

文章编号:1674-8190(2022)05-059-10

# 基于POD-BPNN模型的热启动策略及其在气动代理优化中的应用

贾续毅<sup>1</sup>, 李春娜<sup>1</sup>, 常琦<sup>2</sup>, 季稳<sup>1</sup>

(1. 西北工业大学 陕西省空天飞行器设计重点实验室, 西安 710072)

(2. 火箭军装备部 装备项目管理中心, 北京 100085)

**摘要:** 传统气动优化设计需要大量CFD分析,而代理优化(SBO)方法能够有效降低CFD分析次数,但该方法并没有改变单次CFD分析时间。提出一种基于本征正交分解-反向传播神经网络(POD-BPNN)模型的热启动策略,并应用于气动代理优化。使用POD-BPNN模型对SBO中的初始样本建立从几何设计变量到流场数据的预测模型;在SBO迭代过程中,使用该模型预测新样本的流场,并将其作为CFD分析的初场,进行热启动计算,获得新样本的数据;添加新样本数据到POD-BPNN建模样本并更新模型,直到优化结束,通过案例对该策略进行对比验证。结果表明:在跨声速翼型减阻优化设计中,基于POD-BPNN的热启动策略使得单次CFD计算时间降低68%,SBO的效率整体提升37%。

**关键词:** POD;BPNN;热启动;气动优化;翼型设计

中图分类号: V211.3

DOI: 10.16615/j.cnki.1674-8190.2022.05.06

文献标识码: A

开放科学(资源服务)标识码(OSID):



## Hot-start Strategy Based on POD-BPNN Model and Its Application in Aerodynamic Surrogate-based Optimization

JIA Xuyi<sup>1</sup>, LI Chunna<sup>1</sup>, CHANG Qi<sup>2</sup>, JI Wen<sup>1</sup>

(1. Shaanxi Aerospace Flight Vehicle Design Key Laboratory, Northwestern Polytechnical University, Xi'an 710072, China)

(2. Project Management Center, PLA Rocket Force Equipment Department, Beijing 100085, China)

**Abstract:** The traditional aerodynamic optimization design requires computational fluid dynamics (CFD) analysis, and the surrogate-based optimization (SBO) method can effectively reduce the number of CFD analyses, but it cannot speed up a single CFD analysis time. A hot-start strategy using the proper orthogonal decomposition-back propagation based neural network (POD-BPNN) model is proposed, and applied in surrogate-based aerodynamic optimization. The prediction model from geometric design variables to flowfield data through the initial samples is built with SBO POD-BPNN model. During iteration of the SBO, the flowfield of a new sample is predicted by the built model, and the flowfield is used as the initial flowfield of the hot-start CFD analysis for the new sample. The new sample is used to update the POD-BPNN model until the end of the optimization. The comparison verification of proposed strategy is performed with instance. The results show that, in the aerodynamic optimization design of the transonic airfoil, the hot-start strategy based on POD-BPNN model can reduce the time of a single CFD analysis by 68%, and improve the efficiency of the SBO by 37%.

**Key words:** POD; BPNN; hot-start; aerodynamic optimization; airfoil design

收稿日期: 2021-11-02; 修回日期: 2022-02-04

基金项目: 国家自然科学基金“叶企孙”科学基金(U2141254)

通信作者: 李春娜, chunnali@nwpu.edu.cn

引用格式: 贾续毅, 李春娜, 常琦, 等. 基于POD-BPNN模型的热启动策略及其在气动代理优化中的应用[J]. 航空工程进展, 2022, 13(5): 59-68.  
JIA Xuyi, LI Chunna, CHANG Qi, et al. Hot-start strategy based on POD-BPNN model and its application in aerodynamic surrogate-based optimization[J]. Advances in Aeronautical Science and Engineering, 2022, 13(5): 59-68. (in Chinese)

## 0 引言

随着计算机技术的发展,计算流体力学(Computational Fluid Dynamics,简称CFD)成为获取高可信度气动数据的主要手段并被大量应用于气动优化设计<sup>[1-2]</sup>。梯度优化算法和启发式优化算法是当前常用的气动优化设计算法。相比于梯度优化算法,差分进化(Differential Evolution,简称DE)算法<sup>[3]</sup>、粒子群算法<sup>[4]</sup>等启发式优化算法具有更好的全局搜索能力,从而在气动优化中得到广泛使用。但是,该类算法在气动优化过程中需要进行成千上万次CFD仿真,导致优化效率低下。为了兼顾全局搜索能力和优化效率,代理优化(Surrogate-based Optimization,简称SBO)<sup>[5]</sup>应运而生。

SBO具有设计效率高、全局优化能力好、鲁棒性高等特点,在具有高维设计变量、多目标等工程优化问题<sup>[6-8]</sup>中具有良好的应用前景。目前已发展了Kriging模型<sup>[5]</sup>、径向基函数(Radical Basis Function,简称RBF)<sup>[9]</sup>、多项式混沌展开<sup>[10]</sup>、神经网络<sup>[11]</sup>等多种代理模型建模方法。在气动SBO中,代理模型建立了从气动外形参数到气动力的映射关系。SBO本质上降低了CFD计算次数但没有改善单次CFD计算时间,且没有有效使用CFD的流场信息。

机器学习技术在气动力建模、流场降阶、流动特征提取等流体力学领域得到大量应用和发展<sup>[12-15]</sup>,S. A. Renganathan等<sup>[16]</sup>使用深度神经网络和高斯过程实现了气动外形的优化设计,但该方法仍为梯度优化;Sun Z W等<sup>[17]</sup>、Huang D M等<sup>[18]</sup>使用具有特征提取能力的降阶模型如本征正交分解(Proper Orthogonal Decomposition,简称POD)和具有高效建模能力的神经网络模型建立了从气动外形参数到流场信息的映射关系,实现了流场预测。常用的神经网络包括反向传播神经网络(Back Propagation based Neural Network,简称BPNN)<sup>[19]</sup>、径向基函数神经网络<sup>[9,11]</sup>等,Zhu L等<sup>[20]</sup>使用径向基函数神经网络构建的涡黏预测模型代替了CFD求解中的湍流模型,通过与N-S方程耦合求解降低了单次CFD计算时间,但是该方法需要对CFD求解器进行相应修改,对于优化设计人员,鲜见成熟的、已嵌入湍流建模的求解器可供使用。

本文以气动优化为研究对象,首先,结合SBO和机器学习流场预测模型的特点,提出一种基于

本征正交分解—反向传播神经网络(POD-BPNN)模型的热启动策略,并将其嵌入SBO;然后将该策略应用于跨声速翼型减阻优化,并对优化结果进行分析;最后通过案例对优化效率、POD-BPNN的流场预测性能、热启动策略的效果进行分析。

## 1 优化策略

### 1.1 优化总流程

气动优化中所涉及的目标优化问题可以表示为

$$\begin{aligned} S = \min f(x) & \quad (1) \\ \text{s.t.} \begin{cases} g_l(x) \geq 0 & (l = 1, 2, \dots, L) \\ h_m(x) = 0 & (m = 1, 2, \dots, M) \\ x_i^l \leq x_i \leq x_i^u & (i = 1, 2, \dots, n) \end{cases} \end{aligned}$$

式中: $f$ 为目标函数; $x$ 为设计变量, $x = [x_1, x_2, \dots, x_n]^T$ ; $g(\cdot)$ 为不等式约束,共 $L$ 个; $h(\cdot)$ 为等式约束,共 $M$ 个; $x_i^u$ 和 $x_i^l$ 为设计空间上下界。

针对以上气动优化问题,本文结合SBO和POD-BPNN流场预测模型,提出一种基于POD-BPNN的热启动策略并将其应用于气动代理优化。以翼型气动减阻优化为例,优化策略的总流程如图1所示,具体分为以下5个步骤。

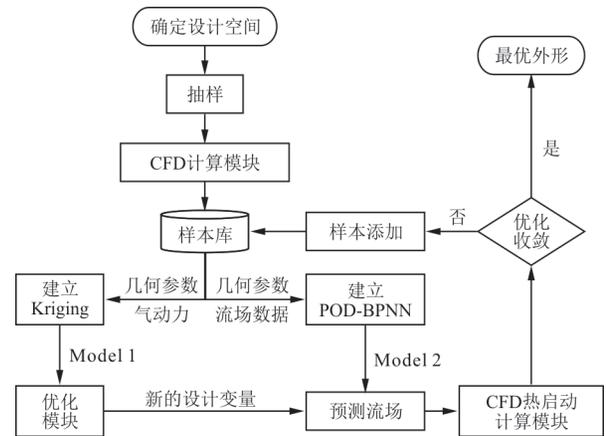


图1 优化流程

Fig. 1 Procedure of the optimization

#### (1) 生成初始样本库

使用拉丁超立方抽样(Latin Hypercube Sampling,简称LHS)在几何设计空间中抽取 $r-1$ 组几何参数,并与基准外形共同构成初始外形库,共计 $r$ 个外形。然后生成基准外形的气动网格,并基于该网格利用RBF网格变形技术<sup>[21]</sup>生成其他 $r-1$ 个外形的气动网格。RBF网格变形方法具有良好

的鲁棒性和较高的计算效率,可以解决复杂的网格变形问题,并在后续气动优化过程中也使用该方法获得气动网格。最后通过CFD计算模块得到 $r$ 个外形的流场数据和气动力。

### (2) 建立初始气动预测模型

使用Kriging模型直接建立从几何参数到气动力的气动力预测模型 Model 1,使用POD和BPNN建立从几何参数到流场数据的流场预测模型 Model 2,具体建模流程如图2所示。

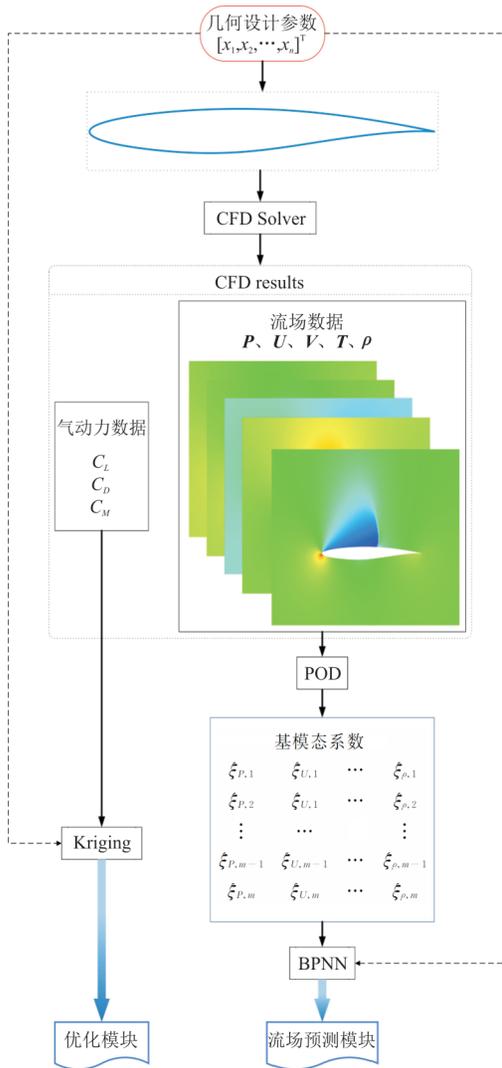


图2 气动预测模型

Fig. 2 Procedure of the aerodynamic prediction model

对于优化模块,选取具有全局搜索能力的DE算法求解优化问题,通过 Model 1 预测得到气动力。为了兼顾局部和全局搜索能力,在动态添加样本点选取策略方面,采用改善期望(Expected Improvement,简称EI)<sup>[22]</sup>准则和最小化代理预测值(Minimizing Surrogate Prediction,简称MSP)<sup>[23]</sup>准则。每进行一轮优化,会获得两个新样本点 $(x_1, p'_1, y'_1)$ 和 $(x_2, p'_2, y'_2)$ ,其中 $x$ 为设计变量,即几何设计参数; $p'$ 为 Model 1 预测气动力, $p'=[C'_L, C'_D, C'_M]^T$ ;  $y'$ 为 Model 1 预测目标函数值。

### (3) 流场预测及CFD热启动计算

对于优化模块得到的两组新的设计变量,通过 Model 2 预测相应的流场数据 $Y'_1$ 和 $Y'_2$ ,预测过程详见1.5节;并将 $Y'_1$ 和 $Y'_2$ 作为CFD热启动计算的初场进行热启动计算,计算得到真实气动力 $p_1$ 、 $p_2$ ,真实目标函数 $y_1, y_2$ 和真实流场数据 $Y_1, Y_2$ 。

### (4) 更新气动预测模型

每完成一轮CFD热启动计算,判断优化是否终止,若判断出优化仍将继续,则将新样本添加到样本库。由于Kriging建模效率高,每完成一轮CFD热启动计算,就将 $(x_1, p_1, y_1)$ 和 $(x_2, p_2, y_2)$ 添加到Kriging模型并重新建立 Model 1;而POD-BPNN模型的建模效率较低,每完成 $k$ 轮CFD热启动计算,把 $2k$ 个样本流场数据 $(x_j, Y_j), j=1, 2, \dots, 2k$ ,添加到POD-BPNN模型并重新训练得到新的 Model 2。

(5) 重复进行步骤(2)~步骤(4),直到优化终止。

## 1.2 Kriging模型

Kriging模型具有较好的非线性拟合能力,能够提供插值点的预测函数值和统计学误差估计信息,该误差估计信息可以用于动态加点,因此,本文使用Kriging模型用于气动代理优化过程。

Kriging模型可以表示为

$$\begin{cases} \hat{y}(x) = \hat{\mu} + r^T R^{-1} (y - \hat{\mu} F) \\ s^2(x) = \hat{\sigma}^2 \left[ 1 - r^T R^{-1} r + (1 - F^T R^{-1} r)^2 / (F^T R^{-1} F) \right] \end{cases} \quad (2)$$

式中: $\hat{\mu}$ 为预测得到的递归参数值; $r$ 为预测点 $x$ 与已知样本点之间的相关函数值构成的相关矢量,是列向量; $R$ 为已知样本点之间的相关函数值组成

的相关矩阵; $y$ 为已知样本点的真实响应值, $y=[y_1, y_2, \dots, y_r]^T$ ;  $F$ 为 $r$ 维单位列向量, $r$ 为已知样本点数; $\hat{\sigma}^2$ 为相关矩阵的方差。

Kriging 模型的具体推导详见文献[5]。

### 1.3 POD 模型

具有高维、复杂特征的流场数据可以通过降阶模型实现其在低维空间的映射和流场特征的提取。在气动优化问题中会生成一定规模的高维流场数据,可以通过建立 POD 降阶模型,将高维流场数据近似表示为若干阶基模态的线性叠加。

设样本数据为  $\mathbf{X}^{(i)}, i=1, 2, \dots, r$ , 其中  $\mathbf{X}^{(i)}$  为  $m$  维列向量,  $r$  为样本数目, 样本均值为

$$\mu_X = \sum_{i=1}^r \mathbf{X}^{(i)} / r \quad (3)$$

将样本数据减去均值称为标准化, 可得到标准化样本数据  $\bar{\mathbf{X}}^{(i)} = \mathbf{X}^{(i)} - \mu_X$ 。

通过对矩阵  $\bar{\mathbf{X}}$  的协方差矩阵进行特征值求解, 得到按能量占比从大到小排列的  $s$  个 POD 基模态:  $\mathbf{q}^{(1)}, \mathbf{q}^{(2)}, \dots, \mathbf{q}^{(s)}$ ,  $\mathbf{q}$  为  $m$  阶列向量。记  $\mathbf{U} = [\mathbf{q}^{(1)}, \mathbf{q}^{(2)}, \dots, \mathbf{q}^{(s)}]^T$  为映射矩阵。  $\mathbf{X}^{(i)}$  的基模态系数  $\xi^{(i)} = [\xi_1, \xi_2, \dots, \xi_s]^T$  为

$$\xi^{(i)} = \mathbf{U} \mathbf{X}^{(i)} \quad (4)$$

当前  $s$  阶基模态的能量占比达到一定值时,  $\mathbf{X}^{(i)}$  能够以低误差率近似表示为

$$\mathbf{X}^{(i)} \approx \mathbf{U}' \xi^{(i)} + \mu_X \quad (5)$$

式中:  $\mathbf{U}'$  为  $\mathbf{U}$  的伪逆矩阵。

通过 POD 降阶模型实现了高维数据  $\mathbf{X}^{(i)}$  到低维基模态系数  $\xi^{(i)}$  的映射。除了上述一般的 POD 求解方法, 还有 Snapshot-POD<sup>[24]</sup>、基于 SVD 分解的 POD<sup>[25]</sup> 等, 它们的区别只是求解方法不同, 但都会获得相同的 POD 基模态等信息。通常, 当  $m \ll r$  时, 使用一般的 POD 可以加快速度节省计算内存; 当  $m \gg r$  时, 使用 Snapshot-POD 可以加快速度节省计算内存。

### 1.4 BPNN 模型

BPNN 作为神经网络的一种, 对较低维度的多输入多输出数据具有较强的非线性拟合能力<sup>[26]</sup>。典型的单隐含层 BPNN 架构如图 3 所示, 图中输入层、隐含层和输出层的神经元分别用  $x_i (i=1, 2, \dots, n)$ ,  $z_j (j=1, 2, \dots, b)$  和  $y_k (k=1, 2, \dots, s)$  表示, 该模型实现了  $n$  维输入到  $s$  维输出的建模。通过调整隐含层的层数、各层神经元个数、各层间

的激活函数类型、学习率等超参数<sup>[19]</sup>, 可以使模型具有较好的拟合能力和泛化能力, 实现对新样本输出值的稳健预测。BPNN 的具体建模过程详见文献[27]。

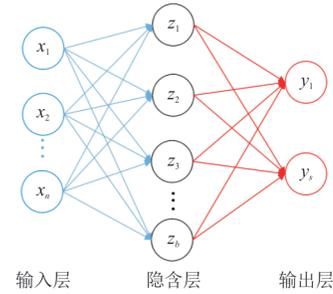


图3 BPNN 架构

Fig. 3 Architecture of BPNN

### 1.5 POD-BPNN 流场预测模型

结合 POD 模型和 BPNN 模型, 可以构建出 POD-BPNN 流场预测模型。

针对在设计空间中抽样获取的  $r$  组二维外形, 其几何设计参数为  $\mathbf{x}^{(i)} (i=1, 2, \dots, r)$ ,  $\mathbf{x}^{(i)}$  为  $n$  维列向量, 通过 CFD 计算得到对应的流场数据: 压强  $P$ 、速度  $U$ 、速度  $V$ 、温度  $T$ 、密度  $\rho$ , 这五个物理场数据均为  $m \times r$  阶矩阵,  $m$  为气动网格的网格数量。以压强场  $\mathbf{P} = [\mathbf{P}^{(1)}, \mathbf{P}^{(2)}, \dots, \mathbf{P}^{(r)}]$  ( $\mathbf{P}^{(i)}$  为  $m$  维列向量) 为例, 对其建立 POD 模型, 得到压强场均值  $\mu_P$  ( $m$  维列向量)、基模态系数  $\xi_P^{(i)}$  ( $s$  维列向量)、映射矩阵  $\mathbf{U}_P$  ( $s \times m$  阶矩阵), 且有:

$$\mathbf{P}^{(i)} \approx \mathbf{U}_P' \xi_P^{(i)} + \mu_P \quad (6)$$

对几何设计参数  $\mathbf{x}^{(i)}$  和基模态系数  $\xi_P^{(i)}$  建立 BPNN 模型, 模型的输入维度为  $n$ , 输出维度为  $s$ 。把训练好的 BPNN 模型所表征的输入输出映射关系记为  $\phi$ , 即  $\xi_P^{(i)} = \phi(\mathbf{x}^{(i)})$ , 则通过 POD 和 BPNN 可以建立几何设计变量  $\mathbf{x}^{(i)}$  和压强场  $\mathbf{P}^{(i)}$  的映射关系:

$$\mathbf{P}^{(i)} \approx \mathbf{U}_P' \phi(\mathbf{x}^{(i)}) + \mu_P \quad (7)$$

式(7)为 POD-BPNN 流场预测模型。

对于设计空间的任一设计变量  $\mathbf{x}^c$ , 可以通过 POD-BPNN 模型中的 BPNN 预测其基模态系数  $\xi_P^c$ :

$$\xi_P^c = \phi(\mathbf{x}^c) \quad (8)$$

然后通过 POD 模型的  $\mu_P$  和  $\mathbf{U}_P$  重构出压强场的预测值  $\mathbf{P}^c$ :

$$P^c \approx U_p' \xi_p^c + \mu_p \quad (9)$$

同样可以通过对物理场  $U$ 、 $V$ 、 $T$ 、 $\rho$  建立 POD-BPNN 模型,从而快速获得这些物理场的预测值,具体预测流程如图 4 所示,模型的输入为几何设计变量,由优化模块给出;模型的输出为各个物理量的流场预测数据,并作为计算初场传递给 CFD 热启动计算模块。

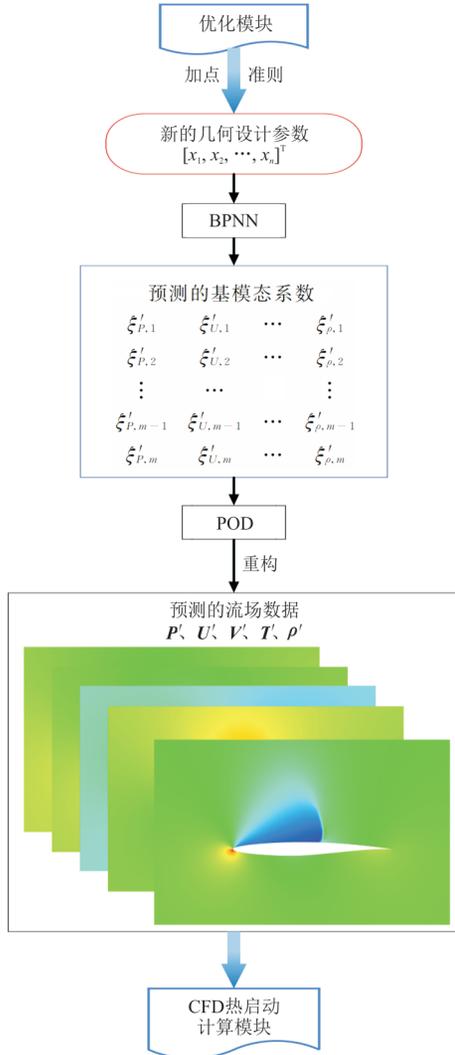


图 4 使用 POD-BPNN 进行流场预测

Fig. 4 Prediction of the flowfield by POD-BPNN

## 1.6 效率分析

对于气动代理优化中是否应用基于 POD-BPNN 的热启动策略进行计算时间分析对比。优化的初始样本个数为  $r$ , 优化过程共调用  $\lambda k + b$  次优化模块, 其中  $\lambda, k \in N^+, b = 0, 1, \dots, k-1$ 。当不使用基于 POD-BPNN 的热启动策略时, 优化总时间  $T_1$  为

$$T_1 = (\lambda k + b) \cdot \bar{t}_1 + (r + 2\lambda k + 2b) \cdot \bar{t}_{\text{CFD}} \quad (10)$$

式中:  $\bar{t}_1$  为 Model 1 即 Kriging 代理模型的平均建模时间, 该数值一般为数秒, 相比于耗时的 CFD 计算可忽略不计;  $\bar{t}_{\text{CFD}}$  为 CFD 计算的平均时间, 数值与网格数量、网格质量、计算工况等有关, 一般为数分钟至数小时不等。

当使用基于 POD-BPNN 的热启动策略时, 优化总时间  $T_2$  为

$$T_2 = (\lambda k + b) \cdot \bar{t}_1 + (\lambda + 1) \cdot \bar{t}_2 + r \cdot \bar{t}_{\text{CFD}} + (2\lambda k + 2b) \cdot \bar{t}_{\text{CFD}'} \quad (11)$$

式中:  $\bar{t}_2$  为 Model 2 即“POD-BPNN”预测模型的平均建模时间, 该数值一般为几十秒至数分钟;  $\bar{t}_{\text{CFD}'}$  为 CFD 热启动计算的平均时间, 一般小于  $\bar{t}_{\text{CFD}}$  数值的 50%。

可以得到如下关系:

$$\bar{t}_1 < \bar{t}_2 < \bar{t}_{\text{CFD}'} < \bar{t}_{\text{CFD}} \quad (12)$$

使用基于 POD-BPNN 的热启动策略, 气动代理优化的时间节省量  $\Delta_T$  为

$$\Delta_T = 2(\lambda k + b) \cdot (\bar{t}_{\text{CFD}} - \bar{t}_{\text{CFD}'}) - (\lambda + 1) \cdot \bar{t}_2 \quad (13)$$

## 2 案例分析

### 2.1 优化问题描述

本文以 RAE2822 翼型为优化的基准翼型, 优化设计工况:  $Ma = 0.734, \alpha = 2.79^\circ, Re = 6.5 \times 10^6$ , 优化问题的数学模型为

$$M = \min C_D \quad (14)$$

$$\text{s.t.} \begin{cases} C_L - C_{L0} \geq 0 \\ |C_{M0}| - |C_M| \geq 0 \\ A - A_0 \geq 0 \end{cases}$$

式中:  $C_D, C_L$  和  $C_M$  分别为当前翼型的升力、阻力和俯仰力矩系数;  $C_{L0}$  和  $C_{M0}$  分别为基准翼型的升力和俯仰力矩系数;  $A$  和  $A_0$  分别为当前翼型和基准翼型的面积, 为无量纲化数值。

### 2.2 参数化及网格收敛性分析

本文采用 CST(Class-function Shape-function Transformation) 参数化方法<sup>[28]</sup>, 采用 6 阶伯恩斯坦多项式, 共 14 个设计变量。基准翼型网格收敛性分析如表 1 所示, 表中网格均采用结构/非结构混

合网格形式,这四套网格的物面网格疏密程度不同,根据  $C_L$  和  $C_D$  的数值对比确定出气动优化所使用的气动网格为Ⅲ,网格数量约为 4.7 万,远场边界为  $70c$  ( $c$  为翼型弦长,这里  $c$  取无量纲数 1);物面第一层网格高度为  $5.0 \times 10^{-6}c$ 。采用网格Ⅲ得到的 CFD 仿真结果与实验值以及文献[7]中仿真结果对比如表 2 所示,翼面压力系数分布与实验值的对比如图 5 所示,可以看出:本文的升力系数计算结果与实验值相差不到 3%;阻力系数与实验值相差不到 5%;力矩系数与实验值相差不到 11%,与文献[7]相差不到 3%;压力系数分布曲线与实验值基本吻合,说明本文的 CFD 计算具有一定准确性。

表 1 基准翼型的气动网格收敛性分析  
Table 1 Grid convergence analysis for the baseline

网格	网格数量	$C_L$	$C_D$
I	18 875	0.771	$0.017\ 67 \pm 0.000\ 02$
II	34 951	0.779	0.017 82
III	46 573	0.781	0.017 63
IV	65 603	0.782	0.017 62

表 2 基准翼型的力系数计算结果对比  
Table 2 Validation of CFD simulation for the baseline

对比方法	$C_L$	$C_D$	$C_M$
实验值	0.803	0.016 8	-0.099 0
文献[7]	0.802	0.017 8	-0.090 2
本文策略	0.781	0.017 6	-0.088 2

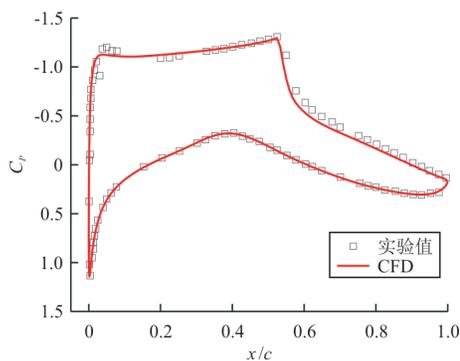


图 5 RAE2822 翼型压力系数分布与实验值对比  
Fig. 5 Comparison of pressure coefficient distribution of RAE2822

基准网格为网格Ⅲ。使用 RBF 网格变形技术获得其他外形的气动网格,网格变形前后的气动网格对比如图 6 所示,可以看出:变形后网格的网格质量与基准网格基本保持一致。

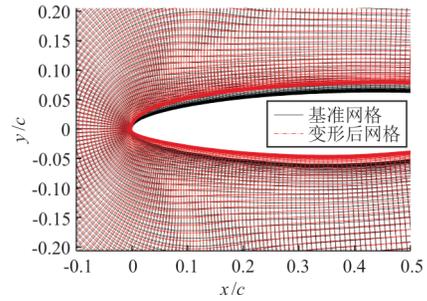


图 6 网格对比  
Fig. 6 Comparison of grids

## 2.3 优化参数设置

初始样本通过 LSH 获取,抽取个数为  $n(n-1)/2$ ,  $n$  为设计变量个数,剔除计算不收敛样本,得到有效样本 89 个。优化中参数  $k$  的取值为 5,即每完成 5 轮优化模块的调用,进行一次 POD-BPNN 预测模型的更新,既可以保证流场的预测精度,又能够避免由于重复建立 POD-BPNN 而降低模型效率。

## 2.4 优化结果及分析

目标函数随着加点个数的收敛历程如图 7 所示。优化前后的气动性能对比如表 3 所示,可以看出:对比基准翼型,优化后阻力系数  $C_D$  降低了约 0.006 3,优化得到的翼型相比于基准翼型阻力系数减小了 35.8%,升力系数、面积和力矩系数均满足约束条件。

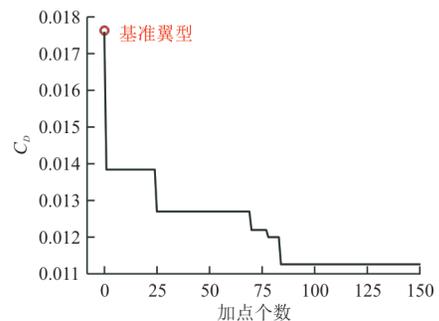


图 7 目标函数的收敛曲线  
Fig. 7 Convergence curve of goal function

表 3 优化前后的气动性能对比  
Table 3 Compare of aerodynamic performance of baseline and optimum shape

翼型	$C_L$	$C_D$	$C_M$	面积
基准翼型	0.781	0.017 6	-0.088 2	0.077 8
优化翼型	0.782	0.011 3	-0.083 9	0.077 9

优化前后的翼型几何形状和翼面压力系数分布对比如图 8~图 9 所示。

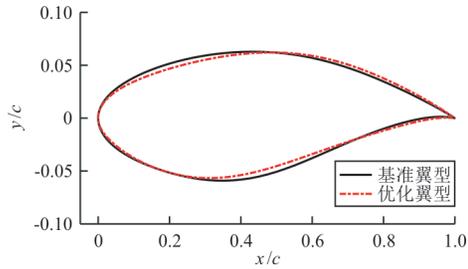


图 8 优化前后翼型对比

Fig. 8 Compare of baseline and optimum shape

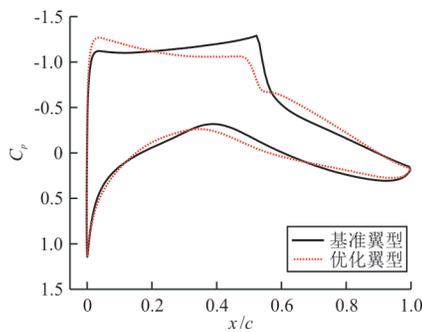


图 9 优化前后翼面压力系数分布对比

Fig. 9 Comparison of pressure coefficient distribution of baseline and optimum shape

优化前后翼型的压强场云图对比如图 10 所示,可以看出:优化后上表面的强激波得到有效削弱,减阻优化效果明显。

由于 POD-BPNN 仅在 SBO 中加入样本预测流场及 CFD 热启动计算,不会对 SBO 的相关参

数、优化过程和优化结果产生影响。因此仅对本文策略和 SBO 进行效率对比分析,结果如表 4 所示,可以看出:本文策略相比于 SBO,单次 CFD 计算时间降低约 68%,整体效率提升约 37%。

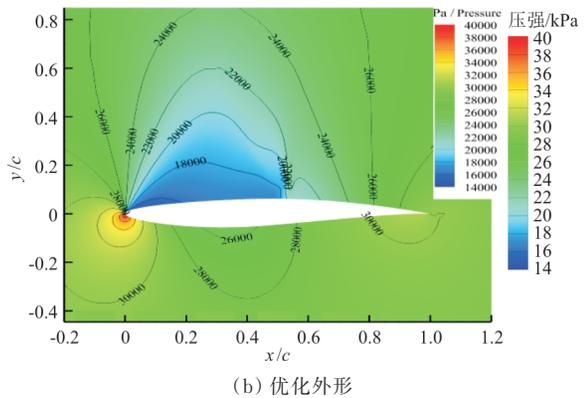
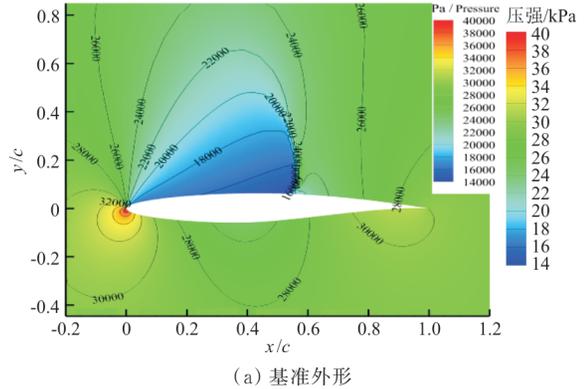


图 10 优化前后压强云图对比

Fig. 10 Comparison of pressure field of baseline and optimum shape

表 4 计算时间分析

Table 4 Time-consuming analysis

方法	计算次数				平均计算时间/s				总时间/h
	CFD	CFD 热启动	Model 1	Model 2	CFD	CFD 热启动	Model 1	Model 2	
SBO	245	—	77	—	260	—	约 1	—	17.7
本文策略	91	154	77	16	278	89	约 1	约 50	11.1

在 SBO 中使用 POD-BPNN 对某一新加样本点的流场预测效果如图 11 所示,可以看出:POD-BPNN 在上翼面距离前缘 60%*c* 位置附近的压强预测效果较差,而在非激波位置处的等压线拟合均较好。

给出最优外形下两个方法的收敛曲线如图 12 所示,可以看出:CFD 需要约 900 步完成  $C_L$  和  $C_D$  的计算收敛,而使用基于热启动策略的 CFD 计算仅

需 200 步左右就可以完成  $C_L$  和  $C_D$  的计算收敛。

在整个代理优化过程中,初始样本和新加样本点的 CFD 计算的收敛步数如图 13 所示,其中使用 CFD 计算的初始样本收敛步数,数值集中在 800 步左右;采用基于 POD-BPNN 热启动策略的新加样本点的计算收敛步数,数值集中在 200 步左右,新加样本点在使用基于 POD-BPNN 模型的 CFD 热启动计算后,其收敛步数整体上低于使用 CFD

计算的初始样本收敛步数,CFD热启动计算失败的情况主要集中在加点的前期。热启动计算失败的样本量为9个,占整个热启动样本量的5.8%,当在计算中出现该情况,只需切换为CFD计算即可。

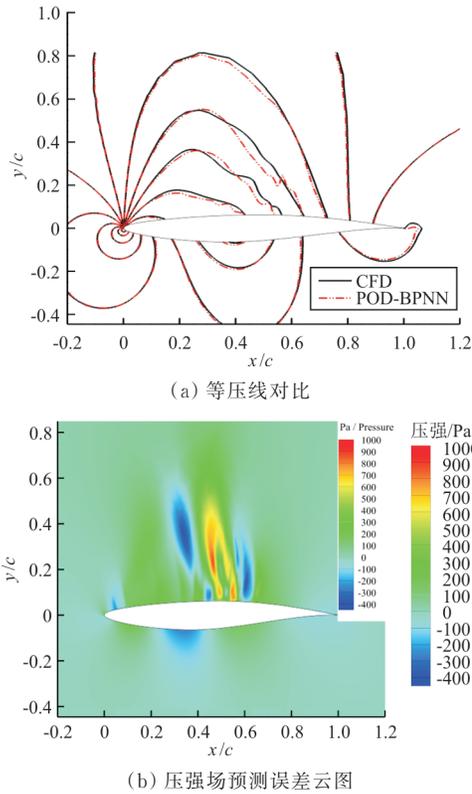


图 11 POD-BPNN对压强场的预测效果

Fig. 11 Forecast result of pressure field by POD-BPNN

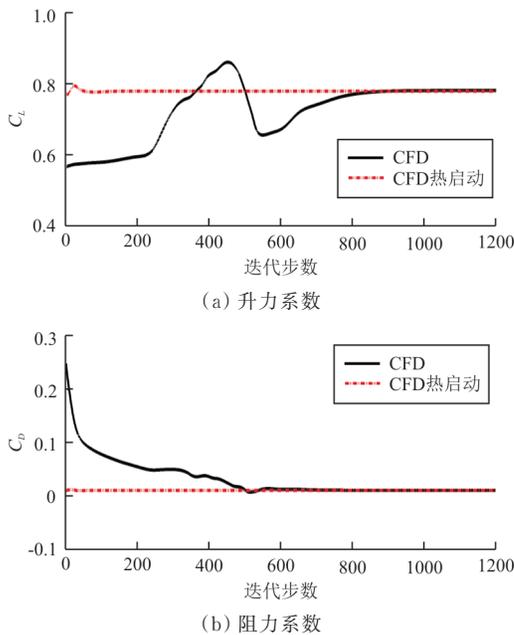


图 12 两种方法的收敛曲线

Fig. 12 The convergence curves of the two methods

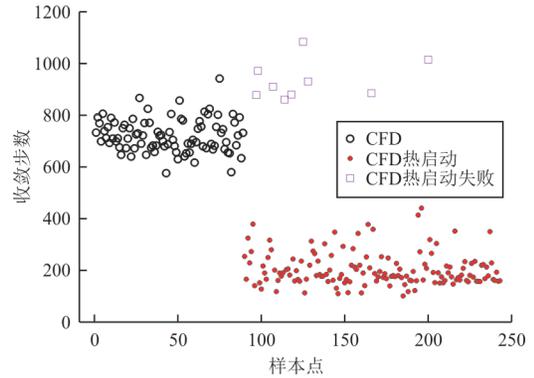


图 13 气动计算的收敛步数分析  
Fig. 13 Analysis of convergence steps for aerodynamic calculation

POD-BPNN模型对每个新加样本点压强场的预测均方根误差如图14所示,可以看出:预测误差呈现初期大、后期小的趋势,这与图13中CFD热启动失败集中在加点前期的现象是一致的。

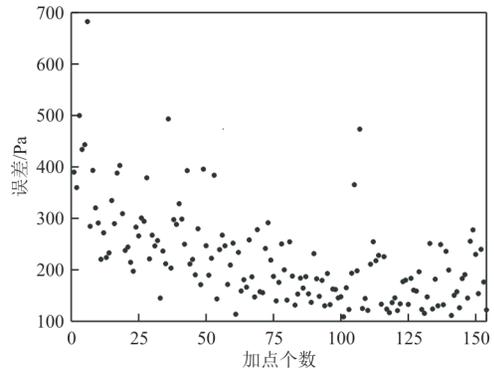


图 14 POD-BPNN模型对压强场的预测误差

Fig. 14 The RMSE of pressure flow filed by POD-BPNN

### 3 结 论

(1) 针对翼型跨声速减阻优化算例,使用基于POD-BPNN模型的热启动策略进行气动代理优化,获得了减阻明显的优化翼型,在优化中单次CFD计算时间降低了68%,整体优化效率提升了37%。

(2) 由于POD-BPNN模型的建立相比于Kriging需要耗费一定时间,但是Kriging模型随着优化模块的调用实时更新;而POD-BPNN模型在调用多次优化模块后再进行更新,可以有效提高建模效率。

(3) POD-BPNN流场预测模型中使用了POD,而POD的建模效率很高,因此POD-BPNN的建模效率与网格量的相关性较小。在气动网格

数目较多的三维外形气动优化中,该策略的引入使得优化效率的提升更加显著。

(4) 使用POD-BPNN模型的预测流场作为初场进行CFD热启动计算可能会产生计算不收敛的情况导致计算失败,该比例不超过6%。可以通过提高模型预测精度来有效降低热启动计算失败的概率。

### 参考文献

- [1] 白俊强, 雷锐午, 杨体浩, 等. 基于伴随理论的大型客机气动优化设计研究进展[J]. 航空学报, 2019, 40(1): 98-115.  
BAI Junqiang, LEI Ruiwu, YANG Tihao, et al. Progress of adjoint-based aerodynamic optimization design for large civil aircraft [J]. Acta Aeronautica et Astronautica Sinica, 2019, 40(1): 98-115. (in Chinese)
- [2] 何萌, 白俊强, 昌敏, 等. 翼型气动优化设计问题多极值特性研究[J]. 航空工程进展, 2019, 10(5): 664-672.  
HE Meng, BAI Junqiang, CHANG Min, et al. Study on multimodality in aerodynamic airfoil optimization design [J]. Advances in Aeronautical Science and Engineering, 2019, 10(5): 664-672. (in Chinese)
- [3] QIN A K, HUANG V L, SUGANTHAN P N. Differential evolution algorithm with strategy adaptation for global numerical optimization [J]. IEEE Transactions on Evolutionary Computation, 2009, 13(2): 398-417.
- [4] VENTER G, SOBIESZCZANSKI-SOBIESKI J. Multidisciplinary optimization of a transport aircraft wing using particle swarm optimization [J]. Structural and Multidisciplinary Optimization, 2004, 26(1/2): 121-131.
- [5] 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. (in Chinese)
- [6] HAN Z H, XU C Z, LIANG Z, et al. Efficient aerodynamic shape optimization using variable-fidelity surrogate models and multilevel computational grids [J]. Chinese Journal of Aeronautics, 2020, 33(1): 31-47.
- [7] 张阳, 韩忠华, 柳斐, 等. 高超声速飞行器宽域翼型多目标优化设计研究[J]. 气体物理, 2019, 4(4): 26-40.  
ZHANG Yang, HAN Zhonghua, LIU Fei, et al. Multi-objective aerodynamic shape optimization of wide-Mach-number-range airfoil [J]. Physics of Gases, 2019, 4(4): 26-40. (in Chinese)
- [8] 韩忠华, 许晨舟, 乔建领, 等. 基于代理模型的高效全局气动优化设计方法研究进展[J]. 航空学报, 2020, 41(3): 22-65.  
HAN Zhonghua, XU Chenzhou, QIAO Jianling, et al. Recent progress of efficient global aerodynamic shape optimization using surrogate-based approach [J]. Acta Aeronautica et Astronautica Sinica, 2020, 41(3): 22-65. (in Chinese)
- [9] ZHANG Y W, GONG C L, FANG H, et al. An efficient space-division-based width optimization method for RBF network using fuzzy clustering algorithms [J]. Structural and Multidisciplinary Optimization, 2019, 60(2): 461-480.
- [10] FANG H, GONG C L, SU H, et al. A gradient based uncertainty optimization framework utilizing dimensional adaptive polynomial chaos expansion [J]. Structural and Multidisciplinary Optimization, 2018, 59(4): 1199-1219.
- [11] WANG X, KOU J Q, ZHANG W W. Unsteady aerodynamic modeling based on fuzzy scalar radial basis function neural networks [J]. Proceedings of the Institution of Mechanical Engineers Part G, Journal of Aerospace Engineering, 2019, 233(14): 5107-5121.
- [12] 王怡星, 韩仁坤, 刘子扬, 等. 流体力学深度学习建模技术研究进展[J]. 航空学报, 2021, 42(4): 225-244.  
WANG Yixing, HAN Renkun, LIU Ziyang, et al. Progress of deep learning modeling technology for fluid mechanics [J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(4): 225-244. (in Chinese)
- [13] 张伟伟, 寇家庆, 刘溢浪. 智能赋能流体力学展望[J]. 航空学报, 2021, 42(4): 20-65.  
ZHANG Weiwei, KOU Jiaqing, LIU Yilang. Prospect of artificial intelligence empowered fluid mechanics [J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(4): 20-65. (in Chinese)
- [14] 陈海昕, 邓凯文, 李润泽. 机器学习技术在气动优化中的应用[J]. 航空学报, 2019, 40(1): 47-63.  
CHEN Haixin, DENG Kaiwen, LI Runze. Utilization of machine learning technology in aerodynamic optimization [J]. Acta Aeronautica et Astronautica Sinica, 2019, 40(1): 47-63. (in Chinese)
- [15] HAN R K, WANG Y X, ZHANG Y, et al. A novel spatial-temporal prediction method for unsteady wake flows based on hybrid deep neural network [J]. Physics of Fluids, 2019, 31(12): 1-14.
- [16] RENGANATHAN S A, MAULIK R, AHUJA J. Enhanced data efficiency using deep neural networks and Gaussian processes for aerodynamic design optimization [J]. Aerospace Science and Technology, 2021, 111: 106522.
- [17] SUN Z W, WANG C, ZHENG Y, et al. Non-intrusive reduced-order model for predicting transonic flow with varying geometries [J]. Chinese Journal of Aeronautics, 2020, 33(2): 508-519.
- [18] HUANG D M, HE S Q, HE X H, et al. Prediction of wind loads on high-rise building using a BP neural network combined with POD [J]. Journal of Wind Engineering and Industrial Aerodynamics, 2017, 170: 1-17.
- [19] 李春娜, 贾续毅, 龚春林. 基于两层POD和BPNN的翼型反设计方法[J]. 航空工程进展, 2021, 12(2): 30-37.  
LI Chunna, JIA Xuyi, GONG Chunlin. Airfoil inverse design method based on two-layer POD and BPNN [J]. Ad-

- vances in Aeronautical Science and Engineering, 2021, 12 (2): 30-37. (in Chinese)
- [20] ZHU L, ZHANG W, KOU J, et al. Machine learning methods for turbulence modeling in subsonic flows around airfoils[J]. Physics of Fluids, 2019, 31(1): 1-14.
- [21] LI C N, WEI Q, GONG C L, et al. An efficient multiple point selection study for mesh deformation using radial basis functions [J]. Aerospace Science and Technology, 2017, 71: 580-591.
- [22] JEONG S, MURAYAMA M, YAMAMOTO K. Efficient optimization design method using Kriging model[J]. Journal of Aircraft, 2005, 42(2): 413-420.
- [23] BOOKER A J, DENNIS J E, FRANK P D, et al. A rigorous framework for optimization of expensive functions by surrogates[R]. Houston: Center for Research on Parallel Computation, 1998.
- [24] WU L, CHEN K S, ZHAN C C. Snapshot POD analysis of transient flow in the pilot stage of a jet pipe servo valve [J]. Journal of Turbulence, 2018, 19(10): 889-909.
- [25] FAREED H, SINGLER J R. A note on incremental POD algorithms for continuous time data[J]. Applied Numerical Mathematics, 2019, 144: 223-233.
- [26] LIANG R F, LI T L, LI L F, et al. Knowledge consistency between neural networks and beyond [C] // 2020 International Conference on Learning Representations. [S.l. : s.n.], 2020: 1-10.
- [27] PHIL K. 深度学习: 基于MATLAB的设计实例[M]. 邹伟, 王振波, 王燕妮, 译. 北京: 北京航空航天大学出版社, 2018. PHIL K. Deep learning for beginners: with MATLAB examples[M]. ZOU Wei, WANG Zhenbo, WANG Yanni, Translation. Beijing: Beihang University Press, 2018. (in Chinese)
- [28] 刘俊. 基于代理模型的高效气动优化设计方法及应用[D]. 西安: 西北工业大学, 2015. LIU Jun. Efficient surrogate-based optimization method and its application in aerodynamic design[D]. Xi'an: Northwestern Polytechnical University, 2015. (in Chinese)

#### 作者简介:

贾续毅(1999—),男,博士研究生。主要研究方向:智能流体技术,气动优化设计,总体设计。

李春娜(1982—),女,博士,副教授。主要研究方向:优化方法与技术,气动优化设计,智能流体技术等。

常琦(1990—),男,硕士,工程师。主要研究方向:导弹总体设计、控制系统。

季稳(1999—),男,硕士研究生。主要研究方向:气动力建模,总体设计。

(编辑:丛艳娟)

(上接第 35 页)

- [15] 王哲,李旭东,贾晓,等. 民用飞机货舱舱门设计要求: HB8490—2014[S]. 北京:中国航空综合技术研究所, 2014. WANG Zhe, LI Xudong, JIA Xiao, et al. Design requirements for cargo door of civil aircraft: HB8490—2014 [S]. Beijing: China Aero-poly Technology Establishment, 2014. (in Chinese)
- [16] 中国民用航空局. 运输类飞机适航标准: CCAR-25-R4 [S]. 北京:中国民用航空局, 2011. Civil Aviation Administration of China. Airworthiness standard of transport aircraft: CCAR-25-R4 [S]. Beijing: CAAC, 2011. (in Chinese)
- [17] FAA. Uniform distribution of exits: AC25-783-1A [S]. USA: Department of Transportation, 1990.
- [18] SAE. Exits and their operation—air transport cabin emergency: SAE ARP 488[S]. USA: The Engineering Society For Advancing Mobility Land Sea Air and Space, 2000.
- [19] 吴铁锋. 民用飞机舱门在气密试验中的典型超差处置分析 [J]. 科技视界, 2018, 22(10): 69-71. WU Tiefeng. Schemas for typical tolerances of cabin door in civil aircraft air tight test[J]. Science & Technology Vision, 2018, 22(10): 69-71. (in Chinese)
- [20] 牛春匀. 实用飞机结构工程设计[M]. 北京:航空工业出版社, 2008. NIU Chunyun. Airframe structural design [M]. Beijing: Aviation Industry Press, 2008. (in Chinese)
- [21] 姚雄华,邓军锋,冯蕴雯. 运输类飞机舱门设计[M]. 北京:国防工业出版社, 2017. YAO Xionghua, DENG Junfeng, FENG Yunwen. The doors design of transport airplane[M]. Beijing: National Defense Industry Press, 2017. (in Chinese)
- [22] 夏越美,祝耀昌. 民用飞机机载设备环境条件和试验方法(第13部分)结冰试验: HB6167.13—2014[S]. 北京:中国航空综合技术研究所, 2014. XIA Yuemei, ZHU Yaochang. Environmental conditions and test procedures for airborne equipment of civil airplane—Part 13: Icing test: HB6167.13—2014[S]. Beijing: China Aero-poly Technology Establishment, 2014. (in Chinese)

#### 作者简介:

甘亚东(1972—),男,学士,研究员。主要研究方向:飞机结构及运动机构设计。

姚雄华(1965—),男,硕士,研究员。主要研究方向:飞机总体设计及飞机结构设计。

刘万春(1982—),男,硕士,高级工程师。主要研究方向:飞机结构及运动机构设计。

(编辑:马文静)