

基于深度学习的多尺度数字全息图重建

浦健, 桂进斌*, 张凯

昆明理工大学理学院, 云南 昆明 650550

摘要 针对单个深度学习模型不能对多尺度的数字全息图进行波前重建的问题, 提出一种基于 U-Net 模型的改进网络结构, 模拟数字全息成像过程, 生成不同尺度的全息图像作为数据集。将不同尺度的数字全息图分别用于训练网络的不同部分, 得到一个可以对三种不同尺度的数字全息图波前信息进行重建的深度学习模型。实验结果表明, 所提网络结构可对不同尺度的数字全息图进行重建, 获得准确的数字全息图波前信息。研究内容为使用单个深度学习模型处理多种尺度的数字全息图这类问题提供了一种解决思路。

关键词 全息; 数字全息; 全息重建技术; 深度学习; 卷积神经网络; 多尺度

中图分类号 O438.1

文献标志码 A

doi: 10.3788/LOP202259.0209001

Multiscale Digital Hologram Reconstruction Based on Deep Learning

Pu Jian, Gui Jinbin*, Zhang Kai

Faculty of Science, Kunming University of Science and Technology, Kunming, Yunnan 650550, China

Abstract To address the problem of a single deep-learning model being unable to reconstruct the wavefront of digital holograms with multiple scales, an improved network structure based on the U-Net model is proposed to simulate the digital holographic imaging process and generate holographic images with different scales as data sets. Digital holograms with different scales are used in different parts of the training network, and a depth learning model is obtained, which can reconstruct the wavefront information of digital holograms with three different scales. The experimental results show that the proposed network structure can reconstruct digital holograms with various scales and obtain accurate wavefront information of digital holograms. The research content solves the problem of using a single deep-learning model to deal with digital holograms with varying scales.

Key words holography; digital holography; image reconstruction technique; deep learning; neural neuro network; multiscale

1 引言

全息术^[1]是一种同时记录相位信息和振幅信息的技术。随着电荷耦合器件(CCD)技术和计算机性能的发展,使用 CCD 代替全息干板来记录全息图的数字全息技术获得了快速发展^[2-3]。数字全息图重建时,通过使用计算机模拟光波的衍射过程来重

建物光波的振幅和相位信息,由于数字全息术具有精度高且成像速度快的优点,在形貌测量、防伪、数字全息显微等领域获得了重要应用^[2]。但是基于数字全息重建^[4]波前信息的传统算法需要数字全息图产生时的相关参数,如参考光波长、物体到全息记录面的距离、衍射面的尺寸和成像面的尺寸等,同时还要去除零级干扰、孪生图像,重建后的相位信

收稿日期: 2021-03-02; 修回日期: 2021-03-05; 录用日期: 2021-03-10

基金项目: 国家自然科学基金(62065010, 61565011)

通信作者: *jinbingui@163.com

息还要进行相位解包裹^[5-6]等,这些因素都导致了传统重建算法计算速度慢、重建过程繁琐等问题。

随着计算机硬件性能和软件算法的发展,深度学习已进入了快速发展阶段,目前已经在语音识别^[7]、图像分割^[8]、自然语言处理^[9]等领域取得了突破性进展。与此同时,一些研究团队把深度学习应用在超分辨率成像^[10-11]、散射介质成像^[12-13]、自动聚焦^[14-15]等光学领域,取得了显著的成果。在基于深度学习的数字全息波前重建领域,国内很多学者展开了相关应用研究,并取得了瞩目的结果^[16-23],如清华大学深圳研究生院光学实验室的何永红团队^[18]把深度学习应用到了离轴数字全息重建上,在重建速度上取得了一定的突破;西北工业大学赵建林团队^[19]提出的 Y-Net 把两个 U-Net 网络下采样路径融合为一个,形成了单个输入对应两个输出的网络结构,训练好的模型可从单幅数字全息图中同时重建出相位信息和振幅信息;上海光学精密机械研究所的司徒国海团队^[20]提出了 eHoloNet 结构,该结构对 U-Net 网络进行改进得到,从而简化了传统重建算法过程中需要去除零级干扰和孪生图像两个步骤,该深度学习模型只需一步就可以重建出波前信息,同时不用考虑参考光束是平面波还是球面波。这些研究工作证明了深度学习技术用于数字全息重建的可行性与有效性。

尽管深度学习让数字全息的波前重建变得简便和快速,但现有的网络结构在训练深度学习模型时基本都只采用了某一特定尺度的数字全息图,导致训练完成的模型只能重建与训练集相同尺度的数字全息图。对于机器视觉领域来说,可以通过缩放、裁剪等手段将不同尺度的图片统一到某一特定的尺度来解决此类问题;但对于数字全息图来说,

其在获得的时候尺度就已经确定了,为保证空间带宽积(SBP)不变^[24],也就是数字全息图包含的信息不发生改变,数字全息图的裁剪和缩放具有严格的限制。因此传统的图像缩放与裁剪方法无法用于数字全息图,不同尺度的数字全息图通常不能统一为相同尺度进行学习。针对这些问题,本文基于 U-Net 网络结构^[25]进行改进,得到一个三层的卷积神经网络结构,使用不同尺度的数字全息图对不同的层进行训练,得到可以对不同尺度数字全息图进行重建的深度学习模型。

2 原理和方法

2.1 数字全息波前记录与传统重建

数字全息记录原理如图 1 所示,物光波传播到全息记录面与参考光相干叠加,形成干涉条纹,使用 CCD 记录干涉条纹图像,获得数字全息图。

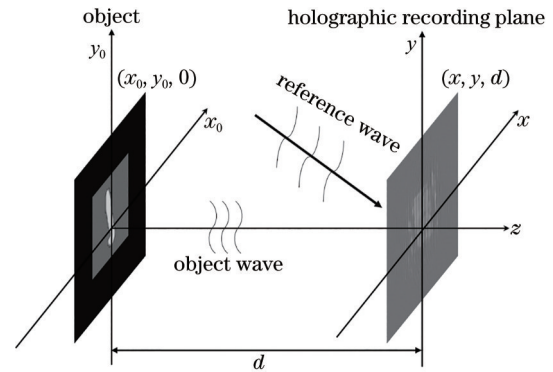


图 1 全息波前记录示意图

Fig. 1 Schematic of holographic wavefront recording

设物平面分布函数为 $O(x_0, y_0)$, 相干光照明后到达全息记录面的物光波复振幅可使用角谱衍射公式计算得到:

$$O(x, y) = F^{-1} \left\{ F \left[O(x_0, y_0) \right] \exp \left[j \frac{2\pi}{\lambda} d \sqrt{1 - (\lambda f_{x_0})^2 - (\lambda f_{y_0})^2} \right] \right\}, \quad (1)$$

式中: F 为傅里叶变换; F^{-1} 为傅里叶逆变换; d 为物平面到全息记录平面的距离。为简明起见, 设 $O(x, y) = A_o(x, y) \exp[j\varphi_o(x, y)]$, 其中 $A_o(x, y)$ 和 $\varphi_o(x, y)$ 分别表示物光波振幅和相位分布, 设全息记录平面上参考光波复振幅为 $R(x, y) = A_r(x, y) \exp[j\varphi_r(x, y)]$, $A_r(x, y)$ 和 $\varphi_r(x, y)$ 分别表示参考光波振幅和相位分布, 则数字全息图记录面上光强分布可表示为

$$I(x, y) = |O(x, y) + R(x, y)|^2 = |O(x, y)|^2 + |R(x, y)|^2 + O(x, y)R^*(x, y) + O^*(x, y)R(x, y), \quad (2)$$

式中: $|O(x, y)|^2$ 和 $|R(x, y)|^2$ 分别表示物光和参考光的光强信息; 第三项为共轭参考光调制的物光

波; 第四项为参考光调制的共轭物光波。因此, 数字全息图包含了物体的振幅和相位信息。

传统数字全息再现原理如图 2 所示,使用再现光波照射数字全息图,然后进行零级干扰、孪生图像去除和相位解包裹等处理后即可得到重建像,由于使用深度学习来重建数字全息图,未

涉及上述处理,因此未对这些处理进行一一赘述。

设再现光波为垂直照明的平面波 $Z(x, y)$, 照明数字全息图后的衍射光波可表示为

$$I'(x, y) = Z(x, y)I(x, y) = Z(x, y) \left[|R(x, y)|^2 + |O(x, y)|^2 \right] + Z(x, y)R^*(x, y)O(x, y) + Z(x, y)R(x, y)O^*(x, y) \quad (3)$$

则可根据角谱衍射计算公式得到重建物光场:

$$O(x_i, y_i) = F^{-1} \left\{ F \left[I'(x, y) \right] \exp \left[j \frac{2\pi}{\lambda} d \sqrt{1 - (\lambda f_x)^2 - (\lambda f_y)^2} \right] \right\} \quad (4)$$

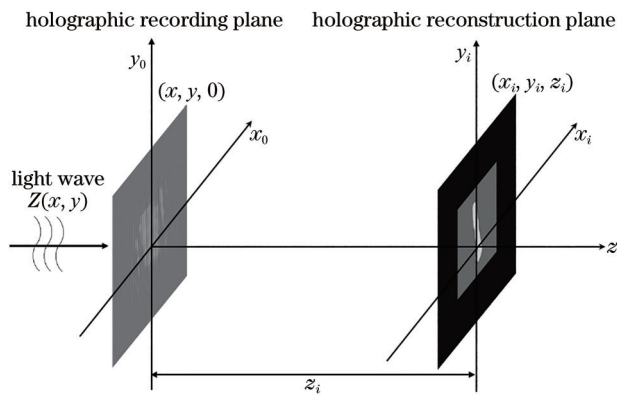


图 2 数字全息重建示意图

Fig. 2 Schematic of digital holographic reconstruction

2.2 神经网络结构

共进行两组实验,第一组实验使用的网络结构如图 3 所示,其中 $W \times H$ 表示输入图像的尺度, $W/2 \times H/2$ 表示输入 $W \times H$ 尺度的数字全息图经最大池化后尺度变为原来的 $1/2$, 依此类推。矩形框表示经过不同操作模块之后提取到的特征图。

2) 下采样使用池化核大小为 2×2 的最大池化来实现,作用是为了降低特征图的尺度并保留有效信息(经过池化层后,特征图大小变为原来的 $1/2$), 增大感受野,同时能在一定程度上避免过拟合,降低后续网络结构参数的计算难度。

3) 使用最近邻填充,目的是逐步解码以恢复原始图像大小,经过上采样块之后,特征图大小变为原来的 2 倍。

4) 跳远连接把浅层网络和深层网络输出的特征图通道连接到一起,结果作为下一层的输入,使得更深层的网络能保留有用的浅层信息,同时避免梯度消失,提高网络性能。

当前特征图的通道数量在矩形框上方表示,其中 1 表示输入和输出都是灰度图像;C1 表示当前特征图的通道数不确定,由具体的实验需要来给定;2C1, 4C1 等分别表示当前特征图的通道数为 C1 值的 2 倍, 4 倍等。该网络结构主要有 5 个操作模块(如图 3 右下角图例所示): 分层分割块(HS-Block)^[26]、下采样块、上采样块、跳远连接、输出卷积层,模块的具体说明如下。

1) 分层分割块(HS-Block)的结构如图 4 所示。基本思想是先用卷积核大小为 3×3 的卷积提取特征图,并执行 BatchNorm 和 ReLU 操作,然后将输出特征图的通道均分为 5 组。第一组的输出直接输入到下一层;第二组的输出同样经过卷积核大小为 3×3 的卷积层,进行特征提取,然后再将通道均分为两个子组,其中一子组直接输入到下一层,另外一个子组和第三组输出连接在一起,然后再经过卷积进行更深的特征信息提取,然后均分,重复该步骤,直到处理完第五组特征图;然后把所有的输出特征图的通道拼接在一起,汇总输入给网络的下一层。这种处理方式的好处是网络提取出更多尺度特征的同时降低了网络模型参数的数量,去除了冗余的特征信息,大大降低了网络模型的计算成本,使得深度学习模型更容易训练,重建时的速度更快。

5) 输出卷积层仅是一层卷积层和激活层的组合,目的是输出单通道的图像。

第二个实验所用到的网络结构如图 5 所示,网络是在改进的 U-Net 网络基础上扩展得到的,共有三个操作模块(图 5 右下角所示),结构中的 U-Net 是图 3 结构中虚线框所示的网络结构,其他模块的作用和图 3 网络结构对应的模块一样。矩阵框上面的数字表示当前特征图的通道数,1 表示输入和输出都是灰度图像,40, 20, 20 表示通道数的同时还表示所采用到的改进 U-Net 结构中的 C1 分别等于 40, 20, 20。该结构从上到下分为三层,最开始只有最上一层结构,用来训练尺度为 256×256 的数字全

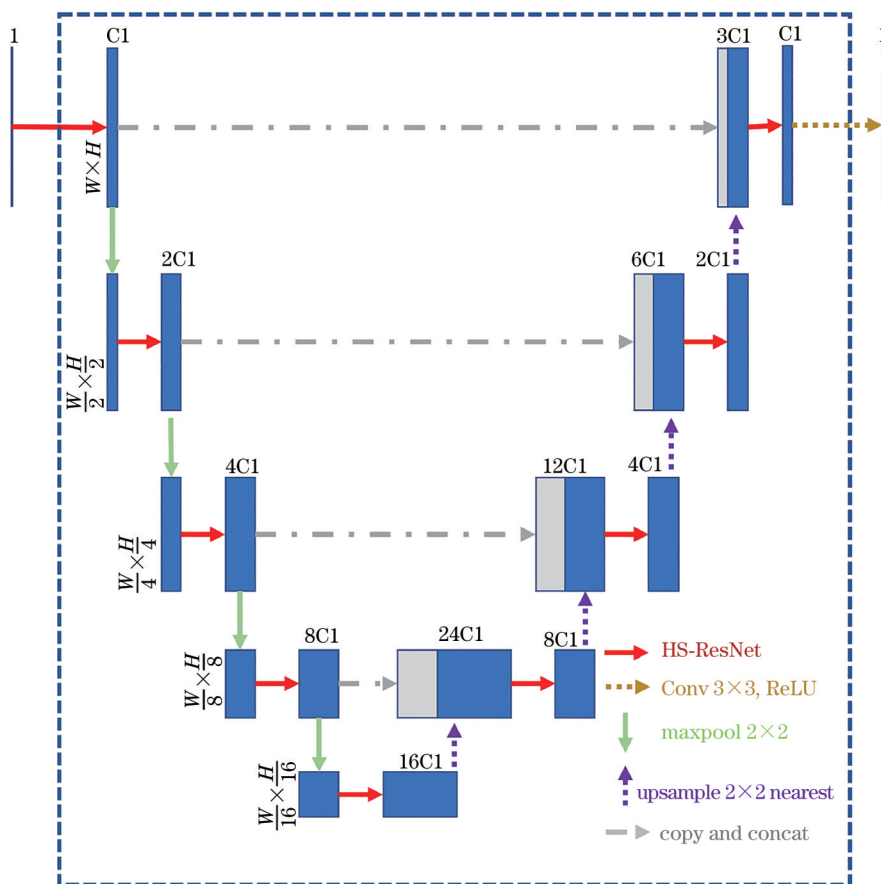


图 3 改进后的 U-Net 结构, 当前特征图的尺寸位于矩形框的左侧

Fig. 3 Improved U-Net structure, the size of the current feature map is located at the left of the rectangular box

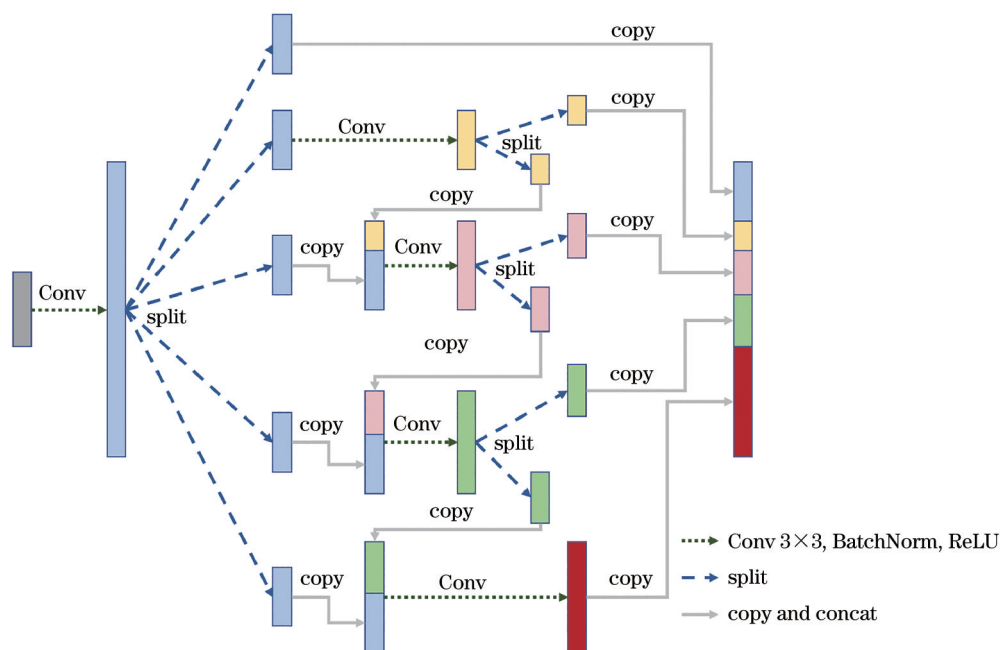


图 4 HS-Block 结构

息图, 完成之后固定当前模型参数。增加第二层网络结构, 让尺度为 512×512 的数字全息图经过

第一层和第二层网络结构, 但是只训练第二层网络结构参数, 然后固定第二层网络的参数。增加




图 5 可重建多种尺度数字全息图的神经网络结构

Fig. 5 Network structure for reconstructing multi-scale digital holograms

第三层网络结构,让 640×480 的数字全息图经过所有的网络,同样只训练第三层的网络参数。这样做的目的是减少网络总参数,因为上一层网络提取的部分特征图对于下一层的网络是有用的。该网络结构可以避免重复提取这些相同的特征图,进而减少模型参数,同时使一个深度学习模型能对多种尺度的数字全息图进行重建。

2.3 数据集的生成与网络训练

使用计算机模拟数字全息成像时生成的数字全息图。振幅信息是把 MNIST 数据集中的 1.8 万张手写字体图片放大到不同尺度得到的,相位信息是 1.8 万个汉字图像经归一化后放大到不同尺度再乘以 1.9π 得到的,照明物体的光波波长 $\lambda=632.8 \text{ nm}$,物体到全息记录面的距离 $d=0.3086 \text{ m}$,全息记录面的尺寸为 5 mm 。参考光为平行参考光,且参考光与 x 轴和 y 轴夹角分别为 $\pi/2.02$ 和 $\pi/2$,抽样数分别为 256×256 , 512×512 , 640×480 ,然后使用 (1) 式计算得到到达数字全息面的物光波复振幅分布,并与参考光波进行相干叠加,得到三种尺度的数字全息图各 6000 张,选择每种尺度的数字全息图 5000 张作训练集,1000 张作测试集。

训练损失函数采用均方误差损失函数 (MSELoss),该函数表示预测数据和原始数据对应点误差的平方和,表达式为

$$l_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2, \quad (5)$$

式中: n 表示图片的尺度大小; y_i 表示重建后振幅信息或相位信息的第 i 个值; \bar{y}_i 表示原始信息所对应的第 i 个值。采用 Adam 优化算法来优化权重,当测试

集误差上升时,采用提前终止的方法来防止过拟合。使用 Pytorch 搭建深度学习模型,并在 Nvidia RTX 2080Ti 上完成训练。

3 实验结果与分析

为证明所提深度学习模型可以重构出三种不同尺度的数字全息图,进行两组实验。第一组实验,混合不同尺度的数字全息图形成数据集,使用图 3 所示改进后的 U-Net 网络结构,训练之后得到所需深度学习模型。第二组实验,使用图 5 所示的网络结构,使用不同尺度的数字全息图依次对其进行训练并固定参数,从而得到一个可以同时重建不同尺度数字全息图的深度学习模型。为了减少单个模型参数和减小所需 GPU 内存,对振幅信息和相位信息分别进行训练,得到两个模型,一个用来重建振幅信息,另外一个用来重建相位信息。

3.1 混合不同尺度的数字全息图形成数据集训练网络

本次实验中,针对目前使用深度学习进行全息重建时只能重建单一尺度的数字全息图这个问题,把不同尺度的数字全息图打乱(否则会导致训练当前尺度的数字全息图时损失函数下降,训练下一尺度时反而上升,进而导致无法训练)混合形成训练集,网络模型选择图 3 所示的神经网络结构,其中 C1 值为 120(数据集复杂,需要更宽的卷积网络模型),然后把混合的数据集用于训练网络。训练时保证每个 Batch 输入的数字全息图尺度大小一致(否则无法训练),从而得到分别重建振幅信息和相位信息的两个网络模型。模型重建结果如图 6 所示。

图 6 是混合不同尺度的数字全息图作为数据集来训练深度学习模型时对不同尺度数字全息图的重建效果对比。从图中的结果可以看出,混合不同尺度的数字全息图作为数据集训练出的深度学习模型完全无法重建出数字全息图的相位信息,虽然能重建出振幅信息,但观察到重建的振幅图像出现模糊现象,即重建准确度不是很高。同时网络模型比较大,需要较大的 GPU 内存才能完成训练,训练时还要严格控制每个 Batch 输入数字全息图的尺度相同。这些问题都表明简单的混合不同尺度的数字全息图作为数据集来训练深度学习模型时,对多种尺度的数字全息图进行重建是不可行的。

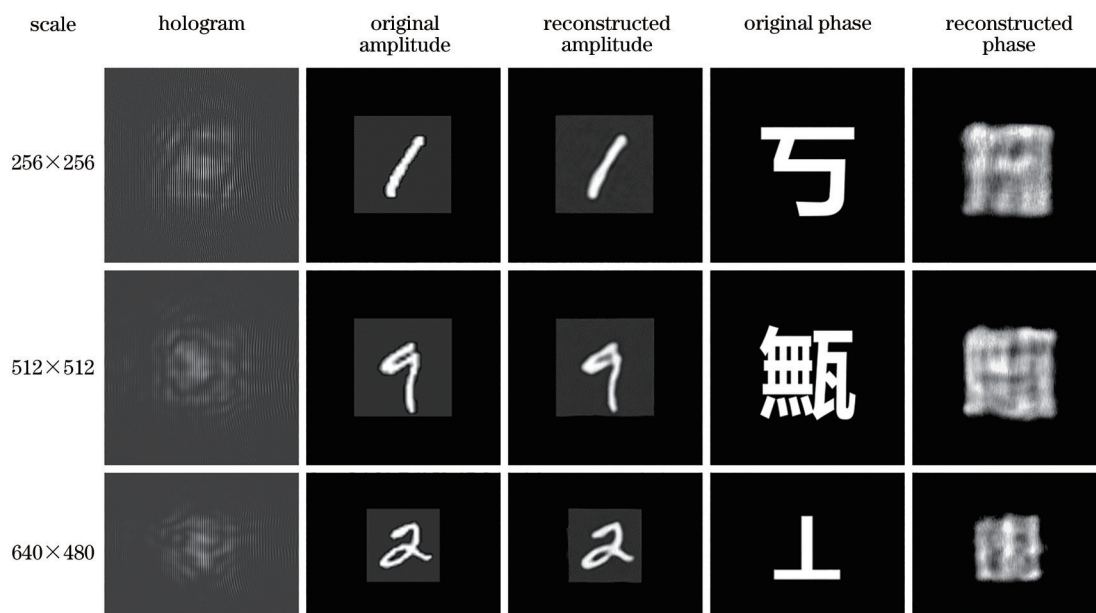


图 6 混合不同尺度的数字全息图作为数据集训练深度学习模型时,对不同尺度数字全息图的重建效果对比
Fig.6 Mixing digital holograms with different scales as a data set training deep learning model to compare the reconstruction effect of different resolution digital holograms

3.2 不同尺度的数字全息图分别训练网络中的一层

3.1 节表明简单的混合不同尺度的数字全息图训练深度学习模型时依然得不到较好的结果。因此对改进过后的 U-Net 网络再进行扩展,得到图 5 所示的网络结构。训练时首先使用尺度为 256×256 的数字全息图数据集训练图 5 中最上层的网络模块,完成后固定参数;新增第二层网络模块,让 512×512 数字全息图数据集通过第一层和

第二层网络,但是第一层参数是固定的,只训练第二层的网络参数,然后固定第二层网络的参数;最后增加第三层网络模块,让 640×480 数字全息图经过整个网络,第一、二层参数保持不变,只训练第三层网络参数。其原因是某种尺度的数字全息图训练的网络提取到的一些特征图对其他尺度特征图来说同样是有用的,这样避免冗余,进而使得深度学习模型更为精简。该深度学习模型重建结果如图 7 所示。

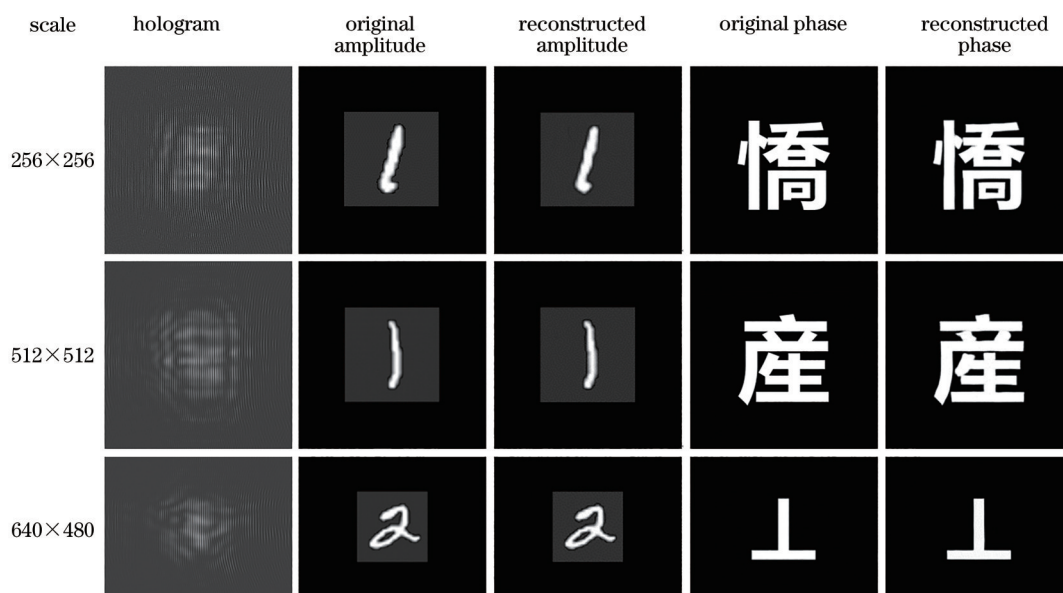


图 7 单个深度学习模型对不同尺度数字全息图重建结果对比
Fig.7 Comparison of reconstruction results of different scale digital holograms by a single deep learning model

从图 7 可以看出,该模型可以重建出 256×256 , 512×512 , 640×480 三种尺度的数字全息图,人眼观察发现重建后的信息和原始信息几乎没有区别。表 1 给出网络模型在测试集的平均峰值信噪比 (PSNR) 和结构相似性 (SSIM) 值,可看出,该网络

模型重建三种尺度的数字全息图波前信息结果较为精确,重建出的振幅信息或相位信息与原始信息差距都很小 (PSNR 和 SSIM 值都比较大)。由此说明所提网络模型与训练方法能使单个深度学习模型准确重建出多种尺度的数字全息图。

表 1 测试集的平均 PSNR 和 SSIM
Table 1 Average PSNR and SSIM of test set

Parameter	256×256		512×512		640×480	
	Amplitude	Phase	Amplitude	Phase	Amplitude	Phase
PSNR /dB	32.4708	25.4167	45.8376	28.3130	41.4651	37.7251
SSIM	0.9689	0.8685	0.9981	0.8748	0.9953	0.9131

提出的网络可用单个深度学习模型重建出三种不同尺度数字全息图的波前信息,但仍然存在一些问题。实验中为了得到完整的波前信息,采用了计算机模拟生成数字全息图,这样避免了杂散光和散斑的干扰,降低了全息重建的难度,但训练后的网络还不能直接对实验拍摄的数字全息图进行重建,要实现真实拍摄数字全息图的重建,还需要增加训练的数据集;同时由于 GPU 内存的限制,无法实现单个网络模型同时重建振幅和相位信息。在以后的研究中,考虑获取真实拍摄的数字全息图及其对应的波前信息作为训练集,并使用 GPU 集群来训练深度学习模型,提高模型的实用性。

4 结 论

针对现有使用深度学习对数字全息图进行重建的算法进行了研究,提出一种改进的 U-Net 网络结构,实现了同一网络结构对不同尺度数字全息图进行训练的功能。为验证改进网络结构的正确性,进行了两组实验,第一组实验的结果表明了简单的混合不同尺度的数字全息图作为数据集来训练深度学习模型时对数字全息图进行重建是不可行的,同时训练条件较为苛刻。第二组实验在第一组实验的基础上,改进网络模型并改变训练方法,减少网络模型参数的同时,使得单个深度学习模型就能重建出多种尺度数字全息图相位信息或振幅信息,相对于使用多个模型来重建不同尺度数字全息图的波前信息网络,该网络模型的实现更简单同时更容易训练。

参 考 文 献

[1] Gabor D. A new microscopic principle[J]. Nature, 1948, 161(4098): 777-778.

[2] Li J C. Diffraction calculation and digital holography [M]. Beijing: Science Press, 2014.
李俊昌. 衍射计算及数字全息[M]. 北京: 科学出版社, 2014.

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

[4] Li J C, Song Q H, Pascal P, et al. Discussion of wavefront reconstruction algorithm of off-axis digital holography[J]. Chinese Journal of Lasers, 2014, 41(2): 0209008.
李俊昌, 宋庆和, Pascal P, 等. 离轴数字全息波前重建算法讨论[J]. 中国激光, 2014, 41(2): 0209008.

[5] Qian X F, Li B, Li X H, et al. Improvement of least-square phase unwrapping algorithm based on lateral shearing interferometry[J]. Chinese Journal of Lasers, 2012, 39(11): 1109002.
钱晓凡, 李斌, 李兴华, 等. 横向剪切最小二乘相位解包裹算法的改进[J]. 中国激光, 2012, 39(11): 1109002.

[6] Guo Y, Chen X T. Study of improved phase unwrapping algorithm based on least squares[J]. Chinese Journal of Lasers, 2014, 41(5): 0508005.
郭媛, 陈小天. 基于最小二乘相位解包裹改进算法的研究[J]. 中国激光, 2014, 41(5): 0508005.

[7] Xiong W, Droppo J, Huang X, et al. Achieving human parity in conversational speech recognition [EB/OL]. (2016-10-17) [2021-02-25]. <https://arxiv.org/abs/1610.05256>.

[8] Bochkovskiy A, Wang C Y, Liao H Y M. YOLOv4: optimal speed and accuracy of object detection[EB/OL]. (2020-04-23) [2021-02-25]. <https://arxiv.org/abs/2004.10934>.

[9] Qin L B, Ni M H, Zhang Y, et al. CoSDA-ML: multi-lingual code-switching data augmentation for zero-shot cross-lingual NLP[C]//Proceedings of the Twenty-Ninth International Joint Conference on

- Artificial Intelligence, July 11-17, 2020, Yokohama, Japan. California: International Joint Conferences on Artificial Intelligence Organization, 2020: 3853-3860.
- [10] Zhao F, Zhu L X, Fang C Y, et al. Deep-learning super-resolution light-sheet add-on microscopy (Deep-SLAM) for easy isotropic volumetric imaging of large biological specimens[J]. *Biomedical Optics Express*, 2020, 11(12): 7273-7285.
- [11] Xiao K, Tian L J, Wang Z Y. Fast super-resolution fluorescence microscopy imaging with low signal-to-noise ratio based on deep learning[J]. *Chinese Journal of Lasers*, 2020, 47(10): 1007002.
肖康, 田立君, 王中阳. 基于深度学习的低信噪比下的快速超分辨荧光显微成像[J]. *中国激光*, 2020, 47(10): 1007002.
- [12] 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.
孟磊, 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.
- [13] 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.
- [14] Ren Z B, Xu Z M, Lam E Y. Autofocusing in digital holography using deep learning[J]. *Proceedings of SPIE*, 2018, 10499: 104991V.
- [15] 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.
- [16] Yin D, Gu Z Z, Zhang Y R, et al. Digital holographic reconstruction based on deep learning framework with unpaired data[J]. *IEEE Photonics Journal*, 2019, 12(2): 1-12.
- [17] Li H Y, Chen X W, Chi Z Y, et al. Deep DIH: single-shot digital in-line holography reconstruction by deep learning[J]. *IEEE Access*, 2020, 8: 202648-202659.
- [18] 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.
- [19] Wang K Q, Dou J Z, 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.
- [20] 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.
- [21] Ren Z B, Xu Z M, Lam E Y M. End-to-end deep learning framework for digital holographic reconstruction [J]. *Advanced Photonics*, 2019, 1(1): 016004.
- [22] 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.
- [23] 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.
- [24] Jin G F, Zhang H, Su P. Computer-generated holograms[M]. Beijing: Science Press, 2020.
金国藩, 张浩, 苏萍. 计算机全息图[M]. 北京: 科学出版社, 2020.
- [25] 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.
- [26] Yuan P C, Lin S F, Cui C, et al. HS-ResNet: hierarchical-split block on convolutional neural network[EB/OL]. (2020-10-15)[2021-02-25]. <https://arxiv.org/abs/2010.07621>.