

# 基于小样本神经网络与多约束的风力机翼型快速优化设计

鞠浩<sup>1</sup>, 王旭东<sup>1,2</sup>, 陆佳红<sup>1</sup>, 秦雪帅<sup>1</sup>

(1. 重庆工商大学制造装备机构设计与控制重庆市重点实验室, 重庆 400067; 2. 重庆工商大学国家智能制造服务国际科技合作基地, 重庆 400067)

**摘要:** 针对神经网络模型可以基于现有数据快速准确地预测风力机翼型的气动性能, 但大量学习样本的构建需要较高的时间成本的问题, 建立基于小样本集的风力机翼型神经网络模型, 提出了多约束条件下的翼型气动性能优化设计方法, 解决了训练数据过少所造成的学习不充分问题。基于建立的优化设计模型, 应用粒子群算法完成了NACA4415翼型的优化设计, 将新翼型与原始翼型进行气动特性对比分析。结果表明: 新翼型在主要工作攻角范围内最大升力系数提高了6.96%, 最大升阻比提高了7.37%, 气动性能明显改善; 该方法的优化效率远远高于传统方法, 从而验证了该方法的可行性。

**关键词:** 风力机翼型; 神经网络; 小样本; 多约束; 优化设计

中图分类号: TK83 文献标识码: A DOI: 10.16146/j.cnki.mdgc.2022.11.023

[引用本文格式] 鞠浩, 王旭东, 陆佳红, 等. 基于小样本神经网络与多约束的风力机翼型快速优化设计[J]. 热能动力工程, 2022, 37(11): 176-184. JU Hao, WANG Xu-dong, LU Jia-hong, et al. Rapid optimization design of wind turbine airfoil based on small sample neural network and multiple constraints[J]. Journal of Engineering for Thermal Energy and Power, 2022, 37(11): 176-184.

## Rapid Optimization Design of Wind Turbine Airfoil based on Small Sample Neural Network and Multiple Constraints

JU Hao<sup>1</sup>, WANG Xu-dong<sup>1,2</sup>, LU Jia-hong<sup>1</sup>, QIN Xue-shuai<sup>1</sup>

(1. Chongqing Key Laboratory of Manufacturing Equipment Mechanism Design and Control, Chongqing Technology and Business University, Chongqing, China, Post Code: 400067; 2. National Research Base of Intelligent Manufacturing Service, Chongqing Technology and Business University, Chongqing, China, Post Code: 400067)

**Abstract:** Neural network model can quickly and accurately predict the aerodynamic performance of wind turbine airfoil based on existing data, but the construction of a large number of learning samples requires a high time cost. To solve this problem, a neural network model of wind turbine airfoil based on small sample set was established, and an optimization design method for aerodynamic performance of airfoil under multiple constraints was proposed, which solved the problem of insufficient learning caused by too little training data. Based on the established optimization design model, the optimization design of NACA4415 airfoil was completed by using particle swarm optimization algorithm. The aerodynamic characteristics of the new airfoil and the original airfoil were compared and analyzed. The results show that the

收稿日期: 2021-12-10; 修订日期: 2021-12-29

基金项目: 重庆市基础与前沿研究计划项目 (cstc2016jcyjA0448); 重庆市教委科学技术研究项目 (KJ1600628); 制造装备机构设计与控制重庆市重点实验室开放基金项目 (1556031); 重庆工商大学研究生创新科研项目 (yjsx2022-112-158)

**Fund-supported Project:** Chongqing Foundation and Frontier Project (cstc2016jcyjA0448); Chongqing Municipal Education Commission Scientific Research Project (KJ1600628); Open Fund Project of Chongqing Key Laboratory of Manufacturing Equipment Mechanism Design and Control (1556031); Postgraduate Innovative Research Project of Chongqing Technology and Business University (yjsx2022-112-158)

作者简介: 鞠浩 (1997-), 男, 山东济南人, 重庆工商大学硕士研究生。

通讯作者: 王旭东 (1981-), 男, 陕西蓝田人, 重庆工商大学教授。

maximum lift coefficient and the maximum lift-drag ratio of the new airfoil in the main angle of attack are increased by 6.96% and 7.37%, and the aerodynamic performance of the new airfoil is significantly improved. Moreover, the optimization efficiency of this method is much higher than that of the traditional method, which verifies the feasibility of this method.

**Key words:** wind turbine airfoil, neural network, small sample, multiple constraints, optimization design

## 引 言

翼型是组成叶片的基本元素,其设计与优化需要进行复杂的高维非线性流体力学问题模拟求解。计算流体力学(Computational Fluid Dynamics, CFD)方法凭借高精度与高可信度成为现阶段气动设计的主要手段<sup>[1-2]</sup>。但其计算周期长,通常会耗费巨大的计算机算力。

近年来,机器学习与神经网络有了长足的发展,数据驱动建模方法流行,因此部分学者将其应用于流场预测与翼型优化设计<sup>[3]</sup>。Oztiryaki 等人<sup>[4]</sup>利用浅层神经网络简化了对升力系数的预测,并将其用于动态优化设计;Balla 等人<sup>[5]</sup>以翼型固定点的压力为输出,建立了多输出神经网络,并与正交分解法进行了比较,实现了更高精度的预测;Zahn 等人<sup>[6]</sup>基于长短时记忆神经网络,提出一种非线性系统降阶建模技术,用于跨声速抖振空气动力学的预测;Baek 等人<sup>[7]</sup>以 NACA0015 翼型为研究对象,通过人工神经网络反馈流控制抑制流动分离,显著提高了翼型的压力减阻效果;刘凌君等人<sup>[8]</sup>通过人工神经网络模型实现了翼型气动力的快速预测和反设计;郑天韵等人<sup>[9]</sup>基于深度残差网络发展了一种代数转捩模型,准确预测了间歇场;吴秋雨<sup>[10]</sup>采用生成式对抗网络对气动外形进行了降维并提取了可解释特征变量,加快了翼型优化过程。

上述研究表明,神经网络在应对高维非线性流体力学问题中的巨大潜力,但也证实其模型性能严重依赖于学习样本。过少的训练数据将导致网络学习不充分,而若要获取大量的高精度样本则要付出高昂的时间成本。针对此问题并结合翼型设计实际,提出使用多约束限制神经网络输入变量,从而解决基于小样本集训练带来的学习不充分问题,并将其与粒子群优化算法相结合进一步优化以获得性能更佳的风力机翼型。

## 1 翼型神经网络模型的建立

### 1.1 广义回归神经网络

广义回归神经网络(Generalized Regression Neural Network, GRNN)是径向基神经网络的一种,它基于非参数核回归,以样本数据为后验条件,通过观测样本求解自变量和因变量之间的联结概率密度函数,从而计算后者对前者的回归值<sup>[11]</sup>。GRNN 包含以下 4 层结构:

(1) 输入层:输入层神经元数目等于输入向量的维数,输入向量在此不经任何变换传递给模式层。

(2) 模式层:又称隐回归层,每个神经元与训练样本一一对应,以高斯函数为活化核函数,输入向量在模式层进行如下变换:

$$P_i = e^{-\frac{(X-X_i)^T(X-X_i)}{2\sigma^2}} \quad (1)$$

式中: $X$ —网络输入向量; $X_i$ —第  $i$  个神经元对应的学习样本, $i = 1, 2, \dots, n$ ; $\sigma$ —光滑因子;上角标  $T$ —转置矩阵。

(3) 求和层:该层含有两类求和神经元,一类对模式层所有输出进行算术求和,模式层各神经元与其连接权值均为 1,传递函数为:

$$S_D = \sum_{i=1}^n P_i \quad (2)$$

另一类则对模式层所有输出进行加权求和,第  $i$  个模式层神经元与第  $j$  个求和层分子神经元之间的连接权值为第  $i$  个输出样本  $Y_i$  中的第  $j$  个元素,即:

$$S_{Nj} = \sum_{i=1}^n Y_{ij} P_i \quad (3)$$

式中: $Y_{ij}$ —第  $i$  个输出样本中的第  $j$  个元素, $j = 1, 2, \dots, k$ 。

(4) 输出层:第  $j$  个神经元的输出对应预估结果  $Y(X)$  的第  $j$  个元素,即:

$$Y_j = \frac{S_{Nj}}{S_D} \quad (4)$$

GRNN 的网络结构如图 1 所示。相比于其他神经网络,其具有较强的非线性映射能力和较快的学习速度<sup>[12]</sup>。在样本数据较少的情况下,依然具有良好的预测能力。

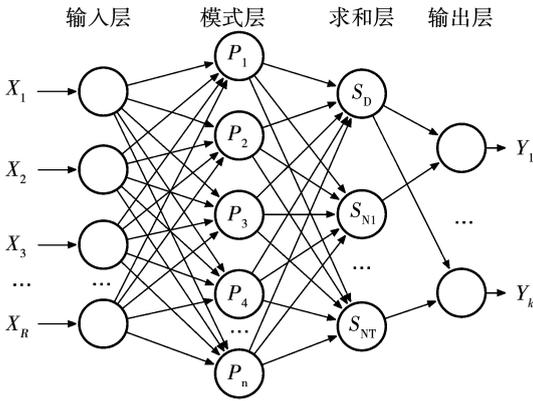


图 1 广义回归神经网络结构图

Fig. 1 Structure of generalized regression neural network

### 1.2 NACA 翼型形状的参数化

神经网络的性能严重依赖于学习样本,对于翼型设计而言,样本库应覆盖较广的形状变化范围。NACA 四位翼型族是美国最早建立的高升力、低阻力的低速翼型系列,通过最大相对厚度、最大相对弯度、最大相对弯度位置 3 个形状参数即可精确地描述翼型<sup>[13]</sup>。利用 NACA 四位翼型族方程计算 3 个形参在较大范围内均匀变化时的翼型数据,并将其作为学习样本。NACA 四位翼型计算方程如下(假定弦长为 1):

$$y_m = \begin{cases} \frac{m(2px - x^2)}{p^2}, & 0 \leq x \leq p \\ \frac{m(1 - 2p + 2px - x^2)}{(1 - p)^2}, & p < x \leq c \end{cases} \quad (5)$$

$$y_t = \frac{t}{0.2}(0.2969x^{0.5} - 0.1260x - 0.3516x^2 + 0.2843x^3 - 0.1015x^4) \quad (6)$$

$$\begin{cases} x_{upper} = x - y_t \sin(\arctan \frac{dy_c}{dx}) \\ y_{upper} = y_c + y_t \cos(\arctan \frac{dy_c}{dx}) \\ x_{lower} = x + y_t \sin(\arctan \frac{dy_c}{dx}) \\ y_{lower} = y_c - y_t \cos(\arctan \frac{dy_c}{dx}) \end{cases} \quad (7)$$

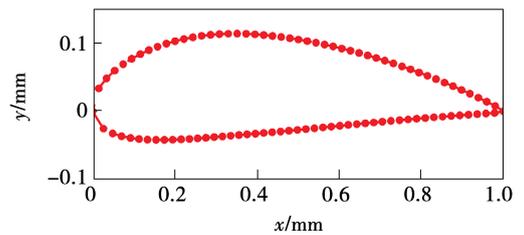
式中:  $m$ —最大相对弯度,%;  $p$ —最大相对弯度位置,%;  $t$ —最大相对厚度,%;  $y_m$ —中弧线坐标,mm;  $y_t$ —翼型半厚度,mm;  $x, y$ —翼型横、纵坐标,mm;  $c$ —弦长,mm;  $x_{upper}$ —翼型上翼面横坐标,mm;  $x_{lower}$ —翼型下翼面横坐标,mm。

通过该方程可以获得指定形状的翼型二维离散坐标点,但当离散点数量较少时,计算获得的翼型点在关键的翼型前缘位置分布将较为分散,无法精确地描述前缘形状。因此,在原始方程的基础上增加了 1 个翼型点的分布改进式:

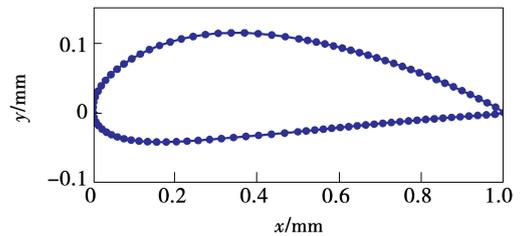
$$x = \begin{cases} \frac{\sin(\pi x - 0.5\pi) + 1}{2}, & x < 0.5 \\ x, & x \geq 0.5 \end{cases} \quad (8)$$

经过上述变换,可以在离散点总数不变的情况下,将曲率变化平缓的翼型中部处的离散点向弯曲的前缘处靠拢。

为了测试该改进式的有效性,以 NACA4415 为例,上下翼面各用 49 个数据点表示,即沿弦长方向均匀取 49 个点作为横坐标,代入原始方程和改进方程计算翼型纵坐标,并绘制其分布图,如图 2 所示。分析可得,改进方程计算所得的翼型离散点分布更加合理,能更好地描述翼型前缘。



(a) NACA 方程翼型



(b) 改进方程翼型

图 2 翼型数据点分布对比图

Fig. 2 Comparison of airfoil data point distribution

神经网络本质上是输入与输出之间的相互映射。若直接以翼型离散点作为输入变量,将导致维度过高<sup>[14]</sup>、计算量大以及过拟合等问题,因此要将翼型参数化。类函数/形函数变换(Class function/

Shape function Transformation, CST)法是一种通用的翼型参数化表示方法,它使用 1 个类函数来控制所表示的翼型的种类,通过形函数的系数唯一确定具体的翼型。该方法具有设计变量少、设计空间广且生成翼型光滑的特点<sup>[15]</sup>。因此,选择 CST 方法对翼型进行参数化,其基本公式为<sup>[16]</sup>:

$$\begin{cases} y_{\text{upper}} = C_{N_2}^{N_1}(x)S(x)_{\text{upper}} + x\Delta z_{\text{upper}} \\ y_{\text{lower}} = C_{N_2}^{N_1}(x)S(x)_{\text{lower}} + x\Delta z_{\text{lower}} \end{cases} \quad (9)$$

$$C_{N_2}^{N_1}(x) = x^{N_1} \cdot (1-x)^{N_2} \quad (10)$$

$$S(x) = \sum_{i=0}^n \frac{a_i n! x^i (1-x)^{n-i}}{i!(n-i)!} \quad (11)$$

式中: $N_1, N_2$ —类函数决定系数,分别取 0.5 和 1 时表示钝头尖尾缘翼型; $a_i$ —型函数系数; $n$ —型函数阶数; $\Delta z$ —翼型尾缘厚度,mm。

为满足精度要求并减少系数变量,对上、下翼面分别选用 5 阶、6 阶型函数多项式进行拟合,共计 13 个系数变量对翼型进行参数化,且皆为尖尾缘翼型, $\Delta z$  设为 0。

### 1.3 翼型神经网络模型的训练

首先,确定形状参数的变化范围。在合理翼型的较大范围内将 NACA 四位数翼型的几何参数限定为:最大相对弯度( $1\% \leq m \leq 6\%$ );最大相对弯度位置( $30\% \leq p \leq 50\%$ );最大相对厚度( $11\% \leq t \leq 17\%$ )。将 3 组参数任意组合,代入改进后的 NACA 四位翼型族方程并参数化,计算可得 126 组 13 维系数向量,将其作为学习样本的输入部分。

然后,利用翼型分析软件 XFOIL 快速计算上述翼型在  $Re = 1.6 \times 10^6$ ,  $Ma = 0.37$  的工况下位于  $5^\circ$  攻角时的升阻比,将其作为学习样本的输出部分。

最后,对学习样本随机划分,90% 作为训练集,10% 作为测试集,建立广义回归网络模型,并验证其可靠性。

图 3 是神经网络的训练与预测结果。训练集的均方误差为  $5.37 \times 10^{-5}$ ,测试集的均方误差为 1.353 1,神经网络模型具有较好的预测能力以及较强的泛化能力。表 1 为部分测试样本数据。实际值与预测值的最大误差为 1.21%,最小误差仅为 0.05%,因此该神经网络模型具有较好的准确性与可靠性。

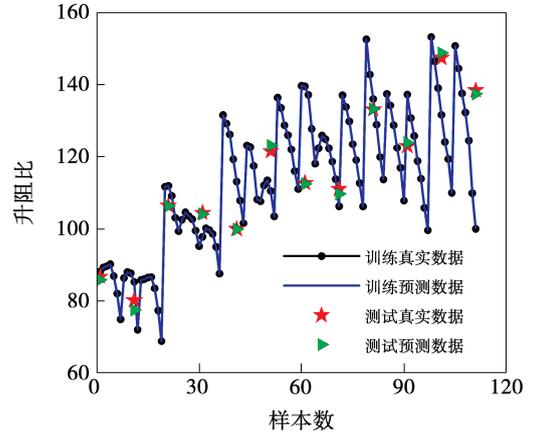


图 3 神经网络训练与预测结果

Fig. 3 Neural network training and prediction results

表 1 部分测试样本数据

Tab. 1 Partial test sample data

测试样本	升阻比实际值	升阻比预测值	误差/%
1	99.87	99.82	0.05
2	133.05	133.15	0.08
3	110.96	109.62	1.21
4	86.62	85.79	0.96

## 2 翼型的多约束条件

优化后的翼型应保持最大相对厚度不变,位置可适当前后移动,最大相对弯度与最大相对弯度位置在合理的范围内变化。因此,需要对翼型的 3 个形状参数施加约束,然后利用上述神经网络模型结合智能算法进行了多次优化设计。图 4 为翼型优化结果。该翼型的下翼面型线存在较多波动,不符合翼型设计规律,属于优化失败的问题翼型。

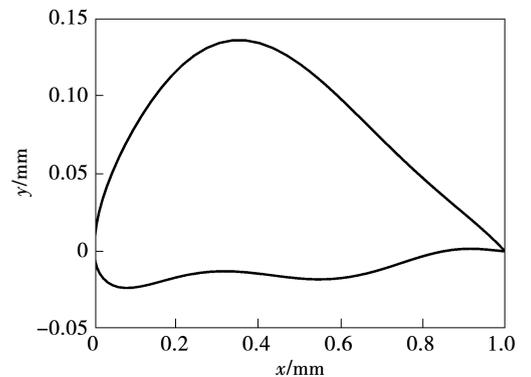


图 4 优化失败产生的问题翼型

Fig. 4 Incorrect airfoil due to optimization failure

初步分析优化失败原因可知,基于小样本集的神经网络模型因训练集较小,学习不充分,无法完全取代 XFOIL 或者 CFD 求解器。当输入向量符合翼型规律时,神经网络模型可以快速准确地预测其气动性能;反之,当输入向量不满足翼型形状时,神经网络模型则会产生较大误差。而神经网络与智能进化算法相结合进行优化设计时,以神经网络的输入作为智能算法的设计变量,其变化通常是随机的。因此,一部分错乱曲线将被输入神经网络模型,易产生误判,从而干扰整个优化进程。

进一步量化分析可知,下翼面设计变量的变化范围更小,且存在正负变换的情况。在小样本集的训练下,神经网络模型对下翼面的微小变化更加不敏感,因此优化翼型型线可能出现较多的波动,且气动性能预测误差较大。

针对上述问题,对翼型型线施加约束,避免错误曲线的出现,以提高神经网络模型预测能力。型线的波动等价于曲线弯曲方向的变化次数,因此对型线凹凸性变换次数进行限制。对于单个翼面而言,翼型型线凹凸性改变次数应不超过 1 次。

CST 参数化方程的一阶及二阶导函数为:

$$y'(x) = \sum_{i=0}^n \left[ \frac{a_i n!}{i!(n-i)!} [(i+0.5)x^{i-0.5}(1-x)^{n-i+1} - (n-i+1)x^{i+0.5}(1-x)^{n-i}] \right] \quad (12)$$

$$y''(x) = \sum_{i=0}^n \left[ \frac{a_i n!}{i!(n-i)!} [(i^2-0.25)x^{i-1.5}(1-x)^{n-i+1} - (2i+1)(n-i+1)x^{i-0.5}(1-x)^{n-i} + (n-i+1)(n-i)x^{i+0.5}(1-x)^{n-i}] \right] \quad (13)$$

计算每一个  $x$  的二阶导函数值,判断其正负性。总计算次数取决于翼型二维离散点数目,因此通过改进方程减少离散点总数可有效地降低计算量。当离散点的二维导数满足以下不等式时,可视为翼型型线凹凸性改变 1 次:

$$y''(x_i) \cdot y''(x_{i+1}) < 0, i = 1, 2, \dots, q-1 \quad (14)$$

式中: $q$ —单个翼面的离散点总数。

翼型强度与翼面面积直接相关。当翼面面积大

幅度减小时,将导致翼型强度降低,且难以与其他翼型相配合,因此需要对翼面面积做出约束,优化后翼型面积应不小于优化前。翼面面积计算公式为:

$$A = \sum_{i=1}^q x_i \cdot [y_{\text{upper}}(x_i) - y_{\text{lower}}(x_i)] \quad (15)$$

式中: $A$ —翼型面积,  $\text{mm}^2$ 。

### 3 气动优化实例与结果分析

#### 3.1 优化算法

利用粒子群算法与神经网络模型相结合进行风力机翼型优化设计。粒子群优化算法 (Particle Swarm Optimization, PSO) 是一种基于群体中个体之间相互协作和信息共享来寻找最优解的进化计算技术。粒子群算法结构简单、容易实现并且需要调节的参数少,其基本公式为:

$$\begin{cases} v_i = wv_i + e_1 r_1 (p_{\text{best}} - u_i) + \\ \quad e_2 r_2 (g_{\text{best}} - u_i) \\ u_i = u_i + v_i \end{cases} \quad (16)$$

式中: $v$ —粒子速度; $u$ —粒子位置; $w$ —惯性权重; $e_1$ ,  $e_2$ —学习因子; $p_{\text{best}}$ —个体最优粒子; $g_{\text{best}}$ —全局最优粒子; $r_1, r_2$ —0~1 之间的随机数。

#### 3.2 优化实例

以 NACA4415 为原始翼型,将 13 维 CST 参数化系数作为设计变量,在特定工况 ( $Re = 1.6 \times 10^6$ ,  $Ma = 0.37$  下以  $5^\circ$  攻角处的升阻比最大为目标进行优化设计。优化流程如图 5 所示。设置形参约束范围为最大相对厚度 15%、最大相对弯度 1%~6%、最大相对弯度位置 20%~50%。优化步骤为:

(1) 设置粒子群基本参数。种群规模为 80,最大迭代次数为 100,粒子维度为 13,采用自适应学习因子与惯性权重,学习因子极值为 0.9 和 2.4,惯性权重初始值和结束值设为 0.9 和 0.4。

(2) 设计变量范围界定。优化翼型厚度限制在 15%,以样本库中 15% 厚度翼型的 CST 参数化系数作为边界值,对其取交集,初步可得设计变量范围,如表 2 所示。

(3) 种群初始化。在设计变量范围内随机挑选

初始粒子,所选粒子组成的翼型最大相对厚度应为 15%,以提高优化效率,并将 NACA4415 的 CST 参数化系数设为一组初始粒子传入粒子初始种群。

(4) 以升阻比最大为目标函数,通过神经网络模型计算适应度值,并将型线凹凸性约束、翼面面积约束、形参约束以罚函数的形式加入适应度函数。

(5) 迭代优化,获取最佳翼型。

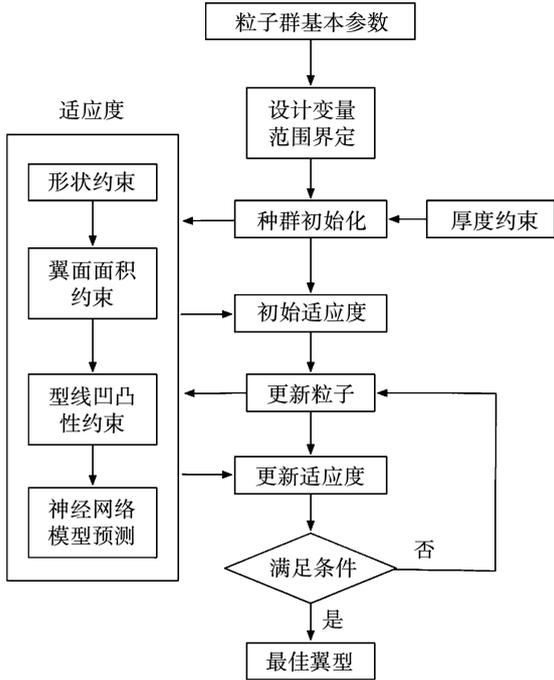


图 5 优化流程

Fig. 5 Optimization flow chart

表 2 CST 参数取值范围

Tab. 2 CST parameter value range

CST 参数	上限	下限
1	0.335 8	0.225 0
2	0.347 2	0.212 2
3	0.437 8	0.220 3
4	0.334 6	0.207 0
5	0.402 0	0.190 4
6	0.456 3	0.239 9
7	-0.131 5	-0.204 9
8	-0.042 7	-0.174 6
9	0.047 2	-0.192 0
10	-0.014 3	-0.163 5
11	0.076 1	-0.194 5
12	0.072 0	-0.114 0
13	0.020 4	-0.195 6

### 3.3 优化结果分析

粒子群优化算法的迭代次数如图 6 所示。适应度值在迭代 49 次后收敛于 135.9。

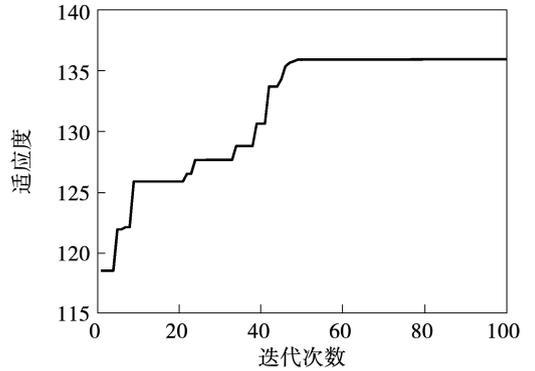


图 6 优化收敛结果

Fig. 6 The results of optimization convergence

将全局最佳粒子作为系数向量代回 CST 参数化方程,计算可得优化翼型的二维离散点坐标。与 NACA - 4415 原始翼型的形状进行对比,结果如表 3 所示。该优化翼型的最大相对厚度为 15%,位于弦向位置  $x/c = 0.342$  处,最大相对弯度为 5.36%,位于弦向位置  $x/c = 0.434$  处。与原始翼型相比,优化后获得的新翼型最大相对厚度保持不变,最大相对弯度增加,且最大厚度位置与最大弯度位置皆后移。图 7 为优化前后翼型对比图。

表 3 翼型形状参数

Tab. 3 Parameters of airfoil shape

翼型	最大相对弯度/%	最大弯度位置/%	最大相对厚度/%	最大厚度位置/%	面积/ $\text{mm}^2$
原始	4.02	40.29	15.00	30.00	0.10
优化	5.36	43.44	15.00	34.20	0.10

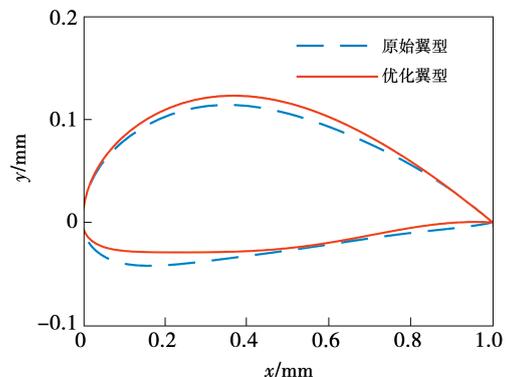


图 7 优化前后翼型对比图

Fig. 7 Comparison of profiles between original airfoil and optimized airfoil

为验证该结果的可信度及多约束条件的有效性,将该优化翼型与其他约束条件下的优化结果进行了对比,如图 8 所示。翼型 1,2,3 分别为只有形参约束、形参约束加面积约束、形参约束加型线凹凸性约束的优化结果,优化翼型为多约束下的优化结果。将 4 种翼型代入 XFOIL,在  $Re = 1.6 \times 10^6$ ,  $Ma = 0.37$ 、固定转捩的工况下,计算了其在  $5^\circ$  攻角下的升阻比,并与神经网络预测值进行了对比,结果如表 4 所示。多约束条件下神经网络预测值与计算值的误差最小,仅为 0.52%,结果具有较高的可信度,而且实际优化效果优于其他约束,因此可认为多约束条件是有效的。

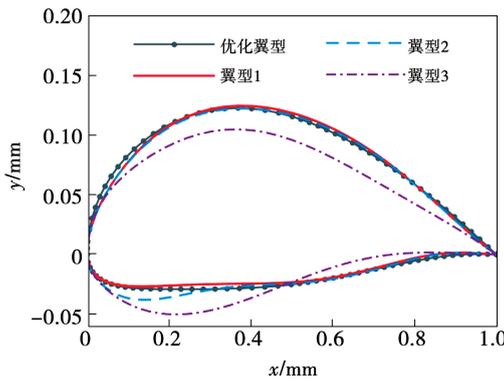


图 8 不同约束下的翼型优化结果对比

Fig. 8 Comparison of airfoil optimization results under different constraints

表 4 优化结果误差比较

Tab. 4 The errors of optimization results

翼型	计算升阻比	预测升阻比	误差/%
优化	135.2	135.9	0.52
1	128.7	145.9	13.36
2	121.0	142.3	17.60
3	124.2	137.1	10.38

在上述工况下,利用 XFOIL 对比原始翼型与优化翼型的气动性能,将两种翼型在  $0^\circ \sim 20^\circ$  攻角下作气动特性分析。

图 9 是两种翼型的升力系数对比图。分析图中数据可知,在  $14^\circ$  攻角时原始翼型的最大升力系数为 1.472 1。在  $15.8^\circ$  攻角时优化翼型的最大升力系数为 1.574 6。优化翼型的最大升力系数相较于

原始翼型提升了 6.96%。在  $0^\circ \sim 4^\circ$  攻角时,优化翼型的升力系数远远高于原始翼型。 $4^\circ$  攻角以后,新翼型的升力系数也始终优于原始翼型。随着攻角的增加,其升力优势逐渐增大。且在  $3^\circ \sim 5^\circ$  攻角时,原始翼型的升力系数存在跃增情况,即短时间内翼型受力增大。这对翼型的结构强度不利,而优化翼型整体升力系数变化平稳,因此新翼型具有更好的结构特性。

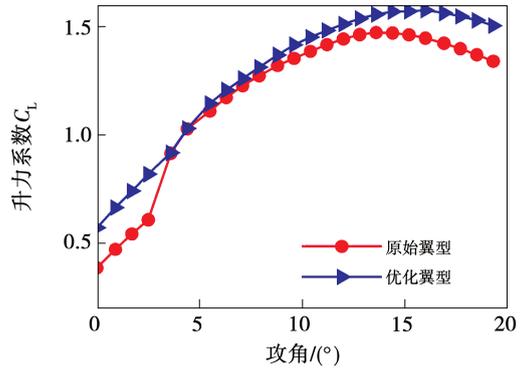


图 9 两种翼型升力系数对比图

Fig. 9 The lift coefficients of two airfoils

图 10 是翼型优化前后的阻力系数对比图。原始翼型和优化翼型在  $0^\circ \sim 14^\circ$  攻角范围内阻力系数相差无几,但  $14^\circ$  攻角以后优化翼型具有更低的阻力系数。

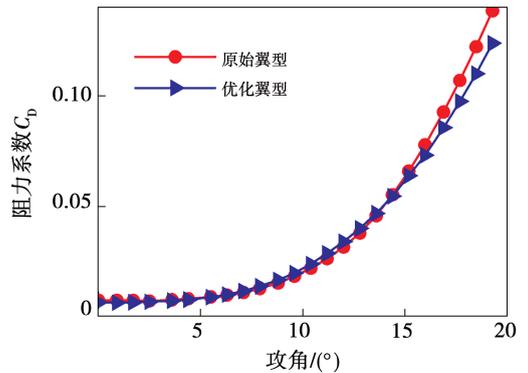


图 10 两种翼型阻力系数对比图

Fig. 10 The drag coefficients of two airfoils

图 11 是两种翼型的升阻比曲线对比图。在  $4.4^\circ$  攻角时原始翼型的最大升阻比为 129.13。在  $4.6^\circ$  攻角时优化翼型的最大升阻比为 138.65。相比于原始翼型,优化翼型的最大升阻比提高了

7.37%。在  $0^\circ \sim 6^\circ$  攻角范围内,新翼型升阻比明显优于原始翼型,提升幅度最大达 70.7%,出现在  $0.1^\circ$  攻角。 $6^\circ$  攻角以后,新翼型的升阻比与原始翼型相差不大。总体来说,优化后获得的新翼型在气动性能方面有较大提升,尤其是在  $0^\circ \sim 6^\circ$  攻角范围内。

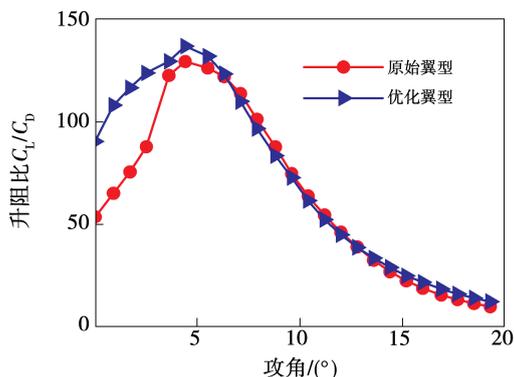


图 11 两种翼型升阻比曲线对比图

Fig. 11 The lift-drag ratios of two airfoils

随机记录了 4 组使用神经网络模型和调用 XFOIL 计算一次翼型气动性能的时间进行比较,结果如表 5 所示。分析表中数据可知,使用神经网络模型可节省大量的计算时间,计算速度平均增长 51.6 倍,可实现翼型的快速优化设计。

表 5 两种方法时间对比

Tab. 5 Time comparison of the two methods

组别	神经网络计算时间/s	XFOIL 计算时间/s
1	0.006 8	0.344 6
2	0.005 9	0.333 8
3	0.006 1	0.336 9
4	0.006 4	0.346 9

## 4 结 论

(1) 对 NACA 四位翼型族方程进行了改进,增加了 1 个翼型离散点的分布改进式,在降低总点数的同时,实现了对翼型更加合理精确的描述,并验证了该改进式的有效性。

(2) 基于小样本集建立了广义回归神经网络模型,实现了翼型气动性能的准确预测。针对小样本神经网络学习不充分的问题,提出使用多约束条件

限制设计变量,避免错乱曲线的出现。并将其与粒子群优化算法相结合求解气动特性进行翼型优化设计,获得了最大相对厚度为 15% 的新翼型。与原始翼型相比,新翼型在主要工作攻角范围内最大升力系数提高了 6.96%,最大升阻比提高了 7.37%,升阻比提升幅度最大达 70.7%,气动性能明显改善。且该方法的优化效率远远高于传统方法,单次计算速度提升 51.6 倍,从而验证了该方法的有效性。

## 参考文献:

- [1] FERNANDEZ M G, PARK C, KIM N H, et al. Issues in deciding whether to use multifidelity surrogates[J]. AIAA Journal, 2019, 57(5): 2039 - 2054.
- [2] PARK C, HAFTKA R T, KIM N H. Remarks on multi-fidelity surrogates[J]. Structural and Multidisciplinary Optimization, 2017, 55(3): 1029 - 1050.
- [3] 姚琳. 机器学习在翼型优化问题中的应用[J]. 航天标准化, 2020(1): 43 - 47.  
YAO Lin. Application of machine learning to airfoil optimization problems[J]. Aerospace Standardization, 2020(1): 43 - 47.
- [4] OZTIRYAKI F G, PISKIN T. Airfoil performance analysis using shallow neural networks [C]//AIAA Scitech 2021 Forum, 2021: 0174.
- [5] BALLA K, SEVILLA R, HASSAN O, et al. An application of neural networks to the prediction of aerodynamic coefficients of aerofoils and wings[J]. Applied Mathematical Modelling, 2021(96): 456 - 479.
- [6] ZAHN R, BREITSAMTER C. Airfoil buffet aerodynamics at plunge and pitch excitation based on long short-term memory neural network prediction[J]. CEAS Aeronautical Journal, 2021: 1 - 11.
- [7] BAEK J H, PARK S H. Feedback flow control using artificial neural network for pressure drag reduction on the NACA0015 airfoil [J]. Journal of the Korean Society for Aeronautical & Space Sciences, 2021, 49(9): 729 - 738.
- [8] 刘凌君, 周越, 高振勋. 基于神经网络的翼型气动力计算和反设计方法[J]. 气体物理, 2018, 3(5): 41 - 47.  
LIU Ling-jun, ZHOU Yue, GAO Zhen-xun. Aerodynamic force calculation and inverse design for airfoil based on neural network[J]. Physics of Gases, 2018, 3(5): 41 - 47.
- [9] 郑天韵, 王圣业, 王光学, 等. 基于深度残差网络的高精度自然

- 转换模拟方法[J]. 物理学报,2020,69(20):275-286.
- ZHENG Tian-yun, WANG Sheng-ye, WANG Guang-xue, et al. High-order natural transition simulation method based on deep residual network [J]. Acta Physica Sinica, 2020, 69 ( 20 ): 275 - 286.
- [10] 吴秋雨. 基于生成式对抗网络的气动外形优化方法研究[D]. 成都:电子科技大学,2021.
- WU Qiu-yu. Research on aerodynamic shape optimization method based on generative adversarial network[D]. Chengdu:University of Electronic Science and Technology of China,2021.
- [11] MARZABADI F R, MASDARI M, SOLTANI M R. Application of artificial neural network in aerodynamic coefficient prediction of subducted airfoil[J]. Journal of Research in Science and Engineering, 2020, 2(1):13-17.
- [12] KHARAL A, SALEEM A. Neural networks based airfoil generation for a given  $C_p$  using Bezier-PARSEC parameterization[J]. Aerospace Science and Technology, 2012, 23(1):330-344.
- [13] STOLZMAN J E, MANOHARAN S. Testing the efficacy of dimples on a NACA airfoil at low Reynolds numbers: a numerical study[C]. AIAA Aviation 2021 Forum, 2021:2584.
- [14] 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 Zhong-hua. 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.
- [15] 孙祥程, 韩忠华, 柳 斐, 等. 高超声速飞行器宽速域翼型/机翼设计与分析[J]. 航空学报, 2018, 39(6):31-42.
- SUN Xiang-cheng, HAN Zhong-hua, LIU Fei, et al. Design and analysis of hypersonic vehicle airfoil/wing at wide-range Mach numbers[J]. Acta Aeronautica et Astronautica Sinica, 2018, 39(6):31-42.
- [16] 张启鹏. 超临界自然层流翼型优化方法研究[D]. 南京:南京航空航天大学,2018.
- ZHANG Qi-peng. Optimization methods for supercritical natural laminar airfoils[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2018.

(刘 颖 编辑)



## GE 公司和印度国家电力公司联合开展燃气轮机掺烧氢气技术测试

美国通用电气公司(GE)和印度国家电力公司(NTPC)就 GE 9E 燃气轮机开展天然气掺烧氢气测试研究达成协议。协议确定将 NTPC 在吉吉拉特邦的 645 兆瓦 Kawas 联合循环电厂作为掺氢燃烧项目的研究试点,该电厂由 GE 公司生产的 4 台透平提供动力,项目所需的氢气由 NTPC 公司提供。GE 公司表示,即将在 Kawas 电厂实施 5% 混合氢的燃烧测试,并在燃料中的氢体积含量超过 5% 时,对燃气轮机辅助设备进行升级改造,最高可实现纯氢燃烧。这是 GE 公司在印度签署的第一项此类协议,而 GE 公司此前已在全球拥有超过 100 台燃气轮机支持使用氢和相关燃料进行脱碳发电。

另据报道,GE 公司与纽约电力公司(NYPA)和电力研究所(EPRI)联合公布了位于长岛的布伦特伍德小型清洁发电厂的氢气掺烧试验结果。在 GELM-6000 燃气轮机发动机中使用 5% - 44% 的混合氢进行掺烧试验,通过试验数据分析,研究结果符合预期发展趋势,碳排放量随着氢含量的增加而减少。

(孙嘉忆摘译自 <https://www.powerengineeringint.com>)