

基于生成对抗网络的无透镜成像方法

张超^{1,2}, 邢涛^{1,2}, 刘紫珍^{1,2}, 何昊昆^{1,2}, 沈华^{1,2*}, 卞殿旭^{1,2}, 朱日宏^{1,2}

¹南京理工大学电子工程与光电技术学院, 江苏 南京 210094;

²工业和信息化部先进固体激光重点实验室, 江苏 南京 210094

摘要 无透镜同轴全息图中包含零级像和孪生像噪声,采用基于菲涅耳衍射模型的方法进行抑制时需要多幅无透镜图像。针对此问题,提出一种基于生成对抗网络(GAN)的无透镜成像方法。首先计算部分相干光照明下无透镜图像的离焦距离,根据该离焦距离反向衍射传播,得到含零级像和孪生像的物平面图像。然后对该物平面图像与作为标准参考的商用显微镜图像进行配准,将配准后的图像作为GAN的训练样本,训练后得到GAN的核函数。最后用训练好的核函数对无透镜图像进行处理,得到清晰的目标图像。实验结果表明,所提方法可对零级像和孪生像有效抑制,图像的对比度和清晰度明显提高,效果可达4×商用显微物镜。所提方法在图像重建阶段只需单张无透镜图像且无需傅里叶变换等复杂操作,成像时间大大缩短。相比于基于卷积神经网络(CNN)的方法,所提方法需要的训练数据量更少,损失函数更易收敛,具有更高的处理效率。

关键词 成像系统; 无透镜成像; 深度学习; 生成对抗网络; 相位恢复; 图像重建

中图分类号 O438

文献标志码 A

doi: 10.3788/AOS202040.1611003

Lens-Free Imaging Method Based on Generative Adversarial Networks

Zhang Chao^{1,2}, Xing Tao^{1,2}, Liu Zizhen^{1,2}, He Haokun^{1,2}, Shen Hua^{1,2*},
Bian Yinxiu^{1,2}, Zhu Rihong^{1,2}

¹ School of Electronic and Optical Engineering, Nanjing University of Science & Technology, Nanjing, Jiangsu 210094, China;

² Key Laboratory of Advanced Solid Laser, Ministry of Industry and Information Technology, Nanjing, Jiangsu 210094, China

Abstract Lens-free inline holography contains zero-order image noise and twin image noise. Methods based on the Fresnel diffraction model can suppress these noise, but require many lens-free images. To resolve this problem, this paper proposes a lens-free imaging method based on generative adversarial networks (GAN). First, the defocusing distance of a lens-free image is calculated under partially coherent illumination, and the object plane image with zero-order image and twin image is reconstructed through back diffraction propagation according to the defocusing distance. Next, the object plane image is registered with commercial microscope images which are the gold standard. The registered images are taken as the training inputs of the GAN. Finally, the trained kernel function of the GAN is used for reconstructing the lens-free images, thus obtaining clear target images. The experimental results show that the proposed method can effectively suppress the zero-order image and twin image and significantly improve (up to 4× commercial microscope objective) the contrast and clarity of the image. Because the proposed method requires only a single lens-free image and omits Fourier transforms and other complex operations in the image reconstruction stage, it greatly shortens the imaging time. The proposed method requires fewer training data, better converges the loss function, and has higher processing efficiency than the method based on convolutional neural networks (CNN).

Key words image systems; lens-free imaging; deep learning; generative adversarial network; phase recovery; image reconstruction

OCIS codes 110.0180; 110.1758; 110.3010; 110.2960

收稿日期: 2020-01-14; 修回日期: 2020-05-06; 录用日期: 2020-05-18

基金项目: 江苏省基础研究计划(BK20190456)、江苏省重点研发计划(BE2019114)、中国科学院光学系统先进制造技术重点实验室面上开放课题(KLOMT190101)、南京理工大学自主科研项目(30919011261)

* E-mail: edward_bayun@163.com

1 引 言

无透镜成像是指不使用任何透镜,直接应用 CCD/CMOS 图像传感器记录样品信息。由于不使用光学透镜,系统的体积和质量得以大大缩减,更有利于便携式应用。相比于商用显微镜,无透镜显微成像系统在保证分辨率的同时,由于其视场大小由 CCD/CMOS 图像传感器的感光面积决定,因此拥有更大的成像视场。无透镜成像系统因具有大视场、高分辨、便携式等优点,在野外水质检测、移动医疗设备等领域中得到广泛应用。但是无透镜同轴全息图像往往同时包含零级像和孪生像,如何分离两种像或抑制这两种像的互扰是目前无透镜成像技术的关键瓶颈。现在通常的抑制方法为从菲涅耳衍射模型出发,基于物理模型和边界条件,通过光强度信息来求解相位信息,进而对无透镜同轴全息图像进行恢复,消除零级像和孪生像的干扰。在应用过程中,这些方法需要几十甚至上百次傅里叶变换,使得成像的处理时间大幅增加。此外,为了实现相位恢复和图像重建,目前的抑制方法如改变光源口径大小^[1-4]、改变样品到成像传感器的距离^[5-9](在某些情况下称为离焦距离^[10])、改变照明光波长^[11-12]或参考光束的相位^[13-16]、其他方法^[17-22],往往需要记录额外的强度信息。所有这些措施都是通过附加的物理约束结合强度测量,计算波动方程的解析解或迭代解来恢复丢失的相位信息。但是这些方法都需要改变系统条件来记录额外的光强度信息,无法满足成像的实时性。

近年来,基于深度学习的成像方法已经在光学成像领域得到广泛研究,如在相位恢复、图像重建等过程中都开始使用深度学习理念。对于无透镜同轴全息中零级像和孪生像的抑制问题,相比于基于菲涅耳衍射模型的方法,基于深度学习的图像处理方法无需改变成像系统的硬件条件,图像重建过程只需单张无透镜图像,因此成像时间大大缩减。目前,基于深度学习的图像处理方法主要是基于监督学习的卷积神经网络(CNN)。Rivenson 等^[23]对 CNN 方法进行了研究,将无透镜图像作为 CNN 的输入,将 TIE/G-S 迭代处理的图像作为输出对 CNN 进行训练,将训练好的 CNN 用于无透镜成像,对孪生像进行了抑制。Ren 等^[24]通过 CNN 实现了快速自聚焦,将无透镜全息中的自动聚焦作为回归问题,将距离估计转换为全息图预测,实现了离焦距离的快速计算,并对离焦反向传播全息图和相应的聚焦相

位恢复图进行 CNN 训练,实现了图像的相位恢复。Wu 等^[25]用 CNN 方法实现了无透镜图像的相位恢复,在抑制孪生像的同时扩展了成像的景深。还有研究团队^[26-28]将 CNN 方法用于无透镜成像的相位恢复和重建。深度学习的方法是将以往的模型问题转换为数据问题,通过“训练数据”来解决问题,利用基于深度学习的方法对问题进行求解时更依赖于数据,而非问题模型,因此大量且准确的数据是基于深度学习的方法所必需的。目前基于 CNN 的方法理论上需要大量的训练样本,时间耗费较大。

根据以上分析,本文提出一种基于生成对抗网络(GAN)的无透镜成像方法,用于无透镜图像的恢复过程,从而有效抑制零级像和孪生像互扰的问题。该方法通过计算 LED 照明下无透镜图像的离焦距离,根据该离焦距离进行反向衍射传播,得到含零级像和孪生像的物平面图像。将对重建的物图像与显微镜下图像进行配准后的结果作为样本训练 GAN,将生成的核函数用于处理无透镜图像,从而得到清晰的目标图像。所提方法在图像重建阶段只需单张无透镜图像,成像时间大大缩短。

2 方法原理及算法过程

2.1 无透镜成像系统构成及原理

无透镜成像是指将被成像样品放置于 CMOS 图像传感器前,不使用任何透镜,直接进行成像记录。无透镜成像系统装置如图 1(a)所示,照明光选用 480 nm 波长的蓝光 LED,功率为 3 W,LED 发出的光经光纤耦合器进入芯径为 200 μm 的光纤,经过光纤的空间滤波作用后形成均匀光束。尺寸为 25 mm \times 75 mm 的生物样品由载物装置固定于 CMOS 图像传感器上方,通过精密位移调整装置实现样品在 x - y 方向的姿态调整,使得样品位于视场中央区域。裸板型 CMOS 图像传感器(DMM27UJ003-ML, ImagingSource, Germany)的像素尺寸为 1.67 μm ,成像面积为 6.4 mm \times 4.6 mm,能直接记录样品的离焦图像。

本实验的光路如图 1(b)所示,LED 经光纤滤波后对生物样品进行照明,实际照明光源为光纤的出光端。实际光源与生物样品的距离约为 15 cm,生物样品与 CMOS 的距离约为 700 μm 。由于 CMOS 感光区域很小(尺寸为 mm 量级),在感光区域内的波前半径相对很大,因此在 CMOS 尺寸范围内的波前半径相对很大,因此在 CMOS 尺寸范围内的光波可以等效为平面波,故简化照明方式为近似平面波照明,这避免了放大倍率对成像的影响。

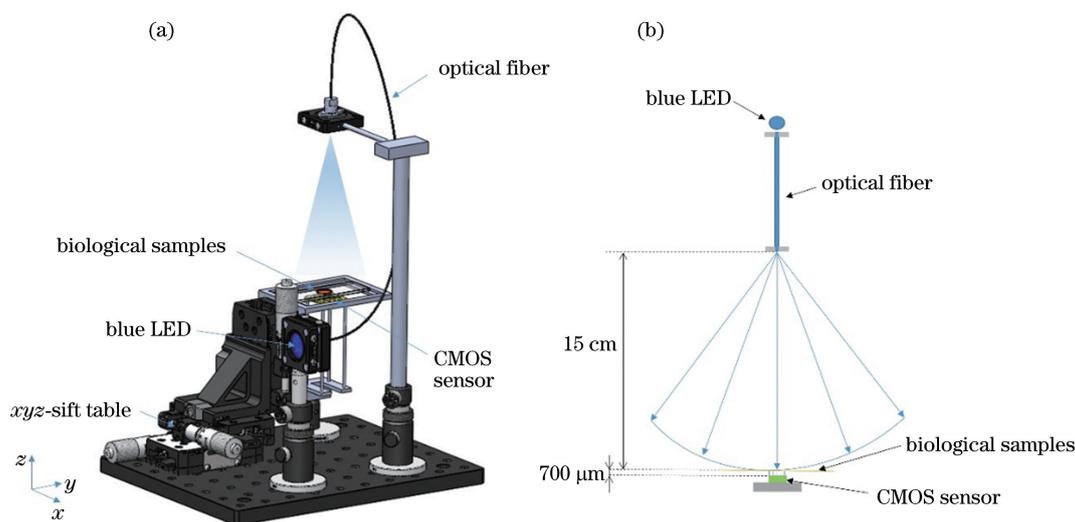


图 1 无透镜成像实验装置及光路。(a)实验装置图;(b)光路示意图

Fig. 1 Lens-free imaging experimental device and light path. (a) Diagram of experimental device; (b) diagram of light path

所提方法对无透镜图像进行处理的流程如图 2 所示,其中 d 为离焦距离。CMOS 获得样品的离焦图像,利用自动聚焦算法计算出图像的离焦距离,通过角谱传播理论,利用离焦距离反向计算重构出物平面样品图。该样品图中有零级像和孪生像的干扰。

将该物平面样品图和相应的商用显微镜下的图像作为训练样本,通过多次采集不同生物切片的图像样本来训练 GAN。最终训练完成的 GAN 可处理恢复样品的相位信息,对单张无透镜图像中的零级像和孪生像进行抑制,从而重建出清晰的样品图像。

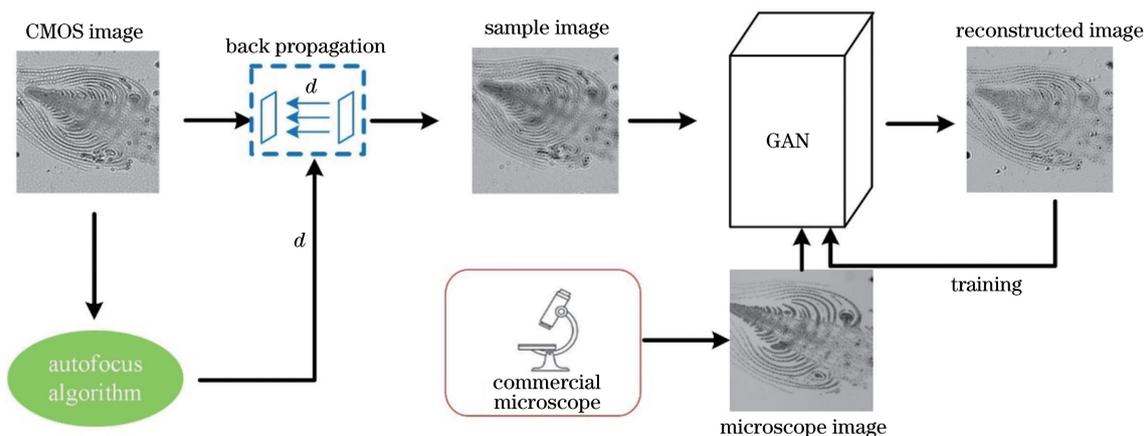


图 2 无透镜图像处理流程图

Fig. 2 Flow chart of lens-free imaging processing

2.2 离焦距离计算方法

CMOS 记录的是样品的离焦图,要想获得目标图像,需要将该离焦图反向传播至物平面(反向传播后的图像中含零级像和孪生像)。由于该反向传播过程是基于角谱传播理论的,传播距离的准确性影响重建物平面图像的清晰度,因此需要准确得到衍射传播距离,即离焦距离 d 。本文提出了一种降低硬件依赖性的算法,利用离焦图像自身来计算离焦距离。

反向传播再现物平面图像时需要的并不是轴向传播的物理距离,而是在各个介质中的光学衍射传播距离。通常在平面光波照射下,光从物平面 $u(x_0, y_0; 0)$ 传播到探测平面 $u(x, y; d)$ 满足的方程式为

$$u(x, y; d) = \iint u(x_0, y_0; 0)h(x - x_0, y - y_0; d)dx_0 dy_0, \quad (1)$$

式中: $h(x - x_0, y - y_0; d)$ 为非涅耳传播核函数。对图像传感器探测到的光场复振幅的强度值进行反

向计算,就能得到物平面上的复振幅分布。离焦距离 d 的准确性体现在重建的物平面图像的清晰度上。提出的自动聚焦算法就是通过重建的物平面图像清晰度的变化来获得光学衍射传播距离 d 。该算法首先需要预估 d 的取值范围;然后在这个范围内等间隔地对 d 赋值,以这些 d 值反向重建物平面图像;通过观察这些 d 值下重建的图像清晰度,确定最佳的 d 值;再以此值细化 d 的取值范围,重复以上过程,直到 d 的取值范围小于设定的阈值,此时的 d 值即为所求的准确离焦量。具体步骤如图 3 所示。

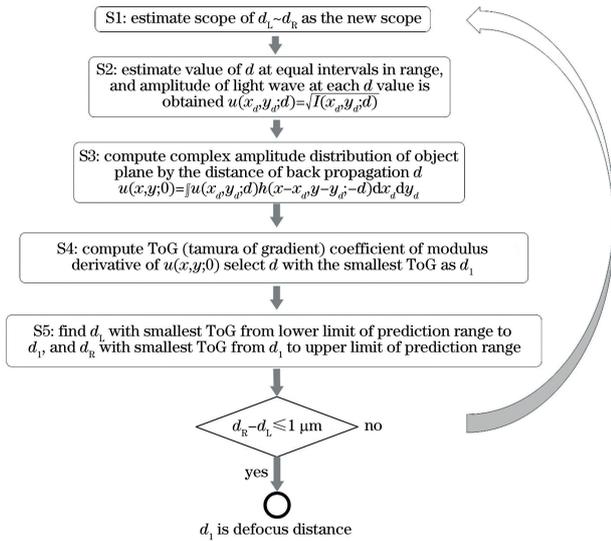


图 3 离焦距离计算原理

Fig. 3 Calculation principle of defocus distance

由于 CMOS 图像传感器只记录光波的强度信息,其相位信息是缺失的,因此反向传播重建的物平面图像中会包含零级像和孪生像,如图 4 所示。

零级像反映在背景光强上,主要影响图像的对比度;孪生像则和真实像混叠在一起,使得图像模糊、可读性差。

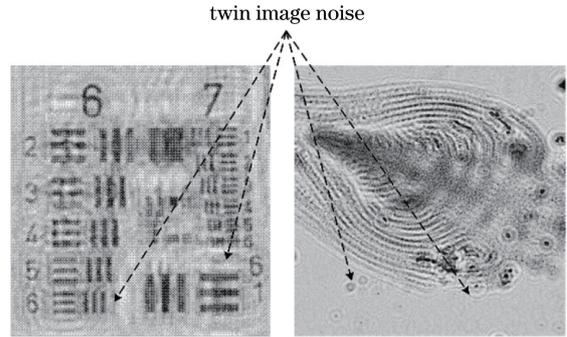


图 4 反向传播重建的物图像

Fig. 4 Object image reconstructed by back-propagation

2.3 基于 GAN 的相位恢复和图像重建算法

GAN 方法是基于博弈学的思想,其主要的两个工作单元分别为生成网络(GN)和判别网络(DN)。GN 负责生成一幅和目标图像接近的图像, DN 负责判别图像是否由 GN 生成或是真实目标图像。GN 和 DN 是两个独立的网络,它们在训练的过程中建立联系,工作原理如图 5 所示,其中 CM 为商用显微镜图像, SM 为含有孪生像的重建物图像。将无透镜图像作为 GN 的输入,将 GN 输出的生成图像和商用显微镜下的图像共同作为 DN 的输入,对 DN 进行训练,优化各层的权值和偏置。在 DN 训练完成后,将其参数固定,同时将训练得到的误差回传至 GN,更新 GN 参数,生成新的图像并将其再次作为 DN 的输入样本,不断重复上述过程。上述训练过程单独交替训练,设定迭代次数,直到 GAN 训练完成。

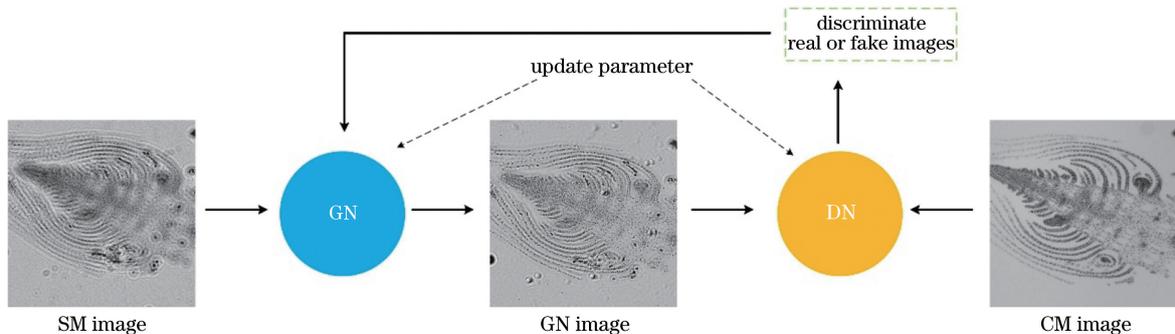


图 5 GAN 原理图

Fig. 5 Diagram of GAN principle

GN 主要由卷积层、激活层、多个残差层、若干激活层及卷积层构成,结构如图 6(a) 所示。将带有零级像和孪生共轭像的无透镜图像作为输入,经卷

积层进行图像特征提取。激活层采用 Leaky ReLU 函数,解决非线性问题。多个残差层为 GN 的关键,每个残差模块的输入经卷积、归一化、激活函数后,

再对该模块的输出求和。由于残差层中额外添加了每一层的输入,因此网络可以很好地解决反向传播中的梯度弥散问题。令每一个残差模块中的输入为 x ,卷积、归一化、激活函数分别为 f, g, h ,则经过一个残差模块的输出应为 $y = h\{g[f(x)]\}$,反向传播中, y 对 x 的导数为 $y'(x) = h'\{g[f(x)]\} \cdot g'[f(x)] \cdot f'(x)$ 。在层数增加的过程中,如果其中某一项的导数很小,则其梯度非常小,多次传播后梯度逐渐变小,传播到浅层后就几乎消失,导致梯度弥散。而残差模块中最后一步为单元输出和输入直接相加,即 $y = h\{g[f(x)]\} + x$,导数为 $y'(x) = h'\{g[f(x)]\} \cdot g'[f(x)] \cdot f'(x) + 1$,此时无论哪一项的导数很小,都可以保证连乘之后梯度不会消失。经过多个残差层后,再经过一个卷积层,最后输出能对零级像和孪生共轭像进行抑制的清晰图像。

DN 由多个卷积层、归一化层(BN)、激活层、两个全连接层(FC)及最后的激活层构成,结构如图 6(b)所示。输入为 GN 输出的图像和由商用显微镜获得的清晰样品图像。多层特征提取网络采取卷积层-归一化层-非线性激活层-卷积层-归一化层

的结构,作用是能深层提取特征。全连接层是对前层的特征进行加权,通过线性变换将隐层空间特征映射到样本标记空间,两个全连接层的大小分别取 1024 和 1。选取 Sigmoid 函数对后一个全连接层的输出进行判断。Sigmoid 函数的输出为 $0 \sim 1$,结果越接近 1 代表输入的图像大概率是由商用显微镜记录的清晰样品图像,结果接近 0 代表大概率是生成器所生成的图像。

GAN 在训练过程中最重要的部分就是损失函数。损失函数是神经网络优化参数的指标之一,指导如何调整网络结构参数及何时停止训练等。GAN 的损失函数分为 GN 的损失函数和 DN 的损失函数。GN 的损失函数为

$$\hat{\theta}_G = \operatorname{argmin}_{\theta_G} \frac{1}{N} \sum_{n=1}^N L^{GI}[G_{\theta_G}(I_n^{SM}), I_n^{CM}], \quad (2)$$

式中: I_n^{SM} 为含有孪生像的重建物图像,是 GN 的输入; I_n^{CM} 为商用显微镜图像; $G_{\theta_G}(I_n^{SM})$ 为 GN 生成的第 n 张图像; n 为样本图像序号; N 为训练样本数;感知损失函数 $L^{GI} = L^{VGG} + 10^{-3} L^{GEN}$, L^{VGG} 是内容损失, L^{GEN} 是對抗损失,分别定义为

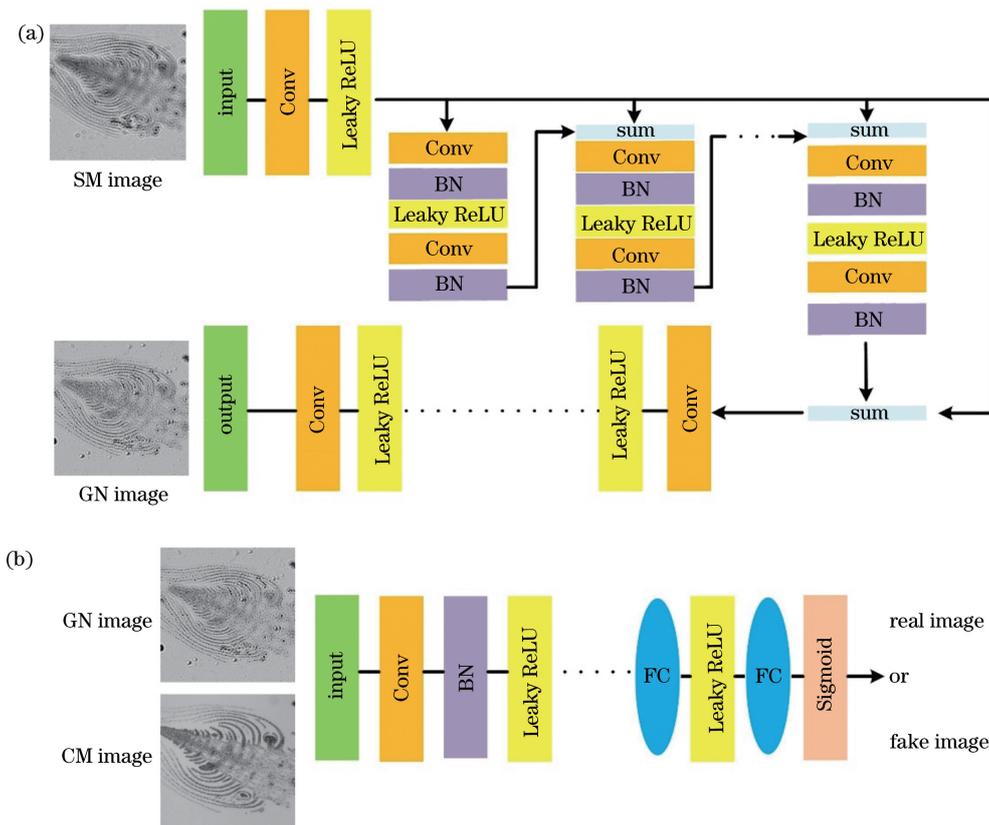


图 6 GAN 的主要构成。(a) GN;(b) DN
Fig. 6 Main components of GAN. (a) GN; (b) DN

$$L_{VGG(i,j)}^{GI} = \frac{1}{W_{i,j}H_{i,j}} \sum_{x=1}^{W_{i,j}} \sum_{y=1}^{H_{i,j}} \{\phi_{i,j}(I^{CM})_{x,y} - \phi_{i,j}[G_{\theta_G}(I^{SM})]_{x,y}\}^2, \quad (3)$$

$$L_{GEN}^{GI} = \sum_{n=1}^N \{-\log_{10} D_{\theta_D}[G_{\theta_G}(I^{SM})]\}, \quad (4)$$

式中： $W_{i,j}$ 为 VGG(Visual Geometry Group)网络中每个特征图的宽； $H_{i,j}$ 为 VGG 网络中每个特征图的高； $\phi_{i,j}(\cdot)$ 为 VGG 网络中第 i 个最大池化层之前通过第 j 个卷积并进行激活获得的特征映射； $D_{\theta_D}[G_{\theta_G}(I^{SM})]$ 为重构图像。在一般的图像重建方法中，内容损失都选择生成图像和目标图像的方均差损失(MSE-Loss)，训练网络时使用方均差损失可以获得较高的峰值信噪比(PSNR)，但是由此恢复的图像会丢失很多高频细节。因此，采用先将生成图像和目标图像分别输入到 VGG 网络中，然后对他们经过 VGG 网络后的特征图求欧氏距离，并将其作为内容损失的方式。

DN 的损失函数为

$$\hat{\theta}_D = E_{p(I^{CM})} [\log_{10} D_{\theta_D}(I^{CM})] + E_{q(I^{SM})} \{\log_{10} \{1 - D_{\theta_D}[G_{\theta_G}(I^{SM})]\}\}, \quad (5)$$

式中： $D_{\theta_D}(I^{CM})$ 为 DN 判别输入是显微镜下拍摄的真实清晰样品图的概率； $D_{\theta_D}[G_{\theta_G}(I^{SM})]$ 为 DN 判别由 GN 生成图像的概率； $E_{p(I^{CM})}(\cdot)$ 为判别显微镜图像的概率分布； $E_{q(I^{SM})}(\cdot)$ 为判别生成图像的概率分布。 $D_{\theta_D}(I^{CM})$ 越接近于 1，则 $D_{\theta_D}[G_{\theta_G}(I^{SM})]$ 越接近于 0，说明 DN 训练的效果越好，越能分辨图像的来源。GAN 最终在训练到判别器输出

接近 0.5 时停止训练，完成参数的优化。

GAN 训练结束后，将 GN 的参数固定并保存，用于输入图像的处理。对于一幅单张无透镜图像，采用自动聚焦算法计算其离焦距离，并反向传播重构出含零级像和孪生像的物平面图像。将重构的物平面图像作为 GN 的输入，经 GN 处理后，输出清晰目标图像，此时零级像和孪生像均得到充分抑制。

3 实验与讨论

首先搭建了如图 1 所示的无透镜成像实验装置，图像样本采用苏州神鹰光学有限公司的生物切片，对不同切片进行无透镜图像采集，再由 $4\times$ 物镜、数值孔径(NA)为 0.13 的商用显微物镜(NIB900L, 宁波永新光学股份有限公司)采集相应的明场显微图像，共计 200 对图像作为 GAN 的训练样本，分辨率为 256×256 。GAN 的硬件环境为处理器 i7, GPU 为 GTX1080TI, 内存 32G; 软件环境为 Win10 + Anaconda + Python3.7 + TensorFlow2.1。深度学习训练结束后的网络被用于无透镜图像的处理，以分辨率板为例的结果如图 7 所示。图 7(a) 为含有零级像和孪生像的样品图，是 GAN 的输入，图 7(c) 为经过 GAN 处理后的输出图像，对比看到，孪生像得到了抑制，清晰度明显提升。图 7(b)、(d) 分别为图 7(a)、(c) 的局部放大图，对比可以看到，图 7(b) 中的刻度线非常模糊，难以分辨，而图 7(d) 中的刻线部分得到了明显的改善。实验结果证明，GAN 可用于无透镜成像的零级像和孪生像的抑制，能够实现图像的相位恢复和清晰重建。

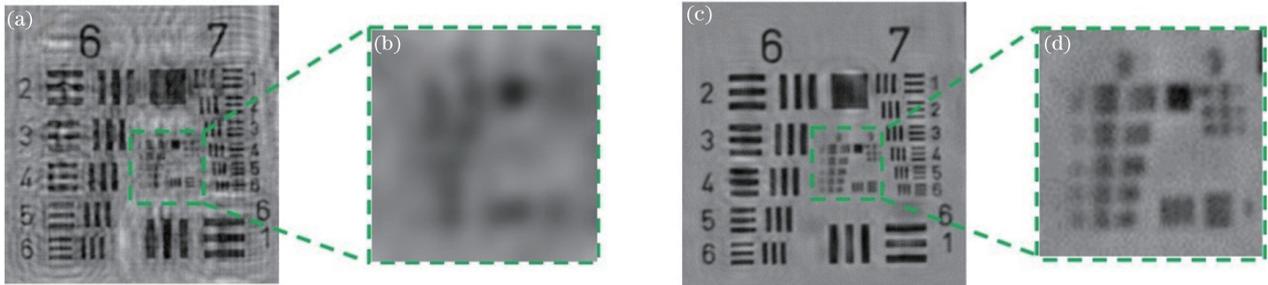


图 7 基于 GAN 的图像处理结果。(a) GAN 的输入；(b) 图 7(a) 的局部放大图；(c) GAN 处理后的输出；(d) 图 7(c) 的局部放大图

Fig. 7 Image processing results based on GAN. (a) GAN input; (b) partial enlarged image of Fig. 7(a); (c) GAN output; (d) partial enlarged image of Fig. 7(c)

对顶芽纵切样品在显微镜下的图像和 GAN 处理结果进行对比，如图 8 所示。图 8(a) 为无透镜原始图像，图 8(b) 为利用自聚焦算法计算离焦距离

后，反向衍射传播重建的物平面图像，图 8(c) 为 GAN 处理的结果，图 8(d) 为显微镜下拍摄的样品图像。对比可知，图 8(b) 中存在明显的孪生像干

扰,孪生像和样品的真实像混叠在一起,导致样品中的颗粒物分辨不清;而经过 GAN 处理的图像中的孪生像得到了充分的抑制,视场中的颗粒物清晰可

见,如图 8(c)所示。对比图 8(c)、(d),可以证明,所提基于 GAN 的无透镜成像方法最终所恢复的图像清晰度与商用显微镜下的样品图相当。

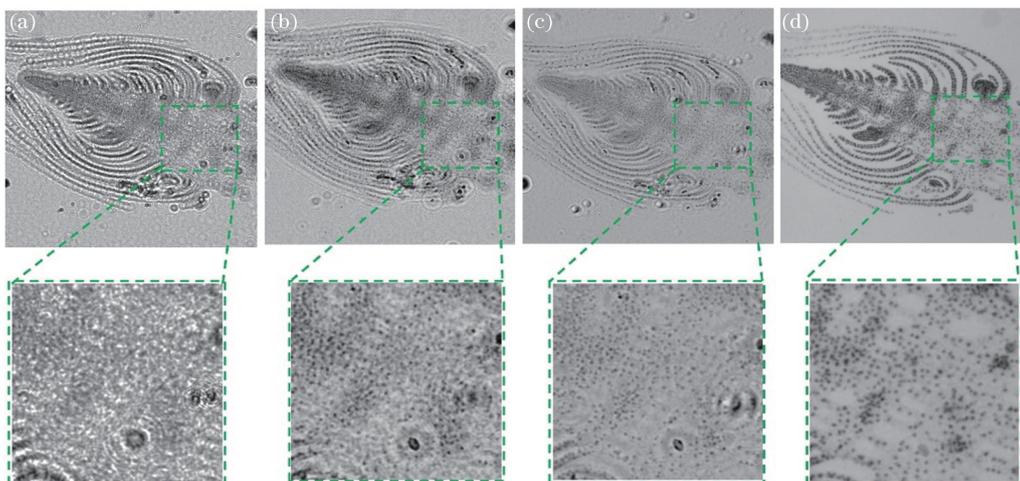


图 8 顶芽纵切样品。(a)无透镜图像;(b)反向传播重建物平面图像;(c) GAN 结果;(d)显微镜图像

Fig. 8 Apical bud slitting images. (a) Lens-free image; (b) reconstructed object plane image through back-propagation; (c) GAN result; (d) microscope image

为了验证所提 GAN 方法与 CNN 方法的差异,采用商用显微镜镜下的图像。先计算各目标图像的方均误差:

$$E_{MS} = \frac{1}{mn} \sum_{i'=0}^{m-1} \sum_{j'=0}^{n-1} [I(i',j') - K(i',j')]^2, \quad (6)$$

式中: $I(\cdot)$ 和 $K(\cdot)$ 分别为商用显微镜图像和目标图像。

再根据方均误差对各图像的 PSNR 进行计算,公式为

$$R_{PSN} = 10 \cdot \log_{10} \frac{M_{AX,I}^2}{E_{MS}}, \quad (7)$$

式中: $M_{AX,I}^2$ 为商用显微镜图像中最大像素值的平方。PSNR 计算结果如图 9 所示。CNN 结果的 PSNR 为 20.0642,GAN 结果的 PSNR 为 21.4096,与重建的物平面图像相比,基于 CNN 方法和基于 GAN 方法的孪生像均得到一定的抑制,且基于 GAN 方法的处理效果优于基于 CNN 方法。

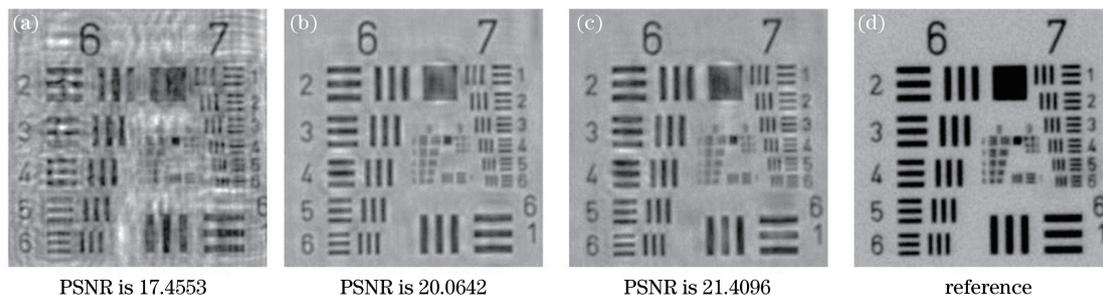


图 9 PSNR。(a)反向传播重建的物平面图像;(b) CNN 结果;(c) GAN 结果;(d)显微镜图像

Fig. 9 PSNR. (a) Reconstructed object plane image through back-propagation; (b) CNN result; (c) GAN result; (d) microscope image

为了进一步说明基于 GAN 方法与 CNN 方法在处理性能上的不同,绘制了各自生成图像的 PSNR 与迭代次数的关系曲线,如图 10 所示。可知,GAN 方法在迭代 100000 次左右时,PSNR 趋近饱和状态,为 21.5 左右;CNN 方法在迭代 800000 次左右时,PSNR 才趋近饱和,为 20.1 左右。GAN

方法在 PSNR 达到饱和状态时大约耗时 3 h,而 CNN 方法则需要 10 h,因此 GAN 方法的处理效率远远高于 CNN 方法。

4 结 论

针对基于菲涅耳衍射模型的方法在抑制无透镜

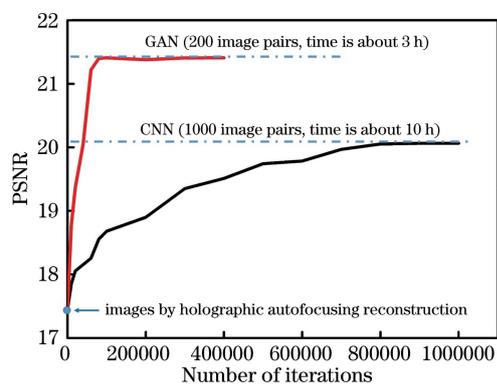


图 10 GAN 与 CNN 的性能对比

Fig. 10 Performance comparison between GAN and CNN 成像中的孪生像时需要多幅图像等问题,提出了基于 GAN 的无透镜成像方法。实验结果表明,所提方法在记录额外的光强度信息时无须改变系统的硬件条件,在图像重建阶段只需单张无透镜图像,大大缩减了成像处理时间。相比于 CNN 方法,在 PSNR 接近的情况下,所提方法需要的训练数据量更少,损失函数更容易收敛,具有更高的处理效率。所提方法的效果可达 $4\times$ 商用显微物镜下图像的效果。所提方法将进一步推动无透镜成像在移动医疗、环境检测等领域的应用。

参 考 文 献

- [1] Faulkner H M L, Rodenburg J M. Movable aperture lensless transmission microscopy: a novel phase retrieval algorithm [J]. *Physical Review Letters*, 2004, 93(2): 023903.
- [2] Dierolf M, Menzel A, Thibault P, et al. Ptychographic X-ray computed tomography at the nanoscale[J]. *Nature*, 2010, 467(7314): 436-439.
- [3] Zheng G A, Horstmeyer R, Yang C. Wide-field, high-resolution Fourier ptychographic microscopy [J]. *Nature Photonics*, 2013, 7(9): 739-745.
- [4] Tian L, Waller L. 3D intensity and phase imaging from light field measurements in an LED array microscope[J]. *Optica*, 2015, 2(2): 104-111.
- [5] Misell D L. An examination of an iterative method for the solution of the phase problem in optics and electron optics: I. test calculations [J]. *Journal of Physics D: Applied Physics*, 1973, 6(18): 2200-2216.
- [6] Teague M R. Deterministic phase retrieval: a Green's function solution[J]. *Journal of the Optical Society of America*, 1983, 73(11): 1434-1441.
- [7] Paganin D, Barty A, McMahon P J, et al. Quantitative phase-amplitude microscopy. III. the effects of noise[J]. *Journal of Microscopy*, 2004, 214(1): 51-61.
- [8] Greenbaum A, Ozcan A. Maskless imaging of dense samples using pixel super-resolution based multi-height lensfree on-chip microscopy [J]. *Optics Express*, 2012, 20(3): 3129.
- [9] Rivenson Y, Wu Y C, Wang H D, et al. Sparsity-based multi-height phase recovery in holographic microscopy[J]. *Scientific Reports*, 2016, 6: 37862.
- [10] Wang H D, Göröcs Z, Luo W, et al. Computational out-of-focus imaging increases the space-bandwidth product in lens-based coherent microscopy [J]. *Optica*, 2016, 3(12): 1422-1429.
- [11] Ferraro P, Miccio L, Grilli S, et al. Quantitative phase microscopy of microstructures with extended measurement range and correction of chromatic aberrations by multiwavelength digital holography [J]. *Optics Express*, 2007, 15(22): 14591-14600.
- [12] Luo W, Zhang Y B, Feizi A, et al. Pixel super-resolution using wavelength scanning [J]. *Light: Science & Applications*, 2016, 5(4): e16060.
- [13] Gonsalves R A. Phase retrieval and diversity in adaptive optics [J]. *Optical Engineering*, 1982, 21(5): 829-832.
- [14] Eisebitt S, Lüning J, Schlöter W F, et al. Lensless imaging of magnetic nanostructures by X-ray spectroholography[J]. *Nature*, 2004, 432(7019): 885-888.
- [15] Rosen J, Brooker G. Non-scanning motionless fluorescence three-dimensional holographic microscopy[J]. *Nature Photonics*, 2008, 2(3): 190-195.
- [16] Marchesini S, Boutet S, Sakdinawat A E, et al. Massively parallel X-ray holography [J]. *Nature Photonics*, 2008, 2(9): 560-563.
- [17] Popescu G, Ikeda T, Dasari R R, et al. Diffraction phase microscopy for quantifying cell structure and dynamics[J]. *Optics Letters*, 2006, 31(6): 775-777.
- [18] Coppola G, di Caprio G, Gioffré M, et al. Digital self-referencing quantitative phase microscopy by wavefront folding in holographic image reconstruction [J]. *Optics Letters*, 2010, 35(20): 3390-3392.
- [19] Wang Z, Millet L, Mir M, et al. Spatial light interference microscopy (SLIM)[J]. *Optics Express*, 2011, 19(2): 1016-1026.
- [20] Rivenson Y, Katz B, Kelner R, et al. Single channel in-line multimodal digital holography [J]. *Optics Letters*, 2013, 38(22): 4719-4722.
- [21] Shechtman Y, Eldar Y C, Cohen O, et al. Phase retrieval with application to optical imaging: a contemporary overview [J]. *IEEE Signal Processing Magazine*, 2015, 32(3): 87-109.

- [22] Kelner R, Rosen J. Methods of single-channel digital holography for three-dimensional imaging [J]. IEEE Transactions on Industrial Informatics, 2015: 220-230.
- [23] Rivenson Y, Zhang Y B, Günaydin H, et al. Phase recovery and holographic image reconstruction using deep learning in neural networks [J]. Light: Science & Applications, 2018, 7(2): 17141.
- [24] Ren Z B, Xu Z M, Lam E Y. Learning-based nonparametric autofocusing for digital holography [J]. Optica, 2018, 5(4): 337-344.
- [25] 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.
- [26] 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.
- [27] Nguyen T, Bui V, Lam V, et al. Automatic phase aberration compensation for digital holographic microscopy based on deep learning background detection [J]. Optics Express, 2017, 25(13): 15043-15057.
- [28] 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.