

引用格式: HE Chen, FANG Hong, ZHANG Ningchao. Single-shot On-axis Digital Holography Reconstruction Method Based on Deep Learning[J]. Acta Photonica Sinica, 2021, 50(12):1210004

何晨, 房鸿, 张宁超. 基于深度学习的单帧同轴数字全息重建方法[J]. 光子学报, 2021, 50(12):1210004

基于深度学习的单帧同轴数字全息重建方法

何晨, 房鸿, 张宁超

(西安工业大学 基础学院, 西安 710021)

摘 要: 针对同轴数字全息中零级像及孪生像对再现像干扰的问题, 提出一种基于深度学习的单帧同轴数字全息图重建方法。利用神经网络强大的特征提取能力, 去除同轴全息重建过程中零级像及孪生像对再现像的干扰。分别针对强度型和相位型目标所对应的同轴全息图利用 U-Net 的卷积神经网络进行了训练和重建, 结果表明 U-Net 网络对强度型和相位型目标均能实现高质量的重建。为进一步验证该网络对不同目标泛化性, 将字母数据集生成的同轴全息图在不同噪声水平下进行了重建, 结果表明该网络对不同目标及噪声均具有良好的鲁棒性, 且重建结果与真实目标的结构相似度均保持在 0.92 以上。

关键词: 数字全息; 同轴; 深度学习; 相位; 神经网络; 重建

中图分类号: O438

文献标识码: A

doi: 10.3788/gzxb20215012.1210004

Single-shot On-axis Digital Holography Reconstruction Method Based on Deep Learning

HE Chen, FANG Hong, ZHANG Ningchao

(School of Sciences, Xi'an Technological University, Xi'an 710021, China)

Abstract: A single-frame on-axis digital hologram reconstruction method based on deep learning is proposed to suppress the zero-order and twin images in on-axis digital holography based on the powerful feature extraction capabilities. The U-Net is used to train and reconstruct different kinds on-axis holograms, including intensity and phase targets. The results show that the U-Net-based neural network can achieve high-precision reconstruction of the on-axis holograms. A set of on-axis holograms based on letters with different noise levels are generated to verify the robustness of the U-Net-based neural network. The results show that the U-Net-based neural network is robust to different targets and noise levels, and the structural similarity of the reconstruction results is better than 0.92.

Key words: Digital holography; On-axis; Deep learning; Phase; Neural networks; Reconstruction

OCIS Codes: 100.3010; 100.5070; 110.1758; 090.1995

0 引言

数字全息术^[1-3]是一种利用电荷耦合器件(Charge Coupled Devices, CCD)等感光器件代替传统全息干板记录物光和参考光的干涉条纹, 通过计算机数值模拟光波场的衍射传播以重建再现像^[4-6], 从而定量获取原始物光波的振幅和相位分布, 能够全场、实时、非接触、定量测量原始物光波的振幅和相位分布^[7-9], 被广泛应用于流场、温度场等物理场特征参数的实时表征, 生物细胞、光学元器件及微机电系统(Micro-Electro-Mechanical System, MEMS)等目标的表面及内部形貌的三维测量^[10-12]。离轴数字全息术中由于物光和参

基金项目: 国家自然科学基金(No.12004292)

第一作者: 何晨(1993—), 男, 硕士研究生, 主要研究方向为相位成像技术。Email: 505088883@qq.com

导师(通讯作者): 房鸿(1964—), 男, 副教授, 硕士, 主要研究方向为光电子学。Email: 1738284194@qq.com

收稿日期: 2021-06-24; 录用日期: 2021-09-20

<http://www.photon.ac.cn>

考光之间存在一定的夹角,在离轴数字全息图重建过程中,目标零级像、孪生像与目标像分处在不同空间,在频谱域可以简单方便地滤除零级像及孪生像对再现像的影响,应用场景极为广泛。然而,由于目前记录全息图的CCD像原尺寸要求较高。当CCD像元尺寸比较大时,无法记录条纹周期太小的干涉条纹,此时物光和参考光夹角也被限定在一个较小的范围中,零级像和孪生像与再现像容易出现重叠,影响最终再现像的像质及准确性。同轴数字全息术物光和参考光夹角为零,物光和参考光产生的干涉条纹周期比较大,因此,同轴数字全息术能降低对CCD等感光器件的要求。然而,同轴数字全息术由于物光和参考光夹角为零,零级像、目标像和孪生像都在同光轴上,无法直接分开。并且零级像和孪生像会对同轴数字全息再现像像质及测量结果准确性产生很大影响,这也限制了同轴数字全息术的广泛应用。

为了去除同轴数字全息术中零级像和孪生像对再现像的干扰,一般采用数值迭代和相移技术两种方式实现。数值迭代方法在记录平面和物品面之间进行多次迭代实现孪生像及零级像的去除,得到了良好的重建效果。在数值迭代去孪生像方面,LATYCHEVSKAIA T等^[13-15]提出了相位迭代算法去除零级像和孪生像的影响。由于数值迭代的方式计算量大且目前无法完全准确去除零级像和孪生像的影响,因此目前还并未获得广泛应用。相移法以其简单的计算过程且不受适用条件的影响,受到了更广泛的关注。相移法通过在物光和参考光之间引入额外的相移量,记录多幅具有不同相移量的数字全息图,而后根据相移算法可以直接获取物光波的复振幅分布,避免了零级像及孪生像对再现像的干扰。1997年,日本的YAMAGUCHI I和ZHANG T将相移技术应用到数字全息领域,获取了不受零级像和孪生像影响的高质量再现像^[16]。近年来,多种相移技术^[17-20]被相继提出,也促进了同轴数字全息术的不断发展。然而相移法虽然能完全去除零级像和孪生像的干扰,但相移的引入额外增加了系统的复杂性,增加了系统对稳定性的需求。由于相移技术通常需要记录多幅相移全息图,影响了系统对动态目标的测量。

深度学习^[21]技术是机器学习的一个分支,通过组合低层特征形成更加抽象的高层表示属性类别或特征,从而实现不同特征信息的提取。近年来,深度学习技术被引入到数字全息术中^[22-24],在不同应用领域都显示出了巨大的应用潜力^[25-26]。WANG K等将深度学习用于包裹相位图的解包裹过程^[27];LIU H等利用RSNet实现了离轴数字全息图的重建^[28];XIAO W等利用深度学习实现了数字全息显微镜像差的自动补偿^[29]。2017年,RIVENSON Y等利用神经网络实现了同轴数字全息图的重建,但还需要辅助同轴迭代方法配合使用,无法实现端到端的重建^[30]。2018年,WANG H等利用eHoloNet实现了同轴数字全息图的端到端重建,省去了同轴迭代过程^[31]。然而文献^[31]并未就相位型目标和强度型目标以及全息图中有噪声的情况进行讨论。

本文利用深度学习的特征数据提取能力,在单幅同轴数字全息图中去除掉零级像和孪生像的干扰,实现强度型及相位型目标的单幅同轴数字全息图的重建,并在对同轴全息图存在噪声情况下的重建结果进行了讨论。本文所采取的网络结构为U-Net,分别针对不同类型的强度型和相位型目标生成了2 500幅同轴全息图进行训练,并分别生成了500幅同轴全息图进行测试。重建结果表明,利用U-Net神经网络针对相位型目标及强度型目标的同轴全息图均可进行重建,且重建结果与真实目标的结构相似度(SSIM)均保持在0.92以上。为了进一步验证该网络的泛化性,给同轴全息图中分别加入不同水平的随机噪声。结果表明,噪声并不会影响网络对同轴全息图的重建结果,也证明该网络除了对不同目标具有很好的鲁棒性之外,对噪声也有很好的抑制能力。

1 同轴数字全息物理模型

1.1 同轴数字全息图的记录

同轴数字全息术中物光为经目标调后的衍射光 $O(x,y)=o(x,y)\exp(i\phi_o)$,参考光为无目标区域的衍射光 $R(x,y)=r(x,y)\exp(i\phi_r)$,当物光波和参考光波在相机靶面形成干涉时,所产生全息图的强度分布 $I(x,y)$ 可以表示为

$$\begin{aligned} I(x,y) &= |O(x,y)+R(x,y)|^2 \\ &= |O(x,y)|^2 + |R(x,y)|^2 + R^*(x,y)O(x,y) + R(x,y)O^*(x,y) \\ &= o^2(x,y) + r^2(x,y) + 2r(x,y)o(x,y)\cos[\phi_r(x,y) - \phi_o(x,y)] \end{aligned} \quad (1)$$

式中, $o(x, y)$, $r(x, y)$, $\phi_o(x, y)$ 和 $\phi_r(x, y)$ 分别表示物光波和参考光波的振幅和相位分布。可以看到, 全息图中的干涉条纹是物光和参考光相位及振幅信息互相调制的结果, 所记录的全息图也包含了物光波和参考光波的振幅和相位信息^[32]。

1.2 传统同轴数字全息图的重建方法

传统同轴数字全息图重建主要利用相移法实现。相移数字全息术需要在全息图记录过程中, 让物光或参考光波依次产生一个附加相移, 记录多幅具有一定相移量的全息图。通过对所记录的多幅具有一定相移量的数字全息图进行相关初等运算, 就能获取原始物光波的复振幅分布, 无需进行傅里叶变换等操作。

四步相移即是在全息图记录过程中记录四幅具有一定相移量的数字全息图, 而后通过四步相移算法获取原始物光波的复振幅分布。通常, 所记录的四幅相移数字全息图相邻全息图之间的相移量也为 $\pi/2$, 其强度分布分别表示为

$$\begin{cases} I_1(x, y) = I_o + I_r + 2\sqrt{I_o I_r} \cos \phi \\ I_2(x, y) = I_o + I_r + 2\sqrt{I_o I_r} \cos\left(\phi + \frac{\pi}{2}\right) \\ I_3(x, y) = I_o + I_r + 2\sqrt{I_o I_r} \cos(\phi + \pi) \\ I_4(x, y) = I_o + I_r + 2\sqrt{I_o I_r} \cos\left(\phi + \frac{3\pi}{2}\right) \end{cases} \quad (2)$$

将式(2)中四个式子进行两两相减, 可达到如下关系

$$\begin{cases} I_4 - I_2 = 2\sqrt{I_o I_r} \sin \phi \\ I_1 - I_3 = 2\sqrt{I_o I_r} \cos \phi \end{cases} \quad (3)$$

因此, 可根据式(3)获取原始物光波的复振幅分布

$$\begin{cases} O(x, y) = \frac{I_1 - I_3 + j(I_4 - I_2)}{4\sqrt{I_r}} \\ \phi(x, y) = \arctan\left(\frac{I_4 - I_2}{I_1 - I_3}\right) \end{cases} \quad (4)$$

2 基于U-Net的同轴数字全息重建方法

U-Net^[33]网络结构如图1所示。包含一个捕捉语义的收缩路径作为编码部分和一个用于精准定位的扩展路径作为解码部分, 编码部分与解码部分结构对称。从图中可以看出, U-Net网络为U型的网络结构, 先下采样再上采样的训练策略, 增加少量参数换取网络深度增加。网络中添加跳层连接, 使得不同尺度的特




图1 U-Net网络框图

Fig.1 U-Net network structure

征信息为解码阶段提供更多的细节信息。

网络的编码过程利用卷积和最大池化操作对图像进行编码和下采样。具体来说,首先对输入图像进行两次卷积操作,再重复使用 2×2 的最大池化和两次卷积,共4次最大池化和10次卷积操作。卷积核的大小固定为 3×3 ,每次卷积操作后进行一次批归一化(Batch Normalization, BN)操作,并使用修正线性单元(Rectified Linear Unit, ReLU)作为激活函数,通过为适当的零填充卷积操作不改变特征图的大小。

网络解码过程对编码得到的特征图重复进行上采样和两次 3×3 的卷积,共进行4次采样和8次卷积操作,最终得到和输入图片相同大小的特征图。基于U-net的同轴数字全息图再现算法采用有监督的方法对同轴数字全息图进行端到端的训练。U-net使用训练对 $D=\{S, G\}$ 作为训练数据集。图像描述图 S 用作输入, G 是 S 对应的真实标签图像(也叫参考图像)。对于同轴数字全息图,在U-net中使用感知损失(生成图像的感知特征和参考图像的感知特征之间的 L_1 距离)来衡量输出图像和真实图像之间的差异。本文中,损失函数可以定义为Smooth L_1 ,用于度量生成图像和目标图像每一对像素之间的差异:

$$\text{Minimize loss}(x, y) = \sum_{i,j} \text{Smooth}L_1[x(i, j) - (i, j)] \quad (5)$$

式中,

$$\text{Smooth}L_1(x) = \begin{cases} 0.5x^2 & \text{if } |x| < 1 \\ |x| - 0.5 & \text{otherwise} \end{cases} \quad (6)$$

在同轴数字全息术的重建过程中,零级像、孪生像与目标再现像在同一光轴上无法直接分离,需要用到相移或者数学迭代等手段实现目标再现像的提取。然而实际上,零级像、孪生像与目标再现像在同一光轴上的分布位置是不同的,不同目标目标分布的叠加结果也不尽相同。因此,利用神经网络强大的信息提取能力,能够提取出目标再现像的信息,省去了数学迭代的过程,因此利用神经网络实现同轴数字全息图的重建是完全可行的。

3 重建结果与分析

3.1 训练数据集的生成

分别选取2 500幅和500幅不同目标的同轴数字全息图作为网络的训练集和测试集。假设照明光源波长 λ 为532 nm,测量目标与相机靶面距离为 z ,相机像素尺寸为 $5.5 \mu\text{m}$,相机分辨率为 $256 \text{ pixel} \times 256 \text{ pixel}$ 。在理想的同轴数字全息系统中,物光与参考光夹角为零,此时相机靶面上的干涉条纹周期很大,整个靶面无法观察到一个完整周期的干涉条纹。为了便于观察,将物参光的额夹角设置为 0.15° ,便于观察干涉条纹产生的变化。而 0.15° 的夹角又不会将零级像、孪生像与目标再现像分开,不会对此方法的准确性与有效性产生影响。所生成的随机挑选的同轴数字全息图如图2(b),图2(a)为全息图对应的目标图。设置衍射距离 z 为10 cm。训练神经网络的硬件设备为为主板i9-10900k,显卡RTX-2080Ti 11G,运行内存32 G。将生成的2 000副同轴数字全息图当作输入,全息图对应的目标强度分布当作输出对U-Net神经网络进行训练。

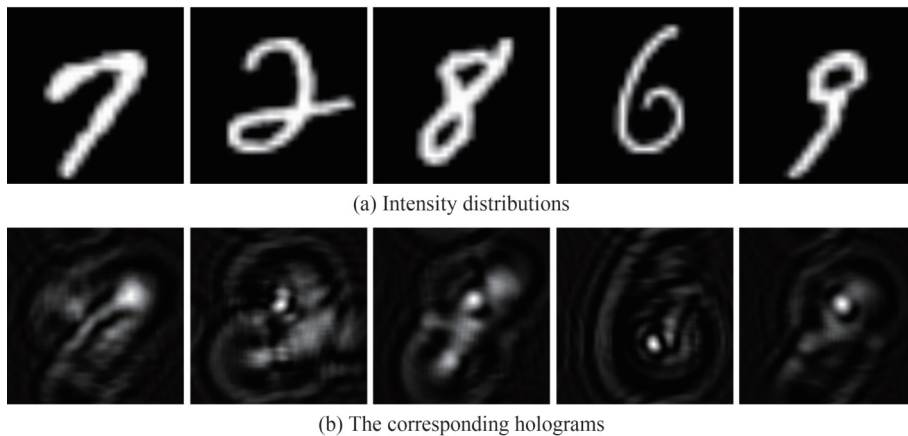


图2 五个目标强度分布及其生成的训练集全息图
Fig.2 Five intensity distributions and holograms generated for training

3.2 U-Net训练结果与分析

在完成U-Net网络对同轴全息图的重建训练后,利用生成的另外500幅同轴全息图对训练后的网络进行测试,相关测试同轴全息图及重建结果如图3。图3(a)为测试集中五个目标的强度分布,图3(b)为图3(a)所对应的同轴全息图。通过对图3(b)所示的全息图进行傅里叶变换,得到对应的傅里叶频谱图,如图3(c)。从图3(c)可以看出,尽管不同目标频谱图稍许差别,但所有频谱图中, ± 1 级与零级分量均重合在一起无法分辨。这也验证了所生成同轴全息图的准确性。首先利用角谱法对生成的测试全息图进行单帧重建,其结果如图3(d)。从图3(d)中可以看出,重建效果很差,很多图像甚至无法分辨原始目标的轮廓,这是由于在重建过程中,目标零级像、共轭像与目标再现像重合在一起无法分离,导致在重建过程中无法精确获取原始目标强度分布。之后,利用U-Net网络对测试全息图进行重建时,获得了原始目标的高精度强度分布,相关结果如图3(e)。通过对比基于U-Net神经网络的重建结果与图3(a)中目标真实强度分布可以发现,基于U-Net神经网络的重建结果没有目标零级像、共轭像的干扰,可以清晰地重建出原始目标的轮廓及细节信息。这是因为,在U-Net网络训练过程中,充分考虑到了同轴全息图的特性,在训练的过程中,消除了零级像与孪生像对目标再现像的干扰,实现了单帧同轴全息图的高精度重建。




图3 测试集同轴全息图及重建结果

Fig.3 The on-axis holograms in training set and the reconstructed results

为进一步说明基于U-Net神经网络的重建结果的准确性,对比了测试集重建结果的强度分布与原始目标之间的SSIM,其结果如图4。从SSIM曲线可以看出,在测试集中500幅同轴全息图SSIM均在0.97以上,均值为0.9873。从数据可以看出,基于U-Net的重建方法不但实现了基于单帧的同轴全息图重建,且保持了较高的重建精度。




图4 基于U-Net重建结果与原始目标强度分布的结构相似度
Fig.4 The SSIM between U-Net results and the intensity distributions of the objects

前面验证了基于U-Net的神经网络对强度型目标的重建效果,接下来对其重建相位型目标的能力进行研究验证。实验首先按照3.1节所述参数,生成新的训练集和测试集。图5即为生成的相位型目标的同轴全息图及其对应的相位分布。之后,利用生成的测试全息图及其对应的相位分布对U-Net神经网络进行训练。

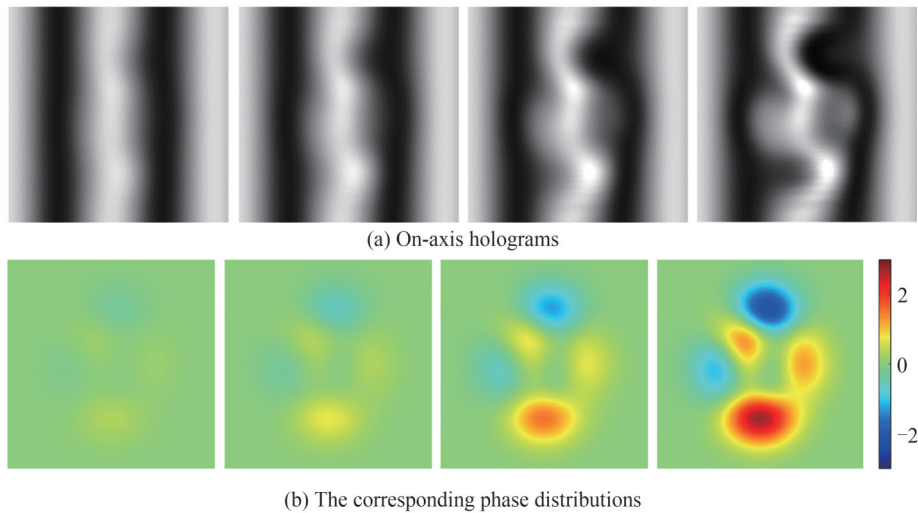


图5 相位型目标的同轴全息图及其对应的相位分布
Fig.5 The on-axis holograms of phase objects and the corresponding phase distributions

完成U-Net神经网络的训练后,利用训练好的神经网络对测试集中相位型目标的同轴全息图进行重建,图6(b)为图6(a)所对应的利用神经网络重建得到的相位分布。从图6(b)可以看出,零级像和孪生像没有对最终重建的相位分布产生影响。图6(c)为图6(b)中黑色直线区域的相位分布曲线与该区域实际相位分布曲线。从图6(c)可以看出,利用神经网络重建得到的相位分布曲线与原始真值的相位曲线一致,这也说明了利用U-Net对相位型目标同轴数字全息图重建的准确性。利用U-Net网络可去除相位型目标同轴数字全息术中零级像和孪生像对最终再现像的影响,实现单帧相位型目标同轴数字全息图的实时重建。

为进一步验证利用U-Net重建得到的相位分布与真实相位分布之间的差异,实验计算了图6(b)中相位分布与实际相位分布之间的差值,并绘制了相位差异图,如图7。从图中可看出,无论是原始相位分布中有相位变化的区域还是没有相位变化的区域,在利用U-Net重建后,都与原始相位分布之间有数值差异,但数值差异与实际相位变化趋势及零级像均没有关联。这也说明利用U-Net重建同轴数字全息图所产生的误差并不是零级像和孪生像产生的影响,也从侧面说明U-Net可以消除同轴数字全息术中零级像和孪生像的影响。虽然利用U-Net对同轴数字全息图进行重建后会产生误差,但总体SSIM均在0.94以上。

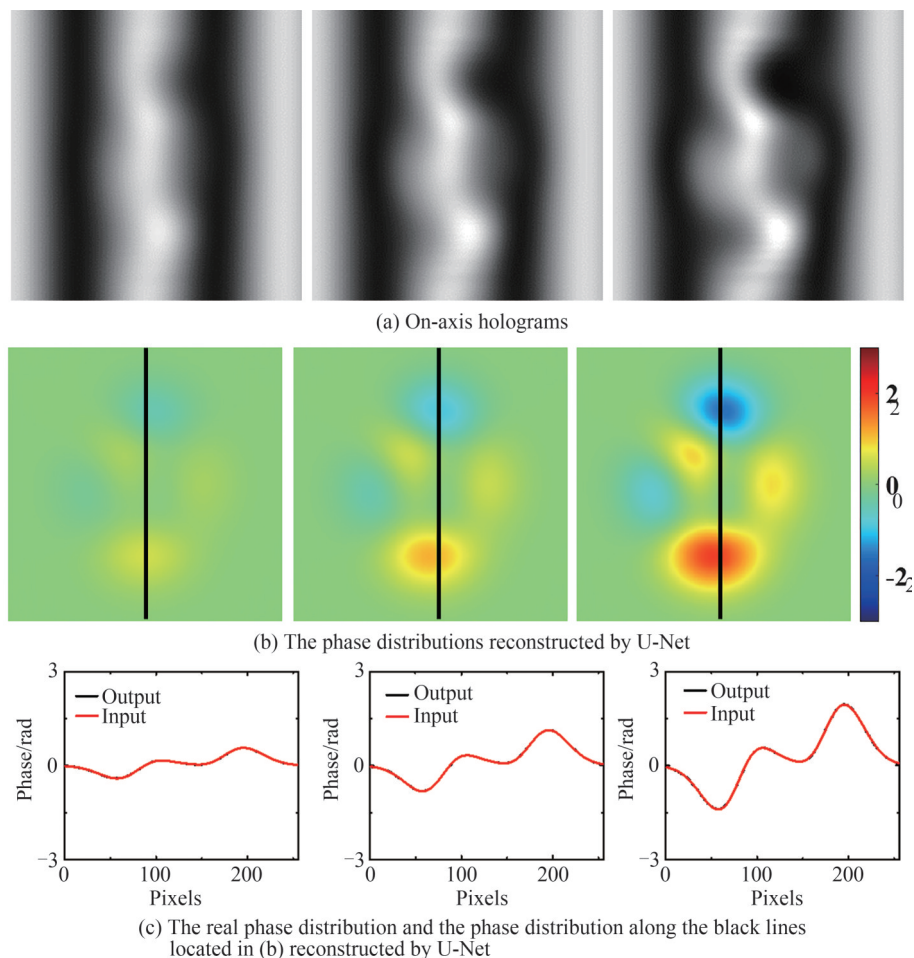


图6 测试集中同轴全息图及利用U-Net神经网络重建的相位分布

Fig.6 The test holograms and the results reconstructed by U-Net




图7 利用重建图6(a)所得到的相位分布与真实相位分布之间的差异

Fig.7 The difference between real phase distributions and the phase distributions reconstructed by Fig. 6(a)

为验证网络对不同目标的重建效果,采用字母的数据集生成了相应的同轴数字全息图,利用U-Net网络对相应的全息图进行重建,结果如图8。图8(a)为原始目标图,图8(b)为生成的同轴数字全息图,图8(c)为利用训练好的U-Net神经网络再现得到的目标图像。对比重建结果与原始目标间的SSIM可以发现,针对不同目标,其重建结果的SSIM均能保持在0.94以上。说明该网络对不同目标均具有较好的重建能力。

为进一步探究该网络的泛化能力,将字母目标生成的同轴数字全息图加入不同水平的随机噪声,验证在噪声情况下网络的重建能力,结果如图9。从重建结果可以看出,尽管在同轴全息图中添加了不同水平的随机噪声,但是重建结果的结果相似度仅在一个很小的范围内波动,并不会产生剧烈变化,这也验证了利用U-Net实现同轴数字全息图重建具有很好的噪声抑制能力。




图8 字母数据集生成的同轴数字全息图及相应的重建结果
 Fig.8 The on-axis digital holograms generated by the letter data set and the corresponding reconstruction results




图9 字母“F”对应同轴全息图在不同噪声水平下的重建结果
 Fig.9 The reconstruction results of on-axis hologram of letter “F” under different noise levers

4 结论

本文利用U-Net神经网络对同轴数字全息图进行训练和测试,实现了基于U-Net神经网络对同轴数字全息图的单帧再现。与传统同轴数字全息图重建方法相比,利用U-Net神经网络,只需要一幅同轴数字全息图就能实现零级像与孪生像的消除,并再现得到对应的强度或相位分布。由于神经网络只需要一个输入,且不用对同轴全息图进行预处理,可直接进行重建,降低了同轴数字全息术的应用条件也拓展了应用场景。分别针对强度型和相位型目标进行了测试,结果表明该网络针对不同目标同轴全息图均具有高精度的重建能力。最后利用不同噪声水平的同轴全息图验证了U-Net网络对噪声的抑制能力,最终重建结果的SSIM优于0.92,验证了该方法的有效性与鲁棒性。

参考文献

- [1] SCHNARS U, JÜPTNER W P O. Digital recording and reconstruction of holograms in hologram interferometry and shearography[J]. *Applied Optics*, 1994, 33(20): 4373-4377.
- [2] SCHNARS U, JÜPTNER W. Direct recording of holograms by a CCD target and numerical reconstruction[J]. *Applied Optics*, 1994, 33(2): 179-181.
- [3] XIA P, RI S, WANG Q, et al. Nanometer-order thermal deformation measurement by a calibrated phase-shifting digital holography system [J]. *Optics Express*, 2018, 26: 12594-12604.
- [4] GOODMAN J W, LAWRENCE R W. Digital image formation from electronically detected holograms [J]. *Applied Physics Letters*, 1967, 11(3): 77-79.
- [5] HUANG T S. Digital holography[J]. *IEEE*, 1971, 59(9): 1335-1346.
- [6] FUKUCHI K, KOJIMA S, HISHIDA Y, et al. Optical water-level sensors using fiber Bragg grating technology [J]. *Hitachi Cable Review*, 2002, 21(3): 23-28.
- [7] SINGH D K, AHRENS C C, LI W, et al. Label-free, high-throughput holographic screening and enumeration of tumor cells in blood[J]. *Lab on a Chip*, 2017, 17: 2920-2932.
- [8] EBRAHIMI S, MORADI A R, ANAND A, et al. Digital holographic microscopy with coupled optical fiber trap for cell measurement and manipulation[J]. *Optics Letters*, 2014, 39(10): 2916-2919.
- [9] MINETTI C, VITKOVA V, DUBOIS F, et al. Digital holographic microscopy as a tool to study the thermal shape fluctuations of lipid vesicles[J]. *Optics Letters*, 2016, 41(8): 1833-1836.
- [10] WANG F, XIAO W, PAN F, et al. Curvature measurement of optical surface using digital holography[J]. *Optics and Lasers in Engineering*, 2011, 49(7): 903-906.
- [11] SUN W W, ZHAO J L, DI J L, et al. Real-time visualization of Karman vortex street in water flow field by using digital holography[J]. *Optics Express*, 2009, 17(22): 20342-20348.
- [12] DI J, YU Y, WANG Z, et al. Quantitative measurement of thermal lensing in diode-side-pumped Nd:YAG laser by use of digital holographic interferometry[J]. *Optics Express*, 2016, 24(25): 28185-28193.
- [13] LATYCHEVSKAIA T, FINK H W. Solution to the twin image problem in holography[J]. *Physical Review Letters*, 2007, 98(23): 233901.
- [14] LATYCHEVSKAIA T, LONGCHAMP J N, FINK H W. When holography meets coherent diffraction imaging[J]. *Optics Express*, 2012, 20(27): 28871-28892.
- [15] ZHONG Z, BAI H, SHAN M, et al. Fast phase retrieval in slightly off-axis digital holography[J]. *Optics and Lasers in Engineering*, 2017, 97: 9-18.
- [16] YAMAGUCHI I, ZHANG T. Phase-shifting digital holography[J]. *Optics Letters*, 1997, 22(16): 1268-1270.
- [17] JACKIN B J, NARAYANAMURTHY C S, YATAGAI T. Geometric phase shifting digital holography [J]. *Optics Letters*, 2016, 41(11): 2648-2651.
- [18] YANG T D, KIM H J, LEE K J, et al. Single-shot and phase-shifting digital holographic microscopy using a 2-D grating[J]. *Optics Express*, 2016, 24(9): 9480-9488.
- [19] ZHANG X, MENG X, YIN Y, et al. Two-level image authentication by two-step phase-shifting interferometry and compressive sensing[J]. *Optics and Lasers in Engineering*, 2018, 100: 118-123.
- [20] GAO P, YAO B, MIN J, et al. Parallel two-step phase-shifting microscopic interferometry based on a cube beamsplitter[J]. *Optics Communications*, 2011, 284(18): 4136-4140.
- [21] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553): 436 - 444.
- [22] TANG J, WANG K, REN Z, 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.
- [23] TANG J, WU J, WANG K, et al. RestoreNet-Plus: Image restoration via deep learning in optical synthetic aperture imaging system[J]. *Optics and Lasers in Engineering*, 2021, 146:106707.

-
- [24] DI J, HAN W, LIU 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.
- [25] DI J, WU J, WANG K, et al. Quantitative phase imaging using deep learning-based holographic microscope [J]. *Frontiers in Physics*, 2021, 9:651313.
- [26] WANG K, LI Y, QIAN K, et al. One-step robust deep learning phase unwrapping[J]. *Optics Express*, 2019, 27(10): 15100-15115.
- [27] 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.
- [28] LIU Hang, XIAO Yongliang, TIAN Junlong, et al. Nonlinear reconstruction for off-axis fresnel digital holography with deep learning[J]. *Acta Photonica Sinica*, 2020, 49(7):0709001.
刘航,肖永亮,田军龙,等. 基于深度学习的离轴菲涅耳数字全息非线性重构[J]. *光子学报*, 2020, 49(7):0709001.
- [29] XIAO W, LI J, PAN F, et al. Super-resolution in digital 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.
- [30] RIVENSON Y, ZHANG Y, GUNAYDIN H, et al. Phase recovery and holographic image reconstruction using deep learning in neural networks[J]. *Light: Science & Applications*, 2017, 7(2):17141.
- [31] WANG H, LYU M, SITU G. eHoloNet: a learning-based end-to-end approach for in-line digital holographic reconstruction[J]. *Optics Express*, 2018, 26(18): 22603-22614.
- [32] 李俊昌,熊秉衡. 全息干涉计量: 原理和方法[M]. 北京: 科学出版社, 2009.
- [33] OLAF R, PHILIPP F, THOMAS B. U-Net: convolutional networks for biomedical image segmentation [C]. *International Conference on Medical Image Computing & Computer-assisted Intervention*, 2015, 9351: 234-241.