

深度学习在数字全息显微成像中的应用

孟章¹, 丁浩¹, 聂守平¹, 马骏², 袁操今^{1*}

¹南京师范大学物理科学与技术学院, 江苏省光电技术重点实验室, 江苏 南京 210023;

²南京理工大学电子工程与光电技术学院, 江苏 南京 210094

摘要 数字全息显微成像技术因能高精度实现定量相位成像的优势受到生物成像与材料科学领域的关注, 但共轭像的存在、相位包裹的困扰以及分辨率受限等问题一直阻碍了数字全息显微术的广泛应用。近些年, 深度学习作为机器学习中一种对数据特征提取进行特化的模型, 在光学成像领域中被广泛应用。除用于提高成像效率外, 其解决成像逆问题的潜力也不断被研究人员发掘, 为成像领域开辟了一条蹊径。本文从深度学习应用于数字全息显微成像的工作原理出发, 介绍它解决光学成像逆问题的思路与重要数理概念, 同时对深度学习的完整实施过程进行归纳。扼要地总结了近年来深度学习对于全息重建、自动聚焦与相位恢复、全息去噪与超分辨等方面的研究进展, 并对该研究领域存在的问题与发展趋势进行展望。

关键词 成像系统; 数字全息显微; 深度学习; 定量相位成像

中图分类号 O438.1

文献标志码 A

doi: 10.3788/LOP202158.1811006

Application of Deep Learning in Digital Holographic Microscopy

Meng Zhang¹, Ding Hao¹, Nie Shouping¹, Ma Jun², Yuan Caojin^{1*}

¹Jiangsu Key Laboratory for Opto-Electronic Technology, School of Physics and Technology, Nanjing Normal University, Nanjing, Jiangsu 210023, China;

²School of Electronic Engineering and Optoelectronic Techniques, Nanjing University of Science and Technology, Nanjing, Jiangsu 210094, China

Abstract Digital holographic microscopy (DHM) has attracted attention in the fields of biological imaging and materials science due to its advantages in high-precision quantitative phase imaging. However, the existence of conjugate images, the problem of phase wrapping, and the limited resolution have always hindered the wide application of DHM. In recent years, deep learning, as a specialized model for data feature extraction in machine learning, has been widely used in the field of optical imaging. In addition to improving imaging efficiency, its potential to solve imaging inverse problems has also been continuously explored by researchers, opening up a new path for the optical imaging. In this paper, we start from the working principle of deep learning applied to DHM, introduces its ideas and important mathematical concepts to solve the inverse problem of optical imaging, and at the same time summarizes the complete implementation process of deep learning. A brief summary of the research progress in recent years of deep learning in holographic reconstruction, auto-focusing and phase recovery, and holographic denoising and super-resolution is given, and summarize the existing problems in this research field and look forward to the development trend of research.

Key words imaging systems; digital holographic microscopy; deep learning; quantitative phase imaging

OCIS codes 110.0180; 090.1995

收稿日期: 2021-06-02; 修回日期: 2021-07-10; 录用日期: 2021-07-20

基金项目: 国家自然科学基金(61775097, 61975081)、国家重点研发计划(2017YFB0503505)

通信作者: *yuancj@njnu.edu.cn

1 引言

细胞和组织成像是生物学研究和医学诊断的关键环节,光学显微镜则是活细胞成像的首选工具。然而,大多数生物活细胞是透明的,对入射光振幅调制较弱。而传统的光学传感器只能获取样品的时间平均信号,即强度。因此其用于活细胞成像时成像对比度低,并且难以对未染色的样品直接成像。作为细胞的另一光学特征性参量——相位分布则成为活细胞分析的重要信息来源,它不仅能反映样品三维形貌,而且能提供内部结构与折射率分布的信息,所以对样品的相位分布进行可视化或定量测量具有重要的意义。

定量相位成像(QPI)技术便是一种用来处理光学成像背景下相位信息丢失问题的有效方法。其通过定量测量由于折射率差异引起的衍射图样或者干涉条纹的变化,从而获取物体相位信息^[1]。全息显微技术(HM)是 QPI 技术中的典型成像技术之一,其通过引入参考光波与物光波进行干涉从而将相位信息转化为强度并记录在全息图中,当使用再现光波照射全息图像时,能恢复物体的相位与振幅分布^[2]。随着电耦合元件(CCD)以及互补金属半导体氧化物(CMOS)的出现,全息图的记录方式实现了由全息干板记录到数字化记录的转变,通过计算机进行全息图像的数字存储和重建,大大提高了记录效率并降低成本^[3],数字全息显微(DHM)技术由此产生。DHM 成像原理如图 1 所示,携带物体信息的物光 O 和参考光 R 发生干涉,将不能被直接记录的相位信息编码到干涉图中,通过数字探测器(CCD 或 CMOS)记录干涉图,然后用计算机模拟物光波的衍射过程实现再现。假设物平面的坐标为




图 1 数字全息记录示意图

Fig. 1 Schematic diagram of digital holographic recording (x_0, y_0) , 记录平面的坐标为 (x, y) 。以角谱衍射算法为例^[4],在记录平面位置物体的光场分布可以表示为

$$O(x, y) = \mathcal{F}^{-1} \{ \mathcal{F}[O_0(x, y)] \times As_{z_0}(x, y) \}, \quad (1)$$

式中: z_0 为物体衍射距离; $O_0(x, y)$ 和 $O(x, y)$ 分别是物平面和记录平面位置处物体的光场分布;符号 \mathcal{F} 和 \mathcal{F}^{-1} 分别表示傅里叶变换和傅里叶逆变换。 As_{z_0} 表示角谱衍射正向传播 z_0 的距离。

$As_{z_0} = \exp[jkz_0 \sqrt{1 - (\lambda f_x)^2 - (\lambda f_y)^2}]$, (2) 式中: λ 为光源波长; $k = 2\pi/\lambda$ 表示波数; (f_x, f_y) 表示频域坐标,其中 $f_x = 1/x, f_y = 1/y$ 。进一步我们将物体的光场分布表示成复振幅形式。

$$O(x, y) = |O(x, y)| \exp[j\varphi(x, y)], \quad (3)$$

式中: $\varphi(x, y)$ 代表物体相位分布。对于一束与 z 轴夹角为 θ 的参考光,其可以表示为

$$R(x, y) = A \exp[-j2\pi(xf_x + yf_y)]. \quad (4)$$

该式表明参考光在 X 和 Y 方向分别引入了空间载频 f_x 和 f_y ($\theta = 0$ 时, $f_x = f_y = 0$)。因此该参考光与物光相互干涉产生的全息图的强度表达式为

$$\begin{aligned} I(x, y) &= |O(x, y) + R(x, y)|^2 = \\ &|O(x, y)|^2 + |R(x, y)|^2 + O(x, y) \cdot R^*(x, y) + O^*(x, y) \cdot R(x, y) = \\ &A^2 + |O(x, y)|^2 + A |O(x, y)| \exp[j\varphi(x, y) - j2\pi(xf_x + yf_y)] + \\ &A |O(x, y)| \exp[j2\pi(xf_x + yf_y) - j\varphi(x, y)] = \\ &A^2 + |O(x, y)|^2 + 2A |O(x, y)| \cos[\varphi(x, y) - 2\pi(xf_x + yf_y)], \end{aligned} \quad (5)$$

式中:符号*表示对应分量的共轭项。干涉效应将物体的振幅和相位信息记录在了明暗相间的干涉条纹中,从而使得物体的全部波前信息转化为强度被捕获下来。

要想重新得到物体的振幅与相位信息则便需要

进行数字全息图重建。该重建过程便是将采集到的强度图 $I(x, y)$ 恢复为物光复振幅 $C(x, y)$ 的过程。整个过程可以表示为

$$C(x, y) = \mathcal{F}^{-1} \{ \mathcal{F}[\sqrt{I(x, y)}] \times As_{-z_0}(x, y) \}. \quad (6)$$

至此,通过 DHM 方法便可以获取物体完整的波前信息。

基于数字全息显微术已经成为生物医学研究中对样品进行相衬成像的一种便捷方法^[5-7]。DHM 作为一种相干成像系统,其最大优势在于可以从波前重建中实时且定量获取物体振幅与相位信息。通过这种方法获得的高分辨率相位分布可以用于确定折射率变化以及样品厚度,这一点对于不合适染色的透明活体待测样品的研究是非常有吸引力的。DHM 同时也是在三维体积中分析与追踪微型物体的有效工具,这是由于在传统显微技术中只能记录固定平面处的二维聚焦图像,不在焦平面的信息会永远丢失,而 DHM 的自聚焦特性则提供了将样品重新聚焦的工具,且能在没有机械调焦的情况下记录样品所有的实时三维结构全息图。这些信息以数字形式记录,便于后续数据处理。因此 DHM 可以检测非常微小相位变化的能力使定量相位成像可以深入揭示细胞的三维特征及其结构,反过来可能对医学诊断有许多潜在影响。DHM 可以克服传统显微成像中景深较浅且无法实时成像的局限性,还可以最大限度地减少像差与背景失真。基本的 DHM 设置简单,仅需一个带有相干光源的显微成像系统和一台数字相机,这种设置常常以 Gabor 全息术的形式展现,即同轴全息;离轴 DHM 设置基于 Mach-Zehnder 干涉仪,在调制灵活度上相较同轴全息有所提高,并且避免了孪生像问题。当今 DHM 系统设计针对不同问题形态各异,例如为了克服 CCD 像素大小的制约,干涉测量中的相移技术也被应用到 DHM 中,其至少需要捕获三幅全息图,参考光与物光之间的相位差需要逐步变化。在实施这种实验采集处理过程较为复杂的方案中,我们可以引入深度学习技术,从而降低达成同种成像目的所耗费的时间成本或计算成本,以便提升显微成像系统的成像效率,具体内容将于下文展开论述。总之,DHM 方法为微观物体的三维形貌、透明物体的厚度与折射率分布的量化提供了一种快速、无损、无标签的测量手段,已经广泛应用于细胞成像^[8-9]、缺陷与折射率检测^[10-11]以及表面形貌测量^[12-13]等领域。

近年来,机器学习(ML)领域发展如火如荼,与用定义明确的模式或规则来处理数据的传统计算机算法不同,ML 可以直接从一系列数据中通过学习其中的模式或规则从而执行特定的任务。深度神经网络(DNN)作为机器学习研究的一个新领域^[14],起源于人工神经网络(ANN)模型。如图 2 所示,DNN

由许多相互连接的计算单元(人工神经元)构成,它们共同组成了一个多层的网络结构,其中包含输入层、隐藏层(DNN 的隐藏层通常大于 5 层)以及输出层。通过全连接的形式,同一层的每个神经元的输入都是上一层所有神经元的输出与各自权重乘积的加权和,再通过非线性变换函数^[15](即激活函数),后一层在接受前一层加权和的激活值后再输入到下一层。如果能适当地分配和调整人工神经元之间的权重参数,DNN 便可以近似为任意的函数。基于通用图形处理器(GPU)的强大计算能力、大规模数据集、特有的反向传播算法以及可以使用通用特征学习的能力,深度学习(DL)在计算机视觉、自然语言处理、语音识别等领域取得了显著优于传统机器学习算法的成果^[16-18]。深度学习在求解“逆问题”以及非线性问题方面的独特优势同样也引起了国内外光学成像研究者的广泛关注。通过对大型数据集的训练,深度学习可以实现大批量特征值提取,从而无需对成像过程中的每一步都精确建模^[19]。在许多光学成像分支领域,例如光学层析成像^[20-21]、光纤成像^[22]、鬼成像^[23]、散射成像^[24]和弱光环境成像^[25]等,深度学习解决了这些领域尚未很好解决的成像逆问题,并获得了较好的成像结果。对于 DHM 来说,深度学习同样也为其在成像过程中提供了新的思路并开拓了新的应用前景。




图 2 深度神经网络示意图

Fig. 2 Schematic of deep neural network

如今,深度学习已经可以很好地处理 DHM 中涉及的许多问题,例如全息重建^[26-27]、自动聚焦^[28]等。与传统方法相比,这些与深度学习相结合的方法具有更高的成像效率,这是由于传统方法需要孤立处理单个图像且需要先验知识,而深度学习方法通常无需大量先验知识^[29],基于深度学习的重建方法可以利用大规模数据集对重建问题施加潜在约

束。通过网络学习优化阶段,基于深度学习的方法可以进行实时重建,而传统算法则需要为每个新图像进行迭代优化,这便体现出深度学习方法高效的特点。本文系统地梳理与总结了深度学习与 DHM 结合相关工作的研究进展。首先从基础网络框架下深度学习辅助 DHM 成像任务的基本原理出发,阐述了深度学习结合 DHM 成像方法的具体实施步骤;其次,针对深度学习在 DHM 中全息图的重建、焦点估计与自动聚焦、去噪、提高分辨率等方面回顾并讨论近年来国内外各课题组所报道的相关成果,对深度学习在 DHM 成像中的应用进行了汇总;最后对深度学习 DHM 的发展趋势进行了总结与展望。

2 深度学习数字全息显微成像的基本原理

2.1 基本理论

深度学习在 DHM 中多数是用来建立图像之间的映射关系,通常以使用监督式深度学习模型处理该问题为主。下面以 DHM 中深度学习辅助全息图重建为例解释图像映射关系。携带物体信息的物光 O 在成像系统中与参考光 R 干涉后,数字探测器记录下干涉条纹的强度分布 I ,在这里参物光干涉形成全息图的过程可以视为 DHM 成像系统的前向传播过程。因此对于深度学习网络来说,一旦建立起映射函数 $f: I \rightarrow O$,便可以完成从 I 到 O 的恢复重建。在深度学习中,映射函数的建立是通过大量权重参数 ϕ 定义的神经网络 \mathfrak{R}_ϕ 的拟合数据过程逐渐得到一个与真实映射函数非常逼近的映射模型来实现的,只要通过数据统计完成该模型的建立,便可以将其应用到类似问题的求解中。该过程实现步骤通常是:首先获取大量全息图与其对应的重建图像并构建数据集,为了与前文对应,在这里将数据集表示为 $\delta = \{(O_n, I_n) | n=1, 2, \dots, N\}$ 。然后构建一个用于拟合该数据集的神经网络,通过不断调整 ϕ 的值使得网络的输出 $\mathfrak{R}_\phi(I_n)$ 与标签图像 O_n 之间的误差最小化。该训练过程可以表示为

$$\phi_0 = \arg \min_{\phi} \sum_{i=1}^N F [O_n, \mathfrak{R}_\phi(I_n)], \quad (7)$$

式中: ϕ_0 为网络权重参数的最优解; $F [O_n, \mathfrak{R}_\phi(I_n)]$ 为损失函数。最后,用训练数据集以外的数据对受训网络进行测试,检验其性能。

2.2 数据收集与预处理

作为一种基于数据驱动的策略,深度学习网络

训练所使用的数据数量与质量对最终网络输出的结果有着很大的影响,所以数据集准备是实施深度学习方案的关键步骤。数据的收集和预处理通常是深度学习网络实施过程中最耗时的步骤,此步骤的目的是根据当前任务目标对现有或正在收集的数据进行组织与整理。数据集的构成通常分为两类:模拟数据和实验数据。模拟数据在解决标准化问题或泛用问题时有一定的优势,实验数据则更有利于解决特定问题。但无论对于何种数据,首先都需要确保数据集的可信度,即数据是否忠于事实。在大多数情况下,训练数据的获取手段并不复杂,因为我们旨在解决成像“逆问题”的正向模型是已知的且易于获取。仍以全息图重建任务为例,训练数据集由原始全息图以及通过传统重建算法得到的振幅与相位图构成,其中,原始全息图作为网络输入,重建图像作为训练标签。对于数据量,数据集规模并不是越大越好,通常在解决实际问题时要以数据采集成本作为衡量标准^[30],即数据集规模大小通常取决于实际问题的复杂程度,其与为解决某问题所搭建的光路系统有关:例如搭建成本较低的同轴全息光路^[31],其精简的光学元件构成使之在数据获取过程中不易受到环境因素等引入的干扰,因此允许获取以万数为单位的数据集;而复杂光路想要获取同等量级的数据集便需要数据增强处理的辅助^[32]。

需要注意的是,根据网络结构与性能,实验中获取的原始图像通常会被分割成较小尺寸的补丁图像进行训练,这也是数据预处理中最常见的图像分割步骤,补丁的大小会对网络训练性能产生影响。具体体现在该预处理步骤需要应和网络架构,例如卷积神经网络(CNN)中较大的卷积核或较深的网络层数都需要较大尺寸的补丁来完成训练^[33]。与此同时,训练数据的数量会对网络训练结果造成影响。若数据集过小,模型便不能从少量样本中概括特征,在该情况下拟合数据会导致测试集错误率的上升。通常可以采用数据增强处理,即创建同一图像具有轻微变化的多个副本。具体处理方式如裁剪、旋转、平移或缩放图像;对于不同数据集还可以进行添加噪点、模糊或改变颜色等处理。这种方法可以凭借低实验和计算成本获得大量额外的与原始样本相区分的新数据样本。另外,训练数据的质量也会对网络训练结果造成影响,在数据预处理阶段中可能会引入人为误差,导致生成图像产生伪影,如褶皱、阴影与区域模糊等,这些不良结果会严重影响网络训练的质量,因此这一过程对于网络实施的成功与否

意义重大。对于低质量训练数据,往往需要对训练数据进行人工筛选或阈值剔除,将不符合要求的样本从数据集中删除,从而降低低质量数据对训练结果的干扰。为了进一步确保数据预处理的质量,还应当对数据图像进行归一化处理。常用的归一化处理方法如简单缩放、逐样本均值消减、特征标准化等。在归一化处理后还可以进行数据白化,降低特征相关性并使其具有相同的方差,从而去除输入数据的冗余信息。最后,所有图像均应使用相同的格式保存,并具有相同的尺寸、分辨率与像素比例,避免引入额外误差影响网络训练与判断。图像之间唯一的区别应该是和亟待解决的问题相关的特征信息。

2.3 网络的搭建

对于 DHM 成像任务构建用于拟合数据集的神经网络,CNN 是使用频率最高的深度学习框架之

一。与传统 DNN 相比,CNN 凭借其独特的局部感知、权重共享和池化等特性可以轻松地从图像或其他结构化数据中学习特征^[33]。在 CNN 中,人工神经元主要分为两种:第一种组成了用于对数据中的每一个特征进行局部感知的卷积层;另外一种组成了用于特征降维、数据压缩并抑制过拟合的池化层。其中,卷积层的输出需要经过激活函数才会映射到池化层中。CNN 架构示意图如图 3(a)所示,其对于图像数据的运作机理为:通过卷积层提取输入图像的特征,在特征图上逐区域地应用激活函数,将一些邻域统计信息合并以替换特征图的部分邻域,最终将图像特征完全提取并加以学习。每层间单元相互连接,每个单元都可以从上一层中获取加权输入,从而形成金字塔式结构,即高层可以从越来越宽的底层中学习特征。下面对 CNN 中的卷积层、激活层与池化层进行介绍。

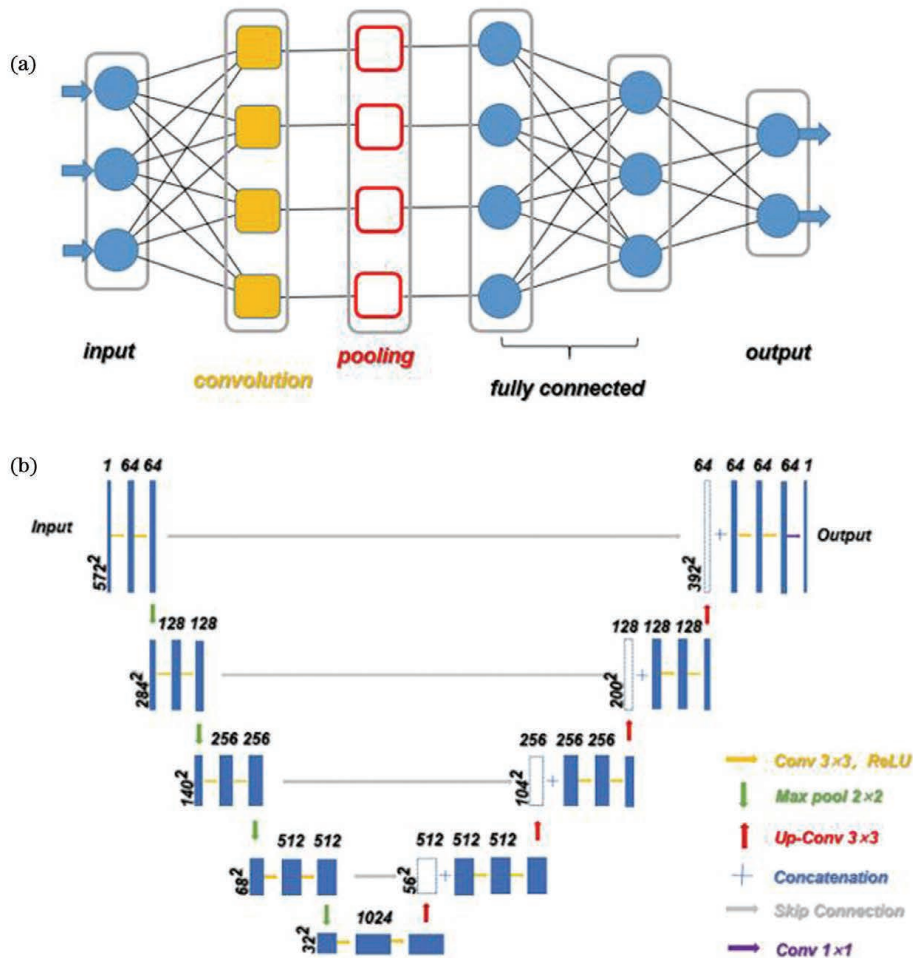


图 3 网络架构。(a)卷积神经网络;(b)U-net^[38]

Fig. 3 Network architecture. (a) Convolutional neural network; (b) U-net^[38]

1) 卷积层是 CNN 的基础与关键构成部分。该层的输入是图像或特征图,由卷积核(滤波器)通过

卷积运算来提取输入图像中的特征。每个卷积核在对图像的运算过程中先从左向右移动,后从上到下

移动。每次移动的距离称为步长,在每次移动前将计算卷积核和相应区域图像矩阵进行点积操作,运算结束后便得到一个受该卷积核约束的新特征图。值得一提的是,每个卷积核在整个层内共享权重,这便可以大大减少网络参量。因为图像中具有相同特征的部分可能出现在多个位置,经过训练并确定权重后的卷积核可以快速地对整个图像进行检索并提取相应特征。卷积层的深度决定了其对特征提取的性能,浅层卷积层通常用于检测边缘特征或颜色特征,而深层卷积层通常将浅层卷积层所获得的特征结合起来以获得更具体的细节特征。然而深层卷积层会使图像变得越来越小而丢失边缘信息,因此通常使用零填充操作解决该问题。

2) 激活层通常由非线性激活函数组成,其目的是增加神经网络的非线性特性,以便其可以尽可能逼近输入与输出间的真实映射关系。如果没有该层,神经网络将无法解决“异或”(XOR)问题。典型的激活函数有 S 型函数、tanh 函数和线性整流单元 ReLU^[34]等。其中,无论 S 型激活函数的输入值是多少,输出都将被限制在 $[0, 1]$ 的范围内。tanh 函数由于输出范围为 $[-1, 1]$ 而解决了非零中心的问题。ReLU 作为近年来最常用的激活函数,其定义为 $\text{ReLU}(x) = \max(0, x)$ 。与其他激活函数相比,ReLU 缓解了梯度消失的问题,这是因为在正区间内其输出永不为零且只需与零比较,所以其计算速度更快。除上述激活函数外还有许多其他类型的激活函数,需要根据任务和网络结构对合适的激活函数进行选择。

3) 池化层主要对特征图进行压缩处理,从而简化网络计算并从每个特征图中提取主要特征,以赋予网络平移不变性。通过卷积得到的大量边缘特征参数中,相邻的边缘往往具有相似的特性,因此继续获取大量相似的次边缘特征便没有太大的增量价值,反而会使得系统里充斥着大量冗余的信息,消耗计算资源。池化层便可以把语义上相似的特征合并起来,该池化操作能够减少卷积层输出的特征向量,从而达到减少参数并缓解过拟合的目的。所以池化是一种合并策略,合并操作会将输入图像的每个固定大小的矩阵用一个数字代替,通常使用最大合并法或平均合并法。

总体来说,在 CNN 训练过程中,输入网络的图像数据在下采样过程中尺寸减小,特征信息被提取出来。这些提取出的特征信息通常被用来解决两类问题,即分类问题与回归问题。其中,分类问题中常

见的网络模块为全连接层,通常存在于卷积神经网络的最后几层,如图 3(a)所示,其目的是将先前层中学习到的特征映射到标记样本空间,从而对不同特征类型的进行区分。对于回归问题(如图像生成),则需要对特征图进行上采样处理从而还原图像原始大小,这便需要转置卷积层。除了这些基本模块以外还有一些具有更高级功能的模块,例如批归一化处理单元^[35]、Dropout 层^[36]以及残差层^[37]等,设计这些模块都是为了进一步辅助训练过程并避免过度拟合问题的出现。另外,通过诸如桥接或级联操作,可以在层与层之间建立数据共享从而优化网络训练效率。网络构建的过程便是通过组合以上基本模块完成的,这样一来也就建立了网络输入到输出的映射模型。图 3(b)展示了 CNN 中一种常用网络模型 U-net^[38]的架构,在深度学习辅助 DHM 成像工作中,许多网络框架的构建都基于 U-net 进行改动与优化,它是一种十分泛用且基础的端到端卷积神经网络模型。该网络主要由两部分组成,前半部分为用于特征提取的下采样路径,后半部分为用于图像重构的上采样路径,两个路径之间使用桥接路径与跳跃连接相连,这种结构也被称作“编码器-解码器”结构。U-net 中的这种桥接路径采用了与传统 CNN 不同的特征融合方式,将上采样与下采样对应的两部分特征拼接在一起,使得最终网络的输出结果与物理测量值(标签真实值)更加贴近。

2.4 网络的训练与测试

神经网络的训练离不开两个重要的概念:损失函数与优化器。它们完成了网络在训练期间作为训练监督者使训练结果更好地贴近真实物理测量值的职责。如(7)式所示,神经网络的学习过程是通过损失函数进行的,网络训练的目标便是尽可能减少损失。例如对于分类问题来说,若网络预测值偏离实际结果太多,则损失函数会很大,但随着模型的改进优化,损失值会逐渐降低。而在回归问题的模型训练过程中会产生一个连续的损失下降值,因此对于不同问题便有不同的损失函数的设计。解决这两类问题最常用的损失函数有三种:均方误差(MSE)、平均绝对误差(MAE)和 Huber 损失^[39]。每个损失函数的公式定义如下。

均方误差(L2 损失):

$$F_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N [O_n - \mathfrak{R}_p(I_n)]^2. \quad (8)$$

平均绝对误差(L1 损失):

$$F_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^N |O_n - \mathfrak{R}_\phi(I_n)|. \quad (9)$$

Huber 损失:

$$F_{\text{Hub}} = \begin{cases} \frac{1}{2} [O_n - \mathfrak{R}_\phi(I_n)]^2, & \text{if } |O_n - \mathfrak{R}_\phi(I_n)| \leq \delta \\ \delta |O_n - \mathfrak{R}_\phi(I_n)| - \frac{1}{2} \delta^2, & \text{otherwise} \end{cases}. \quad (10)$$

MSE 是连续的, 而 MAE 不是。除此之外, MSE 的梯度变化有助于模型收敛, 而 MAE 的梯度则几乎不变。但涉及异常值时, MSE 非常敏感, 而 MAE 不容易受到影响。这是因为 $|O_n - \mathfrak{R}_\phi(I_n)| > 1$, MSE 的损失会变得比 MAE 大得多。因此, 没有具有绝对优势的损失函数, 其性能像网络架构一样取决于用来执行何种任务。除上述基本损失函数外, 还有一些针对某些特定任务设计的复杂损失函数, 例如用于图像风格转换的感知损失函数^[40]。

前述损失函数只是估计了输出值与真实值之间的静态差异, 而想要动态改变并使网络优化这一差异便需要另一个重要概念, 即优化器。优化器对损失函数的输出进行更新从而影响模型训练和模型输出的网络参数, 这样便可以把损失函数和模型参数联系在一起。简言之, 优化器从损失函数中学习到了使用特定方法来更新模型中的参数。最经典的优化算法是梯度下降算法, 该算法通过迭代运算求得最优解, 其对参数更新的规则表示为

$$\phi(s_{\text{step}} + 1) = \phi(s_{\text{step}}) + \eta \cdot N_\phi \hat{F}(\phi), \quad (11)$$

式中: s_{step} 为当前的训练步数, 训练开始时 $s_{\text{step}} = 0$, 需要初始化权重值 ϕ ; η 为学习率, 学习率越大表示权重变化越快, 但模型可能难以收敛到全局最小值, 学习率越小意味着每个步骤的权重更新越少, 训练模型花费的时间则会越长, 且模型更可能收敛于局部最小值, 所以学习率在包括梯度下降算法内的优化器中起着十分重要的作用, 需要谨慎选择合适的数值; $N_\phi \hat{F}(\phi)$ 是通过反向传播算法^[41]得到的损失函数 F 在 ϕ 处的梯度。对于不同的优化器的选择之间存在着利弊权衡, 随着深入的研究, 更多具有各项均衡能力的优化算法被提出, 如动量^[42]、Nesterov 加速梯度^[43]、Adagrad^[44]、RMSprop^[45]、Adadelata^[46]和 Adam 自适应矩估计^[47], 但使用何种优化器仍旧取决于任务种类与目的。

在对上述各种参数初始化完毕之后, 我们便可以将数据集引入。训练开始前需要将数据集按比例

随机划分为三个不相交的部分, 即训练集、验证集和测试集。在训练阶段仅用到训练集和验证集, 测试集则在训练完成后使用。其中, 训练集用于拟合模型, 且模型主要直接从训练集的数据中进行学习, 标准的训练集由输入-标签对组成, 网络在一一对应的数据中学习特征。训练过程中, 随着迭代次数的增加, 网络对训练集数据的输出与标签之间的误差会一直降低; 但过度训练后可能产生过拟合现象, 导致测试集数据输出与标签间的误差增大, 如图 4(a) 所示。验证集则对训练模型进行评估, 如图 4(b) 所示, 当在验证集上的误差开始增大时, 便可以及时停止训练。除此之外, 验证集还可以用于调整训练前初始化的各项训练超参数, 如学习率与训练批次大小等, 以便帮助模型的优化。如果模型得以改进, 则其在测试集上的输出质量或性能也会提高。测试集的目的是对模型是否有能力完成任务进行判断。与其他两类数据集相比, 测试集是不会影响模型的训练与性能的。对于数据集的三个组成部分, 有几项需要注意的事项: 首先, 训练集、测试集与验证集之间不应有任何重叠, 例如用于训练和验证的数据不应出现在测试集中, 否则对模型能力的评估是不完整的; 其次, 测试集中的数据不仅应涵盖训练集或验证集中包含的具有代表性的数据范围, 还应包括

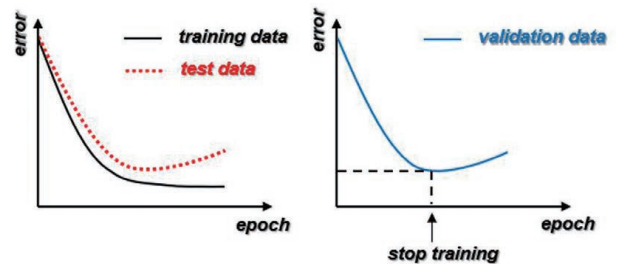


图 4 训练集、测试集与验证集中输出与标签之间的误差与迭代次数的变化关系。(a) 训练集与测试集; (b) 验证集

Fig. 4 Relationship between error between output and label in training set, test set, and validation set and number of iterations. (a) Training set and test set; (b) validation set

一些模型未曾见过但存在的真实情况。倘若条件允许则应测试相同类型的其他数据,从而评估模型的泛用性,测试结果可用于表示受训模型的性能。一旦受训模型在实际应用中满足处理特定任务的最低要求,便可以对其进行部署,唯一前提是训练过程的数据集需要能够代表部署时遇到的数据。通常默认训练集、测试集与验证集大小之比为 8 : 1 : 1,实际比例受整个数据集的大小和模型参数数量的影响。如果与模型参数相比数据集非常庞大,则训练集和验证集之间的比例对训练结果的影响较小,因为在该情况下训练数据量与验证数据量足以训练模型。但如果数据集较小,则应该仔细考虑该拆分比率。对于超参数很少的模型,减小验证集的大小易于验证和调整超参数;相反则应增加验证数据集的比例。

3 基于深度学习的数字全息显微成像

前文阐述深度学习 DHM 成像基本原理概念与实施流程便于后续对各领域方向中应用介绍的展开。本节将依次介绍深度学习对 DHM 成像过程中涉及的几项重要且热门的问题进行辅助性的相关工作。由于卷积神经网络在解决成像逆问题中表现出杰出的成效^[48],本文列举的相关研究工作均以卷积神经网络作为训练网络架构,汇总深度学习在数字全息显微成像应用中体现出的各项重要意义。

3.1 基于深度学习的全息图重建

DHM 从光路设计角度出发通常被分为同轴全息^[2]和离轴全息^[49]两种类型,当(5)式中 $\theta=0$ 时,即参考光与物光共光轴传播时为同轴全息,否则便为离轴全息。在同轴全息重建中,会产生一个虚假的物像叠加到重建的光场中,从而造成孪生像。为了解决孪生像问题,传统数字同轴全息系统在全息图采集时大多需要增加额外的器件对同一样品多次测量从而采集多张同轴全息图进行迭代重建。例如,测量不同的轴向距离、照明角度、波长、偏振态或其他物理量,这些额外的测量值是为了用作迭代重建中的物理约束,迫使重建值通过迭代算法收敛到物体的真实相位^[50]。由于该系统需要对物体进行多次测量,因此其通常只能用于准静态样品的成像。此外,迭代算法的实施繁琐且耗时,需要调整自定义参数才能使算法收敛并得到理想的重建图像。在离轴全息重建中,通过控制参考光光轴与物光光轴之间的夹角,可以在频域中将物体信息与孪生像分离,并且通过菲涅耳衍射^[51]或角谱法^[52]等数值算法,

仅需一幅离轴全息图即可完成重建过程,这种方法便可以用于动态样品成像,并且与同轴全息相比具有更高的重建效率。但同轴全息与之相比则拥有更简单的成像装置和更高的空间带宽积(可以在更大的视场上获得更高的分辨率)。为了优化传统数字全息重建过程,或者说将两种全息系统的优点相结合并进一步扩大,深度学习的辅助全息重建方法由此引入。与物理驱动的传统数字全息重建方法相比,基于深度学习的数据驱动方式可以从单幅全息图中快速、稳定地重建物体振幅和相位信息。

2017 年 9 月, Sinha 等^[53]首次提出可以通过端到端神经网络来进行同轴全息重建。如图 5(a)所示,他们在实验中搭建无透镜成像系统获取训练数据,训练网络对给定相位对象的衍射强度图(原始全息图)进行相位重建。与此同时, Rivenson 等^[28]证明了经过训练的神经网络可以快速消除同轴全息重建中的孪生像,如图 5(b)所示,将实验获得的单张同轴全息图经过反向传播计算得到带有孪生像的振幅图与相位图作为网络输入,对应物体真实重建图像作为标签进行训练,训练完毕的神经网络便可以去除该孪生像。2018 年 6 月,该课题组又提出了一种基于深度学习的同轴全息图重建执行自聚焦并显著扩展景深的方法^[54],如图 5(c)所示,获得的同轴全息图通过反向传播计算得到一定距离范围内带有“孪生像”的离焦振幅图与相位图,将得到的离焦振幅图与相位图作为网络输入,神经网络便可以输出聚焦的没有孪生像的高质量振幅图与相位图。2018 年 9 月, Wang 等^[31]提出了另一种基于深度学习的端到端的同轴全息图重建思路,该方法与前述工作相比不需要数据预处理过程,即无需为了获取标签图像而在同轴全息重建过程中引入的去零阶与孪生像所用的相移或相位去包裹算法,如图 5(d)所示,将获取的全息图直接输入训练好的网络中,利用神经网络直接从单张全息图中重建物体的相位,该方法同时降低了对物参光光程差与平面波或球面波差异的要求。2019 年 10 月, Wang 等^[55]提出了一种 Y 型卷积神经网络用于离轴全息重建,如图 5(e)所示,其特点是仅需将获取的单幅全息图输入网络即可同时输出振幅与相位两幅图像,该方法通过使用紧凑的网络模型带来了比典型网络模型更高的全息图重建效率与质量。2020 年 8 月,该课题组将他们提出的网络进行拓展,即提出具有四个输出通道的 Y4-Net 网络^[56],应用于双波长离轴数字全息图的重建。该方法使用单幅离轴数字全息图同时高效

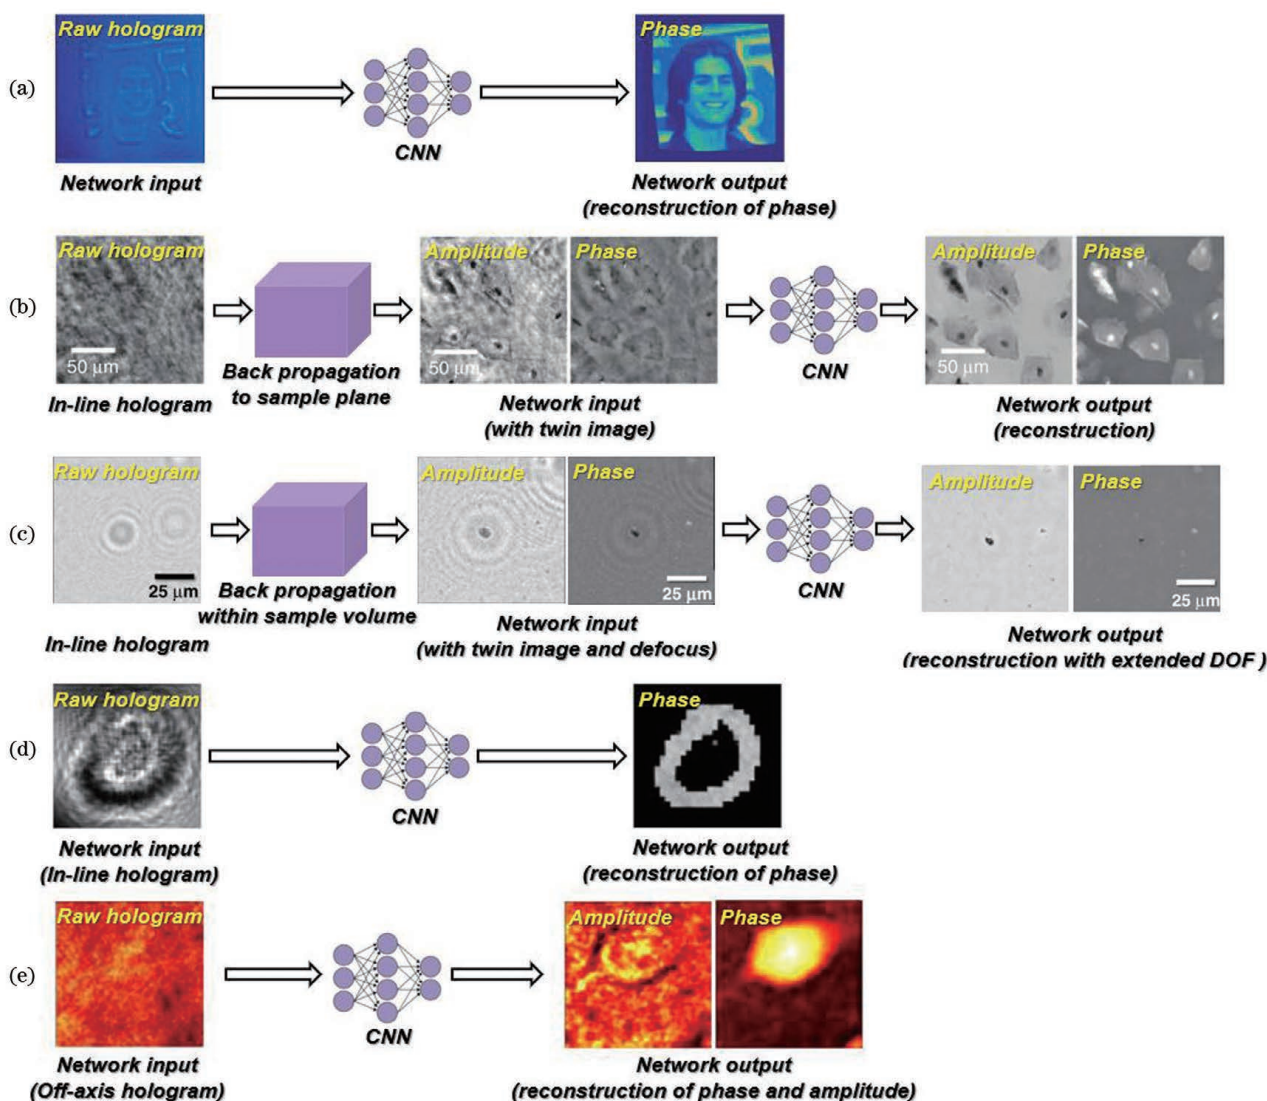


图 5 基于深度学习的全息重建。(a)基于深度学习的端到端的衍射强度图的相位重建^[53]；(b)基于深度学习的同轴全息重建中孪生像的去除^[28]；(c)基于深度学习的同轴全息重建中的执行自动聚焦与扩展景深^[54]；(d)基于深度学习的端到端全息图相位重建^[31]；(e)基于深度学习的全息图振幅与相位重建^[55]

Fig. 5 Deep-learning-based hologram reconstruction. (a) Phase reconstruction of diffraction intensity map based on end-to-end deep learning^[53]; (b) removal of twin images in in-line holographic reconstruction based on deep learning^[28]; (c) deep-learning-based autofocusing and removal of twin-images with extended depth-of-field^[54]; (d) autofocus and extended depth of field in in-line holographic reconstruction based on deep learning^[31]; (e) amplitude and phase reconstruction of off-axis hologram based on deep learning^[55]

重建两个波长下的振幅与相位信息,可以准确解决在共光路情况下具有挑战的频谱重叠问题。

上述的这些算法在训练过程中,输入图像和标签图像的信息分布必须严格配对,目标信息分布的匹配与否直接决定了网络训练的准确性。但使用实验真实数据训练网络时,在数据记录过程中由于系统不稳定而产生的图像随机位移等环境因素影响往往会不利于网络输出的精确度。因此,获得精确且完美匹配的真实数据用于网络训练仍然是深度学

习领域中的一大难题。2019年12月,本文课题组的Yin等^[57]提出了一种新的基于Cycle-GAN框架^[58]的端到端深度学习的方法,该方法可以在深度学习辅助同轴全息重建过程中使用未配对且较少的图像进行训练,从而解决了训练过程中的输入图像与标签图像难以完美匹配的问题。如图6(a)所示,该方法所提出的网络的独特性在于无需与对象真实分布相关的先验知识。网络训练过程中使用的全息图(训练集输入)可以不与它们的真实相位图像(训练

集标签)相对应,且相位图像的数量可以小于全息图的数量。这是因为网络输入与标签,即全息图和真实相位图像之间的严格对应关系被图 6(a)所示框架中的三个损失函数所取代。其实现的具体过程为:全息图与不匹配的相位图同时输入到两个独立的网络中,每个网络具有两个生成器, $G: X \rightarrow Y$ 和 $F: Y \rightarrow X$,以及两个相应的鉴别器 D_Y 和 D_X 用于生成对抗性数据。 D_Y 的作用是测量真实相位图与生成器 G 生成的伪图像之间的差异,对于 D_X 也是

如此,这样构成的循环网络框架体系便可以提取对象特征信息而无需配对训练数据。这对于动态相位物体(如生物细胞)的全息重建具有重要意义,这是由于该方法可以通过学习相似的静态细胞相位图和非配对的全息图来获得全息重建机制。图 6(b)为该方法的实验结果,该结果表明即使标签集的数量为训练集的一半,网络也可以很好地完成全息重建。总之,该方法降低了获取训练数据的难度。

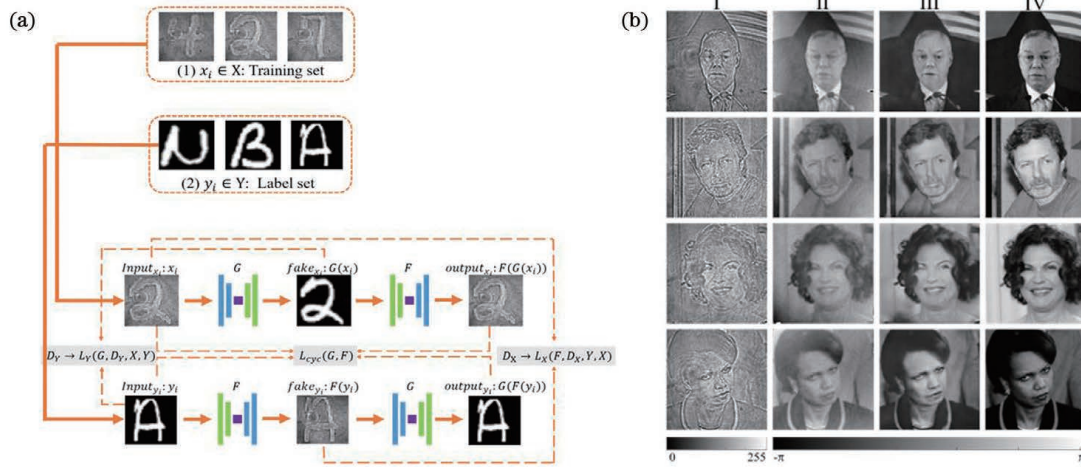


图 6 非配对数据下基于深度学习的全息重建^[57]。(a)训练过程($X_i \in X$:全息图; $Y_i \in Y$:相位图; G 和 F :生成器; D_Y :鉴别由 G 生成的图像; D_X :鉴别由 F 生成的图像; $L_{cyc}(D, F)$:循环一致损失; $L_Y(G, D_Y, X, Y)$: D_Y 与 G 之间对抗损失; $L_X(F, D_X, Y, X)$: D_X 与 F 之间的对抗损失);(b)重建结果(I: 输入网络的未经训练用于测试的全息图;II, III: 通过传统方法和基于深度学习的重建图像;IV: 真实相位分布)

Fig. 6 Deep-learning-based hologram reconstruction with unpaired data^[57]. (a) Process of network training ($X_i \in X$: hologram; $Y_i \in Y$: phase image; G & F : generator; D_Y : determine the authenticity of the images generated by G ; D_X : determine the authenticity of the images generated by F ; $L_{cyc}(D, F)$: loss of cyclic consistency; $L_Y(G, D_Y, X, Y)$: antagonistic loss between D_Y and G ; $L_X(F, D_X, Y, X)$: antagonistic loss between D_X and F); (b) reconstruction results (I: untrained hologram of input network for testing; II, III: reconstruction based on traditional methods and deep learning; IV: real phase distribution)

3.2 基于深度学习的 DHM 自动聚焦与相位恢复

在 DHM 技术中,对物体的聚焦位置,即(6)式中 z_0 值的准确获取是全息重建的关键。但实际情况中 z_0 值往往不能直接精确地获得,而需要使用聚焦算法获取。其具体步骤为:先对 z 堆栈中的多幅图像进行重建,然后通过熵函数^[59]、梯度算子^[60]、Tamura 系数^[61]、量值微分^[62]、边缘稀疏性^[63]等算法计算每张重建图像的清晰度,将最锐利或运算系数获得极值的图像对应的位置作为焦点位置。在实际应用中,为了提高聚焦精度,通常在整体粗聚焦之后还需要将重建距离缩短进行精确聚焦得到最终结果。这种方法虽然有效,但是对计算成本要求高,耗时长。此外,对于纯相位型物体,重建结果中的相位

跃变往往会被算法误解为尖锐结构,因此需要在重建后增加相位展开步骤,计算成本进一步增加。

2017 年,Pitkäaho 等^[64]首次提出利用深度学习的方法来估计全息图的焦点位置。他们先对获得的同轴全息图进行数值重建,去除孪生像后将重建图像向后传播并构成一组手动选择轴向距离的衍射图像,然后利用网络训练对重建图像进行轴向信息的提取。2018 年 4 月,Ren 等^[65]提出了一种基于深度学习的通过全息图直接获取物体深度信息的方法,与前一方法相比,该方法不需要对全息图进行预处理即可通过网络预测焦点位置,并通过预测出的焦点位置对全息图进行恢复重建。在这之后,Riverson 等提出了基于深度学习的用于同轴全息

图重建中同时执行自聚焦并显著扩展景深的方法。同年 7 月, Zhang 等^[26]提出了一种基于深度学习的应用于离轴 DHM 的相位恢复算法, 所提出网络的主要功能是通过离焦全息图得到相位展开后的聚焦相位图。如图 7(a)所示, 首先将获取的全息图粗聚焦重建后得到离焦的振幅图与未展开的相位图, 为了消除由于相位包裹导致的图像像素不连续而引起的神经网络误判情况, 使用正弦函数与余弦函数映射未展开的相位图得到 cos 相位图与 sin 相位图。将获得的离焦振幅图、离焦 cos 相位图与离焦 sin 相位图一同输入网络参与训练, 最终获得相位展开后的聚焦相位图。值得一提的是, 该课题组使用模拟数据集来模拟通过实验采集的真实图像, 其优点如前文所述, 即无需对不同样本进行重复聚焦工作而

使得网络易于实施, 并且利用传播算法在任意衍射距离处生成目标对象, 该对象只有一个对应的真实相位值。2019 年 1 月, Ren 等^[66]提出了一个基于深度学习端到端的全息自聚焦重建网络, 并通过重建振幅型物体与相位型物体证明了该方法的有效性。如图 7(b)所示, 所提出的网络可以输出无任何衍射斑的重建图像, 且不需要知道成像系统的任何物理参数或进行任何数据预处理。与此同时, Pitkäaho 等^[67]在他们先前工作^[64]的基础上, 将深度学习应用于 DHM 中完成对三维多细胞样本的焦点位置预测; Jaferzadeh 等^[68]以聚苯乙烯微球与人血红细胞作为研究样品, 将深度学习与 DHM 结合用于预测单细胞的焦点位置。这些研究工作有利于进一步推进对细胞间深度的测量和细胞粘附等方向的研究。

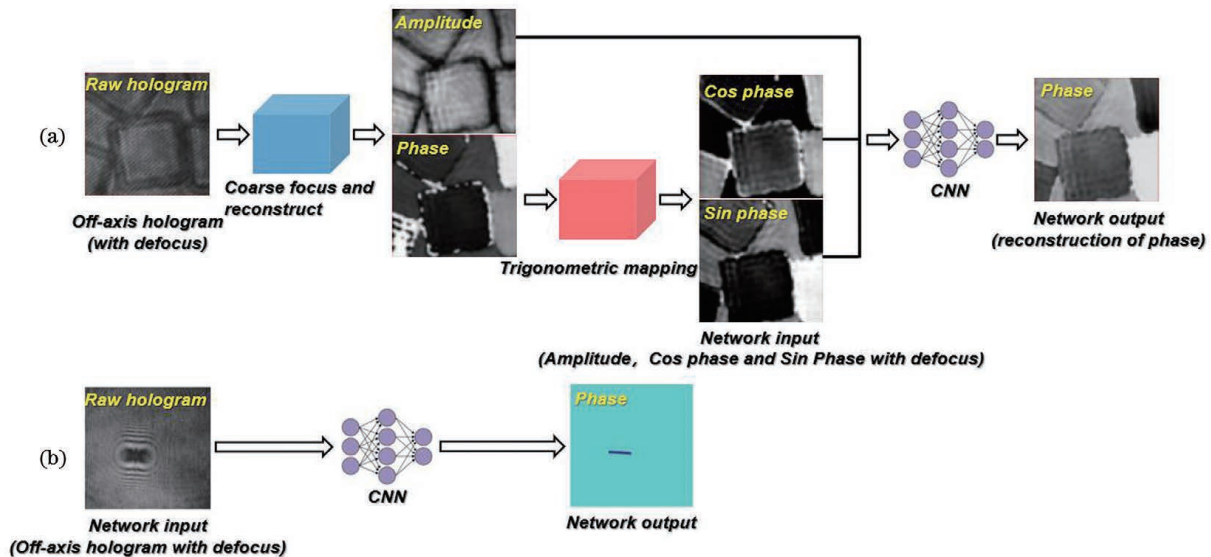


图 7 基于深度学习的自动聚焦与相位恢复。(a)基于深度学习的离焦全息图的相位恢复^[26]; (b)基于深度学习的端到端全息自聚焦重建^[66]

Fig. 7 Deep-learning-based autofocusing and phase reconstruction. (a) Phase recovery of defocus hologram based on deep learning^[26]; (b) holographic self-focusing reconstruction based on end-to-end deep learning^[66]

3.3 基于深度学习的 DHM 去噪

深度学习在 DHM 中用于对全息重建像进行去噪, 并且提高输出图像的信噪比也是一项重要的应用。在 DHM 成像过程中通常需要使用相干性较好的光源, 如激光, 以实现干涉。随之带来的问题则是相干光源对全息重建图像中引入的相干噪声, 通常在实验中还会加之环境噪声等因素的干扰, 极大影响了成像质量和成像对比度。对于噪声问题, 总体上有三种解决方案: 第一种是通过减少时域或空域中光源的相干性来实现散斑噪声抑制, 具体可以采用带有机械振动或部分相干光源的成像系统^[69-70], 但这往往会增加成像系统的复杂性; 第二种方法是

利用时间平均法^[71-72]抑制噪声, 该方法需要在成像系统中加入旋转的毛玻璃, 通过对所记录的多幅全息图进行平均处理抑制噪声, 显然这会影响到 DHM 成像的实时性; 此外还可以使用各种图像处理算法来抑制噪声, 例如使用传统滤波器、重采样掩模^[73]、BM3D^[74]等, 但是图像处理方法大多只能用于特定场景, 或者也需要记录多幅全息图像, 且还原的能力有限, 在处理噪声的同时还可能会造成一些有用信息的丢失。

研究人员将深度学习引入 DHM 成像去噪中, 并取得了显著效果。网络可以从大量成对无噪声的干净图像和有噪声图像的统计中学习两者之间的映

射关系来完成去噪处理。但在实验当中,获得干净图像用作去噪网络的训练数据是一件十分困难的事情。尽管在 DHM 之外的领域,Choi 等^[75]提出了基于 Cycle-GAN 的深度学习网络建立干净图像与有相干噪声的层析图像之间的关系,从而消除光学衍射层析中相干噪声的影响,但该方法在缺少干净训练数据的情况下仍然无法实施;Jeon 等^[76]使用具有加性高斯噪声的模拟图像和对应干净图像来学习去噪模型,若用于测试图像中的实际噪声与高斯噪声越接近,则去噪质量越高。但对于 DHM 来说,全息图中的噪声往往都是模型复杂并有一定随机性的,因此很难将其归类为任何典型的噪声模型并进行模拟数据集训练。为了解决这一问题,针对不同的相干成像系统的噪声抑制,本文课题组 Yin 等^[77]提出了一种基于深度学习的无需干净图像作为先验知识的算法来降低 DHM 重建过程中的散斑噪声。该算法基于 Noise2Noise 模型^[78],将基于深度学习的图像降噪作为回归问题处理:

若存在大量成对的噪声图像 x_n 与其对应的干净图像 y_n 输入到神经网络中用于训练时,根据(7)式可以将这个过程表示为

$$\phi_0 = \arg \min_{\phi} \sum_{i=1}^N F [y_n, \mathcal{R}_{\phi}(x_n)] \quad (12)$$

从统计学的角度来看,损失函数 F 可以理解为

负对数似然函数,且其优化过程可以看作最大似然估计。因为在降噪的过程中 x_n 与 y_n 并不是独立的,那么根据贝叶斯定理^[79],上式可以改写为

$$\phi_0 = \arg \min_{\phi} E_x \{ E_y |x F [y_n, \mathcal{R}_{\phi}(x_n)] \} \quad (13)$$

式中: x 和 y 表示的是一组输入图像 (x_n, y_n) ;符号 E 表示期望。对于均方误差损失 $F(x, y) = (x - y)^2$ 。用 \hat{y} 表示 y 加上对应数学期望的噪声,在网络参数保持不变的情况下,当 x_n 和 \hat{y}_n 之间的区别仅仅是噪声分布不同,且数据集足够大时,(13)式等价于:

$$\phi_0 = \arg \min_{\phi} \sum_{i=1}^N F [\hat{y}_n, \mathcal{R}_{\phi}(x_n)] \quad (14)$$

这便意味着可以在不改变网络训练结果的情况下将标签图像替换为带有散斑噪声的图像。

图 8(a)为该降噪算法的整个流程。在记录全息图的过程中,通过在物体前插入可旋转的毛玻璃来增加斑点噪声的随机性,从而获得噪声分布不同的全息图。对于每个样本,将散射介质随机旋转两次并记录下两张带有噪声的全息图,对全息图进行恢复重建后,可以得到两张内容一致,但噪声分布不同的全息图重建像。之后重复上述步骤拍摄足够多的样本图像用于网络训练。最终,经过无干净图像训练集对模型的训练,网络仍可以输出具有降低噪声效果的高信噪比全息重建结果。

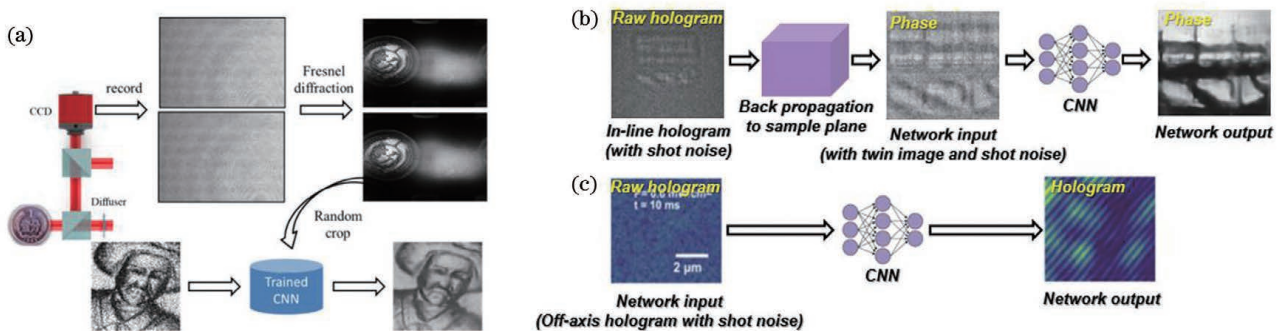


图 8 基于深度学习的全息重建噪声抑制。(a)基于深度学习的无需干净数据的相干成像散斑噪声抑制^[77]; (b)基于深度学习的同轴全息重建图像的散斑噪声抑制^[25]; (c)基于深度学习的离轴全息图散斑噪声抑制^[81]

Fig. 8 Deep-learning-based holographic reconstruction noise suppression. (a) Coherent noise suppression without clean data based on deep learning^[77]; (b) speckle noise suppression of in-line holographic reconstructed image based on deep learning^[25]; (c) off-axis hologram speckle noise suppression based on deep learning^[81]

另外,对于生物样品成像,高功率光源可能会诱导光毒性的产生从而影响细胞活力^[80]。但随着光源功率的减小,散斑噪声对成像质量的影响则会越来越强。2018 年 12 月, Goy 等^[25]针对这一问题提出了一种基于深度学习的低光功率同轴全息图相位

去噪重建方法,如图 8(b)所示,在低功率光源照射下获得带有噪声的全息图,并将其反向传播到焦平面重建带有噪声的相位图,将噪声相位图输入到训练好的深度学习网络中使网络输出干净的相位图像。最近, Zhang 等^[81]直接用深度学习的方法对

记录的离轴全息图进行去噪,避免噪声通过相位恢复步骤进一步传播,从而对振幅图与相位图都产生不利影响。如图 8(c)所示,将获取的带有噪声的离轴全息图输入训练好的神经网络中即可输出无噪声的离轴全息图,再对网络输出的干净离轴全息图进行数值重建即可获得无噪声的振幅图与相位图。

3.4 基于深度学习的 DHM 超分辨

在显微成像领域中,超分辨成像一直是一个热门话题。由于记录器件的像素尺寸以及显微物镜数值孔径的限制,DHM 成像系统的分辨率也会受到限制。针对记录器件像素间距使 DHM 成像系统的分辨率受限的问题,研究人员通过对同一样本进行多次亚像素移动的方法获取多幅低分辨率全息图后数字合成高分辨率全息图^[82];针对显微物镜数值孔径限制导致系统分辨率降低的问题,除了通过直接更换更大数值孔径的显微物镜来获取更高分辨率的成像之外,还有许多提升全息图重建分辨率的方法被提出^[83-85],或是引入倾斜照明、结构光照明与随机调制照明等照明方式来提升系统分辨率。这些技术大多是通过在系统

中增加额外的硬件用来辅助对准静态样品的连续多次测量以实现分辨率提高。近年来,基于稀疏性的全息重建方法证明了不需要增加额外器件以及多次测量也能够提高 DHM 成像系统的分辨率^[86-88]。但这些算法对全息图的高分辨重建都基于迭代优化算法,这便导致了重建时间的大大增加。研究人员继续将深度学习引入,并以将低分辨率输入图像转换为高分辨率的图像为思路完成基于深度学习的 DHM 超分辨。如图 9 所示,Liu 等^[82]便是基于这一思路,通过将单张由较少数量的亚像素移动测量合成的低分辨率的全息重建图像输入到网络中,输出得到由较多数量的亚像素移动测量合成的高分辨率的全息重建图像。所提出的网络训练完毕后便可以大大降低全息重建提高分辨率过程中需要记录并计算的全息图数量。另外,该课题组通过将低倍显微物镜下获得的全息图的重建图像输入网络得到相同视场下的高倍显微物镜下获得的全息的重建图像,这样便可以突破显微物镜数值孔径所定义的衍射极限以及系统的整体空间带宽积,使得全息重建图像拥有更高的分辨率,同时提高了重建效率。




图 9 基于深度学习的全息重建分辨率增强^[82]

Fig. 9 Resolution enhancement of hologram reconstruction based on deep learning^[82]

3.5 其他方面的应用

除了上文介绍的深度学习在 DHM 成像中的应用之外,还有许多诸如全息图生成^[89]、数字染色^[90]、交叉模式图像转换^[91]、全息衍射层析^[92-93]、分类^[94]、相差补偿^[95]等其他诸多方面的应用。Zhang 等^[26]探究了深度学习在 DHM 成像中的综合应用,图 10 便是这种基于深度学习的 Gabor 同轴全息图获取无噪声相位的方法,该方法本质上是通过神经网络将从同轴全息图中重建的带有孪生像的相位图转换为相应离轴全息图中重建的相位图,同轴与离轴数据集获取和预处理以及网络训练与实施的完整过程在图中展示。

DHM 能够记录包含物体三维体积信息的全息图。然而,这一过程通常需要附加额外的光学元件,如部分或完全相干光源产生干涉。Go 等^[89]提出了

一种基于深度学习的同轴全息图生成方法,该方法将普通白光光源获取的散焦明场图像转换为由相干光源记录的同轴全息图像,如图 11 所示。经过训练后的网络生成的同轴全息图的重建图像对比度优于真实全息图重建图像,信噪比相比于真实全息图提高了 3~5 倍,并且能够准确提供样品的三维位置信息。

有关交叉模式图像转换的工作则将侧重点放在传统相干光源全息重建图像与非相干光源显微成像的差异中。与显微镜成像不同,DHM 重建图像会受到相干噪声以及同轴全息中的孪生像等各种因素的影响,从而降低重建图像对比度。Wu 等^[91]便提出了一种名为“Bright-field Holography”的通过深度学习将同轴全息重建图像转化为明场显微镜图像从而提高成像对比度的方法,如图 12 所示。该方

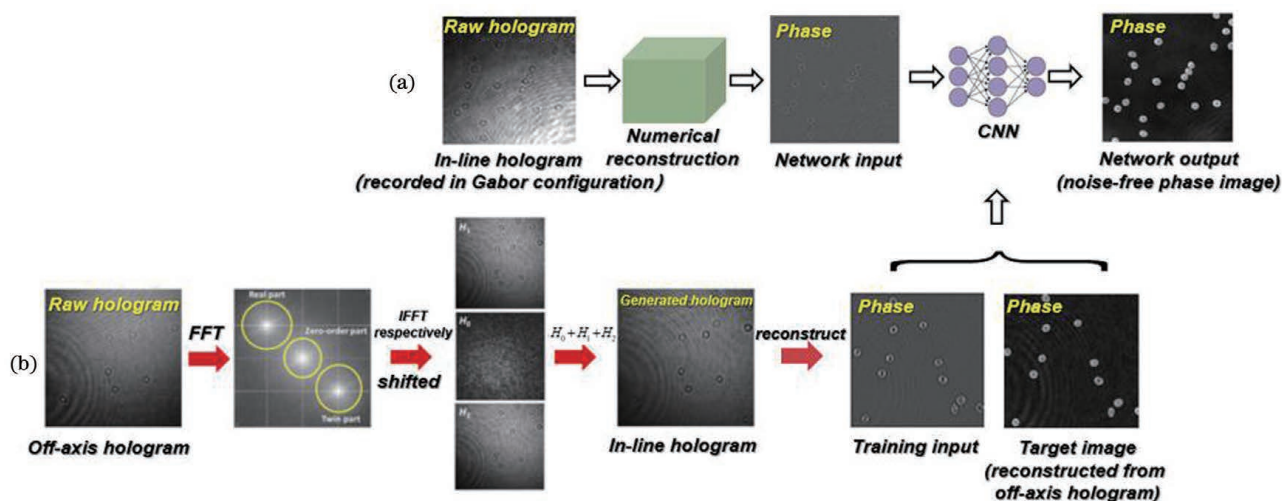


图 10 基于深度学习的同轴全息无噪声定量相位成像^[26]。(a)无噪声定量相位的获取流程；(b)数据集生成及网络训练过程
 Fig. 10 Deep-learning-based noise-free quantitative phase imaging of in-line holography^[26]. (a) Method to achieve the noise-free quantitative phase image; (b) training dataset generation and network training process




图 11 基于深度学习的全息图生成^[89]
 Fig. 11 Deep-learning-based hologram generation^[89]




图 12 基于深度学习的交叉模式图像转换^[91]
 Fig. 12 Deep-learning-based cross-modality image transformations^[91]

法将 DHM 成像获取信息量大与明场显微镜成像高对比度的优点相结合,实现了 DHM 的定量相位成像与非相干明场显微镜成像的融合。

还有一些工作将 DHM 作为成像工具并设计 DHM 系统用来获取作为网络训练所用的数据集,这些网络用来完成各类成像任务^[96-97]。本文课题组 Meng 等^[98]在去年 11 月发表了一项关于深度学习

暗场显微成像的工作。在该工作中,我们搭建了偏振复用离轴全息显微系统,这种经过特殊设计的 DHM 系统可以令带有偏振正交态的明场与暗场光路共同存在于成像路径中,由此得到的复合全息图可以同时重建物体明场与暗场信息。将这些采集到的图像制作成数据集后供给网络训练,使网络建立明场图像与暗场图像之间在理论上难以精确推导的

潜在联系,并最终通过深度学习的方法完成明-暗场图像转化,从而实现高效的高分辨数值暗场显微成像,如图 13 所示。正是因为偏振复用 DHM 系统的实施,我们得以轻松地获得完美匹配的明场与暗场图像,在省略了耗时且容易引入人为误差的数据配

准过程,在确保端到端网络输出质量的同时提高了成像效率。由此可见,在深度学习应用于 DHM 中解决相关问题的同时,DHM 也可以凭借自身特性为其他成像问题提供用于神经网络训练的优质数据集,两者在某种意义上达成了互利共赢的良好局面。




图 13 基于深度学习的高分辨数值暗场显微成像^[98]

Fig. 13 High-resolution numerical dark-field microscopy imaging based on deep learning^[98]

4 结束语

本文回顾了将深度学习技术与数字全息显微成像相结合后诞生的各项研究成果,详细列举如自动聚焦这些基于深度学习的 DHM 重建方法,这些方法对 DHM 成像过程中遇到的各种问题均可以起到一定程度的辅助作用。虽然目前基于深度学习的 DHM 成像方法已经在一些前文所述的难以解决的 DHM 成像问题中取得突破,但这种基于数据驱动的方法对数据量的获取始终有较高的要求,因此在生物医学中该方法的实施往往会受到限制^[99]。对于这一点,首先可以考虑利用迁移学习策略^[100],用非生物医学图像或者易于获取的其他类型生物医学图像对模型进行预训练,从而引导模型完整功能的实现。通过建立类似计算机视觉中的 ImageNet^[101] 这样的公开可用的标准数据集也可以促进生物医学成像领域的进一步发展。此外,虽然基于深度学习的成像方法可以利用大量特征值降低对实际成像过程的精确建模需求,但是基于神经网络搭建的模型往往需要大量不同的样品数据和广泛的重建距离等信息来量化模型,并使其更好地逼近理想模型。

综上所述,由于 DHM 成像技术的独特优势以及深度学习应用于 DHM 中显著的令人印象深刻的研究成果,我们有理由相信如今仍处于飞速发展的深度学习方法,即这种具有强大数据统计功能的由神经网络和数据驱动构成的映射策略有望成为 DHM 成像领域中一个不可或缺的“工具箱”。

参 考 文 献

[1] Park Y K, Depeursinge C, Popescu G. Quantitative phase imaging in biomedicine[J]. Nature Photonics,

2018, 12(10): 578-589.

- [2] Gabor D. A new microscopic principle[J]. Nature, 1948, 161(4098): 777-778.
- [3] Kim M K. Principles and techniques of digital holographic microscopy[J]. SPIE Reviews, 2010, 1(1): 018005.
- [4] Stepanishen P R, Benjamin K C. Forward and backward projection of acoustic fields using FFT methods[J]. The Journal of the Acoustical Society of America, 1982, 71(4): 803-812.
- [5] Marquet P, Rappaz B, Magistretti P J, et al. Digital holographic microscopy: a noninvasive contrast imaging technique allowing quantitative visualization of living cells with subwavelength axial accuracy[J]. Optics Letters, 2005, 30(5): 468-470.
- [6] Kemper B, Carl D D, Schnekenburger J, et al. Investigation of living pancreas tumor cells by digital holographic microscopy[J]. Journal of biomedical optics, 2006, 11(3): 034005.
- [7] Stern A, Javidi B. Theoretical analysis of three-dimensional imaging and recognition of microorganisms with a single-exposure on-line holographic microscope[J]. Journal of the Optical Society of America. A, Optics, Image Science, and Vision, 2007, 24(1): 163-168.
- [8] Doblaz A I, Sánchez-Ortiga E, Martínez-Corral M, et al. Accurate single-shot quantitative phase imaging of biological specimens with telecentric digital holographic microscopy[J]. Journal of Biomedical Optics, 2014, 19(4): 046022.
- [9] Marquet P, Depeursinge C, Magistretti P J. Review of quantitative phase-digital holographic microscopy: promising novel imaging technique to resolve neuronal network activity and identify cellular biomarkers of psychiatric disorders[J]. Neurophotonics, 2014, 1(2): 020901.

- [10] Pourvais Y, Asgari P, Abdollahi P, et al. Microstructural surface characterization of stainless and plain carbon steel using digital holographic microscopy[J]. *Journal of the Optical Society of America B*, 2017, 34(5): B36-B41.
- [11] Dai S Q, Dou J Z, Zhang J W, et al. Digital holography based near-field imaging and its application[J]. *Acta Optica Sinica*, 2020, 40(1): 0111008.
戴思清, 豆嘉真, 张继巍, 等. 基于数字全息术的近场成像与应用[J]. *光学学报*, 2020, 40(1): 0111008.
- [12] Cuche E, Marquet P, Depeursinge C. Simultaneous amplitude-contrast and quantitative phase-contrast microscopy by numerical reconstruction of Fresnel off-axis holograms[J]. *Applied Optics*, 1999, 38(34): 6994-7001.
- [13] Brady D J, Choi K, Marks D L, et al. Compressive holography[J]. *Optics Express*, 2009, 17(15): 13040-13049.
- [14] Liu W B, Wang Z D, Liu X H, et al. A survey of deep neural network architectures and their applications[J]. *Neurocomputing*, 2017, 234: 11-26.
- [15] Bottou L. Large-scale machine learning with stochastic gradient descent [M] // Lechevallier Y, Saporta G. *Proceedings of COMPSTAT '2010*. Heidelberg: Physica-Verlag HD, 2010: 177-186.
- [16] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444.
- [17] Russakovsky O, Deng J, Su H, et al. ImageNet large scale visual recognition challenge[J]. *International Journal of Computer Vision*, 2015, 115(3): 211-252.
- [18] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[J]. *Advances in Neural Information Processing Systems*, 2012, 25: 1097-1105.
- [19] Zhang J L, Chen Q, Zhang X Y, et al. Lens-free on-chip microscopy: theory, advances, and applications[J]. *Infrared and Laser Engineering*, 2019, 48(6): 0603009.
- [20] Halupka K J, Antony B J, Lee M H, et al. Retinal optical coherence tomography image enhancement via deep learning[J]. *Biomedical Optics Express*, 2018, 9(12): 6205-6221.
- [21] Huang Y Q, Lu Z X, Shao Z M, et al. Simultaneous denoising and super-resolution of optical coherence tomography images based on generative adversarial network[J]. *Optics Express*, 2019, 27(9): 12289-12307.
- [22] Rahmani B, Loterie D, Konstantinou G, et al. Multimode optical fiber transmission with a deep learning network[J]. *Light, Science & Applications*, 2018, 7: 69.
- [23] He Y C, Wang G, Dong G X, et al. Ghost imaging based on deep learning[J]. *Scientific Reports*, 2018, 8: 6469.
- [24] Li Y Z, Xue Y J, Tian L. Deep speckle correlation: a deep learning approach toward scalable imaging through scattering media[J]. *Optica*, 2018, 5(10): 1181-1190.
- [25] Goy A, Arthur K, Li S, et al. Low photon count phase retrieval using deep learning [J]. *Physical Review Letters*, 2018, 121(24): 243902.
- [26] Zhang G, Guan T, Shen Z Y, et al. Fast phase retrieval in off-axis digital holographic microscopy through deep learning[J]. *Optics Express*, 2018, 26(15): 19388-19405.
- [27] Xiao W, Wang Q X, Pan F, et al. Adaptive frequency filtering based on convolutional neural networks in off-axis digital holographic microscopy [J]. *Biomedical Optics Express*, 2019, 10(4): 1613-1626.
- [28] Rivenson Y, Zhang Y, Günaydin H, et al. Phase recovery and holographic image reconstruction using deep learning in neural networks [J]. *Light, Science & Applications*, 2018, 7: 17141.
- [29] Barbastathis G, Ozcan A, Situ G H. On the use of deep learning for computational imaging[J]. *Optica*, 2019, 6(8): 921-943.
- [30] Wang F, Wang H, Bian Y M, et al. Applications of deep learning in computational imaging [J]. *Acta Optica Sinica*, 2020, 40(1): 0111002.
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): 0111002.
- [31] Wang H, Lyu M, Situ G H. eHoloNet: a learning-based end-to-end approach for in-line digital holographic reconstruction [J]. *Optics Express*, 2018, 26(18): 22603-22614.
- [32] Zuo C, Feng S J, Zhang X Y, et al. Deep learning based computational imaging: status, challenges, and future [J]. *Acta Optica Sinica*, 2020, 40(1): 0111003.
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.
- [33] Albawi S, Mohammed T A, Al-Zawi S. Understanding of a convolutional neural network [C]//2017 International Conference on Engineering and Technology (ICET), August 21-23, 2017, Antalya, Turkey. New York: IEEE Press, 2017:

- 1-6.
- [34] Nair V, Hinton G E. Rectified linear units improve restricted boltzmann machines [C] // Proceedings of the 27th International Conference on Machine Learning (ICML-10), June 21-24, 2010, Haifa, Israel. San Diego: ICML, 2010: 807-814.
- [35] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C] // Proceedings of the 32nd International Conference on Machine Learning, (ICML) 2015, July 6-11, 2015, Lille, France. Cambridge: JMLR, 2015: 448-456.
- [36] Srivastava N, Hinton G, Krizhevsky A, et al. Dropout: a simple way to prevent neural networks from overfitting [J]. The Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [37] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [38] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[M]//Navab N, Hornegger J, Wells W M, et al. Medical image computing and computer-assisted intervention-MICCAI 2015. Lecture notes in computer science. Cham: Springer, 2015, 9351: 234-241.
- [39] Huber P J. Robust estimation of a location parameter [M] // Kotz S, Johnson N L. Breakthroughs in statistics. Springer series in statistics. New York: Springer, 1992: 492-518.
- [40] Johnson J, Alahi A, Li F F. Perceptual losses for real-time style transfer and super-resolution [M] // Leibe B, Matas J, Sebe N, et al. Computer vision-ECCV 2016. Lecture notes in computer science. Cham: Springer, 2016, 9906: 694-711.
- [41] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagating errors[J]. Nature, 1986, 323(6088): 533-536.
- [42] Qian N. On the momentum term in gradient descent learning algorithms[J]. Neural Networks, 1999, 12 (1): 145-151.
- [43] Nesterov Y. A method for solving the convex programming problem with convergence rate $O(1/k^2)$ [J]. Dokl. Akad. Nauk SSSR, 1983, 269 (3): 543-547.
- [44] Duchi J C, Hazan E, Singer Y. Adaptive subgradient methods for online learning and stochastic optimization [J]. Journal of Machine Learning Research, 2011, 12(7): 257-269.
- [45] Liu L Y, Jiang H M, He P C, et al. On the variance of the adaptive learning rate and beyond [EB/OL]. (2019-08-08) [2021-05-30]. <https://arxiv.org/abs/1908.03265>.
- [46] Zeiler M D. Adadelta: an adaptive learning rate method [EB/OL]. (2012-12-22) [2021-05-30]. <https://arxiv.org/abs/1212.5701>.
- [47] Kingma D P, Ba J. Adam: a method for stochastic optimization [EB/OL]. (2014-12-22) [2021-05-30]. <https://arxiv.org/abs/1412.6980>.
- [48] McCann M T, Jin K H, Unser M. Convolutional neural networks for inverse problems in imaging: a review[J]. IEEE Signal Processing Magazine, 2017, 34(6): 85-95.
- [49] Leith E N, Upatnieks J. Reconstructed wavefronts and communication theory[J]. Journal of the Optical Society of America, 1962, 52(10): 1123-1130.
- [50] Rivenson Y, Wu Y C, Ozcan A. Deep learning in holography and coherent imaging [J]. Light: Science & Applications, 2019, 8: 85.
- [51] Schnars U, Jptner W P O. Digital recording and numerical reconstruction of holograms[J]. Measurement Science and Technology, 2002, 13(9): R85-R101.
- [52] 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.
- [53] Sinha A, Lee J, Li S, et al. Lensless computational imaging through deep learning [J]. Optica, 2017, 4 (9): 1117-1125.
- [54] 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.
- [55] Wang K, Dou J, Kemao Q, et al. Y-Net: a one-to-two deep learning framework for digital holographic reconstruction [J]. Optics Letters, 2019, 44 (19): 4765-4768.
- [56] Wang K, Kemao Q, Di J, et al. Y4-Net: a deep learning solution to one-shot dual-wavelength digital holographic reconstruction [J]. Optics Letters, 2020, 45(15): 4220-4223.
- [57] Yin D, Gu Z Z, Zhang Y R, et al. Digital holographic reconstruction based on deep learning framework with unpaired data [J]. IEEE Photonics Journal, 2019, 12(2): 1-12.
- [58] Zhu J Y, Park T, Isola P, et al. Unpaired image-to-image translation using cycle-consistent adversarial

- networks[C]//2017 IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 2242-2251.
- [59] Guo J, Zeng W H, Xie T B. Fast autofocus method based on entropy function[J]. Metrology Technology, 2003, 11: 30-32.
郭军, 曾文涵, 谢铁邦. 基于熵函数的快速自动聚焦方法[J]. 计量技术, 2003, 11: 30-32.
- [60] Subbarao M, Tyan J K. Selecting the optimal focus measure for autofocusing and depth-from-focus [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1998, 20(8): 864-870.
- [61] Memmolo P, Distante C, Paturzo M, et al. Automatic focusing in digital holography and its application to stretched holograms [J]. Optics Letters, 2011, 36(10): 1945-1947.
- [62] Lyu M, Yuan C, Li D, et al. Fast autofocusing in digital holography using the magnitude differential [J]. Applied Optics, 2017, 56(13): F152-F157.
- [63] Zhang Y, Wang H, Wu Y, et al. Edge sparsity criterion for robust holographic autofocusing [J]. Optics Letters, 2017, 42(19): 3824-3827.
- [64] Pitkäaho T, Manninen A, Naughton T J. Focus classification in digital holographic microscopy using deep convolutional neural networks[J]. Proceedings of SPIE, 2017, 10414: 104140K.
- [65] Ren Z B, Xu Z M, Lam E Y. Learning-based nonparametric autofocusing for digital holography [J]. Optica, 2018, 5(4): 337-344.
- [66] Ren Z B, Xu Z M, Lam E Y M. End-to-end deep learning framework for digital holographic reconstruction[J]. Advanced Photonics, 2019, 1(1): 016004.
- [67] 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.
- [68] Jaferzadeh K, Hwang S H, Moon I, et al. No-search focus prediction at the single cell level in digital holographic imaging with deep convolutional neural network[J]. Biomedical Optics Express, 2019, 10(8): 4276-4289.
- [69] Mehta D S, Naik D N, Singh R K, et al. Laser speckle reduction by multimode optical fiber bundle with combined temporal, spatial, and angular diversity[J]. Applied Optics, 2012, 51(12): 1894-1904.
- [70] Pan J W, Shih C H. Speckle reduction and maintaining contrast in a LASER pico-projector using a vibrating symmetric diffuser [J]. Optics Express, 2014, 22(6): 6464-6477.
- [71] Liu S J, Wang D, Li S J, et al. Speckle noise suppression method in holographic display using time multiplexing[J]. Optical Engineering, 2017, 56(6): 063107.
- [72] Makowski M. Minimized speckle noise in lens-less holographic projection by pixel separation[J]. Optics Express, 2013, 21(24): 29205-29216.
- [73] Bianco V, Paturzo M, Memmolo P, et al. Random resampling masks: a non-Bayesian one-shot strategy for noise reduction in digital holography [J]. Optics Letters, 2013, 38(5): 619-621.
- [74] Bianco V, Memmolo P, Paturzo M, et al. Quasi noise-free digital holography [J]. Light, Science & Applications, 2016, 5(9): e16142.
- [75] Choi G, Ryu D, Jo Y, et al. Cycle-consistent deep learning approach to coherent noise reduction in optical diffraction tomography [J]. Optics Express, 2019, 27(4): 4927-4943.
- [76] Jeon W, Jeong W, Son K, et al. Speckle noise reduction for digital holographic images using multi-scale convolutional neural networks[J]. Optics Letters, 2018, 43(17): 4240-4243.
- [77] Yin D, Gu Z Z, Zhang Y R, et al. Speckle noise reduction in coherent imaging based on deep learning without clean data [J]. Optics and Lasers in Engineering, 2020, 133: 106151.
- [78] Lehtinen J, Munkberg J, Hasselgren J, et al. Noise2noise: learning image restoration without clean data[EB/OL]. (2018-03-12)[2021-05-30]. <https://arxiv.org/abs/1803.04189>.
- [79] Lindley D V. Fiducial distributions and Bayes' theorem[J]. Journal of the Royal Statistical Society: Series B (Methodological), 1958, 20(1): 102-107.
- [80] Kang I, Zhang F C, Barbastathis G. Phase extraction neural network (PhENN) with coherent modulation imaging (CMI) for phase retrieval at low photon counts[J]. Optics Express, 2020, 28(15): 21578-21600.
- [81] Zhang Z D, Zheng Y J, Xu T N, et al. Holo-UNet: hologram-to-hologram neural network restoration for high fidelity low light quantitative phase imaging of live cells [J]. Biomedical Optics Express, 2020, 11(10): 5478-5487.
- [82] Liu T, de Haan K, Rivenson Y, et al. Deep learning-based super-resolution in coherent imaging systems [J]. Scientific Reports, 2019, 9(1): 3926.
- [83] Mico V, Zalevsky Z, García-Martínez P, et al. Synthetic aperture superresolution with multiple off-axis holograms[J]. Journal of the Optical Society of America A, 2006, 23(12): 3162-3170.

- [84] Bishara W, Su T W, Coskun A F, et al. Lensfree on-chip microscopy over a wide field-of-view using pixel super-resolution[J]. *Optics Express*, 2010, 18(11): 11181-11191.
- [85] Luo W, Zhang Y B, Feizi A, et al. Pixel super-resolution using wavelength scanning [J]. *Light, Science & Applications*, 2016, 5(4): e16060.
- [86] Szameit A, Shechtman Y, Osherovich E, et al. Sparsity-based single-shot subwavelength coherent diffractive imaging [J]. *Nature Materials*, 2012, 11(5): 455-459.
- [87] Liu Y, Tian L, Hsieh C H, et al. Compressive holographic two-dimensional localization with $1/30^2$ subpixel accuracy[J]. *Optics Express*, 2014, 22(8): 9774-9782.
- [88] Fournier C, Jolivet F, Denis L, et al. Pixel super-resolution in digital holography by regularized reconstruction[J]. *Applied Optics*, 2016, 56(1): 69-77.
- [89] Go T, Lee S, You D, et al. Deep learning-based hologram generation using a white light source[J]. *Scientific Reports*, 2020, 10: 8977.
- [90] Rivenson Y, Liu T, Wei Z, et al. PhaseStain: the digital staining of label-free quantitative phase microscopy images using deep learning [J]. *Light, Science & Applications*, 2019, 8: 23.
- [91] Wu Y C, Luo Y L, Chaudhari G, et al. Bright-field holography: cross-modality deep learning enables snapshot 3D imaging with bright-field contrast using a single hologram[J]. *Light, Science & Applications*, 2019, 8: 25.
- [92] Kamilov U S, Papadopoulos I N, Shoreh M H, et al. Learning approach to optical tomography[J]. *Optica*, 2015, 2(6): 517-522.
- [93] Di J, Han W, Liu S, et al. Sparse-view imaging of afiber internal structure in holographic diffraction tomography via a convolutional neural network [J]. *Applied Optics*, 2021, 60(4): A234-A242.
- [94] Wang H D, Rivenson Y, Jin Y Y, et al. Deep-learning enables cross-modality super-resolution in fluorescence microscopy[J]. *Nature Methods*, 2019, 16(1): 103-110.
- [95] Nguyen T, Bui V, Lam V, et al. Automatic phase aberration compensation for digital holographic microscopy based on deep learning background detection[J]. *Optics Express*, 2017, 25(13): 15043-15057.
- [96] Jo Y J, Park S, Jung J H, et al. Holographic deep learning for rapid optical screening of anthrax spores [J]. *Science Advances*, 2017, 3(8): e1700606.
- [97] Kakkava E, Rahmani B, Borhani N, et al. Imaging through multimode fibers using deep learning: the effects of intensity versus holographic recording of the speckle pattern[J]. *Optical Fiber Technology*, 2019, 52: 101985.
- [98] Meng Z, Ding L Q, Feng S T, et al. Numerical dark-field imaging using deep-learning [J]. *Optics Express*, 2020, 28(23): 34266-34278.
- [99] Jo Y J, Cho H, Lee S Y, et al. Quantitative phase imaging and artificial intelligence: a review[J]. *IEEE Journal of Selected Topics in Quantum Electronics*, 2019, 25(1): 1-14.
- [100] Pan S J, Yang Q. A survey on transfer learning[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2010, 22(10): 1345-1359.
- [101] Deng J, Dong W, Socher R, et al. ImageNet: a large-scale hierarchical image database [C] // 2009 IEEE Conference on Computer Vision and Pattern Recognition, June 20-25, 2009, Miami, FL, USA. New York: IEEE Press, 2009: 248-255.