

基于轻量化深度学习模型的粒子图像测速研究

于长东^{1**}, 毕晓君^{2*}, 韩阳³, 李海云¹, 郜云飞³

¹哈尔滨工程大学信息与通信工程学院, 黑龙江 哈尔滨 150001;

²中央民族大学信息与工程学院, 北京 100081;

³哈尔滨工程大学船舶工程学院, 黑龙江 哈尔滨 150001

摘要 粒子图像测速(PIV)作为一种非接触的、全局的间接流体力学测量技术,能够从图像中获取流体的速度场,从而揭示流体的运动规律。随着深度学习技术的发展,用深度学习技术来进行粒子图像测速具有很重要的研究价值和广泛的应用前景。基于光流神经网络,提出了一种改进型轻量级卷积神经网络,在提高粒子图像测速精度的同时,减小了模型的参数量,提高了测试速度。首先,将目前能够获取最优刚体估计的光流神经网络架构进行了改进,采用人工合成的粒子图像数据集进行有监督训练。然后,将训练得到的网络模型与当前最先进的用于粒子图像测速的深度学习模型进行对比评估。实验结果表明,本文提出的基于轻量化深度学习模型的粒子图像测速模型在不损失精度的同时,模型参数量减小了 9.5%,测试速度提高了 8.9%。

关键词 光计算; 粒子图像测速; 深度学习; 光流; 卷积神经网络; 轻量化

中图分类号 TP391

文献标志码 A

doi: 10.3788/AOS202040.0720001

Particle Image Velocimetry Based on a Lightweight Deep Learning Model

Yu Changdong^{1**}, Bi Xiaojun^{2*}, Han Yang¹, Li Haiyun¹, Gui Yunfei³

¹College of Information and Communication Engineering, Harbin Engineering University, Harbin, Heilongjiang 150001, China;

²College of Information and Engineering, Minzu University of China, Beijing 100081, China;

³College of Shipbuilding Engineering, Harbin Engineering University, Harbin, Heilongjiang 150001, China

Abstract Particle image velocimetry (PIV), as a non-contact, global indirect hydrodynamics measurement technique, can capture the velocity field of a fluid from an image to reveal the motion of the fluid. The development of deep learning technology and its use for PIV have significant research value and a potentially wide range of applications. In this paper, the authors propose an improved lightweight convolutional neural network based on the optical flow neural network. The proposed method improves the accuracy of particle image velocity measurement while reducing the parameter quantity of the model and improving the test speed. First, this work improves the optical flow neural network architecture with superior rigid body estimation performance, and uses an artificial particle image dataset for supervised training. The trained network model is then compared with a state-of-the-art PIV deep learning model. Experimental results indicate that the PIV based on the lightweight deep learning model proposed in this paper can reduce the number of model parameters by 9.5% and improve the test speed by 8.9% without losing accuracy.

Key words optical computing; particle image velocimetry; deep learning; optical flow; convolutional neural network; lightweight

OCIS codes 200.4740; 200.4260; 100.4996

1 引 言

粒子图像测速(PIV)是 20 世纪 80 年代提出的一种非接触的、多点、定量的流体力学测量技术,它

能够从连续的图像中获取流体运动的速度场信息^[1-2]。二维 PIV 的原理就是在流体介质中放入示踪粒子,应用强光如激光照射特定平面,通过相机多次捕捉粒子位置得到粒子图像,最后计算相邻的图

收稿日期: 2019-11-14; 修回日期: 2019-12-17; 录用日期: 2019-12-26

基金项目: 国家自然科学基金(51779050)

* E-mail: bixiaojun@hrbeu.edu.cn; ** E-mail: heu_yuchangdong@163.com

像之间的位移和移动时间,从而得到流场的速度矢量。粒子图像测速最重要的步骤就是得到流体运动的速度场。

目前,用于粒子图像测速的方法可以分为传统方法和深度学习方法,常用的传统方法有互相关分析法^[3]和光流法^[4]。相关法是通过计算连续两帧图像查询窗口的相关性,将查询相关性最大的方向作为该查询窗口的位移矢量。该方法计算速度较快,可实现现场实时处理,可直接获得速度矢量。目前具有代表性的方法是多重网格迭代算法(WIDIM),该算法通过迭代,不断减小查询窗口的尺度和间隔,进而获得更高精度的速度场。后期,研究者们又提出了很多基于互相关分析的改进算法,如自适应加权窗口互相关、单像素互相关、自适应窗口形状等方法。但是,互相关分析法是基于流体均匀移动的假设,这与流体非均匀流动不一致,故会直接导致PIV测量结果和真实速度场存在误差。目前诸多基于互相关的改进方法仍然无法测量较小尺度的精细涡结构。光流法是在光流守恒条件下建立的图像运动整体度量方法^[5]。光流法计算的奠基性方法是Horn&Schunck^[4]提出的HS光流法和Lucas&Kanade^[6]提出的LK光流法,之后很多研究者在此基础上提出了众多的改进方法。HS光流法能够提供稠密、高分辨率的速度场矢量,在近年来得到了更多的关注。但是,光流法是在图像无噪声和小位移条件下建立的,因此对噪声非常敏感,同时变分光流法由于需要进行变分优化,计算量较大,光流法的应用扩展受限。

近些年来,随着人工智能技术在各个领域的快速发展,因为深度学习具有强大的非线性拟合能力,自动特征提取的功能,批量迭代的参数更新训练方法等优势,深度学习及其相关技术在图像^[7]、语音^[8]、视频处理^[9]、文本^[10]等领域取得了广泛的应用。为了更好地提高粒子图像测速的效果,文献^[11]创新性地提出了将深度神经网络与PIV进行结合的思想。Lee等^[12]构建了一种级联形式的神经网络用以进行估计流体速度场,但是文章采用类似于相关法的查询窗口进行速度场估计,得到的速度场较稀疏,同时因为网络结构过于冗余,存在计算效率低下的问题。蔡声泽等^[13]利用光流的思想,提出了一种基于光流神经网络LiteFlowNet^[14]改进的深度学习模型LiteFlowNet-en,提高了估计速度场的精度和计算效率。然而,随着深度学习的发展,也伴随着网络复杂性问题的出现,文献^[13]提出的

模型虽然在速度场精度上在达到了一个很好的效果,但是存在网络结构庞大、冗余的缺陷,限制了深度学习的实际应用场景。因此本文研究的关键问题是如何对神经网络模型进行改进,在保证精度不减小的情况下得到更轻量化的模型,以提高模型的计算效率。

光流神经网络LiteFlowNet是当前比较先进的一种用于光流估计的网络^[14],它适用于解决刚体运动估计问题,可理解为从图片对中获取光流场(速度场)从而估计刚体的运动。在PIV中,需要得到粒子运动的速度场,这与光流的思想是一致的。因此,本文在光流模型LiteFlowNet基础之上,对网络结构进行了改进,以适应流体测速场景。为了减小模型复杂度,对网络进行了压缩并引入了轻量化神经网络中的深度可分离卷积模块;同时为了获取更精细的速度场,重新定义了损失函数。实验结果表明,本文提出的改进模型相比于文献^[13]的深度学习模型LiteFlowNet-en,在不损失精度、分辨率的情况下,模型减小了参数量,提高了计算效率,达到了轻量化的效果。

2 LiteFlowNet 网络

LiteFlowNet卷积神经网络是当前比较先进的一种用于光流估计的轻量级网络。该网络使用轻量级的级联结构,在每层金字塔结构中得到了更有效的光流估计,与此同时大大减小了模型的参数量,具有更高的计算效率,具体结构如图1所示。

LiteFlowNet网络由NetC编码器和NetE解码器两个子网络构成。NetC是一个金字塔结构的编码器,用于进行特征提取,即将输入的图片对转换成多尺度的高维特征金字塔结构。NetE是一个级联的流推理结构,在每层金字塔结构中,NetE通过选择来自特征金字塔中相同分辨率的特征来进行流推理,实现了对特征由粗到细的光流估计。

金字塔结构NetC由两个线程网络构成,在对输入的图片进行提取特征的过程中共享卷积核和网络权重。不同层用 L_k 表示,其中 k 表示从低阶特征到高阶特征的层数,各层的图像特征分别由 $\{F_k(I)\}$ 表示。例如, $\{F_2(I)\}$ 表示分辨率为一半的第2层特征。NetE光流估计结构由多个反卷积层组成,通过具体的一系列操作可实现由粗到精的光流场估计。由于具体操作超出了本文的研究范围,在这里不再赘述。本研究可以将一系列操作用函数 $f(x)$ 表示。例如,在NetE的第2层,通过使用相同

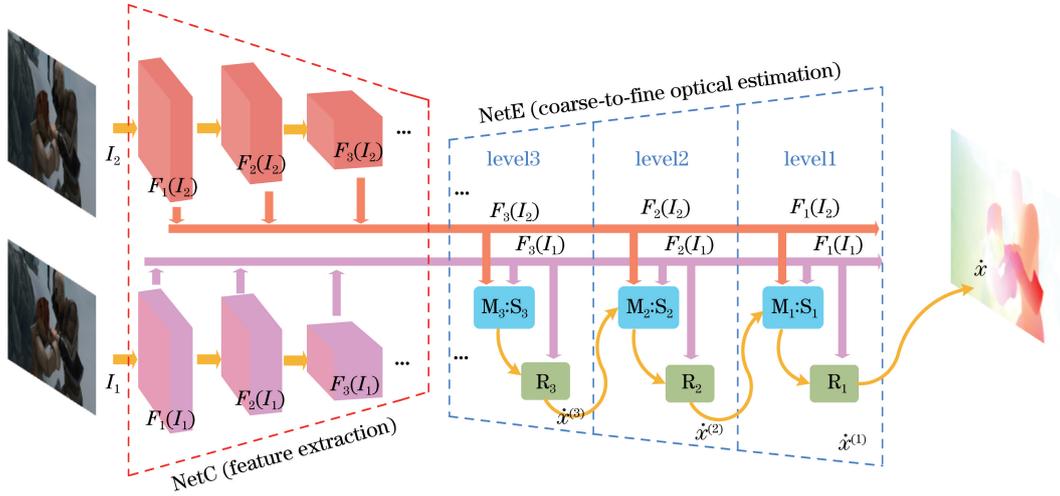


图 1 LiteFlowNet 网络结构
Fig. 1 Structure of the LiteFlowNet

分辨率的 NetC 的特征以及上一层估计出的速度 $\hat{x}^{(3)}$ 来表征图像特征,可以简单地表示为

$$\hat{x}^{(2)} = f(F_2(I_2), F_2(I_1), \hat{x}^{(3)}), \quad (1)$$

式中:函数 f 表示在每个金字塔层进行的操作;上角标 2 和 3 表示第 2 层和第 3 层。1)特征变形:在每个金字塔层,从图像 I_1 和 I_2 的特征 F_1 和 F_2 推断出光流场。如果 I_1 和 I_2 图像之间的位移偏大,则光流推断更有难度和挑战性。本研究通过特征变形来减少 F_1 和 F_2 之间的特征空间距离。通过特征变形可以得到更精细的图片特征,让网络在解决光流问题上更强大和更高效。2)特征匹配和亚像素细化模块(图 1 的 M_k 和 S_k 模块):在 NetE 的每个金字塔层,由高级特征的逐像素匹配产生粗略光流估计(M 模块的作用),随后对粗光流的细化进一步可将图像特征的像素精度提高到亚像素精度(S 模块的作用)。3)光流场正则化模块(图中的 R_k 模块):级联光流推断类似于传统方法中数据保真作用。但是仅使用数据项,光流场中通常会有光流边界模糊和异常值出现。为此,本研究使用特征驱动的局部卷积来正则化级联光流推理的光流场。相比于局部卷积,特征驱动的局部卷积适应性更好,不仅可以在特征图每个位置使用不同的滤波器,还可以自适应地构造针对各个光流补丁的滤波器。

网络训练在深度学习中是一个非常重要的环节,它通过不断地学习、拟合数据最后得到的理想网络模型。由于训练数据集通常很大,为了加快训练效率,可以采用效率更高的基于梯度的优化算法,如 Adam 梯度优化算法。LiteFlowNet 采用的是 L_2 损失函数,即

$$L_2 = \frac{1}{N} \sum_{s \in D} (\dot{x}'_s - \dot{x}_s)^2 = e_i, \quad (2)$$

式中: \dot{x}'_s 表示预测的速度场; \dot{x}_s 表示真实的速度场; e_i 表示预测速度场和真实速度场的度量误差; D 表示预测速度场的区域; S 表示 D 中的任何一个像素点; N 为 D 区域的像素点数量。同样,把训练损失函数表示为

$$\epsilon_{\text{Loss}} = \sum_i \lambda_i e_i, \quad (3)$$

式中: i 表示不同层次; λ_i 表示不同层级的权重。

3 基于改进模型的粒子图像测速

对 LiteFlowNet 网络进行三个方面的改进:

1)删除了有用信息提取量较少的 L_6 层,为了弥补精度损失,在 NetE 的 L_1 层后面又增加了 L_0 层;2)在金字塔 NetC 的部分结构中用深度可分离卷积替代传统的卷积;3)更改了损失函数,并对训练函数的损失权重进行了重新分配。

3.1 LiteFlowNet 的改进

蔡声泽等^[13]将改进的光流网络应用于粒子图像测速,该方案在测量精度上获得了一个令人非常满意的效果,但是该网络存在结构复杂、计算量大等问题。为了进一步减小模型参数数量和计算时间,根据文献[15]的思想,对 LiteFlowNet 进行了改进。在 LiteFlowNet 结构中,NetC 是由 6 层金字塔结构构成,随着金字塔深度的加深,提取的特征维度越高,分辨率越高,提取的有用特征信息越少。在 NetE 中,对应的 L_6 层是级联推理的第一层,获得的是低分辨率的速度场,获得的有用细节的特征信

息很少。所以为了进一步对模型进行压缩,删除了 NetC 和 NetE 的 L_6 层,与此同时,为了弥补精度的损失,在 NetE 的最后增加了一层反卷积层,来替换

原网络结构中的插值操作,同时每个 M 和 S 模块增加了两层卷积层,以促使 NetE 提取精细速度场的能力更强,NetE 的具体结构如图 2 所示。

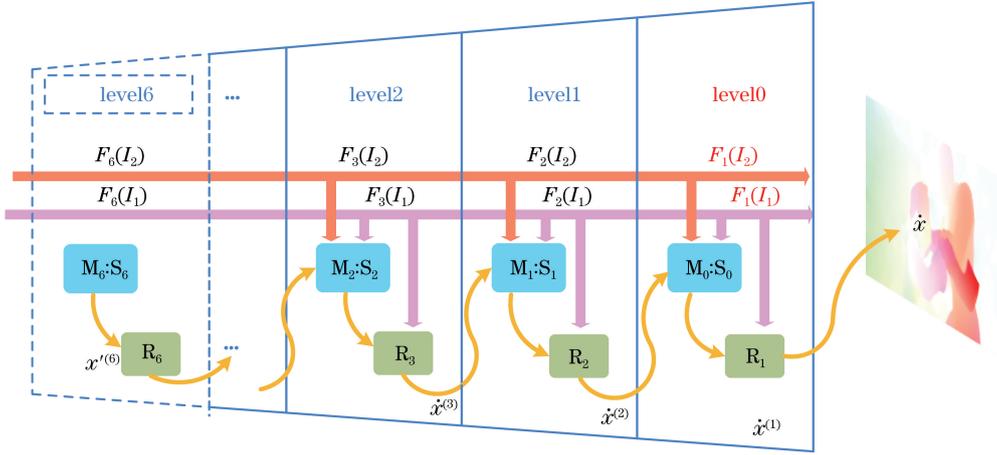


图 2 改进的 NetE 结构

Fig. 2 Improved NetE structure

利用深度可分离卷积结构^[17]对 LiteFlowNet 的 NetC 结构进行改进,深度可分离卷积是轻量化神经网络的主要结构,它的主要作用是在保证网络非线性、充分利用特征信息的同时,减小网络参数、压缩网

络结构,从而减小计算量,提高网络的运行速度。传统卷积^[18]的过程是输入图像通过与相同深度的卷积核进行卷积,得到特征信息。深度可分离卷积由 depthwise 和 pointwise 构成,具体结构如图 3 所示。

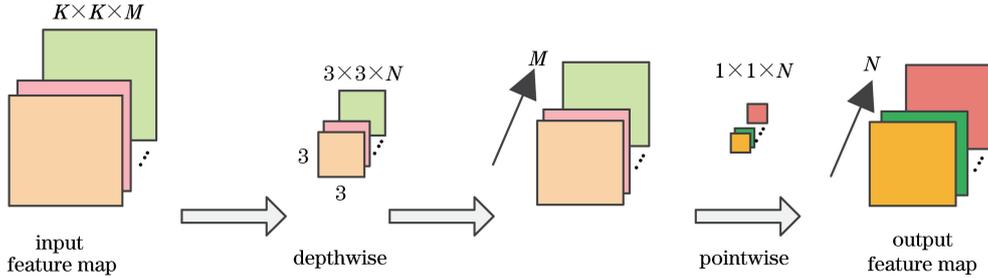


图 3 深度可分离卷积

Fig. 3 Depth separable convolution

depthwise 操作是使用单通道、尺寸为 3×3 的卷积核在对应的输入数据的每个通道上进行卷积, pointwise 是采用尺寸为 1×1 、数量为输出通道数的卷积核进行卷积操作。其中, M 与 N 表示输入通道数和输出通道数。深度可分离卷积与传统卷积的输出特征维度相同,但是模型的参数量和计算量却大幅减小。

下建立的图像运动整体度量方法,在此条件下得到的光流场具有更高的精度和稳定性。所谓的亮度恒定假设是指当图像中的像素点移动时,像素值保持不变,即

$$I(x, y, t) = I(x + u, y + v, t + 1), \quad (4)$$

式中: $I(x, y, t)$ 表示在 t 帧图像中 (x, y) 像素点的像素值; (u, v) 表示位移场, $w = (u, v, 1)^T$ 表示 t 帧图像和 $t + 1$ 帧图像之间像素点的位移。

本文用深度可分离卷积替代了 NetC 的部分卷积结构,在保证精度没有损失的情况下减小了参数量,改进后的 NetC 的网络结构参数如表 1 所示。

因为这种先验约束条件同样适用于本文的流动测速场景,所以本研究在改进的结构中,把亮度恒定假设约束条件放于损失函数中,将损失函数重新定义为

3.2 损失函数的改进

在传统光流方法中,常用的 HS 光流法是基于一种变分方程去解决能量最小化的问题^[4]。光流法是在亮度恒定不变的条件(基本光流法的假定条件)

$$L_D = \sum_{i=1}^N \rho[|I(x_i + u, y_i + v) - I(x_i, y_i)|], \quad (x_i, y_i) \in D, \quad (5)$$

表 1 改进的 NetC 网络结构参数

Table 1 Improved NetC network structure parameters

| Layer name | Kernel | Stride | Repeat times | Output resolution |
|-------------|--------|--------|--------------|-------------------|
| conv1 | 3 | 2 | 1 | 32, 256, 256 |
| conv2_1 | 3 | 2 | 1 | 32, 128, 128 |
| conv2_2 | 3 | 1 | 1 | 32, 128, 128 |
| conv2_3 | 3 | 1 | 1 | 32, 128, 128 |
| conv3_1/dw | 3 | 2 | 1 | 32, 64, 64 |
| conv3_1/sep | 1 | 2 | 1 | 64, 64, 64 |
| conv3_2/dw | 3 | 1 | 1 | 64, 64, 64 |
| conv3_2/sep | 1 | 1 | 1 | 64, 64, 64 |
| conv4_1/dw | 3 | 2 | 1 | 64, 32, 32 |
| conv4_1/sep | 1 | 2 | 1 | 96, 32, 32 |
| conv4_2/dw | 3 | 2 | 1 | 96, 32, 32 |
| conv4_2/sep | 1 | 2 | 1 | 96, 32, 32 |
| conv5/dw | 3 | 2 | 1 | 96, 16, 16 |
| conv5/sep | 1 | 2 | 1 | 128, 16, 16 |

表 2 PIV 数据集包含的流场种类

Table 2 Types of motion fields included in the PIV dataset

| Case name | Description | Quantity |
|----------------------|---|----------|
| Uniform | Uniform flow | 1000 |
| Back-step | Backward stepping flow | 3200 |
| Cylinder | Vortex shedding flow over a circular cylinder | 2050 |
| DNS-turbulence | Ahomogeneous and isotropic turbulence flow | 2000 |
| SQG | Seasurface flow driven by a Surface Quasi-Geostrophic model | 1500 |
| JHTDB-channel | Channel flow provided by Johns Hopkins Turbulence Databases | 1600 |
| JHTIDB-mhd1024 | Forced MHD turbulence provided by JHTIDB | 800 |
| JHTIDB-isotropic1024 | Forced isotropic turbulence provided by JHTIDB | 2000 |

4.2 实验环境和参数设置

本次实验中采用的硬件环境配置为 Intel(R) Core(TM) i7-6800K CPU @ 3.40 GHz、64 G 内存、64 位处理器,采用 GTX TITAN XP GPU 作加速运算,操作系统为 64 位 Ubuntu 16.04,采用基于 C++ 的深度学习框架 Caffe 完成程序编程。

参考文献[14],进行分阶段训练:1)基于金字塔 NetC 结构训练 3×10^5 代;2)基于 NetE 结构部分的 Level5 到 Level3 训练 2×10^5 代,Level2 训练 2×10^5 代,最后的 Level1 训练 3×10^5 代。初始化学率:level5 到 Level3 的学习率为 1×10^{-5} ,level2 的学习率为 2.5×10^{-6} ,level1 的学习率为 1×10^{-7} 。本文将训练后网络模型称为 LiteFlowNet-HD,后续的实验测试均采用该网络模型进行训练。

4.3 评价标准

1) PIV 算法的评价指标

式中, i 表示不同的粒子序号; ρ 表示惩罚项,这里用的是 Charbonnier 惩罚项 $\rho(x) = (x^2 + \epsilon^2)^\alpha$,其中 ϵ 设为 0.001, α 为 0.5。

4 仿真实验与结果分析

4.1 数据集介绍

网络训练需要大量的训练数据,但通常无法获得准确的速度场,故需要通过人工合成数据集进行训练。文献[16]中按照流体力学实验的方法,生成了粒子图像以及流动速度场,通过运动场对称地移动粒子的位置以获得图像对,从而构成了包含多种流场的数据集。数据集所包含的流场种类如表 2 所示。

为了与深度学习模型 LiteFlowNet-en 进行对比,本研究同样采用上述数据集进行有监督训练。该数据集包括超过 13000 项,每 1 项是由 2 张粒子图像对以及中间的速度场.flo 文件组成,超过 10 种不同工况,每种工况具有 1000 个数据样本。

关于 PIV 的评价指标有多种,本研究采用最常用的三个 PIV 算法评价指标:测量结果可视化、测量方均根误差(RMSE)、速度分布直方图统计。测量结果可视化是衡量 PIV 算法的常用手段,如矢量场的可视化、涡量图的显示等,无需真值参考。RMSE 计算公式为

$$R_{\text{MSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N [(u_i - u'_i)^2 + (v_i - v'_i)^2]}, \quad (6)$$

式中: (u_i, v_i) 表示真实粒子图像的速度值, (u'_i, v'_i) 表示测量的速度值。速度分布直方图,通过对测量的速度场进行数据分析,可以揭示峰值锁定现象^[2]。

2) 轻量化模型的参数指标

设计轻量级网络的重要意义就是为了能够使神经网络卷积模型更好地应用于移动端和嵌入式设备,故本文从模型参数量、计算复杂度两方面入手,

将改进的模型与原模型进行对比,分析改进的模型在参数量和计算量上的优势。

4.4 测试结果与讨论

为了验证算法的精度和模型的复杂度,采用具有真实值的仿真数据集进行测试。文献[19]中介绍了二维湍流流场的粒子图像,描述了直接数值模拟(DNS)下湍流流场的粒子运动。DNS数据集是国

际公认的 PIV 测试基准之一,从测试结果可视化、速度分布两方面将本文实验结果与该基准作对比。

4.4.1 可视化结果

本研究给出了湍流粒子图像序列中 $t = 50$ frame 时的真值、LiteFlowNet、文献[14]的模型 LiteFlowNet-en 和改进模型 LiteFlowNet-HD 所估计的速度场和涡量图。

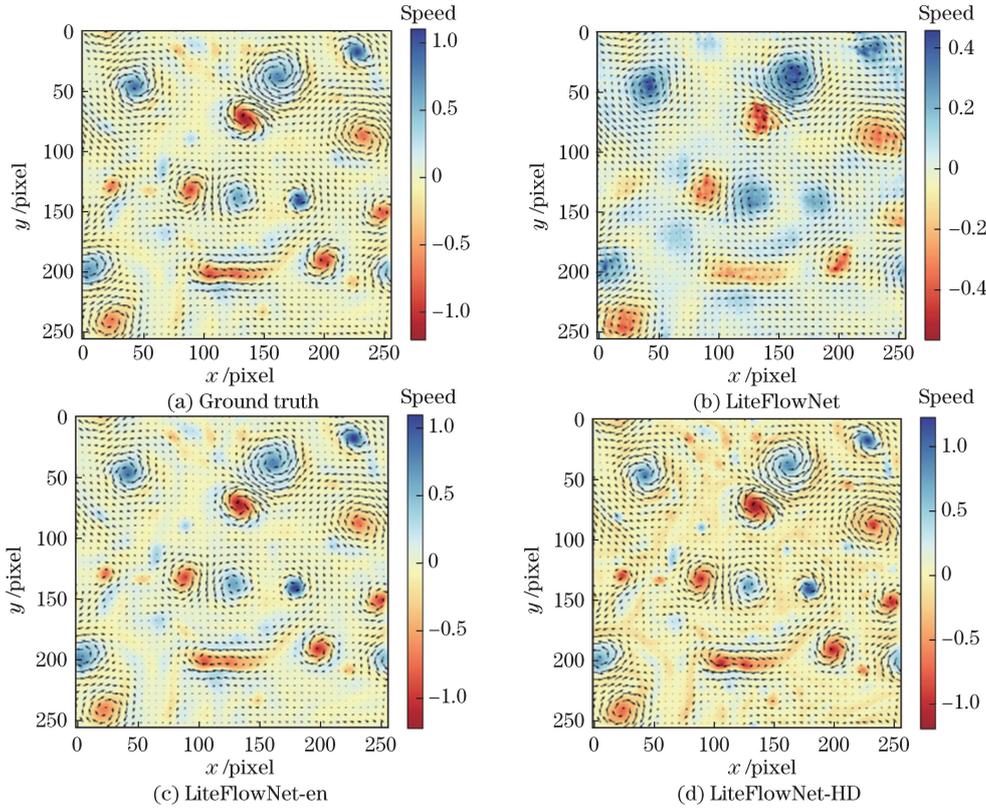


图 4 不同模型所估计的速度场及涡量图

Fig. 4 Velocity fields and vorticity maps of DNS turbulent flow estimated by different models

通过对比可以看出:没有经过改进的 LiteFlowNet 模型所估计的结果和真实值相差较大,没有完全获得速度场细节的信息;LiteFlowNet-en 模型和真实值相差不大,基本与真实值一致;改进的 LiteFlowNet-HD 模型的估计结果同样和真实值相差不大,可以获得速度场的细节信息。可以看出,光流神经网络模型在估计稠密速度场上占有优势。

4.2.2 测试误差

按照 10:1 的比例将 DNS 数据集分成训练集和测试集,并用不同模型在 DNS 数据集上进行了误差测试,结果如表 3 所示。可以看出, LiteFlowNet-HD 在训练集和测试集上都表现最好,其测试误差和训练误差都最低。

同时,为了验证实验的鲁棒性,在测试集中随机

表 3 DNS 上的测试误差

Table 3 Test errors on DNS

| Model | RMSE | |
|----------------|--------|--------|
| | Train | Test |
| LiteFlowNet | 0.2250 | 0.2300 |
| LiteFlowNet-en | 0.0710 | 0.0730 |
| LiteFlowNet-HD | 0.0680 | 0.0682 |

抽取了 100 张粒子图片对进行误差测试,误差如图 5 所示。结果表明,改进的 LiteFlowNet-HD 保持着和 LiteFlowNet-en 一样的估计精度,这对于 PIV 运动估计是十分有效的。

4.2.3 速度分布直方图

在 PIV 测量中,传统的算法只能估计出像素级别的位移场,而后来改进的一些算法,如峰值中心法、高斯峰值拟合等^[2]都可以产生 0.1 pixel 精度的

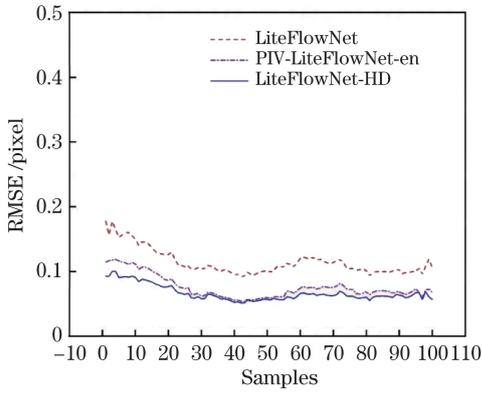


图 5 不同模型对湍流粒子图像的误差
Fig. 5 RMSE estimated by different models for turbulent image

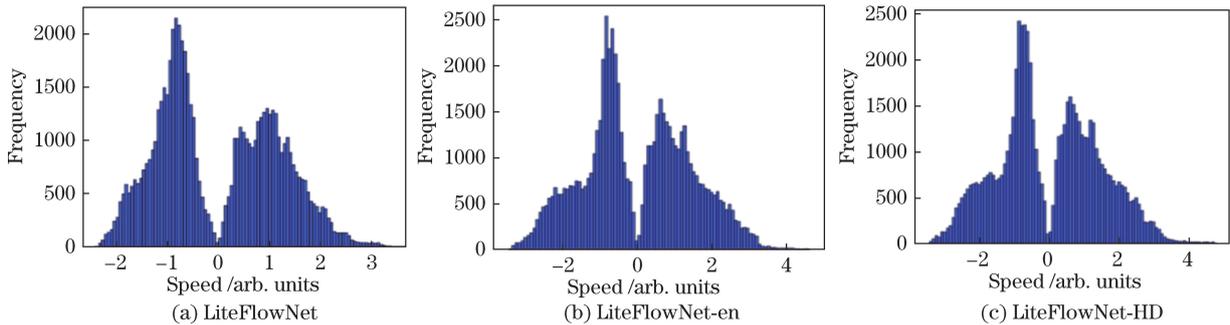


图 6 不同模型估计的速度分布直方图对比

Fig. 6 Histogram comparison of velocity distributions estimated by different models

越。另一个研究重点就是模型的轻量化。对三种模型的测试时间和参数量进行比较,结果如表 4 和图 7 所示。为了使计算时间比较更有说服力,三个模型均在相同的 GPU 下进行运行测试。

表 4 不同模型的测试时间

Table 4 Computation time of different models

| Model | Time /ms | Number of vectors |
|----------------|----------|-------------------|
| LiteFlowNet | 24.74 | 256×256 |
| LiteFlowNet-en | 46.54 | 256×256 |
| LiteFlowNet-HD | 41.98 | 256×256 |

没有进行改进的光流神经网络 LiteFlowNet,其测试速度最快,但是在 PIV 处理上没有达到要求的精度。本研究改进的 Liteflownet-HD 在测试速度相比于最新提出的 LiteFlowNet-en 模型提高了 9.8%,同时粒子图像测速的计算效率也有所提高。

通过比较模型的参数量可以看出,本文提出的模型 LiteFlowNet-HD 在模型大小上优于 LiteFlowNet-en,参数量减少了 9.5%。

综上,在二维湍流粒子图像中,本文提出的轻量级网络模型 LiteFlowNet-HD 在不损失精度的前提

下,计算效率和模型参数量都优于 LiteFlowNet-en,其表现优异的主要原因如下:1)CNN 具有强大的特征提取能力,在 NetC 结构中,CNN 在提取特征的同时能够对特征图进行下采样;2)在 NetE 结构估计速度场时,通过特征变形减小了两幅特征图 F_1 和 F_2 之间的距离,同时利用 M、S 匹配模块使估计的速度场更加精细和高效;3)引用了深度可分离卷积,同时去掉了有用信息提取量较少的 L6 层,减小了模型参数量。

4.2.4 模型参数量和计算效率

通过上述的实验结果分析,在速度场估计精度方面,本研究提出的改进模型可以和最新的粒子图像测速模型 LiteFlowNet-en 相媲美,甚至有所超

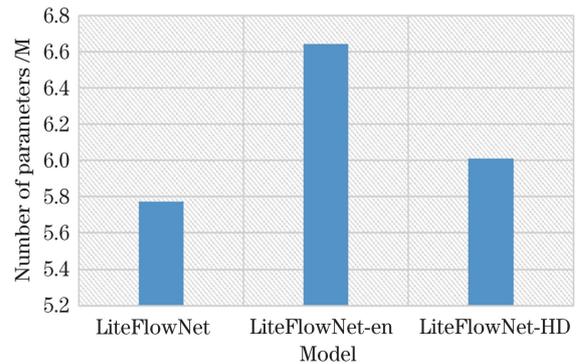


图 7 不同模型的参数量

Fig. 7 Number of parameters for different models

下,计算效率和模型参数量都优于 LiteFlowNet-en,其表现优异的主要原因如下:1)CNN 具有强大的特征提取能力,在 NetC 结构中,CNN 在提取特征的同时能够对特征图进行下采样;2)在 NetE 结构估计速度场时,通过特征变形减小了两幅特征图 F_1 和 F_2 之间的距离,同时利用 M、S 匹配模块使估计的速度场更加精细和高效;3)引用了深度可分离卷积,同时去掉了有用信息提取量较少的 L6 层,减小了模型参数量。

5 结 论

基于深度学习模型 LiteFlowNet-en, 提出轻量级网络模型 LiteFlowNet-HD。去掉了有用信息提取量较少的 L_6 层, 并在 NetE 结构的最后增加了 L_0 层, 在 M 和 S 模块增加了两层卷积层, 以弥补精度损失。引入深度可分离模块, 替代 NetC 金字塔结构的部分卷积模块。这两部分的改进降低了模型的复杂度, 使模型更加轻量化。最后, 重新定义了损失函数, 引入了传统光流方法的亮度恒定假设条件, 通过增加这样的约束条件, 不仅使速度场变得更加光滑, 同时也提高了测试速度场的精度。

经过实验表明, 与蔡声泽的深度学习模型 LiteFlowNet-en 相比, 本文提出的改进模型 LiteFlowNet-HD 在保持精度一样的情况下, 减小了模型的复杂度, 使模型变得更加轻量化, 提高了计算效率, 其总体表现优于 LiteFlowNet-en。本文提出算法将在粒子图像测速的领域具有非常广阔的应用前景。

参 考 文 献

- [1] Adrian R J. Multi-point optical measurements of simultaneous vectors in unsteady flow: a review[J]. *International Journal of Heat and Fluid Flow*, 1986, 7(2): 127-145.
- [2] Raffel M, Willert C E, Wereley S T, et al. Particle image velocimetry [M]. Berlin: Springer-Verlag Berlin Heidelberg, 2007.
- [3] Westerweel J. Digital particle image velocimetry: theory and application[D]. Delft: Delft University of Technology, 1993.
- [4] Horn B K P, Schunck B G. Determining optical flow [J]. *Proceedings of SPIE*, 1981, 0281: 319-331.
- [5] Cai S Z, Zhou S C, Xu C, et al. Dense motion estimation of particle images via a convolutional neural network[J]. *Experiments in Fluids*, 2019, 60(4): 73.
- [6] Lucas B, Kanade T. An iterative image registration technique with an application to stereo vision[C]// *Proceeding of the International Joint Conference on Artificial Intelligence (IJCAI)*, August 24-28, 1981, Vancouver, British Columbia. [S.l.: s.n.], 1981: 674-679.
- [7] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [C]// *Neural Information Processing Systems (NIPS 2012)*. December 3, 2012, Lake Tahoe, Nevada. [S.l.: s.n.], 2012: 1097-1105.
- [8] Graves A, Mohamed A R, Hinton G. Speech recognition with deep recurrent neural networks[EB/OL]. (2013-03-22) [2019-10-28]. <https://arxiv.org/abs/1303.5778>.
- [9] Karpathy A, Toderici G, Shetty S, et al. Large-scale video classification with convolutional neural networks [C]// *2014 IEEE Conference on Computer Vision and Pattern Recognition*, June 23-28, 2014, Columbus, OH, USA. New York: IEEE, 2014: 1725-1732.
- [10] Hermann K, Kočiský T, Grefenstette E, et al. Teaching machines to read and comprehend[EB/OL]. (2015-06-10) [2019-10-28]. <https://arxiv.org/abs/1506.03340>.
- [11] Rabault J, Kolaas J, Jensen A. Performing particle image velocimetry using artificial neural networks: a proof-of-concept[J]. *Measurement Science and Technology*, 2017, 28(12): 125301.
- [12] Lee Y, Yang H, Yin Z P. PIV-DCNN: cascaded deep convolutional neural networks for particle image velocimetry[J]. *Experiments in Fluids*, 2017, 58(12): 171.
- [13] Cai S Z, Xu C, Gao Q, et al. Particle image velocimetry based on a deep neural network[J]. *Acta Aerodynamica Sinica*, 2019, 37(3): 455-461.
蔡声泽, 许超, 高琪, 等. 基于深度神经网络的粒子图像测速算法[J]. *空气动力学学报*, 2019, 37(3): 455-461.
- [14] Hui T W, Tang X O, Loy C C. LiteFlowNet: a lightweight convolutional neural network for optical flow estimation[C]// *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, June 18-23, 2018, Salt Lake City, U T, USA. New York: IEEE, 2018: 8981-8989.
- [15] Hui T W, Tang X O, Loy C C. A lightweight optical flow CNN-revisiting data fidelity and regularization [EB/OL]. (2019-03-15) [2019-10-28]. <https://arxiv.org/abs/1903.07414>.
- [16] Li Y. Deep learning based particle image velocimetry technology and its application[D]. Wuhan: Huazhong University of Science and Technology, 2018: 10-12.
李勇. 基于深度学习的粒子图像测速算法研究及应用[D]. 武汉: 华中科技大学, 2018: 10-12.
- [17] Chollet F. Xception: deep learning with depthwise separable convolutions[EB/OL]. (2016-10-07) [2019-10-28]. <https://arxiv.org/abs/1610.02357>.
- [18] LeCun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. *Proceedings of the IEEE*, 1998, 86(11): 2278-2324.
- [19] Carlier J. Second set of fluid mechanics image sequences-Fluid image analysis and description: FP-6-513663 [R]. Mannheim: University of Meannheim, 2006.