替弯曲能量泛函.

以惩罚预测值(PPS)为代价函数, 下面将介绍本文提出的代理模型结构优化方法基本思路以及基于鸽群搜索策略对方法进行的改进.

2.2 代理模型最优结构选取思路

对代理模型进行结构优化意味着需要评估多个代理模型的性能, 然后从中选择一个最佳的代理模型结构, 但是这种做法会消耗大量的时间成本. 通过采用信息融合的思路, 对比各个代理模型结构的权重值来评估最佳的模型结构, 可以节省时间成本和计算资源^[26]. 其中代理模型组的聚合误差为 $\mathbf{W}^T \mathbf{C} \mathbf{W}$. 权值选择的目的是使约束 $\sum_{i=1}^p \omega_i = 1$ 下的交叉验证误差最小, 利用式(7)所示的权值表达形式得到最优加权代理.

$$\mathbf{W} = \frac{\mathbf{C}^{-1} \mathbf{1}}{\mathbf{1}^T \mathbf{C}^{-1} \mathbf{1}}, \quad (7)$$

其中, 矩阵 $\mathbf{C}$ 的元素为 $c_{ij} = \langle v_i, v_j \rangle$. Viana等人^[30]指出, 不匹配的权重自由度会放大预测误差. 所以, 在此只采用 $\mathbf{C}$ 的对角元素(矩阵 $\mathbf{C}$ 由代理模型误差的协方差进行近似). 则, 权值的表达形式为 $\omega_i = c_{ii}^{-1} / \sum_{k=1}^n c_{kk}^{-1}$.

考虑 $(\bar{m}^{(1)} | Z_n, \dots, \bar{m}^{(n)} | Z_n)$ 为一代理模型组. 令 $\bar{A}$ 为代理模型组的集合, $\mathbf{W}$ 为权重向量, 式(8)为 $\bar{A}$ 的表达形式.

$$\bar{A}(x) = \sum_{k=1}^p \omega_k \bar{m}^{(k)} | Z_n(x). \quad (8)$$

之后, 在 $\sum_{i=1}^p \omega_i = 1$ 的约束条件下通过优化惩罚预

测标准(式(1)), 计算 $\bar{A}(x)$ 的表达式中的权重. 注意, $\bar{A}(x)$ 的均方差是权重的二次形式, 如式(9)所示.

$$\mathfrak{R}_{l_2, \bar{p}_n}(\bar{A}) = \left\| \sum_{i=1}^p \omega_i e_i \right\|^2 = \mathbf{W}^T \mathbf{E} \mathbf{W}, \quad (9)$$

其中, 矩阵 $\mathbf{E}$ 的元素为 $E_{ij} = \langle e_i, e_j \rangle$. 同样, 聚合的交叉验证误差也是权值的二次形式, 式(10)中 $\mathbf{C}$ 的定义同上.

$$\mathfrak{R}_{CV}(\bar{A}) = \mathbf{W}^T \mathbf{C} \mathbf{W}. \quad (10)$$

最后, 能量泛函也是权值的二次形式, 如式(11)所示.

$$\begin{aligned} E_n(\bar{A}) &= \int_{\Omega} \sum_{i=1}^d \sum_{j=1}^d \left(\frac{\sum_{k=1}^p \omega_k \partial^2 \bar{m}^{(k)} | Z_n(x)}{\partial x_i \partial x_j} \right)^2 dx \\ &= \mathbf{W}^T \mathbf{K} \mathbf{W}, \\ K &= \left[k_{kl} = \sum_{i=1}^d \sum_{j=1}^d \int_{\Omega} \left(\frac{\partial^2 \bar{m}^{(k)} | Z_n(x)}{\partial x_i \partial x_j} \right) \right. \\ &\quad \times \left. \left(\frac{\partial^2 \bar{m}^{(l)} | Z_n(x)}{\partial x_i \partial x_j} \right) dx \right]. \end{aligned} \quad (11)$$

令 $R = \alpha E + \beta C + \gamma K$, 则代理模型组的惩罚预测值为权值 $\mathbf{W}$ 的二次形式: $\text{PPS}(\bar{A}) = \mathbf{W}^T \mathbf{R} \mathbf{W}$. 在约束 $\sum_{i=1}^p \omega_i = 1$ 的情况下, PPS的最优解是使PPS最小.

如果进行优化的代理模型组数量适中, 则使用上述方法对模型权重进行求解, 选择最优模型结构较为简单. 但是, 遍历所有可能的代理模型组合形式进行组合评估似乎不切实际, 这是因为该过程中不仅需要罗列出所有可能的代理模型结构, 还需要对含有大量模型结构的代理模型组进行权重求解. 因此, 本文进一步结合鸽群搜索策略对上述代理模型结构优化方法进行改进.

3 结合鸽群搜索策略的代理模型结构优化方法

3.1 结合鸽群搜索策略的代理模型结构选择流程

相比于GA与PSO框架, 鸽群算法会在优化过程中删除适应性差的个体, 从而提高计算速度. 并且采用具

有变异操作算子的鸽群策略可以更好地保证全局优化效果. 对于含有设计变量较多(如, 含有飞行器翼展长度、厚度、前体下倾角等)的飞行器气动优化, 采用鸽群策略相对于GA与PSO框架会大幅度提高计算效率. 所以, 本文结合鸽群算法^[31]的思想对上节中提出的代理模型结构优化方法进一步改进, 可以在满足精度要求的条件下, 获得简洁的代理模型形式.

该方法流程如下: 首先建立设计模型阶次下, 包含所有变量间组合的初始代理模型; 然后根据所要求的拟合精度进行筛选, 获得满足精度要求的最小模型阶次和项数; 之后提取用于鸽群搜索策略的代理模型关键信息; 最后采用提取出的模型信息, 搜索出模型精度最高的代理模型形式. 该算法执行流程图如图1所示, 其实现流程如下.

(1) 初始化和智能算法预处理

确定模型最高阶次 $P_{\max}$ 、最大项数 $D_{\max}$ 和模型精度要求 PPS_c , 如式(12)所示.

$$\begin{aligned} P_{\max} &= \max_{i=1}^p n_i, \\ D_{\max} &= \max \mathcal{J}(\bar{m} \mid Z_n(x)), \\ PPS_c &= \left\{ \alpha \mathfrak{R}_{l_2, Z_n(m)} + \beta \mathfrak{R}_{10-CV(m)} + \gamma E_n(m) \right\}_c, \end{aligned} \quad (12)$$

其中, n_i 为第 x_i 维变量的阶次, p 为变量维数, 函数 $\mathcal{J}(\cdot)$ 为获取代理模型中元素的个数, PPS_c 为指定的模型预测精度要求.

在算法开始运行之前, 还需要设计基于鸽群策略搜索最优模型结构的初始条件. 由于鸽群算法迭代后期, 种群个体会趋向一致. 为保证全局优化的性能, 在标准鸽群算法搜索策略中引入变异操作算子. 先以多组径向基函数对高斯变异鸽群算法中的变异操作算子和种群数目进行统计分析. 根据统计分析结果, 最后在该算法中选用高斯变异算子 $\aleph$ 和 $N=500$ 的种群规模进行运算. $\aleph$ 为服从高斯分布的随机数.

$$\aleph \in N(\mu, \sigma^2), \quad (13)$$

式中, μ 为期望, σ^2 标准方差. 其中, 鸽群算法的初始参数设置为: 种群数目 $N=500$; 地磁因子 $R=0.3$; 迭代次数 $n=150$.

(2) 建立初始模型结构

由于模型结构不确定, 以及模型结构和模型参数

的耦合关系, 建立初始系统代理模型结构包含所有影响因素, 以及变量间的组合情况, 以消除模型结构不确定对拟合参数结果的影响. 其中, 各变量的最高阶次根据实际需求选择. 然后在变量阶数限制下, 获取变量间的组合形式, 构建初始的模型结构.

根据各变量的最高阶次, 列写所有变量最高阶次及以下的形式 $\mathbf{J}_1$, 如式(14)所示.

$$\mathbf{J}_1 = [x_1, \dots, x_1^{n_1}, \dots, x_p, \dots, x_p^{n_p}]. \quad (14)$$

注意, 式(14)中的变量可以是飞行状态也可以是飞行器结构参数, 具体是何种类型的参数视优化目标而定. 然后对 $\mathbf{J}_1$ 的变量进行交叉组合, 获得 $\mathbf{J}_1$ 中各变量间的交叉形式 $\mathbf{J}_2$, 其表达式为式(15).

$$\begin{aligned} \mathbf{J}_2 &= \sum_{i=1}^K (\prod \mathbf{J}_1(i, :)), \\ K &= \frac{\sum_{j=1}^p n_j \left(\sum_{j=1}^p n_j - 1 \right)}{2} - \sum_{j=1}^p \frac{n_j(n_j - 1)}{2}, \end{aligned} \quad (15)$$

其中, p 为变量维数, n_i 为第 x_i 维变量的最高阶次. 然后组合 $\mathbf{J}_2$ 和 $\mathbf{J}_1$, 最终得到式(16)的初始模型结构.

$$\begin{aligned} \mathbf{J} &= \mathbf{J}_1 + \mathbf{J}_2 \\ &= k_1 + k_{11}x_1 + \dots + k_{1n_1}x_1^{n_1} + \dots \\ &\quad + k_{p1}x_p + \dots + k_{pn_p}x_p^{n_p} \\ &\quad + k_{s1}x_1x_2 + \dots + k_{sp}x_1x_p + k_{s(p+1)}x_1^2x_2 \\ &\quad + \dots + k_{s(p+p)}x_1^2x_p + \dots, \end{aligned} \quad (16)$$

其中, x_i 为第 i 维变量, n_i 为 x_i 的最高阶次, k 为模型参数.

(3) 筛选满足精度要求的模型阶次和项数

根据样本空间和建立的初始模型结构, 依据最小二乘法获得相应的模型参数. 并基于惩罚预测值的概念, 获得初始模型结构下的惩罚预测值 PPS , 即模型精度.

$$\begin{aligned} PPS(y_i, \hat{y}_i) &= \alpha \mathfrak{R}_{l_2, (y_i, \hat{y}_i)} + \beta \mathfrak{R}_{10-CV((y_i, \hat{y}_i))} \\ &\quad + \gamma E_n(\hat{y}_i), \end{aligned} \quad (17)$$

式中, $\hat{y}_i$ 表示拟合数据, y_i 表示样本数据. 然后去除模型结构 $\mathbf{J}$ 的最后一项得到新的模型结构, 并基于此模型结构再次拟合, 计算惩罚预测值 PPS . 最后获得满足 PPS_c 精度要求的最低代理模型阶次 P 和项数 D .

图 1 基于鸽群搜索策略的代理模型结构优化算法流程图

Figure 1 Flow chart of optimization algorithm of the surrogate model structure based on pigeon-inspired algorithm (PIO).

(4) 获取模型信息

该算法随机生成在设计的最大项数和自变量最高

阶次内的多种代理模型形式, 如式(18)所示, 作为参与优化的代理模型组, 其包含了多种多项式组合形式。

$$(\bar{m}|_{Z_n})_{\text{first}} = \begin{pmatrix} a_{11}x_1^{k_{11}^1} \cdots x_N^{k_{N1}^1} + a_{12}x_1^{k_{12}^1} \cdots x_N^{k_{N2}^1} + \cdots + a_{1i}x_1^{k_{1i}^1} \cdots x_N^{k_{Ni}^1} + \cdots + a_{1d_1}x_1^{k_{1d_1}^1} \cdots x_N^{k_{Nd_1}^1} \\ a_{21}x_1^{k_{11}^2} \cdots x_N^{k_{N1}^2} + a_{22}x_1^{k_{12}^2} \cdots x_N^{k_{N2}^2} + \cdots + a_{2i}x_1^{k_{1i}^2} \cdots x_N^{k_{Ni}^2} + \cdots + a_{2d_1}x_1^{k_{1d_1}^2} \cdots x_N^{k_{Nd_1}^2} \\ \vdots \\ a_{z1}x_1^{k_{11}^z} \cdots x_N^{k_{N1}^z} + a_{z2}x_1^{k_{12}^z} \cdots x_N^{k_{N2}^z} + \cdots + a_{zi}x_1^{k_{1i}^z} \cdots x_N^{k_{Ni}^z} + \cdots + a_{zd_1}x_1^{k_{1d_1}^z} \cdots x_N^{k_{Nd_1}^z} \end{pmatrix}, \quad (18)$$

式中, a_{zi} 表示第 z 个代理模型结构中第 i 项的系数($z < Z$, Z 为设置的最大种群数目; $i < d_i < D$, D 为代理模型所包含的最大项数), k_{ji}^z 为第 j 个自变量的阶数。生成的初始模型信息会作为鸽群优化算法的输入, 比如最大种群数目 Z , 所以需要在生成初始模型信息之前确定基于鸽群策略搜索最优模型结构的初始条件。因此在算法初始化时, 先以多组径向基函数对高斯变异鸽群算法中的变异操作算子和种群数目进行统计分析。最终, 确定了优化初始集合的种群数目和相应的阶次、项数等约束信息后, 生成用于鸽群算法的优化初始集合(19)。

由于上式中每一个多项式均由 N 个自变量和相应的阶次所组成, 可由整数串表示模型信息, 如式(19)所示, 构成在算法搜索中使用的有效信息。

$$(\bar{m}|_{Z_n})_{\text{first}} = \begin{pmatrix} (a_{z1}, k_{11}^z, \cdots, k_{j1}^z, \cdots, k_{N1}^z), \cdots, \\ (a_{zi}, k_{1i}^z, \cdots, k_{ji}^z, \cdots, k_{Ni}^z), \cdots, \\ (a_{zd_z}, k_{1d_z}^z, \cdots, k_{id_z}^z, \cdots, k_{Nd_z}^z) \end{pmatrix}. \quad (19)$$

算法中的代价函数(或适应度函数)定义为代理模型预测值和实际实验数据之间的惩罚预测值PPS。需要注意的是式(19)中每一个模型都要满足阶次和没有重复的代理模型形式的要求。

(5) 代理模型优化迭代

代理模型优化搜索过程采用了高斯变异鸽群算法的思想。下面介绍具体的搜索过程。

算法每次迭代, 代理模型组个体会根据罗盘因子 R 调整模型阶次的变化方向(升高或降低)。并且在每次迭代中, 会按照适应度函数值的大小对模型组 $(\bar{m}|_{Z_n})_n$ 中的代理模型 $(\bar{m}|_{Z_n})$ 进行排序, 并删除适应度较差的代理模型, 留下较优的模型结构。然后, 针对这些模型结构选取中心点 C 作为剩余模型结构进行变化的参考

方向, 对第 i 次迭代的模型信息进行更新, 获取第 $i+1$ 次迭代的模型信息。

$$C = \frac{\sum_{N,i} (\bar{m}|_{Z_n}) \text{PPS}(\bar{m}|_{Z_n})}{\sum_{N,i-1} \text{PPS}(\bar{m}|_{Z_n})}. \quad (20)$$

需要注意的是在这个过程中同样不允许出现重复项。

在基于该算法进行模型优化时, 当更新后的模型信息多样性 d 低于某一阈值 d_{low} 时, 会执行突变操作, 即在代理模型信息中随机引入一个全新的信息。

$$\text{if } d < d_{\text{low}}, \text{ then } k_{j,i+1}^z = \text{int}(k_{j,i}^z \cdot \aleph), \quad (21)$$

其中, $\text{int}(\cdot)$ 为取整函数, k_{ji}^z 为第 i 次迭代时代理模型组中第 z 个代理模型中第 j 个自变量的阶数。 d 为模型信息多样性的衡量指标, 表达形式如式(22)所示。

$$d = \frac{1}{N} \sum_{z=1}^N \left[\sum_{j=1}^d (k_{j,i}^z - \bar{k}_{j,i})^2 \right]^{1/2}, \quad (22)$$

式中, z 表示鸽群中的第 z 个个体, N 为第 i 次迭代的鸽群数目。并且执行过程中需要检查这个特定的信息是否已经存在。

需要注意的是, 多项式中的所有项都不应该是相同的。如果一个多项式中存在重复项, 那么在使用最小二乘法求解多项式系数时算法中的方程就会变成奇异的。

(6) 结束算法

基于随机生成的第一次迭代的代理模型组 $(\bar{m}^{(1)}|_{Z_n}, \dots, \bar{m}^{(n)}|_{Z_n})$ 信息, 以代理模型预测值和实际实验数据之间的惩罚预测值PPS为适应度函数, 重复执行步骤(5), 直至适应度函数值前后两次值小于某个阈值 $|\text{PPS}_n - \text{PPS}_{n-1}| \leq \varepsilon$ (ε 可设置为 1×10^{-6}), 或达到设置的最大迭代次数 $N \leq N_{\text{max}}$, 算法停止运行。

3.2 算法验证

3.2.1 与遗传规划算法比较

使用智能算法的思想选择多项式结构, 然后对其系数进行最小二乘拟合的思路, Davidson曾提出过, Davidson使用遗传规划来确定拟合多项式结构, 然后用最小二乘拟合来找到该多项式的最佳系数^[21]. 遗传规划算法按照如下步骤运行: (1) 执行规则基组件; (2) 引入常数项; (3) 执行最小二乘拟合; (4) 再次执行规则基组件; (5) 用树中的乘法替换幂, 最后执行自适应交叉和变异. 所有这些步骤都随着遗传程序的不断迭代而重复.

Colebrook-White公式是根据雷诺数 Re 和相对粗糙度 K/D (等效粗糙度 K 与管径 D 之比)计算摩擦系数 f :

$$\frac{1}{\sqrt{f}} = -2\log_{10}\left\{\frac{2.51}{Re\sqrt{f}} + \frac{K}{3.7D}\right\}. \quad (23)$$

Colebrook-White公式是一个隐式方程, 其中 f 出现在方程两边, 求 f 的一个显式多项式函数比较困难, 所以采用Colebrook-White公式验证提出的代理模型算法的好坏.

采用本文中提出的代理模型结构优化方法, 确定Colebrook-White公式的最佳多拟合项式, 将计算结果与Davidson提出算法的计算进行对比, 以验证算法的有效性. 计算100个数据点下Colebrook-White公式的值与多项式近似值之间的最大绝对误差值以及100个数据点的绝对误差值之和. 进而与Davidson的多项式拟合结果进行比较. 结果表明, Davidson的拟合多项式与样本数据点之间的最大绝对误差值为0.000194, 各数据点的绝对误差值之和为0.00297. 本文提出算法获取的拟合多项式与数据点之间的最大绝对误差值为0.000133, 各数据点的绝对误差值之和为0.00356. 所以Davidson提出的遗传规划方法和本文提出的方法可以获得非常相似的结果, 不同之处在于本文提出的代理模型结构优化算法不需要再额外定义规则基和使用树的概念, 相对于Davidson提出的遗传规划算法使用更为简单.

3.2.2 多峰高斯函数验证

本文采用如图2所示的函数对该算法进行进一步验证. 该函数可以较好地测试出代理模型结构优化算

图2 多峰高斯函数

Figure 2 Multi-peak Gaussian function.

法的效果, 因为这个函数具有尖锐的峰值, 很难进行多项式拟合.

使用代理模型结构优化方法计算多项式函数时, 设置多项式阶次最大为30, 多项式的最大项数为300, 由代理模型结构优化方法(最高阶次为20阶, 项数为230)和最小二乘函数(870项)获得的拟合结果如图3所示.

根据图3比较可知, 代理模型结构优化方法可以在设定的最高阶次和最大项数上求出具有较好模型精度的拟合多项式结构. 而对于直接采用最小二乘方法, 根据设定的最高阶次进行拟合的结果显示, 并不一定是多项式阶次越多、项数越高, 拟合效果越好, 图3(b)展示了这样的结果. 所以, 根据该仿真验证结果可以得知, 本文提出的代理模型结构优化方法可以在设置的多项式最高阶次和最大项数限制下, 获取具有较好拟合优度的拟合多项式结构.

4 面向控制的飞行器代理模型结构优化

4.1 面向控制代理建模

以高超声速概念飞行器为例采用本文提出的多项式结构优化方法进行高超声速飞行器纵向非线性气动数据拟合. 阻力系数 C_D 、升力系数 C_L 和俯仰力矩系数 C_m 表达形式如下所示:

$$\begin{aligned} C_D &= C_D(Ma, \alpha, \delta_e), \\ C_L &= C_L(Ma, \alpha, \delta_e), \\ C_m &= C_m(Ma, \alpha, \delta_e), \end{aligned} \quad (24)$$

图3 对比图. (a) 原函数和GA多项式对比图(30阶); (b) 原函数和最小二乘多项式对比图(30阶)

Figure 3 Comparison diagram. (a) Comparison diagram of original function and GA polynomial (order 30); (b) comparison diagram of original function and least square polynomial (order 30).

式中, δ_e 为升降舵偏角. 由CFD计算纵向气动系数的各参数范围如下:

$$Ma = 1.2, 1.5, 2, 4, 6, 7;$$

$$-3^\circ \leq \alpha \leq 15^\circ (\Delta\alpha = 3^\circ);$$

$$-20^\circ \leq \delta_e \leq 20^\circ (\Delta\delta_e = 2^\circ).$$

运用代理模型结构优化方法得到满足精度 $(1-PPS)_c=0.9$ 要求的 C_D , C_L , C_m 解析表达形式. 设定变量 Ma , α 和 δ_e 的最高阶次均为2. 在此以马赫数2~7范围内的数据作为样本数据, 将马赫数1.2~7范围内的所有数据作为检测数据.

列出最高阶次限制下的变量所有组合形式, 并去除其中降低预测精度的项, 获取最高精度代理模型形式 X_1 , 如式(25)所示(遍历方式). 式(26)为精度 $(1-PPS)_c=0.9$ 要求下采用本文提出的代理模型结构优化方法, 得到式(26)所示的最佳代理模型形式 X_2 (注意: α 和 δ_e 的单位为度).

$$\begin{aligned} C_D(Ma, \alpha, \delta_e) = & c_0 + c_1\alpha/Ma + c_2\delta_e/Ma + c_3\alpha^2\delta_e \\ & + c_4\alpha\delta_e/Ma^2 + c_5\delta_e^2/Ma + c_6\alpha \\ & + c_7\delta_e^2/Ma^2 + c_8\alpha^2/Ma + c_9\delta_e^2 \\ & + c_{10}\alpha^2\delta_e^2/Ma^2 + c_{11}/Ma^2 + c_{12}/Ma \\ & + c_{13}\alpha^2 + c_{14}\alpha^2/Ma^2 + c_{15}\alpha^2\delta_e^2/Ma \\ & + c_{16}\alpha^2\delta_e^2 + c_{17}\delta_e/Ma^2 \\ & + c_{18}\alpha^2\delta_e/Ma + c_{19}\delta_e/Ma, \\ C_L(Ma, \alpha, \delta_e) = & c_0 + c_1\delta_e^2/Ma + c_2\delta_e^2 + c_3\alpha\delta_e^2 + c_4\alpha^2 \\ & + c_5\alpha\delta_e^2/Ma^2 + c_6\alpha/Ma + c_7\alpha^2\delta_e^2/Ma^2 \\ & + c_8\alpha\delta_e/Ma^2 + c_9\delta_e/Ma^2 \end{aligned} \quad (25)$$

$$\begin{aligned} & + c_{10}\alpha^2\delta_e/Ma^2 + c_{11}\alpha^2\delta_e/Ma + c_{12}\delta_e \\ & + c_{13}\delta_e/Ma + c_{14}\alpha\delta_e^2/Ma + c_{15}\alpha/Ma^2, \\ C_m(Ma, \alpha, \delta_e) = & c_0 + c_1\delta_e + c_2\alpha\delta_e/Ma + c_3/Ma \\ & + c_4\alpha\delta_e/Ma^2 + c_5\alpha/Ma + c_6\alpha\delta_e^2/Ma \\ & + c_7\alpha\delta_e + c_8\alpha/Ma^2 + c_9\delta_e^2/Ma^2 \\ & + c_{10}\alpha^2\delta_e/Ma + c_{11}\alpha^2/Ma^2 \\ & + c_{12}\delta_e^2/Ma + c_{13}\alpha + c_{14}\alpha^2/Ma \\ & + c_{15}/Ma^2 + c_{16}\alpha\delta_e^2 + c_{17}\alpha/Ma, \\ C_D(Ma, \alpha, \delta_e) = & c_0 + c_1/Ma + c_2\alpha + c_3\alpha^2 + c_4\alpha/Ma, \\ C_L(Ma, \alpha, \delta_e) = & c_0 + c_1\alpha/Ma, \\ C_m(Ma, \alpha, \delta_e) = & c_0 + c_1/Ma + c_2/Ma^2 + c_3\alpha \\ & + c_4\alpha^2 + c_5\delta_e + c_6\alpha/Ma. \end{aligned} \quad (26)$$

表1和表2为 X_1 , X_2 和Kriging模型形式下样本空间内和样本空间外的 $(1-PPS)$, 其值越接近于1, 模型精度越高. 表3展示了分别采用模型结构优化方法、Kriging建模方法, 以及通过遍历各多项式模型组合形式惩罚预测值筛选出满足要求的模型结构的耗时.

根据式(26)和表1中对应的拟合精度可以得知本文所提出的算法可在保证模型精度要求的基础上降低

表1 代理模型精度比较(样本内部测试)

Table 1 Surrogate model accuracy comparison (in-sample testing)

模型形式	C_D	C_L	C_m
X_1	0.9995	0.9974	0.9981
X_2	0.9062	0.9634	0.9022
Kriging	0.9996	0.998	0.9983

表 2 代理模型精度比较(样本外部测试)

Table 2 Surrogate model accuracy comparison (out of sample testing)

模型形式	C_D	C_L	C_m
X_1	0.904	0.8997	0.9
X_2	0.87	0.892	0.8875
Kriging	0.74	0.82	0.668

表 3 运算时间

Table 3 Operation time

模型算法	计算 C_D 耗时 (s)	计算 C_L 耗时 (s)	计算 C_m 耗时 (s)
Kriging模型	0.04	0.0038	0.0052
遍历方法	25.1	18.3	19.3
代理模型结构优化算法	10.3	4.7	6.1

模型的复杂程度, 同时可以筛选出对气动系数影响较大的因素. 并且根据式(25)和(26)模型表达形式以及表1中拟合精度对比可以得知代理模型形式 X_2 较为简洁, 且与高精度模型形式 X_1 的拟合精度相差不大.

根据表3可知基于智能算法的代理模型结构优化方法耗时介于构建Kriging模型和人为筛选或遍历的方法耗时之间. 此外, Kriging模型本质上接近于插值模型, 其在样本空间内的插值更精确, 但外部插值的误差较大. 而多项式模型更具有规律性, 注重数据的变化趋势, 相对于Kriging模型器外部插值的误差更小, 所以得到表2所示的样本空间外部数据的预测精度.

图4为不同 Ma 和 α 条件下CFD气动数据与Kriging模型、 X_1 拟合模型、 X_2 拟合模型获得预测数据的三维对比图.

从图4可以看出, 由Kriging模型获得的预测数据具有很好的内部精确性, 但是预测能力较差; 而通过优化PPS值筛选出的代理模型 X_2 可以兼顾内部精度和预测能力. 其中通过结合鸽群搜索策略的代理模型结构优化方法所获得的代理模型结构 X_2 相较于模型 X_1 更为简单、获取最终模型结构耗时短, 并且拟合效果相差不大.

根据仿真结果可以得出, 通过本文提出的代理模型结构优化方法可以较快地找到一种满足内部精度和预测能力要求的代理模型形式.

图 4 (网络版彩图) C_{D0} 、 C_{L0} 和 C_{m0} 三维图形

Figure 4 (Color online) Three-dimensional figure of C_{D0} , C_{L0} and C_{m0} .

表4给出了不同 Ma 和 α 条件下, 阻力系数部分仿真数据和拟合数据对比结果, 可以得出在不同马赫数和迎角下的拟合误差均在5%以内, 拟合精度较高。

根据数值仿真结果可以看出, 本文提出的基于鸽群搜索策略的代理模型结构优化方法, 可以基于给定的气动数据构造出简洁的、满足拟合精度要求的高超声速飞行器全局非线性气动代理模型形式, 并且代理模型预测数据和仿真数据进行分析比较, 其误差小于5%。

表 4 C_{D0} 的CFD数据与拟合数据

Table 4 CFD data and fitting data of C_{D0}

Ma	α ($^{\circ}$)	CFD数据	拟合数据	误差 (%)
2	-6	0.0292	0.0291	0.17
2	0	0.0124	0.0119	4.51
2	4	0.0164	0.0162	1.42
2	8	0.0341	0.0332	2.6
4	-6	0.0191	0.0192	0.24
4	0	0.0082	0.0081	0.58
4	4	0.0117	0.0116	0.68
4	8	0.0233	0.0237	1.68
6	-6	0.0156	0.0156	0.069
6	0	0.0064	0.0064	1.06
6	4	0.0091	0.0093	1.85
6	8	0.0195	0.0194	0.84

4.2 控制验证

为进一步验证所建立的代理模型是否可以用于飞行器的控制设计, 在此分别基于飞行器原始数据和代理模型 X_2 设计鲁棒跟踪控制器。仿真中, 飞行器的初始状态为飞行马赫数6, 高度为25 km。飞行器的控制目标为跟踪60 kPa的等动压轨迹至26 km巡航高度。考虑飞行器控制饱和和限制: 升降舵偏转角 $\delta_e \in [-20^{\circ} \ 20^{\circ}]$, 发动机燃油当量比限制 $\phi \in [0 \ 1]$ 。分别基于飞行器原始数据和代理模型 X_2 设计鲁棒跟踪控制器进行仿真的结果如图5所示。图中显示了期望轨迹、基于原始模型设计控制器的跟踪轨迹和基于代理模型 X_2 设计控制器的跟踪轨迹。

根据图5所示控制结果可知, 基于简化代理模型 X_2 设计的鲁棒跟踪控制效果与基于原始模型设计的跟踪控制效果非常接近, 并且可以较为精确地控制飞行器达到指令信号, 说明该代理模型能够反映出飞行器气动特性随飞行状态的变化。飞行器代理模型 X_2 非常适合用于控制系统设计, 且具有较好的闭环性能。

5 结论

利用鸽群算法的搜索思想, 对飞行器外形或气动等代理模型结构进行优化。基于数据驱动的方式获取飞行器代理模型, 更能确保代理模型与数据趋势的一致性, 并能从模型结构中明确影响飞行器性能的主要

图 5 (网络版彩图)控制结果图

Figure 5 (Color online) Control result figure.

因素.

本文基于多目标优化准则——惩罚预测值, 提出的代理模型结构优化方法, 可在满足模型精度和预测性的要求下, 获得简洁的代理模型形式. 此外, 本文结合鸽群算法的搜索思想, 进一步改进飞行器代理模型结构优化方法, 解决了高超声速飞行器外形或全局气

动等代理模型难以确定的问题.

基于鸽群搜索策略的代理模型结构优化方法实现过程简单, 适合于大样本下代理模型的建立, 能够快速获得保证模型精度的代理模型结构. 相较于其他模型结构优化算法, 本文所提出的优化方法具有更高的拟合效率, 能够满足高超声速飞行器的工程应用.

参考文献

- 1 Liu Y B, Chen B Y, Xiao D B, et al. A parametric model for control integrated design of hypersonic vehicles (in Chinese). *Sci Sin Tech*, 2016, 46: 1024–1038 [刘燕斌, 陈柏屹, 肖地波, 等. 高超声速飞行器面向控制一体化迭代设计的参数化模型. *中国科学: 技术科学*, 2016, 46: 1024–1038]
- 2 Jameson A, Martinelli L, Pierce N A. Optimum aerodynamic design using the Navier-Stokes equations. *Theor Comput Fluid Dyn*, 1998, 10: 213–237
- 3 Chernukhin O, Zingg D W. Multimodality and global optimization in aerodynamic design. *AIAA J*, 2013, 51: 1342–1354
- 4 Hoyle N, Bressloff N W, Keane A J. Design optimization of a two-dimensional subsonic engine air intake. *AIAA J*, 2006, 44: 2672–2681
- 5 Shi Z W, Huang D, Wu G X, et al. Effects of coupled motion unsteady aerodynamic model on flight characteristics simulation of aircraft (in Chinese). *Chin J Aeronaut*, 2008, 6: 1424–1428 [史志伟, 黄达, 吴根兴, 等. 耦合运动非定常气动模型对飞机飞行特性仿真的影响. *航空学报*, 2008, 6: 1424–1428]
- 6 Bolender M A, Doman D B. Nonlinear longitudinal dynamical model of an air-breathing hypersonic vehicle. *J Spacecraft Rockets*, 2007, 44: 374–387
- 7 Xiong Y H, Liu Y, Zhao X G, et al. Analysis of cavitation performance of an aviation fuel pump based on surrogate model (in Chinese). *Chin J Aeronaut*, 2016, 37: 2952–2960 [熊英华, 刘影, 赵兴安, 等. 基于代理模型的航空燃油泵空化性能分析. *航空学报*, 2016, 37: 2952–2960]
- 8 Wang J, Zhang S. Variable gain observer based output feedback control for hypersonic vehicles (in Chinese). *J Astronaut*, 2019, 40: 543–553 [王锦, 张伸. 基于变增益观测器的高超声速飞行器输出反馈控制. *宇航学报*, 2019, 40: 543–553]
- 9 Lu Y, Shun Y, Lu K F, et al. Fuzzy adaptive control for near-space hypersonic vehicles with saturation restraint of inputs (in Chinese). *J Astronaut*, 2018, 39: 986–994 [路遥, 孙友, 路坤峰, 等. 近空间高超声速飞行器输入饱和和抑制模糊自适应控制. *宇航学报*, 2018, 39: 986–994]
- 10 Zhang Z H, Yang L Y, Shen G Z, et al. Switching LPV control method in wide flight envelope for hypersonic vehicles (in Chinese). *J Astronaut*, 2012, 33: 1706–1716 [张增辉, 杨凌宇, 申功嶂, 等. 高超声速飞行器大包线切换LPV控制方法. *航空学报*, 2012, 33: 1706–1716]
- 11 Wei P, Gao C, Jing W. Longitudinal aerodynamic coefficients estimation and identifiability analysis for hypersonic glider controlled by moving mass. *Int J Aeronaut Space Sci*, 2019, 20: 31–43
- 12 Jameson A. Aerodynamic design via control theory. *J Sci Comput*, 1988, 3: 233–260
- 13 Han Z H. Kriging surrogate model and its application to design optimization: A review of recent progress (in Chinese). *J Astronaut*, 2016, 37: 3197–3225 [韩忠华. Kriging模型及代理优化算法研究进展. *航空学报*, 2016, 37: 3197–3225]
- 14 Iuliano E, Quagliarella D. Application of surrogate-based optimization techniques to aerodynamic design. In: Minisci E, Vasile M, Periaux J, et al., eds. *Advances in Evolutionary and Deterministic Methods for Design, Optimization and Control in Engineering and Sciences. Computational Methods in Applied Sciences*, vol 48. Cham: Springer, 2019
- 15 Koziel S, Leifsson L. Surrogate-based aerodynamic shape optimization by variable-resolution models. *AIAA J*, 2013, 51: 94–106
- 16 Klein V, Batterson J G, Murphuy P C. Determination of airplane model structure from flight data by using modified stepwise regression. NASA Technical Report, 1981. 1–48
- 17 Hall Jr. W E, Gupta N K. System Identification for nonlinear aerodynamic flight regimes. *J Spacecraft Rockets*, 1977, 14: 73–80
- 18 Bai B, Xu M, Zhu X P, et al. Nonlinear aerodynamic modeling using on orthogonal polynomials (in Chinese). *Flight Dyn*, 2013, 31: 398–401 [白斌, 徐敏, 祝小平, 等. 正交多项式在非定常气动建模上的运用. *飞行力学*, 2013, 31: 398–401]
- 19 Davidson J W, Savic D, Walters G A. Method for the identification of explicit polynomial formulae for the friction in turbulent pipe flow. *J HydrolInf*, 1999, 1: 115–126

- 20 Koza J R. Genetic Programming: On the Programming of Computers by Means of Natural Selection. Cambridge: The MIT Press, 1994. 69–73
- 21 Banzhaf W, Koza J R, Ryan C, et al. Genetic programming. *IEEE Intell Syst*, 2000, 15: 74–84
- 22 Stone M. Cross-validatory choice and assessment of statistical predictions. *J R Statist Soc-Ser B (Methodological)*, 1974, 36: 111–133
- 23 Johnson R W. An Introduction to the Bootstrap. *Teach Stat*, 2001, 23: 49–54
- 24 Duchon J. Splines minimizing rotation-invariant semi-norms in Sobolov spaces. In: Schempp W, Zeller K, eds. *Constructive Theory of Functions of Several Variables*. Lecture Notes in Mathematics, vol 571. Berlin, Heidelberg: Springer, 1977. 85–100
- 25 Arlot S, Celisse A. A survey of cross-validation procedures for model selection. *Statist Surv*, 2010, 4: 40–79
- 26 Queipo N V, Haftka R T, Shyy W, et al. Surrogate-based analysis and optimization. *Prog Aerosp Sci*, 2005, 41: 1–28
- 27 Kohavi R. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: *IJCAI’95 Proceedings of the 14th International Joint Conference on Artificial Intelligence*. 1995. 1137–1143
- 28 James G, Witten D, Hastie T, et al. *An Introduction to Statistical Learning*. Berlin: Springer, 2013
- 29 Nguyen H M, Couckuyt I, Knockaert L, et al. An alternative approach to avoid overfitting for surrogate models. In: *Proceedings of the 2011 Winter Simulation Conference*. Phoenix, 2011. 2760–2771
- 30 Viana F A C, Venter G, Balabanov V. An algorithm for fast optimal Latin hypercube design of experiments. *Int J Numer Meth Engng*, 2010, 82: 135–156
- 31 Zhang Y P. Improvement of pigeon-inspired optimization algorithm and its application in hypersonic flight control (in Chinese). Dissertation for Master’s Degree. Nanjing: Nanjing University of Aeronautics and Astronautics, 2017 [张亚平. 鸽群智能算法的改进及其在高超声速飞行控制中的应用. 硕士学位论文. 南京: 南京航空航天大学, 2017]

Optimization algorithm of the surrogate model structure based on pigeon swarm search strategy

CAO Rui¹, LIU YanBin^{2,3}, SHEN HaiDong², XU Liang¹ & LU YuPing¹

¹ College of Automation, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;

² College of Astronautics, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;

³ State Key Laboratory of Virtual Reality Technology and Systems, Beijing University of Aeronautics and Astronautics, Beijing 100191, China

The hypersonic vehicle has problems with multiple systems coupling and multivariate design. Hence, it is difficult to determine the surrogate model structure of the hypersonic vehicle under larger samples. To solve this problem, this paper proposes a surrogate model structure optimization method based on the idea of PIO algorithm. The method can independently search for a polynomial surrogate model structure that satisfies the accuracy and prediction performance requirements. Through comparative analysis, utilizing this method outperforms Davidson’s genetic programming algorithm. Furthermore, it was applied to the global aerodynamic data fitting and control design of a hypersonic vehicle, and the simulation results reveal that the error of the prediction data obtained by this method was less than 5%, which has a good fitting effect and can meet the engineering application requirements.

surrogate modeling, hypersonic vehicle, flight control, optimize design, PIO algorithm

doi: [10.1360/SST-2019-0277](https://doi.org/10.1360/SST-2019-0277)