

## 基于深度学习的无干扰全息图生成

吴佳雪<sup>1</sup>, 桂进斌<sup>1\*</sup>, 李俊昌<sup>1</sup>, 付泰<sup>1</sup>, 程威<sup>2</sup><sup>1</sup>昆明理工大学理学院, 云南 昆明 650500;<sup>2</sup>云南大学信息学院, 云南 昆明 650504

**摘要** 提出了一种基于深度学习的无干扰全息图生成方法。该方法采用模拟生成的离轴菲涅耳数字全息图作为网络训练样本,使用改进的卷积神经网络学习全息频谱图零级与正负一级的特征关系,实现全息图负一级频谱的提取。使用模拟全息图及实拍全息图进行了实验验证,对所得无干扰全息图的重建像进行了分析。研究表明,所提方法可以在无人工干预的前提下大范围消除零级信息和干扰信息,提取出全息图负一级信息并获得较高重建质量的物光场,实现了基于深度学习的无干扰全息图生成。

**关键词** 全息; 数字全息; 无干扰全息图; 深度学习; 全息重建; 全息频谱图

中图分类号 O438.1

文献标志码 A

DOI: 10.3788/AOS202242.1409001

## Deep Learning-Based Interference-Free Hologram Generation

Wu Jiaxue<sup>1</sup>, Gui Jinbin<sup>1\*</sup>, Li Junchang<sup>1</sup>, Fu Tai<sup>1</sup>, Cheng Wei<sup>2</sup><sup>1</sup>Faculty of Science, Kunming University of Science and Technology, Kunming 650500, Yunnan, China;<sup>2</sup>School of Information Science & Engineering, Yunnan University, Kunming 650504, Yunnan, China

**Abstract** This paper presents a method of deep learning-based interference-free hologram generation. In the method, simulated off-axis digital Fresnel holograms are utilized as network training samples, and an improved convolutional neural network is used to learn the feature relationships of the zero order with the positive and negative first orders of the holographic spectra. The negative first-order spectra of the holograms are thereby extracted. Experimental verification is carried out with simulated holograms and real ones, and the reconstructed images of the interference-free holograms are analyzed. The results show that the proposed method can eliminate zero-order information and interference information in a wide range in the absence of manual intervention, extract negative first-order information from the hologram, and obtain an object light field with high reconstruction quality. This means that the proposed method achieves deep learning-based interference-free hologram generation.

**Key words** holography; digital holography; interference-free hologram; deep learning; holographic reconstruction; holographic spectrum

## 1 引言

随着光学器件与信息技术的发展,全息术<sup>[1]</sup>以精度高、成像速度快等特点被广泛应用于全息三维显示<sup>[2]</sup>、全息投影<sup>[3]</sup>、信息安全<sup>[4]</sup>、数字显微全息术<sup>[5]</sup>等领域。近年来,数字全息被广泛应用于全息的生成与重建<sup>[6-8]</sup>,但在重建过程中,大量无关数据信息致使全息图重建效果差、实时存储困难。与此同时,全息图与普通图像相比具有像素之间的相关性弱、空域无法显示原物场信息、频域信息不规则等特点<sup>[9]</sup>。如何在高保

真的前提下,自适应提取全息图中主要重构信息以尽可能地获取高质量全息图并减小存储带宽,是一个亟待解决的问题。目前,全息图主要重构信息的提取一般采用滤波的方法<sup>[10]</sup>,本研究团队曾对无零级衍射干扰的彩色数字全息图进行了研究<sup>[11]</sup>,改进了波前重建方法,也对像平面滤波与频谱平面滤波进行了研究<sup>[12]</sup>,导出了让局部重建图像布满重建平面的表达式。但是,在滤波器的设计上,为避免干扰,不得不选择尺寸较小的滤波窗来获取物光频谱,这损失了重建光场的高频分量,降低了重建图像质量;同时,传统的滤波方

收稿日期: 2021-12-14; 修回日期: 2022-01-24; 录用日期: 2022-02-21

基金项目: 国家自然科学基金(62065010)

通信作者: jinbingui@163.com

法需人工设计滤波器,存在滤波精度不足、处理全息数据时操作繁琐等问题。因此,针对全息数据设计无人工干预的自适应选通滤波器成为全息数据提取和压缩的关键。

随着人工智能的发展,深度学习以学习能力强、准入门槛低等特点被广泛应用到图像特征提取的研究中<sup>[13-16]</sup>,基于深度学习的目标检测器和轻量级分类器的发展也日趋成熟,AlexNet<sup>[17]</sup>、VGG<sup>[18]</sup>、GoogLeNet/Inception<sup>[19]</sup>、ResNets<sup>[20]</sup>、ResNeXt<sup>[21]</sup>、CSPNet<sup>[22]</sup>、EfficientNet<sup>[23]</sup>等一些目标检测架构能够针对不同场景、不同任务进行特征提取。近年来,国内外诸多学者基于深度学习对全息图特征提取进行了深入研究,Park等<sup>[24]</sup>提出了一种新的无斑点全息转换术,利用卷积神经网络(CNN)对提取的正射影图进行散斑噪声去除。Yi等<sup>[25]</sup>提出了两种基于深度学习的全卷积神经网络(FCN)算法,该算法能够从红细胞全息图像中自动提取红细胞的模型。Soukup等<sup>[26]</sup>基于卷积神经网络,仅从全息图堆栈中提取的几个值中就能捕捉全息图类型的基本外观属性,实现基于移动采集方法的全息图认证。深度学习的发展为全息图特征提取、信息压缩、图像重建等研究提供了新的思路。

本文提出了一种基于卷积神经网络 Faster R-CNN<sup>[27]</sup>的无干扰全息图自动生成方法,将采用Mnist手写数据集<sup>[28]</sup>、通过菲涅耳衍射的卷积算法(T-FFT)和快速傅里叶变换(FFT)模拟生成的数字全息频谱

图作为训练与测试样本,利用改进的卷积神经网络学习不同参考光角度下记录的全息频谱图零级与正负一级的关系,实现全息图主要重构信息的提取。此外,通过实际拍摄不同类别的全息图进行验证和质量分析评估,并与现有的研究进行对比。本文方法可提取全息图中主要重构信息,生成无干扰全息图,提高全息图的压缩率,解决全息图重建效果差、实时重建困难、压缩率不足的问题。

## 2 基本原理

### 2.1 传统无干扰全息图的获取

数字全息图是相干光通过物体衍射后到达全息图记录面上,再与参考光相干涉形成的图像。如图1所示,在直角坐标系  $o-xyz$  中,定义  $z=0$  平面为 CCD 面阵所在的平面,令 CCD 的窗口函数为  $\omega(x, y)$ ,到达 CCD 平面的物光复振幅为  $U(x, y)$ ,参考光  $R(x, y)$  为振幅  $A_r$  的均匀平面波,干涉场强度为  $I(x, y)$ ,若使用  $\bar{U}(x, y)$  和  $\bar{R}(x, y)$  分别表示共轭物光和共轭参考光,则获得的数字全息图可表示为

$$I_H(x, y) = \omega(x, y)I(x, y), \quad (1)$$

其中

$$I(x, y) = |U(x, y)|^2 + A_r^2 + R(x, y)\bar{U}(x, y) + \bar{R}(x, y)U(x, y). \quad (2)$$




图1 数字全息图记录示意图

Fig. 1 Schematic diagram of digital hologram recording

全息图中通常包含零级项和孪生像信息,通过在频域中预先消除全息图中干扰的分量,再进行全息图的重建,可以获得无干扰的重建图像<sup>[11]</sup>。设参考光为

倾斜的平面波,  $R(x, y) = A_r \exp [jk(\theta_x x + \theta_y y)]$ , 其中  $f_x, f_y$  为频率平面坐标,  $k = 2\pi/\lambda$ ,  $\lambda$  为光波长,则全息图的傅里叶变换存在以下近似<sup>[12]</sup>:

$$F\{\omega(x, y)I(x, y)\} \approx \delta(f_x, f_y) * F\{I(x, y)\} = F\{I(x, y)\} = F\{|U(x, y)|^2\} + F\{A_r^2\} + A_r F\{\bar{U}(x, y)\} * \delta\left(f_x - \frac{\theta_x}{\lambda}, f_x - \frac{\theta_x}{\lambda}\right) + A_r F\{U(x, y)\} * \delta\left(f_x + \frac{\theta_x}{\lambda}, f_x + \frac{\theta_x}{\lambda}\right), \quad (3)$$

式中,\*表示卷积; $\delta(f_x, f_y)$ 为频域二维 Dirac 函数; $\theta_x, \theta_y$  分别表示参考光与  $x$  轴、 $y$  轴的夹角。当  $F\{U(x, y)\}$  的带宽有限时,可以适当设计参考光,通过滤波窗取出中心平移后的物光或共轭光频谱项,进行傅里叶逆变换(IFFT),得到没有干扰的物光或共轭光复振幅,即无干扰全息图。图2给出了在频域中选择不同尺寸滤

波窗情况下的重建图像。

在上述滤波窗口的选择过程中,由于人为因素的影响,频谱区域的选择不准确,同时实际的全息图存储或检测应用中需要人工干预,显得极为不便。本文通过构建深度学习网络获取无干扰的全息图,对模拟及实际拍摄的数字全息图进行傅里叶变换获得频谱,根




图 2 全息频谱图及不同尺寸的滤波窗重建图像<sup>[11]</sup>。(a)全息图的频谱及滤波窗;(b)大尺寸滤波窗重建图像;(c)小尺寸滤波窗重建图像

Fig. 2 Hologram spectrum and reconstructed images with different sizes of filter windows<sup>[11]</sup>. (a) Hologram spectrum and filter window; (b) reconstructed image with large size filter window; (c) reconstructed image with small size filter window

据频谱图的正负一级的特征,基于深度学习设计选通滤波器,获取仅含负一级的频谱图。通过将滤波后的频谱图进行傅里叶逆变换,得到无干扰项的全息图。

## 2.2 基于深度学习的无干扰全息图生成网络

本文提出的无干扰全息图生成网络(HoloZL)是对 Faster R-CNN<sup>[27]</sup>的改进,是一个双级检测网络,其结构如图 3 所示。该网络使用图像作为物平面,模拟生成离轴菲涅耳数字全息图,经过无干扰全息图生成网络逐级检测提取出包含主要重构信息的全息图,实现无干扰全息图的生成。

无干扰全息图生成网络 HoloZL 的主要作用是识别频谱图中主要重构信息即负一级频谱。网络训练的输入为进行标注后的全息频谱图,输入尺寸为  $512 \times 512$ ,输出为仅含负一级频谱信息的无干扰全息图。损失函数包括分类损失和回归损失,采用随机梯度下降(SGD)优化算法,学习率衰减采取固定步长衰减策略。

无干扰全息图生成网络 HoloZL 由三个模块组成:区域的深度全卷积网络、生成候选区域网络和分类器模块。区域的深度全卷积网络由 13 个卷积层(convolution layer)、13 个 ReLU(rectified linear unit)层和 4 个池化层(pooling)组成,将提取的输入图像中的特征图(feature maps)输入后续的生成候选区域网络层,用于分类识别。生成候选区域网络通过逻辑回归(softmax)识别目标并利用边框回归对通过深度全卷

积网络的识别目标进行修正以获得精准的识别区域,感兴趣区域池化层(ROI Pooling)收集输入的特征图和识别区域,整合信息后提取目标区域的特征图,将其送入全连接层。分类器模块通过全连接层判定目标类别并输出负一级频谱图的坐标,通过无干扰全息图生成网络 HoloZL 的输出频谱边界的坐标,得到频谱中心及滤波窗尺寸,从而对频谱图进行定位,将正一级、零级频谱部分自动滤除,输出保留负一级频谱信息的图像,经傅里叶逆变换后得到无干扰全息图,用于后续物光场的重建。

本文算法的运行过程如下:1)模拟数据集的准备,使用多张手写数字图像 Mnist<sup>[28]</sup>模拟生成全息图的频谱图,对频谱图的负一级频谱进行标注,通过脚本将图像转化为 coco 格式;2)预训练网络模型,随机初始化参数,使网络能基本识别标注好主要重构信息的目标图像;3)初始化训练参数,计算图片均值和方差,根据预训练结果设置初始学习率、阈值和训练周期;4)利用深度全卷积网络对图像进行特征提取,对特征区域进行最大值池化,统一特征大小;5)将提取的特征生成候选区域与全连接层相连接,定义多任务损失函数,输出特征区域坐标;6)根据输出坐标进行参数更新,网络训练稳定且识别准确,则训练结束,否则返回步骤 3);7)将输出坐标定位至频谱图中,进行频域滤波,输出滤波后无干扰全息图,并进行重建。

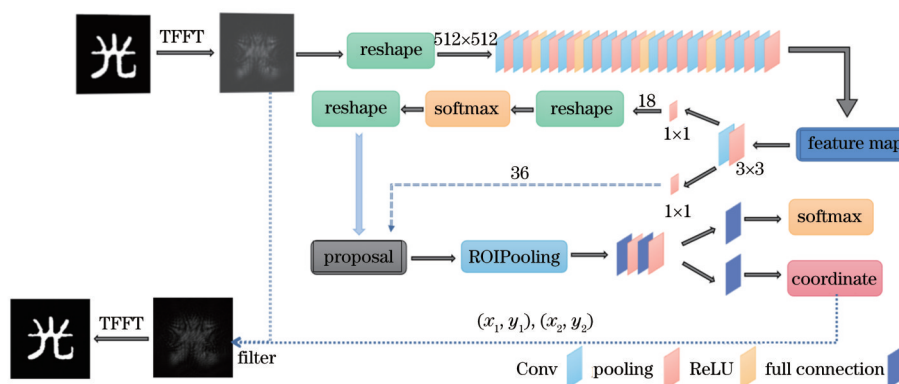


图 3 基于深度学习的无干扰全息图生成网络

Fig. 3 Deep learning-based interference-free hologram generation network



### 3 实验

#### 3.1 准备模拟数据集

模拟数据集是混合 1500 张多角度参考光 Mnist 手写数据集全息图的频谱图和 500 张实际拍摄、来自互联网图片的频谱图,其中 1500 张已标注负一级的手写数据集频谱图作为训练集,其余 200 张作为测试集,300 张作为验证集。所采用光源的光波波长  $\lambda = 632.8 \text{ nm}$ ,物体到全息记录面的距离为  $0.3086 \text{ m}$ ,CCD 面阵尺寸为  $5 \text{ mm}$ ,不同角度参考光的手写数据集全息图各 300 张。随机挑选的模拟实验训练样本如图 4 所示,生成数据集的具体步骤为:1)使用手写数字图像 Mnist 作为调入物的图像,将图像大小从  $28 \times 28$  调整为  $512 \times 512$ ;2)通过




图 4 模拟数据集。(a1)(a2)原图;(b1)(b2)全息图;(c1)(c2)再现像;(d1)(d2)频谱图

Fig. 4 Simulated data sets. (a1)(a2) Original maps; (b1)(b2) holograms; (c1)(c2) reconstructed images; (d1)(d2) spectrograms

#### 3.2 训练

模拟程序在 Ubuntu 18.04 操作系统下安装配置 Anaconda3、Python3.7.10。计算机 CPU 为 8 核主频  $3.3 \text{ GHz}$ ,GPU 为 GeForce RTX 2080 Ti,内存为  $16 \text{ G}$ 。

在 HoloZL 网络训练阶段,将已标注负一级的不同角度参考光记录全息图的频谱图通过脚本转换为 coco 格式,然后将其输入深度全卷积网络和生成候选区域网络中。其中识别矩形框的纵横比使用三种比例,分别为  $1:1, 1:2, 2:1$ 。生成候选区域网络采用非极大值抑制(NMS),其阈值固定为  $0.7$ ,最大训练周期(epoch)为  $12$ ,批处理大小为  $1$ ,采用 SGD 优化算法,初始学习率设置为  $0.02$ ,学习率衰减采取固定步长衰减策略,在第 8 个和第 11 个 epoch 学习率分别减小为  $0.002$  和  $0.0002$ ,训练总时长为  $2 \text{ h}$ 。在测试阶段,输入图像的分辨率为  $512 \times 512$ ,输入图像的数量为  $200$ ,利用 HoloZL 网络的测试集提取负一级频谱图像,在交并比(IoU)阈值为  $0.75$  的情况下平均精度均值(mAP)为  $98.8\%$ ,分类准确率为  $99.8\%$ 。评估时将识别区域的矩形框输出为坐标格式,进行后续负一级全息图的生成和重建。

#### 3.3 测试

##### 3.3.1 模拟数据集测试

用 300 张不同角度的菲涅耳全息图作为验证实验

三次傅里叶变换(TFFT)算法计算全息记录面上的物光场;3)不同角度的离轴记录参考光与全息记录面上的物光场发生干涉,生成大小为  $512 \times 512$  的离轴菲涅耳数字全息图;4)通过单次傅里叶变换(S-FFT)算法再现包含三级的全息像;5)全息图通过傅里叶变换后生成频谱图;6)使用 labeling 标注负一级频谱图像,标注方法为人工预标注,根据频谱功率谱密度曲线进行补充标注、检查、预训练,其中预标注过程为直接框选频谱边界,标注时遵循标注通用规则,即贴边、重叠、独立、不框、边界检查、小目标规则,然后将频谱图的功率谱密度曲线下降至最小的位置视为边界,进行补充标注,从而实现负一级频谱图较精确的标注。

数据,实验结果如图 5 所示,利用 HoloZL 网络训练和 TFFT 算法重建的验证集,能够大范围消除强烈的零级干扰和其他对全息重构干扰的分量,获得无干扰的全息图,同时能够得到高质量的重建物光场。若手动选择滤波窗,可能会出现由滤波窗选择过小导致的振铃效应和图像模糊或滤波窗选择过大导致的零级干扰出现在重建场图像中,但 HoloZL 网络能够针对不同的全息图选择合适的滤波窗,从而避免零级干扰,实现高质量物光场的重建。

##### 3.3.2 实际拍摄全息图的验证

为验证本文算法在实际拍摄全息图上的效果,采用分辨率为  $1344 \times 1024$ 、像元大小为  $0.00645 \text{ mm}$ 、型号为 TriCCD\_Hamamatsu\_ONERA C7780-20 的 CCD,使用波长为  $532 \text{ nm}$  的激光照射京剧脸谱进行实验,根据物体大小设置衍射距离为  $2000 \text{ mm}$ ,拍摄菲涅耳全息图,记录光路图如图 6 所示,其中,  $BS_{1,2}$  为分束镜,  $M_{1,2,3}$  为反射镜,  $Lens_{1,2}$  为透镜,  $MO_{1,2}$  为物镜。

把拍摄的全息图输入网络,输入无干扰的全息图,如图 7 所示,图 7(a)为原始物体,图 7(b)为全息图,图 7(c)为全息图的频谱,图 7(d)为网络输出的无干扰全息图,图 7(e)为使用无干扰全息图重建的图像。从实验中可得出,经过 HoloZL 网络处理后的无干扰全息图能够消




图 5 模拟实验数据。(a)原图;(b)全息图;(c)再现像;(d)频谱图;(e)无干扰全息图;(f)无干扰全息图重建图像

Fig. 5 Simulation experiment data. (a) Original images; (b) holograms; (c) reconstructed images; (d) spectrograms; (e) interference-free holograms; (f) reconstructed images of interference-free holograms

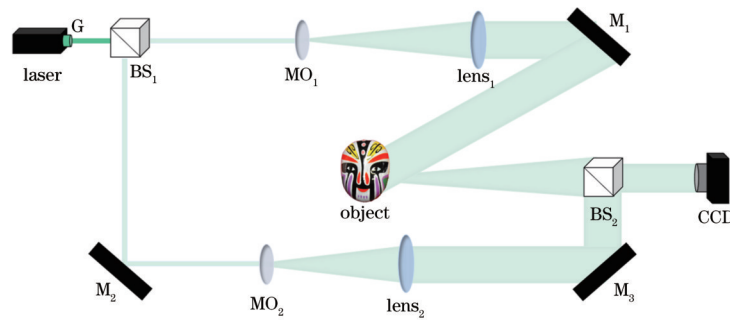


图 6 实际拍摄光路图

Fig. 6 Actual shooting light path diagram

除零级和孪生像,实现主要重构信息的提取并能获得具有较高质量的重建光场图像。事实上,在全息技术的应用研究中,如全息干涉计量、显微全息及全息三维显示等,获取的无干扰全息图去除了干扰项,这有利于物光场振幅及相位的重建;在全息图的压缩应用中,无干扰全息

图的数据量远小于原全息图,这有利于进一步提高全息图的压缩率。由于全息图实际记录的是三维物体信息,三维物体信息的频谱分布特征与平面全息的频谱分布特征一致,该方法同样适用于三维模型的无干扰全息图生成。




图 7 菲涅耳全息图的实际拍摄验证。(a)原始物体;(b)实际拍摄的全息图;(c)频谱图;(d)无干扰全息图;(e)再现像

Fig. 7 Actual shooting of Fresnel hologram for verification. (a) Original object; (b) holograms taken actually; (c) spectrogram; (d) interference-free hologram; (e) reconstructed image

### 3.4 实验分析

#### 3.4.1 损失函数分析

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。为了验证无干扰全息图的生成效果,选择平衡分类损失和回归损失的归一化权重损失函数,损失主要分为生成候选区域网络的损失和 Fast R-CNN 的损失,每个部分同时包括分类损失和

回归损失。生成候选区域网络的分类损失是经典的二分类交叉熵损失, Fast R-CNN 的分类损失是多分类的交叉熵损失,二者的回归损失为  $\lambda \frac{1}{N_{\text{reg}}} \sum_i p_i^* L_{\text{reg}}(t_i, t_i^*)$ 。其中,批尺寸决定分类的取值,分类的取值决定输出权重,从而平衡两种损失的权重,图像的损失函数定义为

$$L(\{p_i\}, \{t_i\}) = \frac{1}{N_{\text{cls}}} \sum_{\text{cls}} (p_i, p_i^*) + \lambda \frac{1}{N_{\text{reg}}} \sum_i p_i^* L_{\text{reg}}(t_i, t_i^*), \quad (4)$$

式中:  $i$  表示每一个矩形框的索引;  $p_i$  表示索引  $i$  的预测概率;  $p_i^*$  表示打标签的训练数据,  $p_i^* = 1$  表示识别对象为正确,  $p_i^* = 0$  表示识别对象为错误;  $t_i$  表示预测矩形框 4 个坐标的向量, 是生成候选区域网络训练部分的预测偏移量;  $t_i^*$  是与  $t_i$  维度相同的向量, 表示预测矩形

框的实际偏移量; 定义回归损失  $L_{\text{reg}}(t_i, t_i^*) = R(t_i - t_i^*)$ ,  $p_i^* L_{\text{reg}}$  表示回归损失作用于识别矩形框的效果。

训练损失函数的误差曲线如图 8 所示, 当训练周期 epoch 为 12, 每个 epoch 验证 9 次, 训练迭代步数为 108 步, 生成候选区域网络(RPN)的分类损失误差收敛至 0.0002, 回归损失误差收敛至 0.001, Fast R-CNN 分类损失误差收敛至 0.01, 回归误差收敛至 0.0250, 训练总误差收敛至 0.02, 平均精度均值 mAP 为 98.8%, 分类准确率为 99.8%。

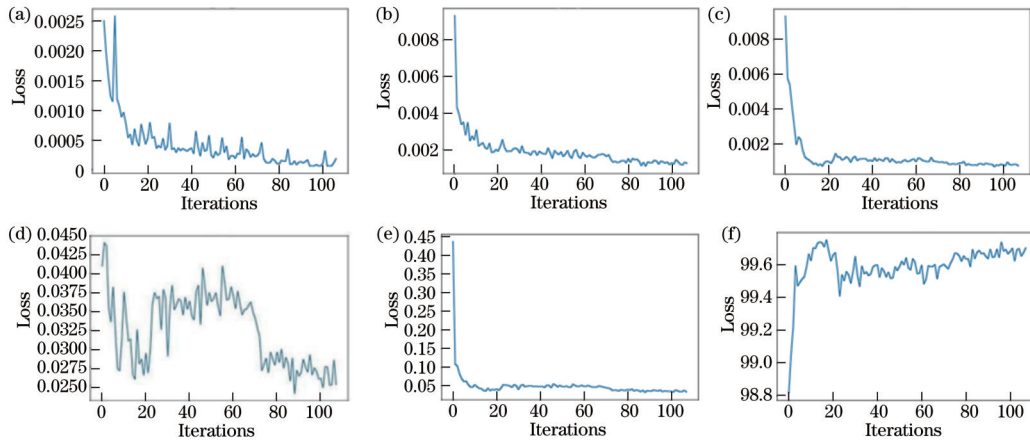


图 8 损失函数误差曲线。(a) RPN 分类损失误差曲线; (b) RPN 回归损失误差曲线; (c) Fast R-CNN 分类损失误差曲线; (d) Fast R-CNN 回归误差曲线; (e) 训练总误差曲线; (f) 分类准确率

Fig. 8 Loss function error curves. (a) RPN classification loss error curve; (b) RPN regression loss error curve; (c) Fast R-CNN classification loss error curve; (d) Fast R-CNN regression error curve; (e) total training error curve; (f) classification accuracy

### 3.4.2 质量评估

目前为止, 国际标准组织尚未对全息图的质量评估进行统一的度量。由于全息图的存储以二维数据矩阵为主, 衡量全息图大部分依然以二维图像衡量标准为主<sup>[29-30]</sup>。为评估无干扰全息图生成网络的性能, 采用压缩比(C)、平均绝对误差(MAE)、峰值信噪比(PSNR)、结构相似性指数(SSIM)4种不同的客观评价指标。

本文通过使用 300 张验证集图片对实验结果进行质量评估。4 种定量指标的值如表 1 所示, 其中  $C_1$  为无干扰全息图再现像与原图的压缩比,  $C_2$  为无干扰全

息图再现像与全息图再现像的压缩比, 无干扰全息图的生成时间为  $t_G$ , 重建时间为  $t_R$ , 其中  $\uparrow$  表示值越大效果越好,  $\downarrow$  表示值越小效果越好。  $C_1$ 、 $C_2$  平均值分别约为 1.31 和 1.66, MAE 平均值为 0.88, PSNR 平均值约为 48.11, SSIM 平均值约为 0.76。对于基于深度学习的无干扰全息图生成方法, 平面参考光与  $x$  轴的夹角  $\alpha = 3\pi/4.00$  时, 无干扰全息图的重建效果最好、信息压缩效果最好。不同参考光角度的无干扰全息图生成及重建运行时间如表 1 所示, 平均生成时间约为 2.18 s, 平均重建时间为 0.64 s。

表 1 无干扰全息图的质量评估指标

Table 1 Quality assessment metrics of interference-free hologram

| Angle $\alpha$ /rad | $C_1$ ( $\uparrow$ ) | $C_2$ ( $\uparrow$ ) | MAE ( $\uparrow$ ) | PSNR ( $\uparrow$ ) | SSIM ( $\uparrow$ ) | Generated time $t_G$ ( $\downarrow$ )/s | Reconstruction time $t_R$ ( $\downarrow$ )/s |
|---------------------|----------------------|----------------------|--------------------|---------------------|---------------------|---|--|
| $\pi/3.00$          | 1.34                 | 1.50                 | 1.03               | 48.11               | 0.76                | 2.30                                    | 0.60   |
| $3\pi/4.00$         | 1.29                 | 1.85                 | 0.57               | 48.11               | 0.76                | 2.20                                    | 0.74   |
| $\pi/4.00$          | 1.30                 | 1.89                 | 0.77               | 48.10               | 0.76                | 2.44                                    | 0.69   |
| $\pi/2.02$          | 1.31                 | 1.49                 | 1.44               | 48.10               | 0.75                | 1.95                                    | 0.56   |
| $\pi/2.00$          | 1.29                 | 1.59                 | 0.59               | 48.11               | 0.76                | 2.00                                    | 0.61   |

为了进一步对基于深度学习的无干扰全息图生成网络的效果进行验证, 通过人工设计滤波器与 HoloZL 网络对生成图像进行定量对比评估。人工设计滤波器的方法如下: 给定一张图片, 模拟生成该图片的离轴菲

涅耳全息图, 通过 FFT 后生成频谱图, 根据频谱分布特性手动设计矩形选通滤波窗, 将负一级频谱图像取出并平移到图像中间, 便获得共轭物光频谱, 将其进行 IFFT 后获得无干扰全息图, 即人工滤波无干扰全息



图,最后用 TFFT 算法进行全息图重建(图 9)。

实验结果如图 10 所示,评估数据如表 2 所示,可知 HoloZL 网络生成的无干扰全息图的峰值信噪比、结构相似性指数、压缩比、绝对误差平均值和运行时间皆优

于人工设计滤波器效果。HoloZL 网络受训练集选择的影响表现出不同的效果,由于训练集中 Mnist 手写数据集的数据量较大,因此在网络中手写数据集的各项指标效果更佳。

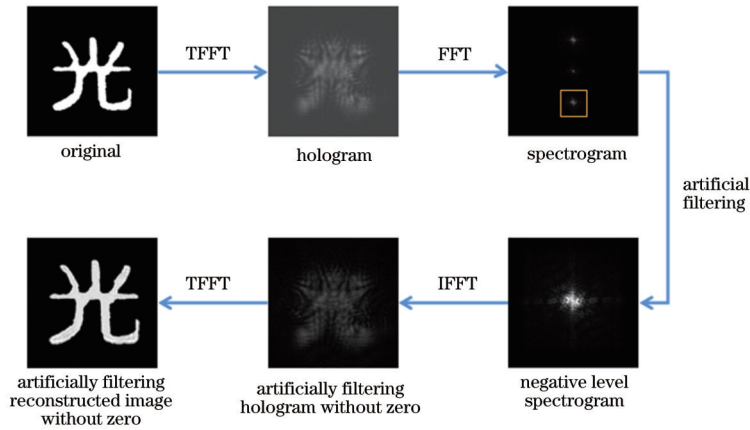


图 9 人工滤波干扰全息图实验流程

Fig. 9 Experimental procedure for artificial filtering hologram with interference

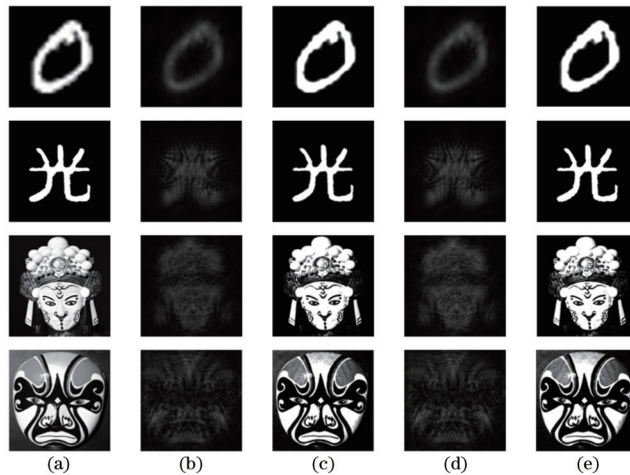


图 10 人工滤波与 HoloZL 网络的生成图像。(a)原图;(b)人工滤波无干扰全息图;(c)人工滤波无干扰全息图再现像;(d) HoloZL 网络生成无干扰全息图;(e) HoloZL 网络生成无干扰全息图再现像

Fig. 10 Images obtained by artificial filtering and HoloZL network. (a) Original images; (b) artificially filtered interference-free holograms; (c) reconstructed images of artificially filtered interference-free holograms; (d) interference-free holograms generated by HoloZL network; (e) reconstructed images of interference-free holograms generated by HoloZL network

表 2 对比实验的定量评估指标

Table 2 Quantitative assessment indexes of comparative experiments

| Data set |                      | PSNR (↑) | SSIM (↑) | C (↑) | MAE (↑) | Generated time<br>$t_G (\downarrow)/s$ | Reconstruction time<br>$t_R (\downarrow)/s$ |
|----------|----------------------|----------|----------|-------|---------|--|---|
| Mnist    | Artificial filtering | 48.00    | 0.76     | 1.36  | 0.83    | 2.01                                   | 0.41  |
|          | HoloZL               | 49.70    | 0.77     | 1.39  | 0.77    | 1.93                                   | 0.33  |
| Guang    | Artificial filtering | 27.82    | 0.91     | 2.98  | 1.32    | 1.93                                   | 0.54  |
|          | HoloZL               | 28.35    | 0.95     | 2.98  | 1.24    | 1.71                                   | 0.66  |
| Wukong   | Artificial filtering | 17.60    | 0.82     | 2.72  | 6.12    | 1.89                                   | 0.41  |
|          | HoloZL               | 18.42    | 0.82     | 2.73  | 5.73    | 1.33                                   | 0.34  |
| Lianpu   | Artificial filtering | 18.82    | 0.80     | 2.99  | 7.76    | 1.61                                   | 0.75  |
|          | HoloZL               | 19.31    | 0.81     | 2.99  | 7.76    | 1.60                                   | 0.53  |

## 4 结 论

基于现有全息图零级衍射干扰和压缩编码算法的研究,提出了一种基于深度学习的无干扰全息图生成方法,实现全息图像主要重构信息的提取。为了验证网络效果,对实际拍摄的全息图进行验证,并对生成的无干扰全息图进行质量评估。结果表明,所提方法在大范围消除零级和孪生像的同时,也具有较好的压缩效果和重建质量。此外,本文方法可泛化至各类全息图,在无人工干预条件下生成无干扰全息图,解决了人工处理全息数据操作繁琐、滤波精度不足等问题,为无干扰全息图的生成和全息图的压缩编码提供新的研究思路。

### 参 考 文 献

- [1] Gabor D. A new microscopic principle[J]. *Nature*, 1948, 161(4098): 777-778.
- [2] 许富洋, 杨鑫, 姚建云, 等. 高分辨率多视点动态全息 3D 显示[J]. *中国激光*, 2021, 48(1): 0109001.  
Xu F Y, Yang X, Yao J Y, et al. High-resolution multiview dynamic holographic 3D display[J]. *Chinese Journal of Lasers*, 2021, 48(1): 0109001.
- [3] Velez-Zea A, Torroba R. Multiplane noniterative color holographic projection[J]. *Optics and Lasers in Engineering*, 2021, 137: 106327.
- [4] Peng Y, Nagase T, Kanamoto T, et al. A virtual optical holographic encryption system using expanded Diffie-Hellman algorithm[J]. *IEEE Access*, 2021, 9: 22071-22077.
- [5] 王宇, 温凯, 张美玲, 等. 数字全息显微中自动调焦技术及其应用(封面文章)(特邀)[J]. *红外与激光工程*, 2021, 50(2): 20200530.  
Wang Y, Wen K, Zhang M L, et al. Autofocusing techniques in digital holographic microscopy and their applications (Cover paper)(Invited)[J]. *Infrared and Laser Engineering*, 2021, 50(2): 20200530.
- [6] 浦健, 桂进斌, 张凯. 基于深度学习的多尺度数字全息图重建[J]. *激光与光电子学进展*, 2022, 59(2): 0209001.  
Pu J, Gui J B, Zhang K. Multiscale digital hologram reconstruction based on deep learning[J]. *Laser & Optoelectronics Progress*, 2022, 59(2): 0209001.
- [7] 余爽, 皮大普, 康睿丹, 等. 基于双步菲涅尔衍射的曲面计算机全息图快速生成方法[J]. *光学技术*, 2021, 47(3): 271-276.  
Yu S, Pi D P, Kang R D, et al. Fast calculation method for curved computer-generated hologram based on Double-step Fresnel Diffraction[J]. *Optical Technique*, 2021, 47(3): 271-276.
- [8] Goi H, Komuro K, Nomura T. Deep-learning-based binary hologram[J]. *Applied Optics*, 2020, 59(23): 7103-7108.
- [9] 姜智翔, 桂进斌, 王国庆, 等. 用于三维显示的全息压缩技术概述[J]. *激光与光电子学进展*, 2019, 56(24): 240001.  
Jiang Z X, Gui J B, Wang G Q, et al. Overview of holographic-compression technology for three-dimensional display[J]. *Laser & Optoelectronics Progress*, 2019, 56(24): 240001.
- [10] 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.  
Liu H, Xiao Y L, Tian J L, et al. Nonlinear reconstruction for off-axis Fresnel digital holography with deep learning[J]. *Acta Photonica Sinica*, 2020, 49(7): 0709001.
- [11] 李俊昌, 樊则宾, Patrice T, 等. 无零级衍射干扰的彩色数字全息研究[J]. *物理学报*, 2011, 60(3): 034204.  
Li J C, Fan Z B, Patrice T, et al. The study of color digital holography free from the zero-order diffraction interruption[J]. *Acta Physica Sinica*, 2011, 60(3): 034204.
- [12] 李俊昌, 宋庆和, 桂进斌, 等. 数字全息波前重建中的像平面滤波技术研究[J]. *光学学报*, 2011, 31(9): 0900135.  
Li J C, Song Q H, Gui J B, et al. Research of image plane filtering technique in digital holographic wavefront reconstruction[J]. *Acta Optica Sinica*, 2011, 31(9): 0900135.
- [13] Jiao L C, Zhang F, Liu F, et al. A survey of deep learning-based object detection[J]. *IEEE Access*, 2019, 7: 128837-128868.
- [14] Zaidi S S A, Ansari M S, Aslam A, et al. A survey of modern deep learning based object detection models[EB/OL]. (2021-04-24)[2022-02-11]. <https://arxiv.org/abs/2104.11892>.
- [15] Zou Z X, Shi Z W, Guo Y H, et al. Object detection in 20 years: a survey[EB/OL]. (2019-03-13)[2022-02-11]. <https://arxiv.org/abs/1905.05055>.
- [16] Sun P Z, Zhang R F, Jiang Y, et al. Sparse R-CNN: end-to-end object detection with learnable proposals[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 20-25, 2021, Nashville, TN, USA. New York: IEEE Press, 2021: 14449-14458.
- [17] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[J]. *Communications of the ACM*, 2017, 60(6): 84-90.
- [18] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2014-09-04) [2022-02-11]. <https://arxiv.org/abs/1409.1556>.
- [19] Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the inception architecture for computer vision[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 2818-2826.
- [20] 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.
- [21] Xie S N, Girshick R, Dollár P, et al. Aggregated



- residual transformations for deep neural networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 5987-5995.
- [22] Wang C Y, Liao H Y M, Wu Y H, et al. CSPNet: a new backbone that can enhance learning capability of CNN[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), June 14-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 1571-1580.
- [23] Tan M X, Le Q V. EfficientNet: rethinking model scaling for convolutional neural networks[EB/OL]. (2019-05-28)[2022-02-11]. <https://arxiv.org/abs/1905.11946>.
- [24] Park D Y, Park J H. Hologram conversion for speckle free reconstruction using light field extraction and deep learning[J]. Optics Express, 2020, 28(4): 5393-5409.
- [25] Yi F L, Moon I, Javidi B. Automated red blood cells extraction from holographic images using fully convolutional neural networks[J]. Biomedical Optics Express, 2017, 8(10): 4466-4479.
- [26] Soukup D, Huber-Mörk R. Mobile hologram verification with deep learning[C]//2017 Fifteenth IAPR International Conference on Machine Vision Applications (MVA), May 8-12, 2017, Nagoya, Japan. New York: IEEE Press, 2017: 169-172.
- [27] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [28] 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.
- [29] Jiao S M, Jin Z, Chang C L, et al. Compression of phase-only holograms with JPEG standard and deep learning[J]. Applied Sciences, 2018, 8(8): 1258.
- [30] Shimobaba T, Blinder D, Makowski M, et al. Dynamic-range compression scheme for digital hologram using a deep neural network[J]. Optics Letters, 2019, 44(12): 3038-3041.