

基于三维卷积编码和 MLP 解码的无监督三维粒子场重建方法

张端宇, 周 鹭, 封明军, 蔡小舒

(上海理工大学 能源与动力工程学院, 上海 200093)

摘要: 深度学习技术的迅猛发展激发了一些新的方法来解决层析粒子图像测速的三维重建问题。针对有监督深度学习需要大量的真值数据, 以及仿真数据集与实验场景一致性的问题, 提出了基于三维卷积编码和 MLP 解码的无监督粒子重建算法, 命名为 MLOS-CNN-MLP。该方法首先利用 MLOS 算法, 从多视角二维图像生成初始三维光强分布, 然后通过三维卷积编码提取特征并构建神经编码体, 再采用 MLP 解码回归精确的三维光强分布。与有监督学习方法使用真值数据不同, MLOS-CNN-MLP 通过投影函数对重建的光强分布进行不同视角的投影, 并与原始二维图像进行比较, 建立损失函数, 这使得整个网络训练不需要真值数据从而实现无监督学习。在仿真数据集上的验证结果表明, 所提出的无监督粒子重建算法在实验常用粒子浓度下的重建精度可达到 0.95, 远高于传统的代数重建技术。进一步对比不同粒子浓度和噪声鲁棒性方面的性能, 该方法的重建质量也均优于传统的代数重建技术, 并且计算速度至少快了一个数量级。

关键词: 层析粒子图像测速; 三维重建; 无监督学习; 神经网络

中图分类号: TP 181 **文献标志码:** A

Unsupervised three-dimensional particle field reconstruction method based on three-dimensional convolution encoding and MLP decoding

ZHANG Duanyu, ZHOU Wu, FENG Mingjun, CAI Xiaoshu

(School of Energy and Power Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: The rapid development of deep learning has inspired some new methods to solve the 3D reconstruction problem of tomographic particle image velocimetry. In order to solve the problem that the supervised deep learning method requires a large number of ground truth data and the synthetic

收稿日期: 2024-03-30

基金项目: 国家自然科学基金资助项目(52376163); 国家航空科学与技术重点实验室项目(614220121050327)

第一作者: 张端宇(2000—), 男, 硕士研究生。研究方向: 图像法流场测量。E-mail: 212210039@st.usst.edu.cn

通信作者: 周 鹭(1986—), 女, 教授。研究方向: 图像法颗粒与两相流在线测量。E-mail: zhouwu@usst.edu.cn

引文格式: 张端宇, 周鹭, 封明军, 等. 基于三维卷积编码和 MLP 解码的无监督三维粒子场重建方法[J]. 上海理工大学学报, 2025, 47(4): 414-421.

Citation: ZHANG Duanyu, ZHOU Wu, FENG Mingjun, et al. Unsupervised three-dimensional particle field reconstruction method based on three-dimensional convolution encoding and MLP decoding[J]. Journal of University of Shanghai for Science and Technology, 2025, 47(4): 414-421.

dataset is consistent with the experimental scene, an unsupervised particle reconstruction algorithm based on 3D convolution encoding and MLP decoding was proposed, named MLOS-CNN-MLP. This method first used the MLOS algorithm to generate the initial three-dimensional light intensity distribution from multi-view 2D images, then extracted features and constructs neural encoders through 3D convolution encoding, and finally used MLP decoding to regress the accurate three-dimensional light intensity distribution. Unlike the supervised learning methods that use ground truth data, MLOS-CNN-MLP employed a projection function to render the reconstructed 3D distribution into multiple views and compared them with the original 2D images to compute the loss function, which made the whole network training without ground truth data to achieve unsupervised learning. The verification result on the synthetic data shows that the reconstruction accuracy of the proposed unsupervised particle reconstruction algorithm can reach 0.95 under typical experimental particle density, which is much higher than that of the traditional algebraic reconstruction technique. Further comparing the performance of different particle densities and noise robustness, the reconstruction quality of the proposed method is better than that of the traditional algebraic reconstruction technique, and the calculation speed is at least one order of magnitude faster.

Keywords: *tomographic particle image velocimetry; 3D reconstruction; unsupervised learning; neural network*

对流体运动机理研究的前提是获得准确及定量的流场数据, 因此, 发展可靠的流场测量方法对于解决流体动力学中的机理问题和指导工程实践都具有重大意义。在所有的 3D-3C(three dimensional-three component) 测量方法中, 层析粒子图像测速 (particle image velocimetry, PIV)^[1] 是一种基于多相机采集与体光源照明的流场测量技术, 结合粒子图像测速技术与计算机断层扫描技术, 能够实现完全意义上三维空间内 3 个速度分量的流场测量。该技术可以同时采集多个不同视角的瞬时流场图片, 再利用三维重建与三维互相关算法测量三维流场。其核心之一是通过光学层析成像重建三维粒子场光强分布, 即求解从二维粒子图像到三维粒子场光强分布的反投影问题。

自 Elsinga 等^[2] 于 2006 年正式提出层析 PIV 原理, 并使用基于最大熵准则的乘法代数重建技术 (multiplicative algebraic reconstruction technique, MART) 重建三维粒子场光强分布以来, 诸多重构算法如 MLOS-(S)MART(2009)^[3]、SF-(S)MART(2013)^[4]、IntE-(S)MART(2016)^[5] 等先后被提出, 用于优化三维粒子场重建结果, 以获得更高的质量或效率。随着深度学习在图像处理领域的发展, 利用深度学习来处理与流场测量相关的问题已成为一个热门话题。在过去的几年中, 有

监督学习方法已被应用于层析 PIV 重建。Liang 等^[6] 提出 MART 层析重建, 使用卷积神经网络 (convolutional neural network, CNN) 进行滤波, 以减少伪影粒子生成和正则化重构粒子形状, 但仅限于二维粒子场。Gao 等^[7] 提出了一种基于具有几何信息特征的 CNN 的粒子重建方法, 该方法可以从非常粗糙的粒子光强分布初始猜测中细化粒子场重建, 其结果优于 SF-(S)MART 的重建结果。

然而, 由于缺乏广泛可靠的真值数据, 有监督学习方法存在一定的局限性, 特别是在试图推广到真实实验场景时。在计算机视觉和图形学领域, 一项名为神经渲染 (neural rendering) 的研究探索了使用无监督学习方法来合成复杂场景的新视图, 其将深度学习与传统渲染结合起来, 通过神经网络学习三维场景表示, 并依赖计算机图形学中的渲染函数进行监督。Lombardi 等^[8] 提出了一种基于半透明体表示的对象和场景建模方法, 可以从多视图 RGB 图像中进行端到端学习重建三维场景。该方法首次将体积渲染技术运用到神经渲染当中, 但重建的三维场景还是会受到空间分辨率的限制。Mildenhall 等^[9] 提出的神经辐射场 (neural radiance fields, NeRF) 则通过输入场景的多视角图片和相机位姿, 使用多层感知器 (multilayer perceptron, MLP) 神经网络来学习三维场景, 然后

使用体积渲染技术来合成任意视角(包括新视角)的场景图片,其经过训练后可以呈现出逼真的合成视图。而针对 NeRF 计算速度慢、泛化能力差等问题,Anpei 等^[10]提出了 MVSNeRF,可以仅从几个(少至 3 个)非结构化多视图中重建辐射场,并且具有较强的泛化能力,避免了繁琐的逐场景优化,可以通过快速的网络推理直接回归到新颖视图的真实图像。神经渲染技术突破了传统三维建模对真实三维数据的依赖限制,仅需借助多视角场景图像序列,即可实现对复杂三维场景的逆向重建,并基于重建结果合成任意视角的高质量场景图像,有效克服了传统有监督学习方法在三维视觉任务中需要大量真值数据的弊端,为层析 PIV 的三维重建问题提供了新的思路。

本文借鉴 MVSNeRF 的架构,提出了一种基于三维卷积编码和 MLP 解码的无监督粒子重建算法,通过最小化原始二维图像与从重建的三维粒子场光强分布生成的投影图像之间的差异来更新三维粒子场光强分布,命名为 MLOS-CNN-MLP。通过生成的仿真数据集,将其和传统代数重建算法进行对比,结果证明了 MLOS-CNN-MLP 在重建质量和噪声鲁棒性方面的优越性。

1 研究原理

1.1 层析 PIV 三维重建

层析 PIV 是将 PIV 技术和计算机断层扫描技术结合而产生的一种三维粒子图像测速技术,能够实现空间流场的全场定量测量。在测量区域内释放一定浓度的示踪粒子,利用体光源照射测量区域内的示踪粒子,同时使用多个(一般为 3~6 个)相机记录粒子运动图像,然后根据照片中像素灰度的分布,通过三维重建和三维互相关算法得到粒子的位移信息,进一步根据曝光时间计算出速度场。

层析 PIV 的工作原理大致可以分成 4 个主要过程: a. 照亮流场,浸没在流体中的示踪粒子被三维空间内的脉冲光源照亮; b. 相机记录,利用相机从多个观测方向记录相邻时刻的示踪粒子分布图像; c. 三维重建,根据不同机位相机的成像结果重构出三维粒子场光强分布; d. 三维互相关,基于互相关分析的迭代多重网格窗口变形技术,将 2 个重构出的三维粒子场光强分布做三维互相

关得到三维空间速度场。

其中,三维重构是层析 PIV 的核心步骤之一,对于获取准确的流场信息起着至关重要的作用。

常用的层析 PIV 重建方法包括代数重建技术(algebraic reconstruction technique, ART)和乘法代数重建技术(multiplicative algebraic reconstruction technique, MART)^[2]。ART 算法基于加法原理,通过迭代地校正初始猜测,计算原始记录图像与投影图像之间的差异,以获取重建的光强分布。在三维光强分布的重建过程中,ART 算法的表达式为

$$E(X_j, Y_j, Z_j)^{k+1} = E(X_j, Y_j, Z_j)^k + \frac{I(x_i, y_i) \sum_{j \in N_i} E(X_j, Y_j, Z_j)^k}{\sum_{j \in N_i} w_{i,j}^2} \quad (1)$$

式中: $E(X_j, Y_j, Z_j)$ 为世界坐标 (X_j, Y_j, Z_j) 处体素 j 的光强; $I(x_i, y_i)$ 为图像坐标 (x_i, y_i) 处像素 i 的强度; $w_{i,j}$ 为加权系数,表示体素 j 对每个像素 i 的贡献,本文采用正向投影面积法对其进行计算^[11]; k 为迭代次数; μ 为松弛参数,取值范围通常为 0~2。

与 ART 算法类似, MART 算法基于乘法原理,通过迭代地修正原始记录图像与投影图像之间的差异,从而获得重建的光强分布。一旦在迭代过程中计算得到某个体素的强度为 0,那么该体素的强度在以后的迭代中将不会改变。因此, MART 算法更适用于层析 PIV 重建。MART 算法的表达式为

$$E(X_j, Y_j, Z_j)^{k+1} = E(X_j, Y_j, Z_j)^k \left(\frac{I(x_i, y_i)}{\sum_{j \in N_i} w_{i,j} E(X_j, Y_j, Z_j)^k} \right)^{\mu w_{i,j}} \quad (2)$$

式中, μ 取值范围通常为 0~1。

可以看出,良好的初始光强分布对于 ART 和 MART 算法至关重要。而乘法视距算法(multiplied line-of-sight, MLOS)^[3]不仅可以为 ART 和 MART 提供良好的初始光强分布,还可以缩短计算时间。MLOS 试图通过每个体素和像素强度的映射关系找出体素空间中的非零体素。真实粒子所在体素的投影可以通过每个摄像机的视线跟踪到相应的像素,为了使该点体素的强度大于零,则对

应位置的像素强度也必须大于零, 而如果这些像素的强度都大于零, 则它们的乘积也大于零。这种方式, 可以利用相应像素强度的乘积快速确定体素是否具有可忽略的强度, 从而获得初始的光强分布。通过使用 MLOS 提供的初始光强分布, MART 重建的处理时间可以大大缩短。然而, 基于乘法的估计方法会误将零值体素误认为非零体素。因此, MLOS 会产生比真实粒子分布更多的不存在的非零体素(称为伪影粒子), 而代数重建算法并不能显著减少伪影粒子的数量。

1.2 深度学习

近年来, 机器学习, 特别是深度学习, 在应用于许多现实问题方面取得了很大进展^[12-14], 一般可以把深度学习方法分为有监督学习和无监督学习, 两者主要的区别在于是否需要真实的标签数据。如之前所说, 目前也已经有基于有监督学习方法的层析 PIV 三维重建工作。然而, 有监督学习方法严重依赖于大量的训练数据, 在大多数实际情况下, 特别是在流体动力学中, 很难获取大量的真值数据或者人为地对数据进行准确注释。尽管使用仿真数据集作为替代方案, 但其与实际场景之间的差距限制了构建网络的泛化能力。这意味着基于有监督学习的方法在面对层析 PIV 实

际场景时可能会遇到困难。

相比之下, 无监督学习方法可以在不需要真值数据的条件下训练神经网络, 因此, 探索其在层析 PIV 三维重建领域的性能具有重要意义。而目前尚无以无监督学习为基础解决层析 PIV 三维重建问题的先例。Anpei 等^[10]关于 MVSNerF 方面的工作给了我们启发, 因此, 将其无监督学习思想扩展到层析 PIV 三维重建问题。通过生成的仿真数据集训练模型, 与有监督学习方法不同的是, 只使用数据集中的粒子图像, 将真实的三维粒子场光强分布用于基准测试。

2 无监督粒子重建算法

本文借鉴 MVSNerF 的架构, 提出了一种基于三维卷积编码和 MLP 解码的无监督粒子重建方法, 命名为 MLOS-CNN-MLP, 用于在层析 PIV 中重建三维粒子场的光强分布。算法的流程如图 1 所示, 基于多视角原始二维图像和相应相机内外参数。首先, 采用 MLOS 算法生成初始三维粒子光强分布 P ; 然后, 通过构建 3D CNN B 作为编码器来重建神经编码体 F ; 最后, 利用 MLP A 作为解码器回归出三维粒子场光强分布 C 。




图 1 无监督粒子重建算法流程图

Fig.1 Diagram of the unsupervised particle reconstruction algorithm

最后, 利用投影函数来对重建的光强分布进行不同视角的投影。将投影后的图像与原始二维图像进行比较, 建立损失函数, 这使得整个网络训练不需要真值数据从而实现无监督学习。

2.1 网络结构

3D CNN B 具体的网络结构如图 2 所示, 主要由 12 个卷积单元组成, 每个卷积单元包括一个三维卷积层, 一个正则化层 (batch normalization, BN), 一个 ReLU 激活函数。正则化层有助于缓解梯度消失问题并提高网络的稳定性, ReLU 激活函数用于引入非线性并促进稀疏激活和快速收敛。

整个 3D CNN 网络通过特征提取来学习构建神经编码体 F , 以用于接下来的体素回归, 整个过程可以表示为

$$F = B(P) \tag{3}$$

加入给定的空间坐标 (X,Y,Z) , 利用 MLP A 从神经编码体 F 中回归三维粒子场光强分布 C 。MLP A 的网络结构如图 3 所示, 由 8 个全连接层组成, 并以 ReLU 函数作为激活函数, 然后再使用 4 个向下采样层来降低维度直至预测一个单一的、非负的输出来得到相应的强度值。整个过程可以表示为




图2 3D CNN B网络结构

Fig.2 3D CNN B network structure




图3 MLP A网络架构

Fig.3 MLP A network structure

$$C = A(X, Y, Z, F) \quad (4)$$

$$p_i = \sum_j w_{i,j} c_j \quad (6)$$

此外,受NeRF^[9]的启发,在将空间坐标输入MLP A进行训练之前,将其归一化到 $[-1,1]$ 范围内,并使用坐标嵌入进行预处理。坐标嵌入的表达式为

$$\gamma(q) = (\sin(2^0 \pi q), \cos(2^0 \pi q), \sin(2^1 \pi q), \cos(2^1 \pi q), \dots, \sin(2^{L-1} \pi q), \cos(2^{L-1} \pi q)) \quad (5)$$

式中:编码函数 $\gamma(\cdot)$ 为对已经归一化到 $[-1,1]$ 范围内的输入坐标 q 进行编码; L 为频率参数,决定了编码的频率数量和输出向量的维度, L 越大,使用的频率越高、越多,能捕捉的细节也越多,但维度也越高,在本文中,将 L 值设置为8。

坐标嵌入采用三角函数对空间坐标进行类似傅里叶变换的编码,有助于MLP网络对高频信息的学习以避免相邻空间坐标在网络训练中的过平滑问题^[15],同时加快了神经网络的训练速度和收敛速度。

2.2 投影函数

在计算机视觉和图形学领域,通常使用发射模型或发射-吸收模型进行模型训练^[16]。鉴于粒子分布重建的离散性和稀疏性,采用透视投影函数从重建的三维粒子场光强分布生成投影图像,并通过将投影图像与真实图像进行比较来进行优化。在特定视角下,通过方程(7),可以获得三维粒子场光强分布在CCD图像平面上的投影结果:

式中: p_i 表示像素 i 的强度值; c_j 表示体素 j 的强度值。

由于上述透视投影函数是完全可微的,可以将其纳入神经网络的训练中。按照上述步骤,可以生成特定视角下粒子场光强分布的预测投影。然后将预测投影图像的像素强度值 p_i 与原始二维图像的像素强度值 $\bar{p}_i$ 之间的均方误差(mean square error, MSE)作为训练的损失函数,表示为

$$\sum_i \|p_i - \bar{p}_i\|_2^2 \quad (7)$$

在训练过程中,使用Adam优化算法^[17],学习率设置为0.001。模型训练的硬件环境为Intel i5-12490F CPU和NVIDIA RTX 2080Ti GPU,通过Python3.9和PyTorch对模型进行编程实现。

3 重建算法验证

3.1 数据集生成

在本研究中,使用仿真数据集对神经网络进行训练和测试。仿真粒子场及其投影图像的生成方法可参考封明军等^[11]的研究。主要采用针孔相机模型生成粒子场的投影,并对粒子的形状和强度进行仿真。仿真成像主要参数包括粒子直径 $d_p=1 \mu\text{m}$,光圈数 $f=10$,入射光波长 $\lambda=0.532 \mu\text{m}$,

放大倍率 $M=0.1$, CCD 单元像素尺寸为 $5\text{ }\mu\text{m}$ 。生成的数据集包括 6000 组大小为 $100\times100\times40$ 的空间分辨率仿真粒子场, 以及其在与 Y 轴偏离角度分别为 $\{-20^\circ, 0^\circ, 20^\circ\}$ 下的分辨率大小为 120×120 的投影粒子图像, 粒子在投影成像上的尺寸为 3×3 像素。当像素与体素尺寸比为 1 时, 可以精确确定粒子的亚像素位置, 以避免“峰值锁定”效应, 从而有助于后续的互相关计算, 因此, 仿真粒子场的粒子尺寸被设置为 $3\times3\times3$ 体素。仿真粒子场的粒子浓度取值范围为 $0.05\sim0.30$ ppp (particle per pixel, 每像素粒子数), 间隔为 0.05 ppp。然后, 通过 MLOS 算法生成的初始粒子场光强分布被用作神经网络的输入。在训练过程中, 将 80% 的数据用于训练, 20% 的数据用于测试。

为了增强模型的鲁棒性, 在 20% 的粒子图像中添加了均值为 0、标准差为 $0.05\sim0.20$ 的高斯噪声。

3.2 结果与讨论

为了验证所提出的无监督粒子重建算法在重建质量方面的准确性和稳定性, 采用空间分布相关系数 $Q^{[2]}$ 作为质量因子对其进行分析。在以往的研究中, 通常采用阈值 $Q_{th} = 0.75$ 作为判定标准。当 Q 大于 Q_{th} 时, 表明重构足够精确。 Q 的计算公式如下:

$$Q = \frac{\sum_j E_r(X_j, Y_j, Z_j) E_{tr}(X_j, Y_j, Z_j)}{\sqrt{\sum_j E_r(X_j, Y_j, Z_j)^2 \sum_j E_{tr}(X_j, Y_j, Z_j)^2}} \quad (8)$$

式中: $E_{tr}(X_j, Y_j, Z_j)$ 为仿真粒子场的光强分布, $E_r(X_j, Y_j, Z_j)$ 为重建粒子场的光强分布。

将训练好的无监督粒子重建算法 MLOS-CNN-MLP 通过测试集数据与 MLOS-MART 和 MLOS-SAMRT 高精度传统重建算法进行对比, 结果如图 4 所示。可以看出, 随着粒子浓度的升高, 几种方法的重建质量均有所降低, 但是相比于 MLOS-MART 和 MLOS-SMART, MLOS-CNN-MLP 始终保持着更高的重建质量。在实验常用浓度 0.05 ppp 下, MLOS-CNN-MLP 的重建精度可到达 0.95 左右, 同样浓度下 MLOS-MART 和 MLOS-SMART 均只能达到 0.86 左右。当粒子浓度高于 0.15 ppp 时, MLOS-MART 和 MLOS-SMART 的重建精度低于 0.75 , 而 MLOS-CNN-MLP 的重建精度在 0.2 ppp 之内都可以保持高于 0.75 , 这说明所提出的无监督粒子重建算法在重建高浓度粒子场方面具有优势。




图 4 不同粒子浓度下重建质量对比

Fig.4 Comparison of reconstruction quality under different particle densities

图 5 展示了粒子浓度在 $0.05\sim0.20$ ppp 范围内不同方法重建粒子场的中心截面图。可以看出, 在粒子浓度为 0.05 ppp 时, MLOS-CNN-MLP 和 MLOS-MART、MLOS-SMART 都可以较好地重建粒子场, 但是 MLOS-CNN-MLP 重建粒子场的光强分布更符合真实粒子场, 而单纯使用 MLOS 算法是无法满足精度要求的。当在重建更高浓度粒子场时, MLOS-MART 和 MLOS-MART 产生了较多的伪影粒子, 并且重建的粒子具有许多不规则的形状, 其重建效果远远不如 MLOS-CNN-MLP。




图 5 不同粒子浓度下的三维粒子场的中心截面图

Fig.5 Central cross-sectional diagrams of the three-dimensional particle field under different particle densities

同时, 为了对所提出的无监督粒子重建算法的抗噪性能进行评估, 在粒子浓度为 0.05 ppp 的投影图像中, 加入标准差 σ 为 $0.05\sim0.20$ 的高斯噪声, 图 6 展示了来自其中一个视角的不同噪声等级下的投影图像。将 MLOS-CNN-MLP 与 MLOS-




图 6 不同噪声等级下的投影图像

Fig.6 Projected images under different noise levels

MART、MLOS-SMART 进行比较，由图 7 可以看出，由于噪声改变了原始图像的灰度值，因此，随着噪声水平的增加，所有方法的重建质量都会降低。但 MLOS-CNN-MLP 依旧始终高于传统的




图 7 不同噪声等级下重建质量对比

Fig.7 Comparison of reconstruction quality under different noise levels

代数重建技术。图 8 显示了在噪声标准差 σ 为 0.10 时，不同方法重建的三维粒子场光强分布的中心截面。可以清楚地看到，与 MLOS-MART 和 MLOS-SMART 只能给出较为粗糙的重建分布不同，MLOS-CNN-MLP 能够更好地重建三维粒子光强分布，表明其有更好的抗噪性。




图 8 σ 为 0.10 时不同方法重建粒子场的中心截面图

Fig.8 The central cross-sectional diagrams of the particle field reconstructed by different methods when σ is 0.10

在重建时间方面，均按照 MLOS 得到初始光强分布之后开始对比。如表 1 所示，在粒子浓度为 0.05 ppp 的情况下，MLOS-MART、MLOS-SMART 的重建时间分别为 126.4 s 和 275.2 s，而 MLOS-CNN-MLP 的重建时间仅为 7.26 s。相比 MLOS-MART 和 MLOS-SMART，MLOS-CNN-MLP 的重建效率大大提升。而在相同大小的重建区域下(本文为 $100\times100\times40$ 空间分辨率的仿真粒子场

表 1 不同方法的重建时间

Tab.1 The reconstruction time of different methods

重建算法	重建时间/s
MLOS-CNN-MLP	7.26
MLOS-MART	126.4
MLOS-SMART	275.2

光强分布)，观察到，在不同粒子浓度和噪声等级下，3 种重建算法的重建时间基本相同，表明粒子浓度和噪声水平对重建时间的影响较小。

4 结 论

提出了一种基于三维卷积编码和 MLP 解码的无监督粒子重建算法，命名为 MLOS-CNN-MLP，用于重建层析 PIV 三维粒子场光强分布。该算法通过最小化原始二维图像与重建的三维粒子场光强分布的投影图像之间的差异，来更新三维粒子场光强分布并训练网络。在仿真数据集上的结果表明，所提出的无监督粒子重建算法在重建质量和噪声鲁棒性方面均优于传统的代数重建技术。无监督学习方法不依赖于任何真值数据进行训练，这使得它相较于有监督学习方法更有希望推

广到复杂的真实实验场景。

参考文献:

- [1] 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.
- [2] ELSINGA G E, SCARANO F, WIENEKE B, et al. Tomographic particle image velocimetry[J]. *Experiments in Fluids*, 2006, 41(6): 933–947.
- [3] ATKINSON C, SORIA J. An efficient simultaneous reconstruction technique for tomographic particle image velocimetry[J]. *Experiments in Fluids*, 2009, 47(4): 553–568.
- [4] DISCETTI S, NATALE A, ASTARITA T. Spatial filtering improved tomographic PIV[J]. *Experiments in Fluids*, 2013, 54(4): 1505.
- [5] WANG H P, GAO Q, WEI R J, et al. Intensity-enhanced MART for tomographic PIV[J]. *Experiments in Fluids*, 2016, 57(5): 87.
- [6] LIANG J M, CAI S Z, XU C, et al. Filtering enhanced tomographic PIV reconstruction based on deep neural networks[J]. *IET Cyber-Systems and Robotics*, 2020, 2(1): 43–52.
- [7] GAO Q, PAN S W, WANG H, et al. Particle reconstruction of volumetric particle image velocimetry with the strategy of machine learning[J]. *Advances in Aerodynamics*, 2021, 3(1): 28.
- [8] LOMBARDI S, SIMON T, SARAGI H J, et al. Neural volumes: learning dynamic renderable volumes from images[J]. *ACM Transactions on Graphics*, 2019, 38(4): 65.
- [9] MILDENHALL B, SRINIVASAN P P, TANCIK M, et al. NeRF: representing scenes as neural radiance fields for view synthesis[C]//16th European Conference on Computer Vision. Glasgow: Springer, 2020: 405–421.
- [10] CHEN A P, XU Z X, ZHAO F Q, et al. MVSNerF: fast generalizable radiance field reconstruction from multi-view stereo[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV). Montreal: IEEE, 2021: 14104–14113.
- [11] 封明军, 周骛, 黄浩钦, 等. 基于正向投影面积法的层析粒子图像测速权重系数计算方法 [J]. *光学学报*, 2023, 43(11): 1110001.
- [12] 田书耘, 万震天, 谢岳生. 燃气轮机气路故障诊断技术综述与展望 [J]. *能源研究与信息*, 2022, 38(1): 23–28.
- [13] 马立新, 李渊, 郑晓栋, 等. 基于高阶 BP 神经网络的最大负荷预测 [J]. *能源研究与信息*, 2016, 32(3): 153–157.
- [14] 马立新, 范丽君. 基于小波包神经网络的整流电路晶闸管故障识别 [J]. *能源研究与信息*, 2016, 32(1): 45–50.
- [15] YU A, YE V, TANCIK M, et al. PixelNeRF: neural radiance fields from one or few images[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville: IEEE, 2022: 4576–4585.
- [16] TAGLIASACCHI A, MILDENHALL B. Volume rendering digest (for NeRF)[DB/OL]. [2022-08-29] <https://arxiv.org/abs/2209.02417>.
- [17] KINGMA D P, BA J. Adam: a method for stochastic optimization[C]//3rd International Conference on Learning Representations. San Diego: ICLR, 2015.

(编辑: 黄 娟)