

申缘琪, 曹从咏, 陈萌, 等. 基于深度学习的流场快速预测方法研究[J]. 智能计算机与应用, 2026, 16(3): 147-153. DOI: 10.20169/j. issn. 2095-2163. 24050101

基于深度学习的流场快速预测方法研究

申缘琪, 曹从咏, 陈萌, 冯雅凡
(南京理工大学 自动化学院, 南京 210094)

摘要: 为了提高传统 CFD 方法的计算效率, 本文提出了一种基于深度学习的流场快速预测方法。该方法以 U^2 -Net 为基础, 用 DSC 替换 RSU 模块中下采样的传统卷积, 引入注意力机制, 在增强对 RoI 区域特征处理能力的同时降低了训练成本。实验以平面半圆绕流为例, 结果表明: 所构建模型的预测结果相较于传统 CFD 方法的误差低于 2.5%, 计算效率上提高了 4 个数量级。该方法在保证流场预测精度的同时, 大幅度提升了计算效率, 弥补了传统 CFD 方法的不足。

关键词: 流场预测; 深度可分离卷积; 深度学习; U^2 -Net

中图分类号: TP18

文献标志码: A

文章编号: 2095-2163(2026)03-0147-07

Research on the fast prediction method for flow fields based on deep learning

SHEN Yuanqi, CAO Congyong, CHEN Meng, FENG Yafan

(School of Automation, Nanjing University of Science and Technology, Nanjing 210094, China)

Abstract: In order to enhance the computational efficiency of traditional Computational Fluid Dynamics (CFD) methods, this paper proposes a rapid flow field prediction method based on deep learning. The method is founded on the U^2 -Net architecture, with traditional convolution in the downsampling RSU module replaced by DSC, and incorporates attention mechanisms. This innovation not only strengthens the feature processing capability of the RoI, but also reduces training costs. Experiments conducted on planar semi-circular cylinder flow demonstrate that the constructed model's prediction error is less than 2.5% compared to traditional CFD methods, and the computational efficiency is improved by four orders of magnitude. This method significantly enhances computational efficiency while maintaining flow field prediction accuracy, thereby addressing the limitations of conventional CFD approaches.

Key words: flow field prediction; depthwise separable convolution; deep learning; U^2 -Net

0 引言

近年来, 深度学习在计算机视觉和自然语言处理方面的成功应用, 推动了人们在探索人工智能在科学计算领域、特别是在计算流体力学 (CFD) 方面的应用进程。为了解决 CFD 方法高计算周期的缺陷, 国内外研究者提出了许多基于深度学习实现快速精确预测流体力学问题的解决方案。

在众多的深度学习方法中, 以卷积神经网络 (Convolutional Neural Network, CNN) 为代表的模型由于归纳偏差而具有强大的非线性映射能力, 在流场建模中受到了高度关注^[1-2]。CNN 方法在流场重

建^[3-4]、湍流重建^[5-6]、气动优化^[7]等方面得到了广泛应用。

Guo 等学者^[8]率先将 CNN 应用于非均匀稳态层流的实时预测模型。Zhang 等学者^[9]探讨了卷积神经网络技术的适应性以实现空气动力学建模任务。Thuerey 等学者^[10]采用基于 U -Net 神经网络的图像对图像方法, 将流场投影到均匀笛卡尔网格中, 建立翼型几何形状和工况到速度场和压力场的映射关系。Lee 等学者^[11]评测了 GAN 和 multi-scale CNN 等 4 种深度神经网络的预测效果。Chen 等学者^[12]创新性地提出了一种多分支融合的卷积神经, 验证了卷积神经网络在超声速燃烧流场重构的可能性。Hu 等学者^[13]提出基于径向基函数的生成对抗

作者简介: 申缘琪 (2000—), 男, 硕士研究生, 主要研究方向: 交通信息工程及控制。

通信作者: 曹从咏 (1964—), 男, 博士, 教授, 主要研究方向: 交通大数据, 交通信息工程及控制。Email: jy108@njust.edu.cn。

收稿日期: 2024-05-01

哈尔滨工业大学主办 ◆ 系统开发与应用

网络方法从有限和系数的数据集高效地重构流场。Ma 等学者^[14]通过将本征正交分解与 ResNet 结合提出一种基于残差网络的非嵌入式流场重构降价模型。何磊等学者^[15]提出了在火箭启动建模中机器学习方法的应用。惠心雨等学者^[16]利用回归生成对抗网络学习圆柱绕流非定常流动,成功预测不同时刻圆柱绕流的流场参数。

总而言之,深度学习已成功应用于流场预测领域,且计算效率已显著优于传统数值模拟方法。针对传统 CFD 方法仿真效率较低的缺陷,本文提出一个通过引入注意力机制关注流场变化剧烈区域,利用深度可分离卷积提高模型计算效率,实现在不同入流速度下的流场快速求解模型。

1 CFD 计算方法及数据集构建

在数值模拟方法方面,要基于流动控制方程的精确数值求解,本节主要介绍流场采样所用 CFD 的物理模型和数值方法的理论,包括基本控制方程、层流模型方程、数值计算方法等^[17]。

1.1 流体控制方程

在笛卡尔坐标系下,积分形式的三维可压缩雷诺平均 Navier-Stokes 方程可写成:

$$\frac{\partial}{\partial t} \iiint_V \vec{W} dV + \int_{\partial V} \vec{F} n dS = 0 \quad (1)$$

研究推得, \vec{W} 可以表示为:

$$\vec{W} = [\rho, \rho u, \rho v, \rho w, \rho E]^T \quad (2)$$

其中, ρ, u, v, w, E 分别表示密度,笛卡尔速度分量和比总能^[18]。 V 是由边界 ∂V 和外法向矢量 \vec{n} 包围的控制体积。总焓为:

$$H = E + p/\rho \quad (3)$$

如果假设流场为非粘条件,通量张量 \vec{F} 则为无粘部分 \vec{F}^C , 即:

$$\vec{F} = \vec{F}^C \quad (4)$$

且,

$$\vec{F}^C = \begin{pmatrix} \hat{e} & \hat{e} & \hat{e} & \hat{e} & \hat{e} \\ \rho u \vec{i}_x & \rho u^2 + p \vec{i}_x & \rho u v \vec{i}_y & \rho u w \vec{i}_z & \rho u(E + p) \vec{i}_x \\ \rho v \vec{i}_x & \rho v u \vec{i}_x & \rho v^2 + p \vec{i}_y & \rho v w \vec{i}_z & \rho v(E + p) \vec{i}_y \\ \rho w \vec{i}_x & \rho w u \vec{i}_x & \rho w v \vec{i}_y & \rho w^2 + p \vec{i}_z & \rho w(E + p) \vec{i}_z \end{pmatrix} \quad (5)$$

$$\vec{\Pi}_x = (u\sigma_{xx} + v\sigma_{xy} + w\sigma_{xz} - q_x) \vec{i}_x \quad (6)$$

$$\vec{\Pi}_y = (u\sigma_{yx} + v\sigma_{yy} + w\sigma_{yz} - q_y) \vec{i}_y \quad (7)$$

$$\vec{\Pi}_z = (u\sigma_{zx} + v\sigma_{zy} + w\sigma_{zz} - q_z) \vec{i}_z \quad (8)$$

其中, \vec{i}_x, \vec{i}_y 和 \vec{i}_z 分别表示笛卡尔坐标的方向矢量。对于完全气体的状态方程为:

$$p = (\gamma - 1) \rho \left(\frac{u^2 + v^2 + w^2}{2} \right) \quad (9)$$

其中, γ 表示比热比。进一步推得:

$$\sigma_{xx} = 2\mu u_x - 2/3\mu(u_x + v_y + w_z) \quad (10)$$

$$\sigma_{yy} = 2\mu u_y - 2/3\mu(u_x + v_y + w_z) \quad (11)$$

$$\sigma_{zz} = 2\mu u_z - 2/3\mu(u_x + v_y + w_z) \quad (12)$$

$$\sigma_{xy} = \sigma_{yx} = \mu(u_y + v_x) \quad (13)$$

$$\sigma_{xz} = \sigma_{zx} = \mu(u_z + w_x) \quad (14)$$

$$\sigma_{yz} = \sigma_{zy} = \mu(v_z + w_y) \quad (15)$$

$$q_x = -k \frac{\partial T}{\partial x}, q_y = -k \frac{\partial T}{\partial y}, q_z = -k \frac{\partial T}{\partial z} \quad (16)$$

其中, T 表示温度,定义公式为:

$$T = \frac{p}{\rho} \quad (17)$$

对于层流流动,假定无量纲粘性系数 μ 服从 Sutherland 定律,即:

$$\mu = \frac{\gamma^{1/2} M_\infty \hat{e} T_\infty^{3/2} \bar{T}_\infty + 110}{Re_\infty \hat{e} T_\infty \bar{T} + 110} \quad (18)$$

热传导系数 k 的定义公式为:

$$k = \frac{\gamma}{\gamma - 1} \frac{\mu}{Pr}$$

1.2 数值方法

方程(1)的空间半离散形式为:

$$\frac{d}{dt} \vec{W}_{i,j,k} = \frac{1}{V_{i,j,k}} (\vec{R}_{i,j,k}^C - \vec{R}_{i,j,k}^V) \quad (19)$$

其中, $\vec{R}_{i,j,k}^C$ 和 $\vec{R}_{i,j,k}^V$ 分别表示控制体积 $V_{i,j,k}$ 的流通量和粘性通量。 $\vec{R}_{i,j,k}^C$ 表示为:

$$\vec{R}_{i,j,k}^C = \vec{R}_{i+\frac{1}{2},j,k}^C - \vec{R}_{i-\frac{1}{2},j,k}^C + \vec{R}_{i,j,k+\frac{1}{2}}^C - \vec{R}_{i,j,k-\frac{1}{2}}^C \quad (20)$$

其中, $\vec{R}_{i+\frac{1}{2},j,k}^C$ 表示网格表面 $i + \frac{1}{2}$ 上的通量。研究中可采用二阶精度 TVD 格式求出。粘性通量项 $\vec{R}_{i,j,k}^V$ 采用中心差分来离散,一阶导数项应用坐标转换方法求出,即:

$$\Phi_x = \frac{\partial \Phi}{\partial \xi} \frac{\partial \xi}{\partial x} + \frac{\partial \Phi}{\partial \eta} \frac{\partial \eta}{\partial x} + \frac{\partial \Phi}{\partial \zeta} \frac{\partial \zeta}{\partial x} \quad (21)$$

1.3 数据集的构建

本文选取平面半圆的无粘流场为算例, 半圆绕流的计算区域如图 1 所示, 其中流向为箭头所示方向, 流体介质选用空气。网格划分如图 2 所示, 计算网格为 276×98 (横向×纵向)。

基于 1.2 节所提到的高精度数值模拟方法, 使用 Fortran 编码对平面半圆绕流流场进行求解。对入流速度在 20~49 m/s 内, 以 1 m/s 为间隔的 30 个工况进行计算, 数值模拟输出包含密度 (ρ)、速度分量 (u_x) 及 (u_y)、马赫数 (Ma) 和压力 (P) 等流场参数。数据集由数值模拟的流场参数、计算区域边界条件和入流速度所构成。




图 1 流场计算区域
Fig. 1 Flow field calculation area




图 2 网格示意图
Fig. 2 Mesh diagram

1.4 数据集预处理

利用深度学习技术对流场进行预测, 首先要解决的就是流场数据的表示问题, 即如何将边界条件、物理场 (如速度矢量场) 等表示为神经网络可以接受的形式。通过符号距离函数 (Signed Distance Function, SDF) [8] 将预测模型的几何拓扑信息抽象为 SDF。定义 Ω 为度量空间 X 的一个子空间, 度量空间 X 代表了平面半圆的几何拓扑信息, 其本质是一个矩阵, 该矩阵元素的值仅包括 -1 和 1 两种情况, 在半圆内为 -1, 流场其他区域为 1。SDF 被定义为:

$$D = \begin{cases} d(x, \partial\Omega), & \text{if } x \in \Omega \\ -d(x, \partial\Omega), & \text{if } x \in \Omega^c \end{cases} \quad (22)$$

其中, d 表示欧几里得距离; $\partial\Omega$ 表示 Ω 的边界; Ω^c 表示 Ω 的内部。对于任意 $x \in X$, 有:

$$d(x, \partial\Omega) = \inf_{y \in \partial\Omega} d(x, y) \quad (23)$$

其中, \inf 表示下确界。

SDF 的物理意义为空间中的某个点到边界的最小距离, 其符号由该点是否在边界内决定。图 3 是平面半圆的 SDF 示意图, SDF 值的大小随着接近半圆的边界而减小。经过 SDF 方法处理过后, 半圆周围非正交网格数据变为可以直接输入模型的数据。




图 3 SDF 示意图
Fig. 3 SDF diagram

2 绕流流场预测模型的构建

2.1 U^2 -Net 网络结构

Qin 等学者 [19] 提出一个由复杂的双层 U 型结构所构成的 U^2 -Net 网络, 内层为提取特征的 Residual U-blocks (RSU) 模块, 外层为连接各模块的 U 型结构。 U^2 -Net 网络结构如图 4 所示, 左侧为编码阶段, 由不同配置的 RSU-L 模块构成 (见图 5), 特征图的尺寸在其中逐渐减半然后恢复, RSU 模块之间通过 2×2 的最大池化层相连, 使得特征图的尺寸缩小至原来的 $1/8$ 。网络右侧为解码阶段, 采用与编码阶段对称的 RSU 配置, 输入数据是上一阶段的输出与对称编码阶段的输出合并。通过双线性插值操作连接各 RSU, 逐步恢复特征图的尺寸。最终, 将解码阶段每个 RSU 输出的特征图拼接起来, 形成最终的特征图。

2.2 深度可分离卷积

U^2 -Net 网络模型结构复杂, 内存需求大, 网络训练时间较长。为了使模型结构轻量化, 训练速度加快, 在 RSU 模块中融入深层可分离卷积 (Depthwise Separable Convolution, DSC) [20]。DSC 将标准卷积分离成深度卷积 (Depthwise Convolution) 和点卷积 (Pointwise Convolution), 如图 6 所示。即为先通过 $n \times n$ 的二维卷积核对输入数据进行分组卷积且不改变通道输入; 后通过 $1 \times 1 \times h$ 的核函数

逐点提取特征,增加特征图数量。DS 卷积在不改变每一个单元的特征通道数的前提下,大大减少模型参数和计算量。




图 4 U²-Net 网络结构图

Fig. 4 The structure of U²-Net

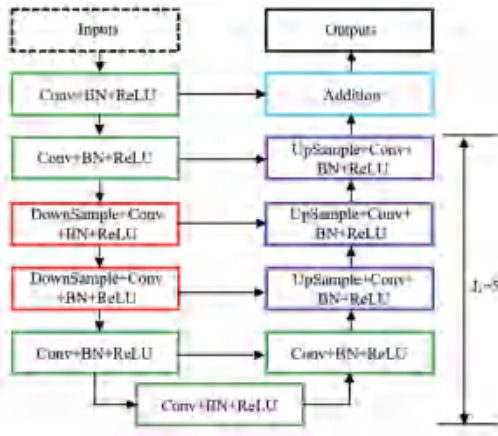


图 5 RSU-L 模块

Fig. 5 ReSidual U-blocks




图 6 深度可分离卷积结构

Fig. 6 The structure of depthwise separable convolution

2.3 注意力机制

在流场预测任务中,通常更加关注几何体周围的流场,这部分区域流场变化剧烈,波动较大,蕴含的信息多,一般称为感兴趣区域^[21] (Region of Interest, RoI)。研究中在流场预测网络结构中引入注意力机制^[22],期望能够提升 RoI 区域的预测精度。

本文引入了 2 个轻量级的注意力模块:通道注意力模块(Channel Attention Module, CAM)和空间注意力模块(Spatial Attention Module, SAM),结构

分别如图 7、图 8 所示。CAM 通过全局池化操作和多层感知机对通道维度的信息进行了整合,SAM 通过全局池化操作和卷积操作对空间维度的信息进行了整合,具体工作原理如下:

$$F_c = M_c(F) \otimes F \quad (24)$$

$$F_s = M_s(F) \otimes F \quad (25)$$

$$M_c(F) = \sigma(\text{MLP}(\text{GAP}(F)) + \text{MLP}(\text{GMP}(F))) \quad (26)$$

$$M_s(F) = \sigma(\text{Conv}(\text{GAP}(F)) + \text{MLP}(\text{GMP}(F))) \quad (27)$$

其中, $F \in R^{C \times H \times W}$ 表示输入特征图 (C, H, W 分别表示通道数和特征图的高度及宽度); $M_c \in R^{C \times 1 \times 1}$ 和 $M_s \in R^{1 \times H \times W}$ 分别表示 CAM 和 SAM;“ \otimes ”表示元素乘法。经过 CAM 和 SAM 处理后的输出特征图 F 相乘,保证输入和最终输出的大小和维度一致。




图 7 CAM 结构示意图

Fig. 7 The structure of CAM




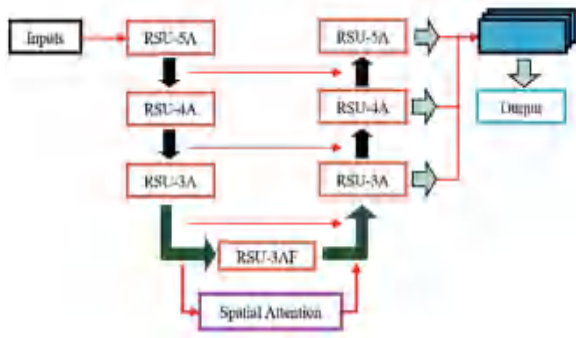
图 8 SAM 结构示意图

Fig. 8 The structure of SAM

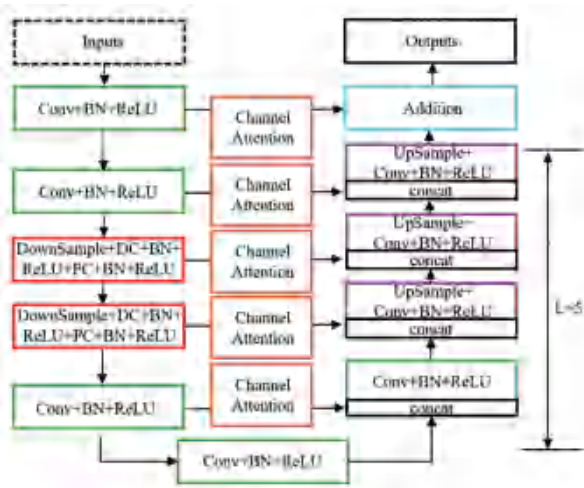
2.4 网络的改进

本节在 U²-Net 模型的基础上做出一些改动,构建了一个流场快速预测模型 U²-Flow。

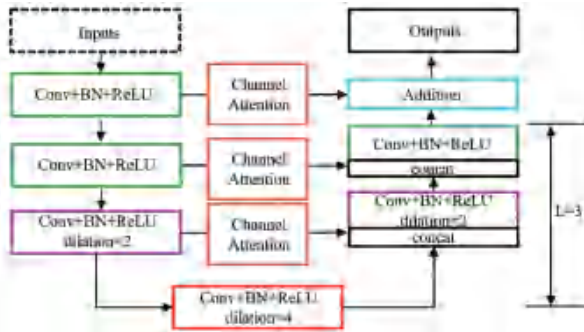
U²-Flow 模型的外层结构如图 9(a) 所示,左侧编码层依次由 RSU-5A、RSU-4A、RSU-3A 和 RSU-3AF 模块所填充,右侧解码层由与编码层对应的 RSU 模块填充,底部设置了 SAM 模块以对空间维度的信息进行融合。在 RSU 模块的改进如图 9(b) 和图 9(c) 所示,使用 DSC 替代下采样中的传统卷积,在减弱了采样过程中的细节特征丢失的同时减少了计算量和模型参数;在拼接的上采样阶段引入 CAM 模块进行通道维度的信息融合,增强对 RoI 区域特征的处理能力。U²-Flow 模型相较于 U²-Net 模型,在具有更多模型参数的同时保持更低的训练成本。



(a) U²-Flow 外层结构示意图



(b) RSU-5A 模块示意图



(c) RSU-3AF 模块示意图

图 9 模型改进示意图

Fig. 9 Diagram of model improvements

3 预测结果与分析

3.1 模型的训练

将 1.4 节中预处理过后的数据集输入 U²-Flow 网络中进行训练,数据集按 7:3 的比例划分为训练集和测试集。模型的参数经过优化后最终设置为:使用 Adam 优化器进行模型训练,0.002 的学习率,0.005 的权重衰减系数,共训练 20 000 步。U²-Net 与 U²-Flow 模型训练过程的损失函数曲线如图 10 所示。可以看出,U²-Net 模型虽然有着不错的结

果,损失函数最小值为 2.3×10^{-1} ,但收敛较慢,波动较大,在 13 500 个循环后甚至出现了发散的现象。相较之下,引入注意力机制和深度可分离卷积后,U²-Flow 模型对流场特征的处理更加优秀,对 RoI 区域的预测能力提升,模型训练加速收敛,预测的稳定性提高,损失函数最小值为 1.6×10^{-2} 。由 2 种模型损失函数的对比可以看出 U²-Flow 模型预测精度高,稳定性好,泛化性优秀。




图 10 不同模型训练损失函数对比

Fig. 10 Comparison of loss functions in training different models

3.2 平面半圆绕流场预测

将密度、流速等流场参数进行可视化对比展示,以直观验证预测模型的准确性。可视化对比结果如图 11 所示。第一行为平面半圆绕流流场的 CFD 方法数值模拟结果,第二行为 U²-Flow 模型预测结果,第三行为预测流场的绝对误差云图。根据云图可以发现整体上两者方法得到的流场分布基本相同,等值线附近有少许偏差,U²-Flow 模型可以很好地预测流体的流场参数,捕捉其特征,基本还原了流场的形态,符合流体运动物理规律。实验表明 U²-Flow 模型具有模拟复杂流体流动的潜力。

3.3 预测结果评价

为了定量衡量预测结果的好坏,对于每个预测参数计算平均绝对百分误差 (Mean Absolute Percentage Error, MAPE),定义为:

$$MAPE_i = \frac{1}{N} \sum_j \left| \frac{\omega_i^j - \tilde{\omega}_i^j}{\omega_i^j} \right| \times 100 \quad (28)$$

其中, ω_i^j 和 $\tilde{\omega}_i^j$ 表示第 i 个测试集的第 j 个流场参数, N 表示网格总数。

U²-Flow 模型对流场数据的预测准确性见表 1。表 1 中,包括整个流场区域的平均绝对百分误差 (MAPE_F)、RoI 区域的平均绝对百分误差 (MAPE_{ROI}),以及激波附近的平均绝对百分误差

(MAPE_S)。数据显示,各流场变量的 MAPE_F 普遍较低,均保持在 2.5% 以下。深入分析可以发现,因为 RoI 区域变化较为剧烈,导致 MAPE_{RoI} 有所增加,尤其是激波附近区域。误差主要集中在激波的边缘区域,可以忽略不计,因此可以看出 U²-Flow 模型对整个绕流流场的预测都表现出色。

表 1 平面半圆绕流预测误差

参数	MAPE _F	MAPE _{RoI}	MAPE _S
$\varepsilon(\rho)$	1.26	2.39	7.92
$\varepsilon(u_x)$	2.24	4.97	5.12
$\varepsilon(u_y)$	0.26	0.58	0.91
$\varepsilon(M_a)$	0.74	1.01	1.44
$\varepsilon(P)$	1.19	3.46	4.21

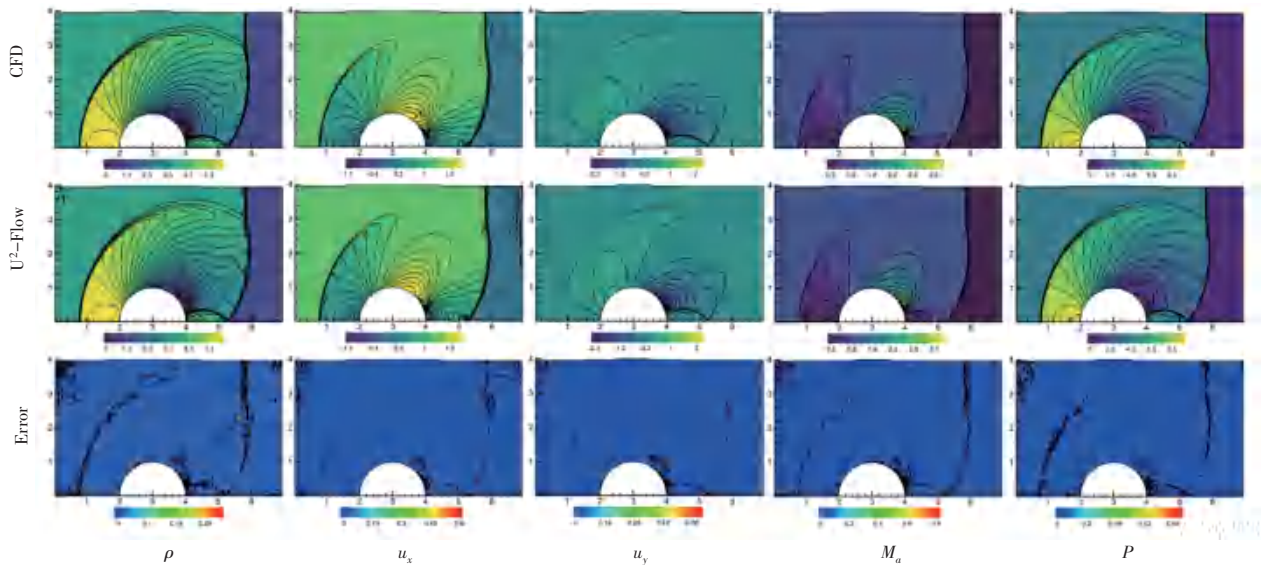


图 11 平面半圆绕流流场参数云图

Fig. 11 Contour map of parameters for planar semi-circular flow field

为了更详细地对比 2 种方法在密度上的计算结果,本节设置 2 条检测线,位置如图 12 所示。图 13 分别为 2 个位置密度随距离的变化曲线。结果显示 2 种方法结果高度吻合,U²-Flow 模型在关注区域表现出优秀的预测能力。

例数目。结果显示,随着算例数目的增加,模型计算时间有着不同的减少,相比通过 Fortran 计算的加速比在 $1.06 \times 10^4 \sim 1.16 \times 10^4$ 之间变化,极大地提高了流场的计算效率。





图 12 检测线位置


Fig. 12 Detection line position

3.4 计算效率评估

在保证优秀的预测能力的基础上,本节将要对比 2 种方法的计算速度,以测试 U²-Flow 模型相较于传统 CFD 算法速度上的提升。Fortran 编码计算的总时间取训练集中算例运行的平均时间,使用的 CPU 型号为 12th Gen Intel i5-12600KF 进行计算。U²-Flow 模型的预测总时间取验证集中算例运行的平均时间,基于 NVIDIA GeForce RTX 3070 进行预测。Fortran 编码计算求解和 U²-Flow 模型预测的计算总时间对比见表 2。表 2 中,Batch Size 表示算



(a) 仿真结果 1



(b) 仿真结果 2

图 13 密度的计算结果对比

Fig. 13 Comparison of density computation results

表2 计算时间对比

Table 2 Comparison of computational time

系统	BATCH SIZE	TIME/s	SPEEDUP/ 10^3
Fortran(CPU)	1	59.11	—
U ² -Flow(GPU)	2	5.07×10^{-2}	1.17
	10	4.02×10^{-2}	1.47
	100	3.83×10^{-2}	1.54

4 结束语

本文介绍了一种改进 U²-Net 的流场快速预测方法 U²-Flow。以平面半圆绕流流场为例,通过 SDF 方法对高精度数值模拟得到的流场数据进行处理,并将其与入流速度、边界条件一同作为模型的输入,训练 U²-Flow 模型。通过引入注意力机制关注流场变化剧烈的 RoI 区域,将 RSU 模块中下采样的传统卷积替换为 DSC 提高计算效率。训练出的模型能够对不同入流速度下的流场进行高精度、高效率的预测。

(1)实验结果表明,U²-Flow 模型所预测的流场与传统 CFD 方法所得结果高度一致。具体来说,整个流场的平均绝对百分误差均保持在 2.5% 以下,MAPE_{RoI} 最大为 6.72%。

(2)在确保计算精度的前提下,U²-Flow 模型相比传统的 CFD 方法,在计算速度上有了显著提升,加速比在 1.17×10^3 至 1.54×10^3 之间。这一显著的加速性能,结合其较高的计算精度,证明了 U²-Flow 作为一种流场快速精准预测方法的巨大潜力。

参考文献

- [1] YE Shuran, ZHANG Zhen, SONG Xudong, et al. A flow feature detection method for modeling pressure distribution around a cylinder in non-uniform flows by using a convolutional neural network [J]. Scientific Reports, 2020, 10: 4459.
- [2] 陈皓, 郭明明, 田野, 等. 卷积神经网络在流场重构研究中的进展 [J]. 力学学报, 2022, 54(9): 2343-2460.
- [3] XIAO Xiangyun, ZHOU Yanqing, WANG Hui, et al. A novel CNN-based Poisson solver for fluid simulation [J]. IEEE Transactions on Visualization and Computer Graphics, 2018, 26(3): 1454-1465.
- [4] OMATA N, SHIRAYAMA S. A novel method of low-dimensional representation for temporal behavior of flow fields using deep autoencoder [J]. AIP Advances, 2019, 9(1): 015006.
- [5] FUKAMI K, FUKAGATA K, TAIRA K. Machine-learning-

- based spatio-temporal super resolution reconstruction of turbulent flows [J]. Journal of Fluid Mechanics, 2021, 909: A9.
- [6] WU Pin, YUAN Wenyan, JI Lulu, et al. Missile aerodynamic shape optimization design using deep neural networks [J]. Aerospace Science and Technology, 2022, 126: 107640.
 - [7] YANG X, BARAJAS-SOLANO D, TARTAKOVSKY G, et al. Physics-informed CoKriging: A Gaussian-process-regression-based multifidelity method for data-model convergence [J]. Journal of Computational Physics, 2019, 395: 410-431.
 - [8] GUO Xiaoxiao, LI Wei, IORIO F. Convolutional neural networks for steady flow approximation [C]// Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2016:481-490.
 - [9] ZHANG Yao, SUNG W J, MAVRIS D N. Application of convolutional neural network to predict airfoil lift coefficient [J]. arXiv preprint arXiv, 1712.10082, 2017.
 - [10] THUREY 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.
 - [11] LEE S, YOU D. Data-driven prediction of unsteady flow over a circular cylinder using deep learning [J]. Journal of Fluid Mechanics, 2019, 879: 217-254.
 - [12] CHEN Hao, GUO Mingming, TIAN Ye, et al. Intelligent reconstruction of the flow field in a supersonic combustor based on deep learning [J]. Physics of Fluids, 2022, 34(3): 032109.
 - [13] HU Liwei, WANG Wenyong, XIANG Yu, et al. Flow field reconstructions with gans based on radial basis functions [J]. IEEE Transactions on Aerospace and Electronic Systems, 2022, 58(4): 3460-3476.
 - [14] MA Wenjun, ZHANG Jun, YU Jian. Non-intrusive reduced order modeling for flowfield reconstruction based on residual neural network [J]. Acta Astronautica, 2021, 183: 346-362.
 - [15] 何磊, 钱炜祺, 汪清, 等. 机器学习方法在气动特性建模中的应用 [J]. 空气动力学学报, 2019, 37(3): 470-479.
 - [16] 惠心雨, 袁泽龙, 白俊强, 等. 基于深度学习的非正常周期性流动预测方法 [J]. 空气动力学学报, 2019, 37(3): 462-469.
 - [17] TORO E F. Riemann solvers and numerical methods for fluid dynamics: A practical introduction [M]. Cham: Springer, 2013.
 - [18] 曹从咏, 江坤. 复杂外形火箭导弹三维绕流与喷流干扰流场的数值模拟 [J]. 南京理工大学学报(自然科学版), 2005, 29(3): 264-266.
 - [19] QIN Xuebing, ZHANG Zichen, HUANG Chenyang, et al. U²-Net: Going deeper with nested U-structure for salient object detection [J]. Pattern Recognition, 2020, 106: 107404.
 - [20] 李怡静, 程浩东, 李火坤, 等. 基于改进 U²-Net 与迁移学习的无人机影像堤防裂缝检测 [J]. 水利水电科技进展, 2022, 42(6): 52-59.
 - [21] 陈东林. 基于深度学习的气动流场快速精确预测 [D]. 长沙: 国防科技大学, 2020.
 - [22] 黄雅静, 廖爱华, 丁亚琦, 等. 多尺度 CNN 结合自注意力特征融合机制的轴承故障诊断方法 [J]. 智能计算机与应用, 2022, 12(9): 37-44.