

火箭协同优化中的气动代理模型研究

沈丹, 彭博, 李舟阳, 宫宇昆, 李平岐

(北京宇航系统工程研究所, 北京 100076)

摘要: 随着运载火箭研发模式转变, 快速迭代和协同优化设计成为主要发展方向, 这就要求作为小回路论证中重要一环的气动特性计算能够实现在线输出数据, 亟需研究一种快速计算气动特性的代理模型, 代替耗时的 CFD 计算和风洞试验参与到总体优化设计中。综合比较多种快速计算途径, 选择高斯基 Kriging 插值和 BP 神经网络两种方法构建代理模型。使用脚本控制的 Cart3D 软件生成数值试验样本, 样本点精度与 Fluent 软件计算误差小于 14%。通过样本点训练、内参优化和加点策略, 最终获得相对误差小于 10% 的代理模型, 能够实现给定外形参数在线秒级输出气动数据, 极大地推动了气动计算在总体论证中的作用。

关键词: 运载火箭; 总体优化; 气动计算; 代理模型

中图分类号: V421

文献标识码: A

文章编号: 2096-4080 (2020) 05-0044-07

Research on Aerodynamic Surrogate Modeling for Launch Vehicle Collaborative Optimization

SHEN Dan, PENG Bo, LI Zhouyang, GONG Yukun, LI Pingqi

(Beijing Institute of Astronautical Systems Engineering, Beijing 100076, China)

Abstract: With the transformation of launch vehicle R&D mode, rapid iteration and collaborative optimization design have become a major trend for the research. This requires that aerodynamic characteristics calculation, which is an important part of the conceptual design, can supply real-time data online. Therefore, it is necessary to develop a surrogate model that can calculate aerodynamic characteristics rapidly, in place of time-consuming CFD methods and wind tunnel experiments for overall design optimization. This paper compared a variety of calculation methods comprehensively, and chose two methods: Gaussian Kriging interpolation and BPNN, to build a surrogate model. A script program was used to drive Cart3D to generate a set of numerical experiment samples. The relative error between the sample value and the result obtained by Fluent was less than 14%. Through sample point training, internal parameter optimization, and point addition strategies, a surrogate model with a relative error of less than 10% was finally obtained. It can output real-time aerodynamic characteristics data for a certain shape, which is significant for aerodynamic design to play its role in the overall design of launch vehicle.

Key words: Launch vehicle; Overall optimization; Aerodynamic calculation; Surrogate model

收稿日期: 2020-01-28; 修订日期: 2020-05-21

基金项目: 装备发展部领域基金 (6140246030216HT19001)

作者简介: 沈丹 (1986-), 女, 高级工程师, 主要研究方向为运载火箭气动与热环境设计。

E-mail: shend_journal@126.com

0 引言

随着运载火箭研发模式的转变,快速迭代和协同优化设计成为主要发展方向。特别是在总体小回路论证时,涉及弹道、气动和姿控等专业,需要从大量构型中筛选可行方案,气动计算对整个方案的设计有较大影响,为实现快速论证,需要气动特性计算实现在线输出数据。而当前运载火箭的气动特性主要依靠风洞试验和 CFD 仿真计算得到,需要耗费较多的资源和时间周期,无法满足快速论证和优化的需求,亟需研究一种快速计算运载火箭气动特性的方法,这一过程对精度要求相对较低,但对速度要求相对较高。

在 CFD 方法出现之前,运载火箭的气动设计主要依靠工程算法。然而,工程算法基于无黏、有势、小扰动等假设,因此对使用范围有严格的限制。一般不单独使用某种公式来给出气动特性数据,需要多种公式和修正手段复合求解,这些复合的方法打包形成软件,例如著名的美国空军 DATCOM 软件包,在有翼导弹快速设计中发挥着重要作用。然而, DATCOM 软件中没有适用于捆绑助推器的复杂外形经验算法^[1-2],因此无法引入到大型运载火箭的协同优化当中。

求解线化位流 PG 方程的面元法,只需要对飞行器表面进行网格划分,建模复杂度较小,由于面元法求解的是线性方程组,因此其计算速度很快。当前较成熟和通用的面元法代码是 NASA 为波音公司开发的 PANAIR^[3]。但由于线化位势方程框架本身的假设,它不可处理跨声速情况,也不适合用于处理黏性效应和气流分离显著的情况,因此不适宜引入到大型运载火箭的协同优化当中。

近年来,随着多学科优化 (Multidisciplinary Design Optimization, MDO) 和气动外形优化 (Aerodynamic Shape Optimization, ASO) 的发展,选择近似的数学模型,将气动特性对外形参数的响应看成黑箱问题,采用样本结果对黑箱问题进行训练和辨识,进行气动特性分析的方法被广泛采用,形成了多种类型的代理模型^[4]。本文针对运载火箭外形变化的特点,对气动参数拟合的代理模型进行研究。

1 代理模型构建途径

代理模型通过对若干采样样本 (不同的火箭

外形) 气动计算数据进行多次分析,得到对部分或全部设计空间的模拟,从而得到气动隐式函数模型的显式函数近似表达式,其流程如图 1 所示,主要步骤为:

1) 确定设计变量 x_1, x_2, \dots, x_m , 确定设计空间 (设计变量的上下限)。对于运载火箭气动计算,设计变量是标准火箭外形的一系列拓扑类型和尺寸参数,设计空间为总体设计对火箭外形的约束范围;

2) 试验设计,选择取样策略,确定每个设计变量的水平数及样本点个数。在设计空间中确定构造模型所用的样本点 \bar{X}^i , 其中 $\bar{X}^i = (x_1, x_2, \dots, x_m)$, 是一个 m 维的空间点,对应着火箭外形尺寸的 m 个变量;

3) 本文针对气动计算外形需要进行前处理操作,即生成几何模型并划分空间网格;

4) 利用数值试验的方法确定在样本点 x^i 处的系统响应值 y^i , 并利用它们构成一系列样本对 $\{(x^i, y^i), i = 1, 2, \dots, m\}$, 其中 $y^i = (y_1, y_2, \dots, y_q)$, 是一个 q 维响应值,针对火箭气动特性, y^i 指升力系数、阻力系数、压心系数等期望得到的计算结果;

5) 选取一部分样本对做为训练样本,采用适当的近似方法构建代理模型,确定代理模型 $f(x^i)$ 的参数,使 $f(x^i)$ 与 y^i 近似程度最好,剩余样本用做检验模型精度。如模型预测精度满足设计要求则结束,否则修改模型参数或者增加样本,直到其预测精度满足要求为止。

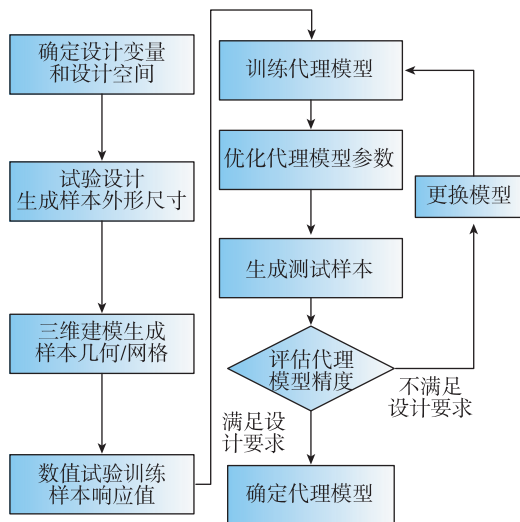



图 1 代理模型的构建途径

Fig. 1 Construction approach of surrogate model

2 设计空间

大型运载火箭一般采用捆绑助推器的构型,我国现役和在研的运载火箭往往采用2个或4个助推器,本文示例的是四助推器的构型,如图2所示。



RF-整流罩球头半径; L1-头部第一锥长度(到实际尖点); A1-头部第一锥锥角; L2-头部第二锥长度; A2-头部第二锥锥角; LF-头部直筒段长度; DF-直径; L3-头部倒锥长度; LC1-芯级直筒一长度; DC1-直径; L4-芯级过渡段长度; LC2-芯级直筒二长度; DC2-直径; RZ-助推球头半径; LZ-助推顶点/全箭顶点距离; LZ1-助推第一锥长度(到助推顶点); AZ1-助推第一锥锥角; LZ2-助推柱段长度; DD-助推直径; H-芯助间隙; BB-尾翼弦长

图2 设计变量释义

Fig. 2 Definition of design variables

根据总体设计各专业经验,形成如下约束条件,最终形成设计空间:

- 1) 芯级直径大于助推直径;
- 2) 整流罩直径与相邻芯级直径比范围: 1~1.6;
- 3) 相邻芯级直径比例(芯级下段直径除以上段直径): 1~1.5;
- 4) 助推器长度与全箭总长的比例: 25%~65%。

3 试验设计

试验设计(Design of Experiments, DOE)为代理模型构建提供训练和测试样本,其合理与否关系到代理模型的预测精度,采样样本点要尽量充满整个空间,应该是整个设计空间的具有代表性的典型子集,具有良好的均匀性和正交性。由于本文中的设计空间是16维的高维空间,采用拉丁超立方试验更为适宜。拉丁超立方试验设计是专门为仿真试验提出的一种试验设计类型。它是一种充满空间的设计,使输入组合相对均匀地填满整个试验区间,并且每个变量只水平使用一次。拉丁超立方试验设计具有非常好的空间填充能力,可以拟合非线性相应,即较正交试验设计而言,可以用同样的点数研究更多的数据组合^[5]。

假设设计问题共有 r 个因子,每个因子分为 n 个间距,每个间距里面取一个值,则每个因子有 n

个水平值,拉丁方设计表是有 r 个因子的 n 个水平值组成的一个 $n \times r$ 矩阵,算法可用下式描述

$$x_j^{(i)} = \frac{\pi_j^{(i)} + U_j^{(i)}}{k} \quad (1)$$

其中, $1 \leq j \leq n$, $1 \leq i \leq k$, k 是水平数, n 是因子个数, U 是区间 $[0, 1]$ 上的随机数, π 是序列 $0, 1, \dots, k-1$ 的一个排列。下标 j 是因子索引,上标 (i) 是水平索引。抽样时首先将 $[0, 1]$ 区间划分成 N 个互不重叠的子区间,然后在每个子区间中进行独立的随机抽样。

4 样本生成

为避免样本生成耗费过长的周期,同时保持一定的工程应用精度,本文使用高精度无黏分析软件Cart3D对飞行器进行气动特性分析。该软件首先在全流场域生成各向尺寸一致的粗糙网格,再根据模型结构在物面附近自动逐步加密得到尺寸合适的流场网格,程序能通过定义网格区域及网格密度,自动捕捉模型的几何特征,快速生成笛卡尔网格(图3),极大地压缩网格生成时间,最后求解Euler方程得到流场结果。该方法网格生成效率高,流场求解速度快,能大大缩短计算时间。为高效批量生成几何模型并划分网格,采用程序控制的脚本模式运行上述过程。




图 3 样本生成中 Cart3D 计算网格
Fig. 3 Cart3D mesh

为验证 Cart3D 软件的计算精度，应用国内某型经典捆绑运载火箭标准外形使用 Cart3D 和 Fluent 软件分别开展计算并比较，结果如表 1 所示。针对标准外形，在各马赫数下 Cart3D 与 Fluent 的计算误差最大约 13.4%（升力系数， $Ma = 3.0$ ，攻角 $\alpha = 0^\circ$ ），平均误差在 10% 以内，可以用于样本库的建立。

表 1 Cart3D 与 Fluent 结果相对误差

Tab. 1 Relative error between Cart3D and Fluent results

Ma	C_l	CM_z	X_{cp}	Ma	C_l	CM_z	X_{cp}
0.6	0.073 624	0.061 268	-0.036 92	1.5	0.070 683	0.051 319	-0.032 24
0.8	0.051 915	0.051 703	-0.031 49	2.0	0.117 06	0.096 728	-0.022 42
0.9	0.007 124	-0.006 06	-0.044 47	3.0	0.134 308	0.128 502	0.000 328
1.0	0.013 38	-0.044 84	-0.06719	5.0	0.094 685	0.101 424	0.010 703
1.2	0.045 764	0.028 801	-0.034 09	7.0	0.062 881	0.070 671	0.008 768
				平均值	0.067 142	0.053 952	-0.024 9

(超过 10% 的标注为红色)

5 模型研究

常用的代理模型有：多项式响应面模型、径向基 RBF 插值模型、Kriging 模型、SVM 支持向量机、BP 神经网络等，表 2 给出了上述几种近似模型

及其优缺点^[6]。由于本文研究的对象维度高、非线性较强，要求拟合方法的鲁棒性较强，因此选用了标准 Kriging 模型并使用 GA 遗传算法进行内参优化。同时选用 BP 神经网络（30×2）作为对比学习组，对 Kriging 结果进行对比评价。

表 2 基本代理模型适用性比较

Tab. 2 Applicability comparison of basic surrogate models

	优势	不足	关注点
响应面	构造简单、计算量小、收敛速度快	对多变量、非线性程度高的问题精度差	
RBF	灵活性好、结构简单、鲁棒性好、计算量也相对较少	对样本数量依赖程度高，所需样本数量大	径向函数具有各向同性，需根据实际问题进行选择
Kriging	应用广泛、模型具有鲁棒性、灵活性、有成熟代码库供二次开发	Kriging 模型的预测精度依赖于参数选取，对样本数量依赖程度高，所需样本数量大	训练样本数量应足够多，并且整齐、均匀
SVM	样本数量要求少、应用广泛，可解决复杂非线性问题，适合样本点数据存在噪声的情况	计算量略大，训练速度较慢	选择对非线性问题适应性强的核函数
神经网络	应用广泛，灵活性好，泛化能力强	有可能出现过学习的问题	权衡神经网络层数与近似能力之间的关系

5.1 Kriging-GA 模型

给定 n 个样本点 $S = [s^{(1)}, s^{(2)}, \dots, s^{(n)}]^T$ ，其中 $s^{(i)}$ 16 维向量（火箭外形参数个数），对应的目

标函数值为 $Y = [y^{(1)}, y^{(2)}, \dots, y^{(n)}]^T$ ，其中 $y^{(i)}$ 是 3 维向量（升力系数、阻力系数、压心系数 3 个变量）。设计变量为 x ，对应的目标函数为 y 。

Kriging 模型由全局模型和局部偏差模型构成^[7-8]

$$y = F(\beta, x) + z(x) \quad (2)$$

$z(x)$ 的协方差矩阵表明其局部偏离的程度, 形式如下

$$\text{cov}(z(\omega), z(x)) = E[z(\omega)z(x)] = \sigma^2 R(\theta, \omega, x) \quad (3)$$

式中, $R(\theta, \omega, x)$ 是表示任意两个样本点 x_i, x_j 之间的相关函数, 这里采用高斯相关函数

$$R(x_i, x_j) = \prod_k^n \exp(-\theta_k |x_k^i - x_k^j|^2) \quad (4)$$

建立 $y(x)$ 的近似响应 $\bar{y}(x)$ 关于观测点 x 的表达式

$$\bar{y}(x) = \bar{\beta} + \mathbf{r}^T(x)R^{-1}(y - F\bar{\beta}) \quad (5)$$

$\bar{\beta}$ 通过如下估计得出

$$\bar{\beta} = (\mathbf{F}^T R^{-1} \mathbf{F})^{-1} \mathbf{F}^T R^{-1} \mathbf{Y} \quad (6)$$

设 $f(x)$ 为常量, $\bar{\beta}$ 简化为标量, 对方差 σ^2 对数取负令其取得最大值

$$-\frac{n \ln(\sigma^2) + \ln |R(\theta)|}{2}$$

求解上式的非线性无约束优化问题, 使用 MATLAB 工具中的遗传算法 GA (Genetic Algorithm) 对 16 维内参 $\theta_k (k=1, 2, \dots, k)$ 进行全局寻优, 从而得到最优插值的 Kriging 模型。Kriging 模型可以在全局范围内提供对预估值值的误差评估, 如式 (7) 所示。由此可以获得模型预测不确定性最大的位置^[9], 并在该位置上添加新的样本点。

$$\bar{s}(x) = \sigma \left[1 - \boldsymbol{\psi}^T \boldsymbol{\Psi}^T \boldsymbol{\psi} + \frac{1 - \mathbf{I}^T \boldsymbol{\Psi}^{-1} \boldsymbol{\psi}}{\mathbf{I}^T \boldsymbol{\Psi}^{-1} \mathbf{I}} \right] \quad (7)$$

在设计空间中随机取 2 000 个外形参数, 按上式计算全局偏差, 如图 4 所示。将均方误差 0.02 作为红线, 将红线之上的测试点进行标记, 使用 Cart3D 计算并加入到样本库中。




图 4 随机测试点的均方误差

Fig. 4 RSME of random test points

5.2 BPNN 模型

BP 神经网络 (Back Propagation neural network, BPNN) 是众多神经网络算法中应用最为广泛的一种, 在神经网络的应用中, 80% ~ 90% 的人工神经网络模型都是采用 BP 网络或者它的变化形式^[10]。对于火箭气动特性而言, 诸参数具有高度非线性, 因而拟合工具的非线性十分重要。本文采用两个隐含层的结构, 每层含 30 个节点, 如图 5 所示。




图 5 BP 网络拓扑结构图

Fig. 5 BP network topology

使用交叉验证方法^[11]对样本点进行检验, 例如针对四助推器在 $Ma=1.5, a=4^\circ$ 这一个工况的 380 个样本, 每次取 1 个作为测试点, 取剩余 379 个点作为训练点, 可以得到图 6 中的误差分布规律, 误差符合正态分布。但误差的分布范围很大, 个别点的误差高达 100% ~ 400% 以上 (红色圈出), 使用其余样本点训练得到的网络在这些点上无效, 由此可以推断这些样本点与其余样本点具有较大差异, 如果数值试验结果可信, 则需要在这些点周围增加样本。

在加点位置围绕其中心, 以原值 50% 为半径的超球面作为加点空间, 使用均匀试验设计进行加点, 对每个目标点周围以同种方式加 12 个“卫星点”, 将样本点规模扩充为 500 个。对加点后的样本库再次进行交叉验证, 误差分布如图 7 所示。由此可见, 加点之后的误差分布更为集中, 标准差减少 34%, 加点效果明显。

5.3 结果分析

选取 490 个样本点作为训练组, 按上述方法得到对于气动特性的估计即升力系数、阻力系数、压心系数 (参考长度为样本的箭体长度, 参考面

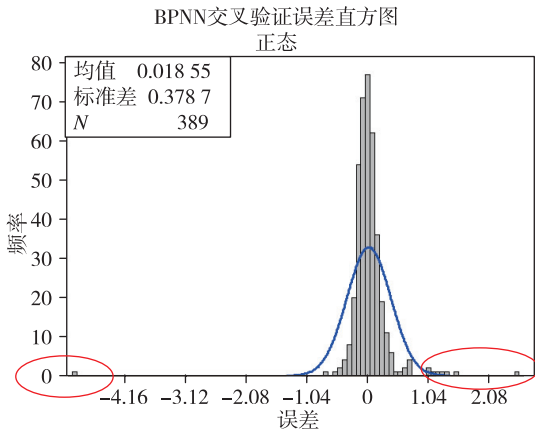


图 6 交叉验证误差分布

Fig. 6 Cross-validation error distribution

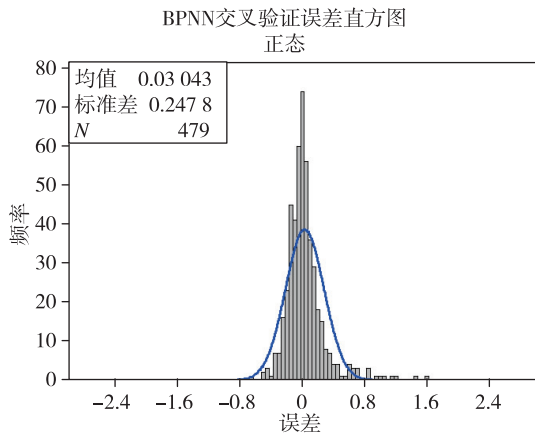
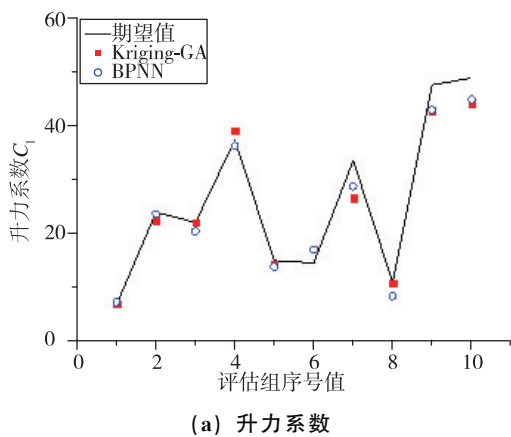



图 7 加点后的交叉验证误差分布

Fig. 7 Cross-validation error distribution after adding points


积为 1 m^2), 选取另外 10 个作为评估组, 则两种方法的拟合值与期望值相比较如图 8 所示, 可以看出预测值较好地落在期望值上下两侧。



(a) 升力系数



(b) 阻力系数



(c) 压心系数

图 8 评估点处的预测值

Fig. 8 Predicted value at evaluation points

根据式 (8) 对平均相对误差 (MRE) 的定义, Kriging-GA 方法和 BPNN 方法得到的代理模型在评估点集得到的误差如表 3 所示, 可以看出 Kriging 模型略优于 BPNN 模型。

$$MRE = \frac{1}{n} \sum_{i=1}^n \left| \frac{f_i - \bar{f}}{f_i} \right| \quad (8)$$

表 3 各气动输出结果相对误差

Tab. 3 Relative error of output data

	$C_l/\%$	$C_d/\%$	$X_p/\%$
Kriging-GA	7.78	8.62	4.11
BPNN	10.0	11.40	5.92

6 结论

代理模型作为保证一定精度条件下对复杂数值模型的替代, 在运载火箭总体协同优化中可发挥重要的作用。本文探索了火箭气动计算代理模

型的完整过程,采用平均相对误差指标评估代理模型的预测精度,评估结果表明:

1) 对于运载火箭外形变化引起气动特性变化这类问题,在16维变量、500个样本点规模的特定情况下,应用Kriging的误差小于BPNN;

2) 利用Kriging模型作为代理模型的方法可满足工程需求,平均相对误差小于10%。

参考文献

- [1] Vukelich S R, 万音. 导弹 DATCOM: 用部件组合法预计常规导弹的气动力[J]. 国外导弹与航天运载器, 1988(7): 6-18.
- [2] 杨维维, 陈小前, 李晓斌, 等. 通用导弹气动力计算软件 DATCOM 的开发与校验[J]. 固体火箭技术, 2006, 29(3): 161-164.
- [3] Cenko A. PANAIR Applications to complex configurations[J]. Journal of Aircraft, 2012, 20(10): 887-892.
- [4] 王丹. 飞行器气动外形优化设计方法研究与应用[D]. 西安: 西北工业大学, 2015.
- [5] 项可风, 吴启光. 试验设计与数据分析[M]. 上海: 上海科学技术出版社, 1989.
- [6] 朱雄峰. 飞行器 MDO 代理模型理论与应用研究[D]. 北京: 国防科学技术大学, 2010.
- [7] Forrester A I J, Sobester A, Keane A J. Engineering design via surrogate modelling: a practical guide[M]. Wiley, 2008.
- [8] Krige D G. A statistical approach to some basic mine valuations problems on the Witwatersrand [J]. Journal of the Chemical, 1951, 52(6): 119-39.
- [9] Vapnik V N. The nature of statistical learning theory [M]. New York: Springer-Verlag Inc, 2000.
- [10] 陈明. MATLAB 神经网络原理与实例精解[M]. 北京: 清华大学出版社, 2013.
- [11] 韩萌, 丁剑. 基于交叉验证的 3D 算法的改进与实现[J]. 计算机工程与设计, 2008, 29(14): 3738-3739.

引用格式: 沈丹, 彭博, 李舟阳, 等. 火箭协同优化中的气动代理模型研究[J]. 宇航总体技术, 2020, 4(5): 44-50.

Citation: Shen D, Peng B, Li Z Y, et al. Research on aerodynamic surrogate modeling for launch vehicle collaborative optimization [J]. Astronautical Systems Engineering Technology, 2020, 4(5): 44-50.