

DOI:10.11918/202509098

# 飞行器多舵面气动力智能融合建模方法

陈昊涵<sup>1</sup>, 王霄<sup>2</sup>, 闫盼盼<sup>2</sup>, 李怀璐<sup>1</sup>, 张伟伟<sup>1</sup>

(1. 西北工业大学 航空学院, 西安 710072; 2. 沈阳飞机设计研究所, 沈阳 110035)

**摘要:** 常规布局飞行器的数据库构建通常采用来流维度全采样, 由于各个舵面距离远、干扰弱, 常采用叠加舵效增量的策略, 避免了舵面组合的全维度采样。但飞翼布局飞行器舵面间的气动干扰强、舵面数量多, 考虑舵面间干扰的全维度采样工程代价极高。为攻克在少量舵面组合样本约束下, 构建考虑舵面间非线性干扰的气动力模型这一飞机设计的主要难点。首先, 针对迎角采样稠密的重要特征(如风洞吹风), 提出了融合卷积神经网络(CNN)与工程模型的气动力智能建模方法。其次, 以低速飞翼后缘3组舵面组合偏转的气动力为研究对象, 运用CFD方法获得单/双舵偏的气动力数据。最后, 采用组合舵效与相邻舵面干扰量线性叠加方法构建低精度工程模型, 再通过引入迎角序列建模机制, 运用卷积神经网络进一步表征舵面间与迎角维度的非线性干扰效应。结果表明, 所提方法相较于工程模型, 精度提升约40%; 与未嵌入工程模型的直接深度神经网络模型相比, 其预测误差标准差降低50%以上。本研究显著提高了飞翼布局飞行器在大迎角、大舵偏下的强非线性气动建模的准确性与稳健性。

**关键词:** 深度神经网络(DNN); 卷积神经网络(CNN); 数据融合建模; 强非线性; 数据驱动

中图分类号: V211.43

文献标志码: A

文章编号: 0367-6234(2025)12-0191-09

## An intelligent fusion modeling method for aerodynamic forces of multi-control-surface aircraft

CHEN Haohan<sup>1</sup>, WANG Xiao<sup>2</sup>, YAN Panpan<sup>2</sup>, LI Huailu<sup>1</sup>, ZHANG Weiwei<sup>1</sup>

(1. School of Aeronautics, Northwestern Polytechnical University, Xi'an 710072, China;

2. Shenyang Aircraft Design & Research Institute, Shenyang 110035, China)

**Abstract:** The aerodynamic database construction for conventional aircraft configurations typically employs full sampling across inflow dimensions. Given the substantial distance and weak interference between control surfaces, the strategy of superimposing control effectiveness increments is widely used, which avoids the need for a full combinatorial sampling of all control surface deflections. However, for flying-wing aircraft, the presence of strong aerodynamic interference among multiple closely-spaced control surfaces makes full combinatorial sampling that accounts for these interactions prohibitively expensive. This paper focuses on the critical challenge of constructing an aerodynamic model capable of capturing nonlinear interference between control surfaces under limited combinatorial sample. Firstly, an intelligent aerodynamic modeling method is proposed that integrates a convolutional neural network (CNN) with an engineering model, specifically for scenarios with dense angle-of-attack sampling such as wind tunnel tests. Secondly, to characterize the aerodynamic forces generated by 3 trailing-edge control surface combinations on a low-speed flying-wing configuration, high-fidelity CFD simulations are used to obtain aerodynamic data for single and dual control surface deflections. Finally, a low-fidelity engineering model is constructed using a method that linearly superimposes individual control effectiveness and interference increments between adjacent control surfaces. Then, by introducing an angle-of-attack sequence modeling mechanism, a CNN is applied to further characterize nonlinear interference effects both among the control surfaces and across the angle-of-attack dimension. Results indicate that the proposed method not only improves accuracy by approximately 40% compared to the engineering model, but also reduces the standard deviation of prediction error by over 50% relative to a direct deep neural network model without embedded engineering knowledge. This research significantly enhances both accuracy and robustness of strongly nonlinear aerodynamic modeling for flying-wing aircraft under high-angle-of-attack and large-control-surface-deflection conditions.

**Keywords:** deep neural network (DNN); convolutional neural network (CNN); data-fusion modeling; strong nonlinearity; data-driven

收稿日期: 2025-09-24; 录用日期: 2025-10-27; 网络首发日期: 2025-11-06

网络首发地址: <https://link.cnki.net/urlid/23.1235.T.20251106.0939.002>

基金项目: 国家自然科学基金联合基金(U2441211); 航空基金(2024M006001002)

作者简介: 陈昊涵(2003-), 男, 博士研究生; 张伟伟(1979-), 男, 教授, 博士生导师

通信作者: 张伟伟, [aeroelastic@nwpu.edu.cn](mailto:aeroelastic@nwpu.edu.cn)

无尾飞翼布局飞行器以其优异的气动效率和隐身特性被广泛视为未来航空飞行平台的重要发展方向<sup>[1]</sup>。该构型为了凸显隐身突防的能力彻底摒弃了传统的平尾与垂尾,丧失了与之相关的气动操纵面和横航向稳定性机制,导致其飞行控制面临严峻挑战<sup>[2]</sup>。具体表现为俯仰、滚转及偏航 3 轴操纵力矩的显著缺失和强烈的气动耦合效应。为应对这一难题,在后缘和翼尖部署多个可独立或协调动作的控制面已成为该布局的核心技术特征<sup>[3]</sup>。可基于多变量控制理论实现操纵力矩的精确分配与冗余控制,从而在维持低可观测性外形的前提下,有效提升飞行品质、控制鲁棒性和机动性能。因此,深入研究如何精确获取多舵面系统的操纵效能,对于推动无尾飞翼布局从概念设计走向工程实践具有关键性的理论价值与工程意义。

构建迎角、马赫数与舵面偏转耦合的气动力数据库是飞机气动设计的关键技术,高精度的气动力数据库是飞机的飞行品质评估和控制率设计的基石。风洞试验作为获取高精度气动力数据的唯一可靠方法,虽能提供真实气动数据,但多舵面组合试验成本高、难度大,并随着舵面数量的增加存在“组合爆炸”问题,数据获取严重受限<sup>[4]</sup>,通常需要构建代理模型来对气动力进行建模。传统的白箱工程模型只考虑试验获取随马赫数和迎角变化的单舵偏气动数据集,然后将各个舵偏状态的气动效应线性叠加从而构建多舵面的气动数据库<sup>[5]</sup>。无尾飞翼布局飞行器由于各个舵面之间非线性耦合效应强,传统的工程模型并没有考虑舵面之间的干扰效应,在大迎角、跨声速等极端工况下气动力模型的精度极低。

近年来,随着计算机水平和人工智能技术的发展<sup>[6-7]</sup>,以神经网络为代表的机器学习气动力建模方法显示出处理高度非线性关系的优势<sup>[8]</sup>。其能够融合多源异质数据(如高精度 CFD 计算、风洞试验和低精度工程估算数据),通过深层特征提取与非线性映射,有效捕获复杂流动机理与舵面耦合效应,为飞翼布局气动建模提供了新途径<sup>[9]</sup>。在相关研究中,张瑞民等<sup>[10]</sup>采用 BP 神经网络对飞机大迎角动态气动特性进行了建模。Sekar 等<sup>[11]</sup>使用深度卷积神经网络进行翼型的反设计。李怀璐等<sup>[12]</sup>将混合精度数据融合架构应用于战斗机气动力建模仿真,对比纯黑箱模型,其在精度、鲁棒性和泛化性方面均有显著提升。Rokhsaz 等<sup>[13]</sup>研究飞行器机动的控制问题,采用多层前馈网络来描述非线性、非定常气动力。Wang 等<sup>[14]</sup>对飞机多舵面偏转的飞行控制系统展开了研究。但是,目前国内、外基于神经网络的气动建模研究主要聚焦于单一自由度非线性动态

气动特性的描述,或是常规构型飞行器的非定常气动力预测,而尚未针对飞翼布局多舵面组合面临的多维强非线性气动力建模进行充分研究。

本文基于飞翼布局多舵面组合的俯仰力矩与滚转力矩数据集,针对传统工程模型未充分考虑舵间非线性干扰,以及现有神经网络气动建模研究在多舵面耦合特性表征方面的不足,提出一种嵌入工程白箱模型的气动力建模方法,构建小样本下兼具精度与鲁棒性的智能气动力模型,为无尾飞翼布局飞行器在复杂流动条件下的操纵效能评估与控制律设计提供可靠的数据基础。

## 1 气动力建模方法

### 1.1 工程多舵面气动力模型

在传统多舵面组合气动力建模中,需要通过计算流体动力学(computational fluid dynamics, CFD)或者风洞试验先获得无舵偏基本状态和单舵偏的气动力,从而得到单舵面偏转的舵效。多舵面组合舵效通常需要补充相邻舵面同时偏转的样本,从而构建考虑相邻舵面间干扰效应的白箱工程模型。本文以 3 舵面偏转构型为例,舵面由内至外分别为 TF、FY 和 AMT。多舵面组合的总气动力增量  $\Delta C_i$  被建模为

$$\Delta C_i = \Delta C_{\delta_{TF}} + \Delta C_{\delta_{FY}} + \Delta C_{\delta_{AMT}} + \Delta C_{\delta_{TF-FY}} + \Delta C_{\delta_{FY-AMT}} \quad (1)$$

式中:等式右侧前 3 项  $\Delta C_{\delta_{TF}}$ 、 $\Delta C_{\delta_{FY}}$ 、 $\Delta C_{\delta_{AMT}}$  分别为 TF、FY 和 AMT 舵面单独偏转时产生的气动力增量,后 2 项  $\Delta C_{\delta_{TF-FY}}$ 、 $\Delta C_{\delta_{FY-AMT}}$  分别为相邻舵面(TF 与 FY、FY 与 AMT)之间的气动干扰量。

上述相邻舵间干扰量通过以下方式计算:

$$\begin{cases} \Delta C_{\delta_{TF-FY}} = \Delta C_{\delta_{TF+\delta_{FY}}} - (\Delta C_{\delta_{TF}} + \Delta C_{\delta_{FY}}) \\ \Delta C_{\delta_{FY-AMT}} = \Delta C_{\delta_{FY+\delta_{AMT}}} - (\Delta C_{\delta_{FY}} + \Delta C_{\delta_{AMT}}) \end{cases} \quad (2)$$

式中,两个舵面(如 TF、FY)组合偏转时测得的气动力增量  $\Delta C_{\delta_{TF+\delta_{FY}}}$ ,与它们各自单独偏转时的气动力增量之和  $\Delta C_{\delta_{TF}} + \Delta C_{\delta_{FY}}$  的差值。该差值捕获了舵面间由流场相互干扰产生的非线性效应,是传统线性叠加方法所忽略的关键项。

该方法作为传统建模的理论上限,仅考虑了相邻舵面间的干扰效应,并未计入跨舵干扰(如 TF、AMT 之间)的影响。尤其在舵面偏转角度较大时,跨舵非线性干扰效应显著,将导致该模型预测精度不足。

### 1.2 深度神经网络

深度学习是神经网络发展的一个重要里程碑。深度学习模型通过增加神经网络的层数,可以学习到更高层次、更抽象的特征表示,从而实现更高水平的任务处理<sup>[15]</sup>。这种层次化的特征提取能力使得

神经网络在计算机视觉、自然语言处理、语音识别等领域取得了巨大成功。如图 1 所示给出了深度神经网络(deep neural network, DNN)的 3 层结构:输入层、隐藏层和输出层。本文将飞行工况和多个舵的组合舵偏作为神经网络模型的输入,模型输出为气动力舵效。对于飞翼布局的刚体静态气动力模型,神经网络具备强大的非线性耦合能力,能够深度挖掘多工况多舵面组合作用下的干扰关系,有效提升建模效率与建模精度。




图 1 深度神经网络

Fig. 1 Deep neural network (DNN)

### 1.3 卷积神经网络

卷积神经网络(convolutional neural network, CNN)采用局部连接方式,通过交替堆叠卷积层和池化层,对输入信号进行分层特征提取与抽象,最终经由全连接层实现从输入到输出的非线性映射<sup>[16]</sup>。该结构通过权值共享显著减少了可训练参数量,不仅提高了训练效率,也增强了模型的泛化能力。每一卷积层包含多个特征图,通过卷积核在输入上执行局部卷积运算,以捕获空间局部模式;池化层则基于局部相关性对特征进行降维,在保留关键信息的同时抑制过拟合,提升计算效率。具体结构见图 2。

在气动力建模中,CNN 尤其适用于构建气动力随迎角变化的非线性序列模型<sup>[17]</sup>。通过一维卷积结构沿迎角方向滑动滤波,可有效提取局部气动响应特征,识别不同迎角区间内的流动模式,克服了传统多项式拟合和线性辨识方法在强非线性工况下的表达局限,为实现高精度端到端气动特性建模提供

了有效途径。




图 2 卷积神经网络

Fig. 2 Convolutional neural network (CNN)

### 1.4 白箱工程模型嵌入的神经网络融合建模方法

机器学习方法的发展为多源异质数据的融合建模提供了有效支撑。本文融合两种模型的建模思路,采用高低精度数据融合策略,将白箱工程估算获得的低精度气动力系数作为卷积神经网络的输入特征,将高保真 CFD 计算结果作为输出目标进行监督训练。该方法充分利用白箱模型反映的整体变化趋势与高精度数据提供的局部精确信息,通过神经网络强大的非线性映射能力,实现对高精度气动特性的逼近与修正,显著提升模型在数据稀疏区域的泛化能力<sup>[18]</sup>。

具体而言,所提出的融合模型结构见图 3。网络输入包括飞行状态参数(如迎角、马赫数等)及多舵面偏转角度,同时引入工程模型得到的低精度气动力数据作为辅助输入特征;网络输出则为对应的高精度气动力系数。该模型通常采用全连接和卷积结构,通过在隐含层中逐步提取输入特征与输出之间的复杂非线性关系,实现对高低精度数据间系统偏差的自动学习。为提升模型的训练效率,本文进一步引入残差连接,构建卷积残差神经网络,用于多舵面组合舵效迎角序列建模,在保持卷积特征提取优势的基础上改善了梯度传播,显著加快了模型收敛速度。在训练过程中,损失函数同时考虑对高精度输出的拟合误差以及对物理约束的一致性,以进一步增强模型的预测可靠性与外推性能。

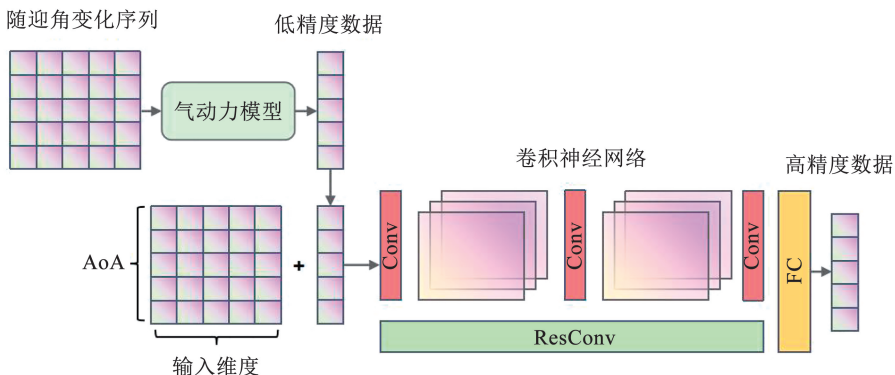



图 3 数据融合神经网络

Fig. 3 Data fusion neural network


## 2 算例模型

本文采用中国空气动力研究与发展中心(China Aerodynamics Research and Development Center, CARDC)公开发布的小展弦比飞翼布局 CHN - F1

标模<sup>[19-21]</sup>,作为神经网络训练模型和验证的气动数据来源,其三维示意图和坐标见图 4。算例模型总长 1 392 mm,半展长 519.5 mm,前缘后掠角 65°,后缘后掠角 ±47°,展弦比 1.54,采用超临界翼型、直前缘和锯齿形尾缘,详细气动力数据参考信息见表 1。



(a) 模型俯视平面参数



(b) 模型三视图

图 4 CHN - F1 标模全机模型图

Fig. 4 General arrangement of the CHN-F1 standard model


表 1 CHN - F1 气动力数据参考信息

Tab. 1 Aerodynamic reference data for the CHN-F1


参考面积/m <sup>2</sup>	参考长度/m	参考展长/m	力矩参考点/m
0.349 5	0.869 0	0.519 5	(0.626 7, 0, 0)

此外,还设计了内侧升降副翼(TF)、外侧升降

副翼(FY)和全动翼尖舵(AMT)等气动控制舵面,如图 5 所示给出了 CHN - F1 标模的舵面划分及偏转状态示意图。通过研究不同舵面单独偏转和组合偏转等状态,获取相应的六分量气动力数据,供后续神经网络训练、测试和验证使用,详细状态见表 2。



(a) 舵面划分



(b) 各舵面偏转状态

图 5 CHN - F1 标模舵面划分及偏转状态示意

Fig. 5 Schematic diagram of control surface division and deflection states of CHN-F1 standard model

表 2 CHN - F1 算例仿真状态

Tab. 2 Simulation status of the CHN-F1 example

类型	马赫数 $Ma$	迎角 $\alpha/(\circ)$	舵面偏度/ $(\circ)$		
			TF	FY	AMT
状态	0.2	10, 12, 14, 16, 20, 24	-30, -10, 0, 10, 30	-30, -10, 0, 10, 30	0, 10, 30, 60

## 3 多舵面组合气动力建模结果

### 3.1 深度神经网络气动力建模

对于飞翼布局的静态气动力建模问题,本文首先通过迎角和 3 个舵面的偏转角度建立气动力数据集,构建了  $Ma = 0.2$  时气动数据模型。神经网络在训练的过程中,通过最小化损失函数  $L$  来更新网络参数。以均方误差(mean squared error, MSE)作为网络模型的残差,有

式中: $N$  为样本数量,  $y_i$  为真实输出,  $\hat{y}_i$  为网络预测输出,  $\lambda$  为正则化系数,  $\sum_{j=1}^M w_j^2$  为神经网络所有权重的平方和。该损失函数第 1 项是为了最小化预测误差,通过减小 MSE 部分使得模型的输出尽可能地逼近高精度真实数据;第 2 项为正则化项,通过惩罚大的权重防止模型为了拟合训练数据中的噪声和细微

$$L = \frac{1}{N} \sum_{i=1}^N \|y_i - \hat{y}_i\|^2 + \lambda \sum_{j=1}^M w_j^2 \quad (3)$$

波动而变得过于复杂,从而提升其在未知测试数据上的泛化能力。

根据仿真模拟的计算数据,将所有单偏舵效与相邻舵面干扰量作为训练集样本,同时选取 27 个大偏度 3 舵面组合舵效样本添加到训练集,划分部分多舵面组合舵效样本作为验证集,其余 20 个多舵面组合舵效样本作为测试集,分别以俯仰力矩和滚转力矩作为训练标签进行模型训练。神经网络结构的超参数设置见表 3。

表 3 神经网络超参数设置

Tab. 3 Neural network hyperparameter settings

激活函数	初始学习率	训练步数	归一化方法
Tanh	0.001	2 000	Z_score

部分建模结果如图 6 所示,横轴为迎角,纵轴为

气动力/力矩。图中:CFD 为测试集真值,CNN\_fusion 为直接 CFD 计算得到,Model 为传统工程模型气动力结果,DNN 为使用深度神经网络建模结果。图 6 挑选了两组不同偏转状态(大偏度偏转和小偏度偏转)的组合舵面建模结果。在本文中,定义 TF 和 AMT 同时偏转 30°以上为大偏度偏转状态,同时偏转小于 30°为小偏度状态。发现在大偏度偏转时舵间干扰的非线性特性强烈,深度神经网络方法能够有效建模,相较于工程模型显著提升了建模的精度。但是在组合舵面小偏度偏转时,TF 与 AMT 之间没有很强的干扰效应,传统工程模型本身已能较好地描述其物理规律,而 DNN 模型由于参数众多、结构复杂,容易对训练数据中微小波动或噪声产生过拟合,反而在测试集上表现不佳。

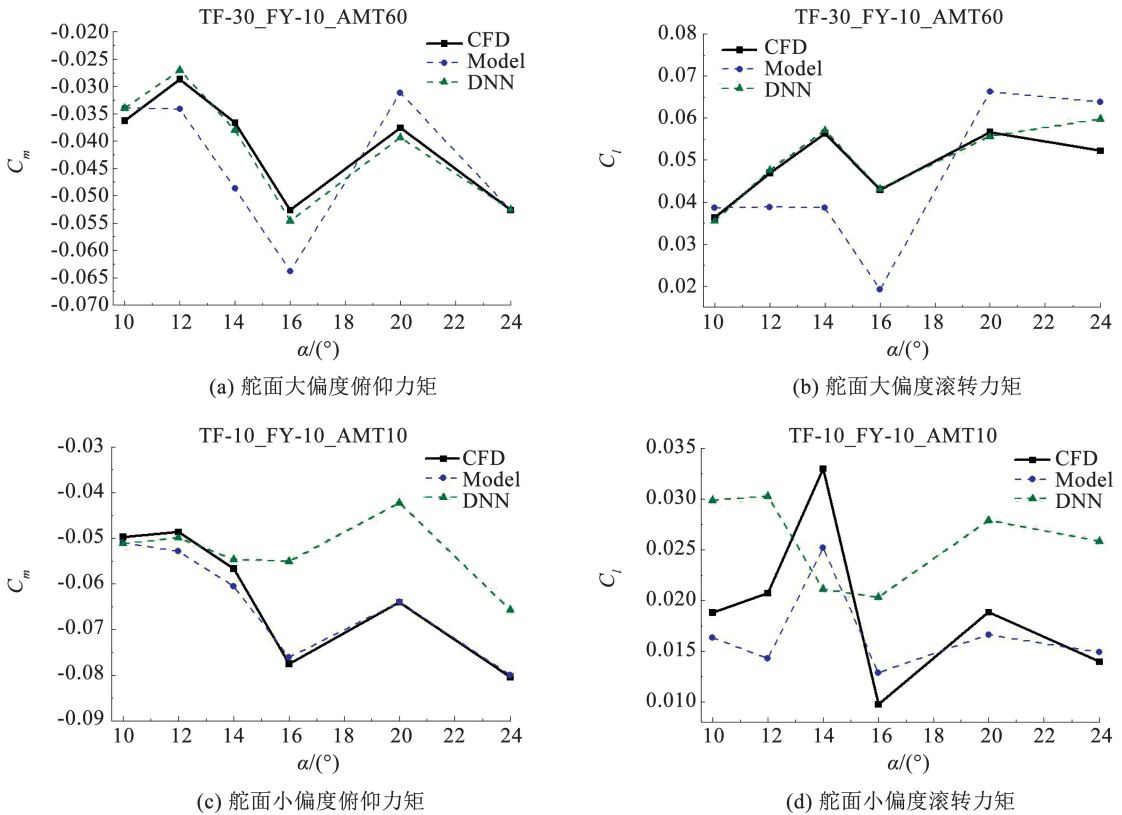


图 6 深度神经网络舵效建模结果

Fig. 6 Results of deep neural network modeling for control surface effect

### 3.2 白箱工程模型嵌入的卷积神经网络融合建模结果

为进一步提升气动建模的整体精度与工况普适性,本文引入迎角序列信息,采用工程模型嵌入的融合建模方法。该方法通过考虑迎角连续变化过程中的气动力响应规律,将建模方式从单点预测扩展为序列预测,从而更有效地捕捉气动力随迎角变化的动态特性。在模型选择上,本文采用卷积神经网络

替代传统深度神经网络,通过卷积操作显式提取不同迎角区间内的气动力变化模式,有效捕获序列中的局部趋势,增强了模型对非线性气动特性的表征能力和泛化性能。

为定量评估建模方法的性能,将本文提出的工程模型嵌入卷积神经网络模型与传统的线性叠加模型进行了对比分析,部分建模结果见图 7。图 7 中:Model 为传统工程模型建模结果,DNN 为深度神经

网络建模结果, CNN\_fusion 为工程模型嵌入的卷积神经网络建模结果。结果表明, 在不同舵偏角度条件下, CNN\_fusion 方法均表现出更优且稳定的预测精度。具体而言, 在线性特征主导的小舵偏角工况下, CNN\_fusion 模型保持了与工程模型相近的误差水平; 而在强非线性耦合显著的大舵偏角区域 (TF

与 AMT 舵偏角超过  $30^\circ$ ), CNN\_fusion 模型仍能保持较高的预测准确性, 显著优于传统线性模型。这表明所提出的方法不仅能够有效捕捉跨舵非线性干扰效应, 也在小扰动条件下保持了良好的数值稳定性, 充分验证了其在全舵偏角范围内的适用性与鲁棒性。

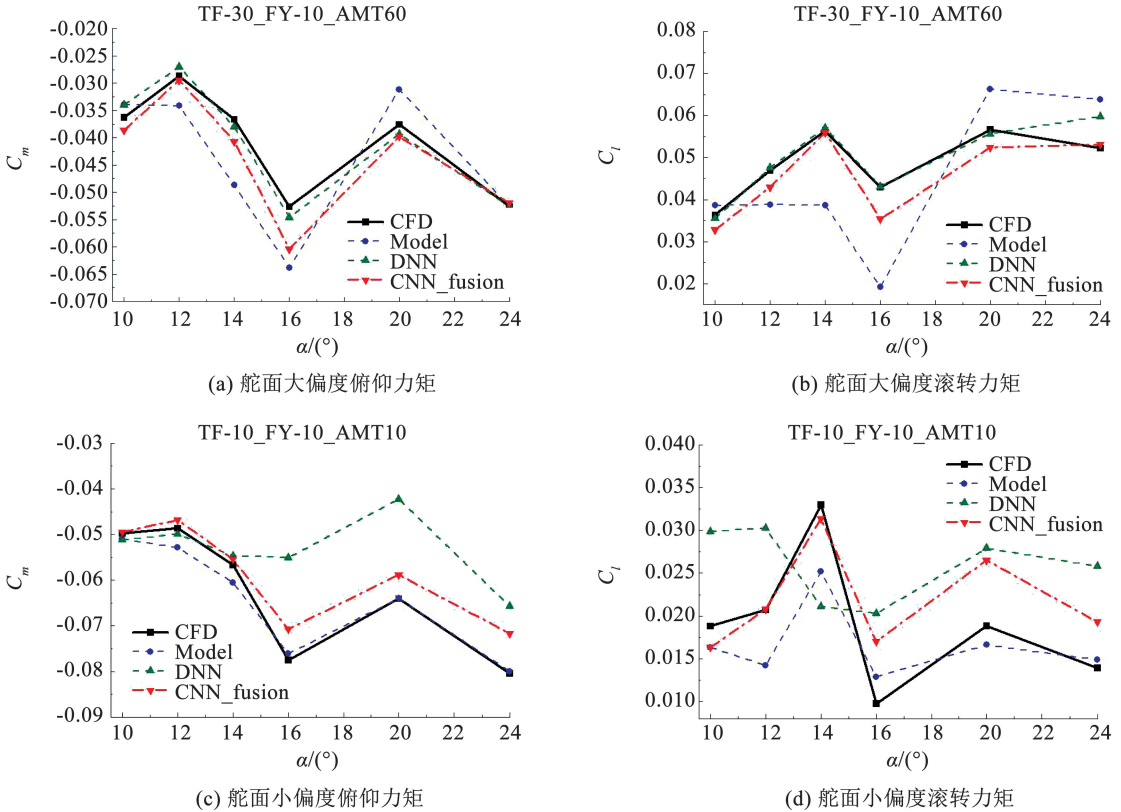


图 7 数据融合卷积神经网络 (CNN) 舵效建模结果

Fig. 7 Results of control surface effect modeling based on data fusion convolutional neural network (CNN)

为充分评估与对比不同建模方法的总体性能与泛化能力, 本文采用  $K$  折交叉验证方法进行总体的建模精度对比和稳健性检验。具体而言, 将全部数据集随机划分为  $K$  个互斥子集, 依次选取其中一个子集作为测试集, 其余  $K - 1$  个子集作为训练集, 重

复训练和测试  $K$  次, 最终以多次测试结果的平均性能作为模型能力的评价指标。该方法可有效减小因数据划分偶然性导致的评估偏差, 尤其适用于气动数据样本量有限的情形, 从而更客观地反映模型在未知数据上的预测稳定性, 交叉验证的结果见图 8。

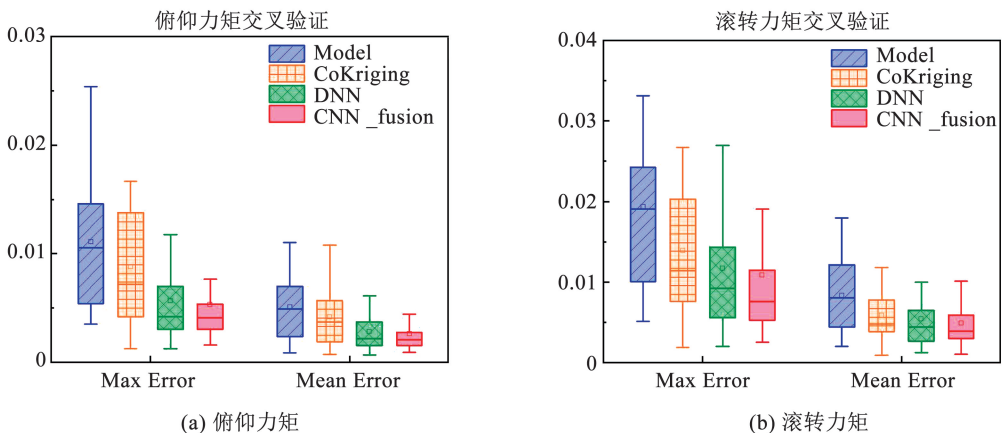


图 8  $K$  折交叉验证结果

Fig. 8  $K$ -fold cross-validation results

除上述方法外,本文还采用 CoKriging 方法进行交叉验证,以全面衡量建模性能。表 4 展示了不同建模策略统计误差的平均值,表 5 为不同建模策略统计误差的标准差,神经网络方法相较于传统气动模型在预测精度方面具有显著优势。具体而言,在俯仰力矩建模中,神经网络方法平均最大误差降低 54% 以上,平均误差减少超过 45%;在滚转力矩建模中,平均最大误差下降 40%,平均误差降幅达 35% 以上。结果表明,神经网络能够

表 4 不同建模策略预测偏差

Tab. 4 Prediction bias of different modeling strategies

俯仰力矩	Model	CoKriging	DNN	CNN_fusion	滚转力矩	Model	CoKriging	DNN	CNN_fusion
最大误差均值	0.011 1	0.008 3	0.005 6	0.005 3	最大误差均值	0.019 4	0.013 3	0.011 7	0.010 8
平均误差均值	0.005 1	0.004 0	0.002 8	0.002 6	平均误差均值	0.008 3	0.005 6	0.005 4	0.004 9

表 5 不同建模策略误差离散程度

Tab. 5 Degree of dispersion of errors in different modeling strategies

俯仰力矩	Model	CoKriging	DNN	CNN_fusion	滚转力矩	Model	CoKriging	DNN	CNN_fusion
最大误差标准差	0.005 3	0.004 4	0.002 6	0.001 4	最大误差标准差	0.007 6	0.008 8	0.005 8	0.003 6
平均误差标准差	0.002 7	0.002 9	0.001 4	0.000 7	平均误差标准差	0.004 2	0.003 6	0.002 3	0.002 1

上述定量分析充分验证了本文所提方法在大迎角、大舵偏这一强非线性工况下的卓越性能,显著提高了飞翼布局飞行器在大迎角、大舵偏角下的强非线性气动建模的准确性。在如图 7(a)、(b)所示大舵偏角、大迎角的极端工况下,流动分离与舵面间干扰效应耦合,产生了强烈的非线性气动响应。传统工程模型在此完全失效,而本文的 CNN\_fusion 模型则展现了其精准捕捉复杂物理现象的能力。表 4 的数据对此进行解释:在俯仰力矩和滚转力矩建模中, CNN\_fusion 相较于工程模型的平均误差降幅超过 45%,最大误差降幅超过 50%。这一定量结果证明,所提方法在面对强非线性问题时,其准确性得到了质的飞跃。

同时本文结果也验证了模型在不同工况下预测性能的一致性与可靠性。表 5 中 CNN\_fusion 模型预测误差的标准差相较于 DNN 模型降低了 50% 以上。这意味着,尤其是在训练数据稀疏或覆盖不足的工况点, CNN\_fusion 模型的预测波动极小,输出非常稳定,确保了模型在全飞行包线内的可靠泛化。

### 3.3 结果解释与物理一致性分析

本文基于可解释性与物理一致性两个维度,对上述建模结果进行机理分析,旨在阐明所提出的白箱工程模型嵌入卷积神经网络方法在物理表征层面的优势。

更准确地捕捉多舵面耦合下的非线性气动特性。本文所提出的数据融合迎角序列建模方法在深度神经网络基础上进一步提升了精度。如图 8 所示为误差分布的箱线图,工程模型嵌入的卷积神经网络方法的预测误差分散度显著减小,统计误差的标准差相较于深度神经网络减小 50% 以上,说明其具有更稳定的输出性能和更强的泛化能力,能够在更广泛的气动状态下保持一致的建模准确性。

从计算机理角度, CNN 的卷积操作可视为对迎角序列的局部特征提取过程。在气动建模框架下,这一过程等价于对局部迎角区间内气动导数的分布式估算。在线性气动区间(图 7(b)、(c)),特定卷积核表现出对线性响应模式的强选择性激活,其输出与基于常导数假设的工程模型预测高度一致,体现了模型对基础气动规律的继承能力。当流动呈现强非线性特征时,气动响应表现出显著的高阶特性。在大舵偏角、大迎角工况下(图 7(a)、(b)),专门优化用于探测信号突变的卷积核被显著激活。这些卷积核在物理层面上实现了对流动分离起始等关键流动现象的自动识别,从而精准再现了气动系统从线性响应到非线性失稳的动态演化过程

深度神经网络(DNN)虽能提升大舵偏角工况的建模精度(平均误差降低约 45%),但其纯数据驱动的本质导致物理一致性的缺失。特别是在物理规律明确但数据稀疏的小舵偏角区域(图 6), DNN 模型因缺乏物理约束而产生非物理振荡,表现出泛化能力不足的限制性。

本文提出的白箱工程模型嵌入卷积神经网络融合架构通过“线性基础+非线性修正”的设计理念,实现了物理先验与数据驱动的有机融合。工程模型提供符合物理趋势的基线解,确保模型在数据未覆盖区域的预测合理性; CNN 则专注于学习高精度

CFD 数据与工程预测间的残差项,该残差主要表征了舵面干扰及流动分离等非线性物理效应。这种协同机制使模型在保持工程模型外推稳健性的同时,具备了精确刻画非线性气动特性的能力。实验结果表明,该方法的预测误差标准差较 DNN 降低 50% 以上(表 5),从本质上证明了物理先验对约束模型解空间、提升预测一致性的关键作用。

## 4 结 论

本文针对飞翼布局飞行器在复杂流场中多舵面联合偏转下的静态气动力建模问题,基于多舵面组合偏转气动力数据,提出了白箱工程模型嵌入的卷积神经网络建模方法。主要结论如下:

1) 本文针对传统工程模型在强非线性工况下精度不足的问题,引入了深度神经网络方法。结果表明,该数据驱动方法能够有效表征多舵面耦合下的非线性气动响应,相较于传统工程模型,精度提升约 40%,但在数据稀疏的小舵偏角工况下,其泛化能力与稳健性存在局限。

2) 为解决纯数据驱动模型的上述局限,本文发展了“线性基础 + 非线性修正”的物理引导融合建模新途径。通过将工程模型输出作为物理先验输入,并利用卷积神经网络专攻迎角序列中的非线性残差映射。该方法显著增强了模型的稳健性与预测一致性,其预测误差标准差较纯黑箱神经网络降低 50% 以上。

3) 本文所提出的融合建模架构,通过将已知物理机理与数据驱动学习相结合,为小样本下高精度气动建模提供了可靠方案,初步表明了智能融合建模方法在解决飞翼布局多舵面非线性气动耦合问题中的可行性与应用前景。

4) 本文所展现的物理机理与数据驱动的融合建模思路或许能为相关领域的研究提供一种有益的参考。当前阶段的研究集中于低速静态特性,可视作这一探索历程的起点。后续希望将方法拓展至跨马赫数及非定常等更复杂的工况,并深入探索多源数据融合与不确定性建模等关键问题,期望最终能为飞行器设计提供更坚实的数据模型支撑。

## 参考文献

[1] 王海峰, 展京霞, 陈科, 等. 战斗机大迎角气动特性研究技术的发展与应用[J]. 空气动力学学报, 2022, 40(1): 1  
WANG Haifeng, ZHAN Jingxia, CHEN Ke, et al. Development and application of aerodynamic research technologies for fighters at high angle of attack[J]. Acta Aerodynamica Sinica, 2022, 40(1): 1.

DOI: 10.7638/kqdlxxb-2021.0306  
[2] 马松辉, 吴成富, 陈怀民. 飞翼飞机稳定性与操纵性研究[J]. 飞行力学, 2006, 24(3): 17  
MA Songhui, WU Chengfu, CHEN Huaimin. Study on stability and manoeuvrability of flying wing aircraft[J]. Flight Dynamics, 2006, 24(3): 17  
[3] 左林玄, 王晋军. 全动翼尖对无尾飞翼布局飞机气动特性影响的实验研究[J]. 空气动力学学报, 2010, 28(2): 132  
ZUO Linxuan, WANG Jinjun. Experimental study of the effect of AMT on aerodynamic performance of tailless flying wing aircraft[J]. Acta Aerodynamica Sinica, 2010, 28(2): 132. DOI: 10.3969/j.issn.0258-1825.2010.02.002  
[4] 宁晨伽, 王旭, 王文正, 等. 高效率采样的数据关联融合气动力建模方法[J]. 空气动力学学报, 2022, 40(5): 39  
NING Chenjia, WANG Xu, WANG Wenzheng, et al. Data association and fusion aerodynamic modeling method based on efficient sampling[J]. Acta Aerodynamica Sinica, 2022, 40(5): 39. DOI: 10.7638/kqdlxxb-2021.0425  
[5] 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): 524689  
ZHANG Weiwei, KOU Jiaqing, LIU Yilang. Prospect of artificial intelligence empowered fluid mechanics[J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(4): 524689. DOI: 10.7527/S1000-6893.2020.24689  
[6] BRUNTON S L, NOACK B R, KOUMOUTSAKOS P. Machine learning for fluid mechanics[J]. Annual Review of Fluid Mechanics, 2020, 52: 477. DOI: 10.1146/annurev-fluid-010719-060214  
[7] 张伟伟, 王旭, 寇家庆. 面向流体力学的多范式融合研究展望[J]. 力学进展, 2023, 53(2): 433  
ZHANG Weiwei, WANG Xu, KOU Jiaqing. Prospects of multi-paradigm fusion methods for fluid mechanics research[J]. Advances in Mechanics, 2023, 53(2): 433. DOI: 10.6052/1000-0992-22-050  
[8] 何磊, 钱炜祺, 汪清, 等. 机器学习方法在气动特性建模中的应用[J]. 空气动力学学报, 2019, 37(3): 470  
HE Lei, QIAN Weiqi, WANG Qing, et al. Applications of machine learning for aerodynamic characteristics modeling[J]. Acta Aerodynamica Sinica, 2019, 37(3): 470. DOI: 10.7638/kqdlxxb-2019.0033  
[9] 唐志共, 朱林阳, 向星皓, 等. 智能空气动力学若干研究进展及展望[J]. 空气动力学学报, 2023, 41(7): 1  
TANG Zhigong, ZHU Linyang, XIANG Xinghao, et al. Some research progress and prospect of intelligent aerodynamics[J]. Acta Aerodynamica Sinica, 2023, 41(7): 1. DOI: 10.7638/kqdlxxb-2023.0128  
[10] 张瑞民, 张石玉, 赵俊波. 基于神经网络的非定常气动力建模研究[J]. 计算机仿真, 2017, 34(2): 106  
ZHANG Ruimin, ZHANG Shiyu, ZHAO Junbo. Thereseearch of neural network in modeling of unsteady aerodynamics[J]. Computer Simulation, 2017, 34(2): 106. DOI: 10.3969/j.issn.1006-9348.2017.02.024  
[11] SEKAR V, ZHANG Mengqi, SHU Chang, et al. Inverse design of airfoil using a deep convolutional neural network[J]. AIAA

- Journal, 2019, 57(3): 993. DOI: 10.2514/1.J057894
- [12]李怀璐,王旭,王霄,等. 大迎角机动飞行的气动力建模与飞行仿真[J]. 航空学报, 2023, 44(19): 128410  
LI Huailu, WANG Xu, WANG Xiao, et al. Aerodynamic modeling and flight simulation of maneuverable flight at high angle of attack [J]. Acta Aeronautica et Astronautica Sinica, 2023, 44(19): 128410. DOI: 10.7527/S1000-6893.2023.28410
- [13]ROKHSAZ K, STECK J E. Application of artificial neural networks in nonlinear aerodynamics and aircraft design [J]. SAE Transactions, 1993, 102: 1790. DOI: 10.4271/932533
- [14]WANG Lei, WANG Lixin. Reconfigurable flight control design for combat flying wing with multiple control surfaces [J]. Chinese Journal of Aeronautics, 2012, 25(4): 493. DOI: 10.1016/S1000-9361(11)60412-3
- [15]SZE V, CHEN Y H, YANG T J, et al. Efficient processing of deep neural networks: a tutorial and survey [J]. Proceedings of the IEEE, 2017, 105(12): 2295. DOI: 10.1109/jproc.2017.2761740
- [16]O'SHEA K, NASH R. An introduction to convolutional neural networks[EB/OL]. 2015: arXiv:1511.08458. <https://doi.org/10.48550/arXiv.1511.08458>
- [17]BHATNAGAR S, AFSHAR Y, PAN Shaowu, et al. Prediction of aerodynamic flow fields using convolutional neural networks [J]. Computational Mechanics, 2019, 64(2): 525. DOI: 10.1007/s00466-019-01740-0
- [18]MAHMOUDABADBOZCHELOU M, CAGGIONI M, SHAHSA-VARI S, et al. Data-driven physics-informed constitutive metamodelling of complex fluids: a multifidelity neural network (MFNN) framework [J]. Journal of Rheology, 2021, 65(2): 179. DOI: 10.1122/8.0000138
- [19]吴军飞,秦永明,黄湛,等. 小展弦比飞翼标模纵向气动特性低速实验研究[J]. 空气动力学学报, 2016, 34(1): 125  
WU Junfei, QIN Yongming, HUANG Zhan, et al. Low speed experiment on longitudinal and lateral aerodynamic characteristics of the low aspect ratio flying wing calibration model [J]. Acta Aerodynamica Sinica, 2016, 34(1): 125. DOI: 10.7638/kqdlxxb-2015.0093
- [20]王延灵,沈彦杰,卜忱,等. 小展弦比飞翼布局大迎角气动特性研究[J]. 气动研究与试验, 2023, 1(3): 64  
WANG Yanling, SHEN Yanjie, BU Chen, et al. Research on high angle of attack aerodynamic characteristics of low aspect ratio flying wing[J]. Aerodynamic Research & Experiment, 2023, 1(3): 64. DOI: 10.20118/j.issn2097-258x.2023.03.005
- [21]张杰,李王斌,王争取,等. 小展弦比飞翼标模跨声速横向失稳运动[J]. 航空学报, 2022, 43(11): 475  
ZHANG Jie, LI Wangbin, WANG Zhengqu, et al. Transonic lateral departure motion characteristics of a low-aspect-ratio flying-wing model[J]. Acta Aeronautica et Astronautica Sinica, 2022, 43(11): 475. DOI: 10.7527/S1000-6893.2021.26340

(编辑 张红)

## 会议通知 | 第九届机械、电子和工业工程国际学术会议 (MEIE2026)

第九届机械、电子和工业工程国际学术会议 (MEIE2026) 将于 2026 年 8 月 14 - 16 日在中国贵阳召开。本届大会由上海交通大学机械与动力工程学院主办, 中国质量发展研究院协办, 《哈尔滨工业大学学报》是合作媒体之一。

MEIE 旨在为世界各地的学者、专家和研究提供一个高效的交流平台, 通过研讨会、特邀报告、口头和海报展示等形式, 共享在机械工程、电子工程和工业工程等相关领域的研究经验和最新成果, 探讨未来研究发展方向以及促进世界范围内的项目合作。

作为年度学术会议, 在过去的 8 年中, MEIE 系列已分别于太原 (2025)、宜昌 (2024)、三亚 (2023)、昆明 (2021)、杭州 (2019, 2018) 以及线上平台 (2022, 2020) 成功召开, 吸引了来自瑞典、加拿大、美国、澳大利亚、新加坡、韩国和马来西亚等超过 15 个国家和地区的与会者。往届出版的会议论文集均已完成 EI Compendex 和 Scopus 检索。

MEIE 2026 聚焦智能制造, 重点讨论工业互联网、智能机器、智能制造系统等话题, 为学术界和工业界搭建桥梁。

MEIE2026 官网: <http://www.icmeie.com/>