

基于卷积神经网络的空化水翼表面的压力预测

王畅, 叶舒然, 张珍, 王一伟

(中国科学院 力学研究所, 流固耦合系统力学重点实验室, 北京, 100190)

E-mail: wangc7631@163.com; wangyw@imech.ac.cn 电话: 15901175699

摘要: 随着神经网络等人工智能技术的快速发展, 利用数据驱动的机器学习方法在探索复杂流体动力学问题中的流场识别、提取、降阶等方面取得了成功的应用。空化是发生在水力机械等领域常见的水动力现象, 作为高速水动力学的核心问题, 云状空化流具有强烈的非定常特性, 因此, 利用数据驱动建立非定常多相流场的识别方法对水力机械等领域具有重要的意义。本文旨在研究一种基于卷积神经网络的空化翼型表面压力预测方法, 该数据驱动方法通过提取非定常云空化流场中水翼尾流速度、空泡体积分数等流动特征构建水翼表面压力分布的完整模型。首先, 对二维 NACA0015 水翼云空化流场进行了数值分析, 得到了 4 种不同空化数下翼型速度场、压力场等数据信息。然后, 建立了卷积神经网络 (CNN) 预测模型, 通过对不同空化数下水翼云空化尾流速度 U 、空泡体积分数 α 及空泡密度 ρ 等进行提取与分类预测了空化水翼表面的压力系数 C_p 。最后, 将 CNN 预测结果与 CFD 计算结果进行对比分析, 表明该卷积神经网络的预测方法对非定常多相流场识别具有较高的精度。

关键词: 机器学习; 卷积神经网络; 水翼; 非定常; 流场识别

1 引言

空化是发生在水力机械等领域常见的水动力现象, 作为高速水动力学的核心问题, 云状空化具有强烈的非定常特性。云空化发生过程中伴随着噪声、振动、空蚀等一系列问题, 对水利机械性能造成一定影响。因此, 深入研究云空化的演变规律及其水动力特性对船舶等水力工程领域具有重要意义。传统方法一般通过数值模拟或试验得到水翼表面压力分布, 但存在计算量大和试验成本高等缺点。

近年来, 为了充分利用 CFD 计算结果、解决数值计算效率等问题, 机器学习技术得到了快速发展, 提出了基于神经网络的流场特征识别及降阶模型等方法。Storfer 等^[1]通过卷积神经网络 (CNN) 对流场的流动特征进行了识别, 并通过数值模拟得到的平均流场信

息对该数据驱动方法进行了测试。Ye 等^[2]提出了一种基于圆柱绕流尾流速度场预测圆柱周围压力系数的数据驱动方法,学习结果表明,卷积神经网络和传递学习在流体力学中具有积极的应用前景。Jin 等^[3]提出了一种基于数据驱动的圆柱周围速度场预测模型,该模型采用融合卷积神经网络(CNNs)通过不同雷诺数下的圆柱表面压力场分布对其周围速度场进行预测。Huang 等^[4]建立了 BP 神经网络预测模型,该模型通过输入雷诺数、马赫数等对二维翼型的升阻力系数进行了预测。Wallach 和 Santos 等^[5-6]建立了神经网络预测模型,通过输入雷诺数、马赫数及翼型几何形状等对翼型的气动参数进行了预测。陈海等^[7]建立了基于深度学习的翼型气动系数预测模型,该数据驱动方法在给定迎角、雷诺数及马赫数情况下,通过输入翼型图像对翼型气动参数进行预测。

目前基于深度学习的流体力学研究主要用于圆柱绕流流场特征识别、机翼绕流场建模及机翼气动系数预测等,而对于强非定常多相流场识别的研究相对较少。张伟伟等^[8-9]在标准 RBF 神经网络的基础上引入了输出反馈,得到了基于递归 RBF 神经网络的非线性、非定常气动力模型,准确表达了气动力非定常特性。Lindhorst 等^[10]将 POD 法和递归 RBF 神经网络模型进行了组合,在 POD 降维后的低维空间建立了动态非线性系统识别模型。Mi 等^[11-12]在电流探针信号基础上,利用神经网络对竖直槽道内的两相流进行了识别研究。苏永生等^[13]基于振动和噪声信号,利用 BP 神经网络和径向基神经网络对喷水推进泵的空化流态进行了识别研究。Giorgi 等^[14]利用神经网络在得到孔口后空化流场压力脉动信号等后有效提取了不同温度不同空化状态下的频带特征。曹玉良等^[15]提出了一种基于深度学习的离心泵空化状态识别方法,基于自动编码器构建了深度学习网络,对离心泵的 4 类空化状态进行了分类识别。已有的研究中关于空化状态识别的特征分析、算法的精度和可靠性还有待提高,因此,如何高效进行空化流场识别,仍是当前空化研究的难点问题。

为了充分研究空化水翼流场特征及其水动力特性并提高计算效率,本文提出了一种卷积神经网络方法对空化水翼表面的压力系数进行预测。文中以二维 NACA0015 水翼云空化流场为研究对象,通过 CFD 计算得到了 4 种不同空化状态下的翼型速度场等数据信息;建立了卷积神经网络预测模型,通过对输入的尾流速度 U 、空泡体积分数 α 及密度 ρ 等进行提取与分类,预测了空化水翼表面的压力系数 C_p 。

2 CNN 基本原理

作为神经网络领域的一个重要分支,CNN 是一种监督学习型的算法,通过数据卷积采样以及反向权值运算,可以解决大量实际识别问题,具有优秀的非线性分类能力。因此,通过构建 CNN 模型作为流场特征识别方法,选取典型流场特征数据标注特征样本数据集,并对 CNN 模型进行训练学习,理论上可以取得对流场典型特征的较好识别效果。

2.1 CNN 基本结构

典型的 CNN 模型由输入层、卷积层、池化层、全连接层和输出层组成，根据具体问题的不同，CNN 可能会有多个卷积层和池化层交替出现，并含有多个全连接层。




图1 CNN 的典型结构

(1) 输入层 (Input Layer)。该层主要是对原始图像数据进行预处理，还需要对图像数据进行归一化和去均值处理，以减少各维度数据取值范围的差异而带来的干扰并降低输入的冗余性。

(2) 卷积层 (Convolutional Layer)。该层是 CNN 的核心组成部分，通过不同的卷积核获取图像的不同特征。

卷积神经网络之所以能解决非线性问题，本质上是激活函数 (Activation function) 加入了非线性因素，弥补了线性模型的表达力，把“激活的神经元的特征”通过函数保留并映射到下一层。CNN 常用的激活函数有 Sigmoid、Tanh、Relu 和 Softplus 等函数，而 Relu 函数可以通过简单的阈值化的激活来实现参数稀疏化，比传统的饱和非线性函数有更快的收敛速度。因此，Relu 函数是目前最受欢迎的激活函数。

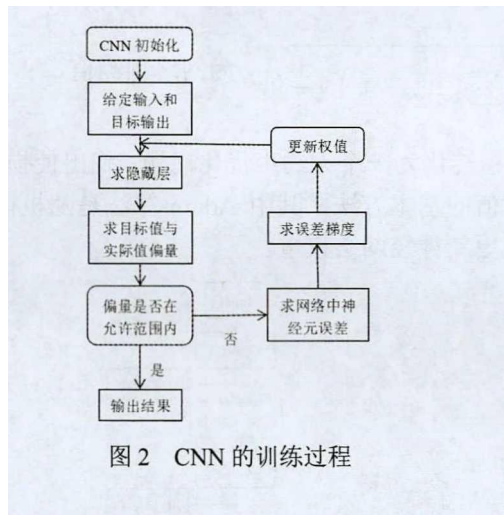
(3) 池化层 (Pooling Layer)。池化层主要用于特征降维，压缩数据和参数的数量，去除冗余信息并减小过拟合，同时提高模型的容错性。网络在训练过程中通常可以引入 Dropout 操作，来随机删除神经网络中的部分神经元，防止训练数据过拟合。

(4) 全连接层 (Fully-connected)。全连接层中的每个神经元预期前一层的所有神经元进行全连接，主要作用是对信息进行分类，可以整合卷积层或者池化层中具有类别区分性的局部信息。

2.2 CNN 训练过程

卷积神经网络的训练过程分为两个阶段：前向传播阶段，即数据从低层次向高层次传播；误差反向传播阶段，即当前向传播得出的结果与预期不相符时，将误差从高层次向底层进行传播训练。训练过程如图 2 所示。

在前向传播阶段，输入的图形数据经过多层卷积层的卷积和池化处理，将提取的特征向量传入全连接层，构建神经网络模型，最后通过输出层得出分类识别的结果。当 CNN 输出的结果与预期值不符时，则进行误差反向传播计算。求出结果与预期值的误差，再将误差逐层返回，计算出每一层的误差，然后进行权值更新，该阶段的主要目的是通过训练样本和预期值来调整网络权值。




3 空化水翼压力系数预测模型

3.1 二维水翼空化流算例

选取二维水翼NACA0015云空化流场为研究对象,采用入口速度 $U=8\text{m/s}$ 、攻角 $\alpha=7^\circ$ 、LES 湍流模型对不同空化数 $\sigma=0.8$ 、1.1、1.4 及 1.7 下水翼云空化流动进行数值模拟,得到了水翼表面压力系数 C_p 、空化水翼尾流速度 U 、空泡体积分数 α 及空泡密度 ρ 等。

文中 CNN 的输入数据来源于空化水翼数值计算结果,将其中三个空化数下得到的结果作为训练数据,另一个空化数下的结果作为测试数据。该数据驱动方法将空化水翼尾流 67×51 点阵上速度 U 、速度与空泡体积分数 U_α 、速度与密度比(空泡密度与水的密度比值) U_ρ 作为输入,取水翼表面 37 个点的压力系数 C_p 作为输出,用卷积神经网络进行拟合。流场中尾流插值区域如图 3 所示。



3.2 CNN 结构设计

卷积神经网络训练模型流程图如图 4 所示,网络训练过程使用 ReLU 函数作为激活函数,其函数计算公式为 $f(x)=\max(0,x)$ 。

损失函数是一个非负实值函数,它反映了预测值与真值之间的偏差[16],损失函数值越少,模型的鲁棒性越好。CNN 训练过程中的损失函数选取均方根误差函数 RMSE。

其中, $RMSE = \sqrt{\sum_{i=1}^n (y_i - \tilde{y}_i)^2 \cdot \frac{1}{n}}$, y 为网络预测值, \tilde{y} 为 CFD 计算值。

因此, 可将训练过程转化为一个无约束优化问题, 找出使损失函数最小值的适当变量。梯度下降法是获得最优值的基本方法, 其中 Adam 算法是随机梯度下降算法的扩展式, 它能基于训练数据迭代地更新神经网络权重。

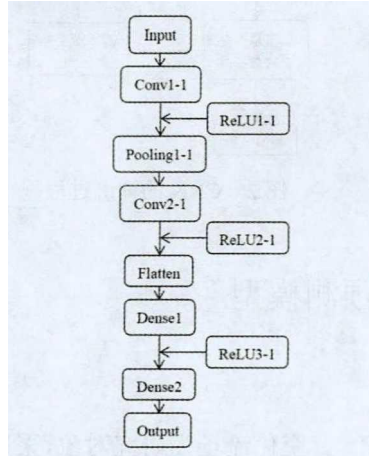


图4 CNN 的训练模型流程图

(“Conv”是卷积层; “ReLU”是激活函数; “Pooling”是池化层; “Dense”是全连接层)
训练模型中的相关参数如表 1 所示:

表 1 CNN 中的相关参数

Layer(type)	Output Shape	Parameters
conv2d_1(Conv2D)	(65,49,16)	304
activation_1		
max_pooling2d_1	(32,24,16)	
conv2d_2(Conv2D)	(30,22,32)	4640
activation_2		
flatten_1	21120	
dense_1	128	2703488
activation_3		
dense_2	37	4773

4 结果分析

4.1 时间相位差对预测结果的影响

为了研究时间相位差对预测结果的影响, 本文分别对同一时刻的模型 C_p-U 、模型

C_p-U_α 以及考虑时间相位差 Δt 时的模型 C_p-U' 、模型 C_p-U_α 进行了预测,得到的均方根误差如表 2 所示。

其中,时间相位差 $\Delta t=L/u$, L 是水翼前端到尾流插值区域的距离, u 是流场速度。

由表 2 中的结果可以看出,在考虑时间相位差的情况下,该数据驱动方法对模型的预测结果相对较好。

表 2 时间相位差对预测结果的影响

	C_p-U	C_p-U'	C_p-U_α	C_p-U_α'
0.8	0.1857	0.1117	0.1541	0.1088
1.1	0.2028	0.1019	0.1287	0.1106
1.4	0.1502	0.1079	0.1427	0.1316
1.7	0.2417	0.2485	0.2661	0.2121

4.2 模型 C_p-U 预测结果

对模型 C_p-U 的预测过程是分别将数值计算得到的其中 3 种不同空化数下水翼云空化尾流速度 U 作为训练数据,另外 1 种空化数下的水翼云空化尾流速度 U 作为测试数据,通过卷积神经网络对水翼表面压力系数 C_p 进行预测。

训练过程中,每批样本的均方根误差 (RMSE) 随循环次数的变化曲线如图 5 所示。




图 5 模型 C_p-U 训练过程中均方根误差变化曲线

为了便于观察,图 5 给出了 50 次循环内的 RMSE 变化情况。从图中可以看出,经过 50 次循环后, RMSE 已下降到 0.2 以下,并且还有继续下降的趋势。

分别对 4 种不同空化数下尾流 U 的计算结果进行训练,得到了水翼表面压力系数 C_p 的预测结果与数值计算结果对比,如图 6 所示(其中,图 6 (a)是将空化数 1.1、1.4 和 1.7 得到的水翼云空化尾流速度 U 作为训练数据,空化数 0.8 得到的水翼云空化尾流速度 U 作为测试数据,通过卷积神经网络进行预测得到水翼表面压力系数 C_p 的模型预测结果与 CFD 数值计算结果的对比)。

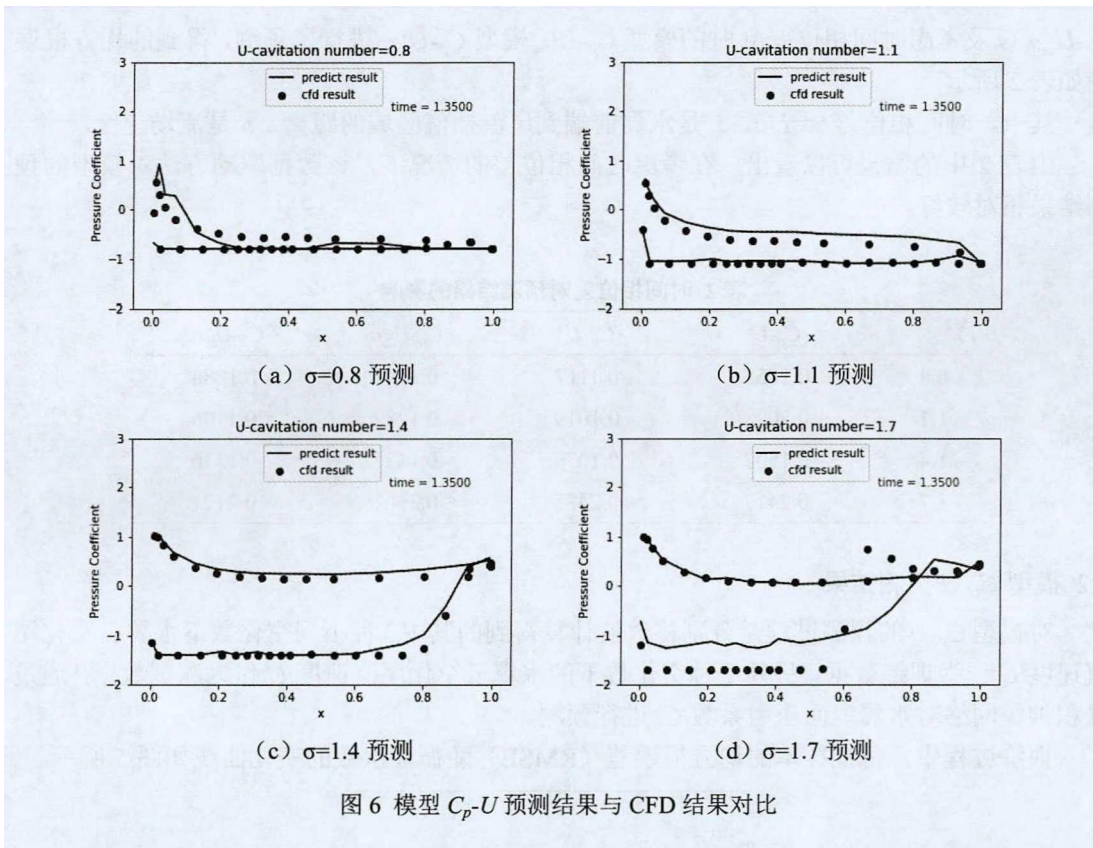


表 3 给出了不同空化数下模型预测结果均方根误差对比。由结果可以得出，该 CNN 的预测方法对模型 C_p-U 预测具有较高精度，并且空化数 1.1 和 1.4 下的内插预测结果比空化数 0.8 和 1.7 下的外插预测结果精度高。


表 3 不同空化数预测结果误差对比

	$\sigma=0.8$	$\sigma=1.1$	$\sigma=1.4$	$\sigma=1.7$
C_p-U	0.1117	0.1019	0.1079	0.2485


4.3 模型 C_p-U_α 预测结果

对模型 C_p-U_α 的预测过程是分别将数值计算得到的其中 3 种不同空化数下水翼云空化尾流速度 U 和空泡体积分数 α 作为训练数据，另外 1 种空化数下的水翼云空化尾流速度 U 和空泡体积分数 α 作为测试数据，通过卷积神经网络对水翼表面压力系数 C_p 进行预测。

训练过程中，每批样本的均方根误差 (RMSE) 随循环次数的变化曲线如图 7 所示。

图7 模型 C_p-U_α 训练过程中均方根误差变化曲线

为了便于观察，图7给出了50次循环内的RMSE变化情况。从图中可以看出，经过50次循环后，采用 $\sigma=0.8$ 和 $\sigma=1.7$ 进行预测时，RMSE已下降到0.1以下，并且还有继续下降的趋势。

图8 模型 C_p-U_α 预测结果与CFD结果对比

分别对4种不同空化数下的 U_α 计算结果进行训练，得到了水翼表面压力系数的模型预测结果与数值计算结果对比，如图8所示。表4给出了不同空化数下模型预测结果误差对比。由结果可以得出，该CNN的预测方法对模型 C_p-U_α 预测结果良好；相较于模型 C_p-U 预测结果的均方根误差，空化数 $\sigma=0.8$ 和 $\sigma=1.7$ 下的均方根误差有所减小。

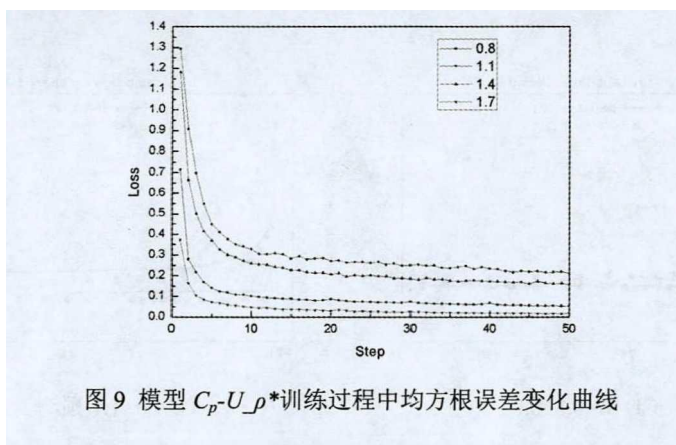
表 4 不同空化数预测结果误差对比

	$\sigma=0.8$	$\sigma=1.1$	$\sigma=1.4$	$\sigma=1.7$
C_p-U_a	0.1088	0.1106	0.1316	0.2121

4.4 模型 C_p-U_ρ *预测结果

对模型 C_p-U_ρ *的预测过程是分别将数值计算得到的其中 3 种不同空化数下水翼云空化尾流速度 U 和空泡密度与水密度比值 ρ^* 作为训练数据, 另外 1 种空化数下的水翼云空化尾流速度 U 和空泡密度与水密度比值 ρ^* 作为测试数据, 通过卷积神经网络对水翼表面压力系数 C_p 进行预测。

训练过程中, 每批样本的均方根误差 (RMSE) 随循环次数的变化曲线如图 9 所示。

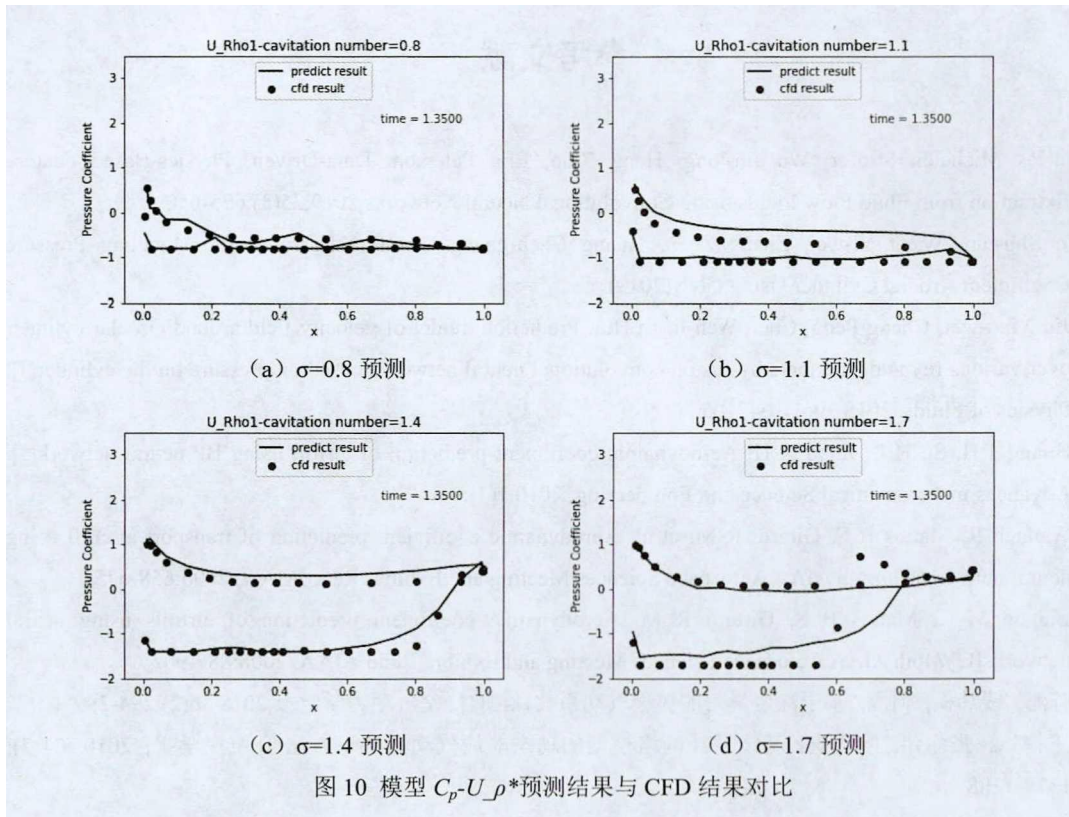
图 9 模型 C_p-U_ρ *训练过程中均方根误差变化曲线

为了便于观察, 图 9 给出了 50 次循环内的 RMSE 变化情况。从图中可以看出, 经过 50 次循环后, 采用 $\sigma=0.8$ 和 $\sigma=1.7$ 进行预测时, RMSE 已下降到 0.1 以下, 并且还有继续下降的趋势。

表 5 不同空化数预测结果误差对比

	$\sigma=0.8$	$\sigma=1.1$	$\sigma=1.4$	$\sigma=1.7$
$C_p-U_\rho^*$	0.1085	0.1219	0.1110	0.2132

分别对 4 种不同空化数下的 U_ρ^* 计算结果进行训练, 得到了水翼表面压力系数的模型预测结果与数值计算结果对比, 如图 10 所示。表 5 给出了不同空化数下模型预测结果误差对比。由结果可以得出, 该 CNN 的预测方法对模型 C_p-U_ρ *预测结果良好; 相较于模型 C_p-U 预测结果的均方根误差, 空化数 $\sigma=0.8$ 和 $\sigma=1.7$ 下的均方根误差有所减小。



5 结论

基于卷积神经网络提出了一种能够有效识别水翼空化流场的方法，构建了空化水翼表面压力分布的完整模型，并将模型预测结果与 CFD 数值模拟结果进行了对比分析，得到了以下结论：

(1) 该卷积神经网络对 3 种模型的预测结果都有较高的精度，且 3 种模型对于空化数 0.8、1.1 和 1.4 预测结果的均方根误差都比空化数 1.7 时的小；

(2) 模型 C_p-U 对空化数 1.1 和 1.4 下预测结果的均方根误差比空化数 0.8 和 1.7 时的小，且模型 C_p-U_α 和 C_p-U_ρ *对空化数 1.1 和 1.4 下预测结果的均方根误差相较于模型 C_p-U 时的有所增大，而对于空化数 0.8 和 1.7 时的均方根误差有所减小；

(3) 在增加时间相位差的情况下，该卷积神经网络在 4 种不同空化数下对 3 种模型预测结果的均方根误差都有所减小，提高了对空化流场识别的精确度。

参考文献

- 1 Carlos Michelén Ströfer, Wu Jin-long, Heng Xiao, Eric Paterson. Data-Driven, Physics-Based Feature Extraction from Fluid Flow Fields using Convolutional Neural Networks,2019,25(3):625-650
- 2 Ye Shu-ran, Wang Yi-wei, Zhang Zhen, Huang Chen-guang. Transfer Learning for Modeling Pressure Coefficient Around Cylinder Using CNN(2019)
- 3 Jin Xiao-wei, Cheng Peng, Chen Wen-li, Li Hui. 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
- 4 Huang J H, Su H L, Zhao X H. Aerodynamic coefficient prediction of airfoil using BP neural network[J]. Advances in Aeronautical Science and Engineering, 2010,1(1):36-39
- 5 Wallach R, Mattos B S, Girardi R M, et al. Aerodynamic coefficient prediction of transport aircraft using neural network[C]//44th AIAA Aerospace Sciences Meeting and Exhibit, Reno:AIAA, 2006:658-675
- 6 Santos M C, Mattos B S, Girardi R M. Aerodynamic coefficient prediction of airfoils using neural networks[C]//46th AIAA Aerospace Sciences Meeting and Exhibit, Reno:AIAA, 2008:887-902
- 7 陈海, 钱炜祺, 何磊. 基于深度学习的翼型气动系数预测[J]. 空气动力学学报,2018,36(2):294-299
- 8 王博斌, 张伟伟, 叶正寅. 基于神经网络模型的动态非线性气动力辨识方法[J].航空学报, 2010, 31(7): 1379-1388
- 9 Zhang W et al. Efficient Method for Limit Cycle Flutter Analysis by Nonlinear Aerodynamic Reduced-Order Models[J]. AIAA Journal. 2012, 50:1019-1028
- 10 Lindhorst K, Haupt M C, Horst P. Efficient surrogate modelling of nonlinear aerodynamics in aerostructural coupling schemes[J]. AIAA Journal, 2014, 52(9): 1952-1966
- 11 MI Y, ISHII M, TSOUKALAS L H. Vertical two-phase flow identification using advanced instrumentation and neural networks[J]. Nuclear Engineering and Design, 1998,184(2):409-420
- 12 MI Y, ISHII M, TSOUKALAS L H. Flow regime identification methodology with neural networks and two-phase flow models[J]. Nuclear Engineering and Design, 2001,204(1):87-100
- 13 苏永生, 王永生, 段向阳. 基于多传感器数据融合的喷水推进泵空化分类识别[J]. 振动与冲击,2012,31(18):93-96
- 14 DE GIORGI M G, BELLO D, FICARELLA A. An artificial neural networks approach to investigate cavitating flow regime at different temperatures[J]. Measurement,2014,47:971-981
- 15 曹玉良, 明廷锋, 贺国, 等. 基于深度学习的离心泵空化状态识别[J]. 西安交通大学学报, 2017(11):165-172
- 16 Zhang Zhen, Song Xu-dong, Ye Shu-ran, Wang Yi-wei, et al. Application of deep learning method to reynolds stress models of channel flow based on reduced-order modeling of dns data. Journal of Hydrodynamics(11)

Pressure prediction of cavitating hydrofoil surface based on convolution neural network

WANG Chang, YE Shu-ran, ZHANG Zhen, WANG Yi-wei

(Key laboratory for Mechanics in Fluid Solid Coupling System, Institute of Mechanics, Chinese Academy of Sciences, Beijing 100190, China

E-mail: wangc7631@163.com; wangyw@imech.ac.cn Tel: 15901175699)

Abstract: With the rapid development of artificial intelligence technologies such as neural network, the data-driven machine learning methods have been successfully applied in exploring the flow field identification, extraction, and reduced-order in complex hydrodynamic problems. Cavitation is a common hydrodynamic phenomenon that occurs in the field of hydraulic machinery and other fields. As the core problem of high-speed hydrodynamics, cloud-like cavitation flow has strong unsteady characteristics. Therefore, the data-driven identification method of unsteady multiphase flow fields is of great significance to hydraulic machinery and other fields. This paper aims to study a method for predicting the surface pressure of cavitation airfoil based on convolutional neural network. This data-driven method constructs a complete model of the hydrofoil surface pressure distribution by extracting the flowing features such as hydrofoil wake velocity and vacuole volume fraction in unsteady cloud cavitation flow field. Firstly, the cloud cavitation flow field of two-dimensional NACA0015 hydrofoil is numerically analyzed, and the data information of airfoil velocity field and pressure field under four different cavitation numbers are obtained. Then, a convolution neural network (CNN) prediction model is established, and the surface pressure coefficient C_p of cavitation hydrofoil are predicted by extracting and classifying the hydrofoil wake velocity U , vacuole volume fraction α and vacuole density ρ under different cavitation numbers. Finally, the comparative analysis of the CNN prediction results and CFD calculation results shows that the prediction method of the convolutional neural network has high accuracy for the identification of unsteady multiphase flow fields.

Key words: Machine learning; Convolutional Neural Network; Hydrofoil; Unsteady; Flow field identification