

一种基于深度学习的光学合成孔径成像系统 图像复原方法

唐睢^{1,2,3}, 王凯强^{1,2,3}, 张维^{1,2,3}, 吴小龔⁴, 刘国栋⁴, 邸江磊^{1,2,3*}, 赵建林^{1,2,3**}

¹西北工业大学物理科学与技术学院, 陕西 西安 710129;

²陕西省光信息技术重点实验室, 陕西 西安 710129;

³超常条件材料物理与化学教育部重点实验室, 陕西 西安 710129;

⁴中国工程物理研究院流体物理研究所, 四川 绵阳 621900

摘要 光学合成孔径成像系统中光学传递函数的频率响应下降, 会不可避免地导致成像模糊, 因此通常需要借助维纳滤波或盲解卷积算法来实现图像复原, 最终获得清晰的高分辨率图像。提出一种基于 U 型卷积神经网络的深度学习框架, 通过 MATLAB 软件构建数据集, 以对网络进行训练, 并将所训练的 U 型网络与盲解卷积算法的图像复原效果进行对比。数值仿真结果表明, 在弱噪声条件下, U 型网络在基于光学合成孔径成像系统的图像复原中展现出较强的复原能力以及一定的泛化能力和通用性, 能够实现图像的快速盲复原, 因而具有潜在的应用前景。

关键词 成像系统; 光学传递函数; 深度学习; 卷积神经网络; 光学合成孔径成像系统

中图分类号 O436.1

文献标志码 A

doi: 10.3788/AOS202040.2111001

Deep Learning Based Image Restoration Method of Optical Synthetic Aperture Imaging System

Tang Ju^{1,2,3}, Wang Kaiqiang^{1,2,3}, Zhang Wei^{1,2,3}, Wu Xiaoyan⁴, Liu Guodong⁴,
Di Jianglei^{1,2,3*}, Zhao Jianlin^{1,2,3**}

¹School of Physical Science and Technology, Northwestern Polytechnical University, Xi'an, Shaanxi 710129, China;

²Shaanxi Key Laboratory of Optical Information Technology, Xi'an, Shaanxi 710129, China;

³Key Laboratory of Material Physics and Chemistry Under Extraordinary Conditions, Ministry of Education, Xi'an, Shaanxi 710129, China;

⁴Institute of Fluid Physics, China Academy of Engineering Physics, Mianyang, Sichuan 621900, China

Abstract The decrease of the frequency response of the optical transfer function in the optical synthetic aperture imaging system will inevitably lead to image blur. Therefore, it is usually necessary to use the Wiener filtering or blind deconvolution algorithm to achieve image restoration, and clear and high-resolution images are obtained finally. A deep learning frame based on a U-shaped convolutional neural network is proposed. The data set is constructed by the MATLAB software to train the network. The image restoration effects of the trained U-shaped network and blind deconvolution algorithm are compared. The numerical simulation results show that the U-shaped network has strong recovery ability, generalization ability, and versatility in the image restoration based on the optical synthetic aperture imaging system under the condition of weak noise. It can realize fast blind restoration for images and has potential application prospects.

Key words imaging systems; optical transfer function; deep learning; convolutional neural network; optical synthetic aperture imaging system

OCIS codes 110.4850; 110.3010; 200.4260

收稿日期: 2020-06-19; 修回日期: 2020-07-10; 录用日期: 2020-07-15

基金项目: 国家自然科学基金(61927810, 61705187)、国家自然科学基金委员会与中国工程物理研究院联合基金(U1730137)、陕西省自然科学基金基础研究计划(2018JQ6012)、中央高校基本科研业务费专项资金(3102019ghxm018)

* E-mail: jiangleidi@nwpu.edu.cn; ** E-mail: jlzhao@nwpu.edu.cn

1 引 言

高分辨成像技术在地形测绘、天文观测、灾情监测和军事侦察等领域的应用日益广泛。对于光学成像系统而言,由于衍射极限的存在,在某一特定工作波段下只能通过增加系统口径来提高其成像分辨能力。但在实际应用中,随着系统口径的增大,光学元件的设计、加工、检测难度以及光学系统的体积、质量、成本等都将迅速增加。近年来快速发展的光学合成孔径成像技术将多个子孔径按照某一特定方式排布组合在一起,以获得与单个大孔径光学系统类似的空间分辨率,这是实现与大孔径光学系统等效成像能力的一种有效、低成本途径^[1]。

在光学合成孔径成像技术中,精准定位的子孔径透镜阵列将代替传统的大口径成像镜头。通过子孔径透镜阵列的光束发生会聚,在成像平面形成干涉图像。由于可见光波长较短,光学合成孔径成像系统在可见光波段的应用对系统透镜面型精度、光机结构设计和控制精度等要求较高。吕亚昆和吴彦鸿^[2]总结了合成孔径技术在激光雷达成像方面的发展历程及其关键技术,李丹阳等^[3]初步分析了天基合成孔径激光雷达成像理论的成像理论。然而,即使对于满足调试要求的光学合成孔径成像系统而言,其通光孔径面积与等效单孔径成像系统相比仍然较小,系统孔径的限制使系统截止频率之外的空间频率成分被拦截而无法参与成像,导致系统的实际点扩展函数(PSF)发生扩展,调制传递函数(MTF)的中频响应下降甚至缺失。同时,由于成像系统噪声的存在,光学合成孔径成像系统所成图像的清晰度受到严重影响,需要结合图像复原技术获得高分辨率图像。Bell等^[4]于1996年首次提出利用图像复原技术补偿系统MTF以获得清晰图像。随后,Fienuip等^[5]采用多种技术实现了合成孔径系统的图像复原;Wang等^[6]通过实验验证了图像复原技术的可行性;Wu等^[7]利用维纳滤波算法成功复原图像;Liu等^[8]通过噪声分析对图像复原技术进行了改进;魏小峰等^[9]通过光瞳结构优化提高成像质量,从而减小图像复原的难度;周程灏等^[10]对MTF中频补偿的图像复原方法进行了探索。不过,传统图像复原

技术需要针对成像过程中的扰动特性进行分析,这严重依赖于人工设计的信息提取器。在成像过程未知的情况下,往往难以确定图像模糊和畸变的原因,导致图像复原难度增大,这时基于成像系统点扩展函数的非盲性复原算法失效。对于不同场景下的图像,传统图像复原技术需要通过专业调参以达到最优效果;对于同一场景下的不同图像,复原效果也极易受到目标种类和外界因素的干扰。传统图像复原技术各有其针对的问题,通常需要配合使用才能达到最佳效果。综上所述,传统图像复原技术的专业性、针对性有限,且其基于一定的先验信息,难以胜任各种场景图像的快速盲复原工作。

深度学习技术近年来得到快速发展,它通过构建深层神经网络并使用数据集对网络进行训练,利用众多神经节点的参数调节,建立起输入与输出之间的非线性映射关系,目前已在图像目标识别^[11]、自然语言处理^[12]等领域取得重大进展,并成功应用于超分辨率成像^[13]、散射介质成像^[14-15]、图像去噪^[16-17]、全息重建^[18-19]、相位提取^[20-21]等光学领域。深度学习利用基于数据的特征提取器,通过大量样本的训练和优化,能够从样本中提取出感兴趣的抽象特征。在样本数据和训练时长均充足的条件下,经过训练的网络能够准确理解图像信息,并迅速产生对应输出,具有不错的鲁棒性和泛化能力,可以适应各种端对端的图像处理工作。针对光学合成孔径成像系统中的图像复原问题,本文提出一种基于深度学习的图像复原方法,在成像模型分析和数值仿真基础上,将光学合成孔径成像系统所成图像设为输入,将原始图像作为标签,构建数据集用于U型卷积神经网络的训练和测试,以实现图像复原的目的,进而通过与盲解卷积算法的图像复原效果对比,验证所提出方法的可行性和优点。

2 方 法

2.1 合成孔径系统

光学合成孔径成像系统(后简称为合成孔径系统)属于非相干成像系统,其成像过程可用线性系统理论来描述。在单色光条件下,合成孔径系统的点扩展函数(又称光强脉冲响应,PSF)可以表示为

$$F_{\text{PSF}}(x, y) = |\text{FT}\{P(x_0, y_0)\}|^2 = \left| \iint P(x_0, y_0) \exp[-j2\pi(x_0 f_x + y_0 f_y)] dx_0 dy_0 \right|_{f_x = \frac{x}{\lambda f}, f_y = \frac{y}{\lambda f}}^2, \quad (1)$$

式中: $P(x_0, y_0)$ 为系统的光瞳函数; (x_0, y_0) 为光瞳面坐标;FT表示傅里叶变换; (x, y) 为像面坐标;

(f_x, f_y) 为对应的空间频率; λ 为光波波长; f 为系统焦距。对 PSF 作傅里叶变换后进行归一化处理或对光瞳函数进行归一化自相关处理,可得到系统的光学传递函数(OTF)为

$$F_{\text{OTF}}(f_x, f_y) = \frac{\text{FT}\{F_{\text{PSF}}(x, y)\}}{\text{FT}\{F_{\text{PSF}}(x, y)\}_{f_x=f_y=0}} = \frac{P(\lambda d_i f_x, \lambda d_i f_y) \otimes P(\lambda d_i f_x, \lambda d_i f_y)}{\iint P(x_0, y_0) dx_0 dy_0} = m(f_x, f_y) \exp[j\varphi(f_x, f_y)], \quad (2)$$

式中: d_i 为系统出瞳平面到像平面的距离; \otimes 表示自相关运算; $m(f_x, f_y)$ 是 OTF 的模,即 MTF; $\varphi(f_x, f_y)$ 是 OTF 的幅角,即 PTF。MTF 和 PTF 分别描述了光学系统对各频率分量的对比度传递特性和施加的相移。图 1 显示了合成孔径系统的

成像效果,其中图 1(a)是原始图像;图 1(b)是本文所采用的“Y”型孔径阵列分布图像,其可由(1)式中光瞳函数表示;图 1(c)是经系统成像后得到的模糊图像。根据(1)和(2)式,可得到合成孔径系统的 MTF。如图 2(a)所示,与等效单口径系统相比,“Y”型合成孔径系统的 MTF 曲线在低频段陡然下降,并在中频段低值附近维持波动。图 2(b)和图 2(c)显示了“Y”型合成孔径系统及其等效单口径系统 MTF 的二维和三维视图,可以看出,合成孔径系统的 MTF 主峰范围被压缩,次峰按规则分布扩展,高频区域内 MTF 与等效单口径系统的 MTF 近似,但中低频区域内 MTF 相差过大,这是导致图 1(c)中合成孔径系统所成图像模糊的主要原因。




图 1 光学合成孔径成像系统的成像效果。(a)原始图像;(b)合成孔径阵列分布图像;(c)所成图像
Fig. 1 Imaging effect of optical synthetic aperture imaging system. (a) Original image; (b) image of synthetic aperture array distribution; (c) imaging map

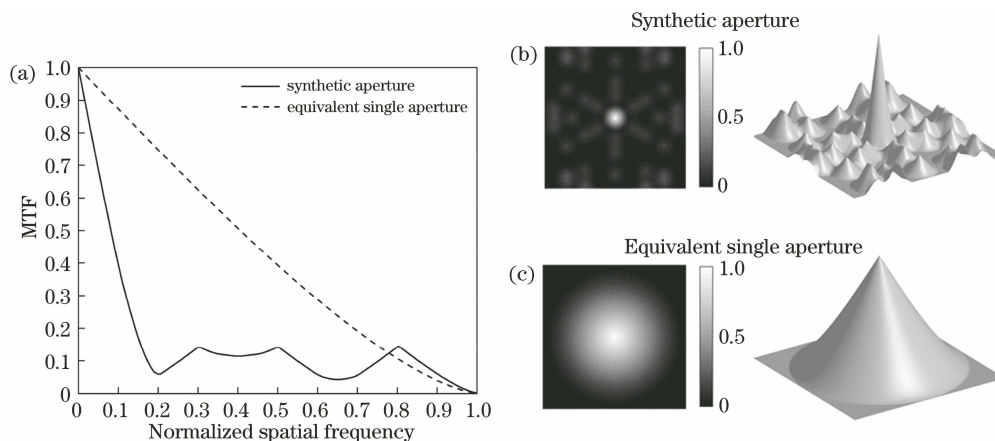


图 2 合成孔径系统及其等效单口径系统的 MTF 对比。(a) MTF 主峰截面曲线;(b)合成孔径系统的 MTF 示意图;(c)等效单口径系统的 MTF 示意图

Fig. 2 Comparison of MTF between synthetic aperture system and its equivalent single aperture system. (a) Section curve of main peak of MTF; (b) diagram of MTF of synthetic aperture system; (c) diagram of MTF of equivalent single aperture system

因此,根据上述系统的成像特性分析,可得到合成孔径系统所成图像在频域内的数学模型为

$$G(f_x, f_y) = F(f_x, f_y) \times F_{\text{OTF}}(f_x, f_y) + N(f_x, f_y), \quad (3)$$

式中: $F(f_x, f_y)$ 、 $G(f_x, f_y)$ 和 $N(f_x, f_y)$ 分别表示原始图像的强度谱、合成孔径系统所成图像的强度谱以及附加噪声的频谱。(3)式代表系统成像过程的普遍模型。因为实际观测目标往往非常遥远,携带目标信息的光波进入合成孔径系统时可近似为平面波,并且合成孔径技术也非常适用于遥感领域,因此选取灰度遥感图像作为原始图像来模拟观测目标。在合成孔径系统的各个子孔径均精确配准的情况下,携带物体信息的光束进入合成孔径系统后,会受到系统 OTF 的调制并最终在像面上形成干涉图像。实际情况下,目标成像过程存在光子散射噪声、环境噪声、CCD 相机的电子噪声等,在此假设合成孔径系统的成像过程较为理想,故在干涉图像上添加信噪比为 60 dB~70 dB 的加性高斯噪声以模拟弱噪声条件带来的影响,最终获得合成孔径系统所成图像。如图 1 所示,图 1(a)为用于模拟无穷远处观测目标的原始图像,图 1(b)为成像模型所使用的‘Y’型孔径阵列分布图像,其填充因子 $F=0.11$,图 1(c)是光波经过合成孔径系统并添加噪声后的模糊图像(后简称为系统所成图像)。所成图像存在由于 MTF 中频部分响应下降所带来的模糊现象,需要进行图像复原处理才能获得清晰图像。

针对合成孔径系统的图像复原问题,常用的算法包括在频域内进行滤波处理的维纳滤波器和在空域内进行解卷积处理的盲解卷积算法^[22-25]。然而,维纳滤波器及其变体大多需要使用成像系统的 PSF 作为模糊核进行图像复原,且只有在附加噪声和原始图像的功率谱之比已知或可估计情形下,才能展现出良好的图像复原能力。在系统 PSF 以及图像和噪声先验信息未知的情况下,图像复原效果不尽理想。本文采用盲解卷积算法,假定系统所成图像、系统 PSF 和原始图像均服从概率统计模型,根据贝叶斯理论并利用迭代近似找到模型的极大似然函数,以进行图像复原^[26]。该算法的最大优点在于不需要准确的系统 PSF 和完整的图像先验信息,仅通过迭代就能够同时复原系统 PSF 和图像,在实际处理图像复原问题上具有较大优势。由图 3(a)可见,通过盲解卷积算法的 50 次迭代计算对图像进行复原,模糊现象得到有效抑制。图 3(c)显示了图 3(a)中沿黑色虚线所在截面的归一化灰度曲线的对比结果。可以看出,系统所成图像的整体灰度相较于原始图像有较大下降,且物体边缘细节信息丢失严重,而通过盲解卷积算法的复原后,图像各部分灰度与原始图像十分接近且部分细节信息得到突出。但

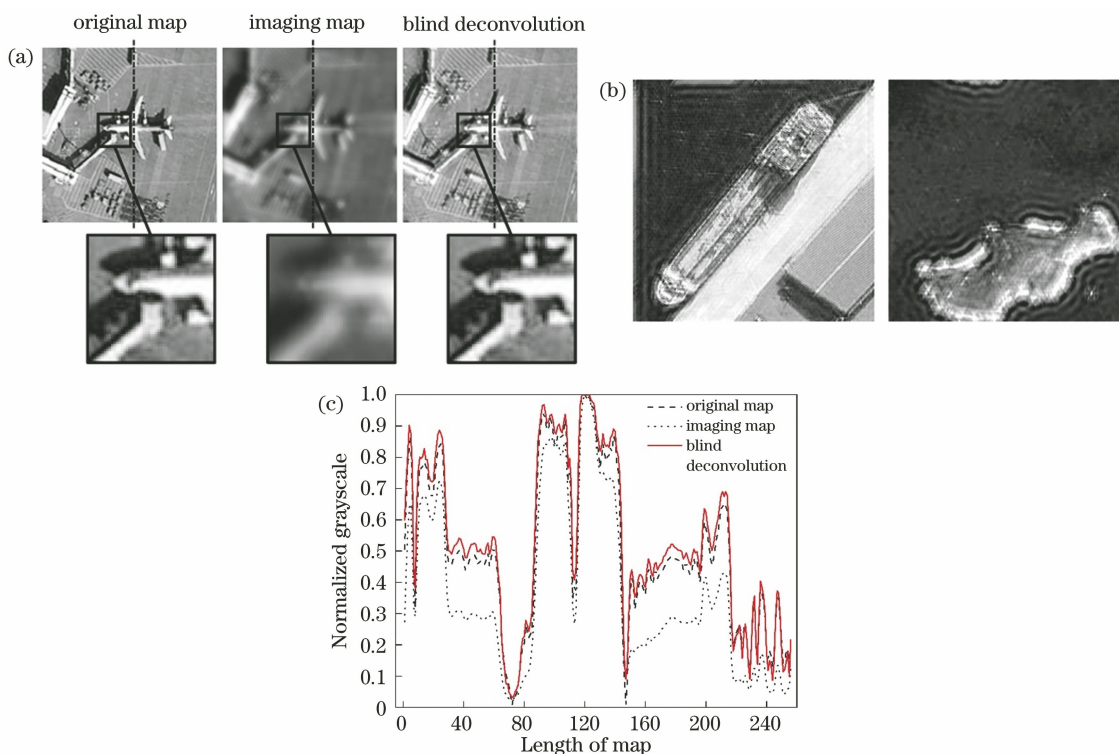


图 3 盲解卷积算法的图像复原效果。(a)盲解卷积算法复原图像对比;(b)振铃现象;(c)截面灰度对比曲线
Fig. 3 Restoration effect of blind deconvolution method. (a) Restoration maps of blind deconvolution method;
(b) ringing phenomenon; (c) comparison of section gray curves

是,盲解卷积算法的计算时间和复原效果受初始 PSF 和迭代次数的影响较大。当初始 PSF 与系统真实 PSF 相差较大时,图像复原的难度也会增大且最终的复原效果变差。当迭代次数过少时,图像复原效果不理想;当迭代次数过多时,噪声会被急剧放大,导致复原效果变差。通常,在选定较好的初始 PSF 的情况下,用盲解卷积算法复原一张图像时的 50 次迭代计算需耗时约 2 s。此外,复原过程中的盲解卷积算法还会在物体边缘和图像边缘区域产生不同程度的振铃效应,如图 3(b)所示。因此,虽然盲解卷积算法能够在图像先验信息未知的情况下提供复原图像的可能性,但其盲复原能力有待提升,同时大批量图像复原工作任务需要充足的计算资源和较高的时间成本,难以应用于需实时反馈的场景。

2.2 U 型深度卷积神经网络

深度学习通过构建多层神经网络,经过大量样本的持续训练,最终建立输入与输出之间的非线性映射关系,可替代传统算法应用于光学合成孔径系统的图

像复原。与全连接神经网络相比,卷积结构的参数共享机制可使卷积神经网络的计算量大幅减少,从而节约计算资源,降低时间成本。因此,本文采用如图 4 所示的 U 型深度卷积神经网络(U-net),其整体为编码-解码器结构,分为下采样、跳跃连接和上采样三部分,训练过程相对简单^[27]。U-net 与原网络的区别在于:U-net 在原网络中添加了批量归一化(BN)操作和值为 0.2 的神经节点丢失率(Dropout),以达到增大训练速度、提升网络泛化能力、避免梯度消失和过拟合的目的^[28-29]。此外,本文还将激活函数设为 leaky ReLU 以避免反向传播过程中梯度为零时导致的神经元停止学习现象,同时选取 Adam 优化器优化输出与标签之间的均方误差值,通过不断反馈、调节网络参数,使得网络的输出与标签的相似度越来越高。该网络基于 Python 3.7 的 Tensorflow 1.13.1 框架搭建,在配置为 Intel Core Processor (Haswell, no TSX) CPU (2.5 GHz)、NVIDIA GeForce GTX 1080Ti GPU 的计算机上完成训练和测试。




图 4 U-net 结构

Fig. 4 Structure of U-net

利用数值仿真获得的系统所成像和对应的原始图像构建数据集,将系统所成像作为网络输入,对应的原始图像作为网络标签。数据集分为训练集和测试集两部分,训练 U-net 的过程中,网络只会学习训练集的内容,而测试集不参与训练。训练完成后,使用测试集测试网络效果,将测试集内的系统所成像输入网络,U-net 会迅速输出对应的复原图像。

2.3 图像评价标准

峰值信噪比(PSNR)和结构相似度(SSIM)是数字图像处理中常用的两种像质评价标准^[30]。为便于比较,本文中同时利用 PSNR 和 SSIM 对盲解卷积算法和 U-net 的图像复原效果进行比较。

PSNR 通过量化比较两张图像之间对应像素点值的差距来客观评价图像的失真程度,其计算公式为

$$R_{\text{PSNR}} = 10 \times \lg \left[\frac{(2^N - 1)^2}{E_{\text{MSE}}} \right], \quad (4)$$

$$E_{\text{MSE}} = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W [X(i, j) - Y(i, j)]^2, \quad (5)$$

式中: X 、 Y 分别表示输入图像与原始图像; E_{MSE} 为两张图像的均方误差; H 、 W 分别表示图像的高度和宽度; N 为每像素的比特数, 一般取 8。一般而言, PSNR 值越大, 代表图像失真越少, 但其像质评价结果与人的视觉感受稍有差异。SSIM 是一种主观衡量两幅图像相似度的指标, 其结果与人眼视觉感受较为接近, 其计算公式为

$$M_{\text{SSIM}} = \frac{(2\mu_X\mu_Y + c_1)(2\sigma_{XY} + c_2)}{(\mu_X^2 + \mu_Y^2 + c_1)(\sigma_X^2 + \sigma_Y^2 + c_2)}, \quad (6)$$

式中: μ_X 、 μ_Y 分别表示 X 和 Y 的均值; σ_X 、 σ_Y 分别表示 X 和 Y 的方差; σ_{XY} 表示 X 和 Y 的协方差; $c_1 = (k_1L)^2$, $c_2 = (k_2L)^2$ 是稳定常数, 其中 $k_1 = 0.01$, $k_2 = 0.03$, L 是像素的动态范围, 一般取 255。SSIM 从亮度、对比度和结构三方面对图像质量进行评价, 其取值范围为 $[0, 1]$, 其值越接近 1, 代表图像越相似。

3 分析与讨论

为证明 U-net 的图像复原效果以及其针对不同目标的泛化能力, 针对性地设计了实验 1 和实验 2,

表 1 不同数据集与网络的对应表

Table 1 Correspondence table of different datasets and networks

Experiment	Experiment 1		Experiment 2			
	Dataset	Train set 1	Test set 1	Train set 2A	Train set 2B	Test set 2
Number of maps		2-500	50	1000	1000	300
Number of map types		1	1	2	10	10
Corresponding network		U-net1(N)		U-net2A	U-net2B	U-net2A, U-net2B

后, 从同类图像中随机选取 50 幅与训练集 1 不重叠的图像作为测试集 1 来测试复原效果, 测试过程耗时约 1 s。测试集 1 的图像复原效果如图 5 所示, 在与系统所成图像的对比下, 除了用 2 幅图像训练的 U-net1(2) 的复原效果较差之外, 采用其他训练集训练获得的 U-net1 均能抑制合成孔径系统带来的成像模糊并有效复原图像。通过对比盲解卷积算法的图像复原效果可得, 由 U-net1 复原的图像能有效避免物体和图像边缘存在的振铃现象, 在视觉上更为清晰。通过进一步对比原始图像可知, 由 U-net1 复原的图像在整体对比度上存在差异, 在物体微细结

构信息复原效果上仍有进步空间。从表 2 展示的测试集 1 的平均 PSNR 和 SSIM 来看, 当训练集图像数量从 2 幅增加到 100 幅时, U-net1 的复原图像的 PSNR 值从 19.63 提升至 23.33, SSIM 值从 0.64 提升至 0.80, 网络的复原能力逐渐提升; 而训练集图像数量从 100 幅增加至 500 幅时, U-net1 的复原图像 PSNR 值和 SSIM 值基本稳定在 23 和 0.80 左右, 网络复原能力基本保持稳定。由此可见, 训练后的 U-net1 确实能够有效实现图像复原并避免振铃现象, 其复原图像在视觉上比盲解卷积算法的复原图像更为清晰, 而其耗时仅为盲解卷积算法的 1/100。

3.1 实验 1

在实验 1 中, 为证实 U-net 的图像复原能力以及训练集图像数量对 U-net 复原能力的影响, 从飞机类图像中随机选取 2, 5, 10, 50, 100, 250, 500 幅图像作训练集 1 来训练 U-net1, 其中利用 N 幅图像的训练集所训练的网络称为 U-net1(N)。训练完成

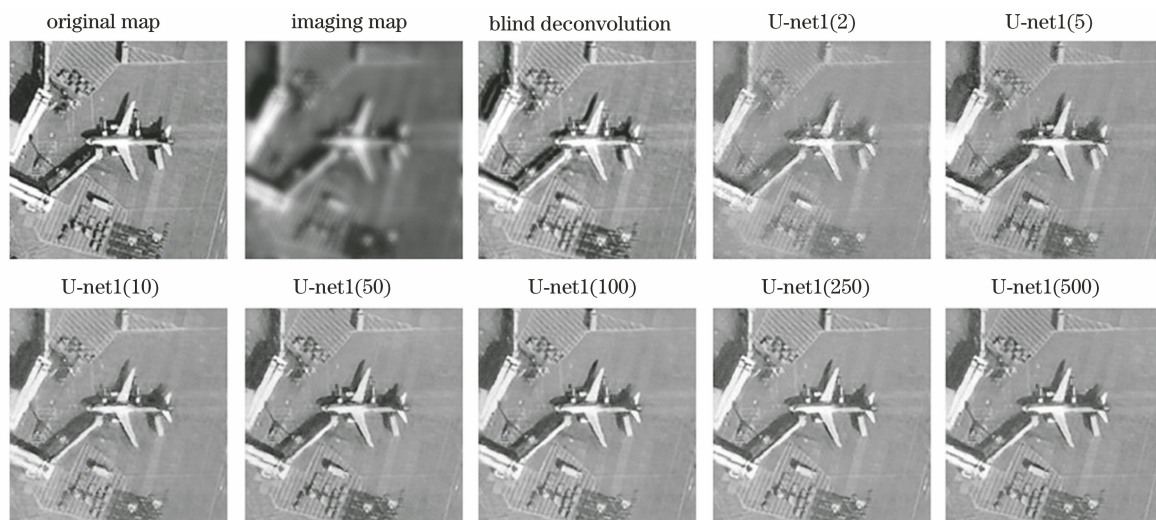


图 5 不同训练集下 U-net1 的复原效果对比

Fig. 5 Comparison of recovery effects of U-net1 under different training datasets

表 2 测试集 1 的平均 PSNR 和 SSIM

Table 2 Average PSNR and SSIM of test set 1

Parameter	Imaging map	Restoration map							
		Blind deconvolution	U-net1						
			(2)	(5)	(10)	(50)	(100)	(250)	(500)
PSNR /dB	16.52	22.99	19.63	20.51	22.21	23.43	23.33	22.73	22.99
SSIM	0.48	0.82	0.64	0.71	0.75	0.78	0.80	0.80	0.81

并且, U-net1 在训练过程只需少量图像作为训练集, 即可获得一定的复原能力。

3.2 实验 2

U-net 对系统所成图像具有一定的复原能力, 但在实际应用过程中难以保证所获取图像的数量, 且图像种类也会受到实际条件的制约, 而不同种类图像的信息差异巨大。为研究 U-net 的泛化能力及训练集图像种类对其泛化能力的影响, 在实验 2 的训练集 2A 中选取飞机和机场两类图像各 500 幅, 共计 1000 幅图像用以训练 U-net2A; 训练集 2B 选取飞机、机场、河流、沙漠等 10 类图像各 100 幅, 共计 1000 幅图像用以训练 U-net2B; 测试集 2 则选取沙滩、桥梁、岛屿、高山等 10 类图像各 30 幅, 共计 300 幅图像, 用于测试 U-net2A 网络和 U-net2B 的复原能力。需要特别指出的是, 为防止训练获得的 U-net 对某一类图像产生依赖, 导致其在泛化过程中对其他种类图像的复原能力下降。训练集和测试集中每类图像的数量相等, 但图像的选取过程完全随机, 且训练集和测试集图像互不重叠。训练过程持续 700 个 epoch, 耗时约 6 h。测试过程共用 300 幅图像, 耗时约 9 s。因为测试集所选图像种类与训

练集没有重叠, 因此可认为其测试结果证明 U-net 具有较好的泛化能力。从图 6 中可以看出, 经过盲解卷积算法复原的图像虽然和原图较为相似, 但仍然存在振铃现象。而经 U-net2A 和 U-net2B 复原后的图像整体对比度有所下降, 但由合成孔径系统带来的图像模糊已经被抑制, 且没有振铃现象, 在视觉上更加清晰。从表 3 中可以看出, 系统所成图像的平均 PSNR 和 SSIM 分别降至 16.08 和 0.39, 而经过 U-net2A 和 U-net2B 复原后图像的平均 PSNR 分别上升至 20.51 和 22.21, SSIM 分别上升至 0.74 和 0.77, 这与盲解卷积算法复原图像的平均 PSNR 和 SSIM (分别为 21.87 和 0.78) 极为接近。在训练集图像数量相等的情况下, 虽然训练集 2B 比训练集 2A 多了 8 种图像, 但面对完全陌生的测试集 2 时, U-net 的表现效果仅有略微提升。因此, 可认为训练集 2A 所含图像的信息已经足够丰富, 后续图像种类的增加对 U-net 的泛化能力并无明显影响。由此可以证明, U-net 在训练后能够有效复原系统所成图像, 并且仅使用部分种类的少量图像就能拥有较强的复原能力和泛化能力, 因此不会对训练集产生过度依赖。

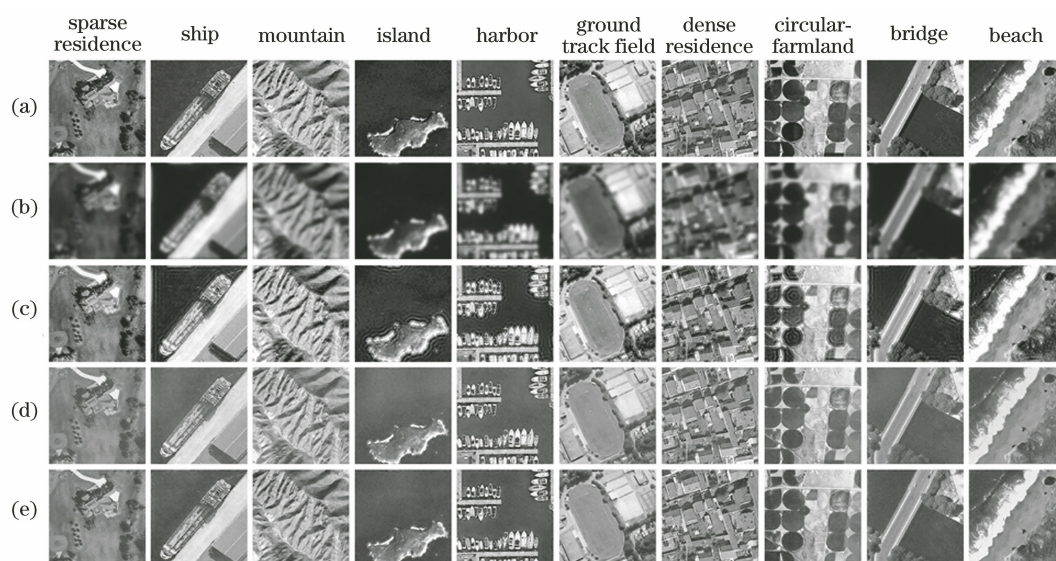


图 6 不同复原方法的效果对比。(a)原始图像;(b)所成图像;(c)盲解卷积所得图像;(d) U-net2A 所得图像;(e) U-net2B 所得图像

Fig. 6 Comparison of effects of different recovery methods. (a) Original images; (b) imaging maps; (c) images obtained by blind deconvolution; (d) images obtained by U-net2A; (e) images obtained by U-net2B

表 3 测试集 2 的平均 PSNR 和 SSIM

Table 3 Average PSNR and SSIM of test set 2

Parameter	Imaging map	Restoration map		
		Blind deconvolution	U-net2A	U-net2B
PSNR /dB	16.08	21.87	20.51	22.21
SSIM	0.39	0.78	0.74	0.77

4 结 论

由上述实验 1 和实验 2 的对比分析可知,在弱噪声条件下,U-net 能够成功复原合成孔径系统所成图像,并在复原效果上与盲解卷积算法接近。在训练过程中,U-net 仅需少量含有丰富信息的图像构成训练集,而对图像种类没有严格要求,可训练出具有良好复原能力和泛化能力的 U-net。面对完全陌生且没有任何先验信息的合成孔径系统所成图像,U-net 能够快速、便捷地开展复原工作。与盲解卷积算法相比,U-net 能够有效避免振铃现象,且盲复原能力更强,在使用时无需任何先验信息和参数调节过程就能获得清晰的复原图像,其耗时仅为盲解卷积算法的 1/100,更加适用于需要大批量复原图像和实时反馈的场景。

参 考 文 献

[1] Barakat R. Dilute aperture diffraction imagery and object reconstruction[J]. Optical Engineering, 1990, 29(2): 131-139.

[2] Lü Y K, Wu Y H. Development and key technologies of synthetic aperture ladar imaging [J]. Laser & Optoelectronics Progress, 2017, 54(10): 100004.
吕亚昆, 吴彦鸿. 合成孔径激光雷达成像发展及关键技术[J]. 激光与光电子学进展, 2017, 54(10): 100004.

[3] Li D Y, Wu J, Wan L, et al. Elementary imaging theory on space-borne synthetic aperture ladar [J]. Acta Optica Sinica, 2019, 39(7): 0728002.
李丹阳, 吴谨, 万磊, 等. 天基合成孔径激光雷达成像理论初步[J]. 光学学报, 2019, 39(7): 0728002.

[4] Bell K D, Boucher R H, Vacek R, et al. Assessment of large aperture lightweight imaging concepts[C]//1996 IEEE Aerospace Applications Conference. Proceedings, February 10, 1996, Aspen, CO, USA. New York: IEEE Press, 1996: 187-203.

[5] Fienup J R, Griffith D K, Harrington L, et al. Comparison of reconstruction algorithms for images from sparse-aperture systems [J]. Proceedings of SPIE, 2002, 4792: 1-8.

[6] Wang D, Han J, Liu H, et al. Experimental study on imaging and image restoration of optical sparse aperture systems[J]. Optical Engineering, 2007, 46(10): 103201.

[7] Wu Q Y, Qian L, Shen W M. Image recovering for sparse-aperture systems [J]. Proceedings of SPIE, 2005, 5642: 478-486.

[8] Liu L, Jiang Y S, Wang C W. Noise analysis and image restoration for optical sparse aperture systems [C]//2008 International Workshop on Education Technology and Training & 2008 International

- Workshop on Geoscience and Remote Sensing, December 21-22, 2008, Shanghai, China. New York: IEEE Press, 2008: 353-356.
- [9] Wei X F, Geng Z X, Cao L, et al. A novel imaging performance index and pupil optimization method for optical synthetic aperture system [J]. *Acta Optica Sinica*, 2014, 34(11): 1111001.
魏小峰, 耿则勋, 曹力, 等. 一种新的光学合成孔径系统成像性能指标与光瞳优化方法 [J]. *光学学报*, 2014, 34(11): 1111001.
- [10] Zhou C H, Wang Z L, Zhang S Q, et al. Large aperture diffraction limited optical synthetic aperture system intermediate frequency MTF compensation [J]. *Acta Optica Sinica*, 2018, 38(4): 0411005.
周程灏, 王治乐, 张树青, 等. 大孔径衍射受限光学合成孔径系统 MTF 中频补偿 [J]. *光学学报*, 2018, 38(4): 0411005.
- [11] Wang F, Jiang M Q, Qian C, et al. Residual attention network for image classification [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6450-6458.
- [12] Sarikaya R, Hinton G E, Deoras A. Application of deep belief networks for natural language understanding [J]. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2014, 22(4): 778-784.
- [13] Rivenson Y, Koydemir H C, Wang H, et al. Deep learning enhanced mobile-phone microscopy [J]. *ACS Photonics*, 2018, 5(6): 2354-2364.
- [14] Lyu M, Wang H, Li G, et al. Learning-based lensless imaging through optically thick scattering media [J]. *Advanced Photonics*, 2019, 1(3): 036002.
- [15] Li Y Z, Xue Y J, Tian L. Deep speckle correlation: a deep learning approach towards scalable imaging through scattering media [EB/OL]. (2018-09-26) [2020-06-19]. <https://arxiv.org/abs/1806.04139>.
- [16] Zhang K, Zuo W M, Chen Y J, et al. Beyond a Gaussian denoiser: residual learning of deep CNN for image denoising [J]. *IEEE Transactions on Image Processing*, 2017, 26(7): 3142-3155.
- [17] Yan K T, Yu Y J, Huang C T, et al. Fringe pattern denoising based on deep learning [J]. *Optics Communications*, 2019, 437: 148-152.
- [18] 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.
- [19] Wang H, Lyu M, Chen N, et al. In-line hologram reconstruction with deep learning [EB/OL]. (2018-01-10) [2020-06-19]. https://www.researchgate.net/publication/325829075_In-line_hologram_reconstruction_with_deep_learning.
- [20] Wang K Q, Li Y, Qian K M, et al. One-step robust deep learning phase unwrapping [J]. *Optics Express*, 2019, 27(10): 15100-15115.
- [21] Wang K Q, Di J L, Li Y, et al. Transport of intensity equation from a single intensity image via deep learning [J]. *Optics and Lasers in Engineering*, 2020, 134: 106233.
- [22] Wei X F, Geng Z X, Song X. Detection and removal of ringing artifact for optical synthetic aperture restoration image [J]. *Optics and Precision Engineering*, 2014, 22(11): 3091-3099.
魏小峰, 耿则勋, 宋向. 光学合成孔径复原图像的振铃探测与消除 [J]. *光学精密工程*, 2014, 22(11): 3091-3099.
- [23] Xu W H, Zhao M, Li H S. Non-iterative wavelet-based deconvolution for sparse aperture system [J]. *Optics Communications*, 2013, 295: 36-44.
- [24] Kundur D, Hatzinakos D. Blind image deconvolution [J]. *IEEE Signal Processing Magazine*, 1996, 13(3): 43-64.
- [25] Kundur D, Hatzinakos D. A novel blind deconvolution scheme for image restoration using recursive filtering [J]. *IEEE Transactions on Signal Processing*, 1998, 46(2): 375-390.
- [26] Yang H L, Chiao Y H, Huang P H, et al. Blind image deblurring with modified Richardson-Lucy deconvolution for ringing artifact suppression [C]//Proceedings of the 5th Pacific Rim conference on Advances in Image and Video Technology, November 20-23, 2011, Heidelberg: Springer, 2011: 240-251.
- [27] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation [M]//Lecture Notes in Computer Science. Cham: Springer International Publishing, 2015: 234-241.
- [28] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift [EB/OL]. (2015-02-11) [2020-06-19]. <https://arxiv.org/abs/1502.03167>.
- [29] Srivastava N, Hinton G E, Krizhevsky A, et al. Dropout: a simple way to prevent neural networks from overfitting [J]. *Journal of Machine Learning Research*, 2014, 15(1): 1929-1958.
- [30] Horé A, Ziou D. Image quality metrics: PSNR vs. SSIM [C]//2010 20th International Conference on Pattern Recognition, August 23-26, 2010, Istanbul, Turkey. New York: IEEE Press, 2010: 2366-2369.
- [31] Cheng G, Han J W, Lu X Q. Remote sensing image scene classification: benchmark and state of the art [J]. *Proceedings of the IEEE*, 2017, 105(10): 1865-1883.