

DOI:10.16356/j.1005-2615.2024.02.007

基于 UNet 的翼型可压缩流场机器学习推理方法

朱智杰, 赵国庆, 高远, 招启军

(南京航空航天大学直升机动力学全国重点实验室, 南京 210016)

摘要: 为进一步提升高雷诺数、大迎角 (Angle of attack, AoA) 和高马赫数下的翼型可压缩流场预测精度和效率, 本文提出了一种基于坐标转换方法和 UNet 神经网络的机器学习推理方法。首先, 提出了用于数据前处理的坐标转换方法, 将计算流体力学中的物理量和网格信息转换成神经网络空间信息, 使流场信息的分布更符合神经网络的输入要求。其次, 建立了新型深度 UNet 神经网络, 使模型学习到翼型流场精细复杂的局部流动特征。本文将两种方法结合, 建立了翼型可压缩流场机器学习推理方法, 得到快速高精度的推理模型。最后, 对不同种类翼型的流场与气动力进行预测分析, 并传统机器学习方法预测的结果进行比较。结果表明, 本文提出的机器学习推理方法能够较好地预测翼型的可压缩流场, 并且能够更好地捕捉高雷诺数下的复杂流动行为以及预测大迎角、高马赫数条件下的流动分离和激波现象。

关键词: UNet; 机器学习; 坐标转换; 翼型; 流动分离; 激波

中图分类号: V211.52

文献标志码: A

文章编号: 1005-2615(2024)02-0253-11

Compressible Flowfields Machine Learning Inference Method for Airfoil Based on UNet

ZHU Zhijie, ZHAO Guoqing, GAO Yuan, ZHAO Qijun

(National Key Laboratory of Helicopter Aeromechanics, Nanjing University of Aeronautics & Astronautics, Nanjing 210016, China)

Abstract: In order to further improve the accuracy and efficiency of predicted compressible flowfields around airfoils at high Reynolds number, large angle of attack (AoA), and high Mach numbers, a machine learning inference method based on coordinate transformation method and UNet neural network is proposed. Firstly, a novel coordinate transformation method for data pre-processing is developed. This method transforms physical quantities and grid information in computational fluid dynamics into spatial information of neural network, making the distribution of flowfield information more in line with the input requirements of the neural network. Secondly, an improved deep UNet neural network is established, allowing the model to learn the fine and complex localized flow characteristics of the airfoil flowfield. The two innovative methods are combined to establish a machine learning inference method for the compressible flowfield of airfoils, and a fast and high-precision inference model is obtained. Finally, the flowfields and aerodynamic forces of different types of airfoils are predicted and analyzed, and results are compared with those from traditional machine learning method. The results show that the machine learning inference method proposed in this paper can better predict the compressible flowfield of airfoils, and can better capture the complex flow behavior at high Reynolds numbers, and predict the flow separation and shock waves phenomena under high Mach numbers with large AoA.

基金项目: 国家自然科学基金(12072156); 直升机动力学全国重点实验室基金(61422202103); 江苏高校优势学科建设工程项目。

收稿日期: 2023-10-19; **修订日期:** 2024-01-31

通信作者: 招启军, 男, 教授, 博士生导师, E-mail: zhaqijun@nuaa.edu.cn。

引用格式: 朱智杰, 赵国庆, 高远, 等. 基于 UNet 的翼型可压缩流场机器学习推理方法[J]. 南京航空航天大学学报, 2024, 56(2): 253-263. ZHU Zhijie, ZHAO Guoqing, GAO Yuan, et al. Compressible flowfields machine learning inference method for airfoil based on UNet[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2024, 56(2): 253-263.

Key words: UNet; machine learning; coordinate transformation; airfoil; flow separation; shock wave

随着直升机飞行速度的提升,直升机旋翼气动环境愈发复杂,翼型作为旋翼的基本单元,其分离流动、转捩流动以及激波/边界层干扰的准确快速预测成为直升机旋翼/翼型设计中的新难题。伴随着计算机硬件和软件技术的进步,翼型流场和气动力系数的主要获取方式由试验技术和理论分析逐渐转变为数值计算和数据科学^[1]。在直升机旋翼/翼型设计过程中,由于风洞试验技术严重依赖于试验人员的经验,且试验设计与过程复杂、持续时间长和成本高,只将其作为验证手段。鉴于CFD方法的灵活性和便捷性,其被广泛应用于设计、优化过程。大规模、多批次的数值模拟为直升机设计提供了大量的翼型或飞行器气动流场数据。但是CFD方法仍然存在局限性,高速直升机的发展要求其旋翼流场和气动力计算愈发精细化和复杂化,这就导致CFD计算过程中设置了大量的网格和迭代步,因此CFD计算成为了直升机旋翼设计过程中最消耗计算资源和时间的步骤^[2-4]。研究人员不断地尝试发展新方法和新技术来改善这种困局^[5]。

近些年来,机器学习的发展出现一个新高潮,在流体力学中的应用也取得了成功^[6]。以卷积神经网络(Convolutional neural network, CNN)为代表的机器学习方法在翼型流场模拟等工业实践中逐步凸显出其重要地位。文献[7]利用CNN对二维汽车和三维半球模型中的非均匀层流进行实时预测,该方法与传统的计算流体力学模拟相比,可以提供比GPU加速格子玻尔兹曼方法(Lattice Boltzmann method, LBM)求解器快2个数量级、比基于CPU的LBM求解器快4个数量级的求解速度。相对于LBM方法,CNN方法在二维汽车测试集中平均相对误差不超过17%。虽然CNN方法预测速度很快,但其精度还无法满足工业需求。文献[8]发展了一种基于Encoder-process-decoder架构的多尺度图神经网络模型进行流场预测,相对于传统CNN方法,此模型在翼型流场和圆柱绕流预测任务中有更好的精度表现。然而模型的预测结果显示出不连续和不现实的速度和压力分布,预测流场缺乏光滑的物理特征。主要原因是为了保持图在不同尺度上的连通性,需要使用稀疏矩阵乘法,这带来了额外的计算开销和非物理一致性。在更为复杂的翼型可压缩流场预测中,需要用到更适合的模型和算法,而UNet以其能够保证流场具有缩放不变性和高分辨率特征精度,成为更合适的选择。文献[9]探讨了深度学习模型推断Reynolds

average Navier-Stokes(RANS)解的准确性,重点分析了UNet网络架构预测翼型不可压缩流场的有效性。其模型训练用的流场数据均来自OpenFOAM中RANS方法的数值模拟。研究发现,训练数据的大小和权重对模型预测的准确性有影响。最优训练策略下得到的模型,在测试集中进行预测分析,预测流场的平均相对压力和速度误差均小于3%。其结果证明在翼型流场预测中,选择合适的模型,采用优秀的训练策略,可以基于数据驱动方法得到快速高精度的机器学习流场推理模型。文献[10]提出了一种使用监督神经网络预测二维层流中任意形状障碍物的速度和压力场的方法。其采用贝塞尔曲线构建了一个随机的障碍外型数据集,并采用CFD方法模拟计算每个障碍物的外型流场,使用流场中的压力和速度信息训练各种UNet神经网络架构。最终证明了基于数据集的丰富几何特征,所训练的神经网络模型具有很强的泛化性,其预测能力在物理上具有可解释性。

尽管这些成果充分证明了在翼型流场预测中使用机器学习方法(以深度UNet为代表的神经网络架构)的巨大优势,但是想要达到工程级别的高精度和高鲁棒性仍然面临很大挑战。具体来说,之前的大多数研究中,神经网络的输入大都使用辅助笛卡尔网格插值方法进行流场数据处理,并且输入到神经网络的几何边界信息都是用符号距离函数或二进制掩码表示的,由此造成了神经网络模型缺少泛化性、对分离流动、转捩流动以及激波/边界层流动预测较差和鲁棒性差等缺点。

为进一步改善这些劣势,实现不同来流工况下的翼型可压缩流场快速高精度预测,本文提出了一种CFD计算坐标与神经网络坐标变换方法用于数据预处理,发展了一种深度UNet神经网络方法用于提取流场高级特征,通过两方法结合开展了翼型可压缩流场高效推理方法研究,并通过多个实例说明了所建立模型的快速高精度推理能力,通过泛化性测试说明了模型的优秀泛化能力。

1 方 法

本文分3个步骤建立高效的推理方法,如图1所示。(1)生成流场数据。首先生成翼型网络,采用高可靠度的CFD数值模拟方法,得到二维翼型流场信息,初步建立流场数据集。(2)建立数据库。建立坐标转换方法,将翼型、来流、网格和流场信息分布方式转换为笛卡尔网格形式,使流场信息分布

更加符合计算机视觉类深度神经网络的输入规范,并将数据归一化,得到适用于神经网络的数据库。
(3)训练深度UNet。建立新型深度UNet神经网络,并采用数据库进行模型训练,得到快速高精度的可压缩一下流场推理模型。

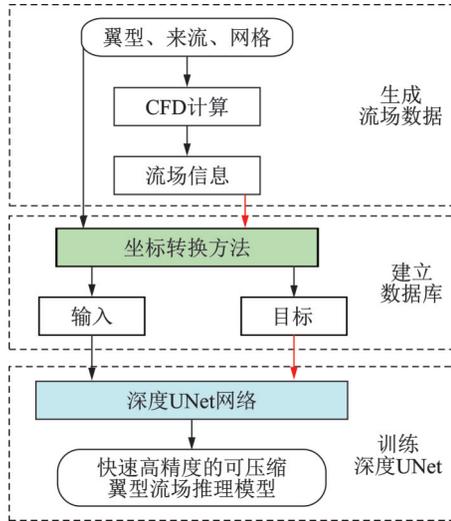


图1 推理方法建立流程

Fig.1 Process of reference method

1.1 学习任务推理

本文研究的目的是采用UNet神经网络架构进行二维翼型可压缩流场的RANS解的快速高精度推理。在本文中,无量纲RANS方程组用张量标记法表示为

$$\frac{\partial \rho u_i}{\partial x_i} = 0 \quad (1)$$

$$\frac{\partial \rho u_i u_j}{\partial x_j} = -\frac{\partial p}{\partial x_i} + \frac{\partial \tau_{x_i x_j}}{\partial x_j} \quad (2)$$

$$\frac{\partial (\rho E + p) u_i}{\partial x_i} = \frac{\partial (-q_i + u_j \tau_{x_i x_j})}{\partial x_i} \quad (3)$$

式中: $\tau_{x_i x_j}$ 和 q_i 为剪切应力项(Stokes假设)和热量通量项,控制基本方程组引入 Re_∞ 、 Ma_∞ 和 Pr 三个无量纲数,具体表示为

$$\tau_{x_i x_j} = (\mu + \mu_T) \frac{Ma_\infty}{Re_\infty} \left[\left(\frac{\partial u_i}{\partial x_j} + \frac{\partial u_j}{\partial x_i} \right) - \frac{2}{3} \frac{\partial u_k}{\partial x_k} \delta_{ij} \right] \quad (4)$$

$$q_i = -\left(\frac{\mu}{Pr} + \frac{\mu_T}{Pr_T} \right) \frac{Ma_\infty}{Re_\infty (\gamma - 1)} \frac{\partial \Theta}{\partial x_i} \quad (5)$$

式中:雷诺数定义为 $Re_\infty = \rho_\infty \sqrt{u_\infty^2 + v_\infty^2} c / \mu_\infty$, c 为翼型弦长, $\gamma = 1.4$ 为空气的比热容系数,层流黏度 μ 分布由萨瑟兰定律得到,湍流黏度 μ_T 由S-A(Spalart-Allmaras)和两方程 $k-\omega$ SST湍流模型决定,层流普朗特常数 $Pr = 0.72$ 和湍流普朗特常数 $Pr_T = 0.90$ ^[12]。

本文中定义初始条件 I 、网格信息 N 、流场求解器 f 和流场基本信息 F 及其关系为

$$I = [Ma_\infty, AoA_\infty, Re_\infty] \quad (6)$$

$$F = [\rho, \rho, u, v] \quad (7)$$

$$F = f(I, N) \quad (8)$$

可以将机器学习任务定义为寻找一个函数 \hat{f} ,此函数表示为初始条件 I 、网格信息 N 与流场 F 的映射关系。因此,本文提出一种机器学习方法,能够表示出这个高维非线性函数关系 $\hat{F} = \hat{f}(I, N, \omega)$,且函数 \hat{f} 可以将 I 和 N 快速准确地映射到 \hat{F} ,还需保证预测流场逼近数值模拟结果,即 $\hat{F} \rightarrow F^{(6)}$ 。这是一种基于数据驱动的监督学习方法, ω 为机器学习内置参数,本文中的机器学习训练过程可以表示为

$$\arg \min_{\omega} \left| f(I, N), \hat{f}(I, N, \omega) \right|_{L1} \quad (9)$$

1.2 CFD方法与验证

本文使用的流场数据来源于CFD计算,为保证翼型流场求解器的稳定性和流场数据的可靠性,本文通过求解椭圆型泊松方程来生成围绕翼型的C形结构网格^[11],并使用CLORNS代码进行流场计算^[12]。图2给出了围绕NACA0012翼型的C形网格,从图中可以看出翼型网格具有良好的正交性和贴体性。

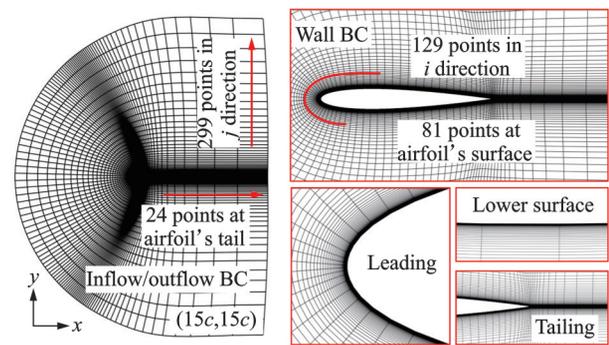


图2 围绕NACA0012翼型的C形网格

Fig.2 C-type grid around NACA0012 airfoil

本文中使用的计算域设置均如图2所示,在距离翼型约 $15c$ 处施加一维黎曼不变量的流入/流出边界条件(Boundary condition, BC),设置壁面第一层网格单元高度为 $1.0 \times 10^{-5}c$ 以保证 $y^+ < 1$ 。

图3给出了不同翼型压强系数 C_p 的CFD数值模拟结果和试验值^[13]的对比,从图中可以看出:本文的CLORNS数值模拟计算值与试验值吻合度较好,且相对于其他CFD求解器(CFL3D^[14])更优秀,表明本文所建立的训练数据集可靠稳定。

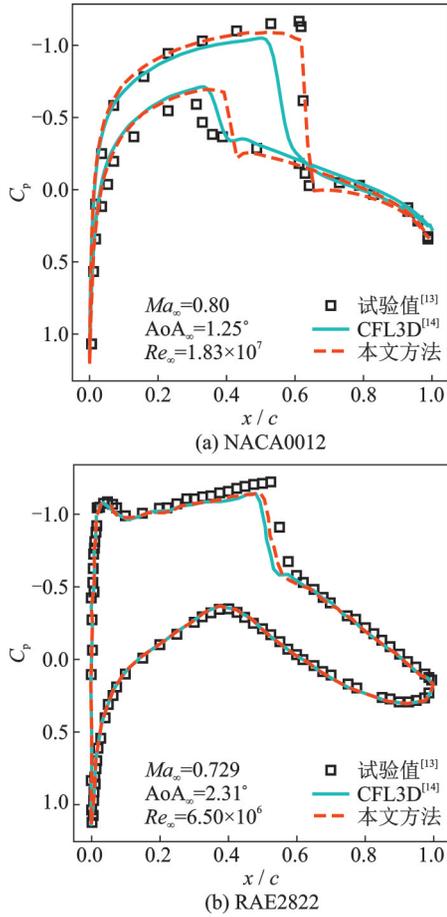


图3 翼型压力系数数值模拟及试验值与本文方法结果对比
Fig.3 Comparison among numerical simulation value, experimental value, and result of the paper method of airfoil pressure coefficient

1.3 数据预处理

考虑到UNet架构是专门为计算机视觉领域设计的神经网络架构,其输入信息在二维空间上符合笛卡尔坐标分布,因此需要对流场进行坐标变换,将包含有翼型外型信息的流场转换为符合UNet架构输入规范的格式。本文定义变换矩阵

$$T = \begin{bmatrix} \partial_x \xi & \partial_y \xi \\ \partial_x \eta & \partial_y \eta \end{bmatrix} = \begin{bmatrix} \partial_{\xi} x & \partial_{\eta} x \\ \partial_{\xi} y & \partial_{\eta} y \end{bmatrix}^{-1} \quad (10)$$

并对计算空间内的坐标信息做归一化处理,定义 $\xi = (i-1)/(i_{\max}-1)$ 和 $\eta = (j-1)/(j_{\max}-1)^{[12]}$ 。其中, (i, j) 为 (x, y) 坐标系下的坐标序号,通过坐标变换,可以建立CFD空间坐标和神经网络计算空间坐标中物理量的坐标转换方法,如图4(a)所示的RAE2822翼型CFD空间和神经网络空间转换方法示意图,左边为CFD计算空间坐标(即 (x, y) 坐标下),右边为神经网络空间(即 (ξ, η) 坐标下,其中 $\xi, \eta \in (0, 1)$)。如图4(b)所示,基于坐标转换方法,输入到神经网络的流体数据分布更加均衡,边界层流动和翼型变化能够更清晰地展示出

来,使神经网络能够学习到更多的复杂流动特征,从而获得更优异的非线性拟合效果。

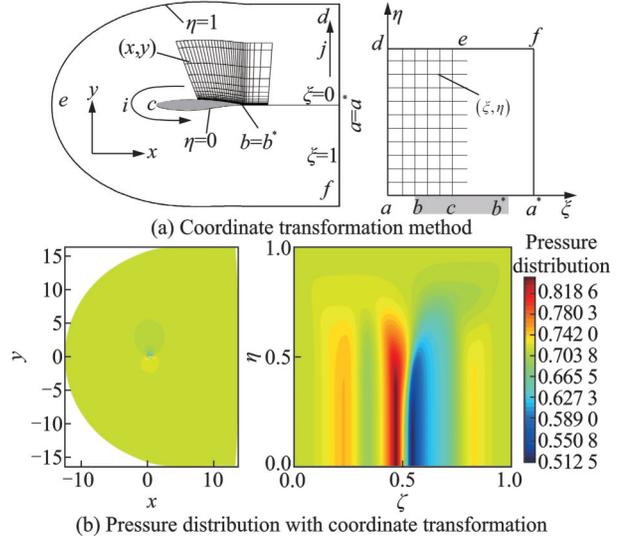


图4 RAE2822翼型空间转换方法
Fig.4 Space transformation method of RAE2822 airfoil

在数值方法求解中,对于给定的自由来流和翼型,可以有无限多的网格形式,但是,在真实情况下,连续空间中的流场解唯一。从数据科学的角度来看,本文所建立的快速推理方法并不需要如式(11, 12)所列这么多的学习参数。对于本文所提出的机器学习推理方法,输入数据库中流体动力学控制方程的离散解高度依赖于CFD网格,要保证模型能够学习到流动的局部特征、边界层流动以及进行完整的流场RANS解推理需要将坐标变换矩阵的全部参数作为输入引入到 $\hat{F} = \hat{f}(I, N, \omega)$ 中。因此综合考虑具有网格单元面积信息的 J^{-1} , i 边的单位法向量的 x 分量 $\hat{\xi}_x$, i 边的单位法向量的 y 分量 $\hat{\xi}_y$, i 边长 $|\nabla \xi|/J$, j 边的单位法向量的 x 分量 $\hat{\eta}_x$, j 边的单位法向量的 y 分量 $\hat{\eta}_y$, j 边长 $|\nabla \eta|/J$ 和翼型表面坐标点 (x_0, y_0) 。最终网格信息和初始条件可以表示为

$$N_{i_{\max} \times j_{\max} \times 9} = \left[J^{-1}, \hat{\xi}_x, \hat{\xi}_y, |\nabla \xi|/J, \hat{\eta}_x, \hat{\eta}_y, |\nabla \eta|/J, x_0, y_0 \right] \quad (11)$$

$$I_{i_{\max} \times j_{\max} \times 3} = [Ma_{\infty}, AoA_{\infty}, Re_{\infty}] \quad (12)$$

1.4 UNet网络架构

翼型流场复杂且精细,且本文提出的推理方法存在较多输入信息,因此选择深度UNet进行模型训练。UNet网络结构的编码器-解码器结构和跳跃连接模块保证了模型获取的特征中包含丰富的上下文信息,也保留了部分原始输入的定位细节。如图5所示,本文所提出的模型采用如式(11)和式(12)所列的大小为12的张量信息作为输入,并输

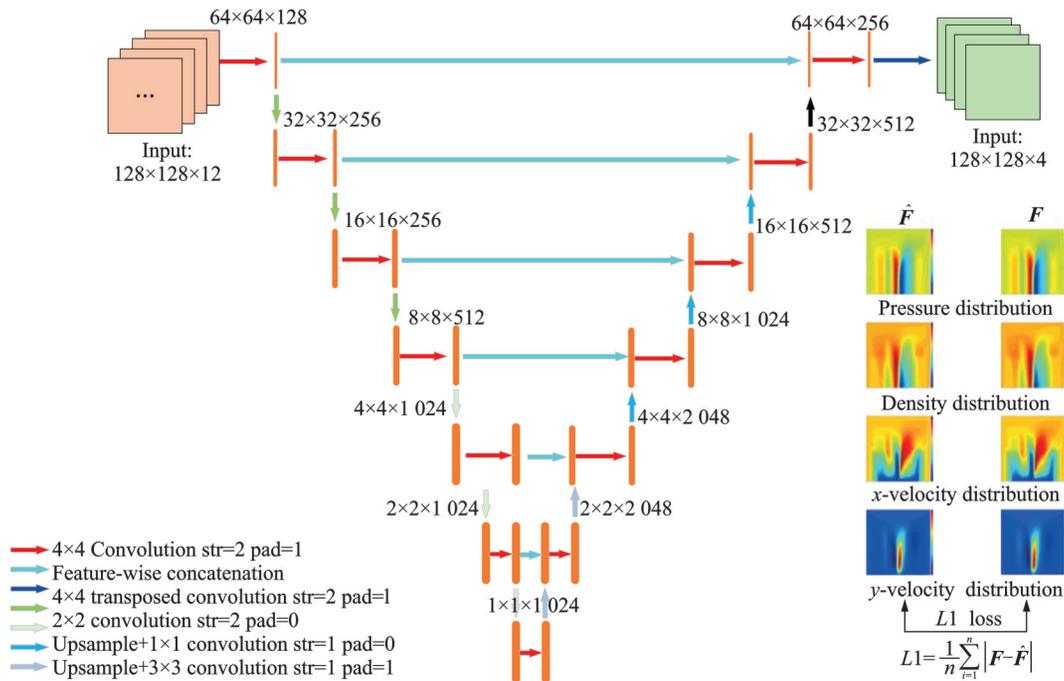


图 5 UNet 模型架构

Fig.5 Architecture of UNet

出如式(7)所列的大小为 4 的张量信息,包括压力场、密度场和 x 、 y 方向的速度场。模型共有 6 个下采样层和 6 个上采样层。每个下采样层由 1 个卷积层和 1 个普通 UNet 块组成,每个上采样层由 1 个普通 UNet 块和 1 个转置卷积层组成。如此进行深度 UNet 网络架构设计,使得模型获得更好的非线性表达能力,可以学习更加复杂的变换,从而可以更好地拟合复杂的输入特征。

与全连接神经网络(Fully convolutional network, FCN)相比,UNet 具有完全对称的特点,FCN 仅使用一个反卷积操作。将 UNet 应用于流场预测领域,作为一款整体端到端的网络架构,训练以及使用 UNet 无需复杂的流场预处理和后处理步骤;通过跳跃连接传递编码器特征至解码器,能够有效缓解流场学习中的信息损失,提高附面层、激波和流动分离等复杂流动预测精度;通过其对称的网络架构,能够保证流场具有缩放不变性和高分辨率特征精度。因此 UNet 可以依托更丰富的高级抽象特征,在提高模型泛化性的同时,实现流场预测精度的提升,还能更准确地预测大分离流动和激波等流动现象。

2 结果和分析

2.1 数据集设置

为验证本文所提出的坐标变换方法的有效性,深度 UNet 的鲁棒性与泛化性,使用大量翼型,在一定范围内的随机自由来流条件下,通过 CFD 方

法得到翼型的流场信息,建立模型训练所需数据库。综合 UNet 网络架构特点,CFD 方法在较高马赫数和大迎角工况下预测精度不高的缺点,为使模型更好地学习到翼型外型特征变化、流动细节和提取出优质翼型可压缩流场高级特征,准确分析出本文所提出方法的综合性能,数据库的随机自由来流范围划定为表 1 所示,表中 900 为训练用翼型数,30 为测试用翼型数。

表 1 数据集分布

Table 1 Dataset distribution

Number of airfoils	Initial condition
900(30)	$Ma_{\infty} \in (0.50, 0.70)$
	$AoA_{\infty} \in (-1.0^{\circ}, 10.0^{\circ})$
	$Re_{\infty} \in (3 \times 10^6, 8 \times 10^6)$

本文计划采用 930 个来自 UIUC 数据库^[15]的翼型,使用如表 1 所示在一定范围内的随机来流条件进行 CFD 计算以生成数据点,其中 900 个翼型,每个翼型对应产生 11 个数据点,另 30 个翼型用以测试,构建共计 9 930 个数据点的数据集用于训练,训练集中如表 2 所示,其中 9 900 个数据点用以模型训练,200 个数据点用以验证。图 6 为 UNet 训练

表 2 数据点分配和损失

Table 2 Data assignment method and model training loss

计划数据点	数据点分配	损失 $L1$
9 930	Train: 9 700	3.33×10^{-4}
	Verify: 200	$(6.56 \pm 0.74) \times 10^{-4}$
	Test: 30	$(4.15 \pm 0.21) \times 10^{-4}$

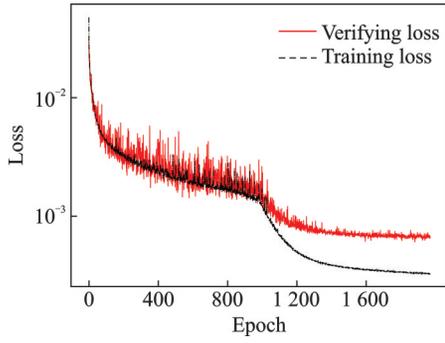


图6 UNet训练与验证损失

Fig.6 Training and verifying loss of UNet

与验证损失对比,由图可见,训练好的模型最终L1正则化损失收敛在 3.33×10^{-4} ,其中验证集的损失为 $(6.56 \pm 0.74) \times 10^{-4}$,模型在30个测试翼型上

的L1正则化损失为 $(4.15 \pm 0.21) \times 10^{-4}$,展示出模型的强学习能力与高鲁棒性。

2.2 方法验证

本文所使用神经网络方法的优势之一为能够实现CFD空间坐标和神经网络计算空间相互转换,因此本文提出的方法可以预测整个流场。本文所使用的神经网络方法优势之一是能够实现CFD空间坐标和神经网络计算空间的相互转换,因此本文提出的方法可以预测整个流场。图7给出了来流条件为 $Ma=0.40$ 、 $AoA=2.20^\circ$ 和 $Re_\infty=1.5 \times 10^6$ 下的计算和预测结果,展示出了采用CFD数值模拟和UNet方法预测的压力场、密度场和 x 与 y 速度场,以及两种方法结果之间的误差 e_{map} 。

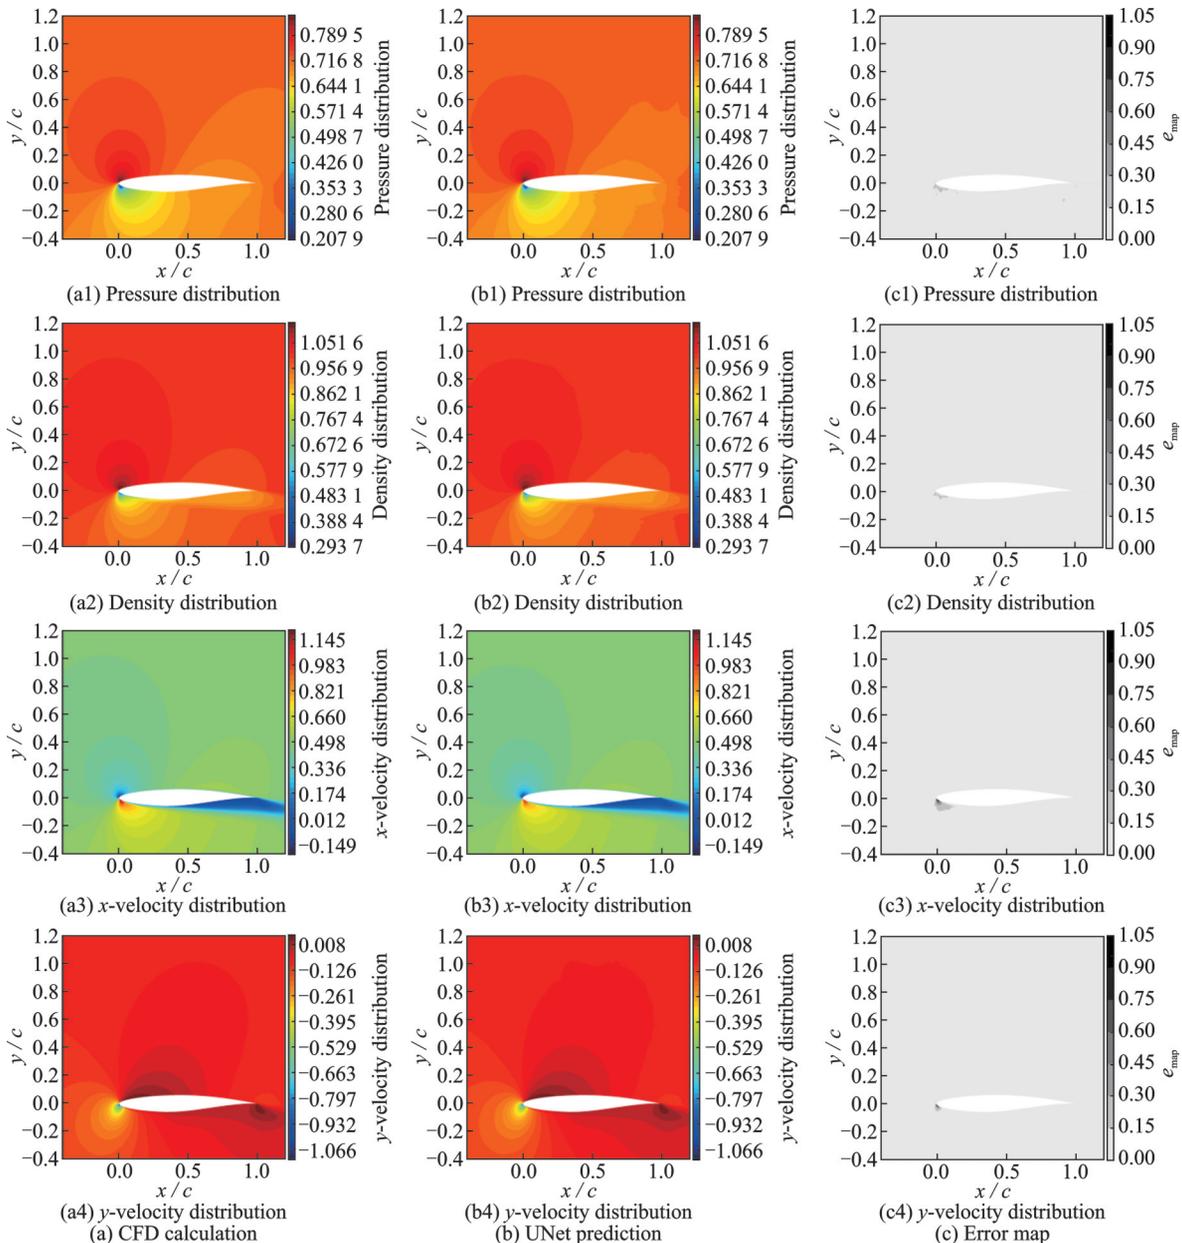


图7 RAE2822翼型CFD计算与UNet预测结果及误差图

Fig.7 Comparison between results of CFD calculations and UNet predictions, and error map of RAE2822 airfoil

文中误差图值 e_{map} 及误差值 MSE 分别为

$$e_{\text{map}} = \frac{\left(\left| (F_n - \hat{F}_n) \right| - \min \left| (F_n - \hat{F}_n) \right| \right)}{\left(\max \left| (F_n - \hat{F}_n) \right| - \min \left| (F_n - \hat{F}_n) \right| \right)} \quad (13)$$

$$\text{MSE} = \sum_{n=1}^S \sqrt{|F_n - \hat{F}_n|^2} / S \quad (14)$$

式中: $S = 128 \times 128$ 为网格单元总数, n 为某一个网格单元。从图 7 中可以看出低马赫数、小迎角和一般雷诺数的计算初始条件下, 本文方法的预测结果与 CFD 数值模拟结果并没有很大差异, 另外在 30 个测试样本中, 流场的推理时间平均为 12 ms, 而 FCN 方法平均预测时间为 88 ms。

2.3 流场预测

为验证本文所提出的基于 UNet 的可压缩翼型流场机器学习推理方法的性能, 本文从测试集的 30 个翼型内挑选出 4 种不同的翼型进行随机自由来流情况下的流场预测分析和翼型表面压力系数预测分析, 包括对称翼型、非对称翼型、厚翼型和薄翼型, 并与 FCN 方法预测结果进行对比。

对于对称翼型, 本文选择测试案例 e473 翼型进行分析, 在自由来流条件为 $Ma_\infty = 0.55$ 、 $AoA_\infty = 0.29^\circ$ 和 $Re_\infty = 1.294 \times 10^6$ 的工况下进行预测分析。如图 8 所示的压力系数预测显示, 本文所提出的方法对比普通机器学习方法精度更高, 在 $0.2c$ 附近的敏感部位与 CFD 计算结果吻合度更高。如图 9 所示, 本文所提出的方法对翼型流场进行快速推理时压力场误差更小, 误差值 MSE 从 0.002 821 下降到 0.000 85, 因此可以准确预测翼型压力系数。如图 10 所示的压力场、密度场和 x 与 y 方向速度场预测中均展示出了对称翼型在低迎角下的流场流动特征。

对于厚翼型, 本文选择测试案例 e342 翼型进行分析, 自由来流条件为 $Ma_\infty = 0.68$ 、 $AoA_\infty = 7.76^\circ$ 和 $Re_\infty = 1.567 \times 10^6$, 对此工况进行预测结果分析, 如图 11 所示, 该方法在上翼面 $0.2c$ 处比传统机器学习方法更好地预测出逆压梯度。图 12 为

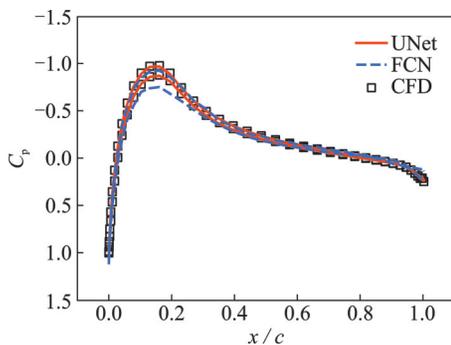


图 8 e473 翼型压力系数

Fig.8 Pressure coefficient of e473 airfoil

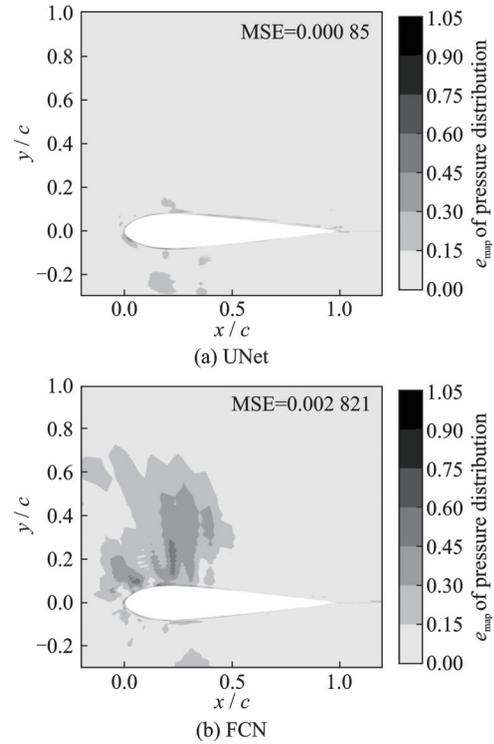
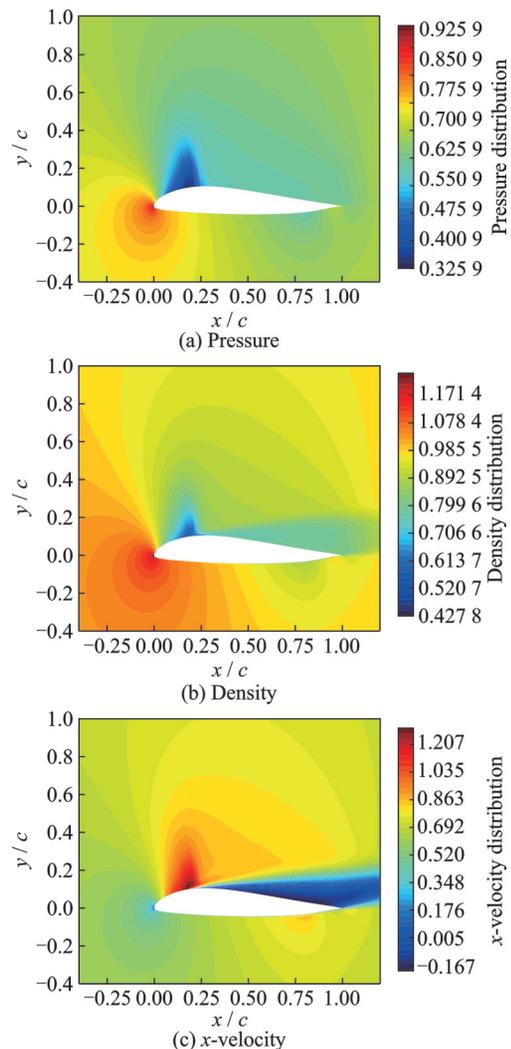


图 9 e473 翼型压力场预测误差

Fig.9 Prediction error of pressure distribution for e473 airfoil



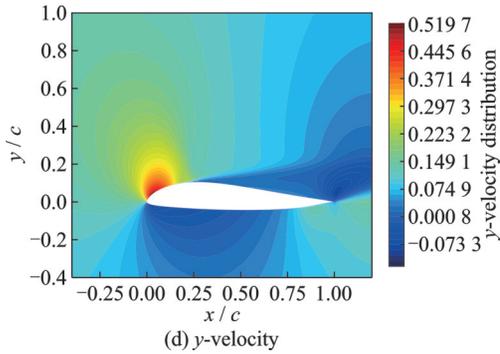


图10 e473翼型流场预测

Fig.10 Flowfield prediction of e473 airfoil

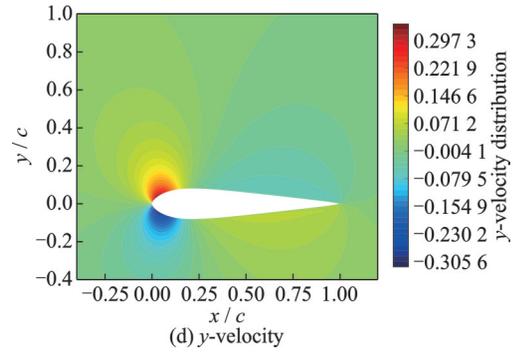


图12 e342翼型流场预测

Fig.12 Flowfield prediction of e342 airfoil

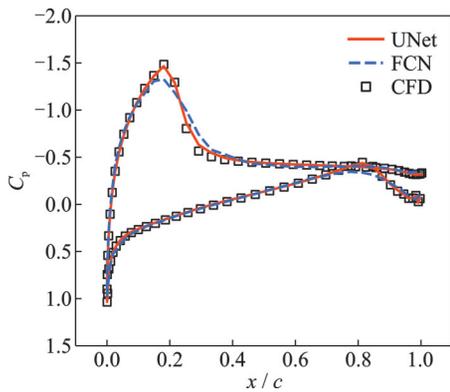
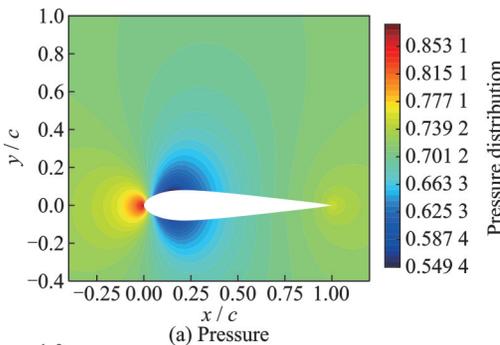


图11 e342翼型压力系数

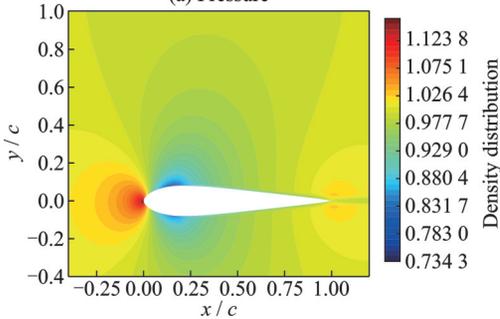
Fig.11 Pressure coefficient of e342 airfoil

e342翼型流场预测结果。如图12所示,在 $0.2c$ 处的翼型流场准确反应出剧烈的压力变化,且在翼型尾缘,由于大迎角而产生的尾缘流动分离导致下翼面出现正压增大,而FCN方法在此处的压力系数预测出现不真实的抖动。

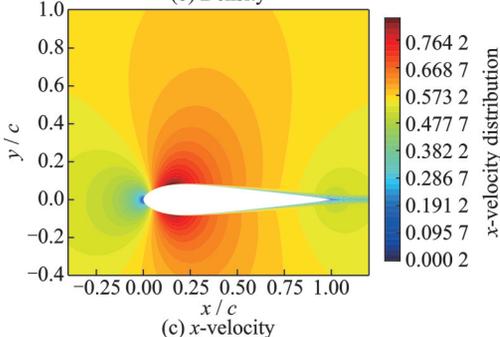
对于薄翼型,本文选择测试案例kc135d翼型进行分析,在 $Ma_\infty = 0.70$ 、 $AoA_\infty = 5.68^\circ$ 和 $Re_\infty = 4.537 \times 10^6$ 的大迎角高马赫数自由来流条件下,如图13所示,本文所提出的翼型流场推理方法可以模拟出此状态下的上翼面弱激波导致的逆压梯度。如图14所示,本文所提出的快速推理方法可以准确预测出翼型流场中的局部压力变化和局部速度变化,且能准确预测上翼面的弱激波现象。结合图15,误差值MSE对比传统机器学习的0.00641下降到0.00263,可见由传统机器学习方法,本文的方法在推理弱激波这种与输入条件具有强关联的特征具有很强的优越性。



(a) Pressure



(b) Density



(c) x-velocity

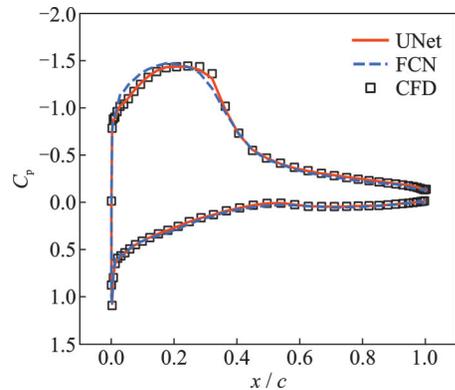


图13 kc135d翼型压力系数

Fig.13 Pressure coefficient of kc135d airfoil

2.4 泛化能力测试

为验证本文提出的快速推理模型的泛化性,本节使用RAE2822翼型在 $Ma_\infty = 0.80$ 、 $AoA_\infty = 11.00^\circ$ 和 $Re_\infty = 6.0 \times 10^6$ 的自由来流下的预测结果进行分析,所使用的翼型和来流条件均不在训练范围内。如图16所示,在翼型流场预测中,压力场和密度场存在极小误差,在 x 方向的速度场中出

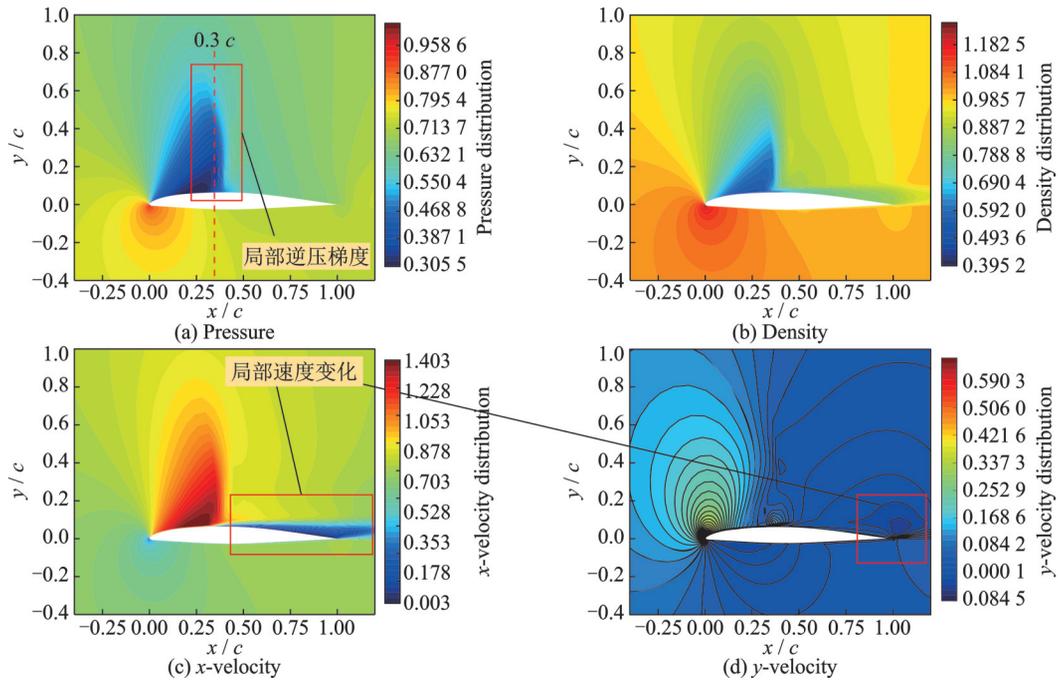


图 14 kc135d翼型流场预测

Fig.14 Flowfield prediction of kc135d airfoil

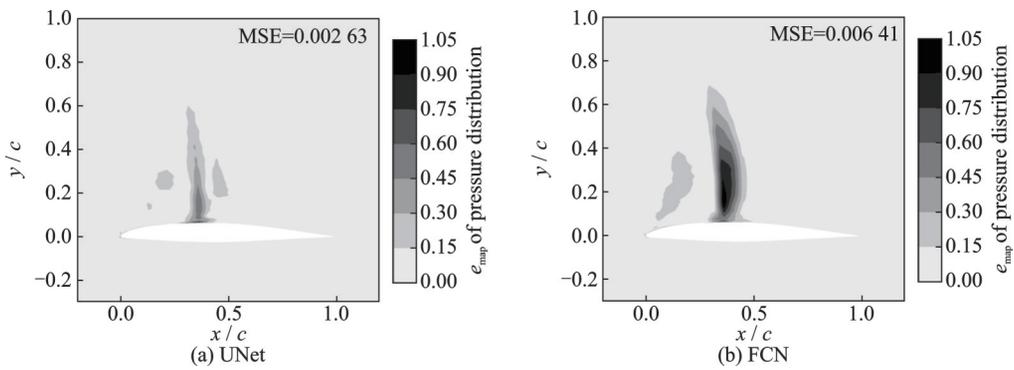


图 15 kc135d翼型压力场预测误差图

Fig.15 Prediction error of pressure distribution for kc135d airfoil

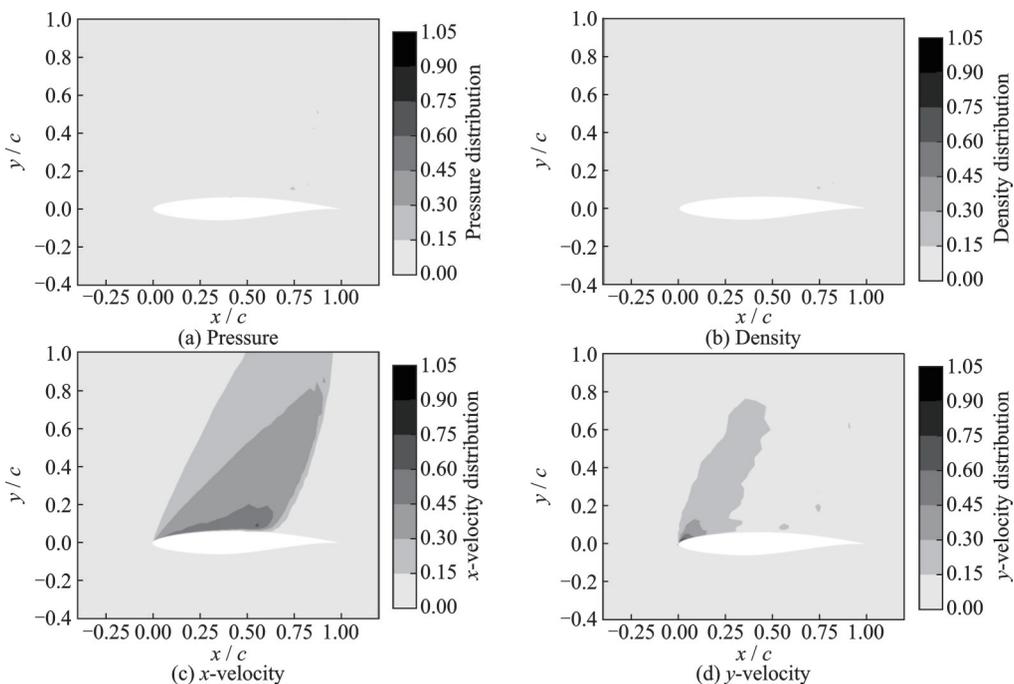


图 16 RAE2822翼型压力场预测误差图

Fig.16 Prediction error of flowfield for RAE2822 airfoil

现较大误差。结合图17(a)分析,这是因为在大雷诺数、大迎角和高马赫数的来流条件下,翼型的上表面出现弱激波,且翼型尾缘出现流动分离,并且

翼型上表面的激波导致的逆压梯度和尾缘分离涡导致的下翼面尾缘正压降低,均能反应在图17(b)所示的压力系数曲线中。

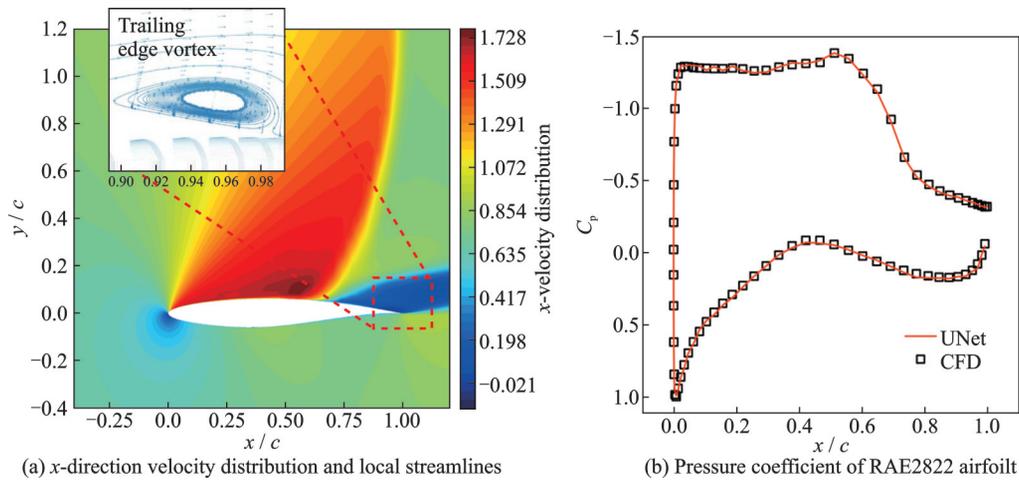


图17 RAE2822翼型压力系数和流场预测

Fig.17 Pressure coefficient and flowfield prediction for RAE2822 airfoil

3 结 论

本文提出了一种翼型可压缩流场高效推理方法,在不同特征的翼型、不同工况和超出训练集范围内工况的流场预测中展示出极强的鲁棒性与泛化性。

(1) 本文提出了一种用于流场数据前处理的坐标变换方法,将CFD计算空间坐标以及流场信息转换为神经网络空间坐标,使流场数据的输入更符合UNet架构规范,使神经网络能够学习到更多的流动细节、边界层流动和进行流场的全局推理。

(2) 本文发展了一种用于流场数据学习的深度UNet架构,通过UNet相应的下采样架构、级联架构、编码模块和深度网络,在输入经过坐标变换的流场数据后,UNet能够更好地提取其感兴趣区域,学习到翼型、来流条件和流场映射中的高级特征,从而构建出对来流雷诺数、马赫数、翼型外形和迎角具有很高敏感性的神经网络模型。

(3) 本文与传统FCN方法,在不同特征翼型、不同来流条件的流场预测任务中进行流场预测对比。结果表明,本文所构建的推理方法更加快速精确,在流场梯度变化大的地方,推理得到的翼型表面的压力系数与CFD方法吻合更好,可以更加准确地预测大迎角高马赫数来流工况下的激波与流动分离现象。

参考文献:

[1] TOLLE K M, TANSLEY D S W, HEY A J G. The fourth paradigm: Data-intensive scientific discovery [Point of view][J]. Proceedings of the IEEE, 2011,

99(8): 1334-1337.

[2] BARAKOS G N, FITZGIBBON T, KUSYUMOV A N, et al. CFD simulation of helicopter rotor flow based on unsteady actuator disk model[J]. Chinese Journal of Aeronautics, 2020, 33(9): 2313-2328.

[3] 阎超, 屈峰, 赵雅甜, 等. 航空航天CFD物理模型和计算方法的述评与挑战[J]. 空气动力学学报, 2020, 38(5): 829-857.

YAN Chao, QU Feng, ZHAO Yatian, et al. Review of development and challenges for physical modeling and numerical scheme of CFD in aeronautics and astronautics[J]. Acta Aerodynamica Sinica, 2020, 38(5): 829-857.

[4] DURBIN P A. Some recent developments in turbulence closure modeling[J]. Annual Review of Fluid Mechanics, 2018, 50: 77-103.

[5] 张伟伟, 朱林阳, 刘溢浪, 等. 机器学习在湍流模型构建中的应用进展[J]. 空气动力学学报, 2019, 37(3): 444-454.

ZHANG Weiwei, ZHU Linyang, LIU Yilang, et al. Progresses in the application of machine learning in turbulence modeling[J]. Acta Aerodynamica Sinica, 2019, 37(3): 444-454.

[6] BRUNTON S L, NOACK B R, KOUMOUTSAKOS P. Machine learning for fluid mechanics[J]. Annual Review of Fluid Mechanics, 2020, 52: 477-508.

[7] GUO X, LI W, IORIO F. Convolutional neural networks for steady flow approximation [C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data mining.[S.l.]:

- ACM, 2016.
- [8] YANG Z, DONG Y, DENG X, et al. AMGNET: Multi-scale graph neural networks for flow field prediction[J]. *Connection Science*, 2022, 34(1): 2500-2519.
- [9] THUEREY N, WEIBENOW 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.
- [10] CHEN J F, VIUERAT J, HACHEM E. U-Net architectures for fast prediction of incompressible laminar flows[EB/OL]. (2019-10-25). <https://arxiv.org/abs/1910.13532>.
- [11] 井思梦, 赵国庆, 招启军. 翼型动态失速气动力二次峰值数值模拟研究[J]. *南京航空航天大学学报*, 2022, 54(2): 191-202.
- JING Simeng, ZHAO Guoqing, ZHAO Qijun. Numerical research on secondary peak of aerodynamic forces of airfoil under dynamic stall[J]. *Journal of Nanjing University of Aeronautics & Astronautics*, 2022, 54(2): 191-202.
- [12] ZHAO Q J, ZHAO G Q, WANG B, et al. Robust Navier-Stokes method for predicting unsteady flow field and aerodynamic characteristics of helicopter rotor [J]. *Chinese Journal of Aeronautics*, 2018, 31 (2) : 214-224.
- [13] ABBOTT I H, VON DOENHOFF A E, STIVERS JR L. Summary of airfoil data: NACA-TR-824[R]. [S.l.]: NACA, 1945.
- [14] CHRISTOPHER L R, BIEDRON R T, THOMAS J L. CFL 3D: Its history and some recent applications: NASA TM-112861[R]. [S.l.]: NASA, 1997.
- [15] UIUC Applied Aerodynamics Group. UIUC airfoil data site [EB/OL]. (2023-10-30). <https://m-selig.ae.illinois.edu/ads.html>.

(编辑:孙静)