

## 基于深度学习的彩色全息图重建

刘俊彤<sup>1</sup>, 桂进斌<sup>1,2\*</sup>, 陈艾帅<sup>1</sup>, 马先栋<sup>1</sup>, 胡先飞<sup>1</sup><sup>1</sup>昆明理工大学理学院, 云南 昆明 650500;<sup>2</sup>昆明理工大学云南省高校现代信息光学重点实验室, 云南 昆明 650500

**摘要** 针对较大尺寸物体彩色全息图重建操作复杂、色彩融合不准确、重建时受零级影响等问题,提出一种基于深度学习的彩色全息图重建方法。采用改进的U-Net模型作为网络结构,使用混合实际拍摄和模拟生成的彩色离轴菲涅耳全息图频谱作为训练样本,实现对彩色全息图的准确重建。对模拟全息图和实际拍摄的数字全息图进行重建实验,结果表明,所提方法相较于传统方法,能够在保持重建图像高分辨率和颜色准确性的同时,具有更好的重建效果。研究结果可应用于大尺寸检测场彩色全息图的重建,为彩色全息检测及深度学习在光学成像领域中的应用提供有益的参考。

**关键词** 数字全息; 深度学习; 彩色全息重建; 全息频谱

中图分类号 O438.1

文献标志码 A

DOI: 10.3788/LOP231492

## Color Hologram Reconstruction Based on Deep Learning

Liu Juntong<sup>1</sup>, Gui Jinbin<sup>1,2\*</sup>, Chen Aishuai<sup>1</sup>, Ma Xiandong<sup>1</sup>, Hu Xianfei<sup>1</sup><sup>1</sup>Science of Faculty, Kunming University of Science and Technology, Kunming 650500, Yunnan, China;<sup>2</sup>Yunnan Provincial Key Laboratory of Modern Information Optics, Kunming University of Science and Technology, Kunming 650500, Yunnan, China

**Abstract** This study proposes a deep learning-based color hologram reconstruction method to address the issues of complex reconstruction operations, inaccurate color fusion, and zero-order influence during the reconstruction of large objects. The improved U-Net model is used as the network structure, and the spectrum of color off-axis Fresnel holograms generated by mixing actual photography and simulation is used as training samples to achieve the accurate reconstruction of color holograms. Reconstruction experiments are conducted on simulated holograms and actual digital holograms. Moreover, the results have shown that compared to traditional methods, the proposed method can maintain high resolution and color accuracy of the reconstructed image while achieving improved reconstruction results. The outcomes of the study have potential applications in the reconstruction of color holograms in large-scale inspection fields, and are useful for the application of color holographic detection and deep learning in the field of optical imaging.

**Key words** digital holography; deep learning; color holographic reconstruction; holographic spectrum

## 1 引言

随着数字全息应用技术的发展,彩色数字全息作为一种实时高精度的检测方法,在医学影像<sup>[1]</sup>、工业检测<sup>[2]</sup>、全息显示<sup>[3]</sup>等领域均有着广泛的应用。由于一般的检测样品尺寸均远大于记录的CCD面阵,因此彩色数字全息图的重建通常使用菲涅耳衍射的单次快速傅里叶变换(S-FFT)算法<sup>[4]</sup>,由于该算法的重建光场尺寸与光波长及衍射距离有关,为实现不同波长重建信息的准确融合,一些针对彩色数字全息图的特殊重建

方法被提出,如1-FFT离焦重建法<sup>[5]</sup>、可变放大率重建法<sup>[6]</sup>等。这些重建算法针对不同波长的全息图,通过滤波等方法提高重建像的质量,但选择滤波窗口时不可避免会引入零级干扰等噪声,影响重建图像的质量,同时在重建过程中,还需要大量的人工操作调整不同通道重建像的位置以及它们之间的相对强度,难以满足高效、准确的重建要求,尤其在彩色全息的显示等方面。

近年来由于人工智能的迅速发展,深度学习在图像处理领域表现优秀,被广泛用于图像分类<sup>[7]</sup>、图像分

收稿日期: 2023-06-08; 修回日期: 2023-07-12; 录用日期: 2023-07-31; 网络首发日期: 2023-08-18

基金项目: 国家自然科学基金(62065010)

通信作者: jinbingui@163.com

割<sup>[8]</sup>、目标检测<sup>[9]</sup>等任务中。由于其计算速度快、特征提取能力强等特点,越来越多的国内外学者将其应用于数字全息领域,如相位解包裹<sup>[10]</sup>、超分辨率成像<sup>[11]</sup>、自动聚焦<sup>[12]</sup>、散射介质成像<sup>[13]</sup>等。与此同时,得益于U-Net<sup>[14]</sup>、VGG<sup>[15]</sup>、ResNet<sup>[16]</sup>、GAN<sup>[17]</sup>等网络模型架构在不同场景中不同特征处理上的优势,深度学习在全息波前重建的研究也取得了显著的进展<sup>[18-24]</sup>,例如:Wang等<sup>[18]</sup>用改进的U-Net对具有不同离焦距离的多幅全息图的相位和振幅信息进行快速重建;Li等<sup>[19]</sup>提出一种用于低载频全息图的数字全息相位解调方案,该方案将物理模型整合到传统的深度神经网络中,无须基于海量数据集进行训练;西北工业大学Wang等<sup>[20]</sup>提出的Y-Net是在U-Net的基础上改进而来的,是一个单输入对多输出的网络结构,可以对单幅数字全息图同时重建出振幅信息和相位信息。

然而,目前多数基于深度学习的全息图重建研究是基于显微全息领域完成的<sup>[18,20]</sup>,大部分针对像面全息图进行学习和重建,尚缺乏一种高效的深度学习方法来对大尺寸(比如CCD尺寸大10倍以上的物体)菲涅耳彩色全息图进行重建。同时,S-FFT算法将物体信息记录在干涉条纹中,全息图受杂散斑影响较大,使得端到端的重建较为困难,因此,本文对卷积神经网络U-Net进行改进,提出一种基于U-Net的彩色全息图重建方法,利用彩色菲涅耳离轴数字全息图频谱包含原图特征的特性,并以其作为训练样本提取图像主要重构信息,通过深度学习方法获得其重建像,解决重建过程中的零级干扰、颜色信息丢失等问题。

## 2 原理与方法

### 2.1 传统彩色全息图重建原理

彩色数字全息图记录示意图如图1所示,其中:BS1、BS2、BS3、M1、M2、M3为反射镜;MO1、MO2为物镜;Lens1、Lens2为透镜。设置Lens2透镜使平面光作为参考光,物体在不同波长照明下,使用单色CCD依次或使用彩色CCD同时记录下数字全息图 $I_i(x, y)$ , $i$ 取值为R、G、B,设到达CCD平面的物光波和参考光波的复振幅分别为 $O_i(x, y)$ 和 $R_i(x, y)$ ,则数字全息图记录面上光强分布可表示为

$$I_i(x, y) = |O_i(x, y) + R_i(x, y)|^2 = |O_i(x, y)|^2 + |R_i(x, y)|^2 + O_i(x, y)R_i^*(x, y) + O_i^*(x, y)R_i(x, y), \quad (1)$$

式中: $|O_i(x, y)|^2 + |R_i(x, y)|^2$ 为物光波与参考光波的强度信息;第3项与第4项为两个光波之间的相对相位关系, $O_i(x, y)R_i^*(x, y)$ 为共轭参考光调制的物光波, $O_i^*(x, y)R_i(x, y)$ 为参考光调制的共轭物光波。记录得到的数字全息图包含物光波的振幅和相位信息。

数字全息图的重建算法以衍射公式为主,由于使用卷积计算或角谱衍射计算时,获得的重建像场




图1 全息图记录光路图

Fig. 1 Hologram recording optical path map

大小与CCD面阵一致,因此在重建大尺寸物体的反射全息图时,需要使用大量的补零方式获得完整的物体重建像,增加了计算的复杂度和计算时间。因此通常使用更为简便的S-FFT算法,使用平面光照明全息图,经过距离 $d_i$ 的衍射后,再现光场的复振幅分布为

$$U(x_i, y_i, d_i) = \frac{\exp(jkd)}{j\lambda d} \exp\left[\frac{jk}{2d}(x^2 + y^2)\right] \times \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} I(x_0, y_0) \exp\left[\frac{jk}{2d_i}(x_0^2 + y_0^2)\right] \times \exp[-j2\pi(x_0 \frac{x_i}{\lambda d_i} + y_0 \frac{y_i}{\lambda d_i})] dx_0 dy_0, \quad (2)$$

式中: $(x_0, y_0)$ 为物平面坐标; $(x_i, y_i)$ 为再现平面坐标。令 $f(x) = \frac{x_i}{\lambda d_i}$ ,  $f(y) = \frac{y_i}{\lambda d_i}$ ,则式(2)可变换为二维傅里叶变换式:

$$U(x_i, y_i, d_i) = \frac{\exp(jkd)}{j\lambda d} \exp\left[\frac{jk}{2d}(x^2 + y^2)\right] \times \text{FFT}\left\{I(x_0, y_0) \exp\left[\frac{jk}{2d_i}(x_0^2 + y_0^2)\right]\right\}. \quad (3)$$

从式(3)可以看出,重建图像的尺寸与波长及其再现距离有关,当记录距离保持不变时,波长越长,重建像平面尺寸越大,所以在使用S-FFT重建图像时,由于重建图像尺寸不一致,需要通过对全息图进行补零操作来获得需要的尺寸,这会消耗大量的时间,如图2所示,在对R、G、B等3幅重建图像进行色彩融合时,还需要人工进行详细的色彩调校,所以重建像会存在一定的色差,同时从图中可看出,由于激光的相干性产生的散斑噪声,对重建图像的影响也较大,因此重建彩色图像质量较差。

### 2.2 基于深度学习的彩色全息图重建网络

在彩色全息图重建任务中,由于需要对不同颜色的通道信息进行处理,而U-Net对保留原始图像的空间信息有很好的效果,这对重建彩色全息图的颜色信息有较大的作用。由此,提出基于U-Net的彩色全息图重建网络(CHR-Net),利用在图像特征提取处理上的优越性,在S-FFT算法的基础上优化重建步骤,解




图 2 补零重建彩色全息图。(a)绿光重建像;(b)蓝光重建像;  
(c)红光重建像 (d)合成彩色全息重建像  
Fig. 2 Zero filling reconstruction of color hologram. (a) Green light reconstruction image; (b) blue light reconstruction image; (c) red light reconstruction image (d) synthetic color holographic reconstruction image

决在重建过程中容易出现的信息丢失、操作繁琐等问题。具体结构如图 3 所示,以使用 S-FFT 算法生成的离轴菲涅耳数字全息图为例,输入尺寸为  $512 \times 512$  的

全息频谱图,输出为高质量的彩色全息图重建像。

CHR-Net 整体框架由两部分组成:左半部分为编码结构,用于提取图像特征,包含 5 个结构相同的下采样块,每个下采样块由 2 个  $3 \times 3$  的卷积层以及 1 个步长为 2 的最大池化层构成;右半部分为解码结构,通过跳跃连接的方式将浅层网络输出的特征图与深层网络的特征图进行特征融合,在保留浅层信息的同时将网络做得更深,使得最后的输出图像效果更好。

由于彩色图像所含有的特征比普通灰度图像更多,网络的计算量更为复杂且更难被学习出来,基于此对特征提取网络进行改进,引入残差网络 ResNet 作为图像处理的基础模块,即在原来 U-Net 的基础上增加残差连接,可在下采样阶段保留原始特征信息的同时,将丢失的图像细节补全,解决其由于特征过多而导致的准确率下降等问题,并减少其处理时间。在处理高噪声和复杂图像的情况下,使用 ResNet 进行彩色全息图重建可以得到更好的重建效果。

在解码阶段,网络采用深监督机制来辅助训练网络模型,深监督机制是指在上采样过程中引入多个输出层,从而对网络不同阶段的特征信息进行有效监督。深监督在解码器的每一层增加一个  $1 \times 1$  卷积核,即每一层添加一个输出,再计算其损失值,网络最后的损失由每一层的损失加权相加得到,解决反向传播中不能达到深层的问题,从而更好提高模型的鲁棒性和泛化性能。在本研究中,考虑到计算机性能的限制,选择其中的两个上采样块的输出图像作为辅助输出,如图 4 所示,256 通道的上采样块输出图像记作 out2,128 通道上采样块的输出图像记作 out1,网络训练最终输出图像记作 out。

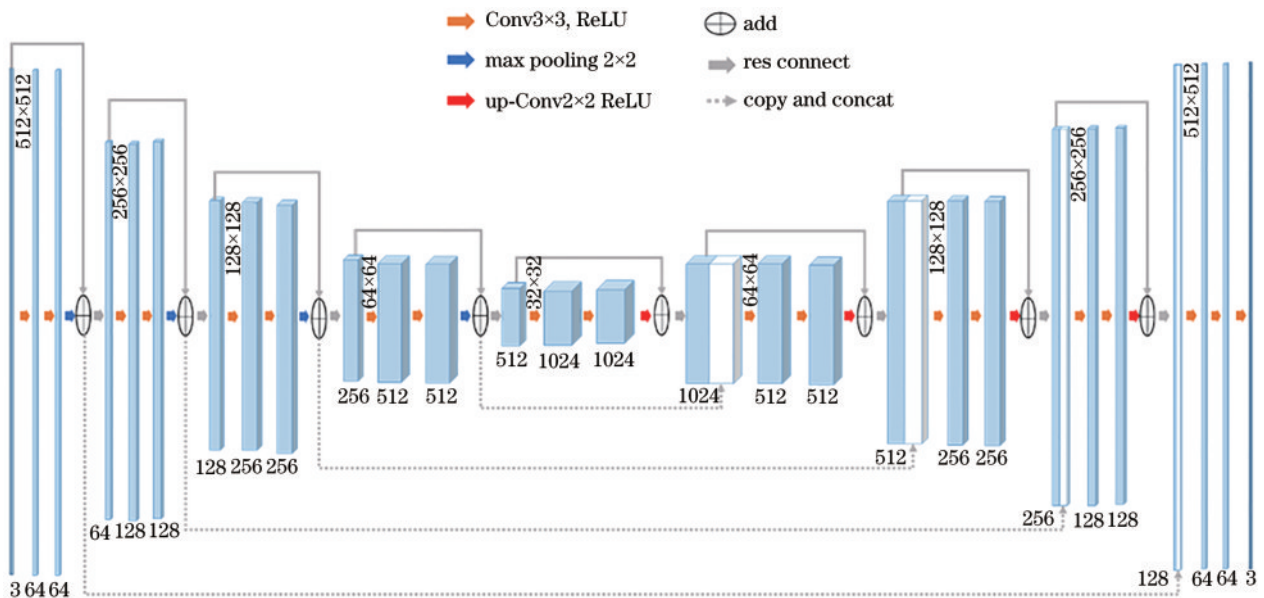


图 3 CHR-Net 结构示意图  
Fig. 3 Schematic diagram of CHR-Net structure

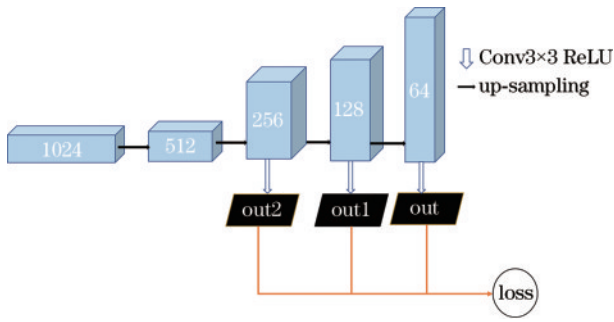


图 4 深监督机制

Fig. 4 Deep supervision mechanism

### 3 实验

#### 3.1 数据集准备

本实验以离轴菲涅耳数字全息图为例,用于此次实验的数据集由人脸谱数据集、互联网以及实际拍摄中随机选取的 2000 张 RGB 图片的频谱图组成,通过数




图 5 数据集制作示例

Fig. 5 Example of dataset production

#### 3.2 训练

本实验在 Python 3.9.12 版本下,使用 PyTorch 搭建的网络模型进行。计算机配置如下:CPU 为 E5-2460;GPU 为 NVIDIA GeForce RTX 2080 Ti;显存为 16 GB。

训练采用 Adam 优化算法对参数的权重进行优化,学习率大小初始为 0.001,随着训练进行使用学习率衰减策略使网络收敛,如每经过 100 个 epoch 学习率就衰减为原来的一半, batch size 大小为 4,最大训练周期为 1000 轮,为避免网络过拟合,当网络在验证集中的性能开始下降时,网络停止训练。损失函数采用的是均方差(MSE)和结构相似性(SSIM)组成的混合损失函数,其计算公式为

$$l_{\text{loss}} = \alpha l_{\text{SSIM}} + (1 - \alpha) l_{\text{MSE}}, \quad (4)$$

式中:  $l_{\text{loss}}$  为混合损失函数;  $l_{\text{SSIM}}$  代表结构相似性损失函数,从图片结构和颜色纹理的角度来衡量图片的重建质量;  $l_{\text{MSE}}$  代表均方差损失函数,从像素的角度来计算重建图像像素值和真实图像像素值之间的差异;  $\alpha$  为分配的权重。在此次重建任务中,考虑到重建图像在结构以及颜色上的重建比内部细节更为简单,所以采取权重衰减的方式,先为  $l_{\text{SSIM}}$  分配更大的权重,取  $\alpha = 0.8$ ,之后每经过 100 个 epoch,使其权重衰减 0.1,这样使训练过程中先完成对图像的边缘结构以及颜色

据增强的方式将数据集扩充到 6000 张。模拟数据集采用模拟图 1 实际光路的方式生成,物体到全息记录面距离  $d$  为 1720 mm, CCD 像素宽度为 0.00645 mm,数据集示例如图 5 所示,为了获得高质量的彩色全息图重建结果,数据集选取的图片包括以下特征:1)具有纯色背景便于与目标物体区分;2)图像的清晰度、色彩饱和度较高;3)包含多种物体,以便提高模型的泛化能力。在训练之前先将数据集按比例划分为训练集、测试集与验证集,选取 5000 张作为网络的训练集,500 张作为测试集,余下的 500 张频谱图像作为网络的验证集。模拟数据集生成步骤如下:1)将原始图像尺寸大小统一为  $512 \times 512$  方便后续处理;2)通过单色 CCD 分别记录 R、G、B 等 3 种波长激光照射下的数字全息图,再将其合成为 1 张彩色全息图;3)将彩色全息图经 FFT 生成频谱图;4)对频谱图的特征图像进行标注,方便网络在训练时对频谱图的特征进行提取;5)将标注后的图像作为网络输入的模拟数据集。

信息的重建,在之后的 epoch 里注重内部细节的补足,以此完成整个图像的重建。

由于采用深监督机制,因此网络总共有 3 个输出值,即总共需要计算网络训练中产生的 3 个损失函数:

$$l_{\text{total}} = l_1 + pl_2 + ql_3, \quad (5)$$

式中:  $l_1$  为网络最终输出的特征图像损失值,代表网络训练的最后效果,因此占比权重为 1;  $l_2$  和  $l_3$  分别为网络在上采样过程中两个辅助输出 out1 和 out2 的损失函数,在此次实验中取  $p = 0.5$ 、 $q = 0.25$ 。网络训练产生的 4 个损失函数曲线如图 6 所示




图 6 网络误差曲线

Fig. 6 Network error curve

从损失函数可以看出,越浅的分支收敛速度越快,因为浅层特征更容易学习和匹配。相反,深层特征通常需要更长的时间来训练和收敛。图 7 给出了 CHR-Net 在训练时输出的 3 个图像。out2 的输出图像未完全提取到原始标签的图像特征,边缘轮廓不清晰。随

着网络继续对图像进行上采样,out1 在输出图像时已经有了一定的原始标签的特征,但是相对于原图来说,仍然存在部分颜色信息丢失的情况。而作为最终输出结果的 out,已经较好学习到了的图像特征,完成对整个 CHR-Net 的训练。




图 7 深监督 3 个分支输出结果;(a)原图;(b) out2;(c) out1;(d) out

Fig. 7 Output results from three branches under deep supervision; (a) Original image; (b) out2; (c) out1; (d) out

### 3.3 实验分析

#### 3.3.1 网络测试结果分析

为验证 CHR-Net 对彩色全息图的重建效果以及泛化能力,使用新类型水果数据集对网络性能进行验证测试,原图像大小为  $512 \times 512$ ,选取部分样本数据分别经 S-FFT、U-Net、CHR-Net 训练得到重建像并进行展示,使用 U-Net 训练时,只更换网络模型,参数以及数据集样本均与 CHR-Net 保持一致,结果

如图 8 所示。可以看出:传统算法由于需要人工对 RGB 通道的再现像强度进行调整,再将其拼接为完整的彩色再现像,在计算时间和图像质量上来说,表现都不如 CHR-Net;U-Net 对图像的结构以及像素的还原效果相较于原图差距较大;经过 CHR-Net 重建后的图像强度与原图基本一致,颜色准确度也较高,说明通过 CHR-Net 能够获得高质量的重建图像。

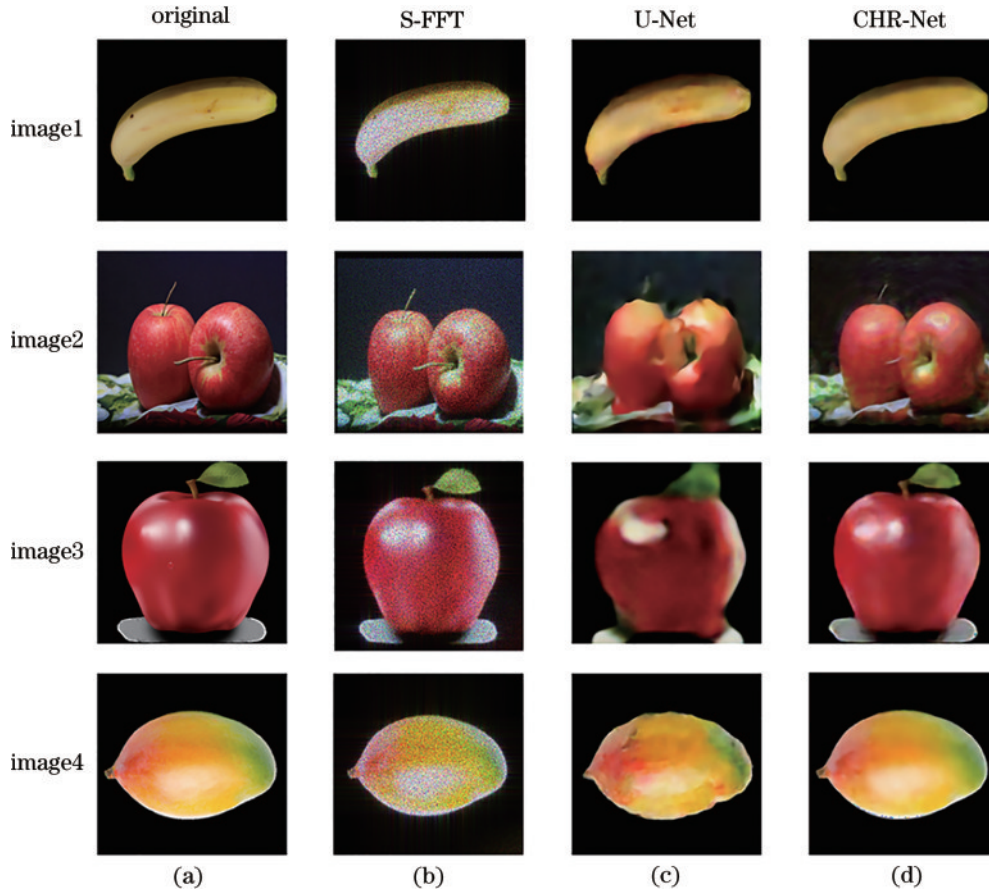


图 8 不同算法重建效果对比。(a)原图;(b) S-FFT 重建像;(c) U-Net 重建像;(d) CHR-Net 重建像

Fig. 8 Comparison of reconstruction effects of different algorithms. (a) Original images; (b) S-FFT reconstruction images; (c) U-Net reconstruction images; (d) CHR-Net reconstruction images

## 3.3.2 质量评估

为了验证重建后的图像效果,采用峰值信噪比(PSNR)和结构相似指数(SSIM)两个客观评价指标对彩色全息图的再现像进行质量评估。PSNR的表达式为

$$R_{\text{PSNR}} = 10\log_{10}\left(\frac{I_{\text{max}}^2}{E_{\text{MSE}}}\right), \quad (6)$$

$$E_{\text{MSE}} = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [I_{\text{truth}}(i,j) - I_{\text{out}}(i,j)]^2, \quad (7)$$

式中: $I_{\text{max}}$ 为重建图像的最大像素值; $E_{\text{MSE}}$ 为大小为 $m \times n$ 的重建像与原图之间的均方误差; $I_{\text{truth}}$ 为原图; $I_{\text{out}}$ 为重建像。PSNR值越大说明重建图像的质量越好,表1给出了4张验证集中的图片由传统算法、U-Net以及CHR-Net重建后的PSNR值。可以看出,CHR-Net的PSNR值明显优于传统算法以及U-Net的,说明CHR-Net的重建像与原图像相似性越高。

表1 重建图像PSNR值

Table 1 Reconstructed image PSNR value

Image	S-FFT	U-Net	CHR-Net
Image1	24.0251	27.2166	35.4487
Image2	22.1999	18.8102	24.6732
Image3	22.5892	17.7430	33.0315
Image4	19.2158	22.7518	26.8650
Average	22.0075	21.6304	30.0046

SSIM值则从图像组成的角度来评判图像的重建精度,更加符合人眼对图像相似程度的判断,其表达式为

$$M_{\text{SSIM}} = \frac{(2\mu_x\mu_y + C_1)(2\delta_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\delta_x^2 + \delta_y^2 + C_2)}, \quad (8)$$

式中: $x, y$ 代表原图像和重建像; $\mu_x, \mu_y$ 分别是两幅图像的平均值; $\sigma_{xy}$ 是两幅图像的协方差; $\sigma_x^2$ 和 $\sigma_y^2$ 为图像的方差; $C_1 = (k_1 \times L)^2$ 、 $C_2 = (k_2 \times L)^2$ ,  $k_1, k_2$ 和 $L$ (像素值取值范围)为常数,均设定为默认值,分别取 $k_1 = 0.01$ 、 $k_2 = 0.03$ 、 $L = 255$ 。重建图像SSIM值如表2所示。

为了进一步验证CHR-Net整体的泛化能力以及重建效果,使用500张验证集图片对网络的性能进行评估,重建效果对比如表3所示。S-FFT算法受激光散斑影响较大,激光散斑产生的背景噪声会降低全息图的对比度和清晰度导致重建图像出现模糊和细节丢

表2 重建图像SSIM值

Table 2 Reconstructed image SSIM value

Image	S-FFT	U-Net	CHR-Net
Image1	0.6090	0.9476	0.9878
Image2	0.3435	0.6871	0.6536
Image3	0.3265	0.8066	0.9546
Image4	0.4527	0.9445	0.9692
Average	0.4329	0.8465	0.8913

表3 网络总体性能评估

Table 3 Overall network performance evaluation

Index	S-FFT	U-Net	CHR-Net
PSNR	22.3452	22.2866	28.6838
SSIM	0.4672	0.8853	0.9104

失等情况,散斑现象还会导致光的干涉在空间上出现扩展和混叠,从而限制全息图的动态范围。因此,S-FFT算法重建图像的SSIM和PSNR值都偏低。通过深度学习的方法对全息图进行重建时,消除了散斑对重建质量的干扰,SSIM有较大的提升,同时相较于U-Net,CHR-Net可以得到更高质量的重建像,拥有更好的重建性能。

## 3.3.3 实际拍摄全息图验证

为验证CHR-Net在实际全息图中的重建效果,搭建如图1所示的光路图,使用尺寸大小为 $100 \text{ mm} \times 75 \text{ mm}$ 的物体进行实验验证,设置有效像素为 $1024 \times 1024$ ,衍射距离为 $1720 \text{ mm}$ ,像素宽度为 $0.00645 \text{ mm}$ 。首先将三色激光调整至合束,再使用遮挡的方式使三色激光分别照明目标物体,用单色CCD记录下数字全息图,并将拍摄得到的3张全息图频谱合成得到物体的彩色频谱图。

将未在训练集中出现过的彩色频谱图输入CHR-Net,提取其频谱图中的主要重构特征,经网络重建后得到其重建像,如图9所示,图9(a)为物体原始图像,图9(b)为S-FFT算法重建像,图9(c)为U-Net重建像,图9(d)为CHR-Net重建像。可以看出,CHR-Net通过提取实际全息图的频谱特征,获得了高质量的彩色重建像,且与传统方法相比,消除了实际拍摄全息图中产生的散斑、杂散光以及零级干扰对重建质量的影响,在较为准确还原图像颜色信息的同时大大节省了重建所需的时间。



图9 实际拍摄菲涅耳全息图重建验证。(a)原始图像;(b)S-FFT重建像;(c)U-Net重建像;(d)CHR-Net重建像

Fig. 9 Verification of Fresnel hologram reconstruction from actual shooting. (a) Original image; (b) S-FFT reconstruction image; (c) U-Net reconstruction image; (d) CHR-Net reconstruction image

## 4 结 论

提出一种基于深度学习技术的重建彩色全息图方法,使用基于残差 U-Net 的网络模型并对其进行改进,实现了高精度、高保真度的彩色全息图重建。通过增加网络的输出通道数、调整损失函数以及增加训练数据等方法,成功地提高重建的准确性和保真度。并在实际拍摄的全息图上对网络进行验证,通过视觉和客观质量评估的方式验证所提方法的有效性。实验结果表明:相较于传统 U-Net,CHR-Net 在 4 种不同类型数据上的 PSNR 以及 SSIM 值上均有显著的提升,分别提高 6.4 dB、0.025;相较于传统方法,CHR-Net 同时还能消除重建过程中零级以及杂散斑对于重建质量的影响。所提方法为在大场景下使用深度学习对彩色全息图进行高质量重建提供了一个新的思路。

### 参 考 文 献

- [1] Liu T R, Wei Z S, Rivenson Y, et al. Deep learning-based color holographic microscopy[J]. *Journal of Biophotonics*, 2019, 12(11): 201900107.
- [2] 宋庆和, 刘志强, 杨文明, 等. 彩色数字全息测量杨氏模量[J]. *光子学报*, 2018, 47(1): 0109001.  
Song Q H, Liu Z Q, Yang W M, et al. Investigation of measuring the Young's modulus with color digital holography[J]. *Acta Photonica Sinica*, 2018, 47(1): 0109001.
- [3] Li Z S, Zheng Y W, Li Y L, et al. Method of color holographic display with speckle noise suppression[J]. *Optics Express*, 2022, 30(14): 25647-25660.
- [4] 桂进斌. 彩色数字全息及其在材料变形检测中的应用研究[D]. 昆明: 昆明理工大学, 2013.  
Gui J B. Study on color digital holography and its application in material deformation detection[D]. Kunming: Kunming University of Science and Technology, 2013.
- [5] 李俊昌, 宋庆和, Pascal Picart, 等. 离轴数字全息波前重建算法讨论[J]. *中国激光*, 2014, 41(2): 0209008.  
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.
- [6] 桂进斌, 宋庆和, 李俊昌, 等. 彩色数字全息常见波面重建算法的实现与比较[J]. *激光技术*, 2015, 39(2): 176-181.  
Gui J B, Song Q H, Li J C, et al. Realization and comparison of wave front reconstruction algorithms commonly used in colour digital holography[J]. *Laser Technology*, 2015, 39(2): 176-181.
- [7] Li C, Polling M, Cao L, et al. Analysis of automatic image classification methods for Urticaceae pollen classification[J]. *Neurocomputing*, 2023, 522: 181-193.
- [8] Khalifa A F, Badr E. Deep learning for image segmentation: a focus on medical imaging[J]. *Computers, Materials & Continua*, 2023, 75(1): 1995-2024.
- [9] Liu J F, Pan C, Yan W Q. Litter detection from digital images using deep learning[J]. *SN Computer Science*, 2022, 4(2): 1-9.
- [10] 王硕, 王华英, 王学, 等. 融合注意力机制的相位解包裹方法[J]. *光学技术*, 2022, 48(4): 385-390.
- [11] Wang S, Wang H Y, Wang X, et al. Phase unwrapping method incorporating attention mechanism[J]. *Optical Technique*, 2022, 48(4): 385-390.
- [12] 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.
- [13] Liao J, Chen X, Ding G, et al. Deep learning-based single-shot autofocus method for digital microscopy[J]. *Biomedical Optics Express*, 2021, 13(1): 314-327.
- [14] Chen L, Chen Z Y, Singh R K, et al. Imaging of polarimetric-phase object through scattering medium by phase shifting[J]. *Optics Express*, 2020, 28(6): 8145-8155.
- [15] 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.
- [16] 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>.
- [17] 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 (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [18] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[EB/OL]. (2014-06-10)[2023-03-02]. <https://arxiv.org/abs/1406.2661>.
- [19] Wang S, Jiang X N, Liu X, et al. End-to-end reconstruction of multi-scale holograms based on CUE-NET[J]. *Optics Communications*, 2023, 530: 129079.
- [20] Li Z S, Chen Y Y, Sun J S, et al. High bandwidth-utilization digital holographic reconstruction using an untrained neural network[J]. *Applied Sciences*, 2022, 12(20): 10656.
- [21] Wang K Q, Dou J Z, Qian K M, et al. Y-Net: a one-to-two deep learning framework for digital holographic reconstruction[J]. *Optics Letters*, 2019, 44(19): 4765-4768.
- [22] Manabe R, Tsuchiya H, Koga M. Trial of deep learning for image reconstruction of lens-less microwave holography[J]. *Plasma and Fusion Research*, 2022, 17: 2401072.
- [23] Daniele P, Daniele S, Lisa M, et al. Speeding up reconstruction of 3D tomograms in holographic flow cytometry via deep learning[J]. *Lab on a Chip*, 2022, 22(4): 793-804.
- [24] 吴佳雪, 桂进斌, 李俊昌, 等. 基于深度学习的无干扰全息图生成[J]. *光学学报*, 2022, 42(14): 1409001.  
Wu J X, Gui J B, Li J C, et al. Deep learning-based interference-free hologram generation[J]. *Acta Optica Sinica*, 2022, 42(14): 1409001.
- [25] 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.