

基于深度神经网络的含运动边界非定常流场预测方法研究



韩仁坤^{1,2}, 杜焦喜^{1,2}, 刘子扬^{1,2}, 李立³, 陈刚^{1,2}

1. 西安交通大学 机械结构强度与振动国家重点实验室, 陕西 西安 710049

2. 西安交通大学 先进飞行器服役环境与控制陕西省重点实验室, 陕西 西安 710049

3. 航空工业计算技术研究所, 陕西 西安 710049

摘要: 针对飞行器设计过程中对流固耦合系统快速预测的需求, 探索基于数据驱动的非定常流场建模策略, 缩短流场演化求解耗时, 从而加快流固耦合系统模拟速度。流固耦合系统中流场演化求解部分等价于含运动边界的非定常流场演化。本文提出了一种基于神经网络的流场预测模型, 来学习并预测运动边界附近的非定常流场演化过程。此神经网络可以基于当前流场状态及边界运动信息预测出下一个时刻的流场状态。通过不同振动频率及振幅下的运动圆柱绕流问题, 测试了本文提出的神经网络模型的预测精度及泛化能力。神经网络的预测结果和计算流体力学仿真结果中流场结构吻合度较高, 且通过对预测的流场数据中边界上的压力积分得到的气动力也具有较高精度。测试结果展示了该神经网络模型具有良好的预测性能, 因此该方法可以用于快速、准确获得运动边界周围非定常流场状态。

关键词: 运动边界; 非定常; 神经网络; 深度学习; 快速预测

中图分类号: V211.3

文献标识码: A

DOI: 10.19452/j.issn1007-5453.2023.12.005

飞行器气动弹性问题是研究飞行器结构与气动力相互耦合关系, 是一种典型的流固耦合问题。工程实践中常使用计算流体力学(CFD)和计算结构动力学(CSD)耦合的策略模拟获得飞行器气动弹性响应过程。但是CFD/CSD耦合计算耗时严重, 特别是在需要反复迭代修改的飞行器初步设计阶段, 模拟耗时是让人难以接受的。气弹问题模拟中主要耗时过程是CFD求解流场演化的过程, 因此许多研究者尝试使用数据驱动的方法模拟流场系统, 实现流场的快速预测^[1], 从而减少整个耦合过程的模拟耗时, 如模态法、系统辨识法等。目前, 针对非线性较强的流固耦合问题, 仍缺乏结构运动影响下的高精度流场快速预测模型。

近年来, 迅速发展的深度神经网络技术依赖于其强大的非线性学习能力, 以及深度特征捕捉能力, 在流场建模问题中已经取得了诸多成功应用^[2-4]。深度神经网络在流体力学中的应用主要可分为三种方式: 第一种是学习流体力学控制方程中某些参数变化规律, 基于高精度数据校正控制方程, 以提高方程在其他问题求解中的精度, 如湍流模型

中雷诺应力项的学习^[5-6]; 第二种是学习流动工况与流场之间的演化关系, 给定流动工况神经网络即可预测出此刻流场状态, 快速实现流场高精度重构^[7-8]; 第三种是学习流动工况与宏观气动力之间的映射关系, 已知流动工况和几何外形可快速预测流场中结构受力情况^[9-10]。

流场重构类方法因能快速给出当前流场状态而备受关注。基于深度神经网络的定常流场重构^[7]通过构建翼型几何形状和流动工况至空间点处的流场信息之间的映射模型, 实现了对不同翼型绕流场的快速预测。非定常流场时空演化特征建模, 主要是通过流场降阶结合深度神经网络预测低维时间演化过程实现, 降阶方式包括本征正交分解(POD)降阶^[11]和神经网络降阶^[12]。通过求解流场在低维空间上的时空演化过程, 可极大缩短非定常流场时间推进模拟的耗时。

现阶段, 使用深度神经网络对非定常流场进行建模研究, 主要集中在固定边界绕流问题上。对于含运动边界非定常流场的建模, 流场演化不仅受流场自身特性影响, 还受结构运动的影响, 这增大了建模难度。多采用响应预测类方

收稿日期: 2023-06-16; 退修日期: 2023-10-09; 录用日期: 2023-11-03

基金项目: 航空科学基金(20200014070001)

引用格式: Han Renkun, Du Jiaoxi, Liu Ziyang, et al. Research on the prediction method of unsteady flow field with moving boundary based on deep neural network[J]. Aeronautical Science & Technology, 2023, 34(12): 37-42. 韩仁坤, 杜焦喜, 刘子扬, 等. 基于深度神经网络的含运动边界非定常流场预测方法研究[J]. 航空科学技术, 2023, 34(12): 37-42.

法,直接预测运动边界的受力情况^[13]。但此方法无法获得系统内部状态演化情况,不能应用于流动控制。Han Renkun等^[14]通过对长短时记忆(LSTM)神经单元内部结构的修改成功将运动边界位置信息引入神经网络中,实现了含运动边界的非定常流场深度学习建模。本文以此为基础,进一步改进边界运动信息引入方式,优化数据结构,从而提高模型预测精度,获得流场中运动物体更准确的受力情况。

1 方法

1.1 神经网络结构

含运动边界的非定常流场建模的关键是如何将边界运动信息引入神经网络中,使其能够同时学习到前一时刻流场的影响和边界运动的影响。本文仍采用卷积和LSTM相结合的方式构建非定常流场预测模型,如图1所示。整个预测模型中卷积层是为了捕捉流场深层结构特征,并降低流场维度,LSTM层则用于根据前一时刻流场特征预测下一时刻流场特征。




图1 神经网络框架

Fig.1 Neural network framework

图2中展示的是长短时记忆神经网络中一个神经元的结构,每个神经元都包含三个门控机制(遗忘门、记忆门和输出门),使数据有选择地输出,从而避免了梯度消失。(1)遗忘门 f_t :对上一个节点传进来的输入进行选择性地忘记;(2)记忆门 i_t :对上一个节点传进来的输入进行选择性地添加至单元状态 c_t ;(3)输出门 o_t :结合当前神经元状态决定上一个节点传进来的输入中哪些将会被当成当前神经元的输出。每层长短时记忆神经网络由一个或多个神经元组成,前一个神经元输出的神经元状态 c_{t-1} 和隐藏状态 h_{t-1} 将作为下一个神经元的输入,以实现时间维度上的连续预测。

本文建模的目的是基于前一个时刻的流场和结构运动信息预测下一时刻的流场状态。因此,将前一个时刻的流场状态作为LSTM层神经元的时序输入 x_t ,预测时刻的流场状态作为LSTM层的输出。为将结构运动引入神经网络中,本文使用结构运动速度作为LSTM层第一个神经元的单元状态 c_0 ,结构运动幅值作为第一个神经元的隐藏状态 h_0 。

这样保证了下一时刻的流场是在上一时刻流场信息和结构运动信息共同作用下的预测结果,使神经网络能够学习到两种数据对流场演化的影响。整个神经网络层布置及卷积核等超参数的设置见表1。输出尺寸中第一位为批次大小,中间两位为二维特征图像尺寸,最后一位为特征通道数。




图2 长短时记忆神经网络神经元

Fig.2 Long short term memory neuron

表1 神经网络结构参数

Table 1 Neural network structural parameters

层名	卷积核/滑动步长	输出尺寸
Inputs	—	32×128×128×3
Conv 1	3×3/2	32×64×64×4
Conv 2	3×3/2	32×32×32×8
Conv 3	3×3/2	32×16×16×16
Conv 4	3×3/2	32×8×8×32
Conv 5	3×3/2	32×4×4×64
LSTM	3×3/1	32×4×4×64
DeConv 1	3×3/2	32×8×8×32
DeConv 2	3×3/2	32×16×16×16
DeConv 3	3×3/2	32×32×32×8
DeConv 4	3×3/2	32×64×64×4
DeConv 5	3×3/2	32×128×128×3

1.2 数据准备

本文拟采用神经网络对二维强迫振动下圆柱周围非定常流场演化过程进行建模。通过求解如式(1)所示的无量纲化的二维不可压流体控制方程,得到流场演化过程所有时刻的空间场数据。基于组内开发程序,采用有限体积方法求解方程,空间离散格式为二阶Van Leer格式,时间推进方式为LU-SGS隐式方法。流场区域及圆柱振动形式如图3所示。圆柱直径为 $1D$,圆柱距入口及上下边界距离均为 $15D$ 、距出口为 $30D$ 。圆柱采用单自由度正弦振动,改变振幅和频率获得多组工况下的流动数据

$$\nabla \cdot u = 0$$

$$\frac{\partial u}{\partial t} + \nabla \cdot uu = -\nabla p + \frac{1}{Re} \nabla^2 u \quad (1)$$




图3 流场求解域示意图

Fig.3 Schematic diagram of flow solution domain

流场求解采用结构化网格,并且在结构边界周围采用O形网格,如图4所示。分别使用了网格量为12752个、23544个和45944个的三套网格进行测试,结果表明中型网格量求解升阻力与最密网格求解结果误差在1%以内,达到收敛状态,并在此网格上对比了时间步长的影响,时间步长设置为0.001可兼顾精度和效率。升阻力系数与试验结果的误差在4%以内,验证了仿真结果的可靠性。

基于结构化网格求解得到的流场数据为点数据格式,本文所采用的卷积神经网络所需要的数据格式为类似图像的二维像素数据,因此需要对模拟数据进行预处理,得到适应于神经网络的数据结构。本文采用将物面附近O形结构化网格沿径向展开的预处理方式,将O形分布数据展开至正交分布的数据,保留了原始CFD数据点之间的相对位置关系,避免了Han Renkun等^[14]在工作中使用投影法将CFD数据投影至均匀分布的笛卡儿网格点上而导致的弯曲物面表达能力不足、物面预测结果出现锯齿现象。




图4 流场求解结构化网格

Fig.4 Structured mesh for flow field simulation

1.3 神经网络的训练

神经网络的训练过程是一个参数寻优的过程,将损失函数作为优化目标,通过数据前向传播和误差反向传播不断优化神经网络中的权重参数,以达到最优的预测效果。本文使用华为公司推出的新一代深度学习框架MindSpore

构建神经网络模型,并利用其自动微分算法训练神经网络。损失函数采用的是如式(2)所示的均方根误差RMSE,采用Adam算法根据预测损失值逐步优化模型。

$$RMSE' = \sqrt{\frac{\sum_{i=1}^N (\psi_i^t - \psi_{o,i}^t)^2}{N}} \quad (2)$$

其中, ψ_i^t 和 $\psi_{o,i}^t$ 分别为第*i*个数据点的预测值和真实值;*N*为数据点个数。

2 结果及讨论

本文以二维均匀来流中正弦强迫振动圆柱非定常流场绕流为例,展示本文所提出的神经网络框架对含运动边界非定常流场演化的学习能力及预测精度。通过改变圆柱振动形式获得不同工况下的流场数据供神经网络学习,振动频率与圆柱不动时流场频率一致,在振动幅值维度选择振幅比为0.25、0.30、0.35、0.40和0.45,一共获得5组不同工况下的流场数据。以前4组数据作为训练数据集;以外插工况振幅比为0.45时的数据作为测试集,以检测训练完成的神经网络模型的预测精度及泛化能力。振幅比为0.45时的升力系数与振幅比为0.4时差距超过5%,且与训练数据中的升力系数区间的距离超过区间大小的40%,因此使用此状态的预测结果足以展示神经网络模型的泛化能力。

图5所示为基于4组训练数据训练完成的神经网络在振幅比为0.45的工况下的流场单步预测结果,预测流场均方根误差RMSE值小于0.01。流场中误差较大的区域主要存在于尾缘距物面较远位置,而在物面附近区域预测精度较高。这是由于较远区域内流场变化较为平缓,物面附近区域流场变化较为剧烈,因此物面附近预测结果是决定损失函数值大小的主要因素,网络参数主要用于提高对物面附近区域的预测精度,而对远场区域变化不敏感。而物面附近区域流场状态是工程设计中最关心的,因此本文所采用的方法具有一定的优势。图6中展示的是此刻表面压力预测值与真实值的对比,可以看出,预测值光滑且较为准确,这进一步验证了流场的预测精度。

在非定常流场持续预测过程中,采用循环预测的策略,将当前时刻流场预测结果作为下一时刻预测的输入数据。图7展示的是神经网络模型在仅给定初始流场条件及结构强迫振动形式的情况下,预测的一个振动周期内流场演化过程。预测流场分布形态符合物理规律,且光滑无锯齿。图8展示了多个周期内预测流场与真实流场之间的RMSE误差,误差值均小于0.02,且没有持续增长的现象。这证明神经网络模型掌握了非定常流场演化规律,对局部预测误




图5 单步流场预测结果

Fig.5 Single step flow field prediction results

差不敏感,预测过程中误差累计现象不明显。

通过积分每一时间步预测流场中物面压力可获得结构所受的升阻力。从图9中可以看出,预测结果与真实值幅值和频率均吻合较好,证明了本文提出的边界运动信息引入方式是有效的。且升阻力积分结果没有出现文献[14]中提到的不规则锯齿现象,证明了基于网格展开的数据结构比投影法具有更准确的物面压力分布表达能力。




图6 单步预测圆柱表面压力结果

Fig.6 Surface pressure of single step prediction

3 结束语

本文改进了一种基于神经网络模型的含运动边界的非

定常流场预测模型,通过优化运动边界引入形式和实用新型数据结构,模型预测精度和泛化性能得到了进一步提升。以单自由度正弦振动圆柱绕流为例,神经网络模型学习不同振动频率和振幅下的非定常流场演化过程,可在学习参数范围外完成对非定常流场演化过程的预测,结果表明神经网络模型具有较高的预测精度和较好的泛化性能。

下一阶段将围绕飞行器气弹设计进一步开展研究,探索二维翼型和三维机翼的流固耦合建模方法。如要实现流固耦合响应的准确预测,还需进一步提高流场预测精度,尤其是物面表面压力。另外,更有效的运动边界引入形式决定着流固耦合模型的参数泛化能力。因此,仍需要从精度和泛化性两个方面改进和完善神经网络模型。

AST

参考文献

- [1] Suzuki T, Chatellier L, David L. A few techniques to improve data-driven reduced-order simulations for unsteady flows[J]. Computers & Fluids, 2020, 201: 104455.
- [2] 王怡星,韩仁坤,刘子扬,等. 流体力学深度学习建模技术研究进展[J]. 航空学报, 2021, 42(4): 225-244.
Wang Yixing, Han Renkun, Liu Ziyang, et al. Progress of deep learning modeling technology for fluid mechanics[J]. Acta Aero-




图7 一个振动周期内流场预测结果

Fig.7 Prediction results of flow field within a vibration cycle




图8 整个振动过程中预测流场的RMSE误差

Fig.8 RMSE error prediction results during the vibration process




图9 整个振动过程中圆柱所受升力预测结果

Fig.9 Prediction results of the lift force on the cylinder during the vibration process

nautica et Astronautica Sinica, 2021, 42(4): 225-244. (in Chinese)

[3] 韩天依星,皮思源,胡姝瑶,等. 基于机器学习预测流场特征的

网格生成技术研究进展[J]. 航空科学技术, 2022, 33 (7): 30-45.

Han Tianyixing, Pi Siyuan, Hu Shuyao, et al. Progress of the grid generation based on flow features predicted by machine learning[J]. Aeronautical Science & Technology, 2022, 33(7): 30-45. (in Chinese)

[4] 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): 1-35.

Tang Zhigong, Zhu Linyang, Xiang Xinghao, et al. Some research progress and prospect of intelligent aerodynamics[J]. Acta Aerodynamica Sinica, 2023, 41(7): 1-35. (in Chinese)

[5] Li Jinping, Tang Denggao, Yi Chen, et al. Data-augmented turbulence modeling by reconstructing Reynolds stress discrepancies for adverse pressure gradient flows[J]. Physics of Fluids, 2022, 34 (4): 1-15.

[6] Tang Hongwei, Wang Yan, Wang Tongguang, et al. Data-driven Reynolds-averaged turbulence modeling with generalizable non-linear correction and uncertainty quantification using Bayesian deep learning[J]. Physics of Fluids, 2023, 35 (5): 055119.

[7] 曹晓峰,李鸿岩,郭承鹏,等. 基于深度学习的二维翼型流场重构技术研究[J]. 航空科学技术, 2022, 33 (7): 106-112.

Cao Xiaofeng, Li Hongyan, Guo Chengpeng, et al. Research on two-dimensional airfoil flow field reconstruction based on deep learning[J]. Aeronautical Science & Technology, 2022, 33

- (7): 106-112. (in Chinese)
- [8] Luo Z, Wang L, Xu J, et al. Flow reconstruction from sparse sensors based on reduced-order autoencoder state estimation [J]. *Physics of Fluids*, 2023, 35 (7): 075127.
- [9] Zhan Bowen, Han Zhonghua, Xu Chenzhou, et al. High-dimensional aerodynamic data modeling using a machine learning method based on a convolutional neural network[J]. *Advances in Aerodynamics*, 2022, 4 (1): 39.
- [10] Zuo K, Ye Z, Zhang W, et al. Fast aerodynamics prediction of laminar airfoils based on deep attention network[J]. *Physics of Fluids*, 2023, 35 (3): 037127.
- [11] Akbari S, Pawar S, San O. Numerical assessment of a noninvasive surrogate model based on recurrent neural networks and proper orthogonal decomposition: Rayleigh-Bénard convection[J]. *International Journal of Computational Fluid Dynamics*, 2023, 36 (7): 599-617.
- [12] Qu J, Zhao Y, Cai W. Nonlinear dynamic mode decomposition from time-resolving snapshots based on deep convolutional autoencoder[J]. *Physics of Fluids*, 2023, 35 (6): 065134.
- [13] Mohamed A, Wood D. Deep learning predictions of unsteady aerodynamic loads on an airfoil model pitched over the entire operating range[J]. *Physics of Fluids*, 2023, 35 (5): 053113.
- [14] Han Renkun, Zhang Zhong, Wang Yixing, et al. Hybrid deep neural network based prediction method for unsteady flows with moving boundary[J]. *Acta Mechanica Sinica*, 2021, 37 (10): 1557-1566.

Research on the Prediction Method of Unsteady Flow Field with Moving Boundary Based on Deep Neural Network

Han Renkun^{1,2}, Du Jiaoxi^{1,2}, Liu Ziyang^{1,2}, Li Li³, Chen Gang^{1,2}

1. State Key Laboratory for Strength and Vibration of Mechanical Structures, Xi'an Jiaotong University, Xi'an 710049, China

2. Shaanxi Key Laboratory for Environment and Control of Flight Vehicle, Xi'an Jiaotong University, Xi'an 710049, China

3. AVIC Aviation Computing Technology Research Institute, Xi'an 710049, China

Abstract: In order to meet the requirement of rapid prediction of fluid-structure interaction system in aircraft design, a data-driven unsteady flow field modeling strategy was explored to shorten the time spent on flow field evolution solution and accelerate the simulation speed of fluid-structure interaction system. The solution of flow field evolution in fluid-structure interaction system is partially equivalent to the evolution of unsteady flow field with moving boundary. This paper proposes a flow field prediction model based on neural networks to learn and predict the evolution of unsteady flow fields with moving boundaries. This neural network can predict the flow field at next timestep based on the current flow field and boundary motion information. The prediction accuracy and generalization ability of the proposed neural network model were tested by the flow around a moving cylinder under different vibration frequencies and amplitudes. The predicted flow fields of the neural network are in accordance with the computational fluid dynamics simulation results. The aerodynamic force obtained by integrating the pressure on the boundary of the predicted flow field data also has a high accuracy. The test results demonstrate that the good predictive performance of the neural network model, so this method can be used to quickly and accurately obtain the unsteady flow field state around the moving boundary.

Key Words: moving boundary; unsteady; neural network; deep learning; fast prediction

Received: 2023-06-16; **Revised:** 2023-10-09; **Accepted:** 2023-11-03

Foundation item: Aeronautical Science Foundation of China(20200014070001)