

引用格式: LIU Hang, XIAO Yong-liang, TIAN Jun-long, *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

# 基于深度学习的离轴菲涅耳数字全息非线性 重构

刘航,肖永亮,田军龙,李红星,钟建新  
(湘潭大学 物理与光电工程学院, 湖南湘潭 411105)

**摘 要:**针对离轴菲涅耳数字全息图,提出基于深度学习的单幅数字全息非线性重构方法.采用经典的菲涅耳衍射积分模拟数字全息成像以供给网络训练所需样本,利用深度卷积残差神经网络通过学习数字全息图与相关物像之间的非线性数学映射关系实现全息图的物像重构.数值模拟表明,与传统的频率滤波和四步相移技术实现菲涅耳数字全息重构相比,本文提出的方法可直接消除零级像及孪生像,无需条纹物项抽取预处理步骤,且重构的物像具有较高的质量,针对相同记录参考光下不同衍射距离所生成的测试集亦具有较强的稳健性.

**关键词:**数字全息;菲涅耳衍射;深度学习;计算成像;衍射距离

中图分类号:O438

文献标识码:A

doi:10.3788/gzxb20204907.0709001

## Nonlinear Reconstruction for Off-axis Fresnel Digital Holography with Deep Learning

LIU Hang, XIAO Yong-liang, TIAN Jun-long, LI Hong-xing, ZHONG Jian-xin  
(School of Physics and Optoelectronic Engineering, Xiangtan University, Xiangtan, Hunan 411105, China)

**Abstract:** A nonlinear reconstruction method with a single digital hologram using deep learning was proposed for off-axis Fresnel digital hologram. Classic Fresnel diffraction integral is utilized for simulating digital holographic imaging to provide the training samples, and a deep convolution residual neural network is utilized to implement on the object image reconstruction from the recorded hologram, by learning the nonlinear mathematical mapping from the digital hologram to the corresponding object image. The results of numerical simulation experiments show that the method could directly eliminate zero-order images and twin images without fringe pre-processing procedure for extracting object term, compared with the traditional frequency filtering and four-step phase-shift techniques for achieving Fresnel digital holography reconstruction, as well as high quality reconstructed object image. It also has strong robustness to the test dataset generated with different diffraction distances using same recording reference light waveform.

**Key words:** Digital holography; Fresnel diffraction; Deep learning; Computational imaging; Distance diffraction

**OCIS Codes:** 090.1995; 100.4996; 110.1758; 110.3010

基金项目:国家自然科学基金(Nos.51772255, 61805208),湖南省教育厅科学研究项目(No.18C0093),湘潭大学人才引进科研启动项目(No.KZ03038)

第一作者:刘航(1995-),男,硕士研究生,主要研究方向为基于深度学习的相干光场相位恢复技术. Email:liuhjack@163.com

导师(通讯作者):肖永亮(1983-),男,讲师,博士,主要研究方向为计算成像与深度学习. Email:ylixiao@xtu.edu.cn

收稿日期:2020-03-26;录用日期:2020-05-20

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

## 0 引言

数字全息术<sup>[1-2]</sup>是一种利用光电传感器取代传统全息干板记录干涉条纹的全息成像方法,通过数值计算模拟光学衍射过程重构物像强度分布.数字全息以其精度高且成像速度快的优点,被广泛应用于数字全息显微镜<sup>[3]</sup>、信息安全存储<sup>[4]</sup>、光学加密<sup>[5]</sup>以及太赫兹成像<sup>[6]</sup>等诸多领域.传统方法主要采用频域滤波或时域相移技术通过消除数字全息图的零级像及孪生像实现物像强度衍射重构.然而频域滤波的方法<sup>[7]</sup>仅适用于零级像和±1级像没有重叠的情况;基于四步相移的方法<sup>[8]</sup>中参考光所记录的全息图需要经过条纹预处理后才能重构物像.

深度学习<sup>[9]</sup>是具有多层次表达特性的神经网络学习方法,通过级联多层非线性模块获得,每个模块从原始输入开始将一个低层次表示转换为一个更高、更抽象层次的表示(例如属性、类别和特征等).有了足够深的非线性数学映射关系,就可以学习逼近非常复杂的函数.近年来,深度神经网络(Deep Neural Network, DNN)被应用于显微成像<sup>[10]</sup>,散射成像<sup>[11]</sup>以及鬼成像<sup>[12]</sup>等多类成像问题,并取得了重大进展.事实证明,DNN非常善于在成像问题的高维数据中发现复杂特征.近年来,DNN也被广泛应用于相干光场成像中的反演问题.SINHA A等<sup>[13]</sup>将DNN用于无透镜计算成像,证明DNN可以解决计算成像中的端到端逆问题;RIVENSON Y等<sup>[14]</sup>提出基于DNN的同轴全息图重构和相位恢复方法;WU Y等<sup>[15]</sup>将基于U-Net的自动聚焦及相位恢复功能用于扩展全息成像的景深.WANG H等<sup>[16]</sup>提出基于DNN端对端的同轴数字全息图重构方法,并在一步过程中消除零级像和孪生像;ZHANG G等<sup>[17]</sup>将U-net应用于离轴数字全息显微镜系统,实现快速数字对焦与相位补偿;WANG K等<sup>[18]</sup>提出Y-Net,采用单幅数字全息图同时重构强度和相位信息;REN Z等<sup>[19]</sup>提出基于HR-Net端对端的数字全息图重构方法.上述基于深度学习的全息图重构方法没有涉及光波干涉物像重构的数学建模,实际上是直接通过DNN隐形地学习全息强度图与物像之间的非线性数学映射关系实现全息图的物像重构,但并不意味着忽略了相干干涉记录的物理过程.

本文利用深度学习在解决相干光场反演问题中的巨大潜力,提出基于卷积残差神经网络(Residual Neural Network, ResNet)<sup>[20]</sup>的单幅离轴菲涅耳数字全息图非线性物像重构.与上述[15]、[17]所采用的基于U-Net以及[18]、[19]的其他两种结构不同,本文网络结构的外型类似于U-Net<sup>[21]</sup>,但添加了局部残差及全局残差计算层,用以学习输入图像更多的特征细节.本文采用MNIST手写数据集通过菲涅耳衍射的卷积算法(T-FFT)数值模拟生成的离轴菲涅耳数字全息图作为训练与测试样本,并利用ResNet学习数字全息图与相应物像之间的非线性数学映射关系.一旦ResNet训练成功,在基于图形处理单元的电脑上可以快速重构物像,并成功的消除零级像及孪生像,无需滤波与相移技术的条纹预处理步骤.采用记录参考光为平面波或球面波的数字全息图验证,测试在相同参考光与衍射距离下神经网络对不同衍射距离全息图重构的稳健性,并进一步采用不同衍射距离所生成的训练集共同训练对距离稳健ResNet,并测试其在记录参考光为平面波时的测试集对衍射距离的稳健性.

## 1 离轴菲涅耳数字全息物理模型

### 1.1 数字全息记录

菲涅耳全息图是指相干光通过物体衍射到达位于菲涅耳衍射区的全息记录面上与记录参考光发生干涉后所记录的全息图<sup>[22]</sup>.离轴菲涅耳数字全息图记录光路示意图如图1所示.物光 $O(x_0, y_0)$ 通过距离为 $z_0$ 的菲涅耳衍射与全息记录面上的离轴记录参考光 $R(x, y)$ 发生干涉,因此全息记录面上的干涉光强 $I(x, y)$ 可表示为

$$I(x, y) = \left| R(x, y) + \text{FrT} \left\{ O(x_0, y_0); z_0 \right\} \right|^2 \quad (1)$$

$$I(x, y) = \left| R(x, y) \right|^2 + \left| \text{FrT} \left\{ O(x_0, y_0); z_0 \right\} \right|^2 + R(x, y)^* \text{FrT} \left\{ O(x_0, y_0); z_0 \right\} + R(x, y) \text{FrT} \left\{ O^*(x_0, y_0); z_0 \right\} \quad (2)$$

$$I(x, y) = |R|^2 + |O|^2 + R^*O + O^*R \quad (3)$$

式中,  $(x_0, y_0)$  表示物面坐标,  $(x, y)$  表示全息记录面的坐标,  $\text{FrT}\{O(x_0, y_0); z_0\}$  表示物光  $O(x_0, y_0)$  通过衍射距离为  $z_0$  的菲涅耳衍射, 符号\*表示相位共轭.

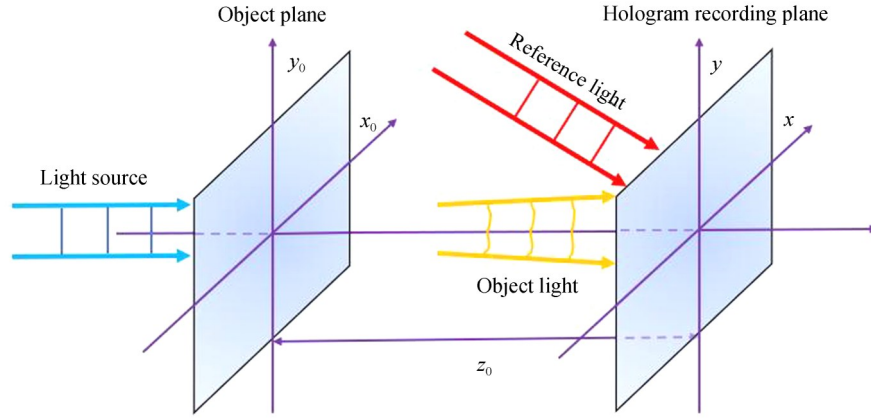


图 1 离轴菲涅耳数字全息图记录示意图

Fig. 1 Schematic diagram of off-axis Fresnel digital hologram recording

## 1.2 传统的数字全息图重构

根据式(3)将光电传感器记录的数字全息图光强表示为

$$I_D(x, y) = \Pi(x, y) \left( |R|^2 + |O|^2 + R^*O + O^*R \right) \quad (4)$$

式中,  $\Pi(x, y)$  表示光电传感器的窗口函数. 模拟照明光波  $C(x, y) = 1$  垂直照射全息图以及出射光到观察面距离为  $z_0$  的衍射过程, 可在观察面上得到含有零级像及孪生像的数字全息图重构强度像. 本文采用数值计算方法模拟传统的频率滤波法与四步相移法预处理后衍射消除零级像及孪生像用以对比本文所提出的方法, 具体方法如下.

### 1) 频域滤波法

首先对  $I_D(x, y)$  做傅里叶变换, 然后选择像素范围一定的带通滤波器  $H(\epsilon, \eta)$  进行滤波操作, 用于消除“0”级频谱  $F[\Pi(x, y)|R|^2] + F[\Pi(x, y)|O|^2]$  以及“+1”级频谱  $F[\Pi(x, y)R^*O]$ , 仅保留“-1”级频谱  $F[\Pi(x, y)O^*R]$ . 滤波后的频谱可表示为

$$H(\epsilon, \eta) F[I_D(x, y)] = H(\epsilon, \eta) \left\{ F[\Pi(x, y)|R|^2] + F[\Pi(x, y)|O|^2] + F[\Pi(x, y)R^*O] + F[\Pi(x, y)O^*R] \right\} \quad (5)$$

$$H(\epsilon, \eta) F[I_D(x, y)] \approx F[O^*R] \quad (6)$$

式中,  $F[\cdot]$  表示傅里叶变换,  $\epsilon = x/\lambda f$ ,  $\eta = y/\lambda f$ . 然后将滤波后的频谱做逆傅里叶变换保留物的共轭项并进行菲涅耳数字衍射可基本消除数字全息图的零级像及孪生像. 此方法重构的物像质量受零级像和±1级像重叠情况以及窗口函数的影响.

### 2) 四步相移法

在四步相移法中,  $R(x, y) = r(x, y) \exp[j\varphi(x, y)]$  通过依次相移可得到四种参考光  $R_n(x, y) = r(x, y) \exp[j\varphi(x, y)] \exp[j2\pi n/4]$  ( $n = 1, 2, 3, 4$ ), 式中  $R_1(x, y) = R(x, y)$ ,  $R_2(x, y) = jR(x, y)$ ,  $R_3(x, y) = -R(x, y)$ ,  $R_4(x, y) = -jR(x, y)$ . 然后在全息记录面上分别采用这四种参考光与物光发生干涉可得到四幅全息图  $I_1, I_2, I_3, I_4$ . 最后模拟相对应的参考光照明这四幅全息图并相加就可得到

$$R_1 I_1 + R_2 I_2 + R_3 I_3 + R_4 I_4 = 4\Pi(x, y) r^2(x, y) O(x, y) \quad (7)$$

由式(7)可计算出物像  $O(x, y)$ , 但其振幅被参考光强  $r^2(x, y)$  调制. 当参考光强在窗口函数  $\Pi(x, y) \neq 0$  的范围内基本均匀时, 实际光路场景需要采用精密的相移器得到4幅依次相移的参考光, 然后采用这四种参

考光分别干涉全息记录面上的物光,记录四幅全息图相加并数字衍射获得全息图的重构物像.

## 2 数值模拟实验

### 2.1 基于深度学习的离轴菲涅耳数字全息图非线性重构

借鉴DNN在解决相干光场成像中的反演问题等方面的应用实例,提出基于深度学习的单幅离轴菲涅耳数字全息图非线性重构方法.物像 $O(x_0, y_0)$ 通过采用T-FFT算法的离轴菲涅耳数字全息得到数字全息图光强 $I(x, y)$ .ResNet用于训练数字全息图光强 $I(x, y)$ 和相关的训练物像集 $O(x_0, y_0)$ 之间的非线性数学映射关系.最后,将训练集中未使用的测试集数字全息图光强应用到已经训练好的ResNet模型实现重构物像 $\hat{O}(x_0, y_0)$ .基于深度学习的离轴菲涅耳数字全息图重构过程如图2所示.

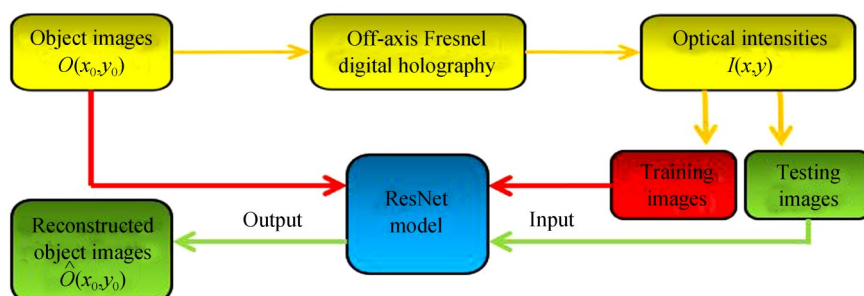


图2 基于深度学习的离轴菲涅耳数字全息图重构方法

Fig. 2 Method for off-axis Fresnel digital hologram reconstruction based on deep learning

根据式(2),物像 $O(x_0, y_0)$ 转换到全息记录面上的光强 $I(x, y)$ 可简化为

$$I(x, y) = D[O(x_0, y_0)] \quad (8)$$

式中, $D[\cdot]$ 表示离轴菲涅耳数字全息操作的正向算符.因此,通过设计和调整ResNet的网络结构,建立 $N[I(x, y)]$ 重构物像 $\hat{O}(x_0, y_0)$ ,其逆过程可简化为

$$\hat{O}(x_0, y_0) = N[I(x, y)] \quad (9)$$

式中, $N[\cdot]$ 表示采用ResNet学习离轴菲涅耳数字全息光强 $I(x, y)$ 到相关物像 $O(x_0, y_0)$ 的非线性数学映射关系. $N[\cdot]$ 在数学意义上不等于 $D[\cdot]$ 的逆运算.

解决这个问题的方法是采用一组由数字全息光强 $I(x, y)$ 和相关物像 $O(x_0, y_0)$ 组成的数据集来学习数字全息图重构物像的非线性逆映射操作,优化问题就可以表示为

$$\hat{O}(x_0, y_0) = \arg \min_{O(x_0, y_0)} \Psi \{O(x_0, y_0), N[I(x, y)], \beta[O(x_0, y_0)]\} \quad (10)$$

式中, $\Psi$ 表示 $O(x_0, y_0)$ 和 $N[I(x, y)]$ 之间的最小化损失函数, $\beta$ 表示 $O(x_0, y_0)$ 的正则化器.ResNet训练时可以隐性地学习神经网络的参数,并根据更新规则自动调整<sup>[23]</sup>.一旦ResNet训练成功就可以采用单个测试集数字全息光强 $I(x, y)$ 近似重构物像 $\hat{O}(x_0, y_0)$ .

### 2.2 ResNet的模型结构

设计和调整ResNet的模型结构时,充分考虑神经网络学习离轴菲涅耳数字全息图 $I(x, y)$ 与相关的物像 $O(x_0, y_0)$ 的特征之间的关系,然后采用单个测试集数字全息图 $I(x, y)$ 重构物像 $\hat{O}(x_0, y_0)$ .ResNet结构模型如图3所示,输入层是光强 $I(x, y)$ ;四个下采样卷积残差块“C”用于提取图像特征;四个上采样卷积残差块“D”用于重构图像特征;四个跳跃卷积块“S”可以防止停滞来优化深层,确保ResNet学习新特征;网络末端的两个卷积残差块“R”用于微调重构.

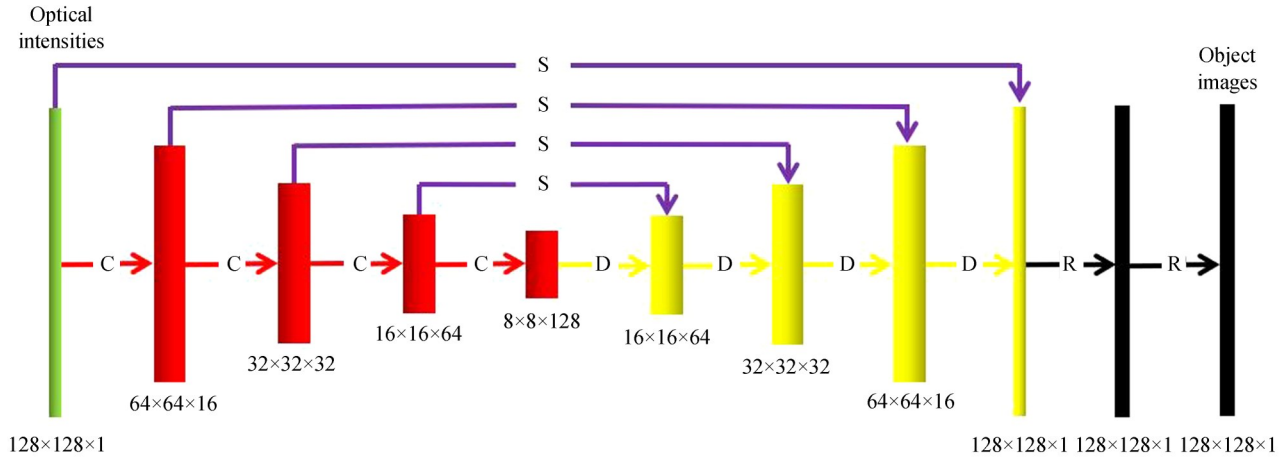


图3 ResNet 结构模型  
Fig. 3 The structure model of ResNet

ResNet 模型中的各模块结构如图 4 所示。“Conv (3, 2)”表示一个滤波器大小  $3 \times 3$  且步长为 2 的二维卷积层,完成卷积后输出图像像素的大小变为输入的一半;“DeConv(3, 2)”表示一个滤波器大小  $3 \times 3$  和步长为 2 的转置二维卷积层,采用 padding 操作完成转置卷积后输出图像像素的大小变为输入的 2 倍;“Conv (3, 1)”表示一个滤波器大小  $3 \times 3$  且步长为 1 的二维卷积层,完成卷积后输出图像像素的大小与输入的相同;“Batch Norm”表示批量归一化层<sup>[24]</sup>,用于最大限度的保证训练时分布统一,优化对权重的调整;“ReLU”表示线性整流层<sup>[25]</sup>,经过其处理后的数据会获得更好的稀疏性,并且可以避免梯度消失问题,加快网络收敛速度。“Batch Norm”和“ReLU”适用于本文 ResNet 中的所有模块,“ReLU”可表为  $\text{ReLU}(x) = \max(0, x)$ 。

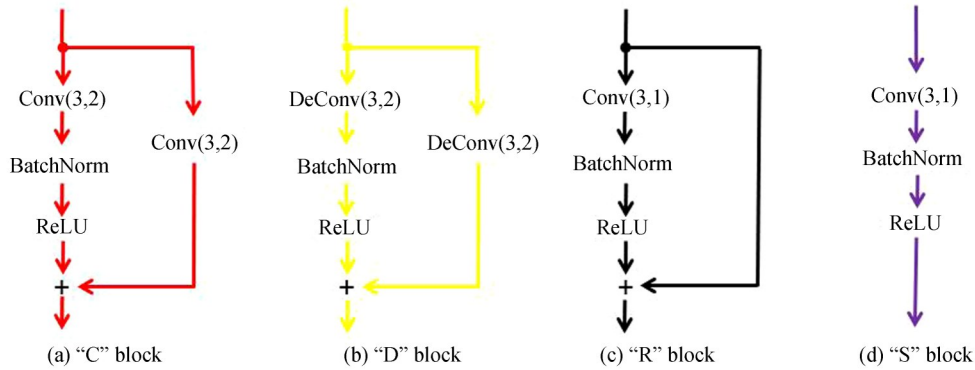


图4 ResNet 模型中的各模块结构  
Fig. 4 Structure of each module in ResNet model

### 2.3 ResNet 的训练方法

权重选择“Xavier”进行初始化<sup>[26]</sup>,偏置初始化为 0. 权重的初始化表示为  $\left[-\sqrt{\frac{6}{n+m}}, \sqrt{\frac{6}{n+m}}\right]$  的均匀分布,  $n$  和  $m$  分别表示输入和输出维度.

初始学习率设置为  $10^{-4}$ ,采用自适应矩估计(Adaptive Moment Estimation, ADAM)优化 ResNet 的权重和偏置<sup>[27]</sup>,并采用 L2 范数作为损失函数应用反向传播算法<sup>[28]</sup>实现参数更新. 损失函数定义为

$$L_2 = \min \frac{1}{2wh} \sum_{u=1}^w \sum_{v=1}^h (Y_{u,v} - O_{u,v})^2 \quad (11)$$

式中,  $w$  和  $h$  分别表示图像像素的宽度和高度.  $Y_{u,v}$  表示 ResNet 输出的重构物像,  $O_{u,v}$  表示相关的物像. 对于所有单物理场景的数据集,训练迭代步数均为 10 000.

### 3 模拟实验与结果分析

#### 3.1 数值模拟实验数据集的生成

分别选取 60 000 幅和 2 000 幅离轴菲涅耳数字全息图与相关物像作为训练与测试样本. 假设光源的光波波长为  $\lambda=632.8$  nm, 衍射物面与观察面中重构像的尺寸设置为 3.5 mm, 且像素的物理间距均为  $27.3$   $\mu\text{m}$ . 平面记录参考光与  $x$  轴之间的夹角为  $\alpha=\pi/2.02$ , 与  $y$  轴之间的夹角为  $\beta=\pi/2$ . 球面记录参考点光源的  $x$  坐标为  $x_r=5$  mm,  $y$  坐标为  $y_r=5$  mm, 半径为  $z_r=0.5$  m. 随机挑选的模拟实验训练样本如图 5 所示, 图 5(a) 表示训练集 MNIST 物像; 图 5(b)~5(d) 表示记录参考光为平面波, 衍射距离分别为  $z_0=0.3$  m, 0.4 m, 0.5 m 的数字全息图; 图 5(e)~5(g) 表示记录参考光为球面波, 衍射距离分别为  $z_0=0.3$  m, 0.4 m, 0.5 m 的数字全息图.

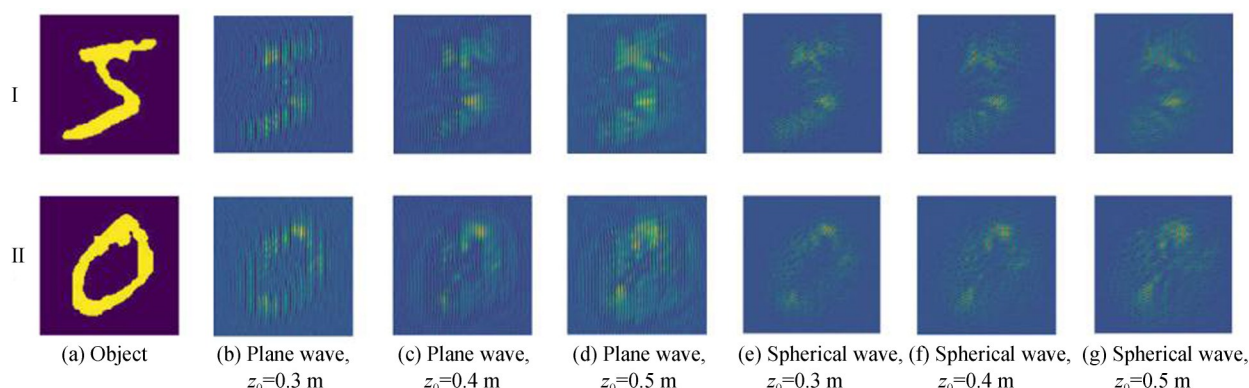


图 5 数值模拟实验训练样本

Fig. 5 Training samples of numerical simulation experiment

模拟生成数据集的具体步骤: 1) 采用手写数字图像(MNIST)作为物像, 将图像像素大小从  $28 \times 28$  调整为  $128 \times 128$ ; 2) 计算振幅调整至最大值 1 时的衍射物光场<sup>[29]</sup>; 3) 采用不同的衍射距离通过 T-FFT 算法数值模拟计算全息记录面上的物光场; 4) 采用不同的离轴记录参考光与全息记录面上的物光场发生干涉, 用 MATLAB 生成像素大小为  $128 \times 128$  离轴菲涅耳数字全息图; 5) 采用 Python 将六种不同物理场景数字全息图以及相关物像分别转换为 TensorFlow 统一的 TF-Record 数据格式.

#### 3.2 损失函数分析

模拟实验程序在 Windows10 操作系统上安装的 Anaconda3(Python3.6.8)、TensorFlow 1.13.1 及其扩展模块下完成. 在 CPU 为 inter core i5 8th, GPU 为 GeForce RTX 2060, 内存为 8G 的电脑中搭建 ResNet 的计算平台. 损失函数在一定程度上可以反映神经网络对数据拟合的好坏程度. 为验证 ResNet 在六种不同物理场景训练集的训练效果, 选择 L2 范数作为训练损失函数, 训练误差曲线如图 6 所示, 训练迭代步数为 10 000 步时, 训练时间约为 1.5 小时. 图 6 表明, 六种模型都可以收敛到一定的误差范围内, 在相同衍射距离时, 参考光为平面波的训练集收敛效果明显比球面波更好, 且曲线的收敛速度更快. 在参考光波形相同时衍射距离为  $z_0=0.3$  m 的训练集收敛效果明显比  $z_0=0.4$  m, 0.5 m 时好, 且曲线的收敛速度更快. 采用记录参考光为平面波且衍射距离  $z_0=0.3$  m 的训练集训练所获得的损失函数值最小大约为 0.5.

#### 3.3 模拟实验结果

为测试深度学习对离轴菲涅耳数字全息图的重

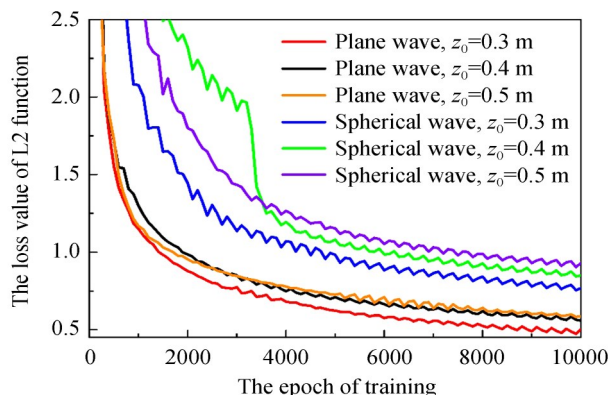


图 6 采用 L2 损失函数在 ResNet 训练时的训练误差曲线

Fig. 6 The training loss curves in ResNet training by using L2 loss functions

构质量,将其与现有的经典重构方法进行对比.选取参考光为平面波,衍射距离 $z_0 = 0.3\text{ m}$ 的菲涅耳数字全息图与相关的MNIST物像作为模拟实验数据,模拟实验全息图的重构结果如图7所示.图7(a)所示的物像 $O(x_0, y_0)$ 表示在训练过程中没有出现过的MNIST测试集中随机选取的;图7(b)表示由物像 $O(x_0, y_0)$ 经过T-FFT算法计算而来的离轴菲涅耳全息图强度 $I(x, y)$ ;图7(c)和图7(d)分别表示频率滤波法以及四步相移法预处理后的带物光波的项经菲涅耳衍射后的强度;图7(e)表示采用图7(b)中单个全息强度图 $I(x, y)$ 通过训练的深度学习直接重物像的结果.由图7可知选取参考光为平面波,衍射距离 $z_0 = 0.3\text{ m}$ 的数据集时,深度学习方法与频率滤波法和四步相移法同样能够消除零级像及孪生像,并在主观视觉上整体重构的质量较好.

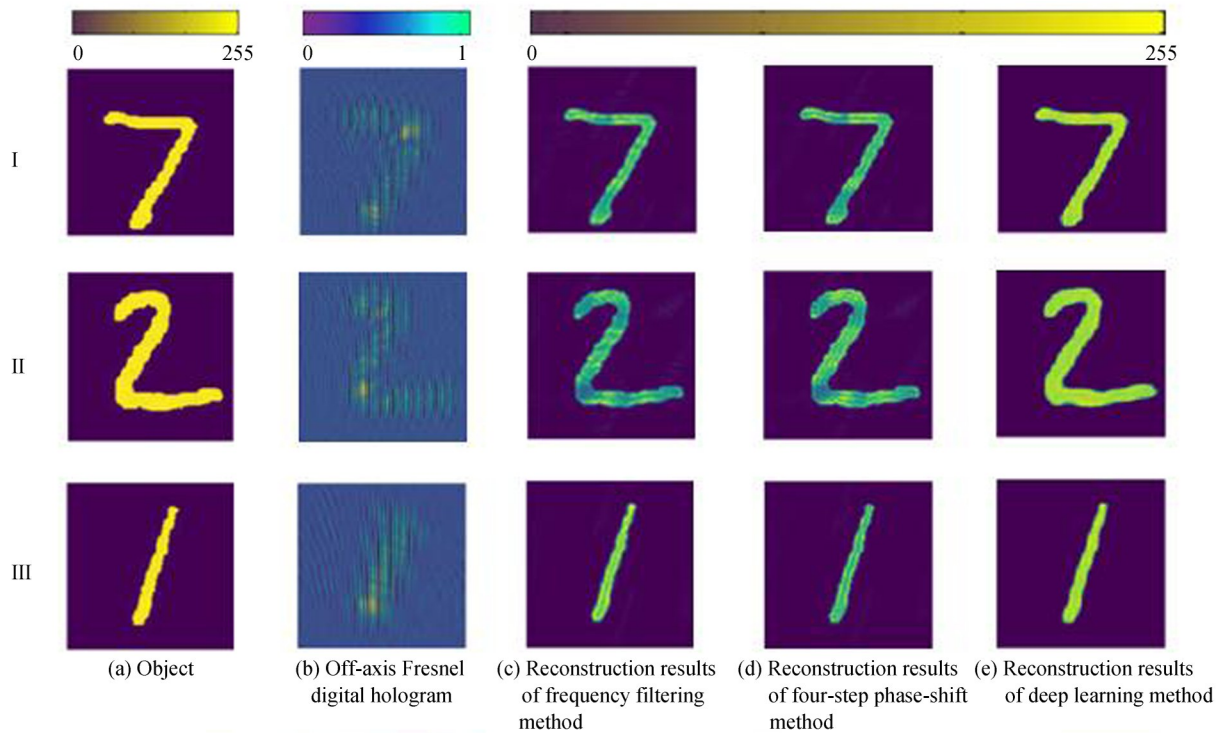



图7 平面波参考光离轴菲涅耳数字全息图重构方法对比

Fig. 7 Comparison results of plane wave reference off-axis Fresnel digital hologram reconstruction

为验证本文算法对其他记录参考光波及衍射距离重物像的质量,分别采用不同参考光及衍射距离的数据集重物像的结果如图8所示.图8(a)表示的物像 $O(x_0, y_0)$ 与图7(a) I相同.图8(b)表示不同的记录参考光及衍射距离下的离轴菲涅耳数字全息图.基于ResNet方法的离轴菲涅耳数字全息图非线性重构的结果如图8(c)所示.图8(c) I-III分别表示数据集选取参考光为平面波,衍射距离为 $z_0 = 0.3\text{ m}, 0.4\text{ m}, 0.5\text{ m}$ 时的重构结果;图8(c) IV-VI表示数据集选取球面波,衍射距离 $z_0 = 0.3\text{ m}, 0.4\text{ m}, 0.5\text{ m}$ 时的重构结果.这六种物理场景的数据集基于ResNet方法重物像的质量都非常好且相似,很难从主观视觉上进行评价.



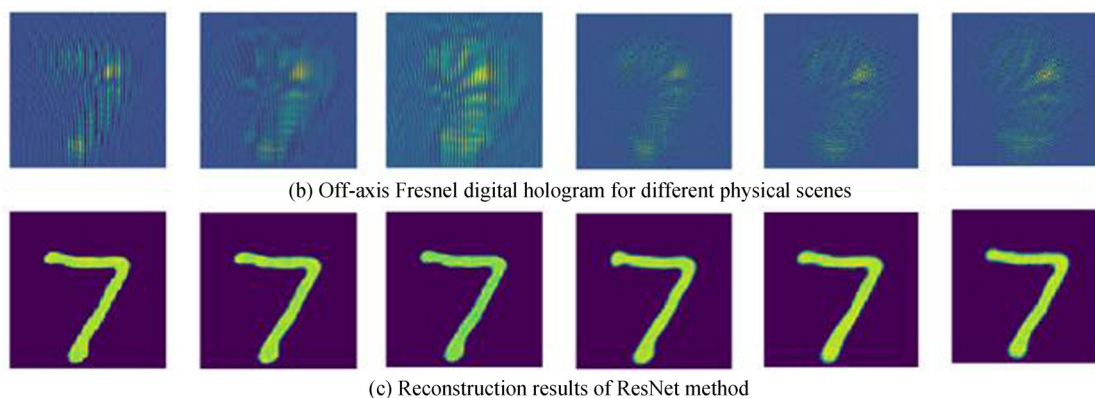


图8 基于 ResNet 的离轴菲涅耳数字全息图非线性重构  
Fig. 8 Off-axis Fresnel digital hologram nonlinear reconstruction with ResNet

### 3.4 重构质量定量评估

为定量评估 ResNet 物像非线性重构,采用平均绝对误差 (Mean Absolute Error, MAE)、均方根误差 (Root Mean Square Error, RMSE) 以及结构相似性指数 (Structural Similarity Index, SSIM)<sup>[30]</sup> 三种不同的客观评估指标评价. MAE 表示两个图像之间绝对误差的平均值, RMSE 表示两个图像之间差异的平均度量. MAE 和 RMSE 的值接近于 0 时恢复图像获得最佳效果. SSIM 用于测量两个图像之间的结构相似性, 索引范围在 0 和 1 之间, 相似度越高数值越接近于 1. 分别采用 2 000 幅重构物像与相关原始物像计算三种定量评估指标的值如表 1 所示. 由表 1 可知, 在参考光波为平面波以及衍射距离为  $z_0 = 0.3\text{ m}$  时深度学习重构物像的客观评估指标接近于其他两种传统的重构方法. 对于深度学习方法, 记录参考光为平面波, 衍射距离为  $z_0 = 0.3\text{ m}$  时的客观评估指标最好.


表 1 比较深度学习算法与传统的算法重构物像的 MAE, RMSE 和 SSIM

**Table 1 Compare MAE, RMSE and SSIM for deep learning object reconstruction with traditional algorithms**

Data Types	Frequency filtering	Four-step phase shift	Plane $z_0=0.3\text{ m}$	Plane $z_0=0.4\text{ m}$	Plane $z_0=0.5\text{ m}$	Spherical $z_0=0.3\text{ m}$	Spherical $z_0=0.4\text{ m}$	Spherical $z_0=0.5\text{ m}$
MAE	1.870 5	1.808 3	↓ 1.212 0	1.398 0	1.524 7	1.932 5	2.111 2	2.200 9
RMSE	2.677 2	2.515 0	↓ 2.208 7	2.295 0	2.427 3	2.609 0	2.688 5	2.675 2
SSIM	0.729 1	0.740 8	↓ 0.918 0	0.909 1	0.906 6	0.888 6	0.883 1	0.879 6

### 3.5 距离稳健性测试

选择参考光为平面波及衍射距离为  $z_0 = 0.3\text{ m}$  的训练集训练 ResNet 模型, 并采用参考光为平面波时四种不同衍射距离的测试集测试已训练成熟的神经网络模型的稳健性, 重构物像的结果如图 9 所示, 图 9(a) 表示与图 7(a) 相同的测试集物像  $O(x_0, y_0)$ . 图 9(b)~(f) 表示在参考光为平面波时衍射距离分别为  $z_0 = 0.3\text{ m}, 0.35\text{ m}, 0.4\text{ m}, 0.45\text{ m}, 0.5\text{ m}$  的离轴菲涅耳数字全息图测试集. 图 9(g)~(k) 分别表示由图 9(b)~(f) 在已训练成熟的 ResNet 网络中非线性重构的结果. 由图 9(h) 可知衍射距离为  $z_0 = 0.35\text{ m}$  时物像还具有较好的重构质量; 图 9(i) 中重构的物像已存在部分失真, 此时衍射距离为  $z_0 = 0.4\text{ m}$ ; 当衍射距离变为  $z_0 = 0.45\text{ m}, 0.5\text{ m}$  时, 图 9(j) 和图 9(k) 重构物像已经完全失真. 图 9 表明 ResNet 使用参考光为平面波及衍射距离为  $z_0 = 0.3\text{ m}$  的训练集训练时对一定衍射距离范围内的测试集的物像非线性重构具有一定的稳健性, 但衍射距离改变过大会严重影响重构质量.





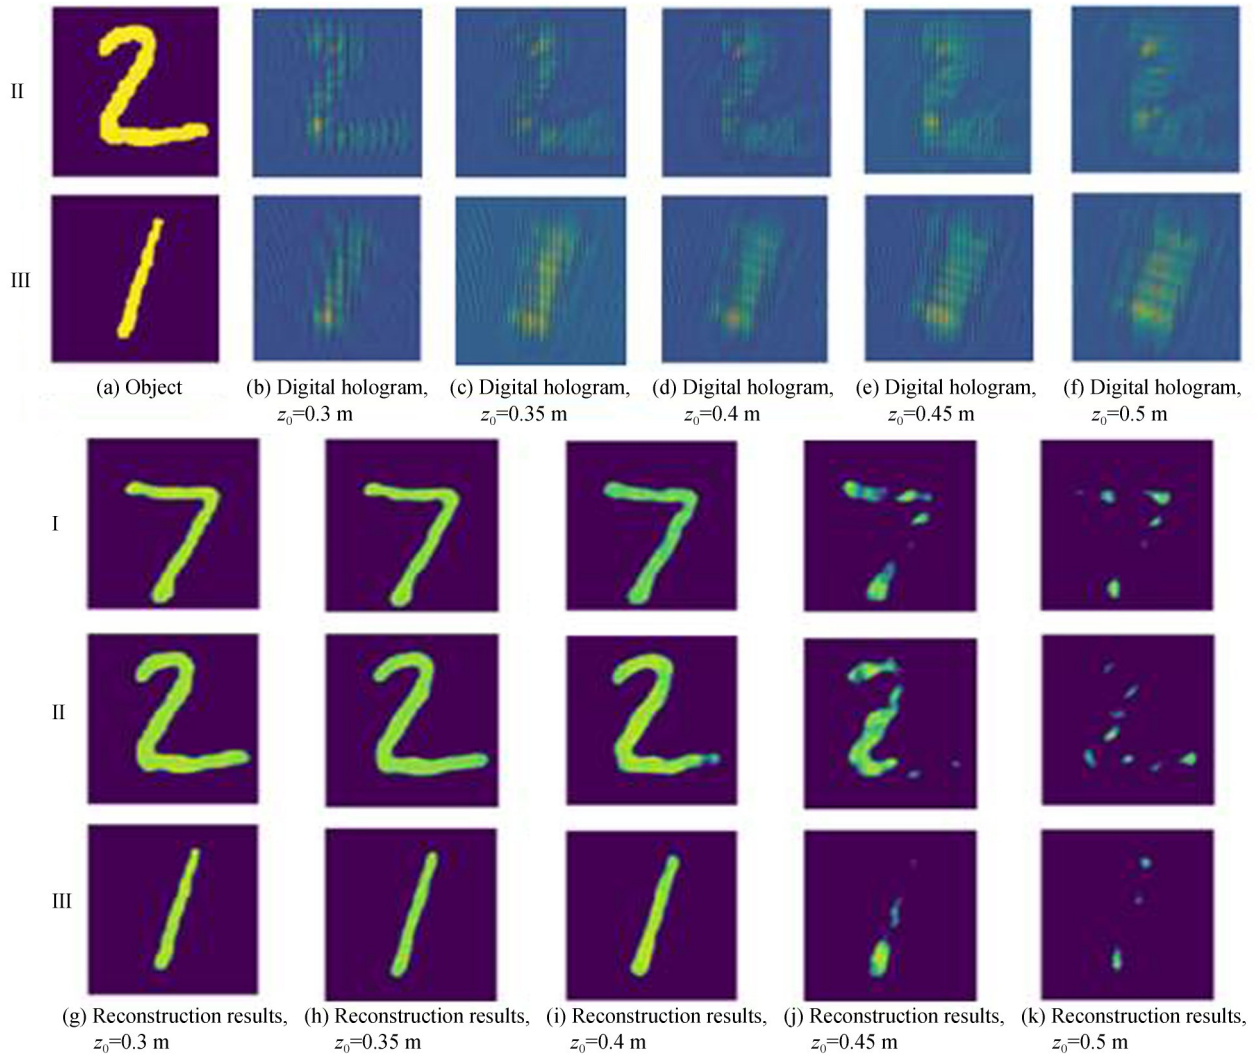



图9 ResNet对不同衍射距离的测试集重构结果(平面波训练,  $z_0=0.3$  m)

Fig. 9 ResNet reconstruction results of test dataset with different diffraction distances (plane wave training,  $z_0=0.3$  m)

### 3.6 距离稳健性神经网络测试

分别在六种不同的物理场景中选取 10 000 幅训练集图像迭代 20 000 步共同训练距离稳健 ResNet 模型, 并采用参考光为平面波且不同衍射距离的测试集重构物像, 训练时间约为 2.5 小时. 重构物像的结果如图 10 所示, 图 10(a) 表示测试集物像与图 7(a) 相同. 图 10(b)~(f) 表示记录参考光为平面波衍射距离分别为  $z_0 = 0.3$  m, 0.35 m, 0.4 m, 0.45 m, 0.5 m 的数字全息图测试集. 图 10(g)~(k) 表示分别由图 10(b)~(f) 在距离稳健 ResNet 执行的重构结果. 图 10 表明记录参考光为平面波时, 不同衍射距离下所生成的测试集在距离稳健 ResNet 作用下能成功地使用单个离轴菲涅耳数字全息图重构质量较好的物像.



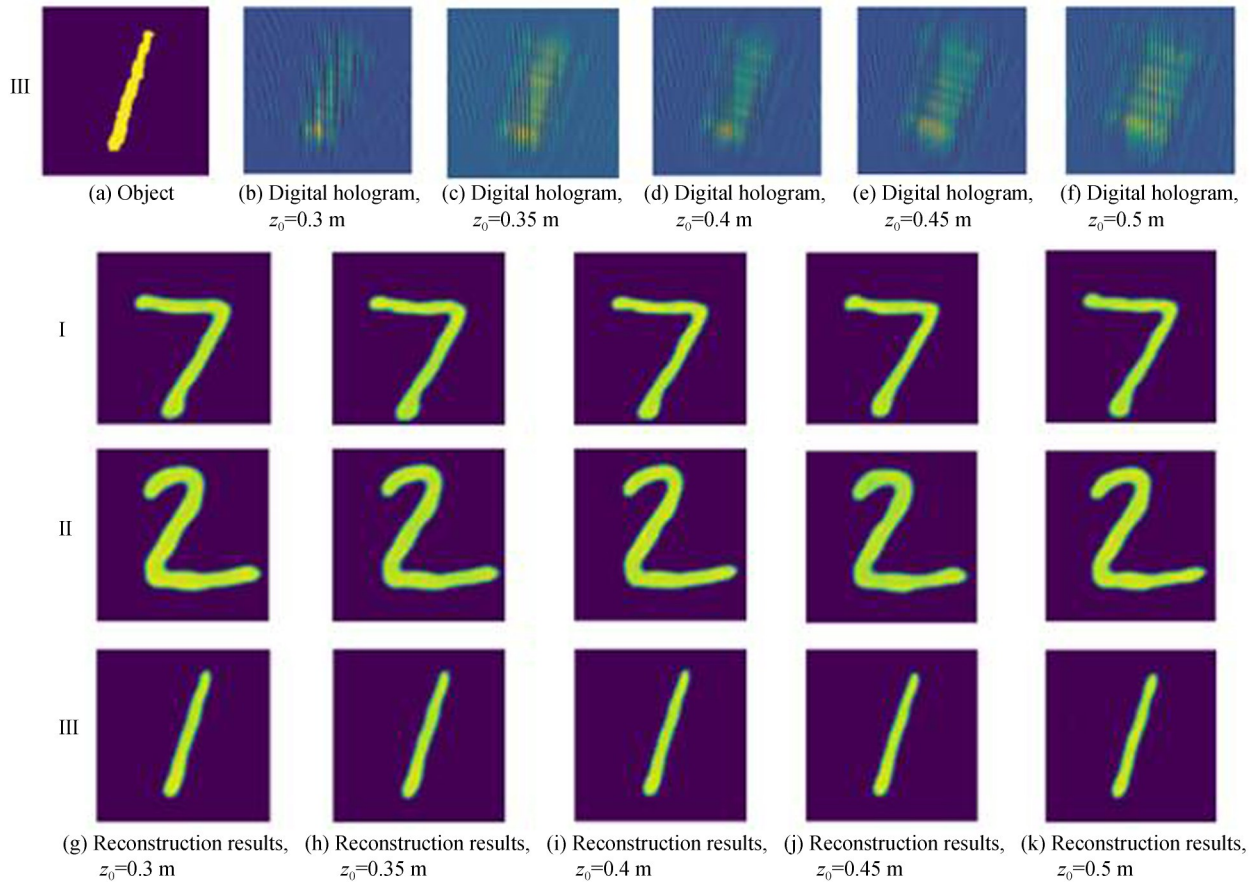


图 10 距离稳健 ResNet 在不同衍射距离下的测试集重构结果(平面波)

Fig. 10 Distance Robust ResNet reconstruction results for different diffraction distance (plane wave)

测试距离稳健 ResNet 在记录参考光为平面波时,对不同衍射距离所生成测试集的重构质量,采用如图 10(a)II 的物像生成参考光为平面波且衍射距离分别为  $z_0 = 0.3\text{ m} \sim 0.5\text{ m}$ , 间隔为  $0.01\text{ m}$  的 21 组测试图像测试距离稳健神经网络,三种定量评估指标的值如图 11 所示.由图 11 可知 21 组测试图像所重构物像与相应物像的 MAE, RMSE 和 SSIM 变化范围不大,故距离稳健神经网络对衍射距离范围内的测试集具有较强的稳健性.

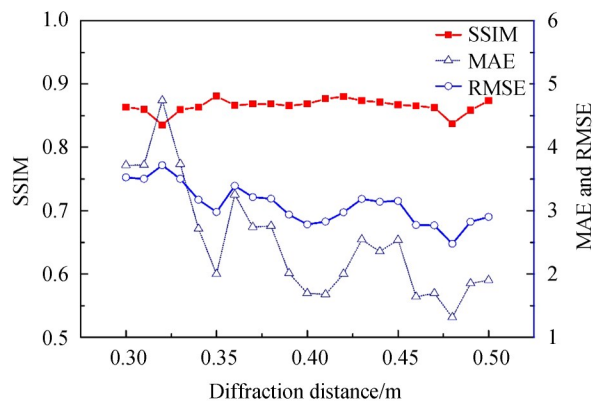


图 11 距离稳健 ResNet 在不同的衍射距离下测试图像重构物像与相应物像的 MAE、RMSE 和 SSIM(平面波)

Fig. 11 The MAE, RMSE, and SSIM of Distance Robust ResNet reconstruction results and corresponding object images for different diffraction distance (plane wave)

为了进一步对比相同测试集对3.3小节中记录的参考光为平面波,衍射距离 $z_0 = 0.3\text{ m}, 0.4\text{ m}, 0.5\text{ m}$ 的单衍射距离模型以及距离稳健ResNet的重构效果,分别采用2 000幅记录参考光为平面波,衍射距离为 $z_0 = 0.3\text{ m}, 0.4\text{ m}, 0.5\text{ m}$ 的测试集测试距离稳健ResNet的重构结果与原始物像之间的MAE、RMSE以及SSIM,定量评估指标如表2所示.由表2可知,采用同一测试集测试时距离稳健ResNet比单衍射距离模型重构结果的定量评估指标稍差.本文旨在训练一定衍射距离范围内的稳健性神经网络,出现部分评估指标上

表2 比较距离稳健与单个衍射距离ResNet重构结果的MAE, RMSE和SSIM  
Table 2 Compare MAE, RMSE and SSIM for distance-robust with single diffraction distance ResNet reconstruction results

Data \ Types	Plane $z_0=0.3\text{ m}$	Plane $z_0=0.4\text{ m}$	Plane $z_0=0.5\text{ m}$	Robust $z_0=0.3\text{ m}$	Robust $z_0=0.4\text{ m}$	Robust $z_0=0.5\text{ m}$
MAE	↓ 1.212 0	1.398 0	1.524 7	2.870 8	1.744 9	1.552 4
RMSE	↓ 2.208 7	2.295 0	2.427 3	3.037 1	2.599 3	2.463 5
SSIM	↑ 0.918 0	0.909 1	0.906 6	0.889 0	0.891 9	0.882 9

升的原因是增加了ResNet训练集的样本类型以及降低了样本数量.即通过增加样本的数量和类型,可改善距离稳健神经网络菲涅耳全息重构结果以及评估指标.

## 4 结论

本文利用深度学习算法对离轴菲涅耳数字全息图实现物像非线性重构.与传统算法相比,在不需要对全息图进行条纹预处理的情况下可隐形消除零级像及孪生像.通过增加不同衍射距离下的全息图训练样本,可增强神经网络对衍射距离重构的稳健性,实现距离稳健型输出网络.由于该深度神经网络模型采用单一输入且无需条纹预处理实现离轴菲涅耳数字全息非线性物像重构,引入了大量的机会设计全新的相干全息成像系统,具有广泛适用于各类全息图物像数字重构问题的潜力.虽然该深度神经网络能够实现离轴菲涅耳全息图物像非线性重构,并不意味着神经网络是最适合于全息图重构,但较适合于传统数字全息数字重构无法胜任的任务.

### 参考文献

- [1] SU Xian-yu, LI Ji-tao, CAO Yi-ping, *et al.* Information optics (second edition) [M]. Beijing: Science Press, 2011.  
苏显渝, 李继陶, 曹益平, 等. 信息光学(第二版)[M]. 北京: 科学出版社, 2011.
- [2] LI Jun-chang, XIONG Bing-heng. Information optics theory and calculation [M]. Beijing: Science Press, 2009.  
李俊昌, 熊秉衡. 信息光学理论与计算[M]. 北京: 科学出版社, 2009.
- [3] KEMPER B, BALLY G. Digital holographic microscopy for live cell applications and technical inspection [J]. *Applied Optics*, 2008, **47**(4): 52-61.
- [4] TAN X, MATOBA O, SHIMURA T, *et al.* Secure optical storage that uses fully phase encryption [J]. *Applied Optics*, 2000, **39**(35): 6689-6694.
- [5] MENG X F, CAI L Z, XU X F, *et al.* Two-step phase-shifting interferometry and its application in image encryption [J]. *Optics Letters*, 2006, **31**(10): 1414-1416.
- [6] WANG Biao, WANG Xin-ke, YU Yue, *et al.* Terahertz linear array fast scanning imaging [J]. *Chinese Journal of Lasers*, 2019, **46**(4): 614029.  
王彪, 王新柯, 俞跃, 等. 太赫兹线阵快速扫描成像 [J]. 中国激光, 2019, **46**(4): 614029.
- [7] CUCHE E, MARQUET P, DEPEURSINGE C. Spatial filtering for zero-order and twin-image elimination in digital off-axis holography [J]. *Applied Optics*, 2000, **39**(23): 4070-4075.
- [8] TAKAKI Y, KAWAI H, OHZU H. Hybrid holographic microscopy free of conjugate and zero-order images [J]. *Applied Optics*, 1999, **38**(23): 4990-4996.
- [9] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. *Nature*, 2015, **521**(7553): 436 - 444.
- [10] RIVENSON Y, WU Y, OZCAN A, *et al.* Deep learning in holography and coherent imaging [J]. *Light: Science & Applications*, 2019, **8**(85): 196.
- [11] LI Y, XUE Y, TIAN L. Deep speckle correlation: a deep learning approach toward scalable imaging through scattering media [J]. *Optica*, 2018, **5**(10): 1181-1190.
- [12] WANG F, WANG H, WANG H, *et al.* Learning from simulation: An end-to-end deep-learning approach for

- computational ghost imaging[J]. *Optics Express*, 2019, **27**(18): 25560-25572.
- [13] SINHA A, BARBARBSTATIS G, LEE J, *et al.* Lensless computational imaging through deep learning [J]. *Optica*, 2017, **4**(9): 1117-1125.
- [14] RIVENSON Y, ZHANG Y, GUNAYDM H, *et al.* Phase recovery and holographic image reconstruction using deep learning in neural networks [J]. *Light Science & Applications*, 2018, **7**(2): 17141-17149.
- [15] WU Y, RIVENSON Y, ZHANG Y, *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] 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.
- [17] ZHANG G, WANG D, GUAN T, *et al.* Fast phase retrieval in off-axis digital holographic microscopy through deep learning [J]. *Optics Express*, 2018, **26**(15): 19388-19405.
- [18] 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.
- [19] REN Z, XU Z, E YLAM. End-to-end deep learning framework for digital holographic reconstruction [J]. *Advanced Photonics*, 2019, **1**(1): 016004
- [20] HE K, ZHANG X, REN S, *et al.* Deep Residual Learning for Image Recognition [C] Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 770-778.
- [21] RONNEBERGER O, FISHER P, BROX T, U-Net: convolutional networks for biomedical image segmentation [C]. International Conference on Medical Image Computing and Computer-Assisted Intervention, 2015:234 - 241.
- [22] GOODMAN J W. Introduction to Fourier Optics[M]. McGraw-Hill, 1995.
- [23] MCCANN M T, JIN K H, UNSER M. Convolutional neural networks for inverse problems in imaging: a review [J]. *IEEE Signal Processing Magazine*, 2017, **34**(6): 85-95.
- [24] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C] Proceedings of the 32nd International Conference on Machine Learning (ICML), 2015: 448-456.
- [25] NAIR V, HINTON G E. Rectified Linear Units Improve Restricted Boltzmann Machines [C]. Proceedings of the 27th International Conference on Machine Learning (ICML), 2010: 807-814.
- [26] GLOROT X, BENGIO Y. Understanding the difficulty of training deep feedforward neural networks [J]. *Journal of Machine Learning Research (JMLR)*, 2010, 9: 249-256.
- [27] KINGMA D P, BAI J. Adam: a method for stochastic optimization [C]. Proceedings of International Conference on Learning Representations (ICLR), 2015.
- [28] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors[J]. *Nature*, 1986, **323**(6088): 533-536.
- [29] QIAN Xiao-fan. Information optical digital laboratory [M]. Beijing: Science Press, 2015.  
钱晓凡. 信息光学数字实验室[M]. 北京: 科学出版社, 2015.
- [30] WANG Z, BOVIK A C, SHEIKH H R, *et al.* Image quality assessment: from error visibility to structural similarity[J]. *IEEE Transactions on Image Processing*, 2004, **13**(4): 600 - 612.