



基于柔性智能蒙皮的翼型流场预测和重建方法

来五星 赵浩哲 黄林 冀晶晶 黄永安

Flow field prediction and reconstruction of aircraft based on flexible smart skin

LAI Wuxing, ZHAO Haozhe, HUANG Lin, JI Jingjing, HUANG Yongan

引用本文:

来五星, 赵浩哲, 黄林, 等. 基于柔性智能蒙皮的翼型流场预测和重建方法[J]. 空气动力学学报, 2025, 43(12): 121–134. DOI: 10.7638/kqdlxxb-2024.0139

LAI Wuxing, ZHAO Haozhe, HUANG Lin, et al. Flow field prediction and reconstruction of aircraft based on flexible smart skin[J]. *Acta Aerodynamica Sinica*, 2025, 43(12): 121–134. DOI: 10.7638/kqdlxxb-2024.0139

在线阅读 View online: <https://doi.org/10.7638/kqdlxxb-2024.0139>

您可能感兴趣的其他文章

Articles you may be interested in

基于自编码器和LSTM的模型降阶方法

Reduced order model based on autoencoder and long short-term memory network

空气动力学学报. 2021, 39(1): 73–81 <https://doi.org/10.7638/kqdlxxb-2019.0082>

智能可变形飞行器关键技术发展现状及展望

Development status of key technologies and expectation about smart morphing aircraft

空气动力学学报. 2019, 37(3): 426–443 <https://doi.org/10.7638/kqdlxxb-2019.0030>

基于深度学习的非定常周期性流动预测方法

A method of unsteady periodic flow field prediction based on the deep learning

空气动力学学报. 2019, 37(3): 462–469 <https://doi.org/10.7638/kqdlxxb-2019.0003>

MF-1飞行试验弹道差异分析及弹道重建研究

Flight trajectory bias analysis and trajectory reconstruction for MF-1 flight test

空气动力学学报. 2019, 37(5): 777–784 <https://doi.org/10.7638/kqdlxxb-2018.0065>

基于压缩感知的高频响流场重构方法及其应用

High-frequency flow field reconstruction method based on compressed sensing and its applications

空气动力学学报. 2022, 40(1): 26–32 <https://doi.org/10.7638/kqdlxxb-2021.0117>

基于卷积神经网络的Bolund岛流场重构

Flow field reconstruction for Bolund Island based on CNN

空气动力学学报. 2023, 41(9): 38–47 <https://doi.org/10.7638/kqdlxxb-2023.0012>

飞行器表面测压试验设计及分区重构方法

Experimental design and regional reconstruction method for wind tunnel pressure measurements on flight vehicles

空气动力学学报. 2024, 42(11): 63–74 <https://doi.org/10.7638/kqdlxxb-2023.0222>

地址: 四川省绵阳市二环路南段8号11信箱9分箱

电话: 0816-2463375

Email: kqdlxxb@163.com



关注微信公众号

获得更多资讯信息

文章编号: 0258-1825(2025)12-0121-14

基于柔性智能蒙皮的翼型流场预测和重建方法

来五星, 赵浩哲, 黄林, 冀晶晶, 黄永安*

(华中科技大学 智能制造装备与技术全国重点实验室, 武汉 430074)

摘要: 飞行器的气动问题会引发机翼结冰、飞行失速等安全隐患, 通过监测气动载荷数据、研究其流场特性有助于解决这一问题。柔性智能蒙皮提供了温敏漆、压敏漆等风洞试验手段不具备的飞行过程数据采集功能, 在获取飞行数据方面展现出巨大潜力。但感知的多物理场数据分布稀疏、数量有限, 难以实现转捩、失速位置精确识别。本文针对机翼全流场重构问题, 提出了一种基于柔性智能蒙皮的流场高分辨率的快速重建方法, 以获取空间密度更大的气动载荷数据, 开发了基于编码器-解码器网络架构的双分支通道注意力融合模型, 该模型能够快速预测 52 种 NACA 翼型在 156 种不同自由来流条件下的二维流场, 实现相对误差为 3.68% 的二维翼型流场快速预测; 利用快速预测模型生成的 M6 翼型周围流场数据, 基于浅层神经网络开发了流场重建模型, 在 2.73% 相对误差内快速重建空间分辨率更高的全域流场分布, 为智能蒙皮进一步飞行应用提供数据支撑。

关键词: 智能蒙皮; 流场重建; 流场预测; 双分支编码器; 特征融合; 神经网络

中图分类号: V211.3 文献标识码: A doi: 10.7638/kqdlxxb-2024.0139

Flow field prediction and reconstruction of aircraft based on flexible smart skin

LAI Wuxing, ZHAO Haozhe, HUANG Lin, JI Jingjing, HUANG Yongan*

(State Key Laboratory of Intelligent Manufacturing Equipment and Technology, Huazhong University of Science and Technology, Wuhan 430074, China)

Abstract: Real-time analysis and prediction of flow field characteristics are essential for flight safety and necessitating in-flight data acquisition, an almost impossible task for traditional techniques such as temperature/pressure-sensitive paints. Flexible smart skins demonstrate great promise for acquiring in-flight data. Nevertheless, the multi-physical data collected are usually sparsely in distribution and limited in quantity, making it difficult to accurately identify transition and stall locations. To overcome this limitation, we introduce a novel method for rapidly reconstructing high-resolution flow fields around aircraft wings from sparse data. Leveraging the flow fields computed by CFL3D, a dual-branch attention fusion model is developed based on an encoder-decoder network. This model facilitates rapid prediction of 2D flow fields for 52 types of NACA airfoils under 156 different freestream conditions, achieving an average relative error of 3.68% and providing a substantial amount of high-fidelity training data for the reconstruction process. Furthermore, using flow fields around the M6 airfoil generated by the rapid prediction model, a flow field reconstruction model is developed based on a shallow neural network. This model fulfills rapid reconstruction of high-resolution flow fields with a relative error of 2.73%. This work establishes a valuable data foundation for the in-flight application of smart skins, enhancing real-time monitoring capabilities and improving flight safety through accurate flow field reconstructions and insights.

Keywords: aircraft smart skin; flow field reconstruction; flow field prediction; double branch encoder; feature fusion; neural network

收稿日期: 2024-09-18; 修订日期: 2024-12-16; 录用日期: 2024-12-17; 网络出版时间: 2025-02-25

基金项目: 国家重点研发计划(2021YFB3200700); 国家自然科学基金(52175536, U23A20111)

作者简介: 来五星(1972—), 男, 湖北赤壁人, 副教授, 研究方向: 智能制造、智能预测. E-mail: wxlai@hust.edu.cn

通信作者: 黄永安*, 教授, 研究方向: 柔性电子器件制造与应用(飞行器智能蒙皮等). E-mail: yahuang@hust.edu.cn

引用格式: 来五星, 赵浩哲, 黄林, 等. 基于柔性智能蒙皮的翼型流场预测和重建方法[J]. 空气动力学学报, 2025, 43(12): 121–134.

LAI W X, ZHAO H Z, HUANG L, et al. Flow field prediction and reconstruction of aircraft based on flexible smart skin[J]. Acta Aerodynamica Sinica, 2025, 43(12): 121–134(in Chinese). doi: 10.7638/kqdlxxb-2024.0139

0 引言

飞行器飞行过程中常面临复杂的气动问题,如边界层转捩^[1]、高低温冲击^[2-3]、分离涡脱落^[4]等,会引起机翼结冰^[5]、飞行失速^[6]等安全隐患。因此,需要通过检测飞行气动载荷、构造飞行器周围的流场,获得气动载荷分布,进而用于飞行器结构验证与优化、飞行状态监测及结构健康评估。

目前,飞行器气动载荷数据的可靠获取主要依赖风洞实验,即通过生成高速气流以模拟飞行器周围的空气流动,常用的测量技术包括打孔安装压力传感器^[7]、热线风速仪^[8]、温敏漆^[9]、红外热测量^[10]、压敏漆^[11]等。近年来兴起的柔性智能蒙皮具备共形能力,能适应各种复杂的气动表面形状,具备良好的动态性能、多参量同步测量能力,为飞行过程数据采集、流场重建提供了一种可行的途径。但该方法也存在一些不足,如智能蒙皮传感器分布面积广、数量有限且稀疏,因此采集的数据空间分辨率低,此外,对于远离翼型边界层的空间数据,目前尚无有效获取措施。为实现转捩、失速现象的精确识别和结构疲劳损伤位置的准确定位,需要基于有限、稀疏的传感数据生成高维的全域流场数据。

进行二维翼型的超分辨率流场重构,是获取空间密度更大的气动载荷数据的有效方法^[12]。Zhao等^[13-15]提出了可在较少的压力测量数据下高精度重构翼型表面压力分布的方法,并通过数据融合等方式优化重构算法,以达到流场数据精细化或气动特性计算等目的。Zhang等^[16-17]结合稀疏风洞实验数据和低精度计算流体力学(computational fluid dynamics, CFD)结果,基于适当正交分解的压缩感知方法(compressed sensing based on proper orthogonal decomposition, CS-POD),提出了用于铰链力矩的预测模型,最终铰链力矩的平均重建精度为97.6%,法向力的平均重建精度为94.3%。黄俊等^[18]通过集合变换卡尔曼滤波(ensemble transform Kalman filter, ETKF)对风洞实验的稀疏实测数据和数值计算数据进行同化,实现了基于模型物面有限测点的全空间流场高精度重构,降低了预测误差,且在测点数目较少时也能获得较好的效果。

然而,基于CFD的流场仿真过程对计算资源要求高、耗时长,无法快速提供全域流场分布的仿真数据。这是因为稀疏传感器数据映射到全域流场数据过程中存在数据不完整问题,需添加额外的信息辅助重建全域流场^[19],从而耗费大量时间。

为此,近年来学者们尝试引入神经网络进行流场预测,该类模型可快速得出流场分布数据,多种面向翼型全域流场预测的神经网络模型被相继提出,为流场超分辨率实时重建提供了数据基础,也为智能蒙皮稀疏数据驱动的实时流场重建研究带来了新的解决思路。例如,Yilmaz和German^[20]通过给定翼型几何信息和压力数据,基于卷积神经网络^[21](convolutional neural networks, CNN)建立翼型表面压力预测模型,预测准确率超过80%,在较低保真度的情况下,CNN模型相比CFD求解器可以更快速地预测压力场。Zhang等^[22]提出了一套适应变化工况及机翼形状的翼型升力系数预测模型,通过训练多个CNN结构,并与传统多层感知机^[23-24](multilayer perceptron, MLP)的预测性能进行了比较。Chen等^[25]针对多翼型气动系数(俯仰力矩、阻力系数和升力系数)的预测任务提出了一种基于CNN的图形化预测方法,将翼型的几何信息、工况、气动参数转换为图像,之后将其融合作为输入,获得了较高的预测精度。

在流场重建方面,目前结合深度神经网络(deep neural network, DNN)拟合非线性函数映射的方法正逐步应用于提取流场特征以达到重建流场的目的。Özbay和Laizet^[26]通过Schwarz-Christoffel映射方法将二维随机几何形状物体周围的流场数据,从笛卡尔坐标系转换到环状空间表示的坐标系中,并将该映射方法融入到4个基于DNN和Unet(U-shaped convolutional network)^[27]的网络模型中,探究了Schwarz-Christoffel映射方法辅助网络模型时,对速度场、压力场重建精度的优化效果。Erichson等^[28]基于浅层解码器,以圆柱绕流案例的多个时间步流场图像作为训练集,通过稀疏传感器数据重建流场,并在各向同性湍流速度场中进行了效果验证,结果显示重构精度较好,表明深度学习在超分辨率图像重建中具有较大潜力。Liu等^[29]提出了两种用于湍流场重建的深度学习方法,分别是静态卷积神经网络和多时间路径卷积神经网络,分别以瞬态序列图像和时序序列图像作为输入,结果表明连续序列图像的额外信息有助于网络模型捕捉流场信息,可生成更加可信的重建结果。此外,也有学者以稀疏传感器数据为约束项,通过神经网络表征的流场特征重建流场。例如,Sun和Wang^[19]提出了一种物理数据约束的贝叶斯神经网络模型,以概率方式对物理空间数据的置信度进行建模,构造基于数据不确定性的似然函数,采用Stein变分梯度下降法^[30]训练贝叶斯模型,同时训练若干个DNN来捕获流场,物理传感器数据作为惩罚项作用在大量无法测量的时

空测点上,最后在理想血管流动腔体和狭窄流管道两个案例中比较了流场重建结果,表明通过稀疏且含噪声的传感器数据重建的流场与原始 CFD 均值数据之间的误差可控制在 5% 以内,具备在淡化噪声影响的前提下准确预测平均流场的能力。

综上,深度学习方法已在流场超分辨率重建中得到了广泛应用,且具有精度高、实时性好的特点,但目前该方面的研究大多聚焦在管道、腔体或圆柱绕流等流动场景,针对翼型表面稀疏传感器数据的超分辨率流场重建研究还较少。本文进行了稀疏蒙皮数据驱动的实时流场重建问题研究,提出了二维翼型流场快速预测模型和数据驱动的翼型流场超分辨率重建模型,通过实验验证了流场预测和重建模型的有效性。

1 数据驱动的流场预测模型

1.1 快速流场预测机理分析

流场快速预测任务旨在通过 DNN 预测二维翼型在多种工况下可压缩流动的 RANS(Reynolds-averaged Navier-Stokes)方程相似解。使用翼型弦长 c 、自由流声速 a_∞ 、自由流密度 ρ_∞ 3个变量作为特征量来描述流场,首先应对这3个变量进行无量纲化处理,则 RANS 方程可描述为:

$$\begin{cases} \frac{\partial \rho u_i}{\partial x_i} = 0 \\ \frac{\partial \rho u_i u_j}{\partial x_j} = -\frac{\partial p}{\partial x_i} + \frac{\partial \tau_{ij}}{\partial x_j} \\ \frac{\partial (pE + p)u_i}{\partial x_i} = \frac{\partial (-q_i + u_j \tau_{ij})}{\partial x_i} \end{cases} \quad (1)$$

式中: u_i, u_j 分别为流体在 i 和 j 方向的速度分量; x_i, x_j 为空间坐标; ρ 为流体密度; p 为压力, E 为总能量, p 和 E 之间的关系可表述为 $p = (\gamma - 1)(pE - \frac{1}{2}\rho u_i u_j)$, γ 为比热比,在空气中取 1.4。需要注意的是,根据理想气体状态方程,压力 $p = \rho a^2/\gamma$, a 为声速。剪切应力 τ_{ij} 和热流项 q_i 分别定义为:

$$\tau_{ij} = (\mu + \mu_T) \frac{Ma_\infty}{Re_\infty} \left[\left(\frac{\partial u_i}{\partial x_j} + \frac{\partial u_j}{\partial x_i} \right) - \frac{2}{3} \frac{\partial u_k}{\partial x_k} \delta_{ij} \right] \quad (2)$$

$$q_i = - \left(\frac{\mu}{Pr} + \frac{\mu_T}{Pr_T} \right) \frac{Ma_\infty}{Re_\infty(\gamma - 1)} \frac{\partial \Theta}{\partial x_i} \quad (3)$$

式中: μ 为层流黏度,由 Sutherland 定律求得; μ_T 为湍流黏度,由湍流模型确定; Re_∞ 为雷诺数,定义 $Re_\infty = \rho_\infty \sqrt{u_\infty^2 + v_\infty^2} c / \mu_\infty$; Ma_∞ 为马赫数; u_k 为特定方向的速度分量; x_k 为特定方向的空间坐标; δ_{ij} 为单位矩阵

开关; Pr 和 Pr_T 分别为层流和湍流普朗特数,为常量,取值分别为 0.72 和 0.9;温度 $\Theta = a^2$ 。

在翼型表面,考虑黏性流动情况,施加无滑移绝热壁面的边界条件;在远场边界处,分别设置其密度 ρ_∞ 、 x 方向速度 u_∞ 、 y 方向速度 v_∞ 和当地声速 a_∞ 4个自由流条件如下: $\rho_\infty = 1.0$, $u_\infty = Ma_\infty \cos(\alpha)$, $v_\infty = Ma_\infty \sin(\alpha)$, $a_\infty = 1.0$, 其中, α 为攻角。此外, $p_\infty = \rho_\infty a_\infty^2 / \gamma$ 。故以上偏微分方程离散后可隐式表示为:

$$\mathfrak{R}(\mathbf{y}, Ma_\infty, \alpha, Re_\infty, \mathbf{G}) = 0 \quad (4)$$

二维稳态 CFD 模拟的目的是针对给定翼型坐标的几何信息 $\mathbf{G}$ 和流场的网格离散化信息,通过迭代求解式(4),得到4个独立的物理场变量(即 $\mathbf{y} = [\rho, u, v, a]$)的空间分布。在气动设计中,重要的是特定自由流条件($\mathbf{x} = [Ma_\infty, \alpha, Re_\infty]$)和几何信息 $\mathbf{G}$ 下的稳态确定性流场 $\mathbf{y}$ 。RANS 模拟的收敛解在物理上是一个集合的平均值,它代表了一个确定性解。将离散的偏微分方程写成显式的输入输出形式为:

$$\mathbf{y} = f(\mathbf{x}, \mathbf{G}) \quad (5)$$

其中,输出 $\mathbf{y}$ 表示 RANS 模拟的参考解,可将学习任务定义为将输入 $\mathbf{x}$ 和 $\mathbf{G}$ 映射到输出 $\hat{\mathbf{y}}$ 近似值的函数 $\hat{f}$ 。用一个深度神经网络表示 $\hat{f}$,以尽可能接近真实函数 f 的输出 $\mathbf{y}$,通过调整其权重 $\mathbf{w}$,使 $\mathbf{y} \approx \hat{\mathbf{y}} = \hat{f}(\mathbf{x}, \mathbf{G}; \mathbf{w})$ 。此时训练目标可表示为:

$$\arg \min |f(\mathbf{x}, \mathbf{G}) - \hat{f}(\mathbf{x}, \mathbf{G}; \mathbf{w})| \quad (6)$$

式(6)代表了一种基于训练数据集提供的输入到输出的完全监督学习方法,即以翼型几何信息及流场工况条件(马赫数、攻角、雷诺数)作为输入,输出定义为全域流场的4个物理量(密度、 x 方向速度、 y 方向速度、当地声速),通过构建神经网络模型实现通过输入工况和翼型几何信息,快速预测翼型流场中4个物理量的分布。

1.2 基于 CFL3D 求解器的数据集

CFL3D (computational fluids laboratory 3-dimensional) 是一款基于结构网络、以单元体为中心的 RANS 方程离散求解器,采用有限体积法对广义坐标下的二维 RANS 方程进行数值求解。首先基于 CFL3D 求解器为每个翼型网格设置边界条件参数,随后在如表 1 所示工况范围内为每种翼型型号随机抽取 3 种工况条件,对每个 NACA 系列翼型网格均迭代计算 10000 次,得到 52 种 NACA 翼型在 156 种工况下的全域流场数据文件。

针对 DNN 而言,离散化的流场网格物理坐标

表1 工况参数范围
Table 1 Operating parameter range

工况参数	参数范围
攻角 $\alpha /(^{\circ})$	$[-0.5, 8]$
马赫数 Ma	$[0.55, 0.8]$
雷诺数 $Re/10^6$	$[0.5, 5]$

处在笛卡尔坐标系中, 网格点的不均匀分布不利于神经网络输入的几何编码, 故需考虑一种适合网格划分且易于在正则空间中表示的离散化方法。因此, 对 CFL3D 求解器计算的原始流场信息进行数据预处理操作。

对 NACA 系列翼型进行网格划分, 翼面法向节点数量为 129, 翼型表面网格节点数量为 81, 网格中尾迹区域后可见节点数量为 24。值得注意的是, 实际添加的节点数量是该数量的两倍, 因为计算网格沿着翼型表面线被切割为两部分, 故有两组相同的节点彼此叠加, 一组属于网格顶部, 另一组属于底部, 且相邻两个节点分别位于一个网格单元的两侧, 由此生成沿翼面方向和翼面法向的网格单元数量均为 128 的 C 型网格。

对于一个给定的结构化网格, 需将样本坐标信息从物理空间 (x, y) 坐标映射到计算空间 (ε, η) 曲线坐标系上, 以符合神经网络的归一化输入习惯。如图 1 所示, 其中: ε 为沿着翼面方向坐标, $\varepsilon = \frac{i-1}{i_{\max}-1}$; η 为沿着翼面法向坐标, $\eta = \frac{j-1}{j_{\max}-1}$; i, j 分别为沿着翼面方向和法向的网格索引号, $i_{\max}$ 和 $j_{\max}$ 分别表示两个方向上网格的索引号最大值, 均为 128。因此, 通过上述映射方法归一化, 将曲线坐标值域限制在 $[0, 1]$ 之间, $\eta = 0$ 表示网格单元处于翼型表面位置。




图1 网格空间坐标编码示意图

Fig. 1 Diagram of grid space coordinate encoding

在笛卡尔物理坐标系中, 任意网格的物理坐标可以表示为:

$$\begin{bmatrix} x \\ y \end{bmatrix}_{i,j} = \begin{bmatrix} x_0 \\ y_0 \end{bmatrix}_{i,1} + \int \begin{bmatrix} dx \\ dy \end{bmatrix} \quad (7)$$

$$\begin{bmatrix} dx \\ dy \end{bmatrix} = \begin{bmatrix} \partial_{\varepsilon} x & \partial_{\eta} x \\ \partial_{\varepsilon} y & \partial_{\eta} y \end{bmatrix} \begin{bmatrix} d\varepsilon \\ d\eta \end{bmatrix} \quad (8)$$

由于无量纲形式更有利于提取特征, 可将任意网格的坐标信息进一步表示为如式(9)所示的无量纲形式:

$$\begin{cases} \hat{\varepsilon}_x = \partial_{\varepsilon} x / |\nabla \varepsilon| \\ \hat{\varepsilon}_y = \partial_{\eta} x / |\nabla \varepsilon| \\ \hat{\eta}_x = \partial_{\varepsilon} y / |\nabla \eta| \\ \hat{\eta}_y = \partial_{\eta} y / |\nabla \eta| \end{cases} \quad (9)$$

同时, 定义变换的雅可比行列式 J 为:

$$J = \begin{vmatrix} \partial_{\varepsilon} x & \partial_{\eta} x \\ \partial_{\varepsilon} y & \partial_{\eta} y \end{vmatrix} \quad (10)$$

因此, 基于以上归一化和无量纲化处理步骤, 神经网络输入的网格几何信息可以表示为如式(11)所示的矩阵形式:

$$\mathbf{G}_{i_{\max} \times j_{\max} \times 9} = \begin{bmatrix} J^{-1} & \hat{\varepsilon}_x & \hat{\varepsilon}_y & |\nabla \varepsilon|/J & \hat{\eta}_x & \hat{\eta}_y & |\nabla \eta|/J & x_0 & y_0 \end{bmatrix} \quad (11)$$

另外, 输入的自由流条件考虑到与几何信息矩阵的维度对齐, 可将其扩充为 $i_{\max} \times j_{\max}$ 的矩阵形式, 即:

$$\mathbf{x}_{i_{\max} \times j_{\max} \times 3} = [Ma_{\infty} \ a_{\infty} \ Re_{\infty}] \quad (12)$$

综上, 经过数据预处理的数据集由 3 个自由流工况条件 $\mathbf{x}$ 与 9 个翼型无量纲几何参数 $\mathbf{G}$ 组成, 共 12 种输入参数, 每个 (ε, η) 曲线坐标系的点均代表一个网格单元, 在 12 个数据通道中均有对应参数, 构成 $i_{\max} \times j_{\max} \times 12$ 的三维数据。

1.3 基于 Transformer 的快速流场预测模型

基于机理分析, 预测模型学习任务可定义为: 输入由自由流条件和翼型的几何信息组成, 自由流条件由式(12)表示, 翼型几何信息由式(11)表示, 各输入变量均为 $i_{\max} \times j_{\max}$ 的二维张量形式, 输出为全域流场的 4 个物理属性 $\mathbf{y} = [\rho, u, v, a]$ 。

基于编码器-解码器搭建的网络模型 DB-TUNet (dual branch network based on Transformer and UNet) 的整体结构如图 2 所示, 主要包括 3 个部分: 基于 Transformer 和 UNet 的双分支全局-局部编码器、基于多尺度通道注意力机制的跳跃连接以及基于上采样和卷积的解码器。整个模型的工作流程为: 将由自由流条件和翼型几何参数信息组成维度为 $H \times W \times 12$ 的三维矩阵作为模型输入, 经过双分支编码器进行特征编码, 提取输入数据的全局和局部特征, 并在跳跃连接中添加注意力融合模块, 将两组特征融合作为解码器的输入,




图 2 DB-TUNet 模型整体结构
Fig. 2 General structure of DB-TUNet

通过 4 次上采样和卷积操作, 最终输出 $H \times W \times 4$ 的翼型流场全域分布。

2 流场超分辨率重建模型

DB-TUNet 流场推演模型利用翼型形状和工况信息,可快速提供特定翼型下的全域流场数据。在此模型构建的多工况全域流场离线数据集基础上,引入新的神经网络,将稀疏传感器数据映射为超分辨率全域流场数据,以此实现流场重建功能。

2.1 快速流场重建机理分析

流场重建的目的是利用离散传感器测量值 $\mathbf{s} \in \mathbb{R}^p$ 来预测全域流场信息 $\mathbf{q} \in \mathbb{R}^m$ ($\mathbb{R}$ 为实数合集, p 表示传感器测量点数量, m 表示整个动力场), 即学习映射关系 $\mathbf{s} \mapsto \mathbf{q}$ 。有限传感器的取值范围区域 $p \ll m$, 其中, 可通过在高纬度全域流场分布 $\mathbf{q}$ 中对翼型表面特定传感器位置上的物理属性进行采样, 获取用于流场重建模型训练的离散测量值 $\mathbf{s}$, $\mathbf{s}$ 可描述为:

$$s = H(\boldsymbol{q}) \quad (13)$$

其中 $H: \mathbb{R}^m \rightarrow \mathbb{R}^p$ 为测量算子, 表示获取全域流场分布中翼型表面特定位置上的物理场信息的采样函

数。因此,流场重建的目的即转化为构建一个可根据测量值 s 来映射全域流场 a 的逆向模型:

$$\mathbf{q} = G(\mathbf{s}) \quad (14)$$

其中 $G: \mathbb{R}^m \rightarrow \mathbb{R}^p$ 表征一个非线性正演算子, 即辅助智能蒙皮离散传感器数据重建超分辨率全域流场的非线性映射关系, 是构建数据驱动流场重建模型的关键。但测量算子 H 在实际工程应用中可能呈现高度非线性, 甚至未知, 故无法通过反推测量算子 H 的方式直接得到正演算子 G 。值得注意的是, 通过给定一系列训练样本 $\{q_i, s_i\}_i$, 对应于翼型表面稀疏位置上的传感器测量值与翼型流场全域分布信息的配对关系, 以学习的方式构建一个函数 F , 对正演算子 G 进行近似, 即流场重建的目标是学习一个函数 $F: s \mapsto \hat{q}$, 构建从有限传感器测量值到估计的全域流场分布数据 $\hat{q}$ 之间的映射关系, 即:

$$\hat{q} = F(s) \quad (15)$$

使全域各离散点与真实值之间的误差控制在较小的范围内,用欧几里得范数可表示为: $\|\mathbf{F}(\mathbf{s}) - \mathbf{G}(\mathbf{s})\|_2^2 < \varepsilon_{\text{num}}$, 其中 ε_{num} 是一个极小正值。

综上,基于深度学习方法的高分辨率流场重建模型构建思路可总结为:获取某种翼型在多个工况下的全域流场分布信息,按照实际应用场景中传感器数量及布局,对以上多工况流场进行数据采样,获取与实验传感器相同位置下的物理属性集合,并与原始全域流场分布信息构成一系列的训练样本,使深度学习模型可学习多种工况下的流场分布规律。在实际应用时,输入相同位置下的智能蒙皮稀疏传感器数据,模型则自动根据学习到的映射关系,对全域流场进行快速重建。然而,以上机理分析中的模型通常只适用于一种翼型在固定传感器位置分布下的映射,如需满足快速重建且对多种翼型具备一定泛化能力的需求,模型结构需遵循轻量化设计原则,以便在应对新翼型或新的传感器布局信息时,能快速基于流场预测模型生成的新的全域流场信息学习特征,得到新的非线性映射关系,从而满足流场重建算法在实际工程中的应用需求。

2.2 流场超分辨率重建数据集

基于二维翼型流场快速推理模型 DB-TUNet,选取 M6 型号的二维翼型,对马赫数、攻角、雷诺数 3 个工况条件进行均匀抽样,工况范围如表 2 所示。每个工况均抽样 5 次,生成 125 个组合工况条件。

表 2 训练集工况

Table 2 Operating conditions of the training set

工况参数	参数范围	抽样条件
攻角 $\alpha / (^\circ)$	$[-0.5, 8]$	$[-0.5, 1.625, 3.75, 5.875, 8]$
马赫数 Ma	$[0.55, 0.8]$	$[0.55, 0.615, 0.675, 0.7375, 0.8]$
雷诺数 $Re/10^6$	$[0.5, 5]$	$[0.5, 1.625, 2.75, 3.875, 5]$

将包含 M6 翼型几何形状信息的 dat 文件及 125 组工况条件输入到 DB-TUNet 模型中,直接获取该翼型在 125 组工况下的 4 个物理量的全场数据,避免了采用 CFD 求解器计算全域流场数据集带来的求解时间长的问题。以压力场为例,对生成的数据集进行划分,划分比例为训练集:测试集 = 100:25。

根据网格文件设置信息可知, M6 翼型表面按网格分布形式共存在 81 个离散节点,如图 3 所示。可在网格对应的离散节点中随机选取 N 个,作为稀疏传感器的布置点。提取这 N 个测点位置对应的压力值,构成 $100 \times N$ 的多工况稀疏数据矩阵,记为 $\mathbf{s}$,相对应的是 100 组相同工况下的全域物理场数据,构成维度为 $128 \times 128 \times 100$ 的三维矩阵,记为 $\mathbf{q}$ 。稀疏流场超分辨率重构算法的目的是构建从 $\mathbf{s} \rightarrow \mathbf{q}$ 的快速映射,即根据 N 个稀疏传感器数据重建 128×128 的全域超分辨率流场。




图 3 翼型表面网格节点分布

Fig. 3 Distribution of grid nodes on the airfoil surface

2.3 基于 SNN (shallow neural network) 的流场重建模型

基于浅层神经网络 (shallow neural network, SNN) 及全域流场数据集,学习离散传感器测量数据到全域流场之间的输入输出映射关系。传统的 POD 方法存在计算近似基和线性加权组合两个方面的复杂性,而浅层神经网络在训练和调节上的难度都更小。首先给出 K 层全连接神经网络 (fully connected neural network, FCNN) 的一般架构,表达式如式 (16) 所示:

$$F(\mathbf{s}; \mathbf{W}) := R(\mathbf{W}^K R(\mathbf{W}^{K-1} \dots R(\mathbf{W}^1 \mathbf{s}))) \quad (16)$$

其中, $R(\cdot): R \rightarrow R$ 代表各层的非线性激活函数, $\mathbf{W}$ 代表一系列的权重参数矩阵 $\{\mathbf{W}^k\}_k, k=1, \dots, K$ 。针对本节的训练集 $\{q_i, s_i\}_{i=1}^n$, n 表示所有工况下的样本数量, q_i 和 s_i 对应每种工况下的全域数据和传感器测量数据,上文分析的 $F: \mathbf{s} \mapsto \hat{\mathbf{q}}$ 的函数学习目标可归属于训练一个可使离散测点值与实际值不匹配度最小化的 SNN 网络问题,即:

$$F \in \arg \min_{\tilde{F} \in F} \sum_{i=1}^n \|q_i - \tilde{F}(s_i)\|_2^2 \quad (17)$$

针对工程应用背景需要,网络架构应满足能快速训练、支持适当调参、层次直观易解释等要求。基于 POD 思想的启发,全域流场 $\mathbf{q}$ 可近似为 k_m 个模态的线性组合表示的近似空间,即 $\mathbf{q} \approx \hat{\mathbf{q}} = \sum_{j=1}^{k_m} \phi_j v_j = \Phi \mathbf{V}$, $\{\phi_j\}_j$ 是某个模态的近似, $\{v_j\}_j$ 是相关系数。应用神经网络的思想可相应地将最后一层网络的输出理解为 $\hat{\mathbf{q}}$, 输入理解为 k_m 个由 $\mathbf{v}$ 加权的模态特征,最后一层是线性层,但其线性加权系数需由传感器数据以非线性学习方式获得。因此 $\mathbf{s} \mapsto \mathbf{v}$ 非线性映射可采取一个隐藏层实现,输出从测量数据中反映的特征 ψ , 描述了输入测量数据 $\mathbf{s}$ 的非线性组合方式,并将其映射到与模态 ϕ 相关的系数 $\mathbf{v}$ 。输出层的尺寸与离散化的全域流场 $\mathbf{q}$ 大小相同,次隐藏层 ζ 的尺寸定义为模态 ϕ 的尺寸

k_m , 可从 $\{q_i\}_i$ 中估计得到。第一个隐藏层的 ψ 本质上是由输入层的尺寸和非线性组合 ν 的数量决定的, 但通常隐藏层灵活性很大。综上, 可将浅层神经网络定义为具有两个隐藏层 ψ 、 ζ 和一个线性输出层 Ω 的 SNN 结构, 即:

$$F(s) = \Omega(\zeta(\psi(s))) \quad (18)$$

由于翼型表面的流场数据只能在有限工况下生成, 样本数量具有一定的局限性, 因此不适合需要大量样本输入的卷积层, 在此两个隐藏层采取全连接形式, 其表达式如式(19)所示:

$$\begin{aligned} z^\psi &= \psi(s) = R(W^\psi s + b^\psi) \\ z^\zeta &= \zeta(z^\psi) = R(W^\zeta z^\psi + b^\zeta) \end{aligned} \quad (19)$$

其中, b 是偏置项。输出线性层可表述为:

$$\hat{q} = \Omega(z^\zeta) = \Phi z^\zeta + b^\Phi \quad (20)$$

其中, 权重矩阵 Φ 即为上文分析的特征分解模式, 最后, 浅层神经网络架构可描述为:

$$s \mapsto \psi(s) \mapsto \zeta(z^\psi) \mapsto \Omega(z^\zeta) \equiv \hat{q} \quad (21)$$

基于以上模型结构设计分析过程, 提出数据驱动的超分辨率流场重建模型 (data-driven shallow neural network, D2SNN), 其网络架构如图 4 所示。输入为稀疏传感器测量数据, 输出为重建的全域流场分部信息。为了防止模型出现过拟合, 降低网络训练的复杂性, 提高收敛性和鲁棒性, 在网络架构中加入 Dropout 层, 并在隐藏层使用 Batch 批处理组件。网络训练过程中激活函数使用 ReLU 函数。




图 4 数据驱动的浅层神经网络架构

Fig. 4 Data-driven shallow neural network architecture

3 实验验证

如图 5 所示, 柔性智能蒙皮安装在 M6 翼型模型

上, 沿着翼型表面的一个截面贴装, 黑色表示压力传感器, 黄色为蒙皮封装。蒙皮传感器采集到的测点信息, 将被作为重建模型的输入, 即 N 个稀疏传感器数据。




图 5 柔性智能蒙皮贴装示意图

Fig. 5 Schematic diagram of flexible smart skin attachment

3.1 流场预测模型精度验证

为了验证所提出的 DB-TUNet 模型中各模块的有效性, 通过 4 组消融实验, 分别对比原始 DB-TUNet 模型在去除各模块后的训练效果。其中, “消融-MSCF” 表示使用元素加法代替模型中的特征融合模块, “消融-Trans” 表示去除编码器中的 Transformer 分支, 只保留基于 UNet 的单分支结构, “消融-UNet” 表示去除 UNet 分支, 只保留 Transformer 分支。对 4 组消融模型均进行 5000 次迭代训练。

训练过程中的损失函数变化如图 6 所示。可以看出, 各消融实验组对比原始 DB-TUNet 实验组, 在损失函数的收敛效果上均有一定程度的衰减, DB-TUNet 实验组的损失函数在相同迭代次数下依旧保持最低, 且初始损失函数更低, 迭代过程更稳定, 未出现振荡现象。因此, 原始 DB-TUNet 模型在训练集中综合表现更好。




图 6 各模块消融实验组与原始组损失函数值随迭代次数变化对比

Fig. 6 Comparison of loss function value variations with iterations between module ablation groups and the baseline group

以测试集中的 NACA2241 翼型为例, 给定工况马赫数为 0.59、攻角为 4.2° 、雷诺数为 2.274×10^6 , 4 组模型对该工况下的翼型流场全域分布预测结果和 CFD 计算结果的对比如图 7 所示, 从上到下依次为 CFD 求解器、DB-TUNet 无消融模型和 3 个消融模型对归一化后的密度、 x 、 y 方向速度和当地声速 4 个流场物理量的预测结果。

为了更直观地表示各模型的流场预测效果与 CFD 原始流场分布的差别, 将 CFD 的 4 个原始流场分布(密度、 x 速度、 y 速度、当地声速)分别与去除 Transformer、UNet 和 MSCF 模块后的模型预测结果在每个像素点上相减, 绝对误差结果以颜色映射表示, 如图 8 所示, 黑色表示绝对误差值为 0, 预测精度最高, 颜色越浅表明该区域绝对误差越大。

根据图 7 和图 8, 可明显观察到 DB-TUNet 模型在不去除任何模块的情况下对 4 个流场物理量的预

测效果最好, 仅在翼型前缘位置存在少许误差, 翼型表面其他位置及翼型远端流场分布都能很好地与 CFD 数值模拟结果吻合。“消融-MSCF”“消融-Trans”“消融-UNet”模型在 4 个物理量上均出现了不同程度的斑点现象, 流场分布不够平滑, 导致了一定程度的失真。其中, “消融-Trans”实验组表明, 缺少编码器中的 Transformer 模块将极大地削弱模型的全局流场特征提取能力, 使整体预测结果与真实值的误差达到最高; “消融-UNet”实验组表明, 去除编码器中的 UNet 模块不会对整体全域流场预测效果产生较大影响, 但对翼型表面流场区域的预测效果会显著下降, 从侧面证明了编码器中的 UNet 模块对流场局部特征的提取能力; “消融-MSCF”实验组则表明, 简单地以相加的方式融合全局和局部流场特征无法达到特征融合的最优效果, 无法深度还原整体流场分布。

将 4 个模型应用到整个测试集中, 并分别计算




图 7 4 种模型的流场预测结果和 CFD 计算结果的对比

Fig. 7 Comparison of flow field predictions from four models and CFD results




图 8 4 种模型的流场预测误差对比

Fig. 8 Comparison of flow field prediction errors of four models

4 个模型对 4 个流场物理量的预测相对误差，随机选取其中 8 个测试样本下的预测误差结果如图 9 所示，不难看出，本文提出的 DB-TUNet 模型在不去除任何模块的前提下，在整体测试集上的表现均为最佳，对密度场、 x 速度场、 y 速度场和当地声速场的预测平均相对误差分别为 1.49%、7.62%、5.37% 和 0.25%，各物理量综合平均相对误差为 3.68%。

以上分析综合表明，编码器中的 Transformer 分支、UNet 分支结构和特征融合模块均对流场预测模型精度有一定的正向作用，能更充分地提取流场全局和局部特征并深度融合，从而证明了各模块的有效性。

基于 DB-TUNet 模型快速预测得到的全域流场分布中的各物理量信息，同样可用于间接计算其他物理量。以压力场为例，翼型的压力系数描述了翼型表面不同位置的压力分布情况，基于压力系数可优化飞行器外形设计以减小升阻比、提高飞行器的巡航效率、预测飞行器在不同飞行状态下的气动性能，对飞行器气动载荷监测具有重要作用。根据式(22)可间

接计算得到翼型的压力系数 C_p ：

$$C_p = \frac{p - p_\infty}{p_0 - p_\infty} \quad (22)$$

其中： p_0 为全场总压，可由式(23)求解； p 为翼型流场的全域压力分布，可由式(24)求解； p_∞ 为远场压力，可由全域压力分布 p 对最远端压力求均值得到。

$$p_0 = p \times \left(1 + (\gamma - 1)/2 \times Ma^2\right)^{\frac{\gamma}{\gamma-1}} \quad (23)$$

$$p = \sqrt{\rho \times a^2 / \gamma} \quad (24)$$

其中， a 为当地声速。

图 10 所示为 DB-TUNet 模型对测试集中 6 种工况的流场预测结果及其压力系数与 CFD 原始计算结果的对比。可以看出，根据 DB-TUNet 模型间接计算得到的压力场同样与 CFD 原始计算结果吻合较好。同理，模型在训练时可拓展得到温度、摩阻等物理量，从而提高模型对更多气动载荷参数的表达能力，为流场重建研究提供更丰富的数据信息。




图9 4种模型在测试集上对4个流场物理量的预测相对误差


Fig. 9 Relative prediction errors of four models for four flow field physical quantities on the test set

3.2 流场超分辨率重建精度验证

3.2.1 定性分析

基于提出的数据驱动的超分辨率流场重建模型D2SNN,以压力场为例,针对不同数量及位置分布的传感器进行了M6机翼流场的超分辨率重建。将实

验分为3组,分别设定翼型表面传感器数量为5、10、15,在每组固定传感器数量的前提下,随机打乱传感器分布位置,进行5次传感器数量相同但位置不同的平行实验,验证D2SNN流场重建模型在任意传感器位置和数量下的重建效果。同时,采用传统POD方法进






图 10 测试集工况下 DB-TUNet 模型对压力和压力系数的预测结果与 CFD 计算结果的对比

Fig. 10 Comparison of the predictions of pressure and pressure coefficients by the DB-TUNet model and CFD computational results under test-set conditions

行以上相同实验步骤并对比结果。传感器数量分别为 5、10 和 15，传感器位置随机分布的情况下，两种模型对应的流场重建效果如图 11 所示。由图 11 可知，POD 模型在给定较少传感器数量的情况下可能发生拟合现象，导致流场重建效果不佳，而 D2SNN 模型由于其网络轻量化、层数少，未发生过拟合现象。随着传感器数量增多，D2SNN 和 POD 模型的重建性均能有一定程度的提升，且 D2SNN 模型总体精

度略高于 POD 模型。此外，根据图 11 传感器数均为 10、位置不同的两组结果对比可知，在传感器数量足够且分布较均匀时，传感器位置对 D2SNN 模型的重建效果无明显影响。

3.2.2 定量分析

对 D2SNN 模型在 3 组不同传感器数量的实验条件下分别进行 4000 次迭代。为清晰表达收敛趋势，对每 500 次迭代进行损失函数取均值处理，在训练集和测试集的收敛过程如图 12 所示。由图 12 可知，D2SNN 模型在给定更多传感器的情况下可达到更好的流场重建效果，训练集和测试集的损失函数均收敛为更小的数值，符合宏观规律。

进一步地，考虑使用标准化的均方根残差 NME 来量化 D2SNN 模型和 SNN 模型流场重建结果的相对误差，表达式如式(25)所示：

$$NME = \frac{\|q - \hat{q}\|_2}{\|q\|_2} \quad (25)$$

其中， q 为全域流场分布的真值， $\hat{q}$ 为根据稀疏传感器数据重建的全域流场数据。

然而，如果经验均值占主导地位，这种测量可能会产生误导。因此还考虑了一种更敏感的方法，量化了经验均值周围偏差的重建精度，定义考虑偏差的均方根残差 NFE 表达式如式(26)所示：

$$NFE = \frac{\|q' - \hat{q}'\|_2}{\|q'\|_2} \quad (26)$$




图 11 D2SNN 和 POD 模型在不同传感器数量下的流场重建结果对比

Fig. 11 Comparison of flow fields reconstruction results between the D2SNN and POD models under different sensor numbers




图 12 不同传感器数量下训练集和测试集的损失函数收敛情况对比
Fig. 12 Comparison of loss convergence between the training set and the test set under different sensor numbers

其中, q' 、 $\hat{q}'$ 分别是考虑了经验均值周围波动部分的全域流场分布真值和根据稀疏传感器数据重建的全域流场数据。

在 3 组不同传感器数量的分组实验中, 分别对固定数量的传感器位置进行湍流模型布局, 进行 5 次不同传感器位置的平行实验, 探究给定任意传感器位

置和数量的条件下, D2SNN 和 POD 两种模型的流场重建效果, 实验结果以训练集和测试集相对误差 NME 和 NFE 表示, 结果如图 13 所示。同时对每组实验下, 不同传感器分布的 5 次平行实验结果的相对误差进行了平均处理, 结果如表 3 所示。从图 13 和表 3 可以看出, 对 D2SNN 模型而言, 在给定 5 个传感器数




图 13 D2SNN 模型与 POD 模型在不同传感器数量下流场重建结果的相对误差对比
Fig. 13 Comparison of the relative errors in flow field reconstruction results between the D2SNN and POD models under different sensor numbers

表 3 不同传感器数量下 D2SNN 和 POD 模型结果的相对误差均值

Table 3 Mean relative error of the D2SNN and POD models using different sensor numbers

重建算法	传感器数量	训练NME	训练NFE	测试NME	测试NFE
D2SNN	5	0.005 630	0.002 818	0.027 328	0.013 568
	10	0.004 820	0.002 412	0.038 146	0.018 942
	15	0.004 130	0.002 066	0.023 678	0.011 742
POD	5	0.017 984	0.009 002	0.088 796	0.044 174
	10	0.007 662	0.003 834	0.118 990	0.059 078
	15	0.006 970	0.003 490	0.054 048	0.026 756

据的情况下, 即可获得在测试集中 2.73% 的流场重建相对误差。而同实验条件下的 POD 模型在测试集的平均相对误差为 4.4%。此外, 两个模型的相对误差曲线表明, D2SNN 模型相对误差曲线较为平缓, 其对传感器位置不敏感, 在翼型表面使用不同传感器分布时, 对模型重建性能影响较低。而 POD 模型在给定传感器数量较少的情况下, 流场重建性能极易受传感器位置影响。综合 3 组实验结果, 不难发现, D2SNN 模型在传感器位置较少的情况下仍能保持一定的重

建精度, 且受传感器位置影响较小, 模型训练仅需耗时约 40 s, 满足快速、稳健的流场重建模型需求。

4 结 论

本文围绕柔性智能蒙皮在飞行器领域的应用, 针对柔性智能蒙皮传感器数据空间分辨率不足、难以准确监测复杂气动现象、无法直接测量翼型远端流场的问题, 从二维翼型流场快速预测模型构建、数据驱动的超分辨率流场重建算法设计两个方面展开了探究。得到以下主要结论:

1) 基于 Transformer 和 UNet 的双分支神经网络 DB-TUNet 实现了二维翼型流场的快速预测, 使其能够替代传统 CFD 求解器, 各物理量平均预测误差为 3.68%。

2) 提出了适应多种翼型、任意位置和数量传感器分布的超分辨率快速流场重建模型 D2SNN, D2SNN 模型能够在较短时间内构建流场重建所需的全域流场数据, 重建相对误差为 2.73%。

本研究所提出的重建算法虽然在实时性方面表现良好, 但其重建精度与高精度算法相比仍有一定提升空间。后续工作可拓展至非标准翼型乃至非翼型结构的应用与算法优化, 以验证本方法的广泛适应性。此外, 该算法具有反向推导潜力, 有望快速给出最优的传感器布局建议, 这在传感器的位置优化问题上具有进一步的研究价值。

参 考 文 献:

- [1] TABRIZIAN A, TATAR M, EIVAZI H, et al. An experimental study on boundary layer transition detection over a pitching supercritical airfoil using hot-film sensors[J]. *International Journal of Heat and Fluid Flow*, 2020, 86: 108743.
doi: 10.1016/j.ijheatfluidflow.2020.108743
- [2] 杜文聪, 陈智. 数据驱动的升力体飞行器表面热流快速预测[J]. *空气动力学学报*, 2025, 43(7): 93–107.
DU W C, CHEN Z. Data-driven rapid prediction of surface heat flux for lifting-body aircraft[J]. *Acta Aerodynamica Sinica*, 2025, 43(7): 93–107 (in Chinese).
doi: 10.7638/kqdlxxb-2025.0109
- [3] 李中华, 陈爱国, 杨彦广, 等. 低温振动非平衡流动数值模拟研究[J]. *空气动力学学报*, 2024, 42(11): 55–62.
LI Z H, CHEN A G, YANG Y G, et al. Numerical study of vibrational non-equilibrium flow at low temperature[J]. *Acta Aerodynamica Sinica*, 2024, 42(11): 55–62 (in Chinese).
doi: 10.7638/kqdlxxb-2023.0149
- [4] RUDMIN D, BENAÏSSA A, POIREL D. Detection of laminar flow separation and transition on a NACA-0012 airfoil using surface hot-films[J]. *Journal of Fluids Engineering*, 2013, 135(10): 101104.
doi: 10.1115/1.4024807
- [5] 陈舒越, 郭向东, 王梓旭, 等. 结冰风洞过冷大水滴粒径测量初步研究[J]. *实验流体力学*, 2021, 35(3): 22–29.
CHEN S Y, GUO X D, WANG Z X, et al. Preliminary research on size measurement of supercooled large droplet in icing wind tunnel[J]. *Journal of Experiments in Fluid Mechanics*, 2021, 35(3): 22–29 (in Chinese).
doi: 10.11729/sytltx20200104
- [6] 高文涛, 张武林, 寇宝智. T 型尾翼飞机抖振试飞研究[J]. *实验流体力学*, 2020, 34(6): 45–51.
GAO W T, ZHANG W L, KOU B Z. Study on buffet flight test of aircraft with T-tail[J]. *Journal of Experiments in Fluid Mechanics*, 2020, 34(6): 45–51 (in Chinese).
doi: 10.11729/sytltx20200040
- [7] KUESTER M S, BORGOLTZ A, DEVENPORT W J. Pressure tap effects on the lift measurement of an airfoil section[C]//32nd AIAA Aerodynamic Measurement Technology and Ground Testing Conference, Washington, USA. AIAA, 2016.
doi: 10.2514/6.2016-3654
- [8] 李刚, 韩杰, 王帆. 风洞变频调速系统对热线风速仪的影响及解决方法研究[J]. *测控技术*, 2022, 41(11): 78–83.
LI G, HAN J, WANG F. Influence and resolution of variable frequency speed regulation system of wind tunnel on hot-wire anemometer[J]. *Measurement & Control Technology*, 2022, 41(11): 78–83 (in Chinese).
doi: 10.19708/j.ckjs.2022.11.012
- [9] 霍俊杰, 易仕和, 牛海波, 等. 基于温敏漆技术的圆锥高超声速大攻角绕流背风面流动结构实验研究[J]. *气体物理*, 2022, 7(4): 67–76.
HUO J J, YI S H, NIU H B, et al. Experimental study of flow on the leeward side of a cone at a high angle of attack based on temperature sensitive paint[J]. *Physics of Gases*, 2022, 7(4): 67–76 (in Chinese).
- [10] 孙晓刚, 李云红. 红外热像仪测温技术发展综述[J]. *激光与红外*, 2008, 38(2): 101–104.
SUN X G, LI Y H. Review of the development of temperature measurement technology with infrared thermal imager[J]. *Laser & Infrared*, 2008, 38(2): 101–104 (in Chinese).
doi: 10.3969/j.issn.1001-5078.2008.02.001
- [11] LI X T, LIU X, LIU Y Z, et al. Experimental study of near-wall underexpanded jet impingement on a flat plate using temperature-insensitive semi-transparent pressure-sensitive paint[J]. *Experiments in Fluids*, 2020, 61(11): 232.
doi: 10.1007/s00348-020-03068-5
- [12] 陈皓, 郭明明, 田野, 等. 卷积神经网络在流场重构研究中的进展[J]. *力学学报*, 2022, 54(9): 2343–2360.
CHEN H, GUO M M, TIAN Y, et al. Progress of convolution neural networks in flow field reconstruction[J]. *Chinese Journal of Theoretical and Applied Mechanics*, 2022, 54(9): 2343–2360 (in Chinese).
doi: 10.6052/0459-1879-22-130
- [13] ZHAO X, DENG Z C, ZHANG W W. Sparse reconstruction of surface pressure coefficient based on compressed sensing[J]. *Experiments in Fluids*, 2022, 63(10): 156.
doi: 10.1007/s00348-022-03505-7
- [14] ZHAO X, DU L, PENG X H, et al. Research on refined reconstruction method of airfoil pressure based on compressed sensing[J]. *Theoretical and Applied Mechanics Letters*, 2021, 11(2): 100223.
doi: 10.1016/j.taml.2021.100223
- [15] 赵旋, 彭绪浩, 邓子辰, 等. 基于多源数据融合的翼型表面压强精细化重构方法[J]. *实验流体力学*, 2022, 36(3): 93–101.
ZHAO X, PENG X H, DENG Z C, et al. Fine reconstruction method of airfoil surface pressure based on multi-source data fusion[J]. *Journal of Experiments in Fluid Mechanics*, 2022, 36(3): 93–101 (in Chinese).
doi: 10.11729/sytltx20210166
- [16] ZHANG Q, ZHAO X, LI K, et al. Prediction model of aircraft hinge

- moment: Compressed sensing based on proper orthogonal decomposition[J]. *Physics of Fluids*, 2024, 36(7): 076102.
doi: [10.1063/5.0214653](https://doi.org/10.1063/5.0214653)
- [17] ZHANG Q, WANG X, YANG D G, et al. Data-driven prediction of aerodynamic noise of transonic buffeting over an airfoil[J]. *Engineering Analysis with Boundary Elements*, 2024, 163: 549–561.
doi: [10.1016/j.enganabound.2024.04.006](https://doi.org/10.1016/j.enganabound.2024.04.006)
- [18] 黄俊, 郭雨欣, 冀晶晶, 等. 基于数据同化的气动压力稀疏重构方法[J]. *实验流体力学*, 2023, 37(5): 9–17.
HUANG J, GUO Y X, JI J J, et al. Aerodynamic pressure field reconstruction from sparse points using data assimilation method[J]. *Journal of Experiments in Fluid Mechanics*, 2023, 37(5): 9–17 (in Chinese).
doi: [10.11729/sytlx20230021](https://doi.org/10.11729/sytlx20230021)
- [19] SUN L N, WANG J X. Physics-constrained Bayesian neural network for fluid flow reconstruction with sparse and noisy data[J]. *Theoretical and Applied Mechanics Letters*, 2020, 10(3): 161–169.
doi: [10.1016/j.taml.2020.01.031](https://doi.org/10.1016/j.taml.2020.01.031)
- [20] YILMAZ E, GERMAN B. A convolutional neural network approach to training predictors for airfoil performance[C]//18th AIAA/ISSMO Multidisciplinary Analysis and Optimization Conference, Denver, Colorado. AIAA, 2017.
doi: [10.2514/6.2017-3660](https://doi.org/10.2514/6.2017-3660)
- [21] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. *Proceedings of the IEEE*, 86(11): 2278–2324.
doi: [10.1109/5.726791](https://doi.org/10.1109/5.726791)
- [22] ZHANG Y, SUNG W J, MAVRIS D N. Application of convolutional neural network to predict airfoil lift coefficient[C]//2018 AIAA/ASCE/AHS/ASC Structures, Structural Dynamics, and Materials Conference, Kissimmee, Florida. AIAA, 2018.
doi: [10.2514/6.2018-1903](https://doi.org/10.2514/6.2018-1903)
- [23] TOLSTIKHIN L, HOULSBY N, KOLESNIKOV A, et al. Mlp-mixer: An all-mlp architecture for vision[C]//35th International Conference on Neural Information Processing Systems, 2021.
- [24] GUO M H, LIU Z N, MU T J, et al. Beyond self-attention: External attention using two linear layers for visual tasks[J]. *IEEE Trans Pattern Anal Mach Intell*, 2023, 45(5): 5436–5447.
doi: [10.1109/tpami.2022.3211006](https://doi.org/10.1109/tpami.2022.3211006)
- [25] CHEN H, HE L, QIAN W Q, et al. Multiple aerodynamic coefficient prediction of airfoils using a convolutional neural network[J]. *Symmetry*, 2020, 12(4): 544.
doi: [10.3390/sym12040544](https://doi.org/10.3390/sym12040544)
- [26] ÖZBAY A G, LAIZET S. Deep learning fluid flow reconstruction around arbitrary two-dimensional objects from sparse sensors using conformal mappings[J]. 2022, 12(4): 045126.
doi: [10.1063/5.0087488](https://doi.org/10.1063/5.0087488)
- [27] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation[M]//Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. Cham: Springer International Publishing, 2015: 234–241.
doi: [10.1007/978-3-319-24574-4_28](https://doi.org/10.1007/978-3-319-24574-4_28)
- [28] ERICHSON N B, MATHELIN L, YAO Z W, et al. Shallow neural networks for fluid flow reconstruction with limited sensors[J]. *Proceedings Mathematical, Physical, and Engineering Sciences*, 2020, 476(2238): 20200097.
doi: [10.1098/rspa.2020.0097](https://doi.org/10.1098/rspa.2020.0097)
- [29] LIU B, TANG J P, HUANG H B, et al. Deep learning methods for super-resolution reconstruction of turbulent flows[J]. *Physics of Fluids*, 2020, 32(2): 025105.
doi: [10.1063/1.5140772](https://doi.org/10.1063/1.5140772)
- [30] LIU Q, WANG D L. Stein variational gradient descent: A general purpose bayesian inference algorithm[C]//30th Conference on Neural Information Processing Systems, Barcelona, Spain. 2016.

(本文责编: 张兴焕)