

卷积神经网络在光学信息处理中的应用研究进展

邸江磊^{1,2*}, 唐雎^{1,2}, 吴计^{1,2}, 王凯强^{1,2}, 任振波^{1,2}, 张蒙蒙^{1,2}, 赵建林^{1,2**}

¹光场调控与信息感知工业和信息化部重点实验室, 西北工业大学, 陕西 西安 710129;

²陕西省光信息技术重点实验室, 西北工业大学物理科学与技术学院, 陕西 西安 710129

摘要 近年来,深度学习技术的爆发式发展引领了机器学习的又一次浪潮。深度神经网络具备抽象特征的高效识别与提取能力、强大的非线性拟合能力、抗干扰鲁棒性及非凡的泛化能力,被广泛应用于自动驾驶、目标识别、机器翻译、语音识别等领域。最近几年,卷积神经网络(CNN)在光学信息处理中获得广泛应用,本文介绍 CNN 的基础概念和结构构成,回顾其在数字全息术、条纹分析、相位解包裹、鬼成像、傅里叶叠层成像、超分辨显微成像、散射介质成像、光学层析成像等领域的最新应用进展,评述 CNN 在光学信息处理中的典型应用特点,最后分析 CNN 应用于光学信息处理中的不足,并展望其未来发展。

关键词 光计算; 光学信息处理; 深度学习; 卷积神经网络; 计算光学成像; 信息光学

中图分类号 O438

文献标志码 A

doi: 10.3788/LOP202158.1600001

Research Progress in the Applications of Convolutional Neural Networks in Optical Information Processing

Di Jianglei^{1,2*}, Tang Ju^{1,2}, Wu Ji^{1,2}, Wang Kaiqiang^{1,2}, Ren Zhenbo^{1,2},
Zhang Mengmeng^{1,2}, Zhao Jianlin^{1,2**}

¹Key Laboratory of Light Field Manipulation and Information Acquisition, Ministry of Industry and Information Technology, Northwestern Polytechnical University, Xi'an, Shaanxi 710129, China;

²Shaanxi Key Laboratory of Optical Information Technology, School of Physical Science and Technology, Northwestern Polytechnical University, Xi'an, Shaanxi 710129, China

Abstract The explosive development of deep learning technology has led another wave of machine learning in recent years. Deep neural network, with the ability to recognize and extract abstract features, fit nonlinear relationships, against interference factors and generalization, is widely used in autopilot, target recognition, machine translation, speech recognition and other fields. The convolutional neural networks (CNN) are popular in optical information processing. In this paper, we introduce the basic concepts and structural components of CNN in detail, and review the applications in digital holography, fringe patterns analysis, phase unwrapping, ghost imaging, Fourier ptychographic microscopy, super-resolution microscopy, scattering medium imaging, optical tomography imaging, etc. We summarize the typical applications and existing shortages of CNN in optical information processing, and finally prospect the future development of convolutional neural networks.

Key words optics in computing; optical information processing; deep learning; convolutional neural networks; computational optical imaging; information optics

OCIS codes 200.3050; 090.1995; 110.3010; 110.5086; 110.1758

收稿日期: 2021-04-30; 修回日期: 2021-06-07; 录用日期: 2021-06-10

基金项目: 国家自然科学基金(62075183, 61927810, 61905197)

通信作者: *jiangleidi@nwpu.edu.cn; **jlzhao@nwpu.edu.cn

1 引言

近年来,基于数据驱动的机器学习算法在医疗诊断、工业生产、科学研究和经济分析等领域发展迅速。作为早期机器学习的代表,人工神经网络(ANN)是受生物大脑神经网络响应机理启发而构建的一种计算结构^[1-2],其中神经元和激活函数概念的首次提出引发了当时的研究热潮,并为神经网络的后续发展奠定了基础。然而,早期的神经网络因为非线性拟合能力的缺乏、计算能力的限制,以及数据样本小、训练时间长、容易过拟合等问题阻碍了其发展。直至20世纪80年代,反向传播(BP)算法在多层感知机(MLP)中成功应用,同时 Sigmoid 函数的提出提高了系统的非线性映射能力,有效解决了网络的非线性学习问题,不过 BP 算法依旧存在局部最优、过拟合和梯度扩散等问题。后来广泛流行的支持向量机(SVM)等浅层机器学习模型虽然可有效地应用于模式识别、目标分类和回归分析等任务,但仍与神经网络有所差异^[3]。2006年,Hinton等^[4]提出通过无监督预训练的方式对权值进行初始化,再进行有监督训练微调以解决深层神经网络训练中梯度消失的问题。伴随着 Relu 激活函数的提出,多层神经网络结构成为可能。深度神经网络是以不少于两个隐藏层的神经网络对输入进行非线性变换或表示的技术,由简单概念间的联系来定义和表达复杂概念,实现从一般抽象概括到高级抽象表示,最终建立“输入”和“输出”之间的映射关系^[5]。随着神经网络参数优化过程中梯度消失、梯度爆炸等问题的陆续解决,用户数据的爆炸式增长带来的数据获取成本的下降,同时得益于显卡(GPU)运算性能的快速提升,作为机器学习重要分支的深度学习技术引领了人工智能技术发展的又一次高潮。深度学习技术当前已广泛并成功应用于自动驾驶、目标识别、机器翻译、语音识别等领域。

深度学习至今已发展出多种模型,典型模型包含卷积神经网络(CNN)^[6]、循环神经网络(RNN)^[7]、深度置信网络(DBN)^[8]、生成对抗网络(GAN)^[9]等。CNN是深度学习中最具代表性的模型之一,它是一类包含卷积计算且具有深度结构的前馈型神经网络,具有局部连接、权重共享和多层使用等特点,其局部连接的结构方式与生物神经元的系数响应特性相符,在多个领域获得非常成功的应用。早在1998年,LeCun等^[6]首先完成了CNN经典模型设计,并为数字分类任务设计了 LeNet-5 网络结构。

2012年,在ImageNet图像识别大赛中,Krizhevsky等^[10]采用改进的深层CNN网络 AlexNet 打破纪录获得比赛冠军,从而令 CNN 模型获得广泛关注。2015年,Szegedy等^[11]提出采用全新 Inception 模块的 GoogLeNet,并在 ILSVRC-2014 大赛中夺冠。不同于 AlexNet 主要通过增加网络深度来提升训练效果,Inception 结构的提出可进一步避免网络层数过深带来的缺陷。RNN 是专门处理序列数据的记忆性神经网络,之后进一步发展的长短期记忆网络(LSTM)有效克服了 RNN 的短期记忆的缺点,从而广泛应用于语音识别、文本分类等自然语言处理任务^[12-14]。GAN 是一种基于博弈对抗思想的网络模型^[9],拥有生成器和判别器两个子网络,该网络可以脱离先验假设学习到高维数据分布信息,在图像处理相关领域应用较多。

由于近几年来深度学习技术快速发展,促使其在不同研究领域逐渐获得应用。在光学信息处理领域,深度学习,尤其是 CNN 为数字全息术、条纹分析、相位解包裹、鬼成像、傅里叶叠层成像、超分辨显微成像、散射介质成像、光学层析成像等领域内部分问题的解决提供一种全新思路,并取得了显著效果^[15-18]。本文首先介绍 CNN 的相关基础知识;随后按照研究领域分类梳理 CNN 在光学信息处理方面的典型应用;最后总结 CNN 的典型应用特点和应用前景。

2 卷积神经网络

2.1 基础概念

在信息光学中,光波在传播过程中受到目标物体调制而携带目标的信息。这些信息通常是隐藏在众多背景因素下的隐式信息,只能采用间接方式转化为显式信息进行测量。如图1所示,假设变量 X 经历某一物理过程 P 后转化为信息 $P(X, \theta)$,其中 θ 代表其他影响因素。通常情况下,该物理过程未知且难以用解析方式表达。一方面,若已知变量 X 的演化趋势,预知 $P(X, \theta)$ 往往需要借助模型仿真,但仿真过程具有一定成本和难度,且准确度难以衡量。如何低成本快速准确地正向推演出 $P(X, \theta)$ 是一个值得研究的问题。另一方面,根据显式信息 $P(X, \theta)$ 的变化,如何反演得到隐藏变量 X 的分布是逆问题求解的关键。深度学习技术的出现为这两类问题的求解带来曙光。深度学习利用数据驱动,通过建立神经网络从大量 X 和 $P(X, \theta)$ 的数据样本学习其隐藏关系,经过复杂的反馈调节参数,建立




图1 仿真过程。(a)物理模型;(b)神经网络拟合正向问题;(c)神经网络拟合逆问题

Fig. 1 Simulation process. (a) Physical model; (b) forward problems fitting by neural network; (c) inverse problems fitting by neural network

非线性隐式映射关系 f 来拟合 P 或者 P^{-1} 。随着计算能力的快速发展和数据样本的海量增加,当前的深度神经网络已发展至数百层,并拥有上亿个神经元。

在信息光学、图像处理等相关领域,CNN 备受青睐。得益于卷积运算所引入的稀疏连接、参数共享和平移不变等特性,CNN 拥有优异的特征提取能力,主要由输入层、隐藏层和输出层构成,其中隐藏层包括但不限于特征提取层、采样层和激活层等。针对具体的光学信息处理任务,通常需要结合特定物理过程,采用相应的神经网络架构并优化细节结构搭建 CNN 网络,结合真实物理过程中采集的大量样本所构建的数据集完成训练,从而实现任务目标。




图2 仿真过程。(a)全连接结构;(b)卷积运算

Fig. 2 Simulation process. (a) Fully connected structure; (b) convolution operation

2) 采样

下采样过程是神经网络进行特征提取和信息滤波的重要方式。通常,下采样过程由池化运算完成,通过计算对应区域中的最大值或平均值,使输出张

1) 特征提取

在神经网络训练过程中,输入网络后的信息通常以张量表示为多维数组。张量经过不同算子多重运算后不同维度上的结构发生变化,即信息从低阶转化为高阶的过程,称之为特征提取。该过程实则是目标信息不断抽象化,同时滤除其他杂散信息的过程。

全连接结构是神经网络中常见的特征提取结构。如图 2(a)所示,全连接结构的输入和输出可以是任意长度的一维张量,其每一层的任意节点都与邻近层的所有节点紧密连接,是一种层间密集连接结构。通过改变输入层节点的权重与偏置,可使输出张量包含的信息发生变化,从而完成特征提取。

CNN 中最主要的特征提取结构是卷积运算。以二维卷积运算为例,如图 2(b)所示,卷积核是尺寸固定而参数可调的二维矩阵。运算时,经参数初始化的卷积核会在输入矩阵上按照一定的步长滑动,在此过程中通过对应区域内矩阵数值与核参数进行内积运算获得输出矩阵上对应点数值,从而完成特征信息提取。与密集连接方式相对应,卷积运算邻近层节点间的连接数远小于两层节点之间的最大连接数,是层间稀疏连接,可大大降低网络参数数量和计算量。在卷积核滑动运算过程中,位于同一通道的输入矩阵使用相同的卷积核参数,因此具有参数共享特性。同时,输入矩阵上不同位置的特征使用相同的卷积核,使卷积对于相同特征的响应与位置无关,具有平移不变性。正是基于 CNN 的上述特性,使 CNN 与全连接网络相比拥有更少的参数量、更强的特征提取能力和更低的训练成本,从而具有更高的效率。

量的尺寸下降从而实现数据压缩和特征提取。对应的上采样过程则使用转置卷积运算或插值运算实现。通过设置合适的卷积核尺寸和滑动步长,转置卷积可实现期望的张量尺寸扩张。插值运算通常包

含双线性插值、双三次插值、最近邻插值等,也可用于上采样运算,常会额外引入不可调参数,降低网络的非线性表达能力。

3) 激活函数

激活函数通过对输入进行非线性映射来增加神经网络的非线性拟合能力。常用的激活函数包括 Relu、Tanh、Sigmoid 等函数。从图 3 可以看出,Relu 函数形式简洁,其导数计算简单,但当自变量非正时,其值为零,梯度消失,会导致神经网络在层数较多时出现梯度消失现象,网络参数会停止更新;Sigmoid 函数的值域为(0, 1),具有良好的对称性,但当自变量值超过一定范围时,函数的梯度变化很小,不利于深层 CNN 的反向传播运算;Tanh 函数的值域为(-1, 1),收敛速度比 Sigmoid 函数快,但梯度消失的问题也难以避免。




图 3 激活函数曲线图

Fig. 3 Curve of activation function

4) 训练优化

损失函数为神经网络的优化过程指明方向,也是衡量映射关系拟合程度的标准。损失函数值越小,表示神经网络拟合的隐式映射与真实物理过程越接近。根据损失函数的不同,神经网络通常可分为回归模型和分类模型两大类。在回归模型中,常用的损失函数有平均绝对误差(MAE)和均方误差(MSE)。在分类模型中,最常用的损失函数是交叉熵。

除此之外,损失函数正则化也是网络训练中常采用的一种策略。通过在损失函数中添加正则化项,可以给网络训练施加约束,使其朝着我们期望的方向优化。将这一策略与物理过程相结合,可以将物理约束转化为独特的正则化约束,从而使网络在具体的应用中获得更好的效果。训练过程中反向传播调节参数的过程通过优化算法来实现的。如今优

化算法如随机梯度下降算法(SGD)、动量随机梯度下降(SGDM)、自适应梯度(Adagrad)和自适应矩估计(Adam)等逐渐发展成熟,而目前最常用的为 Adam。

2.2 网络主体结构

1) 骨干网络

面对不同的任务需求,可以选择不同的 CNN 网络结构。骨干网络是经典的一类基础网络,是各类 CNN 模型的共享结构。从最初的 Lenet^[6]到 Alexnet^[10]、Vggnet^[19]和 GoogLeNet^[11],CNN 的结构不断进化。由图 4(a)可知,Backbone 结构中卷积层及其他功能层依次连接,从输入的图片中提取特征信息,通过全连接层后这些信息会被加权编码,最后由网络输出固定形状的一维张量。Backbone 结构对回归模型和分类模型均适用,伴随着网络层数的增加,特征变得愈加高级抽象。不过,神经网络的层数过深会导致特征提取过程中信息丢失,同时伴随神经节点增加带来庞大计算量。因此,针对不同的应用对象,网络层数往往并不固定,具体结构也存在差异。

2) 全卷积网络

区别于 Backbone 结构中全连接层加权计算固定长度的特征向量,全卷积网络(FCN)^[20]使用卷积层替代全连接层的功能。FCN 采用分阶段训练的方式,揭示网络提取的浅层特征中所蕴含的更多细节信息,图 4(b)为 FCN 最后一个阶段的网络结构。FCN 最先应用于图像分割领域,能够实现任意尺寸图像的等尺寸像素级分割,其内部采取了转置卷积操作增大特征尺寸的思想,推进了“端到端”模型的发展。但是,FCN 分阶段训练比较耗时,且跳跃连接部分通过像素求和实现,导致其无法充分利用浅层信息,在某些更关注细节信息的任务中应用受限。

3) U 型卷积神经网络

受 FCN 结构启发,出现了 U 型 CNN(U-net)并在不同任务中获得广泛应用,如图 4(c)所示^[21]。U-net 结构左右对称,下采样和上采样过程之间以通道串联方式设置跳跃连接,网络的采样深度可自由选择,且无需分阶段训练网络,相比于 FCN 对细节信息的利用率更高。U-net 最早应用于医学图像分割,后来 U-net 的细节结构获得进一步针对性优化,最终在众多的“端到端”任务上取得了不错的效果。

4) 生成对抗网络

GAN 采取博弈思想,由生成模型和判别模型两部分构成^[9,22],其基本结构如图 4(d)所示。生成模




图4 网络主体结构。(a)骨干网络;(b)全卷积网络;(c)U型卷积神经网络;(d)生成对抗网络
Fig. 4 Main structure of network. (a) Backbone; (b) FCN; (c) U-net; (d) GAN

型可采用 U-net 从图像中观察学习来建立从输入样本到标签的拟合关系,生成与标签近似的输出。判别模型则通过训练来判别生成器输出与标签的真伪,并将结果反馈回生成模型用来增强损失函数。通过训练,生成模型和判别模型的能力逐渐提高,彼此不断对抗博弈,能够有效提升最终网络输出的效果。由于需要不断对抗,生成模型和判别模型需要保持一致的能力增强速率,否则会导致训练难以收敛乃至训练崩溃的问题。

2.3 网络细节结构

针对上节所介绍的网络主体结构,可以进一步在细节上对网络进行优化,以提升网络运行效率,改善网络性能。典型的网络细节结构有:

1) 残差结构

如图 5(a)所示,残差结构在原有卷积层级联的基础上增加了一条恒等映射信息链路,输入直接与输出求和后再经过激活传递给下一层^[23]。残差结构使得网络具备自主淘汰冗余层数的能力,彻底解决了深度神经网络训练过程中的梯度消失问题,可加快网络训练收敛速度,极大减少部分训练任务的计算量。

2) 多尺度信息融合

多尺度信息融合是一种能够在不同网络模型和细节结构中广泛应用的思想。如图 5(b)所示,经过不同卷积核或不同层数的卷积层调制的信息具有不同感受野,可将这些不同感受野的信息以层叠方式串联起来传递给下一层网络。多尺度信息融合可针对多个不同尺寸图像,不同分支通道,乃至不同特征

进行信息融合,从而使网络可兼容不同感受野下的信息。

3) 注意力机制

在 CNN 中,主流的注意力机制分为通道注意力机制与空间注意力机制^[24-25]。图 5(c1)所示通道注意力机制通过引入全连接层进行通道尺度的压缩和展开,以不断优化一维通道权重向量。通过与原始的特征在通道尺度上进行点乘,最终的输出特征中有效期望信息所在通道占有更大比重。图 5(c2)所示空间注意力机制通过卷积运算以不断优化二维空间权重张量,进行点乘求积后,最终使不同空间位置的特征对最后的输出产生不同影响。

4) 密集连接

如图 5(d)所示,密集连接的主要特征是在传统级联式网络和残差结构上进一步增加信息传递支路,使每一层都与其他层连接,从而使特征信息被多次提取,实现最大效率的利用^[26]。但是密集连接会增加训练过程中的计算量,降低运算效率,在一定程度上限制网络层数。

2.4 网络训练过程

合适的 CNN 网络结构和足够的样本数据集是神经网络可以有效发挥作用的关键。通常可以采用仿真模拟、实验记录或二者结合的方式构建样本数据集。在完成数据集构建和确定 CNN 网络结构基础上,即可进行神经网络模型的训练和测试。如图 6(a)所示,训练过程中,训练样本输入神经网络并前向传播,经过 CNN 后得到输出样本。随后,通过损失函数对比输出样本与标签的计算误差。误差




图5 网络细节结构。(a)残差块;(b)多尺度块;(c)注意力块,其中(c1)为通道注意力,(c2)为空间注意力;(d)密集连接块
Fig. 5 Detail structure of network. (a) Residual block; (b) multi-scale block; (c) attention block, in which (c1) is channel attention and (c2) is spatial attention; (d) dense connected block

通过梯度反向传播算法反馈调节网络权重,至此完成一次数据样本训练。根据所设定的训练参数,神经网络会对整个数据样本循环学习,直至损失函数的下降曲线达到收敛状态,此时CNN网络模型的训练基本完成。图6(b)是利用训练好的网络模型进行测试的过程,其基本流程与训练时样本的输入过程一致,但反向传播算法并不发挥作用。一般而言,一个可靠的网络模型不仅在训练样本上表现优异,在测试样本上同样表现出色。然而,由于网络结构因素或者数据样本缺陷等,训练过程中网络模型的损失函数可能难以收敛,或网络模型在训练样本和测试样本上的效果会出现较大差异,这是在具体任务中时常面临的挑战。

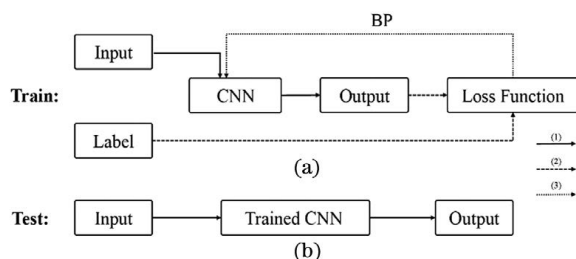


图6 网络训练和测试过程流程图。(a)训练过程;(b)测试过程
Fig. 6 Flow chart of network training and testing.

(a) Training process; (b) testing process

2.5 网络训练技巧

神经网络的训练过程伴随着网络的不断调整,

需要人为地不断进行网络结构微调 and 反复迭代训练以获得最佳效果。调参过程包含网络结构搭配、优化器和损失函数选择、学习率修改、权重初始化方式、正则化添加等内容。此外,还可以使用数据增强、图像预处理、节点随机失活和网络预训练等手段^[27-29]。

数据增强是在不改变图像固有信息的情况下,通过一些常见图像处理操作,例如翻转、位移、尺度变换、亮度调整、颜色抖动、添加噪声等,增加数据量以提高模型的泛化能力,常应用于数据获取成本较高或同质量数据样本较小的任务中。图像预处理是图像被送入CNN前进行的统一操作,可有效降低损失函数收敛难度,有零均值化、标准化等方式。随机失活是在网络的前向传播过程中,使某个神经元以一定概率停止工作。此方法常应用于神经网络节点众多的全连接层,使网络模型在测试过程中泛化性更强。迁移学习则是直接采用其他任务上训练的模型,使用当前数据集进行再训练微调参数。一般选取VGG、AlexNet、ResNet等经典结构,或曾在相似数据集上训练的网络模型,利用网络的泛化能力来降低当前网络的训练成本。

3 卷积神经网络在光学信息处理中的应用

光学信息处理涉及图像信息的获取、传递、解

调、存储等,而图像到图像的非线性映射问题是光学信息处理面临的主要任务之一。U-net 结构的对称分布特性决定了它在处理“端到端”任务时具有巨大的优势,可应用于成像、去噪等过程。

在处理“端到端”任务时,U-net 的下采样部分主要通过卷积运算实现输入图像信息的低层特征提取,并进一步经过层层卷积运算最终抽取获得输入图像的高层语义,而高层语义的表达主要通过上采样部分的反卷积运算,最终顺利实现输出图像重构。得益于 CNN 的稀疏连接、参数共享和平移不变性,相比于全连接网络,CNN 可以极大地降低参数数量和提高网络训练效率,可以更加高效地应用于图像相关的光学信息处理任务。以下就 CNN,尤其是 U-net 在数字全息术、条纹分析、相位解包裹等任务中的应用展开论述。

3.1 数字全息术

全息技术是一种重要的光学测量手段,尤其是 20 世纪 90 年代以来数字全息术得到了快速发展,并在无损检测等领域获得广泛的应用。由于常用的光学探测器无法记录光波的相位信息,数字全息术中通过引入参考光波,使其与经过待测物体调制后的物光波发生干涉,从而将待测物体引入的信息以干涉条纹的形式用 CCD 或者 CMOS 记录下来,形成数字全息图,随后利用计算机数值模拟全息图的衍射再现过程,实现物光波复振幅的数值重建,最终获得物光波的相位信息及待测物体的相关参数。

同轴全息术成像过程简单,相比离轴全息术具有更高的空间带宽积,但重建过程存在“孪生像”问题,严重影响其成像质量。针对这一问题,研究人员提出多种解析或迭代方法,如在不同轴向距离、照明角度、波长和偏振态等条件下拍摄全息图,将其作为重建过程中的物理约束对计算结果进行求解,使其收敛于待测目标的真实相位。Gerchberg 等^[30]提出了相位迭代算法(GS 算法),利用至少两幅在不同轴向距离处记录的同轴全息图进行迭代重建,以避免局部最小值收敛导致解的不唯一问题。然而,该方法在实验过程中需要采集两幅全息图,并且对其轴向距离定位要求较高,因而仅适用于准静态目标测量且计算过程耗时。深度学习技术的出现给解决这一问题带来了新的思路。Sinha 等^[31]在 2017 年首次提出利用 CNN 从衍射强度图像中恢复相位,并用数字、文字和人脸等多类图像证明了该方案的泛化能力,为深度学习技术应用于“端到端”的相位重建工作开创了先河;Riverson 等^[32]利用同轴全息术拍摄乳腺组织切片等的全息图,并经反向传播计算后得到含“孪生像”和自相干伪影的复振幅光场,进一步使用神经网络来抑制“孪生像”和自相干伪影,有效降低了实验复杂性,实验流程如图 7(a)所示。在此基础上,Wang 等^[33]基于 U-net 提出“端到端”全息重建网络 eHoloNet,实现了从同轴全息图到待测目标波前相位的直接重建,无需反向传播计算过程,进一步简化了实验步骤,如图 7(b)所示。

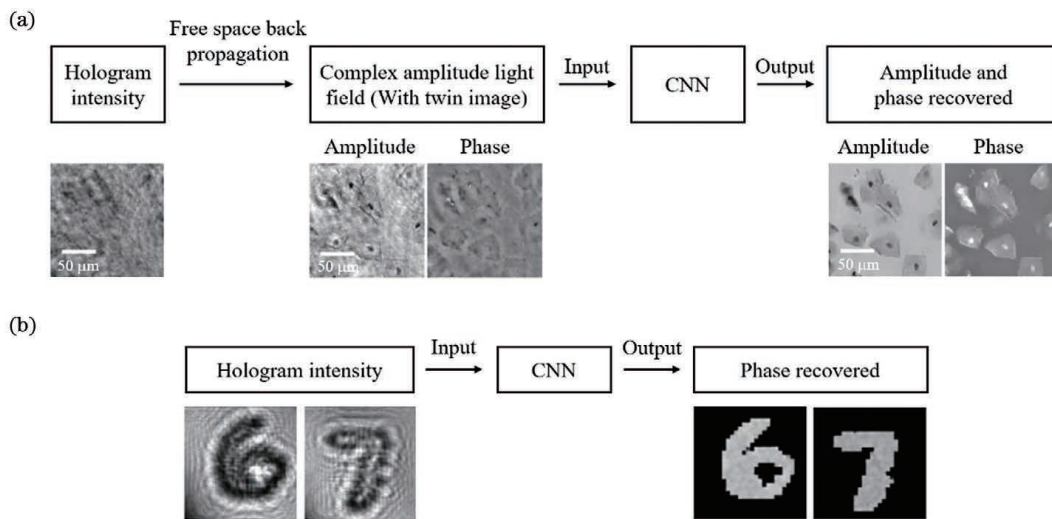


图 7 CNN 应用于同轴全息图数值重建。(a)CNN 用于抑制“孪生像”和自相干伪影^[32]; (b)eHoloNet 实现“端到端”全息相位重建^[33]

Fig. 7 In-line holographic numerical reconstruction with CNN. (a) CNN is used to suppress “twin image” and autocorrelation artifacts^[32]; (b) end-to-end phase reconstruction using eHoloNet^[33]

在离轴全息术中, Zhang 等^[34] 进一步采用 U-net 并在 MSE 损失函数中添加梯度正则化项, 从散焦图直接重建获得在焦重建相位, 简化了重建步骤, 如图 8(a) 所示; Ren 等^[35] 将“端到端”神经网络应用于全息图的数值重建过程, 分别探讨了振幅型和相位型物体形成的数字全息图在不同物参光夹角和轴向距离下的重建效果, 分析论证了网络的泛化能力。Wang 等^[36-37] 更进一步提出如图 8(b) 所示的“Y-net”神经网络, 能够直接从单张全息图同时重建

出振幅和相位信息。之后, 更将 Y-Net 的输出通道增加至四个, 得到“Y4-Net”, 同时实现了双波长数字全息物场的重建, 有效避免双波长信息串扰。在此基础上, 我们进一步将数字全息显微术与 CNN 结合, 设计了一套深度学习显微镜系统, 并成功应用于小鼠成骨细胞的三维测量^[38]。Moon 等^[39] 利用 GAN 实现伽博全息显微系统的无噪声定量相位成像, 不仅能够去除全息图重建过程的噪声, 还可拓展系统的焦深限制。

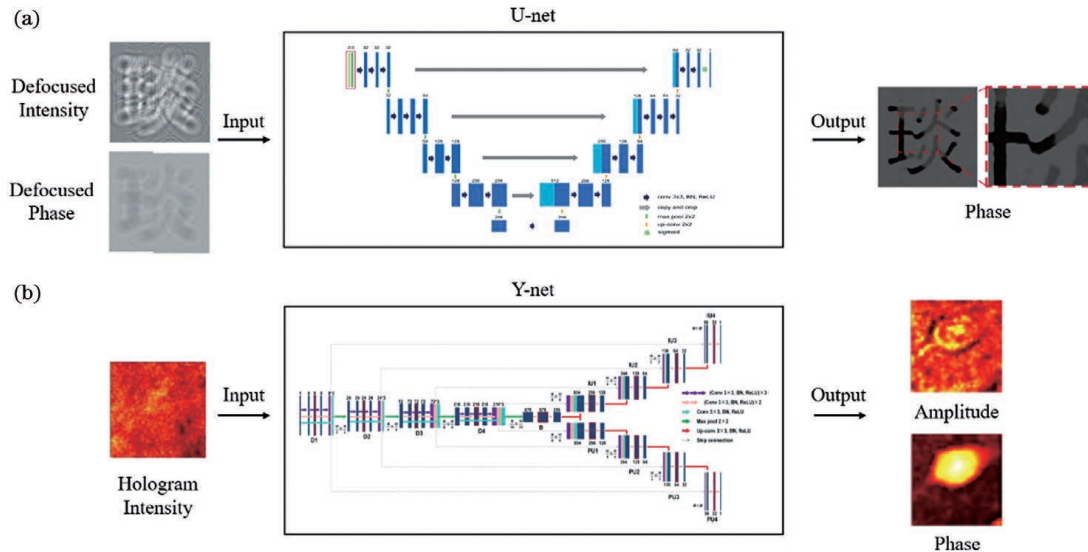


图 8 CNN 应用于离轴全息图数值重建。(a)U-net^[34]; (b)Y-Net^[36]

Fig. 8 Off-axis holographic numerical reconstruction with CNN. (a) U-net^[34]; (b) Y-Net^[36]

全息图数值重建距离的精确估计一直是数字全息术中的核心问题之一。传统解决方法是将全息图预处理后衍射传播至不同重建距离, 并将重建图像的梯度、图像熵等作为判据以获得准确重建距离^[40]或直接计算实现焦深延拓^[41]。但相关方法步骤复杂, 判据的准确性会影响重建距离或使焦深延拓效果并不理想。Pitkäaho 等^[42-44] 率先提出并实验验证了利用深度神经网络解决这一问题的可行性和网络的泛化能力, 随后利用 AlexNet 和 Vggnet 进行回归拟合, 把全息图在不同距离下重建光场的振幅图像作为输入, 对应的离焦距离作为标签, 构建数据集进行网络训练, 如图 9(a) 所示, 最终使重建距离在 20 mm 精度下准确率接近 100%, 10 mm 精度下准确率达到 89%。接着, Ren 等^[45] 进一步分析了不同曝光时间、重建距离、入射角等情形下神经网络的适用性; Jaferzadeh 等^[46] 利用单细胞作为样品进行实验测量, 论证了回归网络模型的可靠性; Son 等^[47] 在相移数字全息系统中采用 FCN 模型实现了重建距离在 50 mm 精度下 95.4% 的准

确率, 且单张图像计算时间不超过 6 ms, 其重建流程如图 9(b) 所示; Wu 等^[48-49] 则并未准确预测重建距离, 而是直接将不同距离下重建的物光场复振幅输入神经网络, 完成训练后网络可直接输出在焦光场分布, 并且具有拓展景深、抑制“孪生像”及伪影等优点。

此外, Xiao 等^[50] 针对离轴全息术中的频谱分离现象, 采取 U-net 实现全息图频谱信息的最优选取和相干噪声抑制; Liu 等^[51] 利用 GAN 网络实现了三个不同波长下全息图的融合, 可在抑制伪影的同时完成高保真彩色图像的重建; Go 等^[52] 则将白光下拍摄的图像通过 GAN 直接转化为对应的全息图, 并进一步实现了数值重建; Wu 等^[53] 通过训练 GAN 使同轴全息再现像与非相干光照明下亮场显微镜图像对比度相当, 并且能够抑制伪影和噪声; Li 等^[54] 利用 GAN 学习单波长下干涉图的转换关系, 仅需单波长下的全息干涉图就可实现双波长相移并恢复相位信息。

由此可见, 有别于传统方法, 深度学习技术的

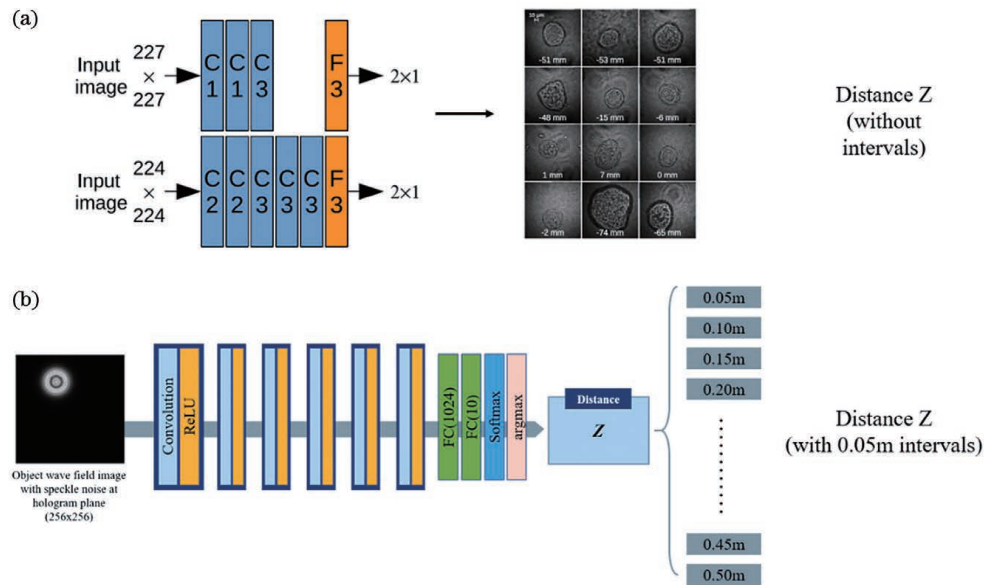


图9 CNN应用于确定全息图重建距离。(a)回归模型^[42-44]；(b)分类模型^[47]

Fig. 9 Applications of CNN in holographic reconstruction distance. (a) Regression model^[42-44] ; (b) classification model^[47]

引入为全息术中孪生像、伪影和噪声等干扰的抑制、重建距离的确定和相位的快速重建等带来了更加便利的解决手段,具备快速计算、高鲁棒性、高准确率等优势。但是深度学习技术在应用中也存在诸多不足。其一是作为一种有监督学习的方式,CNN要求有高质量的样本数据集训练数据,无论是对于同轴全息术还是离轴全息术都需要大量拍摄全息图并完成其数值重建以构建样本数据集,必然增加了实验的复杂性;其二是网络的泛化能力,CNN的泛化能力跟数据集密切相关,对于某一特定样本完成训练后存在网络难以泛化到其他样本的情形。这在一定程度上限制了其进一步的广泛应用。

3.2 条纹分析

条纹投影技术在物体的三维轮廓测量中广泛使用,其主要分为两类:一类使用相移技术采集多张条纹图,然后通过计算提取物体相位信息,称为相移法;另一类从单张条纹图中直接解调相位信息,称为空间相位调制法。相移法拥有更高分辨率和精度,可实现像素级相位测量,但是在不均匀背景强度和较低条纹调制度条件下灵敏度较低且易受外部扰动影响,难以实现实时测量。空间相位调制技术,包括傅里叶变换、窗口傅里叶变换、小波变换、剪切波变换、经验模式分解等^[55-57],仅需单张条纹图就能得到相位信息,与相移法相比在数据采集成本上有较大优势,但其对像素水平的相位值估计不准,易受邻域乃至全局像素影响,且对不连续点和孤立区域的解调能力较低。

基于深度学习技术,Feng等^[58]通过串联两个CNN快速预测反正切函数的分子与分母,从而恢复相位信息,实现了目标边缘的高精度重建,如图10(a)所示;而在图10(b)中,Qian等^[59]进一步发展了彩色编码投影技术,利用多频条纹图和时间相位展开技术,将三个波长下的条纹图分解为三个通道输入网络,预测反正切函数的分子、分母以及绝对相位的粗值,最终实现相位的解调和边缘问题的解决,并将实验误差降到几十微米;Yu等^[60-61]将条纹转换的思想融入CNN中,基于U-net设计了图10(c)所示的FPTNet,将单个或两个正弦条纹图像转化为多张条纹图后实现了动态重建,在避免诱导误差的同时保持了物体边缘的信息。

此外,Kando等^[62]利用U-net完成从干涉条纹图像到相位图像的重建,相比傅里叶变换方法,在对闭合环形条纹的解调问题上具有巨大优势;Li等^[63]提出一种用于干涉条纹检测的CNN模型,其对复杂条纹可实现98%的识别准确率,有利于干涉仪的自动化和精确测量;Yan等^[64]通过仿真的数据集训练条纹去噪CNN网络,并用真实条纹测试了网络的去噪能力,与现有算法相比去噪性能更好且速度更快;Shi等^[65]则基于CNN完成了条纹图的去噪和样本数据增强处理,有效提高了条纹图像质量;Yang等^[66]提出条纹转化网络Tree-Net,可以“端对端”的方式实现三张条纹图的相移转化,仅需三张不同相移的条纹图即可完成六步相移,实验证明该方法可将非线性效应带来的相位误差降低

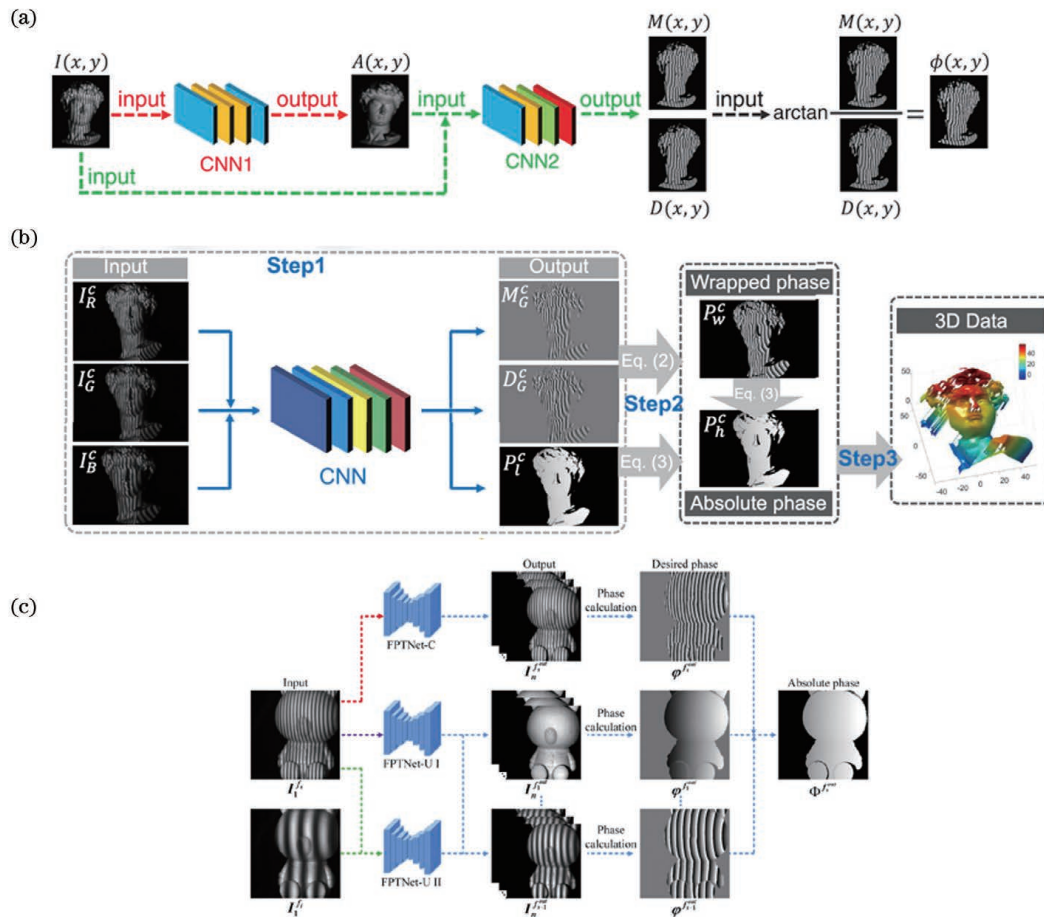


图 10 CNN 应用于条纹分析。(a)文献[58]的方法；(b)文献[59]的方法；(c)文献[60]的方法

Fig. 10 Fringe patterns analysis with CNN. (a) Method in Ref. [58]; (b) method in Ref. [59]; (c) method in Ref. [60]

90%；Nguyen 等^[67]针对三维形貌重建问题，比较了三种 CNN 结构网络在二维散斑图像到三维点云的重建，实验证明 YOLOUNet 具有最好的重建效果。冯世杰等^[68]进一步就深度学习技术在条纹投影三维成像中的应用进行了系统的分析与讨论。

当前，CNN 在包裹相位求解、条纹图像去噪、识别和转化等方面均取得了不错的效果。在 CNN 的辅助下，基于数据驱动的条纹投影技术能有效减少重建过程中需要的条纹图像数量，将空间相位调制法的相位解调精度提升至可与相移法媲美，同时还可抑制成像过程中的噪声干扰。这些优势极大提升了条纹投影技术的效率和精度，使其未来有望应用于运动物体或变化场景的动态测量。然而，数据驱动特性使 CNN 的推演机制、泛化效果、物理解释等难以把握衡量。这意味着除去构建数据集所需的高额成本外，在网络结构优化和训练策略选择方面仍需大量时间去试错。此外，简单粗暴的网络训练往往忽略现实物理规则而去建立映射关系，例如在条纹分析中很少直接采用“端到端”方式直接提取包裹

相位，这是由于 CNN 缺乏对包裹相位跳变性质的认识。

3.3 相位解包裹

相位解包裹技术一直是全息干涉测量^[69]、条纹投影^[70]、合成孔径雷达^[71]等领域的关键技术，主要源于相位计算过程中反三角函数的解处于 $(0, 2\pi]$ 之间。当前经典解包裹算法对于严重噪声、断点和欠采样情况依旧没有很好的解决方案。相位解包裹按工作域可分为空间相位展开^[72-73]和时间相位展开^[74-77]两类。空间相位展开借助格雷码模式或多波长条纹恢复绝对相位，但测量效率较低。时间相位展开则包括路径相关和路径无关两类。路径相关法采用质量导向法^[74]、掩模切割法^[75]和最小不连续性^[76]等方式处理积分路径，对理想的包裹相位图具有较好的解包裹效果；路径无关法基于最小二乘法^[77]，通过计算使展开相位的局部导数与包裹相位梯度之间误差最小化，但有时会导致展开的相位过度平滑，且计算量较大。与全息干涉测量技术相比，条纹投影技术中的相位解包裹问题更具挑战性。一

是因为投影仪和相机的相对位置使得条纹通常向一个方向缠绕而更难标记;二是由于完成高分辨率大范围三维成像需要多组测量结果组合,使准确的相位解包裹更加困难^[78]。

借鉴 CNN 在图像领域的相关发展经验,如图 11(a)所示,Wang 等^[79]提出了一种相位型物体数据集生成方法和相位解包裹算法,通过训练后的 U-net 直接对包裹相位进行展开,成功实现了小鼠成骨细胞和动态蜡烛火焰的湍流场的相位解包裹,相比经典算法具有更好的抗噪声和抗混叠性能,同时使用网络中间层可视化方法对神经网络的泛化能力进行了可解释性分析;Zhang 等^[80]使用图 11(b)所示的分割、求和再细化的步骤,利用 CNN 对包裹相位图进行语义分割获得包裹数的相位区域图,再与包裹相位相加得到展开相位粗值,最终经过细化调节得到准确的展开相位,具有优异的抗噪能力;Qin 等^[81]有效融合了 VGG 结构、U-net 结构和 Resnet 结构,提出的 VUR-Net 使包裹相位展开的

准确率和鲁棒性进一步提升。针对条纹投影的相位解包裹问题,Liang 等^[82]同样通过 CNN 标记包裹相位的包裹数,完成条纹投影成像技术中的相位解包裹;Qian 等^[83]则更进一步,在大体积少视角情形下利用单张包裹条纹图实现复杂物体的相位解包裹;图 11(c)中 Yin 等^[84]综合利用空间和时间相位信息,从两个不同频率的包裹相位图中解调恢复绝对相位;Spoorthi 等^[85]提出的 PhaseNet-2.0 通过 MAE、交叉熵和梯度正则化项作为损失函数完成训练,能有效解决路径相关法的噪声问题和路径无关法中的过度平滑化问题,实现任意形状的包裹相位解包裹,并通过全息干涉和条纹投影实验进行了验证。Zhao 等^[86]提出一种基于残差自动编码网络的相位展开方法,采用图 11(b)的思想并结合网络结构和处理过程的优化,最终相位展开的准确率高达 98%,在严重噪声下准确率保持在 96.4%,且处理一张 256×256 像素尺寸图像仅需 26.5 ms。

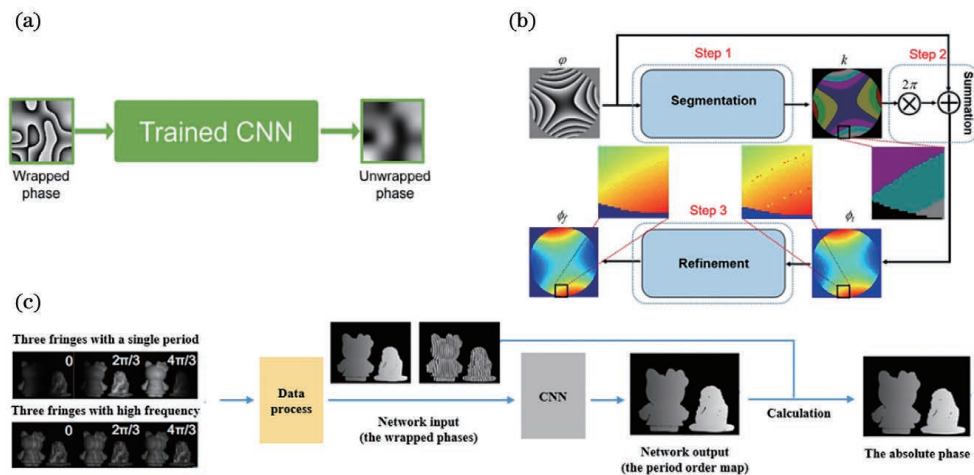


图 11 CNN 应用于相位解包裹。(a)文献[79]的方法;(b)文献[80]的方法;(c)文献[84]的方法

Fig. 11 Phase unwrapping with CNN. (a) Method in Ref. [79]; (b) method in Ref. [80]; (c) method in Ref. [84]

目前,基于 CNN 的相位解包裹方法一方面通过制作足够丰富的数据集以尽可能包含严重噪声、断点和欠采样等极端条件下的包裹相位及其绝对相位;另一方面使用性能优异的神经网络,来充分地学习从包裹相位到绝对相位的映射关系。与传统的相位解包裹算法相比,CNN 方法在多种极端条件下取得了更高的精度和鲁棒性,并在多数样品上具有一定的泛化能力。但是,CNN 方法的泛化能力极大取决于数据集包裹相位的丰富程度,因此在非极端情况下使用传统算法反而更有效率。如何衡量和增强 CNN 方法在不同包裹相位情况下的泛化效果,将是该方法在相位解包裹应用中首要考虑的问题。

3.4 鬼成像

鬼成像,又称关联成像,是一种有别于传统光学成像模式的特殊成像方法,广泛应用于遥感^[87]、太赫兹成像^[88]、荧光成像^[89]和光学加密^[90]等领域。鬼成像系统中往往测试光束直接照射物体后被收集到单像素探测器中进行测量,参考光束自由地传播到高分辨率探测器而不与物体相互作用,之后通过两光束信号之间的相关性完成图像重建。计算鬼成像(CGI)技术仅需测试光束即可完成图像重建,如图 12 所示,使用数字微镜器件对光源进行调制,投射不同散斑光场到待测目标表面,随后通过探测器记录目标调制的光场,利用关联计算恢复待测目标

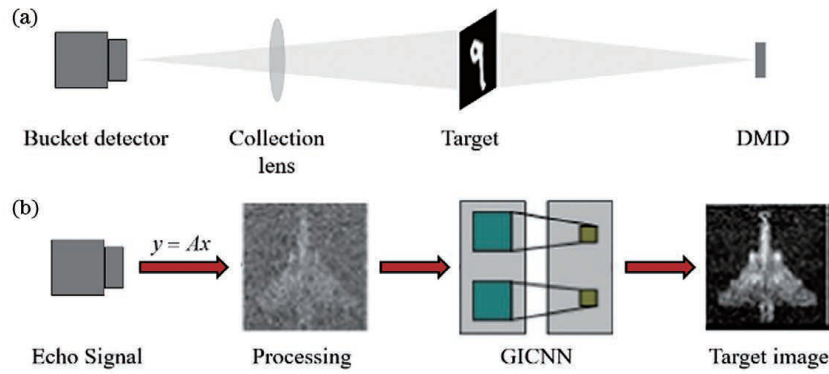


图 12 鬼成像技术。(a)计算鬼成像过程;(b)神经网络用于鬼成像重建

Fig. 12 Ghost imaging technology. (a) Computational ghost imaging process; (b) ghost imaging reconstruction using neural network

的空间信息。为避免噪声干扰,通常需要使用大量随机模式照明,长时间采集数据,并使用归一化方法^[91]、差分方法^[92]以及基于压缩感知的迭代优化方法^[93]等提高成像效率。

深度学习中通过训练建立输入与输出之间映射关系的思想非常适合计算鬼成像技术中根据单像素探测器所采集的光强序列重建目标图像的工作。Shimobaba等^[94]率先使用U-net来降低计算鬼成像重建图像的噪声干扰;Lyu等^[95]通过仿真和实验验证了利用深度神经网络实现计算鬼成像中“端到

端”图像重建的可行性,但其成像目标只局限于手写数字,相对简单;He等^[96]首次在5%~20%采样率下利用CNN实现图像快速重建,单张图像重建时间仅为3ms,并且将重建目标拓展为飞机、人脸等自然图像,增强了实验说服力;Zhai等^[97]将深度学习技术与全变分方法^[98]相结合提出一种基于自适应深度字典学习的全变分最小化算法完成计算鬼成像图像重建,有效提高了重建图像的信噪比;Bian等^[99]提出了如图13(a)所示的双残差U型网络DRU-Net,在预处理阶段采用批量化方法生成了不

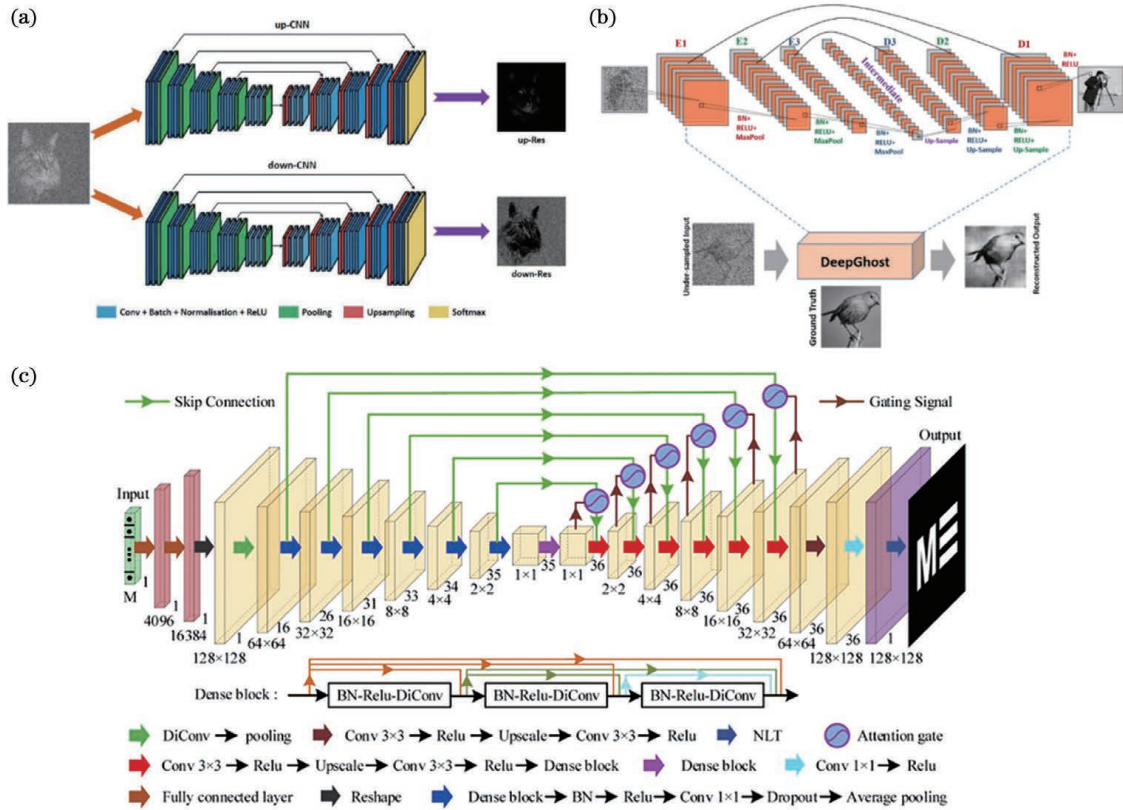


图 13 CNN 应用于计算鬼成像。(a)DRU-Net^[99]; (b)DeepGhost^[101]; (c)DAttNet^[102]

Fig. 13 Computational ghost imaging with CNN. (a) DRU-Net^[99]; (b) DeepGhost^[101]; (c) DAttNet^[102]

同组随机模式,最终在提高图像重建质量的同时极大增强了网络的泛化能力;Li等^[100]搭建偏振鬼成像系统,利用单像素探测器对微弱信号的高灵敏度,并结合偏振方法抑制散射体的直接反射,利用FCN在计算MSE训练网络,最终以“端到端”方式重建透过散射介质的图像,具有快速性、鲁棒性等特点;图13(b)中Rizvi等^[101]针对计算鬼成像图像重建时间长,复杂场景下重建质量低等问题,提出一种快速图像重建框架DeepGhost,在4~5 Hz的帧速率下以80%压缩率实现96×96像素尺寸图像的高质量重建;Wu等^[102-103]提出使用一维光强序列重建目标图像的深度神经网络DAAttNet,如图13(c)所示,能够在低于奈奎斯特采样速率的情况下完成高质量图像重建,可有效避免照明模式带来的时间损失,随后又提出DDANet在重建目标图像的同时能够有效抑制噪声。Wang等^[104]使用仿真数据训练“端到端”网络,实验中无需光照模式序列即可从一维桶探测器信号重建出二维图像。Hu等^[105]利用CNN完成图像去噪,在利用关联鬼成像技术完成图像重构,实现了移动目标的低采样图像重建。黄威等^[106]根据鬼成像的发展历程,全面介绍了鬼成像技术各个方面的应用进展,其中与CNN相结合已成为近年来的研究热点。

目前,基于CNN的鬼成像技术在图像盲重建、低采样成像、照明模式优化等方面取得了新突破,使得数据采集效率提高,重建耗时降低,重建质量提升。但是,当前的相关应用大都局限于光强信号维度。相信基于CNN强大的特征提取和转化能力,结合相位、偏振、光谱等多维度信息的鬼成像技术能够进一步发挥其高信噪比、宽谱成像、散射抑制、低成本等众多优势。

3.5 傅里叶叠层成像

显微成像过程中,透镜的数值孔径会限制成像系统的空间带宽积,而采用高数值孔径物镜又必定会牺牲视场。傅里叶叠层显微成像技术(FPM)^[107]能够利用光学信息处理手段同时实现高分辨率和大视场成像,近年来获得快速发展。如图14所示,FPM通过控制发光二极管(LED)阵列光源点亮顺序,获得不同照射角度下的一组低分辨率强度图像,再通过相位恢复、傅里叶变换、频谱拼接等操作,最终重建获得大视场高分辨率图像。不过,该方法采集图像时间较长,重建算法复杂耗时,计算成本较高。后续出现多种改进方案,如通过优化照明结构或照明方式降低时间成本,改进重构算法提高重构




图14 傅里叶叠层显微系统^[116]

Fig. 14 Fourier ptychographic microscopy system^[116]

效率,或者优化系统像差、强度噪声和LED位置偏差等影响因素以降低对重建像质量的干扰等^[108-111]。

利用深度学习技术可以优化重建算法。Jiang等^[112]在对FPM成像过程建模基础上,从理论和实验方面证实了CNN用于FPM逆向重建的可行性;Nguyen等^[113]通过对大细胞群目标进行单帧成像,利用GAN并在训练中添加正则化进行FPM重建,仅25 s就可实现12800×10800像素相位图像重建,时间仅为传统方法的1/50,并可同时抑制重建噪声和伪影;Zhang等^[114]结合多尺度特征融合和残差结构,提出基于U-net结构的FPNN在模拟数据上完成训练,并成功迁移至实验数据,对重建过程的噪声和模糊等具有一定的鲁棒性。因此,利用CNN实现FPM高分辨图像重构是可行的,但相关应用中照明方式优化、系统像差、光源位置偏差等对CNN的影响仍需深入研究。在图15(a)中,Cheng等^[115]提出联合优化LED阵列照明模式和神经网络的参数,由单张低分辨率强度图像重建出高分辨率复振幅光场,采集时间缩短为1/69,且具有一定的抗噪能力;图15(b)中Sun等^[116]结合FPM实际成像过程,针对重建过程中难以避免的系统像差问题进行神经网络设计和训练,最终成功实现无像差高分辨率图像的重建和系统光瞳函数估计;图15(c)中Zhang等^[117]针对FPM中的位置配准问题,提出一种位置偏差校正网络FNN-CP,可同时补偿LED阵列的全局位置偏差以及系统像差,优化了重建效果。

目前,将CNN应用于FPM带来的主要优势是在降低数据采集量的同时提高图像重建效率,且对于系统像差和噪声等有一定的抑制,可大大节约实验成本。但是如何将CNN与FPM深度融合,有效平衡物镜数值孔径等系统参数与网络深度的

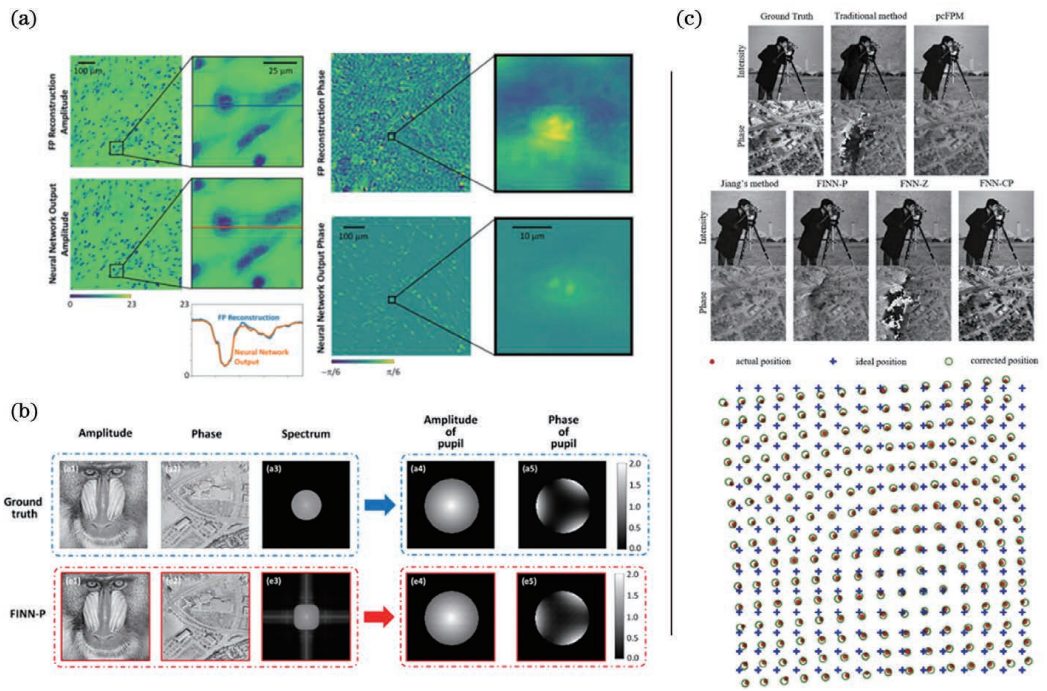


图 15 CNN 应用于傅里叶叠层成像。(a)复振幅光场超分辨重建^[115]；(b)无像差高分辨图像重建及光瞳函数估计^[116]；
(c)LED 阵列位置偏差校正优化重建质量^[117]

Fig. 15 Applications of CNN in Fourier ptychographic microscopy. (a) Super-resolution reconstruction of complex amplitude lightfield^[115]; (b) aberration-free high resolution image reconstruction with pupil function estimation^[116]; (c) LED array position deviation correction to optimize reconstruction quality^[117]

关系,甚至于开发基于 CNN 的智能傅里叶叠层成像显微镜以实现样本的高分辨动态实时成像仍是一个巨大的挑战。

3.6 超分辨显微成像

光学显微镜可以通过使用油浸物镜或者更换大倍率物镜等方式增大系统数值孔径,改善其空间分辨率,但这会导致成像视场和景深减小,系统结构复杂,成本增加。可以利用多图像或单图像重建算法等超分辨率算法,从低分辨率图像中重建高分辨率图像。多图像重建算法通过对多张低分辨率图像配准、插值、去模糊等实现高分辨率图像重建^[118],但需采集多张图像,步骤复杂,误差较大,无法满足成像系统的实时性需求。单图像重建算法在数值采样时使用先验信息从单张低分辨率图像中重建高分辨率图像,因为需要先验信息,重建效果并不理想,限制了这种方法在显微成像上的应用^[119]。

近年来,研究人员将深度学习技术引入超分辨成像领域,尝试使用预训练神经网络直接获得高分辨率图像。Heinrich 等^[120]利用电子显微图像数据对三维 U 型 CNN 进行训练,建立了低分辨率图像到超分辨率图像的映射,网络重建结果的峰值信噪比(PSNR)达到 36.27 dB;Rivenson 等^[121]使用不同

倍率物镜拍摄样品并构建图像训练数据集,完成训练后的 CNN 能够显著提高显微系统在较大视野和景深范围内的空间分辨率;Nehme 等^[122]则从数值仿真和实验两个方面验证了神经网络在荧光显微镜下的超分辨率成像能力;Byeon 等^[123]实现了基于深度学习的全息图超分辨率成像,有效克服高分辨率和大视场之间的矛盾,其全息再现像的 PSNR 达到 37.47 dB;图 16(a)中 Wang 等^[124]利用 GAN 拟合不同模态和数值孔径的显微图像之间的统计关系,实现了显微镜的跨模态与超分辨成像;Liu 等^[125]利用 GAN 实现相干成像系统的超分辨率成像,利用网络获得的图像结构相似度(SSIM)达到 0.9422,在突破数值孔径限制的同时可实现快速超分辨图像重建;Huang 等^[126]利用现有的光学层析数据,数值构建噪声和超分辨率数据集以训练 GAN,同时实现超分辨和去噪,PSNR 达 28.12 dB;图 16(b)中 Luo 等^[127]以“端到端”方式输出高分辨率全息图,打破了无透镜显微成像系统的硬件像元分辨率限制,其重建超分辨率图像的 SSIM 达到 0.977;图 16(c)中 Ren 等^[128]利用 FCN 提高全息图像的条纹分辨率,并实验验证了网络的泛化能力;肖文等^[129]利用注意力网络,提高重建细胞相位的分辨率,其 SSIM 达

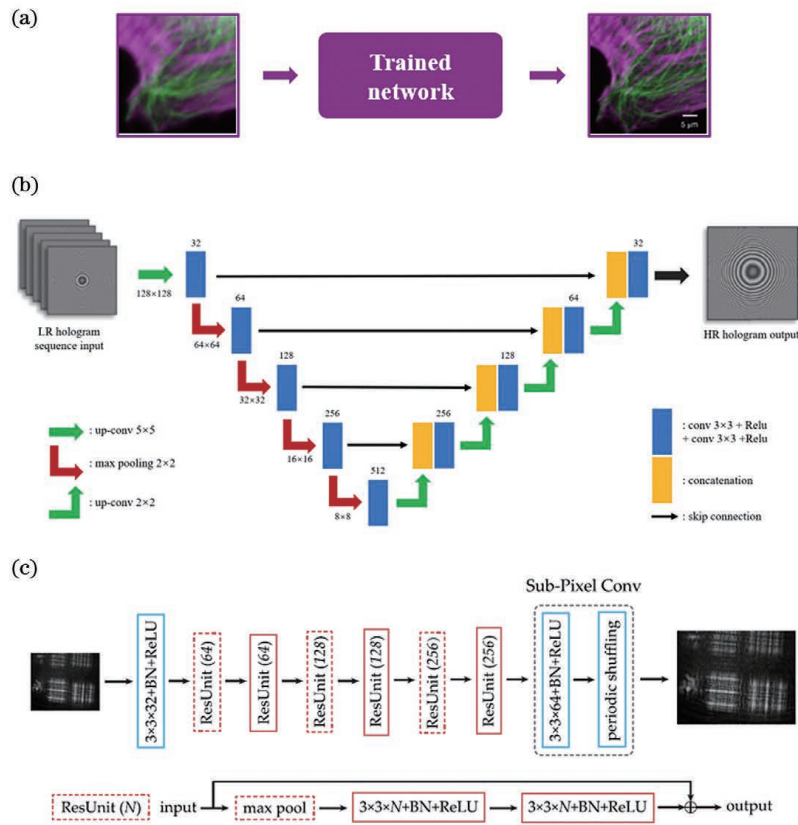


图 16 CNN 应用于超分辨成像。(a)GAN 实现跨模态与超分辨成像^[124]；(b)“端到端”无透镜显微超分辨成像^[127]；
(c)全息图超分辨优化^[128]

Fig. 16 Applications of CNN in super-resolution imaging. (a)Cross modal and super-resolution imaging with GAN^[124]；
(b) end-to-end lensless microscopic super-resolution imaging^[127]；(c) hologram super-resolution optimization^[128]

到 0.9703；Jin 等^[130]结合 CNN 和结构光照明显微技术，将数据采集量降低至原来的 20%，并实验完成了活细胞的多色超分辨显微成像。Qiao 等^[131]提出基于特征频谱信息的深度学习超分辨率重建方法，利用频谱注意力机制构建 CNN 实现了从单张低分辨率图像重建高分辨率的结构光图像。

在当前 CNN 应用于超分辨成像中，目前所做的工作更偏向于图像层面，如 Rivenson 等^[121]通过建立低分辨率图像和高分辨率图像数据集并完成网络训练，赋予了网络“预测”能力，使其可以从一张与训练数据集类似的低分辨率图像中推测获得高分辨率图像，而在此过程中系统的空间带宽积并没有增加。而 Qiao 等^[131]是通过频谱注意力来增加信息利用率，从而实现图像分辨率增强。如何从光学信息处理的角度基于 CNN 来实现超分辨成像，有效拓宽系统空间带宽积，使物体上更多的信息能够被探测器接收，并将神经网络设计与光学成像系统设计深入结合，尽可能全面、高效、快速的恢复物体信息，还有待于进一步深入研究。

3.7 散射介质成像

散射介质成像是近年来的热门研究领域之一^[132-133]。尤其是对于强散射介质，由于介质内部折射率差异较大且分布不均匀，光波会经历多次未知散射而导致信息混乱，无法直接进行观测和成像。由于光的散射特性具有确定性，可通过一定的技术手段，如波前整形或者散斑相关等实现光经过散射介质后的成像。波前整形技术需要利用先验信息求解散射介质的光学传递函数，再通过波前整形实现光波传输的控制，包含基于反馈的波前整形^[134]、传输矩阵测量^[135]和光学相位共轭^[136-137]等方法。然而，波前整形法存在部分缺点，如基于反馈的波前整形技术对散射光场的控制具有位置依赖性，而传输矩阵和光学相位共轭技术要求必须准确实现系统的光学响应特性测量。散斑相关技术利用散射介质的光学记忆效应^[138]，对散斑图进行相关运算并借助相位恢复算法实现散射成像，不过对大目标和厚散射介质难以发挥作用。早在 1967 年，作为强散射介质多模光纤首次被用于图像传输研究^[139]。1991 年，浅层人工神经网络被用来恢复经多模光纤传输

后的图像,但囿于当时神经网络节点数的限制,最终仅能识别不到10幅图像^[140]。2020年,孟球等^[141]对基于深度学习的多模光纤散射介质成像重建技术作了系统的比较分析。

当前,神经网络在散射介质中的应用主要分为两大类:目标分类和目标重建。2015年,Ando等^[142]利用SVM对人脸和非人脸图像通过散射介质后对应的散斑图像进行分类;图17(a)中Satat

等^[143]通过合成数据训练的网络能够有效适用于散斑场的分类问题;Wang等^[144]通过结合CNN和SVM将人脸和非人脸图像对应的散斑图案的分类精度从89%提升至96%,如图17(b)所示;在存在波长漂移的情况下,Kakkava等^[145]利用神经网络成功将多模光纤的散斑图像进行分类,在100 nm和50 nm波长漂移范围内图像分类准确率超过70%和80%。

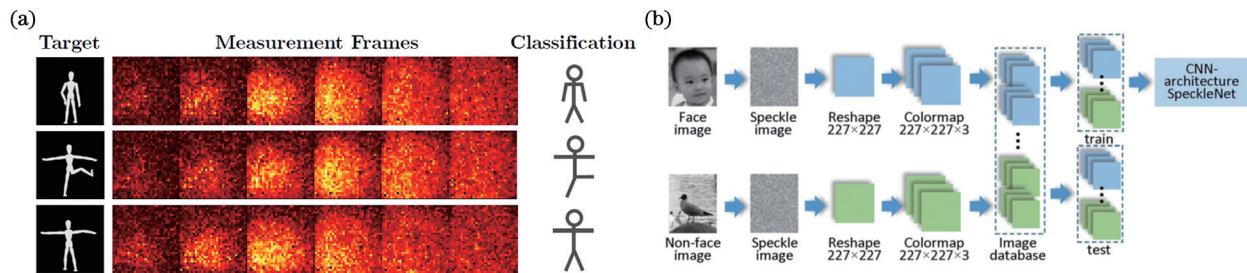


图17 CNN应用于散射介质目标分类。(a)合成数据训练的网络在实验应用中实现准确分类^[143]; (b)人脸和非人脸的散斑图案分类^[144]

Fig. 17 Applications of CNN in scattering medium classification. (a) Network trained by synthetic data achieves classification in experimental application^[143]; (b) speckle pattern classification of face and non-face^[144]

在更具挑战性的目标图像重建问题上, Li等^[146]提出IDiffNet,采用负皮尔逊相关系数作为损失函数有效提高了重建质量; Borhani等^[147]将深度学习应用于多模光纤成像问题上,如图18(a)所示通过训练的CNN成功从1 km光纤传输生成的散

斑场中恢复出手写数字图像; Rahmani等^[148]通过CNN学习0.75 m的多模光纤中的输入与输出关系,证明了网络的泛化能力,并在实验中利用训练的网络将目标相位进行预先重构,进而输入多模光纤后直接得到目标图像,如图18(b)所示,有效论证了

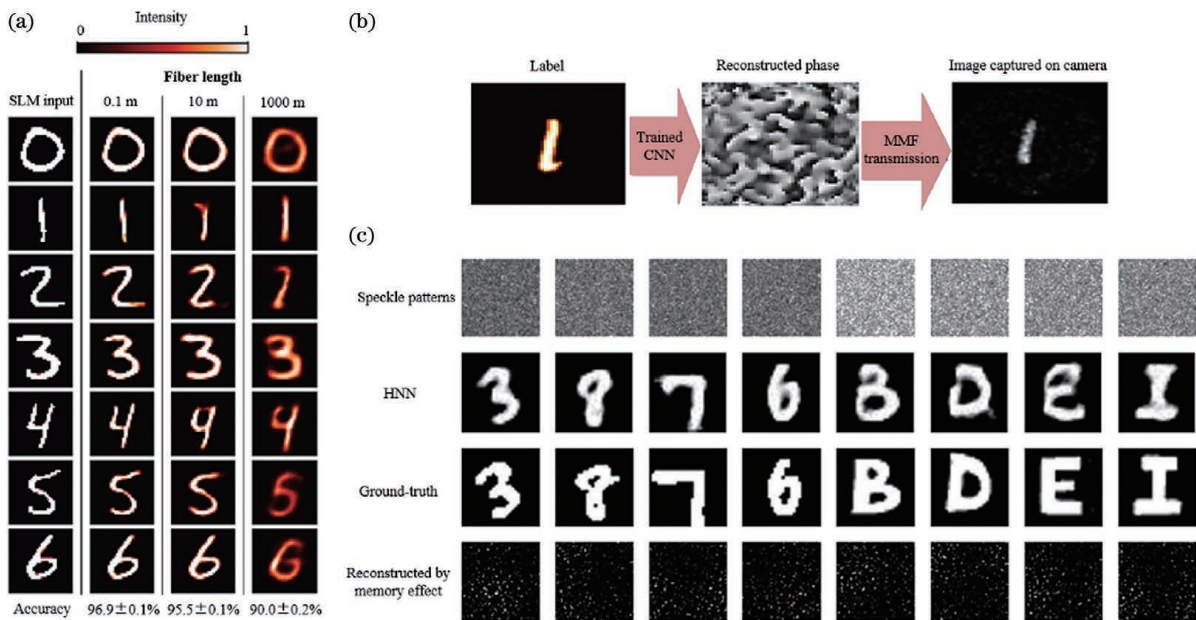


图18 CNN应用于散射介质目标重建。(a)CNN用于光纤后散斑场的数字图像重建^[147]; (b)CNN用于预先重构相位^[148]; (c)CNN用于强散射介质下的图像重建^[150]

Fig. 18 Applications of CNN in scattering medium reconstruction. (a) Image reconstruction of speckle field behind optical fiber with CNN^[147]; (b) CNN is used to pre-reconstruct the phase^[148]; (c) CNN for image reconstruction in strong scattering media^[150]

网络建立的映射关系符合多模光纤的传输过程;Li等^[149]将密集连接结构加入U-net,并利用平均交叉熵作为损失函数训练网络进行二值图像的散斑重建,训练后的CNN可适用于迁移至同类别下其他不同的散射介质重建成像;图18(c)中Lyu等^[150]利用混合神经网络(HNN)进行无记忆效应强散射介质情况下手写数字图像的重建,仅使用散斑图像0.1%的信息即可完成图像重建;Kürüm等^[151]以多芯多模光纤阵列作为随机散射介质,利用网络实现了高光谱信息的快速解调和实时恢复,同时证明了网络对附加噪声和空间偏移的鲁棒性。Li等^[152]将目标放置在两个强散射介质之间,并用U-net完成了图像快速重建;Zhang等^[153]利用CNN实现传统方法重建图像的去噪和超分辨,有效提高其重建质量。此外,An等^[154]通过模拟数据训练CNN以实现多模光纤的实时模态分解,并迁移学习至实验数据,实验测试过程中重构模式与测量模式的平均相关系数超过0.8896,三模态情况下分解速率逼近相机的最大帧率30 Hz。

与传统散射介质成像方法相比,CNN方法具有不可比拟的优势,如相比于波前整形法CNN方法仅需探测强度即可实现聚焦、成像,相比于散斑相关法CNN方法可实现强散射介质成像。不过,类似于传统方法,当介质的散射特性发生变化,如多模光纤抖动等,CNN的成像效果同样会急剧下降。CNN目前尚难以随散射场变化实现在线学习,完成网络参数的自我更新。

3.8 光学层析成像

光学相干层析(OCT)技术基于弱相干光干涉原理,利用待测样品的反射/散射光与参考光发生干涉记录信息,再结合光外差探测技术,可实现微米尺度的一维深度、二维截面和三维立体结构的扫描成像,在眼部医学、口腔医学、皮肤医学和心血管医学等领域获得广泛应用^[155]。虽然OCT技术能够对眼部脉络膜等组织进行精准成像,但却难以将其分割显示,而基于人工的注释标注方法耗时且可靠性低。Kugelmann等^[156]结合神经网络对OCT图像的脉络膜进行分割,研究了网络体系结构、图像预处理方式等因素对分割结果的影响;Wang等^[157]提出一种利用双神经网络CNN-M和CNN-V实现脉络膜识别和分割的算法,流程如图19所示,其中CNN-M根据输入数据判定脉络膜是否存在,若存在则输出其位置的掩模图像并使用CNN-V进一步分割。Fang等^[158]提出一种结合CNN和图像搜索的新型




图19 采用CNN进行脉络膜准确分割^[157]

Fig. 19 Accurate choroidal segmentation using CNN^[157]

框架,通过CNN提取层边界的特征并利用图像搜索算法实现视网膜的九层边界分割,并用医学人眼数据进行了效果验证;Park等^[159]在角膜移植机器人系统中结合深度学习技术以完成快速实时的图像分割和校正任务,实现了“初步进针——OCT成像——分割校正——调整进针”的闭环流程并在猪角膜上进行了实验验证;Gao等^[160]提出基于深度学习的高分辨血管造影重建网络HARNet,用于实现6 mm×6 mm的OCT血管造影图像的信噪比增强、去伪影等高分辨图像重构,改进了生物标记测量和辅助临床评估方法。

光学衍射层析(ODT)技术是一种基于傅里叶衍射定理的三维定量相位成像技术,通过测量不同视角下待测目标的投影平面光场,利用算法重构出目标内部三维结构信息。目标重构过程是病态的逆问题求解过程,滤波反投影(FBP)、代数重建技术(ART)及其改进版本等常被用于层析重建^[161-163]。而在有限稀疏角度条件下,上述方法的重建效果会受到严重影响,往往通过插值和空间变换等方法恢复投影数据并进行重建或在重建过程中添加约束条件以提高重建效果,不过这些方法面临计算过程复杂、计算成本高等问题。Choi等^[164]受GAN结构启发,利用神经网络学习两个“不成对”的数据集之间的统计变换关系,在无任何先验信息条件下有效解决了ODT技术中的相干噪声抑制问题;Ryu等^[165]则采用分类网络提前筛选出含有噪声的投影光场数据,从而避免噪声影响;图20(a)中Yang等^[166]结合物理模型,利用RytovCNN进行投影数据的反演重建,获得较传统FBP和ART类算法更高的重建精度;Di等^[167]利用CNN完成了极稀疏角度下的光子晶体光纤内部折射率结构的三维重建,结果如

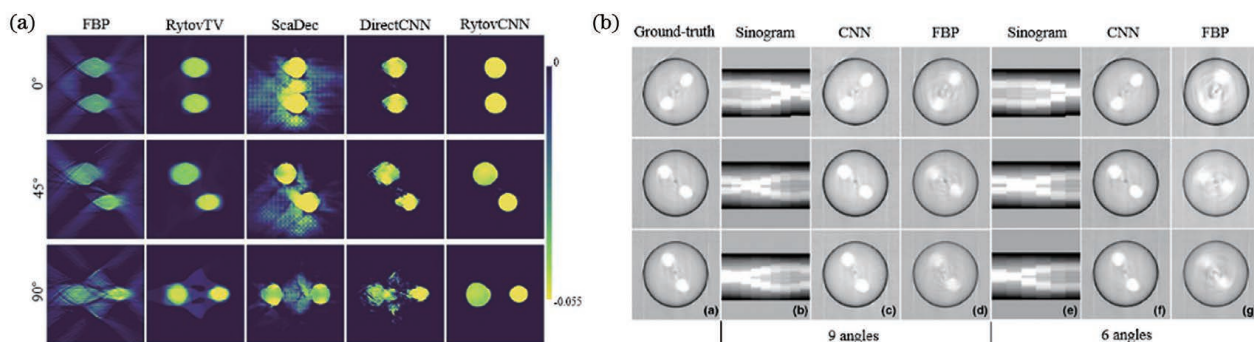


图 20 CNN 应用于光学衍射层析下的光纤重建。(a)受限角度下光纤内部结构重建^[166]；(b)极稀疏角度下光子晶体光纤内部结构重建^[167]

Fig. 20 Optical fiber reconstruction in optical diffraction tomography using CNN. (a) Internal structure reconstruction of optical fiber with limited angle^[166] ; (b) internal structure reconstruction of photonic crystal fiber with sparse angle^[167]

图 20(b)所示。针对 ODT 这一病态逆问题求解过程,有限稀疏角度条件下数据冗余度急剧降低,需要进一步通过与衍射层析物理过程和传统算法相结合,对 CNN 增加约束和网络结构优化,以实现高分辨率重建。

4 结束语

本文总结了 CNN 在数字全息术、相位解包裹等领域中的应用。此外, CNN 还在合成孔径成像^[168-169]、定量相位成像^[170]、系统像差补偿^[171]、粒子场测量^[172-173]、无透镜成像^[174-175]、相干合成^[176]等方面有所应用。按照应用领域、网络结构、损失函数

和所解决问题的不同,表 1 给出了 CNN 的使用情况统计结果,表中加粗字体表示常用结构。由表 1 可见,U-net 结构和 MSE 损失函数在各种使用场景中占了较大比重。如前所述,针对图像等相关问题,由于 CNN 中卷积运算可针对图像进行有效快速的特征提取,是其在信息光学领域广泛应用的基础。U-net 网络所包含的上采样层、下采样层、跳跃连接层等隐藏层,为特征提取和“端到端”物理过程中隐藏映射关系重建过程节省了大量计算资源和时间成本。MSE 损失函数相较于 MAE 有更好的稳定性和对异常数据的鲁棒性,再加上其计算公式简单且适用于多种模型,因此获得广泛应用。

表 1 CNN 在光学信息处理中的应用特点统计

Table 1 Applications of CNN in optical information processing

Application field	Network structure	Loss function	Application problems
Digital holography	Backbone, U-net, GAN	MSE, MAE, cross entropy	Holographic reconstruction ^[30-39] : “twin-image” problem, “end to end” phase recovery, reconstruction of complex amplitude light field Auto focusing ^[42-49] : prediction of holographic reconstruction distance Others ^[50-54] : holographic image denoising, multi wavelength hologram fusion and reconstruction, reconstructed image enhancement
Fringe analysis	Backbone, FCN, U-net	MSE, MAE, regularization	Phase demodulation and 3D reconstruction ^[58-62,67] Fast recognition of fringes ^[63] Fringe image denoising ^[64-66]
Phase unwrapping	FCN, U-net, GAN	MSE, MAE, cross entropy, regularization	Phase unwrapping ^[79-86]

续表

Application field	Network structure	Loss function	Application problems
Ghost imaging	Backbone, FCN, U-net , GAN	MSE , regularization	Noise suppression ^[94] Blind image reconstruction ^[95,97] Low sampling imaging ^[96,101-103,105] Lighting mode optimization ^[98,102-104]
Fourier ptychographic microscopy	U-net , GAN	MSE , MAE, regularization	Super resolution image reconstruction ^[112-113,115-116] Speed up reconstruction ^[113,115] Position deviation correction ^[117] Noise suppression ^[113-115]
Super resolution imaging	FCN, U-net , GAN	MSE , MAE, regularization	Super resolution imaging ^[120-131]
Scattering medium imaging	Backbone , U-net	MSE , MAE, cross entropy	Target classification ^[142-145] Image reconstruction ^[146-153] Modal decomposition of multimode fiber ^[154]
Optical tomography	Backbone, U-net , GAN	MSE , cross entropy, regularization	Coherence tomography ^[156-160] : high precision and fast image segmentation, image enhancement Diffraction tomography ^[164-167] : noise suppression, Inversion reconstruction

目前, CNN 应用于光学信息处理尚有许多问题亟待解决:

1) 由万能近似定理, 足够大的单层前馈网络即足以表示任何函数, 实现“端到端”的任意非线性映射关系表示, 但在实际问题中单层网络可能大到不可实现, 并且无法正确学习和泛化。使用更深的模型可以减少表示期望函数所需的单元数量, 同时减少泛化误差。CNN 具有稀疏连接、参数共享和平移不变等特性, 因此在处理图像等任务时获得广泛应用。然而, 即使是对于 CNN 而言, 应该如何确定网络的深度和层宽, 以及单元之间如何连接, 并无固定规则。更深层网络尽管在每一层使用更少的单元数和更少的参数, 但是也更难以优化。对于不同的神经网络架构, 其输入响应特性也不同。所以, 应该针对具体的光学信息处理任务来进行网络结构设计, 由物理模型来驱动深度学习。

2) 根据训练数据集特性, 可以训练神经网络建立起“输入”和“输出”之间任意复杂的非线性映射关系, 获得“数学”上的最优解, 但是这一结果可能会与真实的物理参数不一致, 并不是“物理”上的最优解。因此, 应该在网络训练过程中实施损失函数的正则化策略, 通过在损失函数中添加与真实物理过程相一致的正则化项, 对网络施加约束, 从而获得物理上

的最佳效果。

3) 当前阶段的 CNN 属于有监督学习的训练方式, 意味着需要有大量的经过标注的数据来用于训练。而对于信息光学中不同应用领域而言, 大量数据的获取及其后期标注均需要付出许多时间和人工成本。尽管数值仿真及模拟可以成为训练数据集构建的重要手段, 但仿真数据往往与真实数据存在偏差, 会导致 CNN 网络在面对真实实验数据时的表现急剧下降。同时, 网络的泛化能力极大地依赖于训练数据集的内容丰富性。构建足够丰富的、覆盖各种情况且标注准确的训练数据集, 是使用神经网络时必须考虑的首要问题。当成像系统、应用场景等发生变化时, 往往代表着物理过程发生了变化, 而针对初始物理过程预训练完成的网络常常无法继续发挥作用。CNN 有监督学习的形式决定了神经网络不能根据动态变化的数据进行在线智能学习。不过, Wang 等^[177]最近提出了一种无监督训练的深度学习方法并成功地从衍射图像中提取获得相位信息。不同于以往需要提前获取大量样本的相位信息作为标签对 CNN 进行有监督训练, 该方法中将 U-net 的输出再次进行相同过程的衍射, 并将其与输入网络的衍射图进行比较作为损失函数来优化网络, 最终实现 CNN 的无监督样品相位信息提取。

不过,该方法要求能够对物理过程准确模拟,使用中计算耗时较多且无泛化能力,仍有待进一步改进。

4) 网络的可解释性问题仍未得到解决。神经网络能够拟合隐藏映射关系以解决正向或逆向的物理问题,但其中所建立的是何种关系,为何建立这种映射关系以及如何解释其物理机制却是基于数据驱动的算法当前面临的最大的问题。

当前,深度学习技术快速发展,已经成为科研中的基本工具之一并获得广泛使用。虽然深度神经网络的优越性不断展现,但其距离成熟尚有很长的一段距离。随着研究的不断深入,人们会对神经网络的理解越来越深,但对于真实物理过程和深度神经网络相匹配的深层次机制尚未了解。面对深度学习与光学信息处理结合过程中的各种问题,如何更好地把握神经网络的特性,深入挖掘其与光学信息处理的结合点,更好地将该技术应用于解决实际问题,将是未来研究的趋势。

参 考 文 献

- [1] Hornik K, Stinchcombe M, White H. Multilayer feedforward networks are universal approximators [J]. *Neural Networks*, 1989, 2(5): 359-366.
- [2] Gardner M W, Dorling S R. Artificial neural networks (the multilayer perceptron): a review of applications in the atmospheric sciences[J]. *Atmospheric Environment*, 1998, 32(14/15): 2627-2636.
- [3] Cortes C, Vapnik V. Support-vector networks [J]. *Machine Learning*, 1995, 20(3): 273-297.
- [4] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks [J]. *Science*, 2006, 313(5786): 504-507.
- [5] Goodfellow I, Bengio Y, Courville A, et al. *Deep learning*[M]. Cambridge: MIT press, 2016.
- [6] LeCun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition [J]. *Proceedings of the IEEE*, 1998, 86(11): 2278-2324.
- [7] Schuster M, Paliwal K K. Bidirectional recurrent neural networks [J]. *IEEE Transactions on Signal Processing*, 1997, 45(11): 2673-2681.
- [8] Hinton G E, Osindero S, Teh Y W. A fast learning algorithm for deep belief nets[J]. *Neural Computation*, 2006, 18(7): 1527-1554.
- [9] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[J]. *Communications of the ACM*, 2020, 63(11): 139-144.
- [10] 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.
- [11] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions [C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 1-9.
- [12] Mirza A H, Cosan S. Computer network intrusion detection using sequential LSTM neural networks autoencoders[C] // 2018 26th Signal Processing and Communications Applications Conference (SIU), May 2-5, 2018, Izmir, Turkey. New York: IEEE Press, 2018: 1-4.
- [13] Karpathy A, Li F F. Deep visual-semantic alignments for generating image descriptions [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(4): 664-676.
- [14] Mikolov T, Karafiát M, Burget L, et al. Recurrent neural network based language model [C] // Eleventh annual conference of the international speech communication association, September 26-30, 2010, Makuhari, Chiba, Japan. Sydney: ISCA, 2010: 1045-1048.
- [15] Zhou H Q, Huang L L, Wang Y T. Deep learning algorithm and its application in optics [J]. *Infrared and Laser Engineering*, 2019, 48(12): 1226004.
周宏强, 黄玲玲, 王涌天. 深度学习算法及其在光学中的应用 [J]. *红外与激光工程*, 2019, 48(12): 1226004.
- [16] Feng W, Zhao X D, Wu G M, et al. Computational ghost imaging method based on convolutional neural network [J]. *Acta Photonica Sinica*, 2020, 49(6): 0610002.
冯维, 赵晓冬, 吴贵铭, 等. 基于卷积神经网络的计算鬼成像方法研究 [J]. *光子学报*, 2020, 49(6): 0610002.
- [17] 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.
- [18] 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.
- [19] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [EB/OL]. (2014-09-04) [2021-04-20]. <https://arxiv.org/abs/>

- 1409.1556.
- [20] 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. New York: IEEE Press, 2015: 3431-3440.
- [21] 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.
- [22] Mirza M, Osindero S. Conditional generative adversarial nets [EB/OL]. (2014-11-06) [2021-04-20]. <https://arxiv.org/abs/1411.1784>.
- [23] 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.
- [24] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 7132-7141.
- [25] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[M]//Ferrari V, Hebert M, Sminchisescu C, et al. Computer vision-ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11211: 3-19.
- [26] Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 2261-2269.
- [27] Shorten C, Khoshgoftaar T M. A survey on image data augmentation for deep learning [J]. Journal of Big Data, 2019, 6(1): 1-48.
- [28] Gupta D, Jain S, Shaikh F, et al. Transfer learning & the art of using pre-trained models in deep learning [EB/OL]. (2017-06-01) [2021-04-20]. <https://www.analyticsvidhya.com/blog/2017/06/transfer-learning-the-art-of-fine-tuning-a-pre-trained-model/>.
- [29] 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.
- [30] Gerchberg R W. A practical algorithm for the determination of phase from image and diffraction plane pictures[J]. Optik, 1972, 35: 237-246.
- [31] Sinha A, Lee J, Li S, et al. Lensless computational imaging through deep learning [J]. Optica, 2017, 4(9): 1117-1125.
- [32] 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.
- [33] 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.
- [34] 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.
- [35] Ren Z B, Xu Z M, Lam E Y. End-to-end deep learning framework for digital holographic reconstruction[J]. Advanced Photonics, 2019, 1(1): 016004.
- [36] 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.
- [37] 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.
- [38] Di J L, Wu J, Wang K Q, et al. Quantitative phase imaging using deep learning-based holographic microscope [J]. Frontiers in Physics, 2021, 9: 651313.
- [39] Moon I, Jaferzadeh K, Kim Y, et al. Noise-free quantitative phase imaging in Gabor holography with conditional generative adversarial network[J]. Optics Express, 2020, 28(18): 26284-26301.
- [40] Fonseca E S, Fiadeiro P T, Pereira M, et al. Comparative analysis of autofocus functions in digital in-line phase-shifting holography[J]. Applied Optics, 2016, 55(27): 7663-7674.
- [41] Wang L, Zhao J L, Di J L, et al. Fast extended focused imaging in digital holography using a graphics processing unit [J]. Optics Letters, 2011, 36(9): 1620-1622.
- [42] Pitkäaho T, Manninen A, Naughton T J. Performance of autofocus capability of deep convolutional neural networks in digital holographic microscopy [C] // Digital Holography and Three-Dimensional Imaging 2017, May 29-June 1, 2017, JeJu Island, Republic of Korea. Washington, D.C.: OSA, 2017: W2A.5.

- [43] Pitkääho T, Manninen A, Naughton T J. Focus classification in digital holographic microscopy using deep convolutional neural networks [C] // European Conference on Biomedical Optics 2017, June 25-29, 2017, Munich, Germany. Washington, D. C.: OSA, 2017: 104140K.
- [44] Pitkääho 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.
- [45] Ren Z B, Xu Z M, Lam E Y. Learning-based nonparametric autofocusing for digital holography [J]. *Optica*, 2018, 5(4): 337-344.
- [46] 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.
- [47] Son K, Jeong W, Jeon W, et al. Autofocusing algorithm for a digital holographic imaging system using convolutional neural networks [J]. *Japanese Journal of Applied Physics*, 2018, 57(9S1): 09SB02.
- [48] 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.
- [49] Wu Y C, Ray A, Wei Q S, et al. Deep learning enables high-throughput analysis of particle-aggregation-based biosensors imaged using holography [J]. *ACS Photonics*, 2019, 6(2): 294-301.
- [50] 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.
- [51] Liu T, Wei Z, Rivenson Y, et al. Deep learning-based color holographic microscopy [J]. *Journal of Biophotonics*, 2019, 12(11): e201900107.
- [52] Go T, Lee S, You D, et al. Deep learning-based hologram generation using a white light source [J]. *Scientific Reports*, 2020, 10(1): 8977.
- [53] 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.
- [54] Li J S, Zhang Q N, Zhong L Y, et al. Quantitative phase imaging in dual-wavelength interferometry using a single wavelength illumination and deep learning [J]. *Optics Express*, 2020, 28(19): 28140-28153.
- [55] Lei H, Qian K M, Bing P, et al. Comparison of Fourier transform, windowed Fourier transform, and wavelet transform methods for phase extraction from a single fringe pattern in fringe projection profilometry [J]. *Optics and Lasers in Engineering*, 2010, 48(2): 141-148.
- [56] Zhu X J, Chen Z Q, Tang C. Variational image decomposition for automatic background and noise removal of fringe patterns [J]. *Optics Letters*, 2013, 38(3): 275-277.
- [57] Li B Y, Tang C, Zhu X J, et al. Shearlet transform for phase extraction in fringe projection profilometry with edges discontinuity [J]. *Optics and Lasers in Engineering*, 2016, 78: 91-98.
- [58] Feng S J, Chen Q, Gu G H, et al. Fringe pattern analysis using deep learning [J]. *Advanced Photonics*, 2019, 1(2): 025001.
- [59] Qian J M, Feng S J, Li Y X, et al. Single-shot absolute 3D shape measurement with deep-learning-based color fringe projection profilometry [J]. *Optics Letters*, 2020, 45(7): 1842-1845.
- [60] Yu H T, Chen X Y, Zhang Z, et al. Dynamic 3-D measurement based on fringe-to-fringe transformation using deep learning [J]. *Optics Express*, 2020, 28(7): 9405-9418.
- [61] Yu H T, Zheng D L, Fu J A, et al. Deep learning-based fringe modulation-enhancing method for accurate fringe projection profilometry [J]. *Optics Express*, 2020, 28(15): 21692-21703.
- [62] Kando D, Tomioka S, Miyamoto N, et al. Phase extraction from single interferogram including closed-fringe using deep learning [J]. *Applied Sciences*, 2019, 9(17): 3529.
- [63] Li H W, Zhang C X, Song N F, et al. Deep learning-based interference fringes detection using convolutional neural network [J]. *IEEE Photonics Journal*, 2019, 11(4): 1-14.
- [64] Yan K T, Yu Y J, Huang C T, et al. Fringe pattern denoising based on deep learning [J]. *Optics Communications*, 2019, 437: 148-152.
- [65] Shi J S, Zhu X J, Wang H Y, et al. Label enhanced and patch based deep learning for phase retrieval from single frame fringe pattern in fringe projection 3D measurement [J]. *Optics Express*, 2019, 27(20): 28929-28943.
- [66] Yang Y, Hou Q Y, Li Y, et al. Phase error compensation based on Tree-Net using deep learning [J]. *Optics and Lasers in Engineering*, 2021, 143: 106628.
- [67] Nguyen H, Tran T, Wang Y Z, et al. Three-

- dimensional shape reconstruction from single-shot speckle image using deep convolutional neural networks [J]. *Optics and Lasers in Engineering*, 2021, 143: 106639.
- [68] Feng S J, Zuo C, Yin W, et al. Application of deep learning technology to fringe projection 3D imaging [J]. *Infrared and Laser Engineering*, 2020, 49(3): 030301.
冯世杰, 左超, 尹维, 等. 深度学习技术在条纹投影三维成像中的应用 [J]. *红外与激光工程*, 2020, 49(3): 030301.
- [69] Waghmare R G, Sukumar P R, Subrahmanyam G R K S, et al. Particle-filter-based phase estimation in digital holographic interferometry [J]. *Journal of the Optical Society of America. A, Optics, Image Science, and Vision*, 2016, 33(3): 326-332.
- [70] Geng J. Structured-light 3D surface imaging: a tutorial [J]. *Advances in Optics and Photonics*, 2011, 3(2): 128-160.
- [71] Yu H W, Lan Y, Xu J Y, et al. Large-scale L^0 -norm and L^1 -norm 2-D phase unwrapping [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(8): 4712-4728.
- [72] Zheng D L, Da F P, Qian K M, et al. Phase-shifting profilometry combined with Gray-code patterns projection: unwrapping error removal by an adaptive median filter [J]. *Optics Express*, 2017, 25(5): 4700-4713.
- [73] Zheng D, Kemao Q, Da F, et al. Ternary Gray code-based phase unwrapping for 3D measurement using binary patterns with projector defocusing [J]. *Applied Optics*, 2017, 56(13): 3660-3665.
- [74] Su X Y, Chen W J. Reliability-guided phase unwrapping algorithm: a review [J]. *Optics and Lasers in Engineering*, 2004, 42(3): 245-261.
- [75] Herráez M A, Burton D R, Lalor M J, et al. Fast two-dimensional phase-unwrapping algorithm based on sorting by reliability following a noncontinuous path [J]. *Applied Optics*, 2002, 41(35): 7437-7444.
- [76] Flynn T J. Two-dimensional phase unwrapping with minimum weighted discontinuity [J]. *Journal of the Optical Society of America A*, 1997, 14(10): 2692-2701.
- [77] Arines J, Ares J. Linear squares modal estimation of wrapped phases: application to phase unwrapping [J]. *Proceedings of SPIE*, 2003, 4829: 178-179.
- [78] Zhang J C, Tian X B, Shao J B, et al. Phase unwrapping in optical metrology via denoised and convolutional segmentation networks [J]. *Optics Express*, 2019, 27(10): 14903-14912.
- [79] 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.
- [80] Zhang T, Jiang S W, Zhao Z X, et al. Rapid and robust two-dimensional phase unwrapping via deep learning [J]. *Optics Express*, 2019, 27(16): 23173-23185.
- [81] Qin Y, Wan S J, Wan Y H, et al. Direct and accurate phase unwrapping with deep neural network [J]. *Applied Optics*, 2020, 59(24): 7258-7267.
- [82] Liang J, Zhang J C, Shao J B, et al. Deep convolutional neural network phase unwrapping for fringe projection 3D imaging [J]. *Sensors*, 2020, 20(13): 3691.
- [83] Qian J M, Feng S J, Tao T Y, et al. Deep-learning-enabled geometric constraints and phase unwrapping for single-shot absolute 3D shape measurement [J]. *APL Photonics*, 2020, 5(4): 046105.
- [84] Yin W, Chen Q, Feng S, et al. Temporal phase unwrapping using deep learning [J]. *Scientific Reports*, 2019, 9(1): 20175.
- [85] Spoorthi G E, Gorthi R K S S, Gorthi S. PhaseNet 2.0: phase unwrapping of noisy data based on deep learning approach [J]. *IEEE Transactions on Image Processing*, 2020, 29: 4862-4872.
- [86] Zhao Z, Li B, Kang X Q, et al. Phase unwrapping method for point diffraction interferometer based on residual auto encoder neural network [J]. *Optics and Lasers in Engineering*, 2021, 138: 106405.
- [87] Erkmen B I. Computational ghost imaging for remote sensing [J]. *Journal of the Optical Society of America A*, 2012, 29(5): 782-789.
- [88] Shrekenhamer D, Watts C M, Padilla W J. Terahertz single pixel imaging with an optically controlled dynamic spatial light modulator [J]. *Optics Express*, 2013, 21(10): 12507-12518.
- [89] Tanha M, Ahmadi-Kandjani S, Kheradmand R, et al. Computational fluorescence ghost imaging [J]. *The European Physical Journal D*, 2013, 67(2): 44.
- [90] Clemente P, Durán V, Torres-Company V, et al. Optical encryption based on computational ghost imaging [J]. *Optics Letters*, 2010, 35(14): 2391-2393.
- [91] Sun B Q, Welsh S S, Edgar M P, et al. Normalized ghost imaging [J]. *Optics Express*, 2012, 20(15): 16892-16901.
- [92] Ferri F, Magatti D, Lugiato L A, et al. Differential ghost imaging [J]. *Physical Review Letters*, 2010, 104(25): 253603.
- [93] Welsh S S, Edgar M P, Bowman R, et al. Fast full-color computational imaging with single-pixel detectors [J]. *Optics Express*, 2013, 21(20): 23068-

- 23074.
- [94] Shimobaba T, Endo Y, Nishitsuji T, et al. Computational ghost imaging using deep learning[J]. Optics Communications, 2018, 413: 147-151.
- [95] Lyu M, Wang W, Wang H, et al. Deep-learning-based ghost imaging[J]. Scientific Reports, 2017, 7(1): 17865.
- [96] He Y C, Wang G, Dong G X, et al. Ghost imaging based on deep learning[J]. Scientific Reports, 2018, 8(1): 1-7.
- [97] Zhai X, Cheng Z, Liang Z, et al. Computational ghost imaging via adaptive deep dictionary learning [J]. Applied Optics, 2019, 58(31): 8471-8478.
- [98] Li C. An efficient algorithm for total variation regularization with applications to the single pixel camera and compressive sensing[D]. Houston: Rice University, 2010.
- [99] Bian T, Yi Y, Hu J, et al. A residual-based deep learning approach for ghost imaging [J]. Scientific Reports, 2020, 10(1): 12149.
- [100] Li F Q, Zhao M, Tian Z M, et al. Compressive ghost imaging through scattering media with deep learning[J]. Optics Express, 2020, 28(12): 17395-17408.
- [101] Rizvi S, Cao J, Zhang K Y, et al. DeepGhost: real-time computational ghost imaging via deep learning [J]. Scientific Reports, 2020, 10: 11400.
- [102] Wu H, Wang R, Zhao G, et al. Sub-Nyquist computational ghost imaging with deep learning[J]. Optics Express, 2020, 28(3): 3846-3853.
- [103] Wu H, Wang R Z, Zhao G P, et al. Deep-learning denoising computational ghost imaging [J]. Optics and Lasers in Engineering, 2020, 134: 106183.
- [104] Wang F, Wang H, Wang H C, et al. Learning from simulation: an end-to-end deep-learning approach for computational ghost imaging [J]. Optics Express, 2019, 27(18): 25560-25572.
- [105] Hu H K, Sun S, Lin H Z, et al. Denoising ghost imaging under a small sampling rate via deep learning for tracking and imaging moving objects[J]. Optics Express, 2020, 28(25): 37284-37293.
- [106] Huang W, Jiao S M, Xiao C Y. Image processing algorithms related to single-pixel imaging: a review [J]. Laser & Optoelectronics Progress, 2021, 58(10): 1011021.
黄威, 焦述铭, 肖昌炎. 单像素成像相关图像处理算法综述[J]. 激光与光电子学进展, 2021, 58(10): 1011021.
- [107] Zheng G A, Horstmeyer R, Yang C. Wide-field, high-resolution Fourier ptychographic microscopy [J]. Nature Photonics, 2013, 7(9): 739-745.
- [108] Lin Z Q, Ma X, Lin J X, et al. Fourier ptychographic microscopy based on rotating arc-shaped array of LEDs [J]. Laser & Optoelectronics Progress, 2018, 55(7): 071102.
林子强, 马骁, 林锦新, 等. 基于弧形阵列 LED 光源旋转照明装置的傅里叶叠层显微术 [J]. 激光与光电子学进展, 2018, 55(7): 071102.
- [109] Shen C, Chan A C S, Chung J, et al. Computational aberration correction of VIS-NIR multispectral imaging microscopy based on Fourier ptychography [J]. Optics Express, 2019, 27(18): 24923-24937.
- [110] Zuo C, Sun J S, Chen Q. Adaptive step-size strategy for noise-robust Fourier ptychographic microscopy [J]. Optics Express, 2016, 24(18): 20724-20744.
- [111] Zhou A, Wang W, Chen N, et al. Fast and robust misalignment correction of Fourier ptychographic microscopy for full field of view reconstruction [J]. Optics Express, 2018, 26(18): 23661-23674.
- [112] Jiang S W, Guo K K, Liao J, et al. Solving Fourier ptychographic imaging problems via neural network modeling and TensorFlow [J]. Biomedical Optics Express, 2018, 9(7): 3306-3319.
- [113] Nguyen T, Xue Y J, Li Y Z, et al. Deep learning approach for Fourier ptychography microscopy [J]. Optics Express, 2018, 26(20): 26470-26484.
- [114] Zhang J Z, Xu T F, Shen Z Y, et al. Fourier ptychographic microscopy reconstruction with multiscale deep residual network [J]. Optics Express, 2019, 27(6): 8612-8625.
- [115] Cheng Y F, Strachan M, Weiss Z, et al. Illumination pattern design with deep learning for single-shot Fourier ptychographic microscopy [J]. Optics Express, 2019, 27(2): 644-656.
- [116] Sun M L, Chen X, Zhu Y Q, et al. Neural network model combined with pupil recovery for Fourier ptychographic microscopy [J]. Optics Express, 2019, 27(17): 24161-24174.
- [117] Zhang J L, Tao X, Yang L, et al. Forward imaging neural network with correction of positional misalignment for Fourier ptychographic microscopy [J]. Optics Express, 2020, 28(16): 23164-23175.
- [118] Irani M, Peleg S. Improving resolution by image registration [J]. CVGIP: Graphical Models and Image Processing, 1991, 53(3): 231-239.
- [119] Keys R. Cubic convolution interpolation for digital image processing [J]. IEEE Transactions on Acoustics, Speech, and Signal Processing, 1981, 29(6): 1153-1160.
- [120] Heinrich L, Bogovic J A, Saalfeld S. Deep learning for isotropic super-resolution from non-isotropic 3D electron microscopy [M] // Descoteaux M, Maier-Hein

- L, Franz A, et al. Medical image computing and computer-assisted intervention-MICCAI 2017. Lecture notes in computer science. Cham: Springer, 2017, 10434: 135-143.
- [121] Rivenson Y, Göröcs Z, Günaydin H, et al. Deep learning microscopy[J]. *Optica*, 2017, 4(11): 1437-1443.
- [122] Nehme E, Weiss L E, Michaeli T, et al. Deep-STORM: super-resolution single-molecule microscopy by deep learning[J]. *Optica*, 2018, 5(4): 458-464.
- [123] Byeon H, Go T, Lee S J. Deep learning-based digital in-line holographic microscopy for high resolution with extended field of view [J]. *Optics & Laser Technology*, 2019, 113: 77-86.
- [124] 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.
- [125] 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.
- [126] 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.
- [127] Luo Z X, Yurt A, Stahl R, et al. Pixel super-resolution for lens-free holographic microscopy using deep learning neural networks [J]. *Optics Express*, 2019, 27(10): 13581-13595.
- [128] Ren Z B, So H K H, Lam E Y. Fringe pattern improvement and super-resolution using deep learning in digital holography [J]. *IEEE Transactions on Industrial Informatics*, 2019, 15(11): 6179-6186.
- [129] Xiao W, Li J, Pan F, et al. Super-resolution indigital holographic phase cell image based on USENet[J]. *Acta Photonica Sinica*, 2020, 49(6): 0610001. 肖文, 李解, 潘锋, 等. 基于 USENet 实现数字全息细胞再现相位像超分辨重构[J]. *光子学报*, 2020, 49(6): 0610001.
- [130] Jin L H, Liu B, Zhao F Q, et al. Deep learning enables structured illumination microscopy with low light levels and enhanced speed [J]. *Nature Communications*, 2020, 11(1): 1934.
- [131] Qiao C, Li D, Guo Y T, et al. Evaluation and development of deep neural networks for image super-resolution in optical microscopy[J]. *Nature Methods*, 2021, 18(2): 194-202.
- [132] Vellekoop I M, Mosk A P. Focusing coherent light through opaque strongly scattering media[J]. *Optics Letters*, 2007, 32(16): 2309-2311.
- [133] Li X J, Tang W S, Yi W J, et al. Review of optical scattering imaging technology with wide field of view and long distance [J]. *Chinese Journal of Lasers*, 2021, 48(4): 0401012. 李修建, 唐武盛, 衣文军, 等. 宽视场远距离光学散射成像技术研究进展[J]. *中国激光*, 2021, 48(4): 0401012.
- [134] Conkey D B, Caravaca-Aguirre A M, Piestun R. High-speed scattering medium characterization with application to focusing light through turbid media[J]. *Optics Express*, 2012, 20(2): 1733-1740.
- [135] Cui M. A high speed wavefront determination method based on spatial frequency modulations for focusing light through random scattering media[J]. *Optics Express*, 2011, 19(4): 2989-2995.
- [136] Ma C J, Di J L, Zhang Y, et al. Reconstruction of structured laser beams through a multimode fiber based on digital optical phase conjugation[J]. *Optics Letters*, 2018, 43(14): 3333-3336.
- [137] Ma C J, Di J L, Li Y, et al. Rotational scanning and multiple-spot focusing through a multimode fiber based on digital optical phase conjugation[J]. *Applied Physics Express*, 2018, 11(6): 062501.
- [138] Freund I, Rosenbluh M, Feng S C. Memory effects in propagation of optical waves through disordered media[J]. *Physical Review Letters*, 1988, 61(20): 2328-2331.
- [139] Spitz E, Werts A. Transmission des images à travers une fibre optique[J]. *Comptes Rendus Hebdomadaires Des Seances De L Academie Des Sciences Serie B*, 1967, 264(14): 1015.
- [140] Aisawa S, Noguchi K, Matsumoto T. Remote image classification through multimode optical fiber using a neural network [J]. *Optics Letters*, 1991, 16(9): 645-647.
- [141] Meng L, Hu H F, Hu J Z, et al. Image reconstruction of multimode fiber scattering media based on deep learning [J]. *Chinese Journal of Lasers*, 2020, 47(12): 1206005. 孟球, 胡海峰, 胡金洲, 等. 基于深度学习的多模光纤散射介质成像重建[J]. *中国激光*, 2020, 47(12): 1206005.
- [142] Ando T, Horisaki R, Tanida J. Speckle-learning-based object recognition through scattering media[J]. *Optics Express*, 2015, 23(26): 33902-33910.
- [143] Satat G, Tancik M, Gupta O, et al. Object classification through scattering media with deep learning on time resolved measurement [J]. *Optics Express*, 2017, 25(15): 17466-17479.
- [144] Wang P, Di J L. Deep learning-based object classification through multimode fiber via a CNN-

- architecture SpeckleNet[J]. *Applied Optics*, 2018, 57(28): 8258-8263.
- [145] Kakkava E, Borhani N, Rahmani B, et al. Deep learning-based image classification through a multimode fiber in the presence of wavelength drift [J]. *Applied Sciences*, 2020, 10(11): 3816.
- [146] Li S, Deng M, Lee J, et al. Imaging through glass diffusers using densely connected convolutional networks[J]. *Optica*, 2018, 5(7): 803-813.
- [147] Borhani N, Kakkava E, Moser C, et al. Learning to see through multimode fibers[J]. *Optica*, 2018, 5(8): 960-966.
- [148] Rahmani B, Loterie D, Konstantinou G, et al. Multimode optical fiber transmission with a deep learning network[J]. *Light, Science & Applications*, 2018, 7: 69.
- [149] 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.
- [150] Lyu M, Wang H, Li G W, et al. Learning-based lensless imaging through optically thick scattering media [J]. *Advanced Photonics*, 2019, 1(3): 036002.
- [151] Kürüm U, Wiecha P R, French R, et al. Deep learning enabled real time speckle recognition and hyperspectral imaging using a multimode fiber array [J]. *Optics Express*, 2019, 27(15): 20965-20979.
- [152] Li Q Y, Zhao J, Zhang Y Z, et al. Imaging reconstruction through strongly scattering media by using convolutional neural networks [J]. *Optics Communications*, 2020, 477: 126341.
- [153] Zhang W H, Zhou S H, Sui X B, et al. Single image detecting enhancement through scattering media based on transmission matrix with a deep learning network [J]. *Optics Communications*, 2021, 490: 126896.
- [154] An Y, Huang L J, Li J, et al. Deep learning-based real-time mode decomposition for multimode fibers [J]. *IEEE Journal of Selected Topics in Quantum Electronics*, 2020, 26(4): 1-6.
- [155] Lu D X, Fang W H, Li Y Y, et al. Optical coherence tomography: principles and recent developments[J]. *Chinese Optics*, 2020, 13(5): 919-935.
- 陆冬筱, 房文汇, 李玉瑶, 等. 光学相干层析成像技术原理及研究进展 [J]. *中国光学*, 2020, 13(5): 919-935.
- [156] Kugelman J, Alonso-Caneiro D, Read S A, et al. Automatic choroidal segmentation in OCT images using supervised deep learning methods[J]. *Scientific Reports*, 2019, 9: 13298.
- [157] Wang J, Hormel T T, Gao L Q, et al. Automated diagnosis and segmentation of choroidal neovascularization in OCT angiography using deep learning[J]. *Biomedical Optics Express*, 2020, 11(2): 927-944.
- [158] Fang L Y, Cunefare D, Wang C, et al. Automatic segmentation of nine retinal layer boundaries in OCT images of non-exudative AMD patients using deep learning and graph search [J]. *Biomedical Optics Express*, 2017, 8(5): 2732-2744.
- [159] Park I, Kim H K, Chung W K, et al. Deep learning based real-time OCT image segmentation and correction for robotic needle insertion systems [J]. *IEEE Robotics and Automation Letters*, 2020, 5(3): 4517-4524.
- [160] Gao M, Guo Y K, Hormel T T, et al. Reconstruction of high-resolution 6×6 -mm OCT angiograms using deep learning [J]. *Biomedical Optics Express*, 2020, 11(7): 3585-3600.
- [161] Katsevich A. An improved exact filtered backprojection algorithm for spiral computed tomography[J]. *Advances in Applied Mathematics*, 2004, 32(4): 681-697.
- [162] Gordon R, Bender R, Herman G T. Algebraic Reconstruction Techniques (ART) for three-dimensional electron microscopy and X-ray photography [J]. *Journal of Theoretical Biology*, 1970, 29(3): 471-481.
- [163] Lell M M, Kachelrieß M. Recent and upcoming technological developments in computed tomography: high speed, low dose, deep learning, multienergy [J]. *Investigative Radiology*, 2020, 55(1): 8-19.
- [164] 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.
- [165] Ryu D H, Jo Y J, Yoo J, et al. Deep learning-based optical field screening for robust optical diffraction tomography [J]. *Scientific Reports*, 2019, 9(1): 15239.
- [166] Yang F S, Pham T A, Gupta H, et al. Deep-learning projector for optical diffraction tomography [J]. *Optics Express*, 2020, 28(3): 3905-3921.
- [167] Di J L, Han W X, Liu S S, et al. Sparse-view imaging of a fiber internal structure in holographic diffraction tomography via a convolutional neural network [J]. *Applied Optics*, 2021, 60(4): A234-A242.
- [168] Tang J, Wang K Q, Zhang W, et al. Deep learning based image restoration method of optical synthetic

- aperture imaging system [J]. *Acta Optica Sinica*, 2020, 40(21): 2111001.
- 唐唯, 王凯强, 张维, 等. 一种基于深度学习的光学合成孔径成像系统图像复原方法 [J]. *光学学报*, 2020, 40(21): 2111001.
- [169] Tang J, Wang K Q, Ren Z B, et al. RestoreNet: a deep learning framework for image restoration in optical synthetic aperture imaging system [J]. *Optics and Lasers in Engineering*, 2021, 139: 106463.
- [170] Wang K Q, Di J L, Li Y, et al. Transport of intensity equation from a single intensity image via deep learning [J]. *Optics and Lasers in Engineering*, 2020, 134: 106233.
- [171] 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.
- [172] 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.
- [173] Wu Y F, Wu J C, Hao R, et al. Research progress of particle field digital holography based on deep learning [J]. *Journal of Applied Optics*, 2020, 41(4): 662-674.
- 吴羽峰, 吴佳琛, 郝然, 等. 基于深度学习的粒子场数字全息成像研究进展 [J]. *应用光学*, 2020, 41(4): 662-674.
- [174] Zeng T J, Lam E Y. Model-based network architecture for image reconstruction in lensless imaging [J]. *Proceedings of SPIE*, 2020, 11551: 115510B.
- [175] Wu J, Cao L, Barbastathis G. DNN-FZA camera: a deep learning approach toward broadband FZA lensless imaging [J]. *Optics Letters*, 2021, 46(1): 130-133.
- [176] Hou T Y, An Y, Chang Q, et al. Deep-learning-based phase control method for tiled aperture coherent beam combining systems [J]. *High Power Laser Science and Engineering*, 2019, 7: e59.
- [177] Wang F, Bian Y M, Wang H C, et al. Phase imaging with an untrained neural network [J]. *Light, Science & Applications*, 2020, 9: 77.