

基于改进残差 Unet 的数字全息端到端相位重建

李坤格¹, 王华英^{1,2,3}, 柳旭^{1,2,3*}, 王杰宇¹, 王文健¹, 杨柳¹¹河北工程大学数理科学与工程学院, 河北 邯郸 056038;²河北省计算光学成像与光电检测技术创新中心, 河北 邯郸 056038;³河北省计算光学成像与智能感测国际联合研究中心, 河北 邯郸 056038

摘要 数字全息术(DH)是监测透明样品定量三维信息的一种重要技术。然而,常规数字全息重建中需要相位畸变补偿和解包裹,严重影响了相位重建速度和重建精度。提出一种融合空洞卷积和注意力机制的改进残差 Unet 方法,实现了数字全息端到端相位重建,简化成像过程,提高了图像重建质量。此外,该方法还可以通过调整残差块,得到最优的实时重建网络模型。实验结果表明,所提基于深度学习的相位重建方法能够实时获得样品精确的三维形貌信息,有利于对动态样品进行实时监测。

关键词 数字全息术; 相位重建; 深度学习; 残差网络

中图分类号 O436 文献标志码 A

DOI: 10.3788/LOP220881

End-to-End Phase Reconstruction of Digital Holography Based on Improved Residual Unet

Li Kunge¹, Wang Huaying^{1,2,3}, Liu Xu^{1,2,3*}, Wang Jieyu¹, Wang Wenjian¹, Yang Liu¹¹School of Mathematics and Physics Science and Engineering, Hebei University of Engineering, Handan 056038, Hebei, China;²Hebei Computational Optical Imaging and Photoelectric Detection Technology Innovation Center, Handan 056038, Hebei, China;³Hebei International Joint Research Center for Computational Optical Imaging and Intelligent Sensing, Handan 056038, Hebei, China

Abstract Digital holography (DH) is critical for monitoring quantitative three-dimensional information of transparent samples. However, phase aberration compensation and unwrapping are needed in conventional digital holographic reconstruction, which adversely affect its speed and accuracy. We propose an improved residual Unet method that combines dilated convolution and attention mechanism to implement end-to-end phase reconstruction of DH, which simplifies the imaging process and improves the quality of image reconstruction. In addition, the proposed method can further optimize the network model for real-time reconstruction by adjusting residual blocks. The experimental results reveal that the proposed phase reconstruction method based on deep learning can obtain accurate three-dimensional information of samples in real time, which benefits real-time monitoring for dynamic samples.

Key words digital holography; phase reconstruction; deep learning; residual network

1 引言

数字全息作为一种重要的科学工具,已被广泛应用于成像、检测和计量等领域^[1]。由于采用光电成像器件直接记录全息图,数字全息可以利用许多数字图像

处理技术完成提升数字全息图和重构图像质量的任务。另外,数字重建可以同时获取物体的强度分布和相位分布,对物体三维形貌的分析与测量有很大的优势^[2-3]。近年来,计算机技术的更新换代给数字全息技术的发展带来了持续不断的动力。在数字全息多样化

收稿日期: 2022-03-03; 修回日期: 2022-03-14; 录用日期: 2022-03-30; 网络首发日期: 2022-04-10

基金项目: 国家自然科学基金面上项目(62175059)、河北省自然科学基金重点项目(2018402285)、河北省创新能力提升计划项目(20540302D)

通信作者: *liuxu@hebeu.edu.cn

的应用中,最有潜力也最常用的领域便是显微测量。

数字全息显微术(DHM)能够实现定量光场信息和透明样品的可视化,并且兼具无标记、低光毒性的特点。DHM能够量化透射光的相移,基于无标记定量相位图像,其中细胞对光的相位延迟被量化并用于计算它们的形貌^[4-5]。DHM的应用包括:在低辐射剂量下对样品的无标记成像^[6];推断物体的相位分布(特别适用于液体环境中对活细胞和其他生物样品的成像);通过只处理全息图,对整个样品进行数值3D重新聚焦^[7]。但是要获得高质量的目标相位图,对实验的采集环境和仪器的精密度要求很高,并且还要对初始相位进行畸变补偿和解包裹,所以必须改进现有的方法来简化整个工作过程的复杂度。

目前深度学习被广泛应用在语音识别、视觉目标识别、目标检测及各种工业和科学等领域。深度学习正成为光学领域的热门研究方向,因为该方法的计算速度更快,并且能为图像处理技术提供新的框架。全息和深度学习结合的设想已在多个应用场景得以实现,比如相位恢复^[8-9]、超分辨成像^[10-11]、景深增强和自聚焦^[12]、粒子场成像^[13-15]、计算全息^[16-17]等。深度学习可以通过构建神经网络对数据集进行学习,得到图像之间的映射关系和重建的细节信息。对神经网络架构的不断改进也是促进深度学习发展的有效手段,通过对不同的架构进行融合,引入新模块或者叠加深度,都能进一步优化全局和局部效果^[18-19]。结合深度学习方

法的优势,本文提出了一种改进残差Unet的端到端相位重建方法,很大程度上消除了噪声干扰,提高了成像质量,更有益于对动态样品的捕捉分析。

2 原理和方法

2.1 数据集准备

实验采用如图1所示的数字全息记录光路进行数据的加载和获取。图1(a)中用到的样品是血细胞,图1(b)中用到的样品是手写数字数据。图1(a)中,波长为632.8 nm的激光由He-Ne激光器发出,经过半波片和偏振分束棱镜(PBS)分为两束,一束经过扩束-滤波-准直系统(BE₁)后照明样品,再经过显微物镜(MO₁)放大,作为物光到达棱镜(BS)。另一束先经过半波片使得物参光偏振方向相同形成干涉,再到达扩束-滤波-准直系统(BE₂)后经显微物镜(MO₂)作为参考光,在BS后与物光合束再发生干涉。干涉条纹被位于样品像平面的CCD记录,形成全息图 $I(x, y)$,随后传输到计算机中进行处理。图1(b)中,由He-Ne激光器发出的激光($\lambda=632.8$ nm)经过半波片和扩束-滤波-准直系统BE后,被PBS分为两束,一束经过空间光调制器(SLM),再经过4f系统进行滤波处理后得到不包含高频分量的光束,与另一束光被BS合束后于CCD光敏面发生干涉,形成全息图 $I(x, y)$ 。手写数字数据作为纯相位样品被加载进SLM,相位为 $0\sim 2\pi$,最后传输到计算机中完成后续处理。




图1 数字全息记录光路示意图。(a)加载血细胞数据光路示意图;(b)加载手写数字数据光路示意图

Fig. 1 Experimental setup for digital holographic recording optical path. (a) Optical path diagram for loading blood cell data; (b) optical path diagram for loading handwritten number data

全息图 $I(x, y)$ 在计算机中经过数值重建,得到包裹相位 $\varphi(m, n)$:

$$\varphi(m, n) = \arctan \left\{ \frac{\text{Im}[U(m, n)]}{\text{Re}[U(m, n)]} \right\} \times \text{mod}(2\pi), \quad (1)$$

式中:Im表示取虚部,Re表示取实部; $U(m, n)$ 表示重建后的光场复振幅分布。由于三角函数的周期性,反正切函数得到的相位被包裹在 $(-\pi, \pi]$,要获得物体的真实相位信息,下一步必须对包裹位相图进行解包

裹。通过基于横向剪切的离散余弦变换(DCT-LS)方法^[20]解包裹,得到展开的初始相位。由于显微物镜相位调制作用以及实验影响因素,用改进的基于相位梯度最小化的相位补偿方法对初始相位进行畸变补偿^[21],得到样品真实的相位分布。如图2所示,其中图2(a)是全息图,图2(b)是相位图。图2(a1)和图2(a2)是血细胞的全息图,图2(a3)和图2(a4)是手写数字的全息图,图2(b1)和图2(b2)是血细胞的相位图,图2(b3)和图2(b4)是手写数字的相位图。




图 2 数据集示例。(a)样品全息图;(b)样品相位图
Fig. 2 Dataset examples. (a) Sample hologram; (b) sample phase

2.2 网络结构

近年来,Unet 网络已被用于许多光学成像应用,例如实现了对生物细胞的精确分割^[22]和医学图像的重建^[23]。而残差网络体系结构^[24]在每一层增加了短期记忆,由于能够迫使网络在每一层学习新的信息,而不是已经编码在网络中的信息,因此多用于逆问题的解决。作为基础的端到端网络模型,Unet 网络的重建过程在网络计算量和输出信息量方面有待提升。所提网络在残差 Unet 结构基础上引入新的自定义结构 dilated attention (DDA) 残差块,利用残差块的特点来改进,改进后的 Udanet 结构如图 3 所示。Udanet 整体来看也是和 Unet 一样的编码-解码结构,前半部分是

特征提取网络,后半部分是上采样路径。特征提取网络由 5 个具有相同结构的下采样块组成。而每一个下采样块分为 3 个部分:2 个 3×3 卷积层、1 个残差块和 1 个步长为 2 的最大池化层。从下采样路径中移除最大池化层,获得桥接路径,获得的桥接路径会在上采样路径中与新的特征图进行结合,以保留一些多尺度的特征信息。而上采样路径每一步分为 3 个部分:用于上采样的转置卷积、通过跳跃连接与相应特征图连接的上采样块、2 个 3×3 卷积层和 2 个卷积层之间的残差块。输入的全息图经特征提取网络提取出高级特征,而上采样路径从高级特征重构相位。




图 3 Udanet 的网络结构
Fig. 3 Network structure of Udanet

2.3 DDA 残差块

为了提高对特征提取的精确度,采用 DDA 残差块代替基础残差块。DDA 残差块使用空洞卷积层来替代常规的池化层,能够在增加特征图像信息量的同时降低过程中的运算负荷。在原始 Unet 结构中,池化

层虽有着聚合上下文信息、减少计算量的功能,同时也损失了部分细节信息。需要保留池化层中所丢失的信息,为此提出了空洞卷积概念^[25]。空洞卷积是一种在特征图上进行数据采样的方法,通过在普通卷积核的每个像素之间插入 0 像素值,增加卷积核的扩张

系数,从而减少计算量并保留完整数据结构。空洞卷积能在不增加算法复杂度的情况下,具有更大的感受野。

DDA 残差块的另一个特点就是增加一个可调整参数的注意力机制层。注意力机制是一种可以在深度网络的整个架构中结合上下文信息的机制,根据输入的全部特征对特征通道进行权重重新分配^[26]。目前注意力机制中最常用的是通道注意力机制。由于通道注意力方法的一个核心步骤是选择全局平均池化(GAP)^[27]来压缩通道,将每一个 $M \times N$ 大小空间的信息压缩到一个点,即

$$G = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \quad (2)$$

将通道注意力推广到频域中^[28],有

$$F(0, 0) = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \quad (3)$$

从频域角度分析可知,GAP只是保留了(0,0)处的最低频分量,通道注意力方法很难很好地学习到输入的各种复杂信息,而扩展得到的频域注意力机制能获取更丰富的信息表示。随着信息量的增加,就要进行信息筛选,根据 FcaNet-LF 和 FcaNet-TS 两种选择标准^[29]选择分量组合,构成频率注意力机制层。FcaNet-LF 根据一定范围内的频率信息来选择频率分量,FcaNet-TS 根据评估结果选择最高性能分量组合,两种标准下不同的模块结构参数可以影响网络的性能。注意力机制原理如图 4 所示。

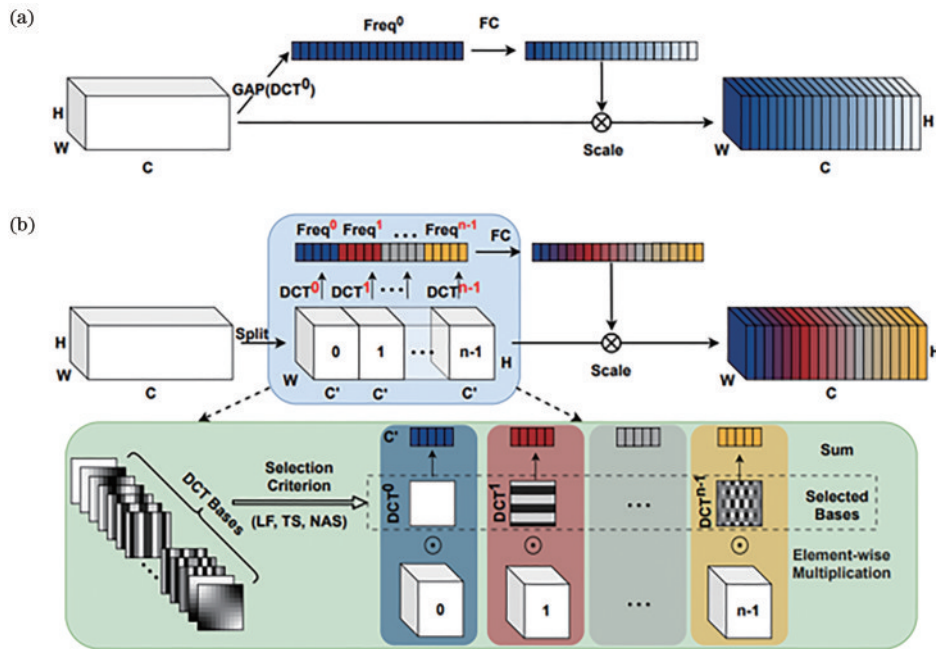


图 4 不同注意力机制的原理^[31]。(a)通道注意力;(b)频率注意力

Fig. 4 Schematic of different attention mechanisms^[31]. (a) Channel attention; (b) frequency attention

基础的残差块包括 2 个卷积层和 2 个激活函数,采用 2 个卷积层为间隔进行跳跃式的连接来加深层。在基础的残差块结构上再叠加一个注意力机制层,构成注意力残差块。而 DDA 残差块的内部结构是 2 个卷积核大小为 3、步长为 2、空洞率为 2 的空洞卷积层和 1 个可根据选择策略调整的注意力机制层。结合残差网络的结构、普通卷积与空洞卷积及注意力机制组合的方式,改进后的残差块使特征提取部分的输入特征包含更加充分的信息。残差块对比如图 5 所示。

2.4 网络训练

为了训练端到端的网络,从实验获得的大小为 1024×1080 的全息图中截取图像大小为 256×256 的全息图作为网络输入,经计算机处理,将得到的相位图像作为 ground truth。同时通过数据扩充的方法提高

神经网络的泛化能力,利用裁剪、翻转、旋转将全息图和相应相位图像的数据集扩展到一定的数据量。血细胞数据集经过数据扩充有 27000 对图像,其中 95% 和 5% 分别用作训练集和测试集。手写数字数据集经过数据扩充得到 35000 对图像,其中 95% 和 5% 分别用作训练集和测试集。UdaneNet 网络输入输出图像尺寸均为 256×256 ,初始学习率为 0.001,迭代次数为 200,批处理参数设置为 32。使用自适应矩估计(Adam)优化器来更新权重,损失函数为均方误差(MSE),通过与 ground truth 进行比较,网络输出的均方误差被最小化。随着迭代次数的增加,权重和损失都在不断变化。损失函数在最初的迭代中下降得最快,最后越来越慢直到收敛,损失函数变化如图 6 所示。而在模块结构参数方面,Lowk 和 Topk 是注意力机制层不同选择标准下的模块参数,k 表示选择 k 个不同的分量组合进行

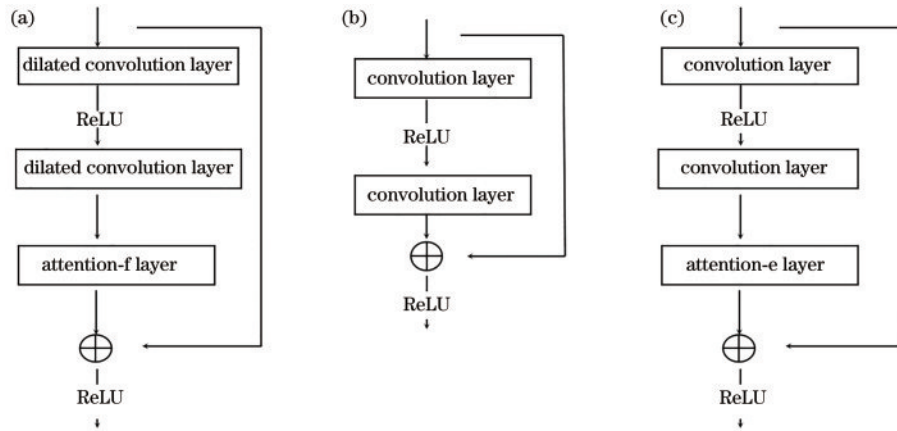


图5 残差块对比。(a) DDA 残差块;(b)普通残差块;(c)注意力残差块

Fig. 5 Residual block comparison. (a) DDA residual block; (b) ordinary residual block; (c) attention residual block

频率选择并组成模块。Unet表示只加入通道注意力机制的Unet结构。使用PyTorch框架在一个带有NVIDIA GeForce GTX 1080显卡的GPU中完成网络模型的训练。网络参数设置如表1所示。




图6 损失函数曲线

Fig. 6 Loss function curve

表1 网络参数设置

Table 1 Network parameter setting

Parameter	Udanet	Unet	Unet
Batchsize	32	32	32
Learning-rate	1×10^{-3}	1×10^{-3}	1×10^{-3}
Epoch	200	200	200
Number of images on training set	26000, 33000	26000	26000
Block parameter	Lowk, Topk		

3 分析与讨论

3.1 测试结果分析

为了验证端到端相位重建效果,用Udanet训练后的网络模型进行测试。网络对血细胞数据集进行相位重建的部分结果如图7所示。图7(a)和图7(b)分别是ground truth和网络相应重建结果三维展示图,选取界

面内不同细胞个数的图像进行展示。图7(c)展示二者之间的差值图,可见Udanet并没有丢失ground truth中的信息并且能去除噪声干扰,网络重建的结果非常接近ground truth。

为了进一步验证Udanet对纯相位物体的相位重建效果,对纯相位物体手写数字数据集进行测试。图8展示对不同数字的重建图像。图8(a)和图8(b)分别是ground truth和相应的Udanet的重建结果。图8(c)展示二者之间的差值图,可见所提Udanet具有一定泛化能力,对手写数字数据集也能较好地识别并重建细节。

3.2 网络性能评估

通过结构相似性指数(SSIM)定量地分析网络优化后的相位重建效果,SSIM计算网络输出图像与真实值(ground truth)的相似度。由于DDA残差块在注意力机制层中可以用选择策略进行网络优化,不同模块的最佳性能也可以通过SSIM值进行评估。Udanet网络中特征图的最小尺寸为 8×8 ,所以特征空间被分为 8×8 个部分。表2展示了各频率分量组合的网络的SSIM值。所有参数下的Udanet都有较高的SSIM值,验证了Udanet应用在端到端相位重建过程的优势和泛化能力。而Top4作为性能最好的频率分量组合,输出的SSIM值达0.922,将网络性能进一步提升0.8%~1.7%。

除了研究Udanet内部结构对网络性能的影响外,还对比Udanet和其他两个网络模型Unet和Unet的SSIM值,结果如表3所示,可见引入空洞卷积和注意力模块后改善了Unet对数字全息相位重建的效果。综上,测试结果表明:Udanet方法比常规数字全息重建方法省去了繁琐的步骤,实现端到端重建;结合残差块模块调整,与其他深度学习方法相比,Udanet方法降低了算法复杂度,重建效果得到提升。尽管如此,深度学习方法也面临着数据驱动模式的限制,有待进一步研究。

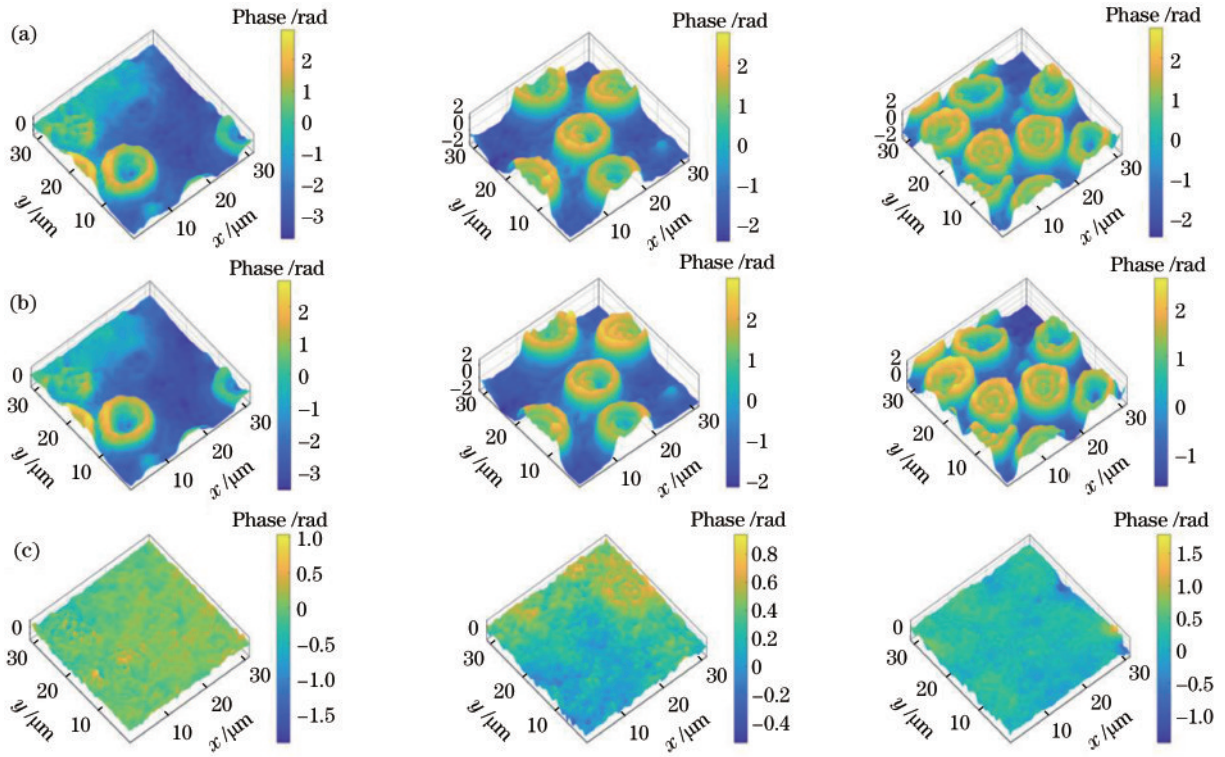


图7 血细胞的相位重建结果。(a) Ground truth; (b) Udanet的重建结果;(c)两者之间差值的三维展示

Fig. 7 Phase reconstruction of the blood cells. (a) Ground truth; (b) reconstruction result of Udanet; (c) three-dimensional image of error map between ground truth and Udanet reconstruction result




图8 手写数字数据集的相位重建结果。(a) Ground truth; (b) Udanet的重建结果;(c)两者之间差值的三维展示

Fig. 8 Phase reconstruction of the handwritten number dataset. (a) Ground truth; (b) reconstruction result of Udanet; (c) three-dimensional image of error map between ground truth and Udanet reconstruction result

表 2 各频率分量组合的 Udanet 网络的 SSIM 值

Table 2 SSIM value of Udanet with different frequency components

Parameter	Low8	Top1	Top2	Top4	Top8
SSIM average value	0.861	0.855	0.853	0.868	0.848
SSIM peak value	0.914	0.915	0.910	0.922	0.907

表 3 不同网络的 SSIM 值

Table 3 SSIM value of different networks

Parameter	Unet	Uanet	Udanet (Top4)
SSIM average value	0.844	0.851	0.868
SSIM peak value	0.901	0.913	0.922

4 结 论

提出了一种基于改进残差 Unet 的方法,该方法可实现数字全息端到端相位重建。该方法使用空洞卷积和频率注意力机制结合的方式来学习更多特征,弥补细节损失,提高实时重建质量。对不同数据集的预测结果表明,Udanet 的重建结果和 ground truth 之间的 SSIM 值较高,能够实时定量相位成像。接着对 Udanet 不同频率分量组合的注意力模块进行对比分析,Top4 频率分量组合的 SSIM 值相比其他分量组合提高,输出的 SSIM 值可以达 0.922。另外,和其他深度学习方法相比,Udanet 方法在构建网络结构方面具有很强的灵活性,采用性能更好的注意力模块从而简单有效地提升效果。Udanet 方法能为生物医学领域的定量相位成像增加更多可能性。

参 考 文 献

- [1] Javidi B, Carnicer A, Anand A, et al. Roadmap on digital holography[J]. Optics Express, 2021, 29(22): 35078-35118.
- [2] 温凯, 马英, 张美玲, 等. 高稳定性定量相位显微技术[J]. 激光与光电子学进展, 2020, 57(20): 200001.
Wen K, Ma Y, Zhang M L, et al. Quantitative phase microscopy with high stability[J]. Laser & Optoelectronics Progress, 2020, 57(20): 200001.
- [3] Kim Y, Park S, Baek H, et al. Voxel characteristic estimation of integral imaging display system using self-interference incoherent digital holography[J]. Optics Express, 2022, 30(2): 902-913.
- [4] Merola F, Memmolo P, Miccio L, et al. Tomographic flow cytometry by digital holography[J]. Light: Science & Applications, 2017, 6: e16241.
- [5] Zeng T J, Zhu Y M, Lam E Y. Deep learning for digital holography: a review[J]. Optics Express, 2021, 29(24): 40572-40593.
- [6] Bianco V, Mandracchia B, Marchesano V, et al. Endowing a plain fluidic chip with micro-optics: a holographic microscope slide[J]. Light: Science & Applications, 2017, 6: e17055.
- [7] 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.
- [8] Rivenson Y, Zhang Y B, Günaydin H, et al. Phase recovery and holographic image reconstruction using deep learning in neural networks[J]. Light: Science & Applications, 2018, 7: 17141.
- [9] 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.
- [10] Liu T R, de Haan K, Rivenson Y, et al. Deep learning-based super-resolution in coherent imaging systems[J]. Scientific Reports, 2019, 9: 3926.
- [11] 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.
- [12] Rivenson Y, Wu Y C, Ozcan A. Deep learning in holography and coherent imaging[J]. Light: Science & Applications, 2019, 8: 85.
- [13] Go T, Lee S, You D, et al. Deep learning-based hologram generation using a white light source[J]. Scientific Reports, 2020, 10: 8977.
- [14] 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.
- [15] Chen N, Wang C L, Heidrich W. Holographic 3D particle imaging with model-based deep network[J]. IEEE Transactions on Computational Imaging, 2021, 7: 288-296.
- [16] Wu J C, Liu K X, Sui X M, et al. High-speed computer-generated holography using an autoencoder-based deep neural network[J]. Optics Letters, 2021, 46(12): 2908-2911.
- [17] 孙晓, 韩超. 基于深度学习和分层角谱的三维纯相位全息显示[J]. 激光与光电子学进展, 2022, 59(4): 0409001.
Sun X, Han C. Three-dimensional phase-only holographic display based on deep learning and angular-spectrum layer-oriented[J]. Laser & Optoelectronics Progress, 2022, 59(4): 0409001.
- [18] Zhou Z W, Siddiquee M M R, Tajbakhsh N, et al. UNet: redesigning skip connections to exploit multiscale features in image segmentation[J]. IEEE Transactions on Medical Imaging, 2020, 39(6): 1856-1867.
- [19] Li X H, Du Z S, Huang Y Y, et al. A deep translation (GAN) based change detection network for optical and SAR remote sensing images[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2021, 179: 14-34.
- [20] 王华英, 刘佐强, 廖薇, 等. 基于最小范数的四种相位解包裹算法比较[J]. 中国激光, 2014, 41(2): 0209016.
Wang H Y, Liu Z Q, Liao W, et al. Comparison of four phases unwrapping algorithm based on method of minimum norm[J]. Chinese Journal of Lasers, 2014, 41

- (2): 0209016.
- [21] 董昭, 王文健, 王华英, 等. 改进的基于相位梯度最小化的相位补偿方法[J]. 中国激光, 2021, 48(24): 2409001.
Dong Z, Wang W J, Wang H Y, et al. Improved phase compensation method based on phase vibration minimization[J]. Chinese Journal of Lasers, 2021, 48(24): 2409001.
- [22] 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.
- [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, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [24] 张文倩, 冯金超, 李哲, 等. 基于Unet的切连科夫激发的荧光扫描断层重建[J]. 中国激光, 2021, 48(17): 1707001.
Zhang W Q, Feng J C, Li Z, et al. Reconstruction for Cherenkov-excited luminescence scanned tomography based on Unet network[J]. Chinese Journal of Lasers, 2021, 48(17): 1707001.
- [25] 颜铭靖, 苏喜友. 基于三维空洞卷积残差神经网络的高光谱影像分类方法[J]. 光学学报, 2020, 40(16): 1628002.
Yan M J, Su X Y. Hyperspectral image classification based on three-dimensional dilated convolutional residual neural network[J]. Acta Optica Sinica, 2020, 40(16): 1628002.
- [26] 朱江平, 王睿珂, 段智涓, 等. 基于多尺度注意力机制相位展开的三维人脸建模[J]. 光学学报, 2022, 42(1): 0112005.
Zhu J P, Wang R K, Duan Z J, et al. Three-dimensional face modeling based on multi-scale attention phase unwrapping[J]. Acta Optica Sinica, 2022, 42(1): 0112005.
- [27] Hu J, Shen L, Albanie S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.
- [28] Xu K, Qin M H, Sun F, et al. Learning in the frequency domain[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 1737-1746.
- [29] Qin Z Q, Zhang P Y, Wu F, et al. FcaNet: frequency channel attention networks[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV), October 10-17, 2021, Montreal, QC, Canada. New York: IEEE Press, 2021: 763-772.