

采用混合粗糙数据物理信息神经网络的 扑翼气动性能预测方法

胡付佳¹, 周逸伦^{1,2}, 刘小民¹

(1. 西安交通大学能源与动力工程学院, 710049, 西安;

2. 西安陕鼓动力股份有限公司, 710075, 西安)

摘要: 为解决时空尺度上扑翼流动控制方程求解需要花费大量时间和计算资源的问题, 基于强非线性曲线拟合能力的物理信息神经网络(PINN)深度学习的方法, 提出了一种混合粗糙数据驱动物理信息神经网络模型(HCDD-PINN), 研究了模型对涉及非定常流动特征和动边界二维俯仰扑翼问题的训练和预测性能。通过使用相较于传统计算流体动力学方法(CFD)更为粗糙的数据驱动模型训练, 将扑翼流动控制方程嵌入神经网络损失中, 并施加初始条件和边界条件约束, 采用一阶自适应矩优化算法(ADAM)和二阶拟牛顿法优化算法(L-BFGS-B), 以前馈-反向传播方式最小化模型损失函数, 从而提高模型预测控制方程数值解的准确性和可靠性。结果表明: 与原始 PINN 模型相比, HCDD-PINN 模型显著降低了流场的预测误差, 能够准确地预测扑翼瞬时气动力和瞬时速度及压力场, 训练时间缩短了 75%。此外, 训练完成的 HCDD-PINN 模型可以快速获得流场任意时刻的物理信息, 而传统 CFD 方法则需要重新对流场进行计算。该研究为求解扑翼流动控制方程乃至流体非线性偏微分方程组(PDEs)提供了一种有效的替代方案。

关键词: 物理信息神经网络; 数据驱动; 深度学习; 扑翼; 气动性能

中图分类号: TP18; V211 **文献标志码:** A

DOI: 10.7652/xjtub202311019 **文章编号:** 0253-987X(2023)11-0194-12

A Predicting Method on Aerodynamic Performance of Flapping Wing Using Hybrid Coarse Data Driven Physical Informed Neural Network

HU Fujia¹, ZHOU Yilun^{1,2}, LIU Xiaomin¹

(1. School of Energy and Power Engineering, Xi'an Jiaotong University, Xi'an 710049, China;

2. Xi'an Shaangu Power Co., Ltd., Xi'an 710075, China)

Abstract: The solution of the governing equations of the flapping wing problem on a spatiotemporal scale takes a great amount of time and computational resources. To solve this challenge, this paper proposes a hybrid coarse data-driven with physics-informed neural network model (HCDD-PINN). The model leverages its strong nonlinear curve fitting ability to investigate the training and predicting performance of the model for two-dimensional pitching flapping wing problems, which involves unsteady flow characteristics and motion boundaries. The model is trained using an order-of-magnitude grid, coarser than the traditional computational fluid dynamic (CFD) required. The architecture is devised to enforce the initial and boundary conditions and incorporate

the governing equations into the loss of the neural network. The optimization process is conducted by ADAM and L-BFGS-B methods with a feed forward-back propagation manner, to improve the accuracy and reliability of predicting the time evolution of nonlinear PDEs solutions. The results show that the proposed HCDD-PINN framework exhibits improved stability and accuracy compared to the PINN models that lack internal data. It effectively reduces the prediction error of the flow field, and accurately predicts the instantaneous aerodynamic forces, velocity and pressure fields of flapping wings. Moreover, the training time has accelerated by approximately four times. Additionally, the interested variables of the flow field at any instant can be rapidly obtained by the trained HCDD-PINN model, which is superior to the traditional CFD method that usually needs to be re-run. This study provides an effective alternative for solving flapping wing governing equations and even nonlinear partial differential equations (PDEs).

Keywords: physics-informed neural network; data-driven; deep learning; flapping wing; aerodynamic performance

深度学习(DL)在图像处理、语音识别和疾病诊断等许多领域有巨大突破^[1-3]。近年来,由于DL在处理强非线性和高维度方面的出色能力,其在求解流体动力学问题中被广泛尝试应用,以期能在未来不影响求解精度的情况下取代或加速数值计算。

Raissi等^[4-5]首次提出了一种基于物理信息的神经网络模型(PINN),将偏微分方程(PDEs)嵌入神经网络以求解正反问题^[6]。PINN是通过用PDEs,包括质量和动量守恒定律,来修正神经网络的损失函数。这是深度学习方法的一个重要突破,PINN的输出预测变量符合相应的物理学定律。纯数据驱动神经网络模型的损失函数是由网络输出与训练数据的差值定义,而PINN可以在使用小数据集或没有数据集的情况下进行有效训练,且任意大小和形状的计算域流场信息经过训练均可以满足相应的控制方程,解决寻找向真值收敛的未知参数的反问题。Rao等^[7]提出了一种混合变量的PINN方法,用于模拟低雷诺数下定常和非定常圆柱绕流问题,提高了PINN的可训练性和求解精度。Choi等^[8]针对一个类似化学反应器的多参考系系统,使用小批量训练和加权损失函数,解决了PINN模型的记忆误差和发散问题。田十方等^[9]提出了一种梯度优化PINN模型提高了损失函数梯度波动的鲁棒性和求解精度。Cheng等^[10]发展了一种基于Resnet块的PINN模型,对流体动力学问题具有更强的预测能力。

PINN在复杂的流体动力学问题上也表现出优异的能力,如涡激振动(VIV)问题^[11]、变截面管道流动问题^[12]、湍流燃烧化学问题^[13]和基于Helmholtz方程的声学问题^[14]。在这些研究中,通过发展深度神经网络深度学习方法,很好地预测了多物

理场耦合问题。因此,如何将PINN方法推广到其他类型复杂流体动力学问题的研究中,如扑翼的气动特性的数值预测,是本文研究工作的主要目标。仿生扑翼微型飞行器(FMAVs)在军事和民用中有巨大的应用潜力^[15],仿昆虫扑翼飞行气动力学的实验^[16]和数值^[17]研究也受到了广泛关注。准确的气动力测量和详细地流场信息捕获对于揭示扑翼潜在的飞行机理具有重要意义^[18]。

自动微分法和反向传播算法是PINN模型采用的主要训练方法,适用于处理复杂边界和任意计算域内的物理量空间时间项导数和求解神经网络参数梯度,如权重和偏差。理想情况下,当初始条件和边界条件设置正确时,PINN模型可以在没有任何训练数据的情况下捕获唯一解^[19]。然而,PINN模型在实现稳定训练和准确预测方面仍然面临着巨大挑战,特别是当需求解的偏微分方程中包含高频或多尺度特征时,PINN模型的预测精度难以满足真实值的要求^[20-21]。对于更为复杂的非线性非定常问题,现有PINN模型的缺点是比较明显的,预测误差随着时间序列的推移而增大。为此,Raissi等^[22]发展了隐藏流体力学(HFM)方法,通过提取少量部分流场信息对相应生物医学问题的物理流场进行定量预测。Kochkov等^[23]引入了一种端到端深度学习方法,通过使用比传统要求的数量级更粗糙的网格来加速和改进二维湍流的近似预测。

为了有效解决PINN模型对复杂瞬态流场预测精度低的问题,本文提出了一种混合粗糙数据驱动的PINN模型(HCDD-PINN),旨在利用从实验和数值研究获得的稀疏数据信息,改进PINN模型对涉及大物体运动和非定常特征的扑翼扰流问题的预测

精确度。施加物理控制方程和边界条件等“硬”约束以及粗糙内部数据“软”约束,最小化神经网络损失函数,得到训练完成的 HCDD-PINN 模型,对扑翼气动力、速度场和压力场等物理量进行预测。

1 扑翼问题物理学描述


1.1 扑翼运动学

昆虫的翅膀围绕着一个平面扑动,定义为扑动平面^[24],指翼根到翼尖从最大位置角扫掠到最小位置角形成的平面。扑动平面与水平面的夹角 β 随生物飞行速度和扑翼运动学不同而变化。假设翅膀是刚性的,其运动学可以用相对于扑动平面的 3 个欧拉角来描述:①绕沉浮轴的沉浮运动,由位置角 φ 描述;②绕俯仰轴的俯仰运动,由攻角 α 描述;③绕偏航轴的偏航运动,由偏航角 θ 描述。图 1(a)所示为果蝇翅膀运动学参数示意图。


为验证本文提出的模型 HCDD-PINN 对涉及大物体运动和非定常特征流动问题的预测精确性,针对昆虫扑翼飞行尺度,扑翼模型选择俯仰运动的 NACA0012 对称翼型,俯仰运动(绕扑翼中心旋转)由下式给出

$$\alpha(t) = \alpha_m \sin(2\pi ft) \quad (1)$$

式中: α_m 为俯仰运动幅值, f 为频率,本文 α_m 和 f 分别选取 $\pi/4$ 和 0.25 Hz。对应基于来流速度和扑翼弦长的雷诺数 Re 为 100,与果蝇扑翼飞行雷诺数相同^[17]。图 1(b)给出了本文研究的扑翼运动学示意图。



(a) 果蝇扑翼运动学



(b) 俯仰运动

图 1 扑翼运动学示意图

Fig. 1 Schematic diagram of flapping wing kinematics

1.2 控制方程和 CFD 计算方法

本文以基于有限体积法的计算流体力学软件 Fluent 20.0 为平台,对扑翼流动进行数值求解,扑翼的运动由 Fluent 用户自定义函数 UDF 给出,并结合动网格技术来实现。由于本文的研究对象是基于低雷诺数条件下的昆虫扑翼飞行,流场流速很低(马赫数 Ma 约为 0.02),且每次扑动都在翼面产生新的剪切层,因此流动可以假设为层流、不可压缩流动,扑翼流场的控制方程简化为二维非定常不可压缩 Navier-Stokes 方程

$$\nabla \cdot \mathbf{u} = 0 \quad (2)$$

$$\frac{\partial \mathbf{u}}{\partial t} + \mathbf{u} \cdot \nabla \mathbf{u} = -\frac{1}{\rho} \nabla p + \frac{\mu}{\rho} \nabla^2 \mathbf{u} \quad (3)$$

式中: $\mathbf{u}$ 、 ρ 、 p 和 μ 分别是速度矢量、流体密度、压力和流体动力黏性。

在数值求解中,采用 SIMPLEC 算法进行压力-速度耦合,采用分步算法进行时间推进。对流项、扩散项和时间项的离散格式分别选用二阶迎风格式、中心差分格式和后向隐格式。




图 2 计算域和边界条件设置

Fig. 2 Computational domain and boundary condition settings

如图 2 所示,计算域为 $[-5c, 10c] \times [-5c, 5c]$,扑翼前缘置于 $(0, 0)$ 处,初始攻角为 0。 c 是扑翼弦长。在进口、顶部和底部施加速度边界条件 $u = 1 \text{ m/s}$ 、 $v = 0$ 。出口施加 Neumann 压力边界条件 $dp/dx = 0$,在扑翼上施加无滑移壁面边界条件。计算域分为非结构化网格的外部“变形”域和结构化网格的内部“运动”域。内域随扑翼执行相同的俯仰运动,网格保持不变,保证扑翼边界层网格质量;外域网格采用 Re-mesh 法保证网格质量。靠近内域的网格由于扑翼俯仰运动产生较大的畸变率,当网格畸变率超过阈值,质量差的网格会被删除,然后再生成新的质量好的网格。本研究采用的 CFD 计算方法已经在先前的研究中被验证具有较高的流场特征捕获精度^[17-18]。

2 神经网络框架搭建

2.1 PINN 框架

流场速度和压力分布是流场特征的决定性因

素,也是研究者最感兴趣的需要求解的物理量。在二维非定常 PINN 框架中,深度神经网络(DNN),也叫多层感知机(MLP),被用来预测偏微分方程的解 $\varphi^*(\mathbf{x})$,也就是相应感兴趣的物理场变量,这里上标 * 表示网络的预测值。DNN 由 N_l 个完全连接的层组成,其中输入层 $\mathbf{x} = (x, y, t)$ 包含计算域 D 内的空间坐标和时间变量,输出层 $\mathbf{y} = \varphi(\mathbf{x}) = (u, v, p)$ 包含速度和压力变量,中间隐藏层用来连接输入和输出之间复杂的非线性关系,建立一种从输入层到输出层映射关系 $\mathcal{F}$

$$\mathbf{y} = \mathcal{F}(\mathbf{x}) = \mathcal{l}(\mathbf{x}, \boldsymbol{\theta}) \quad (4)$$

式中: $\mathcal{l}(\cdot, \boldsymbol{\theta}) \in \mathbb{R}^{N_a} \rightarrow \mathbb{R}^{N_b}$ 表示变量为 $\boldsymbol{\theta}(\mathbf{W}, \mathbf{b})$ 的非线性组成函数, $\mathbf{W}$ 和 $\mathbf{b}$ 分别表示隐藏神经元的权重和偏置值。通过 DNN 结构传播每个选定点的空间坐标和时间变量,计算 PINN 的物理输出生成预测。传播过程为前馈传播,如下所示

$$\mathcal{l}(\mathbf{x}, \boldsymbol{\theta}) =$$

$$\epsilon_{N_l}(\cdot; \boldsymbol{\theta}_{N_l}) \circ \epsilon_{N_{l-1}}(\cdot; \boldsymbol{\theta}_{N_{l-1}}) \cdots \epsilon_{N_1}(\mathbf{x}; \boldsymbol{\theta}_{N_1}) \quad (5)$$

式中: 符号 $\circ$ 是合成运算符; $\epsilon_i(\cdot) \in \mathbb{R} \rightarrow \mathbb{R}$ 。

第 i 层的输出矢量 $\mathbf{h}_i$ 是由前一层输出乘以层权重 $\mathbf{W}_i$ 加上偏置 b_i , 并将所得矩阵传递给层激活函数 $\epsilon_i(\cdot)$ 中, 由下式给出

$$\mathbf{h}_i(\boldsymbol{\xi}; \boldsymbol{\theta}_{N_i}) = \epsilon_i(\boldsymbol{\theta}_i [\boldsymbol{\xi}^T, 1]^T) = \epsilon_i(\sum W_{ij} \xi_j + b_i) \quad (6)$$

式中: $\mathbf{h}_i(\cdot; \boldsymbol{\theta}_i) \in \mathbb{R}^{l_{i-1}} \rightarrow \mathbb{R}^{l_i}$, l_i 表示第 i 层输出的大小; $\boldsymbol{\theta}_i \in \mathbb{R}^{l_{i-1} \times l_i + 1}$ 是第 i 层的权重和偏置矩阵矢量。 $\boldsymbol{\theta} = (\boldsymbol{\theta}_1, \dots, \boldsymbol{\theta}_i, \dots, \boldsymbol{\theta}_{N_l})$ 是 DNN 的权重和偏置矩阵矢量。采用 Xavier 方法对 $\boldsymbol{\theta}$ 进行初始化来加速 DNN 的收敛, 并在神经网络训练过程中对 $\boldsymbol{\theta}$ 不断进行评估修正。隐藏层使用双曲正切激活函数, 输出层使用线性激活函数。

基于物理信息的神经网络 PINN 用式(2)和(3)表示的偏微分方程组修改传统损失函数, 从而实现流体运动的预测。采用 DNN 近似相应的流动, 通常具有以下结构

$$\Pi\{\varphi(\mathbf{x})\} = 0, \mathbf{x} \in D \quad (7)$$

$$\varphi(\mathbf{x}) = \varphi_{bc}(\mathbf{x}), \mathbf{x} \in \partial D \quad (8)$$

式中: $\Pi\{\cdot\}$ 是非线性微分算子, 表示对流项、扩散项和源项等 PDEs 量; $\varphi_{bc}(\cdot)$ 是边界条件函数; D 和 ∂D 分别表示计算域及其边界。

采用自动微分法(AD), 计算以上构建的 PINN 框架中 DNN 输出关于时间和空间的偏导数的项, 以便直接在 Tensorflow 中搭建深度学习框架^[25]。为了

降低式(3)中导数的阶数, 这里引入柯西应力张量 $\boldsymbol{\sigma}$

$$\boldsymbol{\sigma} = -p\mathbf{I} + \boldsymbol{\tau} = -p\mathbf{I} + \boldsymbol{\mu}(\nabla \mathbf{u} + \nabla \mathbf{u}^T) \quad (9)$$

则式(3)可表示为如下

$$\frac{\partial \mathbf{u}}{\partial t} + \mathbf{u} \cdot \nabla \mathbf{u} = \frac{1}{\rho} \nabla \cdot \boldsymbol{\sigma} \quad (10)$$

将柯西应力张量 $\boldsymbol{\sigma}$ 添加到 DNN 的输出变量中, 不仅降低了导数的阶数, 而且提高了 DNN 的可训练性^[7]。针对扑翼绕流问题, 选取翼型弦长 c 为特征长度、扑动周期 T 为特征时间、来流速度 u_0 为特征速度。基于这 3 个特征参数和流体密度 ρ , 分别对 DNN 的输入变量 x, y, t 和输出变量 $u, v, p, \boldsymbol{\sigma}$ 进行无量纲化处理。通过对 PDEs 进行归一化处理, 可以避免由数据量级不同引起的神经网络训练时间延长以及梯度消失和梯度爆炸造成的预测结果不准确, 降低模型噪声敏感性。

PINN 的关键特征是将物理规律嵌入损失函数中, 不断迭代最小化损失, 从而神经网络输出可以准确接近期望的偏微分方程和相关边界条件。损失函数 ϵ_{loss} 的表达形式为

$$\epsilon_{\text{loss}} = \sum_k^K \epsilon_g^k + \sum_k^K \sum_j^J \epsilon_{bc, j}^k \quad (11)$$

式中: K 是计算域 D 中需 PDEs 求解的点数量; J 是位于边界 ∂D 的点数量; ϵ_g^k 是第 k 个点处控制偏微分方程的残差, $\epsilon_{bc, j}^k$ 是第 j 个边界条件上第 k 个点处的边界条件损失, 分别由下式给出

$$\epsilon_g^k = \frac{1}{N_g} \sum_{i=1}^{N_g} (\Pi\{\varphi_k^*(\mathbf{x}_i)\})^2 \quad (12)$$

$$\epsilon_{bc, j}^k = \frac{1}{N_{bc, j}} \sum_{i=1}^{N_{bc, j}} (\varphi_k^*(\mathbf{x}_i) - \varphi_{bc, j}^k(\mathbf{x}_i))^2 \quad (13)$$

式中: N_g 表示计算域内配置点的数量; $N_{bc, j}$ 表示边界 j 上配置点数量。

以上是基于物理信息神经网络的框架描述, 该模型可以基于物理定律来预测流场变量。相比于传统纯数据驱动的深度学习方法, PINN 不再是一个黑箱, 使用小数据集或无数据集就可以对物理流场进行有效训练, 满足相应的控制方程, 适用于任何形状、大小的计算域, 并能求解未知参数的逆问题, 在复杂流体动力学问题中表现出优越的能力。理想情况下, 当施加恰当的初始条件和边界条件, PINN 可以在没有任何数据集的情况下得到相应偏微分方程的唯一解。

2.2 HCDD-PINN 框架

PINN 方法被期望扩展到更为复杂的扑翼流动动力学问题, 但由于扑翼运动具有大变形、大位移特点, 相应流动也具有强非线性和非定常性, 目前

PINN 并没有很好地解决这个问题。PINN 在训练稳定性和预测准确性方面仍面临巨大挑战,尤其是当偏微分方程解包含高频或多尺度特征时^[20-21],不仅难以收敛,而且即使残差降低到相对较低范围时,PINN 的预测也可能难以满足物理规律。对于非定常流动特性,误差会随着时间的推移而逐渐变大^[11]。基于此,本文提出了一种混合粗数据驱动基于物理信息的神经网络模型 HCDD-PINN,利用从实验和数值模拟中获得的少量且不太准确的数据,来提高 PINN 模型解决涉及物体大运动和非定常特征流动问题的能力。换句话说,可以利用 PINN 方法对这些粗糙数据集修正,以获得完整的流场信息。这些粗糙的内部数据随机分布在时空位置,容易应用到 DNN 框架中。

合适的流场初始化方法不仅可以加速收敛,而且能提高预测准确性。引入初始时刻数据集作为模型初始条件,则相应的损失函数增加了一项初始条件损失 ϵ_1 。同时,选取比参考 CFD 结果网格粗糙 10 倍的数值结果作为模型内部数据训练集,则相应的

损失函数增加了一项内部损失 ϵ_{int} 。第 k 个点处的 ϵ_1 、 ϵ_{int} 表达式如下

$$\epsilon_1^k = \frac{1}{N_1} \sum_{i=1}^{N_1} (\varphi_k^*(x_i) - \varphi_{t=0}^k(x_i))^2 \quad (14)$$

$$\epsilon_{\text{int}}^k = \frac{1}{N_{\text{int}}} \sum_{i=1}^{N_{\text{int}}} (\varphi_k^*(x_i) - \varphi_{\text{int}}^k(x_i))^2 \quad (15)$$

式中: N_1 表示用于初始化的点数量; N_{int} 表示用于训练的内部粗糙数据点集。则损失函数可以表示为

$$\epsilon_{\text{loss}} = \sum_k \epsilon_g^k + \lambda_{\text{int}} \sum_k \epsilon_{\text{int}}^k + \lambda_{\text{bc}/1} \left(\sum_k \sum_j \epsilon_{\text{bc},j}^k + \sum_k \epsilon_1^k \right) \quad (16)$$

式中: $\lambda_{\text{bc}/1}$ 表示初始条件和边界条件损失权重系数; λ_{int} 表示内部损失权重系数。权重系数用来平衡总损失各项占比,使优化器合理均匀分配优化各项损失的资源,加速神经网络训练过程,提高收敛性。图 3 给出了 HCDD-PINN 模型的结构框架示意图,图中神经网络包括两个隐藏层,每个隐藏层包含 5 个神经元。




图 3 HCDD-PINN 模型的结构框架

Fig. 3 Structural framework of HCDD-PINN model

2.3 数据准备和求解设置

基于 1.2 小节中介绍的数值计算方法,获得足够精度的俯仰扑翼扰流问题 CFD 计算结果作为参照算例,验证 HCDD-PINN 模型对扑翼气动性能预测能力。由网格粗糙 10 倍的 CFD 计算得到粗糙训练数据。HCDD-PINN 计算域和边界条件设置和 CFD 相同,如图 2 所示。

在 HCDD-PINN 训练中,不采用传统 CFD 计算中贴体网格,输入层采用拉丁超立方抽样法 LHS 随机获取整个时空域的配置点 N_{LHS} ,并在扑翼附近一个矩形区域 ($5.5c \times 3c$) 进行加密,以更好地捕获流场细节。为了精确描述扑翼的形状和运动,扑翼周围的瞬态配置点 N_{Lins} 为由 linspace 法生成的一个矩形域配置点,且在整个扑动周期内仅在时间步长

N_t 对应的空间域均匀间隔采样。图 4 给出了 HCDD-PINN 模型在整个时空域 (x, y, t) 的配置点分布。因此,HCDD-PINN 模型的全部配置点 N_{collo} 可以表达为

$$N_{\text{collo}} = N_{\text{LHS}} + N_t N_{\text{Lins}}$$

(17)




图 4 HCDD-PINN 配置点分布

Fig. 4 Collocation points distribution of HCDD-PINN model

固体扑翼的存在是通过一些特殊的配置点实现的:①扑翼内部是固体域,不存在流场信息,位于扑翼内的固体配置点均被过滤出整个流体时空计算域;②扑翼边界处的配置点应具有指定的速度矢量 (v_x^i, v_y^i) ,以满足扑翼俯仰运动的动边界规律。扑翼俯仰运动的速度矢量由下式给出

$$v_x^i = 2\pi f \alpha_m \cos(2\pi f t) r^i n_x^i$$

(18)

$$v_y^i = 2\pi f \alpha_m \cos(2\pi f t) r^i n_y^i$$

(19)

式中: r^i 是扑翼边界上第 i 个配置点距离扑翼旋转中心的距离。

2.4 求解流程

深度神经网络结构对于拟合未知的映射函数 $y = f(x)$ 是比较困难的,但如果将问题转化为学习损失函数: $h(x) = f(x) - y$,当 $h(x) = 0$,可满足映射 $y = f(x)$ 。这种处理方式降低了问题的复杂性,使得问题从训练映射关系变为优化损失。因此,扑翼流场预测问题从拟合映射函数 $y(u, v, p, \sigma) = \mathcal{L}(x(x, y, t))$ 转化为优化损失函数 ϵ_{loss} 。

对于当前问题,在 Tensorflow 框架中通过 Python 语言编程实现模型搭建和求解。采用自适应矩估计 ADAM 算法和 L-BFGS-B 算法来调整模型参数,以最小化损失函数。ADAM 是一种基于动量和自适应学习率的优化算法,可以在较短时间内实现高效收敛。L-BFGS-B 算法是一种基于拟牛顿法的优化算法,通过构建模型 Hessian 矩阵的逆矩阵来更新网络权重参数,收敛快速,但计算复杂度较高。图 5 为 HCDD-PINN 模型训练优化流程图。




图 5 HCDD-PINN 模型前馈-反向传播流程图

Fig. 5 Flow-process diagram for forward-back-feed propagation of HCDD-PINN model

开展 HCDD-PINN 模型训练优化,首先建立物理模型,针对所研究的物理问题,给出相应的流动控制方程以及边界条件,并根据模型的特点生成相应的训练集数据,对数据进行归一化处理。然后,设计合适的深度神经网络 DNN,包括网络结构、激活函数、学习率以及迭代步数等,并根据物理模型构建相应的损失函数。接着使用训练集数据对 DNN 进行训练,建立输入层和输出层的映射关系,通过反向传播中 ADAM 和 L-BFGS-B 优化算法更新神经网络的权重参数矩阵,直到训练达到设定的迭代步数或模型损失函数降到一定阈值,结束训练。最后,保存模型流场预测结果和损失函数,优化收敛信息。

3 结果与分析

3.1 训练和预测性能

从 CFD 计算结果可以看到,扑翼产生的气动力在 3 个扑动周期内已经达到周期性状态。因此,选择第四周期的 CFD 结果对 HCDD-PINN 模型进行训练、预测和比较。

根据经验选择合适的模型超参数,如损失加权系数($\lambda_{bc/1} = 5$, $\lambda_{int} = 3$)、神经网络结构(8 个隐藏层,每层 50 个神经元)、配置点($N_{collo} = 1.74 \times 10^5$, 其中 $N_{LHS} = 9.5 \times 10^4$, $N_{Lins} = 790$, $N_t = 100$)以及 ADAM 优化器的学习率(5×10^{-4})和最大迭代步(5×10^3)。选取第四扑动周期开始时参照的 CFD 流场数据($t/T = 3$),对 HCDD-PINN 模型进行初始化。

在 CFD 数值计算中,流场 3 个标量(速度 u 、 v 和压力 p)的计算结果被保存成 100 个流场快照。采用 TTS(Train Test Split)方法将相应的粗糙计算结果随机地分为训练集和测试集。其中训练集占总数据点的百分比将决定每个快照用于训练的数据点数量,而一个周期内用于训练模型的快照数将决定用于训练的粗糙数据点总数量。本文选择 41 个流场快照(包含初始时刻 $t/T=0$),且每个快照训练集数据占粗糙数据的百分比为 0.05。

针对俯仰扑翼流动问题,表 1 对比了原始 PINN 模型和本研究提出的 HCDD-PINN 模型训练和预测性能。其中,训练总损失由式(16)定义,模型预测流场物理量 u 、 v 、 p 的预测误差分别由时均相对 L_2 误差 $\bar{\sigma}_u$ 、 $\bar{\sigma}_v$ 、 $\bar{\sigma}_p$ 来表示,用以表征模型的预测性能。流场物理量 u 、 v 、 p 的相对 L_2 误差定义如下

$$\sigma_u = \frac{\sqrt{\sum_{i=1}^{N_{collo}} (u_{pred}^i - u_{ref}^i)^2}}{\sqrt{\sum_{i=1}^{N_{collo}} (u_{ref}^i)^2}} \quad (20)$$

$$\sigma_v = \frac{\sqrt{\sum_{i=1}^{N_{collo}} (v_{pred}^i - v_{ref}^i)^2}}{\sqrt{\sum_{i=1}^{N_{collo}} (v_{ref}^i)^2}} \quad (21)$$

$$\sigma_p = \frac{\sqrt{\sum_{i=1}^{N_{collo}} (p_{pred}^i - p_{ref}^i)^2}}{\sqrt{\sum_{i=1}^{N_{collo}} (p_{ref}^i)^2}} \quad (22)$$

式中： u_{pred}^i 、 v_{pred}^i 和 p_{pred}^i 分别是模型对第 i 个配置点的预测速度和预测压力； u_{ref}^i 、 v_{ref}^i 和 p_{ref}^i 分别是速度 u 、 v 和压力 p 的 CFD 参照结果在第 i 个配置点处的插值。

表 1 PINN 模型和 HCDD-PINN 模型训练和预测性能对比

Table 1 Comparison of variable efficiency and pressure ratio of various schemes at design point

参数	数值	
	PINN	HCDD-PINN
训练时间/s	52 485	13 427
总损失 ϵ_{loss}	2.14×10^{-4}	1.24×10^{-3}
预测误差 $\bar{\sigma}_u$	4.52×10^{-2}	2.94×10^{-3}
预测误差 $\bar{\sigma}_v$	2.65×10^{-1}	6.96×10^{-2}
预测误差 $\bar{\sigma}_p$	1.21	3.98×10^{-2}

从表 1 可以看出,原始 PINN 模型在基于俯仰运动的扑翼流场控制方程和相应边界条件的约束下,即使损失已经优化到 $O(10^{-4})$ 量级,但速度场和压力场的预测并不准确。同时,模型训练时间很长,L-BFGS-B 算法优化器是因为迭代步数达到上限而停止优化损失函数。本文提出的 HCDD-PINN 模型借助少量粗糙内部数据(每个快照近 10^3 个数据点),流场的预测误差均大大降低,且训练过程缩短了 75%。由于引入了内部损失 ϵ_{int} ,加权后的总损失增大,但 L-BFGS-B 算法优化器是因为达到收敛条件而停止优化。

图 6 给出了各项损失收敛历史的更多细节,包括总损失 ϵ_{loss} 、控制方程损失 ϵ_g 、边界条件损失 ϵ_{bc} 、初始条件损失 ϵ_1 、以及内部损失 ϵ_{int} 。可以看到,HCDD-PINN 模型需要近 60 000 迭代步数就完成了训练。初始条件和边界条件容易满足,相应损失容易优化,因此加权系数 $\lambda_{bc/1}$ 取较大值。模型在从 ADAM 优化器切换到 L-BFGS-B 优化器时,损失函数可以实现快速收敛。总损失中各项贡献度主要由相应配置点的数量决定,配置点数量越多,相应的损失项数值越大,占比越多。流域内整个时空配置点远大于相应边界处配置点。

对于完成训练的 HCDD-PINN 模型,任意时刻扑翼周围的瞬时速度场和压力场几乎可以立即实现预测,单从计算资源和成本方面来看,HCDD-PINN




图 6 损失函数随迭代步数的关系曲线图
Fig. 6 Curves for the relationship between different loss terms and iterations

模型在扑翼问题的优化研究中具有相当大的优势。特别是当计算扩展到更高维度时,如果仍采用传统的 CFD 求解器,通常需要高质量的网格来保证数值计算精度,计算成本将会大大增加。采用 HCDD-PINN 模型,在保证计算精度的同时又能较大幅度的节约计算资源。本文选择计算域中近 10^5 个空间散点,对不同时刻的扑翼流场进行预测,在整个扑动周期内共保存 51 个流场快照,包括初始时刻和最终时刻。图 7 对比了原始 PINN 模型和 HCDD-PINN 模型一个周期内预测速度 (u , v) 和预测压力 p 相对 L_2 误差的变化。可以看出,HCDD-PINN 在整个周期内对 u 、 v 和 p 的预测精度均显著提高,能够准确构建扑翼流场,并捕捉到相应的流动非定常特性。




图 7 流场物理量预测误差的周期分布
Fig. 7 Prediction errors of flow field physical quantities over one stroke cycle

3.2 瞬时气动力预测

扑翼的升力 F_L 、阻力 F_D 、压力 F_P 和黏性力 F_V 分别由下式计算得到

$$F_L = \sum_i^{N_w} (-p_x^i dx^i + \mu(2u_x^i dx^i + u_y^i dy^i + v_x^i dy^i)) \tag{23}$$

$$F_D = \sum_i^{N_w} (-p_y^i dy^i + \mu(2v_y^i dy^i + u_y^i dx^i + v_x^i dx^i)) \tag{24}$$

$$F_P = \sqrt{(\sum_i^{N_w} -p_x^i dx^i)^2 + (\sum_i^{N_w} -p_y^i dy^i)^2} \tag{25}$$

$$F_V = \left(\left(\sum_i^{N_w} \mu(2u_x^i dx^i + u_y^i dy^i + v_x^i dy^i) \right)^2 + \left(\sum_i^{N_w} \mu(2v_y^i dy^i + u_y^i dx^i + v_x^i dx^i) \right)^2 \right)^{1/2} \tag{26}$$

式中: N_w 是扑翼边界上用于计算气动力的控制点数量; p_x^i 和 p_y^i 分别是第 i 个控制点压力 p 关于 x 和 y 的偏导数; u_x^i 和 u_y^i 分别是第 i 个控制点 x 方向速度分量 u 关于 x 和 y 的偏导数; v_x^i 和 v_y^i 分别是第 i 个控制点 y 方向速度分量 v 关于 x 和 y 的偏导数。

相应的,气动力无量纲系数由下式给出

$$\begin{cases} C_L = \frac{2F_L}{\rho u_0^2 c}; C_D = \frac{2F_D}{\rho u_0^2 c} \\ C_P = \frac{2F_P}{\rho u_0^2 c}; C_V = \frac{2F_V}{\rho u_0^2 c} \end{cases} \tag{27}$$

式中: ρ 为流体密度; u_0 为进口速度; c 为扑翼弦长; C_L 是升力系数; C_D 是阻力系数; C_P 是压力系数; C_V 是黏性力系数。

图 8 给出了原始 PINN 模型和本文提出的 HCDD-PINN 模型对扑翼产生的 4 种气动力周期分布预测结果,并与 CFD 结果进行比较。从图中可以看出:原始 PINN 模型并不能准确预测扑翼表面产生的气动力大小和趋势;HCDD-PINN 模型不仅可以定量捕捉不同时刻扑翼气动力的大小,而且可以定性预测扑翼气动力周期内分布。从图 8 可以看出,采用 HCDD-PINN 模型得到阻力和压力的预测结果与相应 CFD 计算结果十分吻合,而黏性力和升力预测结果还存在较小误差。由于扑翼升力是压力和黏性力在垂直方向上的分量之和,因此扑翼气动力的预测误差主要来源于垂直来流方向的黏性力误差。要实现 HCDD-PINN 模型准确预测任意计算域内扑翼的瞬时气动力,关键在于准确构建扑翼附近物理流场。




图 8 PINN 和 HCDD-PINN 预测气动周期分布对比

Fig. 8 Comparison of predicting aerodynamic between PINN and HCDD-PINN over one stroke cycle




图 9 $t/T=0.25$ 时速度 (u, v) 场和压力 p 场云图

Fig. 9 Cloud pictures of velocity (u, v) and pressure p fields at $t/T=0.25$




图 10 $t/T=0.5$ 时速度 (u, v) 场和压力 p 场云图

Fig. 10 Cloud pictures of velocity (u, v) and pressure p fields at $t/T=0.5$

3.3 瞬时流场预测

为了研究 HCDD-PINN 模型对扑翼气动性能的预测能力,图 9~图 11 分别给出了 PINN 模型和 HCDD-PINN 模型在 t/T 为 0.25、0.5 和 0.75 时速度场和压力场的预测结果,并与 CFD 参照的计算结果进行对比。其中,HCDD-PINN 模型预测的速度 u, v 和压力 p 相对于 CFD 参照的误差在图中第 4 列给出,分别由绝对误差 $\Delta u, \Delta v$ 和 Δp 表示

$$\Delta u = \sum |u_{\text{HCDD-PINN}}^i - u_{\text{ref}}^i| \quad (28)$$

$$\Delta v = \sum |v_{\text{HCDD-PINN}}^i - v_{\text{ref}}^i| \quad (29)$$

$$\Delta p = \sum |p_{\text{HCDD-PINN}}^i - p_{\text{ref}}^i| \quad (30)$$

式中: $u_{\text{HCDD-PINN}}^i, v_{\text{HCDD-PINN}}^i$ 和 $p_{\text{HCDD-PINN}}^i$ 分别是 HCDD-PINN 模型对第 i 个配置点的预测速度和预测压力。图中,红色表示正绝对误差(预测值大于参照值),蓝色表示负绝对误差(预测值小于参照值)。




图 11 $t/T=0.75$ 时速度 (u, v) 场和压力 p 场云图

Fig. 11 Cloud pictures of velocity (u, v) and pressure p fields at $t/T=0.75$

从图 9~图 11 可以看出,原始 PINN 模型预测的速度场和压力场与 CFD 参照计算结果在不同时刻均存在明显差异,特别是扑翼前缘和尾缘临近区域,相应的流场结构不能被准确捕捉。相比于原始 PINN 模型的预测结果,本文提出的 HCDD-PINN 模型的预测流场严格遵循偏微分控制方程 PDEs 物理定律以及强制施加的“硬”边界条件,能精确捕捉扑翼附近和尾迹的流动区域,仅在远场处和尾迹流存在轻微的时序序列偏差。整个扑动周期内,扑翼涡结构特征产生、发展和脱落的演化过程、以及相应位置和强度大小均能准确的进行预测,且绝对误差控制在 2%~15% 以内。对于验证的算例,速度场预测误差比压力场预测误差更小。

4 结 论

本文基于物理信息的神经网络 PINN 原始模型,提出了一种混合粗糙数据驱动的 HCDD-PINN 模型。将描述俯仰扑翼流动的偏微分控制方程以及初始条件和边界条件,强制施加到神经网络的损失函数中,混合粗糙训练集数据驱动模型训练,通过 ADAM 和 L-BFGS-B 优化算法对损失目标函数进行优化。当损失函数降低到一定阈值时,训练完成的模型就能对扑翼周期内的流场时空演变过程进行准确预测,相应地瞬时气动力和时均气动特性也能够得到准确预测。得到的主要结论如下。

(1) 粗糙训练集数据是从相应实验和数值模拟中获得的少量且不太准确的数据,用来提高 PINN 模型解决涉及大物体运动和非定常特征流动问题的能力。亦或是,利用 HCDD-PINN 模型对这些粗糙

数据集进行修正以获得完整的流场信息,这是传统数值模拟算法难以处理的流动逆问题。这些粗糙的内部数据随机分布在时空位置,容易应用到深度神经网络 DNN 框架中。通过添加初始条件损失 ϵ_i 和内部损失 ϵ_{int} ,引入相应权重系数,可以加速收敛,提高预测准确性。

(2) 原始 PINN 模型即使训练很长时间将损失优化到 $O(10^{-4})$ 量级,仍不能准确预测扑翼的气动力特性和流场特征。HCDD-PINN 模型借助少量粗糙内部数据,就可以大大降低相应的预测误差,准确构建扑翼非定常流场,并评估扑翼气动性能,且模型训练时间缩短了 75%。

(3) 训练完成的 HCDD-PINN 模型可以对扑翼在任意时刻的瞬时流场进行快速预测,而传统 CFD 方法则需要重新计算才能获得未保存时刻的瞬时流场,从计算时间成本上来看,对于更高维的翼型优化、扑翼运动学优化以及气动力优化等问题的研究,采用 HCDD-PINN 模型的优势更明显,可以极大程度上节约计算资源。

参考文献:

[1] GOODFELLOW I, BENGIO Y, COURVILLE A. Deep learning [M]. Cambridge, MA, USA: The MIT Press, 2016.

[2] XIONG Huiy, ALIPANAHI B, LEE L J, et al. The human splicing code reveals new insights into the genetic determinants of disease [J]. Science, 2015, 347 (6218): 1254806.

[3] 周逸伦, 孙永瑞, 胡付佳, 等. 仿鸮翼离心压缩机叶轮的参数优化及性能研究 [J]. 西安交通大学学报,

- 2023, 57(7): 151-159.
- ZHOU Yilun, SUN Yongrui, HU Fujia, et al. Parameters optimization and performance investigation of centrifugal compressor with bionic impeller inspired by owl wing [J]. Journal of Xi'an Jiaotong University, 2023, 57(7): 151-159.
- [4] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Physics informed deep learning: part I data-driven solutions of nonlinear partial differential equations [EB/OL]. (2017-11-28) [2023-03-12]. <https://arxiv.org/abs/1711.10561>.
- [5] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Physics informed deep learning: part II data-driven discovery of nonlinear partial differential equations [J]. (2017-11-28) [2023-03-12]. <https://arxiv.org/abs/1711.10566>.
- [6] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations [J]. Journal of Computational Physics, 2019, 378: 686-707.
- [7] RAO Chengping, SUN Hao, LIU Yang. Physics-informed deep learning for incompressible laminar flows [J]. Theoretical and Applied Mechanics Letters, 2020, 10(3): 207-212.
- [8] CHOI S, JUNG I, KIM H, et al. Physics-informed deep learning for data-driven solutions of computational fluid dynamics [J]. Korean Journal of Chemical Engineering, 2022, 39(3): 515-528.
- [9] 田十方, 李彪. 梯度优化物理信息神经网络(GOPI-NNs):求解复杂非线性问题的深度学习方法 [J/OL]. 物理学报: 1-20[2023-03-12]. <http://kns.cnki.net/kcms/detail/11.1958.O4.20230201.2155.004.html>.
TIAN Shifang, LI Biao. Gradient-optimized physics-informed neural networks(GOPINNs): a deep learning method for solving complex nonlinear problems [J/OL]. Acta Physica Sinica: 1-20[2023-03-12]. <http://kns.cnki.net/kcms/detail/11.1958.O4.20230201.2155.004.html>.
- [10] CHENG Chen, ZHANG Guangtao. Deep learning method based on physics informed neural network with Resnet block for solving fluid flow problems [J]. Water, 2021, 13(4): 423.
- [11] RAISSI M, WANG Zhicheng, TRIANTAFYLLOU M S, et al. Deep learning of vortex-induced vibrations [J]. Journal of Fluid Mechanics, 2019, 861: 119-137.
- [12] 崔永赫, 张文耀, 闫慧龙, 等. “硬”边界低阶导数型物理信息神经网络: 一种流动求解器 [J]. 西安交通大学学报, 2022, 56(9): 123-133.
- CUI Yonghe, ZHANG Wenyao, YAN Huilong, et al. “Hard” boundary low-order derivative physics informed neural network: a fluid flow solver [J]. Journal of Xi'an Jiaotong University, 2022, 56(9): 123-133.
- [13] 王意存, 邢江宽, 罗坤, 等. 基于物理信息神经网络的燃烧化学微分方程求解 [J]. 浙江大学学报(工学版), 2022, 56(10): 2084-2092.
- WANG Yicun, XING Jiangkuan, LUO Kun, et al. Solving combustion chemical differential equations via physics-informed neural network [J]. Journal of Zhejiang University(Engineering Science), 2022, 56(10): 2084-2092.
- [14] 吴国正, 王发杰, 程隋福, 等. 基于物理信息神经网络的内部声场正反问题数值计算 [J]. 计算物理, 2022, 39(6): 687-698.
- WU Guozheng, WANG Fajie, CHENG Suifu, et al. Numerical simulation of forward and inverse problems of internal sound field based on physics-informed neural network [J]. Chinese Journal of Computational Physics, 2022, 39(6): 687-698.
- [15] WOOTTON R. From insects to microvehicles [J]. Nature, 2000, 403(6766): 144-145.
- [16] SRYGLEY R B, THOMAS A L R. Unconventional lift-generating mechanisms in free-flying butterflies [J]. Nature, 2002, 420(6916): 660-664.
- [17] HU Fujia, LIU Xiaomin. Effects of stroke deviation on hovering aerodynamic performance of flapping wings [J]. Physics of Fluids, 2019, 31(11): 111901.
- [18] HU Fujia, WANG Yuanying, LI Dian, et al. Effects of asymmetric stroke deviation on the aerodynamic performance of flapping wing [J]. Proceedings of the Institution of Mechanical Engineers: Part G Journal of Aerospace Engineering, 2023, 237(2): 480-499.
- [19] SUN Luning, GAO Han, PAN Shaowu, et al. Surrogate modeling for fluid flows based on physics-constrained deep learning without simulation data [J]. Computer Methods in Applied Mechanics and Engineering, 2020, 361: 112732.
- [20] FUKS O, TCHELEPI H A. Limitations of physics informed machine learning for nonlinear two-phase transport in porous media [J]. Journal of Machine Learning for Modeling and Computing, 2020, 1(1): 19-37.
- [21] RAISSI M. Deep hidden physics models: deep learning of nonlinear partial differential equations [J]. Journal of Machine Learning Research, 2018, 19(1): 932-955.
- [22] RAISSI M, YAZDANI A, KARNIADAKIS G E.

Hidden fluid mechanics: learning velocity and pressure fields from flow visualizations [J]. Science, 2020, 367(6481): 1026-1030.

[23] KOCHKOV D, SMITH J A, ALIEVA A, et al. Machine learning-accelerated computational fluid dynamics [J]. Proceedings of the National Academy of Sciences of the United States of America, 2021, 118(21): e2101784118.

[24] BAYDIN A G, PEARLMUTTER B A, RADUL A A, et al. Automatic differentiation in machine learning: a survey [J]. Journal of Machine Learning Research, 2017, 18(1): 5595-5637.

[25] ELLINGTON C P, VAN DEN BERG C, WILLMOTT A P, et al. Leading-edge vortices in insect flight [J]. Nature, 1996, 384(6610): 626-630.

(编辑 杜秀杰)

(上接第 180 页)

宽带特性研究 [J]. 微波学报, 2000, 16(4):329-335.

YUE Xin, KANG Xingjian, FEI Yuanchun. Study on the broadband characteristics of sphere and cone loaded single-pole antenna [J]. Journal of Microwaves, 2000, 16(4): 329-335.

[23] 任杰, 翁明, 雷乐, 等. 用八孔耦合器识别 TM_{01}/TE_{11} 混模中 TE_{11} 模式的方法 [J]. 强激光与粒子束, 2022, 34(9): 5-12.

REN Jie, WENG Ming, LEI Le, et al. Method for identifying TE_{11} mode in TM_{01}/TE_{11} mixed mode system with eight-hole coupler [J]. High Power Laser and Particle Beams, 2022, 34(9): 5-12.

[24] CHITTORA A. Design of a compact TM_{01} - TE_{11} mode converter with tuning screws [J]. International Journal of RF and Microwave Computer-Aided Engineering, 2020, 30(9): e22317.

[25] 郁佳婧. 平面天线近场测量系统的研究 [D]. 南京: 南京信息工程大学, 2020.

[26] 林昌禄. 天线测量 [M]. 北京: 国防工业出版社, 1981: 1-3.

(编辑 亢列梅)