

基于深度学习的二维翼型流场重构技术研究



曹晓峰,李鸿岩,郭承鹏,王强,马海

中国航空工业空气动力研究院 高速高雷诺数气动航空科技重点实验室, 辽宁 沈阳 110034

摘要:基于深度学习方法的二维翼型流场重构能够克服传统风洞试验和计算流体力学模拟的缺点,在提高计算速度的同时保证计算精度。提出的深度学习通过模拟RANS方程对速度、压力和密度分布进行预测,最优模型可以达到平均压力、速度、密度误差为5%。该方法的单个算例计算时间约为1s,计算耗时约为常规求解器的0.66%。同时也验证了数据集大小对解的准确性的影响,随着数据集样本数目增大,解的准确性也逐步提高。为深度学习在计算流体力学中提供一个现实的二维流场预测应用场景,探讨了深度神经网络方法与气动领域相关问题的匹配度,后续将进一步通过精细化的几何外形表达与无损失的标签提取方法提高深度神经网络方法计算的可用性。

关键词:深度学习;流场重构;翼型;RANS;U-Net

中图分类号:V211.3

文献标识码:A

DOI: 10.19452/j.issn1007-5453.2022.07.012

翼型设计的最终结果直接决定了飞行器的品质与性能^[1],并直接影响到后续机翼设计工作的开展^[2]。因此在实际的工程应用中,寻找一种有效的方法能够快速准确地计算评估翼型的绕流场,辅助翼型优化设计显得十分必要。

传统的翼型流场及气动特性获取方法是通过风洞试验^[3-4]对初始翼型进行吹风试验,不断迭代,直到设计的翼型满足流场及气动特性要求为止。整个过程需要耗费巨大的人力与财力。随着计算技术的飞速发展,通过计算流体力学^[5](CFD)技术使翼型流场及气动特性的获取减少了对风洞试验的过多依赖,在一定程度上,降低了获取翼型流场的成本,提高了效率。为了减少比较耗时的CFD计算,有研究者提出使用代理模型来辅助风洞试验,提高效率。使用较多的代理模型有多项式响应面模型^[6]、人工神经网络模型^[7-8]和Kriging模型^[9-10]等。基于代理模型的翼型流场及气动特性计算具有周期短、费用低的优点。因此,将代理模型应用到翼型设计中,辅助风洞试验,可以缩短翼型设计的周期、降低翼型设计的研发费用,该方法已成为目前翼型研究设计的重要发展方向。

近年来,随着人工智能技术的发展,人工智能技术逐渐应用到空气动力学研究领域。深度学习技术利用海量训练数据,使用深层次的网络结构,能够实现自动、高效和准确的

多层次特征提取,其可以快速建立从输入数据到目标数据之间的映射关系,具有极强的归纳学习能力。深度学习技术在建模完成后具有计算速度快、计算量小、计算效率高、计算准确的优点。深度学习技术在航空领域逐步拓展。在直升机领域人工智能可以进行减振降噪与辅助控制^[11],在雷达目标检测领域利用深度学习已经实现了对雷达背景的分类^[12];在颤振信号处理方向^[13-14]与低速不可压缩流状态下的流场重构^[15]等领域中已经有了初步的应用探索。

本文建立了一个从数据前处理、深度神经网络计算、计算结果后处理的全流程方法,包括数据集自动生成、批量化生成、计算结果可视化等。基于深度学习技术对二维翼型的高速流场计算结果进行建模,建立从二维翼型、来流速度、迎角速度、密度、压力等流动参数间的直接映射,可快速获得当前翼型的流场分布,其工作流程如图1所示。

1 方法

1.1 数据集生成

1.1.1 翼型几何表达方法

UIUC数据库中包含1200种不同翼型,将UIUC数据库获取其翼型参数文件进行可视化,如图2(a)所示。本文所使

收稿日期: 2022-02-15; 退修日期: 2022-04-20; 录用日期: 2022-05-25

引用格式: 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(07): 106-112. 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(07): 106-112.




图1 二维翼型流程重构工作流程

Fig. 1 The workflow of 2D airfoil field reconstruction

用的翼型几何表达方法借鉴了计算机视觉领域图像分割任务中的掩膜版标签(Mask)形式,将翼型内外以0、1进行区分,1表示翼型轮廓曲线内区域,0表示流体流动计算区域,该方法能够在对翼型几何形状进行描述的同时区分流体流动区域与非流动区域,翼型几何表达的Mask形式如图2(b)所示。




图2 翼型几何形状与Mask表达(以GOE611翼型为例)

Fig.2 Airfoil geometry and Mask expression
(take GOE611 as an example)

1.1.2 数据集生成

神经网络训练的数据来自航空工业气动院自研计算流体力学软件UNSMB的数值仿真计算结果。给定来流速度、迎角和气压,通过CFD计算求解翼型周围可压缩流的速度、压力和密度分布,来流速度范围为150~200m/s,迎角范围为 $\pm 5^\circ$ 。从UIUC数据库中获取了1200种不同翼型,用于根据上述范围内随机取样自由流与迎角生成输入数据。首先使用PointWise软件自动生成翼型网格,如图3所示。随后根据自由流、迎角与压力使用UNSMB软件计算求解。对于当前问题而言,翼型周围和尾流区域的流场是关键的,利用 128×128 的网格对CFD的计算结果进行筛选插值,将

UNSMB计算后的数据映射到 128×128 的矩阵中用于制作卷积神经网络的数据集,共生成5700个数据样例。数据集可视化后示例如图4所示。




图3 GOE611翼型计算网格

Fig.3 Numerical mesh of airfoil GOE611

数据集按照9:1的比例划分为训练集与测试集。训练集用于模型训练与验证,在进行模型训练时,随机从训练集中选定固定样本数用于模型验证,其余样本用于模型训练。验证集用来评估模型在训练过程中的损失值收敛性与训练过程中模型的准确性,可以依据训练模型在验证集上的损失值与准确性进行模型参数保存。测试集用于对已保存的模型进行性能评估。

由于神经网络模型的输入限制,远场速度分量、压力与翼型几何外形在输入神经网络前,都需进行尺寸重置,以确保输入神经网络模型的矩阵大小为 128×128 。同时,用于模型训练的数据标签大小也统一为 128×128 ,便于计算模型预测值与真实标签值之间的均方误差(MSE)。所有输入到深度神经网络的矩阵均统一进行归一化与均值化操作。

1.2 神经网络结构

本文的神经网络模型基于U-Net结构^[16],U-Net网络可以将空间信息转换为卷积层可提取的特征,同时引入了从输入到输出通道间的跳跃连接方式,可以确保输出层中的信息能够被神经网络判别器所利用。我们所使用的神经网络是一种改进后的U-Net变体。




图4 数据集示例(横、纵坐标为采样点序号)

Fig. 4 The example of dataset (GOE 611) (the abscissa and ordinate are the serial numbers of sampling points)

该U-Net网络是一种特殊的编码解码结构体。在编码部分,对图像进行跨步卷积逐步降采样,允许网络在不断增长的特征通道中提取越来越大规模和抽象的信息,通过特征拼接结构将所有通道从编码分支连接到对应的解码部分,有效地将每个解码块的通道数量加倍。网络中的每一

个部分都包括一个卷积层、一个归一化层与一个非线性激活函数层。改进后的U-Net网络使用了7个卷积模块,编码过程中使用了斜率为0.2的ReLU函数,在解码层中使用了规则的ReLU目标函数,目标函数的期望维数为 $128 \times 128 \times 4$ 。网络结构架构如图5所示。




图5 深度神经网络架构

Fig. 5 The framework of deep learning net

1.3 模型训练与评估

基于Pytorch深度神经网络框架搭建了变种U-Net网络。在训练过程中使用Adam优化器与L1正则进行网络结构训练。模型训练过程中学习率为0.0006,迭代次数为10000,dropout随机丢弃单元概率为0.5。模型在训练过程中的平均绝对误差降低到0.00436时,判定模型训练收敛,进行模型保存。

深度神经网络训练基于单台工作站。CPU为Intel Xeon (R) Silver 4210R CPU (2.40GHz, 10 核心)×2, 64G 内存, GPU为NVIDIA Quadro RTX 4000, 基于Ubuntu 20.04.3 LTS。

模型测试共使用570个样本作为测试集。使用速度、压力和密度的平均均方误差(MSE)和各单独物理量的均方误差MSE判断模型性能。均方误差是指参数估计值与参数真值之差平方的期望值。MSE可以评价数据的变化程度,MSE越小说明预测模型描述试验数据具有更好的精确度。MSE的计算公式如式(1)所示

$$MSE = \frac{1}{N} \sum_{i=1}^N (O_i - P_i)^2 \quad (1)$$

式中: O_i 为目标值, P_i 为预测值。

2 测试结果

分别使用不同大小的数据集对深度神经网络模型进行模型训练与验证,得到了两个不同的模型参数文件。对两个不同的模型进行模型测试。在数据集大小为3000的数据集上,

深度神经网络模型的表现较差,平均MSE为10.4082%、密度MSE为2.3965%、 V_x MSE为30.3324%、 V_y MSE为2.4487%、压力MSE为6.4555%。在数据集大小为5700的数据集上,深度神经网络训练模型表现较好,模型的平均MSE为5.0004%、密度MSE为0.9614%、 V_x MSE为14.7701%、 V_y MSE为0.8428%、压力MSE为3.4273%。模型的测试结果见表1。

随着数据集的扩充,模型的测试结果得到了较好的提升,平均MSE由10%降到了5%,表明数据集的扩充可以带来模型准确率的提升。当数据样本较少时,深度神经网络无法从数据中学习更细致准确的流场特征。随着数据集样本的扩充,也带来了详细的各流场分量的MSE的降低,进一步表明数据集的大小对于深度神经网络模型的权重参数学习有着重要的作用,符合常规的随着数据集的扩增深度神经网络建模的准确率逐渐提升的规律。图6所示为真实流场与深度学习预测流场对比。

深度神经网络方法在保证计算精度的基础上,大大提高了计算效率。在模型测试阶段对深度神经网络的单个算例计算时间进行统计,对比UNSMB的单个算例计算时间有较大的速度提升。深度神经网络计算的时间约为常规CFD求解器的1/150,单个算例计算时间统计见表2。

3 结束语

本文中模型的计算准确度较好,相对误差在5%左右。然




图6 CFD计算结果与深度学习计算结果对比(GOE611,自由流速度 174m/s,迎角 1.871°)

Fig.6 Comparison between CFD results and deep learning results(GOE611, freestream 174m/s, $\alpha=1.871^\circ$)

表 1 深度神经网络模型测试结果

Table 1 The result of model test

数据集大小	密度 MSE	V_x MSE	V_y MSE	压力 MSE	平均 MSE
3000	0.023965	0.303324	0.024487	0.064555	0.104082
5700	0.009614	0.147701	0.008428	0.034273	0.050004

表 2 单个算例计算时间对比

Table 2 Comparison of calculation time of single numerical example

	CFD求解器	深度神经网络
时间/s	119	0.81

而,如何进一步减少这一误差是一个重要的问题,当前在数据集扩充后,模型的预测准确度得到了提升,但无限的增加训练数据的大小在达到一定精度后并不会再对模型的准确度有所提升。后续需要进一步进行网络结构优化与方法优化。

任何情况下,模型的预测结果都不是完全与CFD计算结果相同的。误差通常表现在机翼后面尾迹的流场变化。且速度分量 V_x 的相对误差较之密度、 V_y 和压强偏大。这可能是由于模型从当前数据集中所提取的新信息较少,可以考虑引入其他翼型库对模型进行再训练,以提高模型的泛化能力。尽管预测结果与真实流场之间存在相对误差,但从预测可视化结果来看,本文预测的流场趋势基本与真实流场的趋势是相同的。

深度神经网络模型在来流速度为150~200m/s,迎角为 $\pm 5^\circ$ 的速度、压力、密度流场重构的平均MSE达到了5.0003%,在解的准确性上有着较好的表现。本文提出的基于卷积神经网络的二维翼型流场重构方法,可以根据当前来流条件快速获取翼型周围流场,验证了深度学习算法在气动领域流场求解中的应用,表明深度学习算法在快速CFD求解上的可行性,深度学习算法可以有效提高翼型流场求解的效率。

当前工作是深度学习技术在气动研究领域的初步探索,探讨深度神经网络算法与CFD气动问题求解的匹配度。后续可通过更细致的几何外形描述方法(如点云、SDF方法)建立流场与几何外形的映射;进一步区分流场标签中的近场与远场,建立近场标签,避免插值带来的精度损失,建立更为精细化的映射关系。

AST

参考文献

[1] 阎超,甘文彪. 大型飞机气动设计中的CFD技术[J]. 航空制造技术,2010(14):70-73.

Yan Chao, Gan Wenbiao. CFD technology in aerodynamic design of large aircraft [J]. Aeronautical Manufacturing Technology, 2010 (14): 70 - 73. (in Chinese)

- [2] 田宇. 大型飞机气动设计[J]. 航空科学技术, 2007 (1):32-34.
Tian Yu. Aerodynamic design of large aircraft [J]. Aeronautical Science & Technology, 2007 (1): 32-34. (in Chinese)
- [3] 尹迪义, 竹朝霞, 惠增宏, 等. 翼型风洞试验模型姿态角的测量与控制[J]. 实验流体力学, 2001 (1): 70-74.
Yin Diyi, Zhu Zhaoxia, Hui Zenghong, et al. Measurement and control of attitude angle of airfoil wind tunnel experimental model [J]. Journal of Experiments in Fluid Mechanics, 2001 (1): 70-74. (in Chinese)
- [4] 解亚军, 叶正寅, 高永卫. 翼型风洞试验侧壁附面层控制技术研究[J]. 弹箭与制导学报, 2009, 28(6): 205-207.
Xie Yajun, Ye Zhengyin, Gao Yongwei. Research on control technology of sidewall boundary layer in airfoil wind tunnel experiment [J]. Journal of Projectiles, Rockets, Missiles and Guidance, 2009, 28 (6): 205-207. (in Chinese)
- [5] 王福军. 计算流体力学分析: CFD软件原理与应用[M]. 北京: 清华大学出版社, 2004.
Wang Fujun. Computational fluid dynamics analysis: Principle and application of CFD software [M]. Beijing: Tsinghua University Press, 2004. (in Chinese)
- [6] 刘明, 李文辉, 黄福贵. 多项式响应面代理模型在直升机飞行性能计算中的应用[J]. 直升机技术, 2013(2):20-23.
Liu Ming, Li Wenhui, Huang Fugui. Application of polynomial response surface proxy model in helicopter flight performance calculation [J]. Helicopter Technology, 2013(2):20-23. (in Chinese)
- [7] 朱莉, 高正红. 基于神经网络的翼型优化设计方法研究[J]. 航空计算技术, 2007, 37(3):33-36.
Zhu Li, Gao Zhenghong. Research on optimization design method of Airfoil Based on neural network [J]. Aeronautical Computing Technology, 2007, 37 (3): 33-36. (in Chinese)
- [8] Hacıoglu A. Fast evolutionary algorithm for airfoil design via neural network[J]. AIAA Journal, 2007, 45(9):2196-2203.
- [9] 任庆祝, 宋文萍. 基于Kriging模型的翼型多目标气动优化设计研究[J]. 航空计算技术, 2009, 39(3):77-82.
Ren Qingzhu, Song Wenping. Research on multi-objective aerodynamic optimization design of Airfoil Based on Kriging model [J]. Aeronautical Computing Technology, 2009, 39 (3):

- 77-82.(in Chinese)
- [10] 王晓锋, 席光. 基于 Kriging 模型的翼型气动性能优化设计[J]. 航空学报, 2005, 26(5):545-549.
Wang Xiaofeng, Xi Guang. Aerodynamic performance optimization design of Airfoil Based on Kriging model [J]. Acta Aeronautica et Astronautica Sinica, 2005, 26 (5): 545-549.(in Chinese)
- [11] 吴明忠, 刘永志. 人工智能技术在直升机领域的应用及发展展望[J]. 航空科学技术, 2021, 32(1):29-34.
Wu Mingzhong, Liu Yongzhi. Application and development prospect of AI technology in helicopter field[J]. Aeronautical Science & Technology, 2021, 32(1):29-34.(in Chinese)
- [12] 宋婷, 贺丰收, 程宇峰. 深度学习技术在雷达目标检测中的研究进展[J]. 航空科学技术, 2020, 31(10):12-20.
Song Ting, He Fengshou, Cheng Yufeng. Research progress of deep learning technology in radar target detection[J]. Aeronautical Science & Technology, 2020, 31(10):12-20.(in Chinese)
- [13] Li Kai, Kou Jiaqing, Zhang Weiwei. Deep neural network for unsteady aerodynamic and aeroelastic modeling across multiple mach numbers[J]. Nonlinear Dynamics, 2019, 96(3): 2157-2177.
- [14] Duan Shiqiang, Zheng Hua, Liu Junhao. A novel classification method for flutter signals based on the CNN and STFT[J]. International Journal of Aerospace Engineering, 2019(5):1-8.
- [15] Thuerey N, Wei Benow K, Prantl L, et al. Deep learning methods for Reynolds-averaged Navier-Stokes simulations of airfoil flows [J]. AIAA Journal, 2020, 58(1):25-36.
- [16] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation[C]//International Conference on Medical image computing and computer-assisted intervention. Springer, Cham, 2015:234-241.

Research on Two-Dimensional Airfoil Flow Field Reconstruction Based on Deep Learning

Cao Xiaofeng, Li Hongyan, Guo Chengpeng, Wang Qiang, Ma Hai

Aviation Key Laboratory of Science and Technology on Aerodynamics of High Speed and High Reynolds Number, AVIC Aerodynamics Research Institute, Shenyang 110034, China

Abstract: The reconstruction of two-dimensional airfoil flow field based on depth learning method can overcome the shortcomings of traditional wind tunnel test and computational fluid dynamics simulation, improve the calculation speed and ensure the calculation accuracy. The proposed deep learning method simulates the RANS equation in the compressible flow state, and predicts the velocity, pressure and density distribution around the airfoil according to the incoming flow conditions. The optimal model can achieve an average pressure, velocity and density error of 5%. The calculation time of a single example of this method is about 1s, and the calculation time is about 0.66% of that of the conventional solver. At the same time, the influence of the size of the data set on the accuracy of the solution is also verified. With the increase of the number of samples in the data set, the accuracy of the solution is also gradually improved. In order to provide a realistic two-dimensional flow field prediction application scenario for the depth learning method in computational fluid dynamics, the matching degree between the depth neural network method and the problems related to the aerodynamic field is discussed. In the follow-up, the calculation usability of the depth neural network method will be further improved through the refined geometric shape expression and the lossless label extraction method.

Key Words: deep learning; flow field reconstruction; airfoil; RANS; U-Net