

# 基于集成学习的飞机气动力快速预测方法研究



刘哲, 郭承鹏, 李鸿岩, 崔榕峰

中国航空工业空气动力研究院 高速高雷诺数气动力航空科技重点实验室, 辽宁 沈阳 110034

**摘要:**现代飞机设计对气动外形优化效率的要求不断提高,传统气动力获取方法(如风洞试验或计算流体力学(CFD)数值仿真方法)成本高、效率低,探索高效的气动力获取方法对减少风洞试验或数值仿真成本、提高飞机迭代设计效率具有重要意义。本文提出一种基于集成学习的飞机气动力快速预测方法,将线性回归模型、多层感知机模型、梯度提升模型堆叠,对不同机翼展长、根弦比、尖弦长的飞翼布局无人机在不同迎角下的气动力系数进行预测。结果表明,建立的集成学习模型能够快速准确预测飞机气动力系数,测试集升阻力系数均方误差分别为 $0.208 \times 10^{-4}$ 和 $0.424 \times 10^{-5}$ ,平均绝对误差分别为 $0.27 \times 10^{-2}$ 和 $0.1379 \times 10^{-2}$ ,拟合度分别为0.9994976和0.9691,预测时间为0.8s,仅为面元法计算时间的1/4500,有效地提高了飞机气动外形设计效率。

**关键词:**气动力; 集成学习; 快速预测; 梯度提升模型; 堆叠法

中图分类号: V211.3

文献标识码: A

DOI: 10.19452/j.issn1007-5453.2024.11.002

近年来,随着我国航空装备的不断发展,武器装备更新迅速,逐渐进入与世界航空强国竞技的新阶段<sup>[1]</sup>。先进航空武器装备的迅速发展给飞机总体设计带来了新的挑战,飞机总体设计涉及气动设计、结构设计,其中,气动设计作为飞机总体设计的首要环节,直接决定了飞机飞行过程的气动性能。合理的飞机气动外形将有效地提高升阻比,减少飞行阻力,提高飞机的经济性。为了满足现代飞机气动外形设计的需求,快速获得不同外形飞机的气动性能至关重要。飞机气动性能的研究方法主要包括理论分析、风洞试验和数值仿真。其中理论分析往往需要做出大量的简化和假设,因此最常用的方法为风洞试验和数值仿真。风洞试验对试验条件和设施要求较高,试验设备的维护需要大量费用,试验周期长,试验过程复杂,存在支架、洞壁等干扰因素,无法满足越来越迅速的飞机设计需求。随着计算机软硬件的迅猛发展,计算流体力学(CFD)数值仿真方法逐渐成为获取飞机气动性能的主要研究手段。但CFD方法需要求解偏微分方程组,计算效率不高,尤其对于需要修改外形的飞机预研选型阶段,不断变换飞机外形几何参数将

会大幅增加CFD数值仿真的难度及计算成本。

近年来,随着大数据、机器学习、深度学习等技术的迅速发展和计算机硬件水平的不断提高,国内外部分学者将机器学习等数据驱动方法用于翼型<sup>[2]</sup>、导弹<sup>[3-4]</sup>、飞机<sup>[5]</sup>的气动力预测,与CFD数值仿真方法相比,数据驱动方法无须大量的迭代计算,能够迅速获得气动性能数据。Rajkumar等<sup>[6]</sup>研究了基于神经网络的气动系数预测方法,将气动系数转换为速度、迎角、侧滑角等参数的多项式函数。训练数据来源于风洞试验和数值模拟结果,重点评估了高效预测神经网络框架所需的训练数据和传递函数。研究结果表明,神经网络框架能够准确预测气动系数。Peng Wenhui等<sup>[7]</sup>提出了一种用于预测翼型升力系数的神经网络,即空间单元卷积神经网络,输入翼型坐标和迎角,输出升力系数,结果表明该网络快速实现了对翼型升力系数的高精度预测。

国内学者钱炜祺等<sup>[8]</sup>使用支持向量机(SVM)和深度神经网络(DNN)构建了翼型类别形状函数变换(CST)参数与典型工况下气动力之间的预测模型,结果表明在拟合和泛

收稿日期: 2024-04-22; 退修日期: 2024-07-31; 录用日期: 2024-09-26

基金项目: 航空科学基金(2022Z006026004, 2023M071027001)

引用格式: Liu Zhe, Guo Chengpeng, Li Hongyan, et al. Research on rapid prediction method of aircraft aerodynamics based on ensemble learning[J]. Aeronautical Science & Technology, 2024, 35(11): 13-18. 刘哲, 郭承鹏, 李鸿岩, 等. 基于集成学习的飞机气动力快速预测方法研究[J]. 航空科学技术, 2024, 35(11): 13-18.

化能力方面,深度神经网络模型明显优于SVM模型。吕召阳等<sup>[9]</sup>基于卷积神经网络考虑机翼的不同状态建立了一种多变量多输出的模型,实现了机翼气动系数的快速预测。结果表明,其具有较高的预测精度并且其计算效率较CFD提高40倍。胡伟杰等<sup>[10]</sup>提出了一种基于高斯过程回归代理模型快速预测典型导弹气动性能的方案。以导弹外形参数和迎角作为模型输入,升力系数、阻力系数和力矩系数作为模型输出。结果表明,与其他常用代理模型的预测精度对比,高斯过程回归模型精度高于其他代理模型的预测精度,能够满足导弹设计初期快速且精确的气动力预测需求。彭博等<sup>[11]</sup>基于支持向量回归算法构建了火箭气动力预测代理模型,结果表明该模型预测气动力的效率远高于CFD仿真,且预测精度高于气动设计阶段要求的精度水平。

尽管部分国内外学者对气动性能预测方法已经进行了初步尝试,但针对不同外形几何参数的飞机气动力预测研究相对较少。为了迅速获取精确的不同外形飞机气动力,本文构建不同外形几何参数的飞翼布局无人机气动数据集,通过面元法获取不同外形几何参数飞机在不同迎角下的气动力系数,并建立集成学习模型对飞机气动力进行快速预测。

## 1 集成学习算法

集成学习算法是通过训练若干个学习器,通过一定的结合策略,来完成学习任务,能够获得比单一学习显著优越的学习器,从而形成一个强学习器<sup>[12]</sup>。其中堆叠集成模型<sup>[13]</sup>通过多个基学习器学习原数据,然后将这几个基学习算法学习到的数据输出给第二层模型进行拟合。本文中第一层基学习器采用的是线性回归模型、多层感知机模型和梯度提升模型,第二层模型为线性回归模型,下面对机器学习模型的基本原理进行介绍。

### 1.1 多层感知机

多层感知机(MLP)<sup>[14]</sup>即人工神经网络,MLP是由获取其他神经元输入的多个神经元组成,将它们乘以相应的权重并叠加,最后输出给一个或多个神经元。MLP是通过梯度下降法来寻找可能的权矢量的假设空间,以获得最佳拟合效果的权重。

$$y = w^T \max \{0, W^T x + c\} + b \quad (1)$$

式中, $W$ 和 $w$ 为输入层到隐藏层和隐藏层到输出层的权重。 $c$ 和 $b$ 为输入层到隐藏层和隐藏层到输出层的偏差。MLP包括输入层、隐藏层、输出层,如图1所示。

MLP模型的具体计算步骤如下:(1)初始化神经网络




图1 MLP结构图

Fig.1 MLP structure diagram

中的权重和偏置;(2)激活前向传播;(3)计算输出单元的误差和隐藏单元的误差;(4)更新神经网络中的权重和偏置;(5)重复步骤(2)~(4),直到损失函数小于设定的阈值或迭代轮次结束为止。

### 1.2 梯度提升模型

提升算法(Boosting)<sup>[15]</sup>是一种将弱学习器提升为强学习器的算法,基本原理是训练一个弱学习器,再根据弱学习器的表现对训练样本分布进行调整,使得先前基学习器效果不好的样本在后续训练中获得更多的关注,基于调整后的样本分布训练下一个弱学习器,如此反复,直至弱学习器数目达到预先设定值 $T$ ,最后将 $T$ 个弱学习器加权结合。梯度提升(Gradient Boosting)模型通过损失函数的负梯度将当前模型的值作为提升树算法中的残差的近似值,来拟合一个回归树,具体计算步骤如下。

(1) 初始化弱学习器

$$f_0(x) = \arg \min_c \sum_{i=1}^n L(y_i, c) \quad (2)$$

式中, $L$ 为损失函数, $c$ 为损失函数达到最小值时的常数, $n$ 为样本数量。

(2) 创建新的回归树以最小化损失函数

计算负梯度估计残差

$$r_{mj} = - \left[ \frac{\partial L(y_i, f(x_i))}{\partial f(x_i)} \right]_{f(x)=f_{m-1}(x)} \quad (3)$$

创建回归树,对应叶子节点区域为 $R_{mj}, j=1, 2, 3, \dots, J$ 。

通过损失函数最小化计算叶子节点区域的最佳拟合值

$$c_{mj} = \arg \min_c \sum_{x_i \in R_{mj}} L(y_i, f_{m-1}(x_i) + c) \quad (4)$$

更新强学习器,最终表示为

$$f_m(x) = f_{m-1}(x) + \sum_{j=1}^J c_{mj} I_j, \quad x \in R_{mj} \quad (5)$$

$$I_j = \begin{cases} 1, & x \in R_{mj} \\ 0, & x \notin R_{mj} \end{cases}$$

(3) 获得最终强学习器

$$f(x) = f_M(x) = f_0(x) + \sum_{m=1}^M \sum_{j=1}^J c_{mj} I, \quad x \in R_{mj} \quad (6)$$

## 2 数据集生成

以某飞翼布局无人机为例,气动外形参数变量为第1段机翼展长  $S_1$ 、根弦长  $R_{C1}$ 、尖弦长  $T_{C1}$  和第3段机翼尖弦长  $T_{C3}$ ,如图2所示。基于拉丁超立方采样(LHS)法对外形参数进行采样,确定80组飞机外形,各个外形参数变量的统计分析如表1、图3和图4所示。从中可以看出,气动外形参数在一定范围内变化,各外形参数具有差异性。

通过面元法对马赫数为0.7,侧滑角 $0^\circ$ 、迎角分别为 $0^\circ$ 、 $2^\circ$ 、 $4^\circ$ 和 $6^\circ$ 下不同外形参数飞机的气动性能进行计算。面元法的基本思想是通过四边形或三角形面元近似几何模型,核心是将飞机表面分解为一系列简单面元,每个面元均被视为一个独立单元,将整个飞机的气动特性计算转化为对每个面元的求解,最后进行积分<sup>[16]</sup>。




图2 某飞翼布局无人机外形参数变量

Fig.2 Shape parameter variables of flying-wing UAV

表1 外形参数变量统计分析

Table 1 Statistical analysis table of shape parameter variables

变量	$S_1/m$	$R_{C1}/m$	$T_{C1}/m$	$T_{C3}/m$
最小值	8.04	18	6.1	1.02
最大值	9.94	19.54	6.98	2.94
平均值	9.02	18.53	6.68	2.03

## 3 气动力预测

将生成的64组外形在不同迎角下的气动力数据作为训练集,16组外形在不同迎角下的气动力数据作为测试集,将飞机外形参数(第1段机翼展长  $S_1$ 、根弦长  $R_{C1}$ 、尖弦长  $T_{C1}$  和第3段机翼尖弦长  $T_{C3}$ )和迎角作为自变量,分别以升力系数和阻力系数为因变量。对自变量数据进行归一化操作,归一化公式为




图3 外形参数变量数据分布

Fig.3 Data distribution of shape parameter variables




图4 外形参数变量数据箱线图

Fig.4 Data boxplot of shape parameter variables

$$x_i^s = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (7)$$

式中,  $x_i^s$  为归一化后数据,  $x_i$  为原始数据,  $x_{\min}$  为数据最小值,  $x_{\max}$  为数据最大值。

通过Python语言及Sklearn<sup>[17]</sup>包搭建集成堆叠(Stacking)模型,该模型的具体结构如图5所示。第一层基学习器由MLP模型、线性回归(LR)模型、Gradient Boosting模型组成,第二层为LR模型。

其中MLP模型隐藏层层数为2,节点数50,优化器为Adam优化算法<sup>[18]</sup>,最大迭代次数500。模型评价标准为均方误差(MSE)、平均绝对值误差(MAE)和拟合度  $R^2$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - f(x_i))^2 \quad (8)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - f(x_i)| \quad (9)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - f(x_i))^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (10)$$

式中,  $y_i$  为真实值,  $f(x_i)$  为模型预测值,  $\bar{y}$  为真实平均值。

分别建立外形参数、迎角与升力系数、阻力系数的

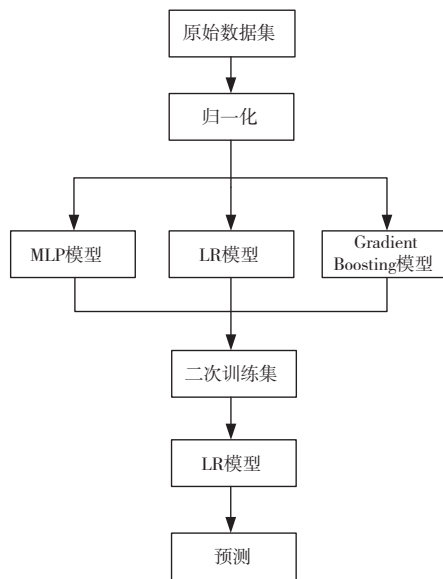


图5 Stacking模型结构图

Fig.5 Stacking model structure diagram

MLP模型、Gradient Boosting模型、Stacking模型。不同机器学习模型预测升力系数 $C_L$ 的均方误差、平均绝对误差和拟合度见表2, Stacking模型预测误差略低于Gradient Boosting模型, MSE为 $0.208 \times 10^{-4}$ , MAE为 $0.27 \times 10^{-2}$ , 模型拟合度为0.9994976, 相比其他机器学习模型更加接近于1, 说明Stacking模型预测升力系数效果最好。

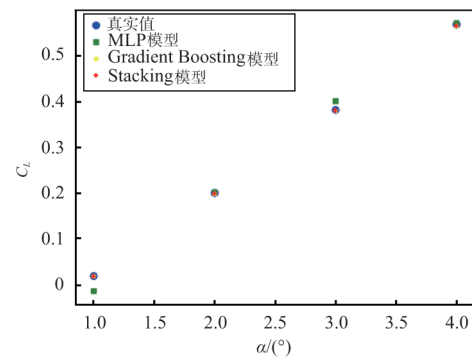
表2 不同模型升力系数 $C_L$ 预测误差对比Table 2 Comparison between lift coefficient  $C_L$  prediction error of different models

	MSE	MAE	$R^2$
MLP模型	$0.1 \times 10^{-2}$	$0.264 \times 10^{-1}$	0.9753
Gradient Boosting模型	$0.212 \times 10^{-4}$	$0.28 \times 10^{-2}$	0.9994873
Stacking模型	$0.208 \times 10^{-4}$	$0.27 \times 10^{-2}$	0.9994976

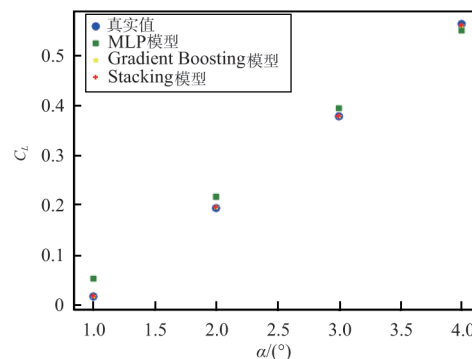
取测试集中的两组算例进行比较, 不同模型的升力系数预测结果对比如图6所示。从图6中可以看出, 升力系数 $C_L$ 随迎角 $\alpha$ 增加呈线性增加趋势, MLP模型预测效果最差, Gradient Boosting模型和Stacking模型预测结果相差不大。

不同机器学习模型预测阻力系数 $C_D$ 的均方误差、平均绝对误差和拟合度见表3, Stacking模型预测误差略低于Gradient Boosting模型, MSE为 $0.424 \times 10^{-5}$ , MAE为 $0.1379 \times 10^{-2}$ , 模型拟合度为0.9691, 相比其他机器学习模型更加接近于1, 说明Stacking模型预测阻力系数效果最好。

不同模型的阻力系数预测结果对比如图7所示。从图7



(a) 测试算例1



(b) 测试算例2

图6 升力系数 $C_L$ 预测结果对比Fig.6 Comparison between lift coefficient  $C_L$  prediction results表3 不同模型阻力系数 $C_D$ 预测误差对比Table 3 Comparison between drag coefficient  $C_D$  prediction error of different models


	MSE	MAE	$R^2$
MLP模型	$0.47 \times 10^{-3}$	$0.17 \times 10^{-1}$	0.1520
Gradient Boosting模型	$0.43 \times 10^{-5}$	$0.137903 \times 10^{-2}$	0.9686
Stacking模型	$0.424 \times 10^{-5}$	$0.1379 \times 10^{-2}$	0.9691

中可以看出, 阻力系数 $C_D$ 随迎角 $\alpha$ 增加呈非线性增加趋势, MLP模型预测效果相对升力系数 $C_L$ 的预测更差, Gradient Boosting模型和Stacking模型预测结果相差不大。

## 4 结论

本文提出了一种基于集成学习的飞机气动力预测方法, 以某飞翼布局无人机为例, 通过面元法构建不同机翼展长、根弦长、尖弦长无人机气动力数据集, 分别建立MLP模型、Gradient Boosting模型、Stacking模型预测飞机气动力系数, 预测时间为0.8s, 仅为面元法计算时间的1/4500。本文提出的研究方法能够实现对不同外形几何参数飞机气动力的快速预测, 有助于减少飞机气动力计算成本, 提高飞机气



图7 阻力系数  $C_D$  预测结果对比Fig.7 Comparison between drag coefficient  $C_D$  prediction results

动外形设计效率,大幅提升飞机的研制发展进程。通过研究,得到以下结论:

(1) 无论是升力系数还是阻力系数,就均方误差MSE和平均绝对误差MAE而言,Stacking模型预测误差均略低于Gradient Boosting模型,MLP模型预测误差最大。

(2) 就拟合度  $R^2$  而言,Stacking模型  $R^2$  均略高于Gradient Boosting模型,MLP模型  $R^2$  最小。说明Stacking模型预测升阻力系数效果最好,MLP模型预测效果最差。

AST

## 参考文献

- [1] 樊会涛,段鹏飞,袁成. 航空颠覆性技术初探[J]. 航空学报, 2024, 45(5):16-32.  
Fan Huitao, Duan Pengfei, Yuan Cheng. Disruptive technologies in aviation: Preliminary study[J]. Acta Aeronautica et Astronautica Sinica, 2024, 45(5): 16-32.(in Chinese)
- [2] 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 Lingjun, Zhou Yue, Gao Zhenxun. Aerodynamic force calculation and inverse design for airfoil based on neural network[J]. Physics of Gases, 2018, 3(5): 41-47.(in Chinese)
- [3] 原智杰,张公平,崔茅,等. 基于神经网络的导弹气动参数预测[J]. 航空兵器, 2020, 27(5): 28-32.  
Yuan Zhijie, Zhang Gongping, Cui Mao, et al. Prediction of missile's aerodynamic parameters based on neural network[J]. Aero Weaponry, 2020, 27(5): 28-32. (in Chinese)
- [4] 崔榕峰,马海,郭承鹏,等. 基于贝叶斯超参数优化的Gradient Boosting方法的导弹气动特性预测[J]. 航空科学技术, 2023, 34(7): 22-28.  
Cui Rongfeng, Ma Hai, Guo Chengpeng, et al. Prediction of missile aerodynamic data based on Gradient Boosting under Bayesian hyperparametric optimization[J]. Aeronautical Science & Technology, 2023, 34(7): 22-28.(in Chinese)
- [5] 周岭,周铸,蔺佳哲,等. 一种基于神经网络的飞行器气动特性预测方法:中国, CN113609596A[P]. 2021-11-05.  
Zhou Ling, Zhou Zhu, Lin Jiazhe, et al. A method based on neural network for predicting aerodynamic characteristics of aircraft: China, CN113609596A[P]. 2021-11-05.(in Chinese)
- [6] Rajkumar T, Bardina J E. Prediction of aerodynamic coefficients using neural networks for sparse data[C]//Proceedings of the Fifteenth International Florida Artificial Intelligence Research Society Conference, 2002.
- [7] Peng Wenhui, Zhang Yao, Laurendeau E, et al. Learning aerodynamics with neural network[J]. Scientific Report, 2022, 12(1): 6779.
- [8] 钱炜祺,赵瞰,黄勇,等. 工程翼型气动特性数据挖掘与建模[J]. 空气动力学学报, 2021, 39(6): 175-183.  
Qian Weiqi, Zhao Tun, Huang Yong, et al. Modeling and data mining of engineering airfoil aerodynamic characteristics[J]. Acta Aerodynamica Sinica, 2021, 39(6): 175-183. (in Chinese)
- [9] 吕召阳,聂雪媛,赵奥博. 基于CNN机翼气动系数预测[J]. 北京航空航天大学学报, 2023, 49(3): 674-680.  
Lyu Zhaoyang, Nie Xueyuan, Zhao Aobo. Prediction of wing aerodynamic coefficient based on CNN[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(3): 674-680. (in Chinese)
- [10] 胡伟杰,黄增辉,刘学军,等. 基于自动核构造高斯过程的导弹气动性能预测[J]. 航空学报, 2021,42(4): 524093.  
Hu Weijie, Huang Zenghui, Liu Xuejun, et al. Missile

- aerodynamic performance prediction of Gaussian process through automatic kernel construction[J]. *Acta Aeronautica et Astronautica Sinica*, 2021, 42(4): 524093.(in Chinese)
- [11] 彭博, 聂蓉梅, 陈海东. 基于支持向量机的火箭气动学科代理模型构建方法[J]. *导弹与航天运载技术*, 2013(4): 33-37.  
Peng Bo, Nie Rongmei, Chen Haidong. Surrogate model construction for rocket aerodynamic discipline based on support vector machine[J]. *Missiles and Space Vehicles*, 2013 (4): 33-37. (in Chinese)
- [12] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016.  
Zhou Zhihua. *Machine learning*[M]. Beijing: Tsinghua University Press, 2016.(in Chinese)
- [13] Wolpert D H. Stacked generalization[J]. *Neural Networks*, 1992, 5(2):241-259.
- [14] Ramchoun H, Amine M, Idrissi J, et al. Multilayer Perceptron: Architecture Optimization and Training[J]. *International Journal of Interactive Multimedia and Artificial Intelligence*, 2016, 4 (1): 26.
- [15] Friedman J H. Greedy function approximation: a gradient boosting machine[J]. *Annals of Statistics*, 2001, 29(5): 1189-1232.
- [16] 徐增. 高超声速飞行器外形优化设计研究[D]. 南京: 南京航空航天大学, 2017.  
Xu Zeng. Shape optimization of hypersonic vehicle for concept design[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2017.(in Chinese)
- [17] Swami A, Jain R. Scikit-learn: machine learning in python[J]. *Journal of Machine Learning Research*, 2013, 12(10):2825-2830.
- [18] Kingma D P, Ba J L. Adam: a Method for Stochastic Optimization[J]. arXiv:1412.6980v8, 2015.

## Research on Rapid Prediction Method of Aircraft Aerodynamics Based on Ensemble Learning

Liu Zhe, Guo Chengpeng, Li Hongyan, Cui Rongfeng

*Aviation Key Laboratory of Science and Technology on Aerodynamics of High Speed and High Reynolds Number, AVIC Aerodynamics Research Institute, Shenyang 110034, China*

**Abstract:** The demand for aerodynamic shape optimization efficiency in modern aircraft design is constantly increasing. Traditional aerodynamic force acquisition methods such as the wind tunnel experiment or the CFD numerical simulation have high costs and low efficiency. Exploring efficient aerodynamic force acquisition methods is of great significance in reducing wind tunnel testing or numerical simulation costs and improving aircraft iterative design efficiency. A fast prediction method for aircraft aerodynamics based on ensemble learning is proposed in this article. The linear regression model, multi-layer perceptron model, and gradient boosting model are stacked to predict the aerodynamic force coefficients of the flying wing layout drones with different wing span lengths, root chord ratios, and tip chord lengths at different angles of attack. The results show that the established ensemble learning model can predict the aerodynamic coefficients of aircraft quickly and accurately. The mean square errors of the lift and drag coefficients in the test sets are  $0.208 \times 10^{-4}$  and  $0.424 \times 10^{-5}$ , respectively, with the mean absolute errors of  $0.27 \times 10^{-2}$  and  $0.1379 \times 10^{-2}$ , the fitting degrees of 0.9994976 and 0.9691, and a prediction time of 0.8s, which is only 1/4500 of the calculation time of the panel method, which improves the efficiency of aircraft aerodynamic shape design effectively.

**Key Words:** aerodynamics; ensemble learning; quick prediction; Gradient Boosting model; stacking method

**Received:** 2024-04-22; **Revised:** 2024-07-31; **Accepted:** 2024-09-26

**Foundation item:** Aeronautical Science Foundation of China(2022Z006026004, 2023M071027001)