

基于卷积神经网络的三色掩膜 PIV 三维粒子重构方法

梁晓艺, 丁俊飞*, 张勇, 刘逸群, 田海平

太原理工大学 航空航天学院, 晋中 030600

摘要:三色掩膜粒子图像测速技术利用三色掩膜光学元件改变成像光路, 将颜色信息与视角信息相结合, 实现单相机三维流场速度测量。然而, 由于 3 个视角间的成像视差较小, 采用传统代数重构技术得到的粒子分布结果存在明显的伸长效应, 在成像景深方向分辨率较低。针对这一问题, 本文将卷积神经网络应用于粒子重构处理中, 以减弱伸长效应, 提高三维粒子重构质量。采用基于 AIPR(Artificial Intelligence Particle Reconstruction)的网络架构, 发展适用于三色掩膜小视差的粒子图像重构算法, 并利用数字合成图像与人工合成流场, 研究不同视差大小和粒子浓度下的粒子重构效果。结果表明: 与传统代数重构方法相比, 本文方法在粒子浓度为 0.05 ppp(particle per pixel)时的重构质量提升了 30%, 重构速度达到传统方法的 2.8 倍, 能够实现粒子场的快速三维重构, 并改善粒子在景深方向的重构质量。

关键词:三色掩膜 PIV; 卷积神经网络; 三维粒子重构

中图分类号: V211.71

文献标识码: A

Three-dimensional particle reconstruction method for trichromatic mask PIV based on convolutional neural networks

LIANG Xiaoyi, DING Junfei*, ZHANG Yong, LIU Yiqun, TIAN Haiping

College of Aeronautics and Astronautics, Taiyuan University of Technology, Jinzhong 030600, China

Abstract: Trichromatic mask particle image velocimetry employs optical elements to alter imaging paths, integrating color and perspective information for single-camera three-dimensional flow velocity measurements. Due to the small imaging viewing angle between three perspectives, conventional algebraic reconstruction techniques yield elongated particle distributions and low directional resolution along the imaging depth direction. To mitigate elongation effects and enhance three-dimensional particle reconstruction quality, convolutional neural networks (CNNs) are applied. Utilizing the AIPR (Artificial Intelligence Particle Reconstruction) architecture, an algorithm tailored for small viewing angle in trichromatic mask PIV is developed. Evaluation involves synthetic image data and artificial flow fields varying in different viewing angles and particle concentration. Results demonstrate that compared to traditional algebraic methods, the proposed method improves reconstruction quality by 30% at the particle concentration of 0.05 ppp. Additionally, it achieves a reconstruction speed of up to 2.8 times faster than traditional methods, enabling the rapid three-dimensional reconstruction of the particle field and enhancing axial reconstruction quality.

Keywords: trichromatic mask PIV; convolutional neural networks; 3D particle reconstruction

收稿日期: 2024-08-01; 修回日期: 2024-08-26; 录用日期: 2024-08-29

基金项目: 国家自然科学基金项目(12102284, 12332017, 12172242); 山西省基础研究计划项目(20210302124262); 春晖计划项目(202200257)

* 通信作者 E-mail: dingjunfei@tyut.edu.cn

引用格式: 梁晓艺, 丁俊飞, 张勇, 等. 基于卷积神经网络的三色掩膜 PIV 三维粒子重构方法 [J]. 实验流体力学, 2026, 40(3): 113-120.

LIANG X Y, DING J F, ZHANG Y, et al. Three-dimensional particle reconstruction method for trichromatic mask PIV based on convolutional neural networks[J]. Journal of Experiments in Fluid Mechanics, 2026, 40(3): 113-120.

0 引言

粒子图像测速(PIV)技术作为一种非接触式流场测量技术,能够准确获取全流场的瞬态定量信息,广泛应用于流场结构的显示与测量。工程实际中的流动现象多为三维非定常流动,为研究这些复杂的流动结构,三维三分量(3D-3C)速度测量技术正在迅速发展。目前,主流的3D-3C测量技术是层析PIV(Tomo-PIV)^[1]技术。它利用3~6台相机从不同角度记录流体被测区域中的示踪粒子,通过算法重构三维粒子的强度分布,并进一步获得精确的速度场信息,具有较高的空间分辨率。

在光学测量窗口数量有限且大小受限的情况下,多相机的实验系统难以搭建。因此,近年来基于单相机的流场测试技术得以发展,主要包括镜头前加装三棱透镜法^[2]、光场PIV技术^[3-4]、彩虹PIV技术^[5-6]和三色掩膜PIV技术^[7]等。其中,三色掩膜PIV技术系统结构简单,能够通过单台彩色相机在单次曝光中对3个视角进行拍摄,并将其分别记录在不同颜色通道中,进而实现流场的三维重构。对三色掩膜彩色粒子图像进行色彩通道分离操作、提取出三视角图像后,需采用与层析PIV技术近似的方法重构粒子空间分布,最终由互相关算法得到三维速度场。因此,三维粒子场的重构是关键步骤,其准确性直接影响到3D-3C速度场的测量结果。

乘法代数重建技术(Multiplicative Algebraic Reconstruction Technique, MART)是层析PIV粒子重构的基本方法^[8-9]。该方法通过代数迭代更新三维体素的光强分布,但MART会将所有体素初始化为统一值,导致重构过程需要大量内存和较长的迭代时间。此后的MLOS-SMART(乘法视线联合乘法代数重构技术)基于MART,根据测量图像中已知的粒子匹配关系估计体素场初始值,同时结合MART迭代重构三维粒子位置,使重构效率得到提升^[10]。

MLOS-SMART方法已成功用于三色掩膜粒子图像的三维重构,并通过人工合成流场验证了其所得速度场的精度^[7],但达到最优重构质量需要数百次迭代。此外,由于单相机成像的视差较小,粒子重构结果沿景深方向会产生明显的伸长效应,导致该方向的空间分辨率降低,进而影响速度场的重构精度。因此,需要基于三色掩膜PIV的成像特点,开发更合适的重构方法。

近年来,深度学习方法在流体力学领域应用广

泛。这类方法基于神经网络的拟合能力,学习大量数据样本的深层特征,提取复杂的映射关系并完成预测表征任务。其中,将深度学习应用于PIV三维粒子重构过程的研究呈现出快速增长的趋势。在全息PIV中,研究者通过应用不同结构的U-net网络,从全息图像中提取粒子的三维坐标和半径信息,提升了粒子的提取准确率和处理速度^[11-12]。在合成孔径PIV中,研究者使用卷积神经网络处理重聚焦图像序列,实现三维粒子的提取与重构^[13-14]。在光场PIV中,研究者通过从光场图像中提取反映视角信息的子孔径图像,然后利用神经网络重构粒子的空间分布,显著减弱了伸长效应^[15-16]。考虑到三维成像原理的差异,这些方法并不直接适用于三色掩膜粒子重构。Gao等^[17]提出了适用于层析PIV三维重构的卷积神经网络方法,即人工智能粒子重构(Artificial Intelligence Particle Reconstruction, AIPR)。该方法将经过MLOS得到的初始粒子体素场作为网络的输入,输出精确的体素结果。与基于MART的传统代数重构方法相比,AIPR能够取得更高的重构质量。Himpel等^[18]应用该方法成功重构了尘埃等离子体实验流场,验证了AIPR的准确性。

基于此,本文采用AIPR方法对三色掩膜下的小视差粒子图像进行三维重构研究。以MLOS-SMART方法作为参照,通过输入不同视差与不同粒子浓度的三色掩膜PIV粒子图像,分析AIPR方法的重构质量;最后,利用人工合成的高斯涡环三维流场,比较不同重构方法的测量误差。

1 基于卷积神经网络的三色掩膜粒子重构方法

1.1 数据集构建

三色掩膜PIV使用单台相机完成粒子图像的拍摄,成像过程如图1所示。其中, S_I 为像距, S_O 为物距, R 为3个通光孔中心所成等边三角形的外接圆半径。成像系统由单台彩色相机与三色掩膜装置组成,采用白色激光照明。镜头前安装了三色掩膜装置由3片中心波长分别为450、532和650 nm的窄带扇形滤光片拼接而成,其上覆盖一层黑色掩膜,掩膜上按等边三角形排列着3个通光孔。粒子场散射的光线经过三色掩膜时,每个通光孔只允许蓝、绿、红中一种颜色的光通过,经相机透镜折射后在传感器不同位置成像。由于彩色相机传感器表面覆有与像元对应的彩色滤光片阵列,3种颜色的光会被各自

的颜色通道记录下来。粒子场被记录在一张二维彩色图像中,分离颜色通道后即可获得不同视角的粒子图像,进而使用相关重构算法恢复三维信息。




图 1 三色掩膜成像原理示意图

Fig. 1 Schematic diagram of trichromatic mask imaging principle

三色掩膜成像系统虽然能在一张图像中获取不同视角的粒子场投影,但由于相机主透镜前布置的 3 个通光孔导致的视差较小,重构出的粒子会产生伸长效应。待测区域尺寸变化时,镜头放大倍率 M 和掩膜外接圆半径 R 是影响视差的主要因素。 M 的定义如下:

$$M = -S_I / S_O \quad (1)$$

由上式可知, M 的绝对值越小,对应的物距 S_O 越大,拍摄范围越大。

神经网络以层析重构得到的初步体素强度场作为输入,输出预测的体素场强度分布,通过学习大量数据样本并提取其特征,从而拟合初始场与真实场之间粒子空间分布的映射关系。由于实验无法获得真实的三维粒子分布,因此使用模拟数据构建数据集,构建过程如图 2 所示。受计算机内存和显存限制,选择 $128 \times 128 \times 200$ 的体素大小作为样本尺寸。首先,在该空间区域内随机生成一组粒子坐标,按高斯分布赋予体素场强度,作为粒子空间分布的真实值样本。然后,利用光线跟踪方法计算每个掩膜孔对应视角的投影变换矩阵,合成三色掩膜分离颜色通道后的粒子图像;最后,利用 MLOS 方法得到初始粒子场。其中,粒子的虚拟直径为 3 体素,粒子空间强度的高斯分布峰值为 160,成像后在图像上占据 3 像素 $\times$ 3 像素。将初始的粗糙粒子空间分布与对应的真实体素场共同作为数据样本。

本文在合成粒子图像时所选用的光学参数为:




图 2 数据集构建过程

Fig. 2 Dataset construction process

像元边长 0.004 mm, 焦距 100 mm, 名义光圈 1.8, 每个掩膜通光孔直径 5 mm。在三色掩膜 PIV 技术中,色彩通道提取步骤可有效减少图像噪声,从而提升重构粒子的准确性和可靠性,因此在模拟数据中忽略了噪声对实验结果的影响。

为了研究不同视差下模型的重构能力,本文选择了 9 种视差条件,由放大倍率 M 分别取 -1.0、-0.5、-0.2,掩膜外接圆半径 R 分别取 32、16、8 mm 两两组合而成。同时,为确保模型能够有效地学习和泛化各种浓度下的粒子分布,每种视差条件下均选取多个粒子浓度,以每像素粒子数 (particle per pixel, ppp) 计分别为 0.01、0.05、0.10、0.15、0.20,每个浓度采集 500 个样本,一种视差条件共 2500 组样本。将样本打乱后,按 8:2 的比例划分为训练集和验证集。

1.2 卷积神经网络模型

神经网络结构基于 AIPR,如图 3 所示,共包含 12 个隐藏层,每层均依次由三维卷积层、批量归一化 (BN) 层和激活函数层组成。为有效提取景深方向特征,前 11 层卷积核形状设置为 $3 \times 3 \times 11$,较大的深度尺寸有助于捕捉更多深度信息;最后一层卷积核形状为 $3 \times 3 \times 3$ 。所有卷积层均采用 same padding,以保持输出尺寸与输入相同。同时,第 2~11 层的通道数均为 16,第一层和最后一层的通道数为 1。每层卷积后接批量归一化层,以提升训练速度




图 3 卷积神经网络结构

Fig. 3 Convolutional neural network structure

和模型稳定性。前 11 层批量归一化后应用 ReLU 激活函数,最后一层则使用 sigmoid 函数,将体素强度预测结果限制在 0 到 1 之间。

本文使用 Dice Loss 作为损失函数^[19-20],网络以最小化该损失函数为目标,在训练过程中优化网络参数。损失函数 L_{oss} 计算式如下:

$$L_{\text{oss}} = 1 - \frac{2 \sum_i (E_{0,i} \cdot E_{\text{pred},i})}{\sum_i E_{0,i}^2 + \sum_i E_{\text{pred},i}^2} \quad (2)$$

式中, $E_{0,i}$ 和 $E_{\text{pred},i}$ 分别为真实体素场与网络预测体素场在 i 位置处的强度值。该损失函数能反映 2 个样本之间的相似程度,当预测结果与真实强度分布完全一致时,其值为 0。

在训练过程中,针对每种视差情况分别进行训练。每次训练共设置 9 个轮次,每 3 个轮次后将学习率降低为原来的 1/10;使用 Adam 优化器更新网络参数,同时采用指数移动平均策略增强网络泛化能力。网络基于 PyTorch 库实现,训练在 NVIDIA RTX 3060 Ti 显卡上进行,每次训练时长约 9 h。图 4 展示了 $M = -1$ 、 $R = 32$ mm 条件下的网络训练情况,其中 Q 值作为评估网络预测准确性的指标,具体定义将在 2.1 节介绍。由于数据集中包含多种粒子浓度的样本,图中的损失值与 Q 值反映的是样本总体的平均情况。随着训练轮次的增加,损失函数不断减小并趋于平缓,验证集 Q 值保持稳定,且与训练集精度基本一致。




图 4 $M = -1$ 、 $R = 32$ mm 时损失函数与准确性随训练过程的变化
Fig. 4 Variation of loss function and accuracy throughout the training process at $M = -1$, $R = 32$ mm

2 结果与讨论

2.1 重构质量

使用训练完成的网络模型进行粒子三维重构。

在 $R = 32$ mm、粒子浓度 0.05 ppp 的条件下,选取 $M = -1.0$ 、 -0.5 、 -0.2 这 3 种放大倍率进行粒子重构。粒子场的真实分布与重构结果的局部放大情况如图 5~7 所示。本文采用世界坐标系, x - y 平面为垂直于光轴的平面, z 轴表示景深方向。随着 M 绝对值减小,视差减小, MLOS 与 MLOS-SMART 方




图 5 $M = -1.0$ 、 $R = 32$ mm、粒子浓度 0.05 ppp 的粒子场局部放大图
Fig. 5 Close-up of particle field at $M = -1.0$, $R = 32$ mm, 0.05 ppp concentration




图 6 $M = -0.5$ 、 $R = 32$ mm、粒子浓度 0.05 ppp 的粒子场局部放大图
Fig. 6 Close-up of particle field at $M = -0.5$, $R = 32$ mm, 0.05 ppp concentration




图 7 $M = -0.2, R = 32 \text{ mm}$ 、粒子浓度 0.05 ppp 的粒子场局部放大图
Fig. 7 Close-up of particle field at $M = -0.2, R = 32 \text{ mm}$, 0.05 ppp concentration

法重构粒子的伸长效应逐渐明显。其中，MLOS 场作为神经网络的输入数据场，其强度分布粗糙，无法确定粒子的具体位置；MLOS-SMART 重构的粒子由椭圆形伸长为梭形甚至针形，景深方向分辨率较低，且强度值降低。而 AIPR 方法能够保持更好的粒子形状，空间位置与强度分布基本与真实情况一致，在景深方向具有更高的分辨率。

重构质量因子 Q 可定量反映真实粒子场与重构粒子场之间的相似性，其定义如下：

$$Q = \frac{\sum_i E_{0,i} \cdot E_{1,i}}{\sqrt{\sum_i E_{0,i}^2 \cdot \sum_i E_{1,i}^2}} \quad (3)$$

式中， $E_{0,i}$ 与 $E_{1,i}$ 分别为 i 位置处的真实体素强度值与重构体素强度值。 Q 取值在 0~1 之间， Q 值越大，表明重构体素场的强度分布与真实分布越相似，重构质量越好。

采用与生成训练集相同的方法构建测试数据集。在粒子浓度 0.05 ppp 条件下，将 M 分别取 -1.0、-0.5、-0.2， R 分别取 32、16、8 mm，组成 9 种视差工况，每种工况生成 100 个样本，并分别使用 AIPR 算法和迭代 100 次的 MLOS-SMART 算法进行重构。对每种视差工况的重构结果计算平均重构质量因子。2 种重构方法在不同 M 与 R 下的 Q 值如图 8 所示。随着 M 绝对值和 R 的减小，成像视差逐步减小，




图 8 2 种方法在不同视差下的粒子重构质量

Fig. 8 Comparison of reconstruction quality under different viewing angles using two methods

2 种方法的粒子重构质量均随之降低，但 AIPR 方法的质量因子始终比传统重构方法高出 30% 以上。

为比较不同方法的重构质量因子随粒子浓度的变化，在 $M = -1.0, R = 32 \text{ mm}$ 的条件下，选取 0.010 ppp 以及从 0.025~0.200 ppp 以 0.025 ppp 为间隔的共 9 种粒子浓度，每种浓度生成 100 个样本，分别使用 MLOS、MLOS-SMART(迭代 10 次、20 次、100 次)和 AIPR 方法进行重构，重构结果的平均质量因子如图 9 所示。随着粒子浓度的增大，各方法的重构质量因子均呈现下降趋势。MLOS-SMART 方法随着迭代次数的增加， Q 值有所提升，但提升幅度逐渐减小；AIPR 方法的 Q 值在各浓度条件下均优于传统方法，且在 0.010~0.100 ppp 浓度范围内的重构质量保持在 0.6 以上，较传统方法提升明显。因此，AIPR 方法在不同粒子浓度下表现出较好的泛化能力与更高的重构质量，能够以较高的准确性预测三维粒子空间分布。




图 9 多种方法在不同粒子浓度下的粒子重构质量

Fig. 9 Reconstruction quality of different methods with varying seeding densities

2.2 人工合成流场验证

为验证 AIPR 模型用于流场测量的可行性，采

用人工合成的高斯涡环三维流场进行速度误差分布测试。

合成流场测量区域的尺寸为 $4 \text{ mm} \times 4 \text{ mm} \times 0.8 \text{ mm}$ ，以测量区域中心平面 ($z = 0 \text{ mm}$) 作为涡核平面，生成直径为 1.4 mm 的圆形涡核。流场运动的位移大小 d 的表达式如下：

$$d = \begin{vmatrix} u \\ v \\ w \end{vmatrix} = \frac{0.05r}{l} e^{-r/l} \quad (4)$$

式中： u 、 v 、 w 分别为速度矢量在 x 、 y 、 z 方向的分量， w 方向对应景深方向； r 为空间点到涡核的径向距离； l 为涡宽度的特征尺度，此处取 0.5 mm 。

选取 $M = -1.0$ ， $R = 32 \text{ mm}$ 的视差工况，图像粒子浓度取 0.05 ppp ，在空间中随机均匀生成 50000 个粒子位置后，由式 (4) 计算粒子的速度矢量，得到下一帧的粒子空间位置，并合成前后 2 帧的三色掩膜各通道粒子图像。


分别使用 AIPR 方法与迭代 100 次的 MLOS-SMART 方法对粒子图像进行三维重构，将测量区域离散为 $1000 \text{ 体素} \times 1000 \text{ 体素} \times 200 \text{ 体素}$ 的体素场，空间分辨率为 $0.04 \times 0.04 \times 0.04 \text{ mm}^3/\text{体素}$ 。

此处需要注意，AIPR 网络模型在训练过程中始终使用较小尺寸的体素场，因此在处理大尺寸体素场时，需将其分割为与网络输入尺寸相同的子区域逐一处理，再拼接回原尺寸。相邻子区域在垂直于景深方向的重叠率为 14.8% 。此外，通过小区域训练学习得到的网络结果反映的是局部映射关系，将其用于处理大尺寸体素场，可视为将小区域的局部映射关系近似为整体粒子体素场的强度映射关系。


对真实三维粒子场与重构所得粒子场，采用多重网格三维互相关算法计算速度场：第一重网格互相关窗口大小为 $64 \text{ 体素} \times 64 \text{ 体素} \times 64 \text{ 体素}$ ，第二重窗口大小为 $32 \text{ 体素} \times 32 \text{ 体素} \times 32 \text{ 体素}$ ，重叠率均为 50% 。图 10 对比了真实速度场与 AIPR 获得的测量速度场，左侧为涡环流场的速度矢量与涡量 0.1 s^{-1} 的等值面，右侧为 $x = 0 \text{ mm}$ 平面上的速度矢量图，真实速度场的最大粒子位移为 4.6 体素 。可以看出，AIPR 所得的涡结构清晰，与真实速度场较为吻合。

2 种方法在 $u-v$ 平面与 $u-w$ 平面的误差散点图如图 11 所示。可以看出：2 种方法所得 u 和 v 的误差分布近似，均聚集在零误差点附近；AIPR 方法的误差分布略微分散。在 w 方向，由于 MLOS-SMART 方法景深方向分辨率较低，且 w 分量误差呈不对称分

布，其 w 误差散点图呈细长状，集中在 $0 \sim 0.3 \text{ 体素}$ 之间；而 AIPR 方法的 w 误差分布较为集中，主要分布在 $0 \sim 0.15 \text{ 体素}$ 之间。使用累积误差分布函数定量对比 2 种方法的速度测量精度，结果如图 12 所示。



(a) 真实速度场



(b) AIPR 所得速度场

图 10 人工合成流场测试结果

Fig. 10 Measurement results of synthetic flow field





图 11 速度误差散点图

Fig. 11 Scatter diagrams of velocity measurement errors

图 12 u 、 v 、 w 方向的速度误差累积分布函数对比Fig. 12 Comparison of cumulative distribution functions of velocity error (u , v , w)

与 MLOS-SMART 方法相比, AIPR 方法在 u 、 v 方向上的误差累积分布曲线向右偏移, 这主要是由于网络模型拟合的局部映射关系与大尺寸体素场的全局粒子位置及强度分布存在偏差, 导致预测精度下降, 重构质量降低。而在 w 方向上, AIPR 方法的速度测量误差明显小于传统方法, 表明 AIPR 方法对粒子三维重构中伸长效应的改善有效减小了景深方向的速度测量误差, 提升了景深方向的速度测量精度。

在流场测试区域的粒子重构过程中, 基于 GPU 计算, 迭代 100 次的 MLOS-SMART 方法重构 1 帧粒子场的耗时为 79.665 s, AIPR 方法的重构时间为 28.435 s, 重构速度提升至约 2.8 倍, 该时间包含大尺寸场裁剪及子区域结果拼接耗时, 每个子区域的实际计算时间仅为 0.147 s。MLOS-SMART 方法的计算速度受迭代次数、粒子浓度和视差大小影响较大, 而训练完成的神经网络能以稳定的计算时间进行重构, 因此 AIPR 方法相较于 SMART 方法具有更高的重构效率。

3 结 论

本文实现了基于卷积神经网络的窄视差三色掩膜三维粒子重构方法, 分析了神经网络在不同视差与粒子浓度下的重构效果, 并通过人工合成流场验证了该方法用于流场测量的可行性。

1) 相较于传统的 MLOS-SMART 重构算法, AIPR 方法可显著改善粒子伸长现象, 三维粒子的位置与强度分布都更加准确。

2) 在不同视差和粒子浓度条件下, AIPR 方法的重构质量因子均优于传统方法, 表现出良好的泛化能力。

3) AIPR 方法能以更高的效率重构粒子分布, 并取得与传统方法精度接近的流场测量效果。其中, w 方向的测量误差小于传统方法, 80% 的速度矢量绝对误差小于 0.2 体素, 优于传统方法 80% 误差小于 0.3 体素的表现; 但受限于训练样本尺寸较小, AIPR 方法学习到的局部映射与全局粒子空间分布存在偏差, 在应用时会给 u - v 方向引入额外的误差。

基于卷积神经网络的窄视差三色掩膜三维粒子重构方法计算成本低, 且在景深方向具有更高的空间分辨率, 有望应用于真实实验测量研究。后续可针对重构体素区域尺寸较小导致的大视场重构需拼接的问题, 引入迁移学习方法, 分区域学习体素场不同位置的空间强度分布映射关系, 以实现全流场的精确三维粒子重构。

参考文献:

- [1] ELSINGA G E, SCARANO F, WIENEKE B, et al. Tomographic particle image velocimetry[J]. *Experiments in Fluids*, 2006, 41(6): 933-947.
doi: 10.1007/s00348-006-0212-z
- [2] GAO Q, WANG H P, WANG J J. A single camera volumetric particle image velocimetry and its application[J]. *Science China Technological Sciences*, 2012, 55(9): 2501-2510.
doi: 10.1007/s11431-012-4921-7
- [3] FAHRINGER T W, LYNCH K P, THUROW B S. Volumetric particle image velocimetry with a single plenoptic camera[J]. *Measurement Science and Technology*, 2015, 26(11): 115201.
doi: 10.1088/0957-0233/26/11/115201
- [4] 丁俊飞, 许晟明, 施圣贤. 光场单相机三维流场测试技术[J]. *实验流体力学*, 2016, 30(6): 50-58.
DING J F, XU S M, SHI S X. Light field volumetric particle image velocimetry[J]. *Journal of Experiments in Fluid Mechanics*, 2016, 30(6): 50-58.
doi: 10.11729/syltlx20160141
- [5] XIONG J H, IDOUGHI R, AGUIRRE-PABLO A A, et al. Rainbow particle imaging velocimetry for dense 3D fluid velocity imaging[J]. *ACM Transactions on Graphics*, 2017, 36(4): 1-14.
doi: 10.1145/3072959.3073662
- [6] SHAN L, XIONG J Z, SHI F Y, et al. Three-dimensional color particle image velocimetry based on a cross-correlation and optical flow method[J]. *Chinese Physics B*, 2023, 32(5): 054702.
doi: 10.1088/1674-1056/acb1ff
- [7] 丁俊飞, 梁晓艺. 基于三色掩膜的单彩色相机三维流场测试技术[C]//第十二届全国流体力学学术会议论文集. 2022.
- [8] SCARANO F. Tomographic PIV: principles and practice[J]. *Measurement Science and Technology*, 2013, 24(1): 012001.
doi: 10.1088/0957-0233/24/1/012001
- [9] 李晓辉, 王宏伟, 黄湛, 等. 层析粒子图像测速技术研究进展[J].

- 实验流体力学, 2021, 35(1): 86-96.
- LI X H, WANG H W, HUANG Z, et al. Research advances of tomographic particle image velocimetry[J]. *Journal of Experiments in Fluid Mechanics*, 2021, 35(1): 86-96. doi: [10.11729/syltlx20190160](#)
- [10] ATKINSON C, SORIA J. An efficient simultaneous reconstruction technique for tomographic particle image velocimetry[J]. *Experiments in Fluids*, 2009, 47(4): 553-568. doi: [10.1007/s00348-009-0728-0](#)
- [11] WU Y F, WU J C, JIN S Z, et al. Dense-U-net: dense encoder-decoder network for holographic imaging of 3D particle fields[J]. *Optics Communications*, 2021, 493: 126970. doi: [10.1016/j.optcom.2021.126970](#)
- [12] WANG S, YOU F C, WANG X W. Research on 3D particle field reconstruction method based on deep learning[J]. *Journal of Physics: Conference Series*, 2023, 2562(1): 012049. doi: [10.1088/1742-6596/2562/1/012049](#)
- [13] QU X J, SONG Y, JIN Y, et al. 3D particle field reconstruction method based on convolutional neural network for SAPIV[J]. *Optics Express*, 2019, 27(8): 11413-11434. doi: [10.1364/OE.27.011413](#)
- [14] QU X J, ZHANG P, QU R, et al. 3D tracer particle field reconstruction based on 3D CNN in SAPIV[C]//Proc of the Sixth Conference on Frontiers in Optical Imaging and Technology: Imaging Detection and Target Recognition. 2024. doi: [10.1117/12.3018841](#)
- [15] 沈诗宇, 李健, 顾梦涛, 等. 基于卷积神经网络深度学习模型的光场显微三维粒子空间分布重建[J]. *光学学报*, 2023, 43(21): 2115002.
- SHEN S Y, LI J, GU M T, et al. Deep learning-based three-dimensional spatial distribution reconstruction for light field micro-particle image velocimetry with convolutional neural network[J]. *Acta Optica Sinica*, 2023, 43(21): 2115002. doi: [10.3788/AOS230958](#)
- [16] 傅梦希, 朱效宇, 张良, 等. 基于深度残差神经网络的光场粒子图像测速粒子场重建方法[J]. *光学学报*, 2024, 44(16): 1612001.
- FU M X, ZHU X Y, ZHANG L, et al. Method of particle field reconstruction in light field particle image velocimetry based on deep residual neural networks[J]. *Acta Optica Sinica*, 2024, 44(16): 1612001. doi: [10.3788/AOS240721](#)
- [17] GAO Q, PAN S W, WANG H P, et al. Particle reconstruction of volumetric particle image velocimetry with the strategy of machine learning[J]. *Advances in Aerodynamics*, 2021, 3: 28. doi: [10.1186/s42774-021-00087-6](#)
- [18] HIMPEL M, MELZER A. Fast 3D particle reconstruction using a convolutional neural network: application to dusty plasmas[J]. *Machine Learning: Science and Technology*, 2021, 2(4): 045019. doi: [10.1088/2632-2153/ac1fc8](#)
- [19] DICE L R. Measures of the amount of ecologic association between species[J]. *Ecology*, 1945, 26(3): 297-302. doi: [10.2307/1932409](#)
- [20] REZATOFIGHI H, TSOI N, GWAK J, et al. Generalized intersection over union: a metric and a loss for bounding box regression[C]//Proc of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2019. doi: [10.1109/CVPR.2019.00075](#)



作者简介:

梁晓艺(2000—), 男, 山西阳泉人, 硕士研究生。研究方向: 三色掩膜单相机三维流场测试技术。

E-mail: liangxiaoyi1844@link.tyut.edu.cn

(编辑: 秦虹)