文章编号:1002-2082 (2020) 04-0662-13

# 基于深度学习的粒子场数字全息成像研究进展

吴羽峰[1,2],吴佳琛[3],郝 然[1,2],金尚忠[1,2],曹良才[3]

(1. 中国计量大学 光学与电子科技学院,浙江 杭州 310018; 2. 浙江省现代计量测试技术及仪器重点实验室,浙江 杭州 310018; 3. 精密测试技术及仪器国家重点实验室,清华大学 精密仪器系,北京 100084)

**摘 要:** 粒子场的数字全息成像中,由一幅粒子场全息图重建出高精度的三维粒子场分布,是数字全息技术领域的经典问题之一。相比于传统反向重建算法,深度学习算法可以从单个全息图直接重建出三维粒子场来简化算法复杂度,提高计算效率和准确率。介绍国内外研究团队将深度学习算法结合数字全息技术实现粒子场数字全息成像的研究进展,从不同粒子表征方法入手,叙述了支持向量机、全连接神经网络、全卷积网络、U-Net 网络、深度神经网络在粒子场数字全息成像中粒子表征及粒子场反向重建过程中的应用原理、实现途径和准确率。最后指出了深度学习算法在这一研究领域的优势及目前基于深度学习算法的不足,并对如何进一步提高该方法的准确率进行了展望。

**关键词:** 粒子场;数字全息;深度学习;神经网络

**中图分类号:** TN206; O436 **文献标志码:** A **DOI:** 10.5768/JAO202041.0409003

## Research progress of particle field digital holography based on deep learning

WU Yufeng[1,2], WU Jiachen[3], HAO Ran[1,2], JIN Shangzhong[1,2], CAO Liangcai[3]

(1. College of Optical and Electronic Technology, China Jiliang University, Hangzhou 310018, China; 2. Key Laboratory of Zhejiang Province on Modern Measurement Technology and Instruments, Hangzhou 310018, China; 3. State Key Laboratory of Precision Measurement Technology and Instruments, Department of Precision Instrument, Tsinghua University, Beijing 100084, China)

**Abstract:** In the digital holography of particle field, reconstructing a high-precision three-dimensional particle field distribution from a particle field hologram is one of the classic problems in the field of digital holography. Compared with the traditional inverse reconstruction algorithm, the deep learning algorithm can directly reconstruct the three-dimensional particle field from a single hologram to simplify the algorithm complexity and improve the calculation efficiency and accuracy rate. The research progress of particle field digital holography in combining deep learning algorithm with digital holography technology by the research teams at home and abroad was introduced. Starting from different methods of particle characterization, the application principles, implementation approach and accuracy rate of the support vector machine, fully connected neural network, fully convolutional network, U-Net network and deep neural network in the process of particle characterization and particle field inverse reconstruction for particle field holography were described. Finally, the advantages and shortcomings of deep learning algorithm in this research field were pointed out, and how to further improve the accuracy of this method was prospected.

**Key words:** particle field; digital holography; deep learning; neural network

---

**收稿日期:** 2020-03-10; **修回日期:** 2020-04-28

**基金项目:** 国家自然科学基金(61975182);国家重点研发计划(2018YFF0214904);浙江省重点科技计划项目(2020C03095);之江实验室重点研发项目(2019DE0KF01)

**作者简介:** 吴羽峰(1995-),男,硕士研究生,主要从事全息成像方面的研究。E-mail: cjluyufengwu@163.com

## 引言

数字全息技术的记录过程是将物波和参考波的干涉图样记录为全息图，重建过程是对单幅全息图进行衍射计算，还原记录的全息图。该技术可实现三维成像，能够用于粒子场数字全息成像中粒子表征及粒子场反向重建。因此，数字全息技术已经应用到生物医学[1]、海水水质分析[2-3]、燃烧过程[4-5]、侵蚀过程[6]、流体力学[7-8]和目标跟踪[9]等多个领域。

深度学习算法是计算成像中一种很有效的工具[10-11]。深度学习就是在神经网络的基础上，通过添加中间层层数的一种学习网络。1986 年，由 D. E. Rumelhart 教授的团队提出了反向传播(BP)算法，使深度学习算法开始在实践中得以应用[12]。后来由于 BP 算法的“梯度爆炸”问题，深度学习的研究进入了低潮。但在 2006 年 G. E. Hinton 提出深度信念网络的概念和新的训练方法，克服了深度学习训练过程中的瓶颈问题，掀起了深度学习算法研究的热潮[13]。在图像识别领域中，传统方法受环境影响大，识别率不稳定[14]，深度学习算法可以获得图像的多种特征，受外界干扰因素影响小，识别准确率高且稳定，使其在该领域得到广泛应用[15-16]。在语音识别领域，传统的语音识别方法在大量的语音数据中难以取得较好的效果，深度学习算法是以数据驱动的算法模型，可以从大量数据中进行对比分析并提取有用特征，使其在该领域得到广泛应用[17]。在文本分析[18]和视频分析[19]等领域中，传统方法不能考虑语序信息，常常忽略前后内容之间信息的关联，而深度学习算法可将前后内容之间信息进行关联，并对后续信息进行预测，基于这种特点使该算法在文本分析和视频分析等领域中得到了广泛应用并取得了显著的效果。

由于深度学习中的卷积神经网络在图像特征提取、复杂函数拟合等方面的卓越表现，近年来，它在数字全息中也显示出巨大的潜力[20]。深度学习算法特别是卷积神经网络(CNN)已经应用到数字全息多个领域中。如采用 CNN 可做全息图重建，同时可实现拓展景深，自动对焦和相位恢复，相比于传统迭代方式，复杂度$\boldsymbol{O}(MN)$降到$\boldsymbol{O}(1)$使得重建速度得到显著提升[21]；Y. Rivenson 等人提出了用 CNN 做相位恢复和全息重建，这种基于深度学习的方法可以快速消除孪生像和与之干涉的伪图像[22]；K. Wang 等人提出了一种 Y-Net 的网络进行全息重建，该方法不需要预先对全息图做反传播重建，直接对探测器上得到的全息图进行重建，使得计算时间更少[23]；同时还有使用 CNN 做全息图的相位解包[24]与全息图的焦点估计[25]等。相比于传统方法，基于深度学习的方法计算时间更快，且不需要太多的先验知识[26]。

粒子场的数字全息成像中，从单幅全息图中重建出三维粒子场分布是数字全息技术领域的经典问题之一。从全息图中反向重建出三维粒子场分布主要分为 2 个步骤：一是全息粒子表征；二是重建三维粒子场。全息粒子表征是对粒子场的全息图作定量分析，以测量各个粒子的三维位置及半径大小。然后用得到的粒子三维信息和半径大小进行粒子场的三维重建。传统全息粒子表征方法主要应用于胶体粒子，用洛伦兹-米氏(Lorenz-Mie)光散射理论来计算全息图，并检测和跟踪胶体粒子[27]。但由于洛伦兹-米氏光散射理论计算公式比较复杂，计算时间较长，很难实现实时计算全息图来检测和跟踪粒子。还有学者通过反向重建算法重建三维粒子场，并应用阈值分割[28-29]或聚焦评价函数[30-31]来提取粒子信息进行粒子场的三维重建。其中阈值方法的准确度随着粒子与背景的区分度减弱而减小，聚焦评价函数则通常对粒子的细节特征和全息图的噪声敏感，此类缺陷限制了这些传统方法的应用。针对上述局限性，研究者提出了几种逆重建方法，主要包括反卷积法[32-33]和迭代优化法[34-37]。反卷积法将三维重建中所观察到的模糊图像建模为真实目标与点扩展函数(PSF)的卷积，对 PSF 建模需根据已知的衍射公式或者通过实验获得点状物体的全息图[32-33]。迭代优化法将原始全息图与计算全息图差异的最小化作为目标优化函数，并引入一组稀疏和平滑的物理约束条件[34-37]。这 2 种方法的计算量大，还需要手动设置或调试参数，同时由于没有考虑与光学畸变和粒子交叉干扰相关的动态噪声特征，使得算法的重建性能存在局限。近年来由于深度学习算法可以直接从单个全息图重建出三维粒子场分布而受到广泛关注。深度学习算法由于将大量时间花费在网络模型训练上，网络模型参数是自动调整参数，无需手动设置，节省了算法的调试时间。网络模型训练完成后，只需要花费$O(1)$的空间复杂度就可以重建出三维粒子场分布，计算效率明显优于传统算法。此外，传统数字全息重建方法只能重建出粒子场分布，若要获取粒子的三维坐标、半

径大小和折射率大小等信息，还需人工做进一步处理。深度学习在对目标信息的特征提取上具有优势，通过特定参数来表征粒子并作为训练的目标函数，可通过训练好的网络直接从全息图中提取出所需信息，大大提高了处理数据的效率。2014 年 D. G. Grier 等人将支持向量机（SVM）应用于全息粒子表征过程中，并采用深度坐标、半径和折射率($z_p, r_p, n_p$)表征粒子的方法，使其运算处理更快，借助上位机可将检测和跟踪单个粒子的时间成倍缩短，并有望在移动端实现更快的实时检测和跟踪单个粒子[38]。2015 年 B. Schneider 等人将 ANNs 神经网络应用于全息粒子表征过程中，并采用内、外核折射率和半径($n_1, n_2, R_{core}, R_{shell}$)表征粒子的方法，使其可以检测更复杂的生物细胞[39]。2019 年 Y. Wu 等人将全卷积网络（FCN）应用于小粒子全息粒子表征中，并采用二维坐标($x, y$)表征粒子，能检测出传统阈值分割方法不能检测到的粒子，从而提高检测精度和误检率[40]。同年 T. Shimobaba 等人将 U-Net 网络应用于全息粒子表征及粒子场反向重建中，并采用粒子三维坐标和半径($x, y, z, R$)表征粒子的方法来提取粒子三维信息和半径大小，然后反向重建出了三维粒子场，实现了比理论值更高的定位精度[41]。2020 年 S. Shao 等人提出了新的 U-Net 架构进行全息粒子表征及粒子场反向重建，并采用三维坐标($x, y, z$)表征粒子的方法进行粒子场反向重建，使得粒子检测效率更高[42]。

本文在统一框架下介绍数字全息的基本概念，基于深度学习算法的粒子场数字全息成像中粒子表征及粒子场反向重建的基本原理，并分别叙述以粒子深度信息、半径大小和折射率大小($z, r, n$)表征粒子，粒子内核折射率、外壳折射率、内核半径和外壳半径($n_1, n_2, R_{core}, R_{shell}$)表征粒子，粒子二维坐标($x, y$)表征粒子，粒子三维坐标($x, y, z$)表征粒子，粒子三维坐标和半径($x, y, z, R$)表征粒子等 5 种不同的粒子表征方法。介绍了支持向量机（SVM），以及全连接神经网络、全卷积网络（FCN）、U-Net 网络和深度神经网络（DNN）4 种深度学习网络结构的应用原理、实现途径和准确率。

## 1 基本原理

### 1.1 数字全息基本原理

传统全息术首先通过物光和参考光的干涉将物体的振幅和相位信息以全息图的形式记录下来，然后再用参考光照射全息图，全息图上的干涉条纹经过衍射就可以还原出物体的三维信息，如图 1 所示。数字全息术不同于传统全息技术，是以全息干板记录全息图的繁琐，数字全息术以像传感器（如 CCD 或 CMOS）代替传统感光材料来记录全息图，并用数值计算的方法代替传统光学衍射的物理过程，通过运用计算机技术和相关算法来重建物体图像。数字全息术可以记录物体运动的瞬时时态，并相比于传统全息技术，数字全息技术在全息图的分析和处理上具有更大的灵活性。物波 $\boldsymbol{o}(x,y)\exp[-\mathrm{j}\boldsymbol{\phi}(x,y)]$ 和参考波 $\boldsymbol{r}(x,y)\exp[-\mathrm{j}\boldsymbol{\varphi}(x,y)]$ 在像传感器上记录的全息图的强度分布为

$$\boldsymbol{I}_H(x,y)=\boldsymbol{r}^2(x,y)+\boldsymbol{o}^2(x,y)+2\boldsymbol{r}(x,y)\boldsymbol{o}(x,y)\cos[\boldsymbol{\phi}(x,y)-\boldsymbol{\varphi}(x,y)] \tag{1}$$

式中：$\boldsymbol{r}^2(x,y)$ 为参考光的强度；$\boldsymbol{o}^2(x,y)$ 为物光的强度。这两项代表零级衍射项，其大小取决于复振幅，在全息图中表现为散斑噪声。第 3 项表示包含物光波复振幅与相位信息干涉的像，在全息图记录中表现为孪生像，需要通过相移技术或离轴记录的方式对孪生像进行消除。

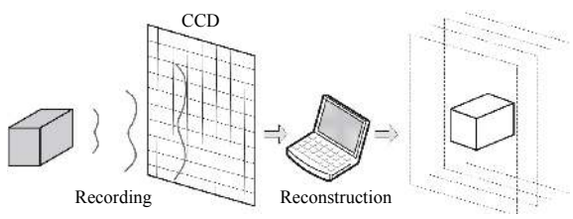


图 1 数字全息记录与重建示意图

**Fig. 1 Digital holography recording and reconstruction**

计算机上得到相应的全息图后，在重建步骤中，对瑞利-索末菲（Rayleigh-Sommerfeld）衍射方程进行数值计算，以模拟从 CCD 靶面($x, y$)到重建面($X, Y$)的反向重建过程。得到的反向重建图像为

$$E_r(X,Y,z)=F^{-1}\left\{F\{I_D(x,y)\}\exp\left(\mathrm{j}\frac{2\pi z}{\lambda}\times\left(1-(\lambda f_x)^2-(\lambda f_y)^2\right)^{1/2}\right)\mathrm{circ}\left(\sqrt{(\lambda f_x)^2+(\lambda f_y)^2}\right)\right\} \tag{2}$$

式中：($f_x, f_y$)为空间频率；$F$ 和 $F^{-1}$ 分别表示傅里叶变换和逆傅里叶变换；$\lambda$ 为参考光的波长。传统重建方法有菲涅尔重建法[43]、角谱重建法[44]和卷积重建法[45]等。这些传统的重建算法主要有两方面的缺陷：一方面是迭代反向重建速度相对较慢，在反向重建过程中菲涅尔重建法进行了一次傅里

叶变换, 角谱重建法进行了 2 次傅里叶变换, 卷积重建法进行了 3 次傅里叶变换。从速度上来看, 菲涅尔重建法最快, 但傅里叶变换具有$O(N\log N)$复杂度, 当像素个数$N$较多时计算速度就会减慢, 不能达到实时计算实时显示的目的; 另一方面是成像质量受许多先验知识的影响, 如菲涅尔重建法的重建质量受再现光波长、再现距离、像感器的像素数目和像元尺寸等影响比较大, 另外两种算法对像传感器的像素数目和像元尺寸比较敏感。传统粒子场三维重建方法在全息图重建之后还需要辅助算法才能得到每个粒子的信息, 深度学习算法可从单幅全息图中得到每个粒子信息而受到广泛关注。将深度学习算法应用在粒子场数字全息成像中还有一个主要优势是, 深度学习算法可利用不断增多的数据不断提升其性能, 而传统算法无法做到这一点。同时深度学习算法还在信息获取能力、成像功能、核心性能指标(如成像空间分辨率、时间分辨率、灵敏度等)上获得了显著提升[11]。

### 1.2　基于深度学习的粒子场数字全息成像的基本原理

基于深度学习的粒子场数字全息成像中粒子表征及粒子场反向重建方法基本流程分为神经网络输入、神经网络计算、神经网络输出、粒子场重建 4 个步骤。其中神经网络的输入是粒子场全息图或相关信息, 神经网络的输出则是包含用于表征粒子的参数, 如粒子半径($R$), 粒子三维坐标($x,y,z$)等。由于网络输出包含每个粒子信息, 不需要进行额外复杂的提取工作, 只需要简单提取就可直接从重建的全息图恢复粒子场的三维信息。

在粒子场数字全息成像中, 粒子场数字全息图为神经网络输入, 用于粒子场反向重建的粒子信息为网络输出, 深度学习算法可以看作是一种拟合网络输入与输出之间映射关系的工具。深度学习算法是一种含多层神经网络参数的模型[46], 旨在找到一种映射函数:

$$\boldsymbol{Y} = f(\boldsymbol{X};\theta) \tag{3}$$

式中: $\boldsymbol{Y}$是神经网络的输出; $\boldsymbol{X}$是神经网络的输入; $f$代表神经网络; $\theta$为需要调整的网络参数。通过训练神经网络不断调整网络参数$\theta$, 找到一个$\widehat{\theta}$使得$\boldsymbol{Y}$与$\boldsymbol{Y}'$(数据集中的真值)之间的相对熵最小[40]。不同神经网络模型所采用的相对熵计算准则不同, 采用$l_2$范数来表示$\boldsymbol{Y}$与$\boldsymbol{Y}'$之间的相对熵:

$$\widehat{\theta} = \underset{\theta \boldsymbol{Nw}}{\operatorname{argmin}} \sum_{i=1}^{M} \|f(\boldsymbol{X};\theta) - \boldsymbol{Y}'\|^2 \tag{4}$$

通过包含网络的输入($\boldsymbol{X}$)和与之对应的真值($\boldsymbol{Y}'$)的训练数据集对神经网络进行训练得到参数$\widehat{\theta}$, 进而确定网络模型。该网络模型能够应用于粒子场数字全息成像中粒子表征及粒子场反向重建。基于上述模型, 采用深度学习的 U-Net 卷积神经网络和传统数字全息反向传播算法中的角谱重建算法对二维平面的数字全息粒子场做反向重建仿真, 如图 2 所示。图 2(a)为粒子场的数字全息图; 图 2(b)是基于角谱重建算法的反向重建结果图; 图 2(c)是 U-Net 卷积神经网络计算出来的反向重建结果图。其中 U-Net 卷积神经网络的输入是粒子场的全息图, 输出的是反向重建图, 其所对应的真值是每个粒子的质心二维坐标($x,y$)和粒子半径($R$)编码形成的灰度图。在图 2(c)中粒子质心位置与其对应粒子的真实二维平面($x,y$)坐标相对应, 粒子的半径大小与其对应粒子的真实半径大小相对应。从图 2 中可以看出, 传统的角谱重建算法将全息图反向重建后还需要阈值分割和聚焦评价函数或者其他算法对粒子的位置信息, 粒子半径做进一步提取, 增加了算法复杂度和运算时间。而基于 U-Net 卷积神经网络重建算法, 则可直接从输出的图像进行简单的阈值分割就可以得到每个粒子的位置信息和粒子半径, 从而缩短了重建粒子场所需要的时间。

(a) 数字全息图　(b) 角谱法反向重建结果　(c) U-Net 卷积网络反向重建结果

**图 2　数字全息粒子场反向重建结果对比**

**Fig. 2　Comparison of inverse reconstruction results for digital holography particle field**

## 2　基于深度学习的粒子表征实例

### 2.1　采用深度坐标、半径和折射率表征粒子

数字全息显微镜获得的胶体球全息图可用洛伦兹-米氏(Lorenz-Mie)光散射理论解释[27, 47], 以跟踪和定位每个粒子, 并测量其尺寸和折射率[48]。但是这种技术是将每个全息图逐像素拟合, 计算量非常大[49]。2014 年 D. G. Grier 等人提出用 3 个参

量($z_p$,$a_p$,$n_p$)来表征粒子，分别表示粒子深度坐标、半径大小和折射率大小。用 3 个 SVM 分别计算粒子的$z_p$, $a_p$, $n_p$ 3 个物理参量。该方法比基于 Lorenz-Mie 光散射方法运算时间更短，有望在移动端实现更快更准确的检测[38]。

如图 3 所示，当平面波照射到粒子所在的($\eta$,$\xi$)平面时，光波发生了衍射，形成物光$\boldsymbol{E}_s(\boldsymbol{r})$，未照射到粒子的光则继续传播，形成参考光$\boldsymbol{E}_o(\boldsymbol{r})$。参考光与物光在($x$,$y$)平面发生干涉，由 CCD 测量的全息图的强度分布$\boldsymbol{I}(\boldsymbol{r})$为

$$\boldsymbol{I}(\boldsymbol{r}) = |\boldsymbol{E}_o(\boldsymbol{r}) + \boldsymbol{E}_s(\boldsymbol{r})|^2 \tag{5}$$

用$\boldsymbol{I}_0(\boldsymbol{r}) = |\boldsymbol{E}_o(\boldsymbol{r})|^2$将得到的$\boldsymbol{I}(\boldsymbol{r})$归一化，归一化的全息图可表示为[48, 50]

$$\boldsymbol{b}(\boldsymbol{r}) = \frac{\boldsymbol{I}(\boldsymbol{r})}{\boldsymbol{I}_0(\boldsymbol{r})} \approx \left|\hat{x} + \mathrm{e}^{-\mathrm{i}kz_p} f\left(k(r-r_p)\middle|a_p,n_p\right)\right| \tag{6}$$

式中 $f\left(k(r-r_p)\middle|a_p,n_p\right)$是洛伦兹-米式散射函数(Lorenz-Mie Scattering Function)。

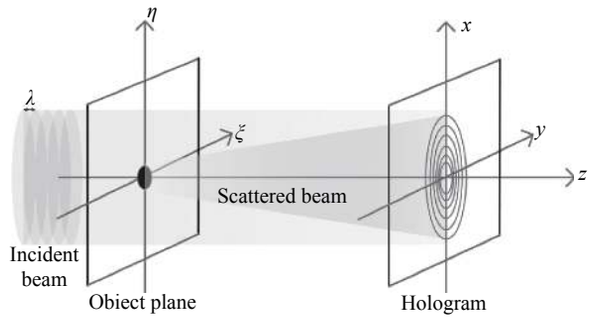


图 3　粒子衍射示意图

**Fig. 3　Schematic diagram of particle diffraction**

SVM 计算过程以及 SVM 训练数据产生和训练流程示意图[32]如图 4 所示。实验假定小球是折射率均匀的圆形球体，所以只采用全息图中心的径向一维扫描光强作为 SVM 的输入数据，输入数据通过量化产生包含 100 个点的向量，将此向量作为 SVM 的输入数据，分别计算$a_p$,$n_p$,$z_p$，再用这 3 个参数去计算$\boldsymbol{b}_n(\boldsymbol{r})$，与(6)式得到的$\boldsymbol{b}(\boldsymbol{r})$来计算径向基函数[51]：

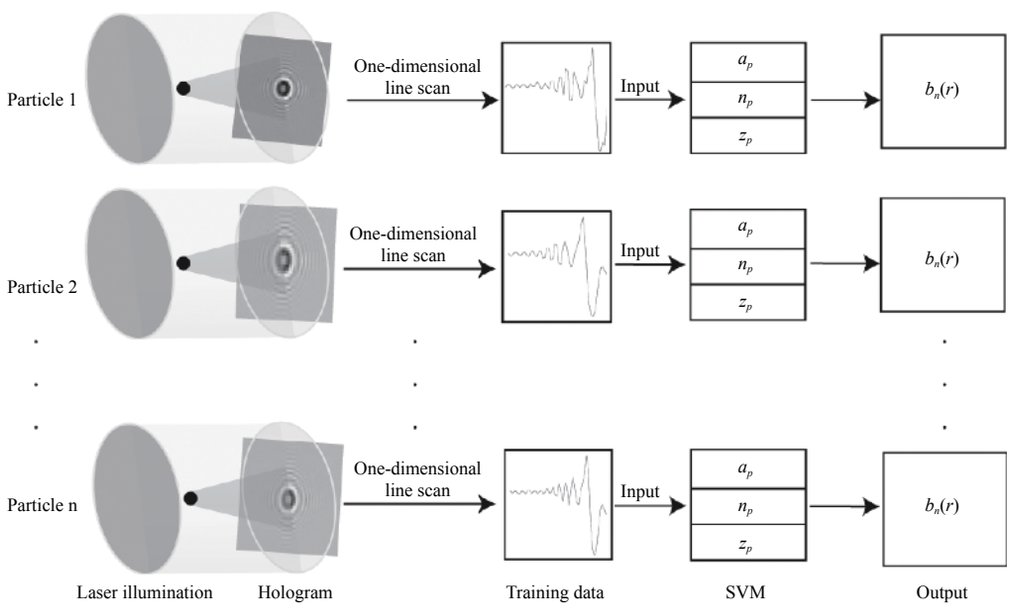


图 4　SVM 训练数据产生和训练流程示意图

**Fig. 4　SVM training data generation and training flow**

$$\boldsymbol{K}_n(\boldsymbol{r}) = \exp\left(-\gamma \int \left|\boldsymbol{b}_n(\boldsymbol{r}) - \boldsymbol{b}(\boldsymbol{r})^2\right| \mathrm{d}\boldsymbol{r}\right) \tag{7}$$

SVM 将输入的 100 个点的向量映射到[$z_p$,$a_p$,$n_p$]的三维向量中，以此来表征未知的粒子。

实验用标准的二氧化硅小球和聚苯乙烯小球进行验证，折射率的模值$n_p \approx 1.4$和1.6分别与二氧化硅和聚苯乙烯的值一致。测得半径值为$a_p \approx 0.5$ μm 和 1 μm，与实验所用小球的规格一致，这与利用相同数据集进行完整的 Lorenz-Mie 分析所得到的半径值略有不同[51]，具体误差见表 1 所示[38]。

表 1　误差比较

**Table 1　Error comparison**

| | $a_p$/μm | $n_p$ |
|---|---|---|
| Reference[38] | 0.790±0.02 | 1.600 0±0.000 6 |
| Reference[51] | 0.805±0.001 | 1.573 0±0.000 6 |

由表 1 可以看出, 提出的 SVM 进行粒子表征的方法与传统方法运算结果大致相同, 说明用 SVM 进行粒子表征具有比较好的可靠性, 同时计算时间明显缩短, 可以达到更快的实时显示、实时检测的目的[38, 51]。

### 2.2　采用内、外核折射率和半径表征粒子

使用数字全息技术跟踪和定位粒子时, 通常采用反向传播和非线性模式匹配等算法, 但这些算法中大都包含积分和 FFT 运算, 因此如果增加图像大小或是并行研究多个粒子, 计算成本会大大增加。2015 年, B. Schneider 等人提出用$(n_1, n_2, R_{\mathrm{core}}, R_{\mathrm{shell}})$来表征粒子, 分别代表粒子内核折射率、外核折射率、内核半径、外核半径, 并以此来跟踪和定位粒子[39]。采用全连接神经网络, 用粒子全息图的一维径向扫描作为全连接神经网络的输入, 输出是包含粒子$[n_1, n_2, R_{\mathrm{core}}, R_{\mathrm{shell}}]$信息的四维向量, 具体训练过程见图 4 所示。全连接神经网络通过公式

$$z = \tanh\left(\boldsymbol{W}^{\mathrm{T}}_{\mathrm{InptoHid}^x} + \boldsymbol{bias}_{\mathrm{Hid}}\right) \tag{8}$$

将输入的物理参量矩阵$\boldsymbol{x}$映射到隐藏层状态向量$\boldsymbol{z}$上, 网络输出是通过公式

$$y' = \boldsymbol{W}_{\mathrm{HidtoOut}^z} + \boldsymbol{bias}_{\mathrm{Out}} \tag{9}$$

将所有隐藏层状态向量$\boldsymbol{z}$进行线性组合输出测量值$y'$, 通过$y'$与真实值$y$的相对熵最小作为损失函数, 并取损失函数最小值作为代价函数来调整神经网络的参数。所有神经元可训练的参数都包含权重矩阵$\boldsymbol{W}_{\mathrm{InptoHid}}$, $\boldsymbol{W}_{\mathrm{HidtoOut}}$和偏差矢量$\boldsymbol{bias}_{\mathrm{Hid}}$, $\boldsymbol{bias}_{\mathrm{out}}$, 通过调整这些参数矩阵和参数矢量使得最终的损失函数达到最小值时, 代表网络训练完成, 如图 5 所示[39]。将训练好的网络模型应用在细胞数字全息图像中, 例如直径通常大于健康细胞的循环肿瘤细胞[52], 取得了很好的效果。

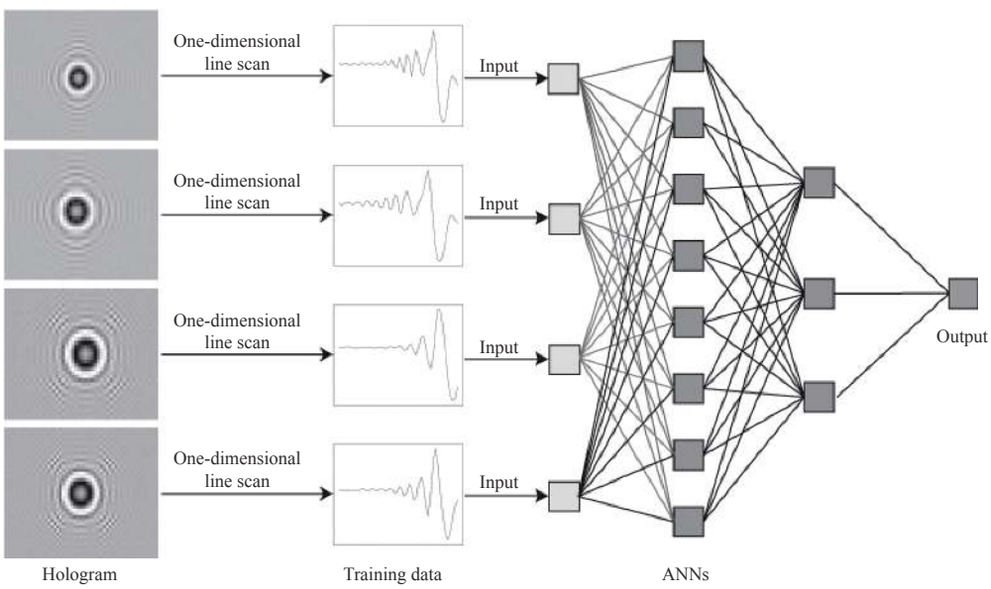


图 5　神经网络训练示意图

**Fig. 5　Schematic diagram of neural network training**

采用归一化均方误差范数(NRMSE)

$$\mathrm{NRMSE} = \frac{\sqrt{\frac{1}{N}\sum_{i=1}^{N}\left(\hat{y}_i - y_i\right)^2}}{y_{\max} - y_{\min}} \tag{10}$$

评价训练好的网络性能。在球体直径 7 μm～20 μm 之间获得最佳的 NRMSE 值, 对于内核和外壳直径的 NRMSE 分别为(4.4±0.2)%和(0.74±0.01)%。

### 2.3　采用二维坐标表征粒子

Y. Wu 等人提出了一种用粒子二维平面坐标$(x, y)$来表征粒子[40]。在燃烧过程中, 由于燃烧速度不同, 燃烧阶段不同, 可燃物燃烧不完全使得小粒子与未燃烧或是小粒子聚集之后产生的大粒子广泛共存, 这使小粒子很难被检测到。将 Y. Wu 等人提出的方法用于燃烧过程中的小粒子检测, 通过训练改进的全卷积网络(FCN)可提高小粒子检测精度和误检率。

改进的 FCN 网络[40]可用图 6 来描述, 网络输入为粒子全息图。网络输出为粒子的二值化图。用每个粒子的二维平面坐标$(x, y)$对粒子进行表征,

以此来识别和检测粒子。改进的 FCN 网络结构在文献 [53] 提出的 FCN 基础上主要做了两种改进：一种是去掉了前 2 个最大池化层；另一种是在第 4 个 ReLu 层后边加入一个上采样层。减少 2 个最大池化层使得最后的分割尺寸不至于太小，同时使得小粒子和背景有一个明显的区分度。增加一个上采样层是为了增加小粒子信息，提高小粒子检测精度。

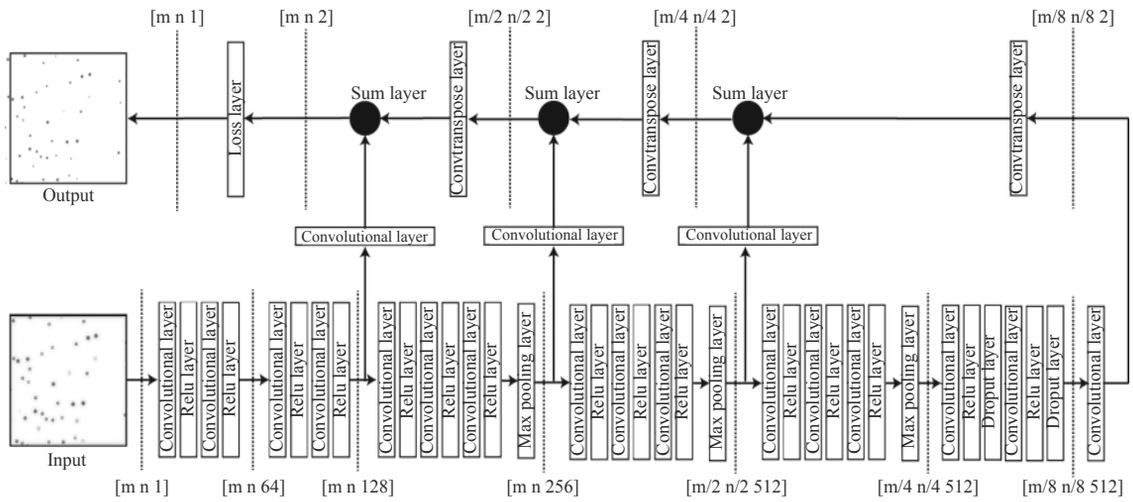


图 6　FCN 网络结构

**Fig. 6　FCN network structure**

用以下 3 个函数评价仿真结果。

像素精度(PA)：

$$\mathrm{PA}=\frac{\sum_i p_{ii}}{\sum_i T_i} \tag{11}$$

均像素精度(MPA)：

$$\mathrm{MPA}=\frac{1}{k_c}\sum_i \frac{P_{ii}}{T_i} \tag{12}$$

均交并比(MIOU)：

$$\mathrm{MIOU}=\frac{1}{k_c}\sum_i \frac{p_{ii}}{\left(T_i+\sum_j (p_{ji}-p_{ii})\right)} \tag{13}$$

式中：$p_{ii}$表示标签和预测中都标记为第$i$类的像素数目；$p_{ji}$表示标记为$i$类但在预测中输出的是第$j$类的像素数目；$k_c$为类别数量，这里$k_c=2$；$T_i$为真值中第$i$类别的像素总数。具体评价结果[40] 如表 2 所示。

**表 2　仿真评价结果**

**Table 2　Simulation evaluation results**

| | PA | MPA | MIOU |
|---|---|---|---|
| Training Data | 0.9985 | 0.9853 | 0.9737 |
| Validation Data | 0.9984 | 0.9888 | 0.9758 |

从表 2 可知，3 种评价函数的平均值都达到了 97% 以上，说明该方法准确率比较高。作者又将此方法与传统的阈值分割方法[54-55] 等进行比较，阈值分割方法存在着漏检或者误检的问题，而使用改进的 FCN 可以很好地解决这两种问题，使得检测精度和效率都达到了一个较高水平。

### 2.4　采用三维坐标表征粒子

S. Shao 等人提出用三维坐标$(x,y,z)$来表征粒子，在三维空间内，粒子的$x,y,z$坐标各不相同，用这 3 个参数可以确定粒子场中的每一个粒子，并以此来检测和定位三维粒子场中的粒子[42]。提出了一种改进的 U-Net 网络模型，是在文献 [56] 提出的 U-Net(见图 7)基础上，在每个编码器和解码器上都加入了残差模块(Residual Connection)，用 Swish 激活函数代替 ReLu 激活函数，从而缩短了网络的训练时间和减弱了网络最后几层的退化，使该网络更好地应用在三维粒子场中的粒子检测。

网络的输入分别是原始全息图、深度映射图、最大相位图；网络的输出为粒子质心投影和粒子深度图。其中深度映射图由

$$\boldsymbol{Z}_{\mathrm{approx}}=\arg\max_z\left(\boldsymbol{u}_{\mathrm{p}}(x,y,z)*\mathrm{conj}\left[\boldsymbol{u}_{\mathrm{p}}(x,y,z)\right]\right) \tag{14}$$

计算得到。最大相位投影由下式计算得到：

$$\boldsymbol{P}(x,y)=\max_z\left\{\mathrm{angle}\left[\boldsymbol{u}_{\mathrm{p}}(x,y,z)\right]\right\} \tag{15}$$

式中$\boldsymbol{u}_{\mathrm{p}}(x,y,z)$表示粒子场。可以从粒子质心投影图中得到粒子的$(x,y)$坐标信息，在粒子深度图中得到粒子的$z$坐标信息，这样可以在三维空间上重建

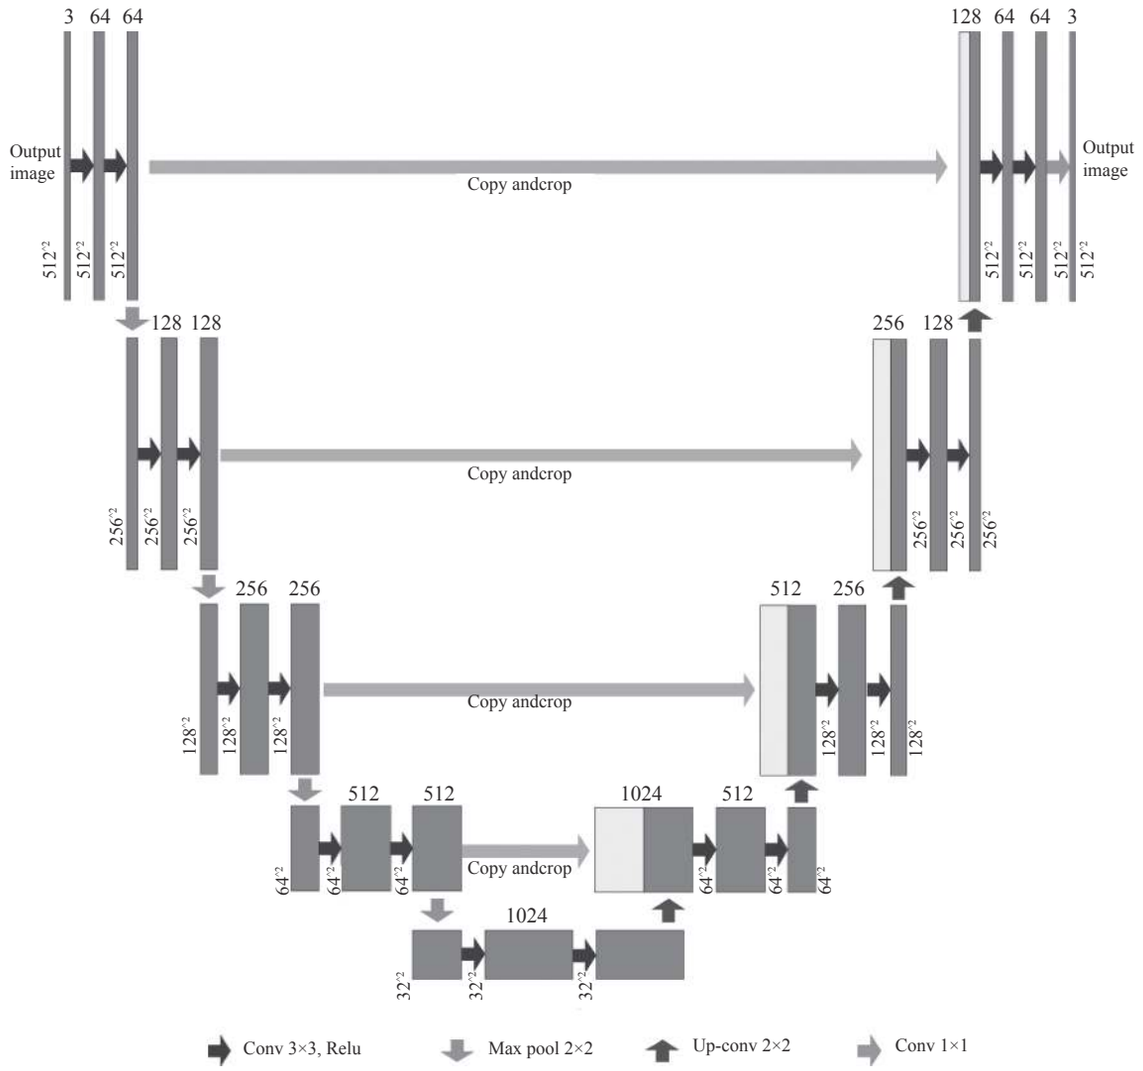


**图 7　U-Net 网络结构图**

**Fig. 7　U-Net network structure**

粒子场。在仿真检测中, 随机对空间中 300 个粒子进行检测, 得到粒子的平均提取率为 98.7%。在对实际场景中固体凝胶的荧光标记颗粒进行检测, 粒子检测准确率为 90%。

### 2.5　采用三维坐标和半径表征粒子

粒子场数字全息成像中粒子表征及粒子场反向重建通常需要多次衍射计算, 通过使用聚焦度量来检测粒子的横向和轴向位置。但这些过程通常要消耗很长时间, 使得该方法很难应用在粒子全息图的实时重建过程中。T. Shimobaba 等人采用粒子的三维坐标($x,y,z$)和粒子半径($R$) 4 个物理参量来表征粒子[41]。由于每个粒子在三维空间内具有独特的$x,y,z$坐标和$R$, 用这 4 个物理参量就可以确定空间中任意一个粒子, 从而检测和定位空间中的粒子。并采用 DNN 网络, 从同轴全息图中直接重建粒子的三维体积场。这种方法较传统方法运算时间要快很多, 且对再现全息图的质量要求不是很高, 在一些复杂场合中也能应用。

DNN 网络训练数据集包含粒子场数字全息图和与之对应粒子场中粒子[$x,y,z,R$]信息通过 RGB 彩色编码形成的 RGB 彩色图像, 如图 8 所示。图 8(a)表示粒子场数字全息图; 图 8(b)表示 RGB 彩色图像中 R 通道信息, 代表粒子质心位置($x,y$)信息; 图 8(c)表示 RGB 彩色图像中 G 通道信息, 代表粒子深度位置($z$), 采用 256 级灰度图像编码, 深度位置 1 cm～3 cm 对应于 0～255 灰度; 图 8(d)表示 RGB 彩色图像中 B 通道信息, 代表粒子半径($R$), 采用 256 级灰度图像编码, 粒子大小 20 μm～100 μm 对应于 0～255 灰度。将粒子场数字全息图 8(a)作为网络的输入, 包含粒子[$x,y,z,R$]信息的 RGB 彩色图像作为网

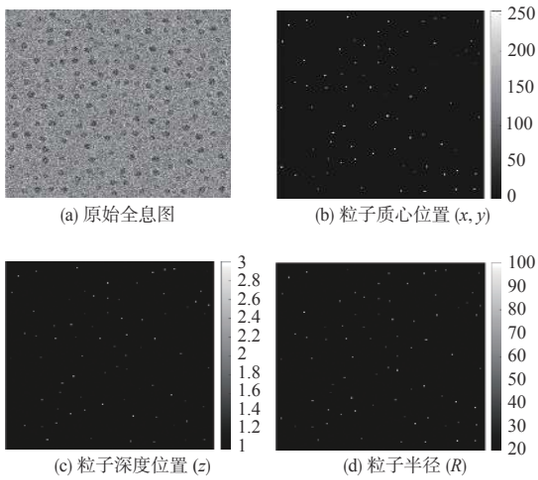


(a) 原始全息图　(b) 粒子质心位置 (*x*, *y*)

(c) 粒子深度位置 (*z*)　(d) 粒子半径 (*R*)

**图 8　DNN 网络训练数据集**

**Fig. 8　DNN network training data set**

络训练的真值图像，将网络输出的图像与真值图像之间的差异的最小化作为目标函数进行网络训练。

Tomoyoshi Shimobaba 等人提出的 DNN 的网络结构[41]采用 U 型网络设计，如图 9 所示。网络包含 7 个模块(Block)，3 个最大池化层和 3 个上采样层。每个 Block 包括 3 个卷积层，3 个归一化层，3 个激活函数层。网络最后通过一个卷积层输出预测图像，并将预测图像与通过 RGB 彩色编码形成的真值进行比较，将其误差最小作为损失函数来调整网络参数。将训练好的模型对测试集中粒子场全息图进行预测，得到的结果[41]如表 3 所示。由表 3 可知，粒子检测误差在误差允许范围内，使得粒子场数字全息成像的三维重建精度相比于传统方法得到进一步提升。

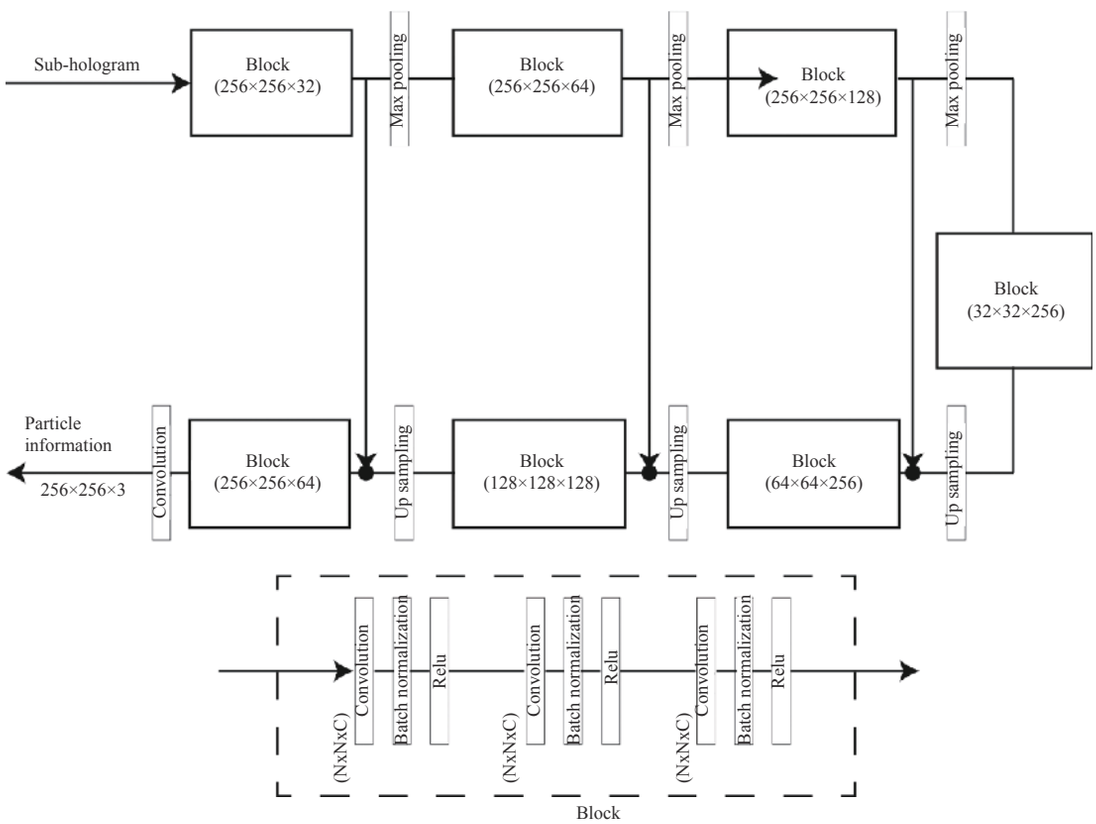


**图 9　DNN 网络结构**

**Fig. 9　DNN network structure**

## 3　结论与展望

深度学习算法由于其重建速度快，相比于传统迭代优化求解算法计算时间明显缩短，在数字全息重建中发挥了重要作用。深度学习算法主要是通过神经网络的线性或非线性拟合实现的。其中神经网络具备强大的拟合能力，可以完成非常复杂的线性或非线性映射。同时卷积神经网络包含很多参数，可以得到非常高维的假设空间，从而使得深度学习具有强大的表征能力。深度学习的最新进展促进了具有实时性能的粒子场数字全息成像的应用，如粒子场数字全息成像中粒子表征及粒子场反向重建、粒子跟踪和定

表 3　$x, y, z, R$ 表征粒子方法的准确率

Table 3　$x, y, z, R$ accuracy of particle characterization method

| Number of Particles | Average | | | Standard deviation | | |
|---|---|---|---|---|---|---|
| | Lateral | Axial | Size | Lateral | Axial | Size |
| 40 | 0.08 | 2.72 | 3.08 | 0.123 | 3.3 | 3.17 |
| 73 | 0.14 | 3.52 | 2.27 | 0.09 | 5.38 | 2.36 |
| 116 | 0.08 | 2.95 | 2.23 | 0.07 | 2.98 | 2.58 |
| 162 | 0.18 | 3.35 | 3.21 | 0.18 | 4.07 | 4.01 |

位等。基于 SVM 的全息粒子表征方法，需要创建深度坐标、半径和折射率 3 个分类器，计算速度较慢。全连接神经网络计算速度得到很大提升，但其特征提取能力较弱，输出结果准确率相对较低。FCN 网络增加了卷积、池化和激活函数等操作，输出结果准确率得到了很大提升。DNN 网络是一种 U-Net 结构的网络，提取图片特征的能力、图片精细度、输出结果准确率和计算速度均得到了改进，可以在包含 300 粒子的粒子场数字全息图中实现 40.4% 的粒子提取率。对 U-Net 网络进一步改进，引入了残差模块和 Swish 函数，粒子提取率可以高达 98%。可以预见，随着深度学习算法的不断进步，会有更多新的网络提出，使得粒子场全息图的深度学习重建算法的准确率和计算速度不断提升。

基于深度学习的粒子场数字全息成像方法主要有以下 3 方面优势：1)深度学习算法将大量时间花费在训练模型中，模型一旦训练好，在粒子场数字全息成像中则会花费很少的时间，能够达到实时计算实时显示的目的；2）由于卷积神经网络的层数不断增加，使其拟合能力不断提升，可以拟合很复杂的逆向光场重建模型，在多种领域中进行粒子场数字全息成像；3）由于深度学习算法的不断发展，有许多成熟的网络架构稍加修改就可以应用在粒子场数字全息成像中，使得算法设计变得简单。

但基于深度学习的粒子场数字全息成像方法也存在着许多挑战：1）实验数据的获取方式与真实场景存在着一定误差，使得训练好的深度学习模型应用在实际中的误差要比理论误差大；2）若三维场景中的 2 个粒子在二维平面上的投影相距很近，或者有部分重合甚至完全重合，现有传感器很难将这 2 个粒子形成的全息图区分开，误判为一个粒子，导致重建误差较大；3）深度学习算法是以数据驱动方式训练神经网络，其网络参数选择是没有理论基础的，按照该参数选择方法，通过有限数据训练神经网络拟合一个符合粒子场数字全息成像的映射函数，该映射函数并不是唯一的，但其真实映射函数却只有一个，这就导致其实际拟合结果和理论结果存在着一定的误差。4）由于深度学习模型计算过度依赖于大量浮点计算而很难应用在一些资源受限的设备上，例如普通移动设备，现场可编程门阵列(FPGA)等，所以需要从模型压缩减少深度学习算法中冗余的浮点运算或是提高设备的硬件处理能力等方面来加快深度学习算法的移动端应用速度。

现阶段基于深度学习的粒子场数字全息成像中粒子的表征及反向重建实验获得的数据集几乎都是在理想情况下得到的，一旦应用到实际中，如光照的不均匀和环境噪声太大等因素都将使得生成的数字全息图受到影响，这时候的网络很难准确表征粒子并检测出粒子。所以增加数据集丰富性或得到更加真实的数据集使得深度学习算法在实际应用中获得更高的准确率是一个必要的研究方向；其次，如何用光场理论来解释深度学习在粒子场数字全息成像中的应用原理，使深度学习算法不再是一个黑匣子，使其得到的结果更具说服力，也是今后的一个研究方向。

**参考文献：**

[1] CHOI Y S, LEE S J. Three-dimensional volumetric measurement of red blood cell motion using digital holographic microscopy[J]. Applied Optics, 2009, 48(16): 2983-2990.

[2] XU W, JERICHO M H, MEINERTZHAGEN I A, et al. Digital in-line holography of microspheres[J]. Applied Optics, 2002, 41(25): 5367-5375.

[3] XU W, JERICHO M H, KREUZER H J, et al. Tracking particles in four dimensions with in-line holographic microscopy[J]. Optics Letters, 2003, 28(3): 164-166.

[4] WU X C, YAO L C, WU Y C, et al. In-situ characterization of coal particle combustion via long working distance digital in-line holography[J]. Energy & Fuels, 2018, 32(8): 8277-8286.

[5] YAO L C, WU C Y, WU Y C, et al. Investigating particle and volatile evolution during pulverized coal combustion using high-speed digital in-line holography[J]. Proceedings of the Combustion Institute, 2019, 37(3): 2911-2918.

[6] MILGRAM J H, LI W C. Computational reconstruction of images from holograms[J]. 2002, 41(5): 853-864.

[7] COËTMELLEC S, BURAGA-LEFEBVRE C, LEBRUN D, et al. Application of in-line digital holography to multiple plane velocimetry[J]. Measurement Science and Technology, 2001, 12(9): 1392.

[8] WU X C, XUE Z L, ZHAO H F, et al. Measurement of slurry droplets by digital holographic microscopy: fundamental research[J]. Fuel, 2015, 158: 697-704.

[9] MEMMOLO P, MICCIO L, PATURZO M, et al. Recent advances in holographic 3D particle tracking[J]. Advances in Optics and Photonics, 2015, 7(4): 713-755.

[10] WANG Fei, WANG Hao, BIAN Yaoming, et al. Applications of deep Learning in computational imaging[J]. Acta Optica Sinica, 2020, 40(1): 31-44.
王飞, 王昊, 卞耀明, 等. 深度学习在计算成像中的应用[J]. 光学学报, 2020, 40(1): 31-44.

[11] ZUO Chao, FENG Shijie, ZHANG Xiangyu, et al. DeepLearning based computational imaging status chalenges and future[J]. Acta Optica Sinica, 2020, 40(1): 0111003-1-26.
左超, 冯世杰, 张翔宇, 等. 深度学习下的计算成像: 现状, 挑战与未来[J]. 光学学报, 2020, 40(1): 0111003-1-26.

[12] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors[J]. Nature, 1986, 323(6088): 533-536.

[13] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.

[14] HU H F, LIAO Z K, XIAO X. Action recognition using multiple pooling strategies of CNN features[J]. Neural Processing Letters, 2019, 50(1): 379-396.

[15] ZOU Z X, SHI Z W, GUO Y H, et al. Object detection in 20 years: a survey[EB/OL]. arXiv: 1905.05055, 2019[2019-05-16]. https://arxiv.org/abs/.

[16] CHEN Qingjiang, ZHANG Xue. Image defogging algorithm combined with full convolution neural network[J]. Journal of Applied Optics, 2019, 40(4): 596-602.
陈清江, 张雪. 基于全卷积神经网络的图像去雾算法[J]. 应用光学, 2019, 40(4): 596-602.

[17] ZHANG Z X, GEIGER J, POHJALAINEN J, et al. Deep learning for environmentally robust speech recognition: an overview of recent developments[J]. ACM Transactions on Intelligent Systems and Technology(TIST), 2018, 9(5): 1-28.

[18] LI J, HUANG G M, CHEN J H, et al. Dual CNN for relation extraction with knowledge-based attention and word embeddings[J]. Computational Intelligence and Neuroscience, 2019, 2019: 1-10.

[19] LIANG X D, LEE L, DAI W, et al. Dual motion GAN for future-flow embedded video prediction[C]//IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017. Venice. USA: IEEE, 2017.

[20] RIVENSON Y, WU Y C, OZCAN A. Deep learning in holography and coherent imaging[J]. Light: Science & Applications, 2019, 8(1): 85.

[21] WU Y C, RIVENSON Y, ZHANG Y B, et al. Extended depth-of-field in holographic imaging using deep-learning-based autofocusing and phase recovery[J]. Optica, 2018, 5(6): 704-710.

[22] RIVENSON Y, ZHANG Y B, GÜNAYDıN H, et al. Phase recovery and holographic image reconstruction using deep learning in neural networks[J]. Light: Science & Applications, 2018, 7(2): 17141.

[23] WANG K Q, DOU J Z, QIAN K M, et al. Y-Net: a one-to-two deep learning framework for digital holographic reconstruction[J]. Optics Letters, 2019, 44(19): 4765-4768.

[24] WANG K Q, LI Y, QIAN K M, et al. One-step robust deep learning phase unwrapping[J]. Optics Express, 2019, 27(10): 15100-15115.

[25] PITKÄAHO T, MANNINEN A, NAUGHTON T J. Focus prediction in digital holographic microscopy using deep convolutional neural networks[J]. Applied Optics, 2019, 58(5): A202-A208.

[26] BARBASTATHIS G, OZCAN A, SITU G H. On the use of deep learning for computational imaging[J]. Optica, 2019, 6(8): 921-943.

[27] LEE S H, GRIER D G. Holographic microscopy of holographically trapped three-dimensional structures[J]. Op-

tics Express, 2007, 15(4): 1505-1512.

[28] TALAPATRA S, SULLIVAN J, KATZ J, et al. Application of in-situ digital holography in the study of particles, organisms and bubbles within their natural environment; proceedings of the Ocean Sensing and Monitoring IV, F, 2012[C]//USA: International Society for Optics and Photonics, 2012.

[29] SHENG J, MALKIEL E, KATZ J. Buffer layer structures associated with extreme wall stress events in a smooth wall turbulent boundary layer[J]. Journal of Fluid Mechanics, 2009, 633: 17-60.

[30] TIAN L, LOOMIS N, DOMÍNGUEZ-CABALLERO J A, et al. Quantitative measurement of size and three-dimensional position of fast-moving bubbles in air-water mixture flows using digital holography[J]. Applied Optics, 2010, 49(9): 1549-1554.

[31] GUILDENBECHER D R, GAO J, REU P L, et al. Digital holography simulations and experiments to quantify the accuracy of 3D particle location and 2D sizing using a proposed hybrid method[J]. Applied Optics, 2013, 52(16): 3790-3801.

[32] SHENG J, MALKIEL E, KATZ J. Digital holographic microscope for measuring three-dimensional particle distributions and motions[J]. Applied Optics, 2006, 45(16): 3893-3901.

[33] TOLOUI M, HONG J R. High fidelity digital inline holographic method for 3D flow measurements[J]. Optics Express, 2015, 23(21): 27159-27173.

[34] VERRIER N, GROSJEAN N, DIB E, et al. Improvement of the size estimation of 3D tracked droplets using digital in-line holography with joint estimation reconstruction[J]. Measurement Science and Technology, 2016, 27(4): 045001.

[35] BERDEU A, FLASSEUR O, MÉÈS L, et al. Reconstruction of in-line holograms: combining model-based and regularized inversion[J]. Optics Express, 2019, 27(10): 14951-14968.

[36] JOLIVET F, MOMEY F, DENIS L, et al. Regularized reconstruction of absorbing and phase objects from a single in-line hologram, application to fluid mechanics and micro-biology[J]. Optics Express, 2018, 26(7): 8923-8940.

[37] MALLERY K, HONG J R. Regularized inverse holographic volume reconstruction for 3D particle tracking[J]. Optics Express, 2019, 27(13): 18069-18084.

[38] YEVICK A, HANNEL M, GRIER D G. Machine-learning approach to holographic particle characterization[J]. Optics Express, 2014, 22(22): 26884-26890.

[39] SCHNEIDER B, DAMBRE J, BIENSTMAN P. Fast particle characterization using digital holography and neural networks[J]. Applied Optics, 2016, 55(1): 133-139.

[40] WU X, LI X, YAO L, et al. Accurate detection of small particles in digital holography using fully convolutional networks[J]. Applied Optics, 2019, 58(34): G332-G344.

[41] SHIMOBABA T, TAKAHASHI T, YAMAMOTO Y, et al. Digital holographic particle volume reconstruction using a deep neural network[J]. Applied Optics, 2019, 58(8): 1900-1906.

[42] SHAO S, MALLERY K, KUMAR S S, et al. Machine learning holography for 3D particle field imaging[J]. Optics Express, 2020, 28(3): 2987-2999.

[43] SCHNARS U, JÜPTNER W. Direct recording of holograms by a CCD target and numerical reconstruction[J]. Applied Optics, 1994, 33(2): 179-181.

[44] DE NICOLA S, FINIZIO A, PIERATTINI G, et al. Angular spectrum method with correction of anamorphism for numerical reconstruction of digital holograms on tilted planes[J]. Optics Express, 2005, 13(24): 9935-9940.

[45] SCHNARS U, JÜPTNER W P. Digital recording and numerical reconstruction of holograms[J]. Measurement Science and Technology, 2002, 13(9): R85-R101.

[46] GOODFELLOW I, BENGIO Y, COURVILLE A. Deep learning[M]. Massachusetts: MIT Press, 2016.

[47] BOHREN C F, HUFFMAN D R. Absorption and scattering of light by small particles[M]. Manhattan:John Wiley & Sons, 2008.

[48] LEE S H, ROICHMAN Y, YI G R, et al. Characterizing and tracking single colloidal particles with video holographic microscopy[J]. Optics Express, 2007, 15(26): 18275-18282.

[49] CHEONG F C, KRISHNATREYA B J, GRIER D G. Strategies for three-dimensional particle tracking with holographic video microscopy[J]. Optics Express, 2010, 18(13): 13563-13573.

[50] SMOLA A J, SCHÖLKOPF B. A tutorial on support vector regression[J]. Statistics and Computing, 2004, 14(3): 199-222.

[51] KRISHNATREYA B J, COLEN-LANDY A, HASEBE P, et al. Measuring Boltzmann's constant through holographic video microscopy of a single colloidal sphere[J].

American Journal of Physics, 2014, 82(1): 23-31.

[52] HOU H W, WARKIANI M E, KHOO B L, et al. Isolation and retrieval of circulating tumor cells using centrifugal forces[J]. Scientific Reports, 2013, 3: 1259.

[53] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015. Boston, MA, USA. USA: IEEE, 2015.

[54] GAO J, GUILDENBECHER D R, REU P L, et al. Uncertainty characterization of particle depth measurement using digital in-line holography and the hybrid method[J]. Optics Express, 2013, 21(22): 26432-26449.

[55] YAO L, WU X, WU Y, et al. Characterization of atomization and breakup of acoustically levitated drops with digital holography[J]. Applied Optics, 2015, 54(1): A23-A31.

[56] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation[C]//Cham: Springer International Publishing, 2015: 234-241.