

基于深度学习的翼型气动弹片流场参数预测

张强, 李春, 缪维跑, 岳敏楠

(上海理工大学能源与动力工程学院, 上海 200093)

摘要: 弹片是解决翼型流动分离的重要技术手段,合理的弹片参数对翼型表面压力分布尤为重要。基于数据驱动的深度学习方法与计算流体力学(Computational Fluid Dynamics, CFD)相结合,可快速有效地完成对复杂流场特征的识别与提取。本文提出一种基于卷积神经网络(Convolutional Neural Network, CNN)的翼型表面压力分布预测方法,通过提取流场的尾流速度、压力等流动特征构建翼型表面压力分布的预测模型。首先,通过数值模拟计算了8种不同抬起角度的NACA 0012弹片翼型的流场;其次,采用提取的流场数据建立CNN预测模型;最后,将预测值和CFD计算值进行对比。结果表明:基于CNN的预测模型对翼型表面压力系数分布有较高的预测精度,其中尾流速度模型在弹片抬起角度为 15° 时的预测均方根误差仅为0.1,说明尾流速度中包含丰富的流场信息。

关键词: 深度学习;卷积神经网络;弹片翼型;流场识别;非定常

中图分类号:TK83 文献标识码:A DOI:10.16146/j.cnki.rndlgc.2024.02.020

[引用本文格式]张强,李春,缪维跑,等.基于深度学习的翼型气动弹片流场参数预测[J].热能动力工程,2024,39(2):162-168. ZHANG Qiang, LI Chun, MIAO Wei-pao, et al. Prediction of flow field parameters for aerodynamic flap of airfoil based on deep learning [J]. Journal of Engineering for Thermal Energy and Power, 2024, 39(2): 162-168.

Prediction of Flow Field Parameters for Aerodynamic Flap of Airfoil based on Deep Learning

ZHANG Qiang, LI Chun, MIAO Wei-pao, YUE Min-nan

(School of Energy and Power Engineering, University of Shanghai for Science and Technology, Shanghai, China, Post Code: 200093)

Abstract: Flap is an important technical tool to solve the flow separation of airfoil, and reasonable flap parameters are especially important for the pressure distribution on the airfoil surface. The combination of data-driven deep learning method and computational fluid dynamics (CFD) can quickly and effectively complete the feature identification and extraction of complex flow fields. In this paper, we proposed a convolutional neural network (CNN)-based method for predicting the pressure distribution on the airfoil surface, by extracting the flow features such as wake velocity and pressure of the flow field to build a prediction model for the pressure distribution on the airfoil surface. Firstly, the flow fields of flap of NACA 0012 airfoil with eight different lift angles were calculated by numerical simulation; secondly, the CNN prediction model was built using the extracted flow field data; finally, the predicted values were compared with the CFD calculated values. Results show that the convolutional neural network-based model has a high prediction accuracy to pressure coefficient distribution on the airfoil surface, and the predicted root mean square error (RMSE) of wake velocity model is only 0.1 when flat lift angle is 15° , indicating the wake velocity contains abundant flow field information.

Key words: deep learning, convolutional neural network (CNN), flap of airfoil, flow field identification, unsteady

收稿日期:2023-02-09; 修订日期:2023-03-08

基金项目:国家自然科学基金资助项目(51976131, 52006148, 52106262)

Fund-supported Project: National Natural Science Foundation of China (51976131, 52006148, 52106262)

作者简介:张强(1996-),男,上海理工大学博士研究生。

通讯作者:李春(1963-),男,上海理工大学教授。

引言

垂直轴风力机运行时攻角周期性大幅变化,极易出现流动分离^[1]。流动分离是翼型绕流中常见的流动现象,其在使翼型气动性能恶化的同时也伴随着噪声和振动等问题,流动的高度非定常是求解此问题的难点^[2]。尾缘气动弹片作为一种流动控制方法,通过控制弹片抬起改善流动分离,从而提高翼型气动性能^[3]。有研究表明,气动弹片对于稳定翼型表面压力分布与降噪有显著效果^[4]。因此,开展气动弹片抬起角度对翼型表面压力分布影响规律的研究尤为重要。然而,通过实验或数值模拟的手段获得翼型表面压力分布存在计算量大且效率低的缺点。

近些年,随着计算机领域人工智能学科的发展,基于数据驱动的深度学习方法与计算流体力学相结合,不仅可以节约计算时间与成本,也可满足复杂流场识别、预测和降阶等方面的需求^[5-6]。流体绕流固体表面时,由于固体表面形状的变化,不可避免地会导致尾流流场的不同,因此,在尾流数据中可学习到固体的轮廓信息^[7]。深度学习具有分析处理抽象数据的能力,能建立复杂特征的输入与输出的映射关系^[8]。Miyawala 等人^[9]采用3组形状不同的几何结构流场数据训练 CNN 模型,随后成功预测了其余10组不同柱体的气动载荷。Jin 等人^[10]通过数值模拟获得不同雷诺数下圆柱绕流流场数据,并基于 CNN 建立了雷诺数对流动特性的数据驱动模型,结果表明,预测结果与 CFD 吻合良好,成功地对流动状态进行了分类及预测。Strofer 等人^[11]通过 CNN 开发出一种基于数据驱动的流体特征识别方法,并利用数值模拟对该方法进行了验证,结果表明,该方法在对新特征识别时不需要提前对特征定义。Ye 等人^[12]利用圆柱绕流尾流速度预测压力系数分布,并对相似流动采用数据迁移学习策略提高效率,结果表明, CNN 在流体力学中应用前景广阔。Duru 等人^[13]提出了一种基于深度学习的翼型跨声速流场预测模型,利用预测的流场数据计算气动力系数,结果表明,精度仅有轻微损失,但是避免了耗时的 CFD 模拟。

现阶段,基于深度学习的流场特征识别研究主

要针对圆柱绕流、单翼型气动力系数预测与流场重构等,对于复杂流场的特征识别与预测研究较少。翼型的尾流流场中包含大量流场信息,翼型表面安装弹片改变了流体绕流的状态,改变了翼型表面的压力系数 C_p ,同时也使得尾流流场数据发生变化。为充分识别安装气动弹片的翼型尾流流场特征,并提高计算效率,本文结合 CNN 建立不同尾流时程数据的流场预测模型,对弹片翼型表面的压力系数展开预测,并与 CFD 模拟结果进行对比。

1 卷积神经网络(CNN)

深度学习的发展增加了神经网络的种类,其中 CNN 是一种适合处理网格数据的算法^[14]。CNN 是一类监督学习算法,主要由输入层、卷积层、池化层、全连接层和输出层组成,通过对输入数据卷积与池化操作,提取数据结构特征。CNN 在挖掘与训练数据时,会考虑数据的空间相关性,对非线性问题有很强的分类能力^[15]。通过不断从流场中学习数据特征,构建翼型几何与流场的数据映射关系,从而对流场的典型特征快速识别与预测。

1.1 卷积层(Convolutional Layer)

卷积运算是整个 CNN 运算中必不可少的一个步骤。卷积层和非线性激活函数通过卷积运算计算输入向量对应的输出值,如下式所示:

$$y_i = \sigma(k_i * x + b_i) \quad (1)$$

式中: x —卷积层的输入, $i=1,2,\dots,n$ 。算子 $*$ —卷积运算; k_i —第 i 个可训练的卷积滤波器; b_i —卷积滤波器 k_i 的第 i 个偏置; y_i —第 i 个卷积滤波器对应的第 i 个输出矩阵,每一层都有若干个卷积滤波器; σ —非线性激活函数,激活函数会对数据进行非线性变换,提高网络的泛化能力。

1.2 池化层(Pooling Layer)

池化操作是一个下采样过程,从相应池化窗口的数据采样窗口中提取最大值、平均值、 L_2 -norm 等作为低维输出。以最大值池化为例,池化层的下采样操作如图1所示。在池化窗口中取最大值的过程是在输入深度维度的每个片断上独立进行的,因此在空间上对输入矩阵进行了下采样,而输出矩阵的深度维度保持不变。池化层可以逐步减少表征的空间大小,以减少网络中的参数和计算量,也可以控制过拟合。

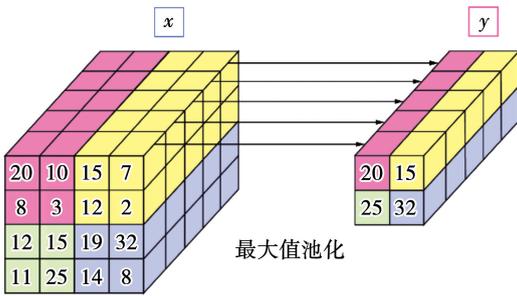


图 1 最大值池化的下采样过程

Fig. 1 Down sampling process of maximum pooling layer

通过一系列的卷积和池化操作, CNN 学习了输入机翼图像中的空间关联性。卷积层之前的网络被认为是一个编码器, 之后的网络被认为是一个解码器。

2 流场模拟与数据提取方法

选取 NACA 0012 为基准翼型, 在吸力面尾缘安装气动弹片, 通过数值模拟获得弹片不同角度下的流场物理量数据集, 将其作为输入参数训练出一个高精度的 CNN 模型。

2.1 网格划分

来流方向设置为速度入口, 出口方向为压力出口。计算域网格如图 2 所示。

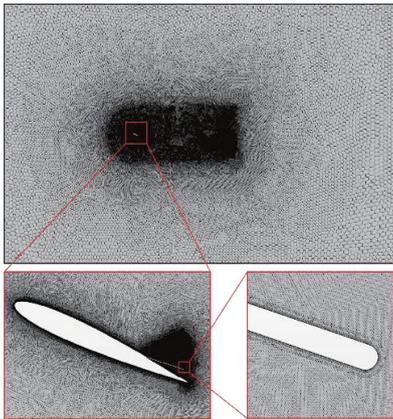


图 2 计算域网格分布

Fig. 2 Grid distribution of computational domain

除壁面层网格采用四边形网格外, 其余区域均采用六面体网格。翼型壁面设置为无滑移壁面, 第一层网格高度取 $1.5 \times 10^{-5} \text{m}$, 以保证 $y^+ = 1$ 。为确保流场数据计算的精确性, 对流动较为复杂的弹片区域进行了网格加密, 网格主要集中在近场翼型四周, 而翼型较远处网格稀疏且均匀。

2.2 计算模型

采用计算流体力学软件 STAR-CCM+ 计算翼型流场数据。通过求解非定常雷诺时均纳维-斯托克斯 (Unsteady Reynolds-Averaged Navier-Stokes, URANS) 方程, 压力与速度的耦合求解使用 SIMPLEC 算法, 对流项选用二阶迎风格式, 扩散项选用二阶中心差分格式, 压力项和粘性通量选择中心差分格式, 收敛残差为 1×10^{-6} 。文献 [16] 用不同湍流模型对 NACA 0012 翼型进行数值模拟发现, SST $k-\omega$ 湍流模型计算结果与实验值吻合较好。

2.3 数据提取方法

为了快速提取尾流数据, 在计算过程中同步采集流场数据, 直接将每一迭代步的流场数据分类保存。各测点的时程参数不仅包含基本的流场计算数据, 也可输出由基本数据计算出的物理场, 如梯度场、涡量场与脉动场等。相比于物理实验中传感器数量布置的局限性, 计算时在流场任意位置布置测点的方式不受测点位置和数量的限制, 能够获取更多实时数据。测点布置方式如图 3 所示。测点位于翼型尾流区域, 分布在距离尾缘点 $1c \sim 3c$, 纵向 $-1c \sim 1c$ 的范围内, c 为翼型弦长。此区域流动最为复杂, 能够获得较多流场信息。单个算例共布置 121 个测点。

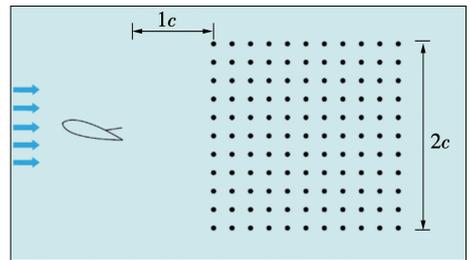


图 3 尾流测点位置示意

Fig. 3 Schematic diagram of location of wake monitoring points

3 CNN 模型构建

将弹片翼型的尾流测点处不同时刻的水平速度 U 、垂直速度 V 、压力 p 和涡量 Ω 作为输入数据, 翼型表面 59 个点的压力系数 C_p 作为输出值, 利用 CNN 建立映射关系。

3.1 参数设置

网络训练是权重系数不断更新的过程。在每一

次迭代中,数据先进行前馈传播,然后进行梯度反向传播。对于给定输入,模型将预测输出和真实数据的损失函数最小化。选择均方根误差 (Root Mean Square Error, RMSE) 作为 CNN 模型训练中的损失函数, RMSE 值越小代表模型鲁棒性越好。其表达式如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2} \quad (2)$$

式中: y —预测值; \tilde{y} —CFD 计算值。

通过训练不同参数组合的网络,根据泛化能力以及预测值与真实值的误差对比生成网络模型。学习率、卷积核尺寸以及卷积层布置的不同会影响网络精度。图 4 为 CNN 模型参数训练的结构示意图。模型训练中的 CNN 参数如表 1 所示。

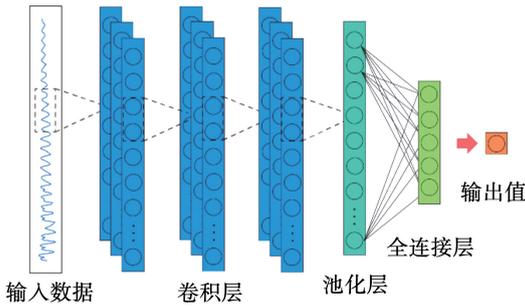


图 4 CNN 模型训练示意图

Fig. 4 Schematic diagram of CNN model training

表 1 CNN 参数设置

Tab. 1 Parameter settings of CNN

层类型	激活函数	卷积核	卷积核尺寸	步长	输出尺寸
输入	-	-	-	-	300
卷积层	ReLU	128	8	2	150
卷积层	ReLU	256	5	2	75
卷积层	ReLU	256	3	2	38
池化层	-	-	-	-	19
全连接层	-	-	-	-	6
输出	-	-	-	-	-

3.2 流场预测模型

图 5 为 CFD 模拟和 CNN 模型结合的训练流程。通过提取的流场数据训练神经网络,构建流场预测模型,以神经网络参数预测值的损失函数最小为目标,建立弹片翼型与流场数据间的映射关系,从而对未知的流场做出预测。该模型可以省去费时的

网格生成和数值迭代的求解过程,对流场数据预测时确保精度良好。

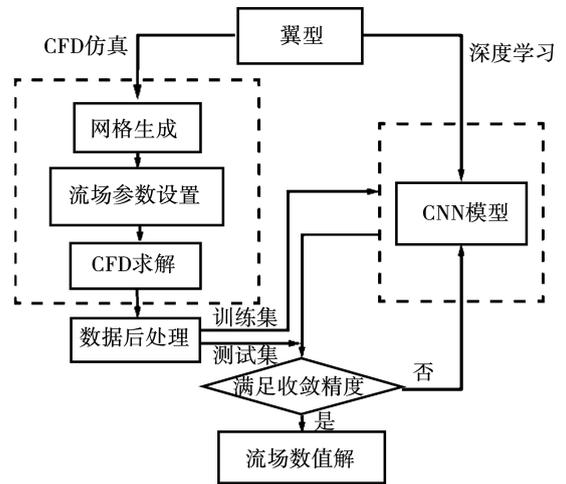


图 5 流场预测模型训练过程

Fig. 5 Training process of flow field prediction model

4 结果分析

入口速度为 16.69 m/s, $Re = 1.35 \times 10^5$, 在攻角 $\alpha = 12^\circ$ 时,对弹片抬起角度 β 为 $0^\circ, 5^\circ, 10^\circ, 15^\circ, 20^\circ, 25^\circ, 30^\circ$ 和 35° 时的流动进行模拟,其中 6 组数据用于训练 CNN 模型,其余 2 组作为测试集。为对比不同尾流时程数据的预测精度,建立了 $U-V-C_p$ 模型、 $p-C_p$ 模型和 $\Omega-C_p$ 模型。选取 $5^\circ, 15^\circ$ 和 25° 攻角的尾流数据,通过 3 种模型对翼型表面 C_p 进行预测,并与 CFD 结果对比。

4.1 $U-V-C_p$ 模型预测结果

$U-V-C_p$ 模型是将不同弹片抬起角度下的翼型尾流速度 U 和 V 作为输入向量,翼型表面压力系数分布 C_p 作为响应值,通过建立 CNN 完成对 C_p 的预测。

模型训练过程中,训练集样本的 RMSE 随次数的变化如图 6 所示。由图 6 可知,经过 200 次的迭代,3 个模型的 RMSE 已经小于 0.2。其中, β 为 $5^\circ, 15^\circ$ 与 25° RMSE 值分别为 0.114 1, 0.089 17 和 0.100 9,其中 $\beta = 15^\circ$ 时最小。

图 7 为 CNN 训练的 $U-V-C_p$ 模型预测的翼型表面 C_p 与 CFD 结果的对比。由图 7 可知, β 为 5° 和 15° 时, $U-V-C_p$ 模型对下表面的预测精度更高;当 β 为 25° 时,由于抬起角度过大,弹片位置的压力分布预测误差较大。

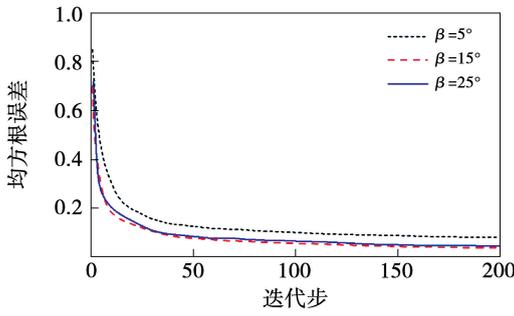
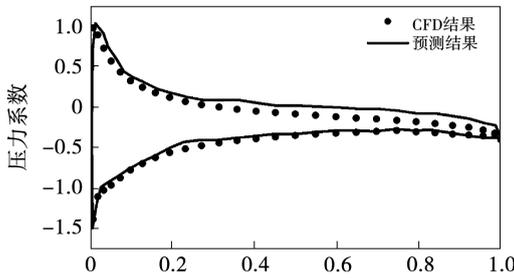
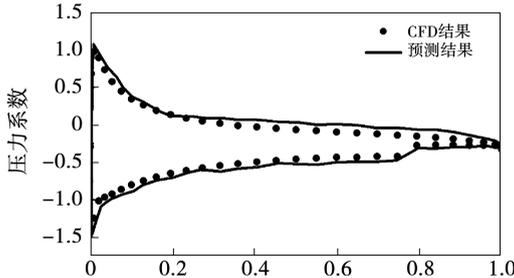


图 6 模型 $U_V - C_p$ 训练误差下降曲线

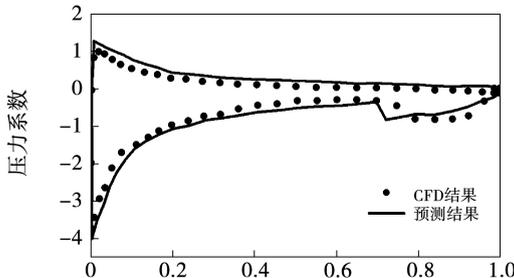
Fig. 6 Error decline curve of model $U_V - C_p$ training



(a) $\beta = 5^\circ$



(b) $\beta = 15^\circ$



(c) $\beta = 25^\circ$

图 7 模型 $U_V - C_p$ 预测结果与 CFD 结果对比

Fig. 7 Comparison of model $U_V - C_p$ prediction results with CFD results

4.2 $p - C_p$ 模型预测结果

$p - C_p$ 模型是将不同弹片抬起角度下的翼型尾流压力 p 作为输入向量,翼型表面压力系数分布 C_p 作为响应值,通过建立 CNN 完成对 C_p 的预测。

模型训练过程中,训练集样本的 RMSE 随次数

的变化如图 8 所示。经过 200 次的迭代,3 个模型的 RMSE 已经小于 0.2。其中 β 为 $5^\circ, 15^\circ$ 和 25° 时, RMSE 分别为 0.117 9, 0.104 8 与 0.153 2。相较于 $U_V - C_p$ 模型误差有所增大。

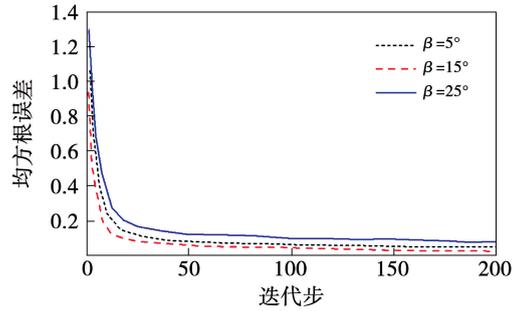
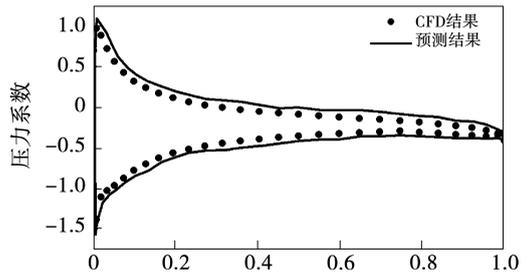


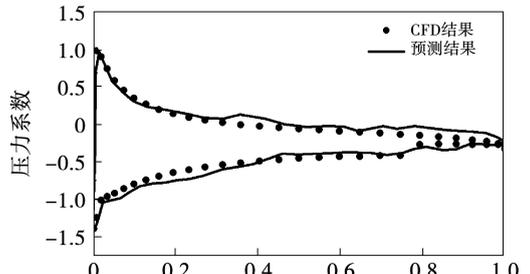
图 8 模型 $p - C_p$ 训练误差下降曲线

Fig. 8 Error decline curve of model $p - C_p$ training

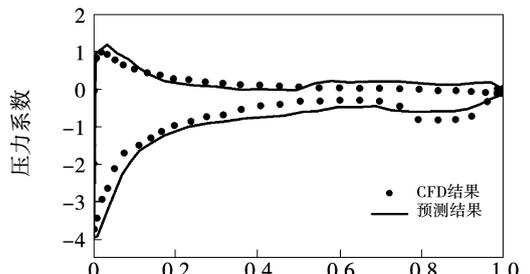
图 9 为 CNN 训练的 $p - C_p$ 模型预测的翼型表面 C_p 与 CFD 结果的对比。



(a) $\beta = 5^\circ$



(b) $\beta = 15^\circ$



(c) $\beta = 25^\circ$

图 9 模型 $p - C_p$ 预测结果与 CFD 结果对比

Fig. 9 Comparison of model $p - C_p$ prediction results with CFD results

由此可见, $p-C_p$ 模型对翼型尾缘的预测结果更好。

4.3 $\Omega-C_p$ 模型预测结果

$\Omega-C_p$ 模型是将不同弹片抬起角度下的翼型尾流涡量 Ω 作为输入向量,翼型表面压力系数分布 C_p 作为响应值,通过建立CNN完成对 C_p 的预测。

模型训练过程中,训练集样本的RMSE随次数的变化如图10所示。图11为CNN训练的 $\Omega-C_p$ 模型预测的翼型表面 C_p 与CFD结果的对比。

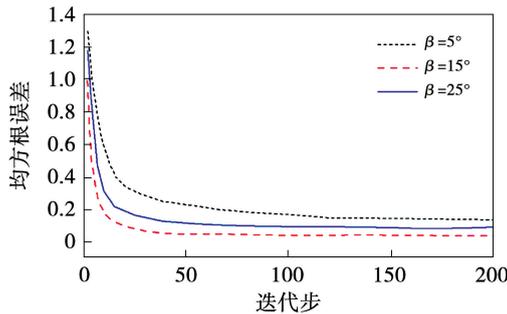
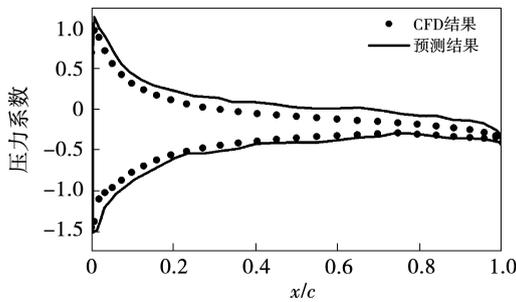


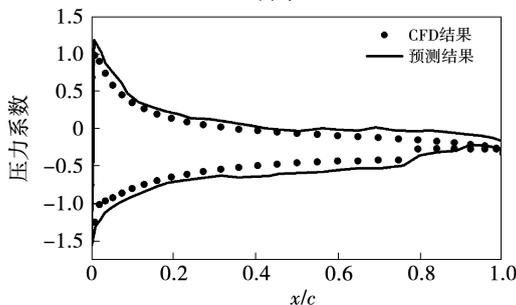
图10 模型 $\Omega-C_p$ 训练误差下降曲线

Fig. 10 Error decline curve of model $\Omega-C_p$ training

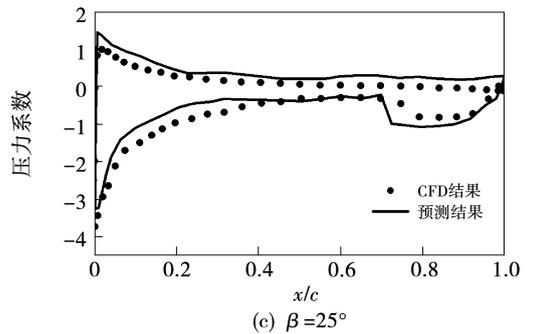
由图10可知,经过200次的迭代,3个模型的RMSE已经收敛。其中 β 为 5° 、 15° 和 25° 时均方根误差分别为0.2032、0.1085与0.1496。 $\Omega-C_p$ 模型的拟合误差相较其余两种较大。由图11可见,翼型上下表面的预测结果均不是很理想。



(a) $\beta=5^\circ$



(b) $\beta=15^\circ$



(c) $\beta=25^\circ$

图11 模型 $\Omega-C_p$ 预测结果与CFD结果对比

Fig. 11 Comparison of model $\Omega-C_p$ prediction results with CFD results

5 结论

通过识别弹片翼型尾流时程数据,基于深度学习的方法构建了翼型表面压力分布的预测模型,并将模型预测结果与CFD结果进行了对比,得到了以下结论:

(1) 采用CNN构建的3种预测模型对翼型表面压力系数分布均有较高的精度,且3种模型预测结果的RMSE从小到大均依次是 β 为 15° 、 25° 和 5° 。

(2) $U-V-C_p$ 模型对翼型表面压力系数的预测精度最好,均方根误差约为0.1, $p-C_p$ 和 $\Omega-C_p$ 模型仅在 $\beta=15^\circ$ 时精度较好,在抬起角度 β 为 5° 和 25° 时均显示出较大误差。

(3) 本文研究的3种典型尾流流场参数,尾流速度对于流场识别与预测的精度最高,说明尾流流场中速度随时间的变化所包含的流场信息最丰富,可用于翼型表面压力系数的预测。

参考文献:

- [1] 李春,叶舟,高伟,等.现代陆海风力机计算与仿真[M].上海:上海科学技术出版社,2012.
LI Chun, YE Zhou, GAO Wei, et al. Computation and simulation of modern land-sea wind turbine [M]. Shanghai: Shanghai Scientific & Technical Publishers, 2012.
- [2] 许子非,缪维跑,李春,等.流场非线性特征提取与混沌分析[J].物理学报,2020,69(24):344-352.
XU Zi-fei, MIAO Wei-pao, LI Chun, et al. Nonlinear feature extraction and chaos analysis of flow field [J]. Acta Physica Sinica, 2020, 69(24): 344-352.

- [3] 郝文星,李 春,陈福东,等.翼型附加气动弹片流动控制研究[J].太阳能学报,2020,41(9):302-309.
HAO Wen-xing,LI Chun,CHEN Fu-dong,et al. Study on flow control of airfoil based on aerodynamic flap[J]. Acta Energetica Sinica,2020,41(9):302-309.
- [4] LIU Q,MIAO W,LI C,et al. Effects of trailing-edge movable flap on aerodynamic performance and noise characteristics of VAWT[J]. Energy,2019,189:116271. 1-116271. 22.
- [5] CHEN H,GUO M,TIAN Y,et al. Intelligent reconstruction of the flow field in a supersonic combustor based on deep learning[J]. Physics of Fluids,2022,34(3):035128. 1-035128. 13.
- [6] LIU B,TANG J,HUANG H,et al. Deep learning methods for super-resolution reconstruction of turbulent flows[J]. Physics of Fluids,2020,32(2):025105. 1-025105. 13.
- [7] 战庆亮,葛耀君,白春锦.基于尾流时程目标识别的流场参数选择研究[J].力学学报,2021,53(10):2692-2702.
ZHAN Qing-liang,GE Yao-jun,BAI Chun-jin. Study on flow field parameters of wake time history target recognition[J]. Chinese Journal of Theoretical and Applied Mechanics,2021,53(10):2692-2702.
- [8] HONG F,LIU C,GUO L,et al. Underwater acoustic target recognition with a residual network and the optimized feature extraction method[J]. Applied Sciences,2021,11(4):1442.
- [9] MIYANAWALA T P,JAIMAN R K. An efficient deep learning technique for the Navier-Stokes equations:Application to unsteady wake flow dynamics[J]. arXiv preprint arXiv,2017:1710.09099.
- [10] JIN X,CHENG P,CHEN W L,et al. Prediction model of velocity field around circular cylinder over various Reynolds numbers by fusion convolutional neural networks based on pressure on the cylinder[J]. Physics of Fluids,2018,30(4):047105. 1-047105. 16.
- [11] STROFER C M,WU J,XIAO H,et al. Data-driven,physics-based feature extraction from fluid flow fields[J]. arXiv preprint arXiv,2018:1802.00775.
- [12] YE S,WANG Y,ZHANG Z,et al. Transfer learning for modeling pressure coefficient around cylinder using CNN[C]//29th International Ocean and Polar Engineering Conference, Honolulu, HI, United States,2019.
- [13] DURU C,ALEMDAR H,BARAN O U. A deep learning approach for the transonic flow field predictions around airfoils[J]. Computers & Fluids,2022,236:105312. 1-105312. 15.
- [14] 许子非,岳敏楠,李 春.基于卷积神经网络风力机轴承混沌空间故障分析与诊断[J].热能动力工程,2020,35(6):243-250,256.
XU Zi-fei,YUE Min-nan,LI Chun,et al. Fault diagnosis and analysis of wind turbine bearing chaotic phase based on convolutional neural network[J]. Journal of Engineering for Thermal Energy and Power,2020,35(6):243-250,256.
- [15] 金江涛,许子非,李 春,等.基于深度学习与支持向量机的滚动轴承故障诊断研究[J].热能动力工程,2022,37(6):176-184.
JIN Jiang-tao,XU Zi-fei,LI Chun,et al. Research on rolling bearing fault diagnosis based on deep learning and support vector machine[J]. Journal of Engineering for Thermal Energy and Power,2022,37(6):176-184.
- [16] MENTER F R. Two-equation eddy-viscosity turbulence models for engineering applications [J]. AIAA Journal,1994,32(8):1598-1605.

(姜雪梅 编辑)