

基于超分辨率对抗网络的傅里叶叠层成像技术

王一^{1,2}, 魏晓雨^{1*}, 刘保辉¹, 苏皓^{1,3}¹华北理工大学电气工程学院, 河北 唐山 063210;²唐山市金属构件产线智能化技术创新中心, 河北 唐山 063210;³唐山市半导体集成电路重点实验室, 河北 唐山 063210

摘要 傅里叶叠层成像(FPM)受硬件和算法等因素的限制,成像的整体性能有待提高。为解决传统FPM技术成像速度慢、成像质量低的问题,融入深度学习的FPM图像重建方法得到广泛关注。基于此,提出一种基于超分辨率对抗生成网络的FPM模型,在原有网络基础上通过增加密集块连接实现全局特征融合并且使用一种加权损失函数提高图像重建质量。分辨率板图像重构结果表明,所提深度学习方法较传统方法重建效果显著、重建速度更快。

关键词 显微; 计算成像; 傅里叶叠层显微成像; 对抗生成网络; 超分辨率重建; 深度学习

中图分类号 TP391

文献标志码 A

DOI: 10.3788/LOP222900

Fourier Ptychography Microscopy Based on Super-Resolution Adversarial Network

Wang Yi^{1,2}, Wei Xiaoyu^{1*}, Liu Baohui¹, Su Hao^{1,3}¹College of Electrical Engineering, North China University of Science and Technology, Tangshan 063210, Hebei, China;²Tangshan Technology Innovation Center of Intellectualisation of Metal Component Production Line, Tangshan 063210, Hebei, China;³Tangshan Key Laboratory of Semiconductor Integrated Circuits, Tangshan 063210, Hebei, China

Abstract Fourier ptychography microscopy (FPM) is limited by hardware and algorithm, and its overall performance needs to be improved. To address the issues of slow imaging speed and low imaging quality of traditional FPM technology, the FPM image reconstruction approach integrated with depth learning has been widely explored. Herein, based on this, a super-resolution countermeasure generation network-based FPM model is proposed. Furthermore, global feature fusion is obtained by adding dense block connections using the original network, and a weighted loss function is used to enhance the quality of image reconstruction. The reconstruction results of the resolution plate image demonstrate that the proposed depth learning method has a better reconstruction effect and faster reconstruction speed than the conventional method.

Key words microscopy; computational imaging; Fourier ptychography microscopy; generative adversarial network; super-resolution reconstruction; deep learning

1 引言

传统显微镜若想获得更高的成像分辨率则必然损失其视场的大小,空间分辨率的提高与视场的扩大往往是一对难以调和的矛盾^[1]。早期为了实现高通量显微成像,通过增加精密的机械扫描装置来增加视场,但由于需要精密的传动装置,其价格也较为高昂^[2]。傅里叶叠层成像(FPM)技术是一种新开发的用于大视

场(FOV)、高分辨率和定量相位成像的显微技术^[1,3]。FPM是从ptychography^[4-5]无镜头成像技术发展而来的,它结合了孔径合成^[6-8]和相位恢复^[9-10]的概念。基于相位恢复原理的交替投影(AP)算法是由Zheng等^[1]最先提出的,通过在空间域和傅里叶域之间交替更新迭代信息,最终得到样品的原始复振幅,并从中获取高分辨的强度信息。FPM技术扩大了系统的等效数值孔径(NA),并通过简单的LED阵列实现了无需激光

收稿日期: 2022-10-26; 修回日期: 2022-12-07; 录用日期: 2022-12-23; 网络首发日期: 2023-01-05

基金项目: 河北省高等学校科学研究项目(ZD2022114)、唐山市科技计划项目(21130212C)

通信作者: *1347870676@qq.com

的相位成像。傅里叶空间中较大的通带导致较大的等效 NA 和较高的分辨率。因此,构建具有低 NA 显微镜系统的 FPM 可以同时实现大 FOV 和高分辨率^[1-2]。传统 FPM 重建方法依赖于迭代算法,虽然能够重构原始图像,但是重构结果质量较差,且随着迭代次数的增加重构速度相对较慢,仍有提升空间。

随着网络的发展以及计算能力的不断提高,深度学习技术结合计算成像将前端光学系统与后端计算机的图像处理相结合,打破了传统技术的限制^[11]。计算成像的过程反映的是测量信息到样本实际信息的映射函数,基于深度学习的计算成像方法就是神经网络通过大量数据拟合训练的权重参数来约束这一映射模型并用于解决实际成像问题的策略。FPM 技术现阶段大多数采用传统迭代算法来实现重建,这一过程的计算成本高、运行时间长,而深度学习的应用能够改善这一不足,避免重复相同的冗长测量,根据低分辨率图像得到高分辨率图像的相位恢复过程构建神经网络是一种有效的重建方案。Zhang 等^[2]设计了一种多尺度残差神经网络,将真实样本物体的复振幅分布作为网络输入,输出幅值和相位的重构结果。结果显示,与传统方法相比该模型在噪声等因素影响下效果更好,大大缩短重构时间。Chen 等^[12]使用基于 U-Net 结构设计的网络实现了图像重构,在低重叠和非重叠采样中性能更优,比传统算法更具鲁棒性。

本文设计了一种基于超分辨率生成对抗网络(SRGAN)的重建模型,在生成器网络中添加密集块连接,使得前层特征连接到后端实现特征复用,能够缓解梯度消失问题,同时引入通道注意力机制让网络自适应注意重要的特征。

2 FPM 成像原理

FPM 包含两个过程,主要包括前向成像过程和图像重构过程^[13-16]。成像系统如图 1 所示。FPM 系统将相位恢复概念与合成孔径相结合,使显微成像大大超




图 1 傅里叶叠层成像系统

Fig. 1 Fourier ptychography microscope system

过所用物镜的截止频率^[17-18]。通过依次点亮 LED 矩阵上不同位置的灯光,LED 发出的入射光相当于频域中不同位置上的光瞳函数,不同光瞳函数形成的频谱在频域上相互交叠形成叠层,由 CCD 采集到的一系列低分辨率的图像在频域进行迭代,并对相应范围内的频谱信息进行更新,每个光瞳函数形成的频谱带相互交叠扩展了频域带宽,从而能够恢复出超过物镜 NA 限制的高频信息,即使用低分辨率强度图像重建高分辨率图像^[19]。

2.1 FPM 前向成像过程

在 FPM 前向成像过程中,假设样本为薄样本,在 x - y 平面的二维分布为 $o(x, y)$,记 $\mathbf{r}=(x, y)$,则薄样本可表示为 $o(\mathbf{r})$ 。当 LED 矩阵与样本之间的距离足够远时,入射的照明波矢大致为倾斜平面波,则第 i 个 LED 的波矢可表示为

$$\mathbf{k}_i = \left(\frac{\sin \theta_{xi}}{\lambda}, \frac{\sin \theta_{yi}}{\lambda} \right), i = 1, 2, 3, \dots, N_{\text{LED}}, \quad (1)$$

式中: θ_{xi} 、 θ_{yi} 为第 i 个平面波传播矢量与 z 轴夹角; λ 为波长。

FPM 系统采用来自不同方向的光照射样本,相当于将样品光谱 $O(\mathbf{k})$ 以 \mathbf{k} 为中心进行移动:

$$O(\mathbf{k} - \mathbf{k}_n) = \mathcal{F}[o(\mathbf{r}) \exp(i\mathbf{k}_n \mathbf{r})], \quad (2)$$

式中: \mathcal{F} 表示傅里叶变换; $O(\mathbf{k})$ 为 $o(\mathbf{r})$ 在傅里叶域的表达式; $O(\mathbf{k} - \mathbf{k}_n)$ 为由具有波矢量的平面波照射的样本的频谱。

当样品出射光谱通过物镜时,该场由具有瞳孔函数 $C(\mathbf{k})$ 的物镜进行低通滤波, $C(\mathbf{k}) = \mathcal{F}[h(\mathbf{r})]$ 为点物光场通过成像系统在像平面产生的输出函数 $h(\mathbf{r})$ 的频域形式,称为相干传递函数(CTF)。FPM 的正向成像模型可以表示为

$$I_i(\mathbf{r}) = |g_i(\mathbf{r})|^2 = \left| \mathcal{F}^{-1}[C(\mathbf{k})O(\mathbf{k} - \mathbf{k}_i)] \right|^2, \quad (3)$$

$$\mathcal{F}^{-1} = \int_{-\infty}^{+\infty} \int f(x, y) \exp[-i2\pi(ux + vy)] dx dy, \quad (4)$$

式中: $I_i(\mathbf{r})$ 为 CCD 传感器上的强度; $g_i(\mathbf{r})$ 为到达传感器上的复数场; \mathcal{F}^{-1} 表示傅里叶逆变换。

2.2 FPM 重建过程

FPM 成像重构过程与鬼成像不同,鬼成像通过比较直接照射样本的测试光束与自由传播的参考光束两束信号相关性来完成重建,FPM 是以采集到的低分辨率图像为约束,寻找物体的高分辨率复振幅解的过程^[17]。通过交替投影法在空域和频域中交替迭代,不断更新子区域内的频谱信息以获得高分辨率的图像振幅分布。传统的 FPM 重建算法主要步骤如下:

1) 图像可由正入射照明时采集的低分辨率图像 $I_{\text{center}}(\mathbf{r})$ 插值放大而成,然后对其进行傅里叶变换得到初始的样品高分辨率频谱图像 O_0 ;

2)对于第 i 个 LED,根据该 LED 的照明角度提取出对应的频谱子区域,采用傅里叶逆变换得到估计的低分辨率复振幅图像;

3)用采集到的第 i 幅低分辨率图像 $I_i(\mathbf{r})$ 替换估计的低分辨率复振幅图像中振幅部分,保留相位:

$$A_{\text{update}} = I_i(\mathbf{r}) \exp(j\phi_i), \quad (5)$$

然后对其进行傅里叶变换得到更新后的低分辨率图像频谱,并提取其中圆形子区域部分用来更新步骤 2)中相应的高分辨率频谱子区域;

4)重复步骤 2)和步骤 3)的迭代更新过程,直到更新过程遍历所有采集的低分辨率图像;

5)重复步骤 2)~步骤 4),直到重建算法收敛。

3 FPM 重建神经网络结构

所提深度学习 FPM 重建网络是在 SRGAN^[20]的基础上改进的,使用密集块代替原有网络主干中的残差块并通过与 FPM 前向成像相结合实现超分辨率重建,网络由生成器(generator)和鉴别器(discriminator)两个

子网络组成,记为 FPSRGAN。生成器的目的是通过训练 FPM 前向成像模型获得的一组低分辨率图像 I_{LR} 来预测重建的高分辨率图像 I_{HR} ,随后由鉴别器网络来判别预测的重建结果与真值图像在像素级别上的差距。在学习过程中通过最小化损失函数的方式来优化两个网络的参数,使得结果逼近真值,建立起低强度图像输入和原始高分辨率图像之间的非线性端到端映射。

3.1 网络结构

随着网络深度的增加,梯度消失问题使网络不稳定,导致预测结果质量低,高频信息在反向传播过程中丢失。为了充分获取有价值的特征信息,在原有的残差结构基础上加入密集连接块(dense block)。这一模块的一大特色是通过特征在通道上的连接来实现特征复用来减少网络的深度,并且在密集块连接中引入通道注意力机制使网络更专注信息量较大的特征通道且模型能够利用特征通道之间的相互依赖性^[21-22]。生成器网络结构如图 2 所示。




图 2 FPSRGAN 生成器网络模型结构

Fig. 2 Structure of FPSRGAN's generator network model

生成器子网络通过卷积层、激活函数层、 n 个密集块(DB)和 n 个残差块(RB)进行全局特征融合,结合浅层特征和深层特征。由相机采集的低分辨率图像首先通过两个 3×3 卷积层为后续特征提取做准备。由于卷积过程本身是一个下采样过程,这一过程不可避免会造成特征的丢失,因此该模型在第一次卷积中也引入通道注意力模块来让模型关注图像中重要的信息。将前层每个 DB 模块和 RB 模块的特征通过 Concat 操作来合并特征信息并经过一个 1×1 的卷积和归一化操作来完成信息整合以及降维操作,最后通过上采样输出一张预测超清重建结果 I_G 。

DB 模块以前馈方式将每一层连接到其后续层,每一层的输入是前面所有层的特征图,当前层自己的特征

映射输出是所有后续层的输入。在 DB 内的每一层中,执行一系列操作,包括批量归一化(BN)、使用 ReLU 或 Leaky ReLU 函数进行激活、并使用内核大小为 $k \times k$ 的滤波器进行卷积等。每个层都会与前面所有层在通道维度上连接在一起并作为下一层的输入。DB 有几个优点:缓解训练中的梯度消失问题;减少参数总量;增强特征传播和重用。典型的 L 层 DB 定义如下:

$$x_L = H_L([x_0, x_1, \dots, x_{L-1}]), \quad (6)$$

式中: H_L 是非线性转化函数(non-linear transformation); $[\cdot]$ 则表示 L 层的所有特征图连接操作。

在每个 DB 之后引入一个通道注意力(SE)模块,如图 3 所示,SE 模块由自适应平均池化层、全连接层(FC)、ReLU 以及 Sigmoid 激活层组成。




图 3 SE 模块

Fig. 3 SE model

鉴别器网络(discriminator)用来判别生成器网络输出图片与真值的相似程度。通过训练生成器网络来欺骗鉴别器网络。对抗网络通常很难训练,当生成器崩溃到始终提供相同输出的参数设置时,它可能会失

败。避免这种失败的一个方法是允许鉴别器执行小批量鉴别^[20]。在这种情况下,鉴别器通过评估预测图像的多个子区域而不是整体来区分重建的相位图像是真还是假。鉴别器网络结构如图 4 所示。




图 4 FPSRGAN 鉴别器网络结构模型

Fig. 4 Structure of FPSRGAN's discriminator network model

鉴别器网络使用 Leaky ReLU 激活函数来防止一些负性输出坏死,网络末端使用 Sigmoid 函数作为二分类器来为网络输入的两张图片打分,整体的判别网络就是一个没有池化层的 VGG 网络,尝试最小化分类错误,以更新鉴别器偏差和权重来优化结果。

3.2 损失函数

超分辨率神经网络中通常使用 L1 损失、感知损失与对抗损失加权来测量生成的超分辨率图像和真实高分辨率图像之间的差异,并指导模型优化,由于模型训练过程中需要对多个任务函数进行优化以达到目的,不同的损失函数会对网络的训练速度和深度估计性能产生显著影响。在生成对抗网络中,对抗损失和传统损失的结合可以使网络朝着更有利的结果进行^[23],因此定义了一种基于均方误差损失函数、感知损失函数(perceptual loss)、对抗损失函数(adversarial loss)、傅里叶均方误差损失函数(FMSE)以及总变差正则化损失函数(TV loss)的加权的全局损失函数来保证模型能够更好地学习包含高频信息的特征,其表达式如下:

$$l = \lambda_1 l_{\text{MSE}} + \lambda_2 l_{\text{FMSE}} + \lambda_3 l_G + \lambda_4 l_{\text{VGG}}^{\text{SR}} + \lambda_5 l_{\text{TV}}, \quad (7)$$

式中: l_{MSE} 和 l_{FMSE} 为均方误差损失以及傅里叶均方误差损失; l_G 为对抗损失; $l_{\text{VGG}}^{\text{SR}}$ 为感知损失; l_{TV} 为总变差正则化损失。

傅里叶域均方误差在恢复过程中起到关键作用。训练过程中通过将生成器生成图像与真值图像转换到傅里叶域后进行均方误差的计算来更好促进像素之间的学习,其表达式为

$$l_{\text{FMSE}} = \text{MSE}[\mathcal{F}(I_G), \mathcal{F}(I_{\text{HR}})]。 \quad (8)$$

感知损失函数起着重要作用。在训练的过程中,感知损失用来衡量图像之间的相似性,通过将生成器输出的图像 $G(I_{\text{LR}})$ 和真值图像 I_{HR} 输入 VGG16 网络得到的特征来计算 MSE 损失,能够更好地恢复图像细节。

$$l_{\text{VGG}}^{\text{SR}} = \text{MSE}\{\text{VGG}_{16}[G(I_{\text{LR}})], \text{VGG}_{16}(I_{\text{HR}})\}。 \quad (9)$$

TV 损失常被用在损失函数里的正则项,图像中相邻像素值的差异可以通过降低 TV 损失在一定程度上解决,从而保持图像的光滑性。该损失函数可以起到平滑图像、去除鬼影、消除噪声的作用,表达式如下:

$$l_{\text{TV}} = \frac{1}{r^2 WH} \sum_{x=1}^{rW} \sum_{y=1}^{rH} \|\nabla G_{\theta G}(I_{\text{LR}})_{x,y}\|。 \quad (10)$$

4 实验数据参数与结果分析

4.1 数据集建立

基于深度学习的计算成像方法所需的数据通常可通过 3 种方式获取:利用传统方法高精度重建图像、预置真实物体、通过仿真生成数据^[11]。本实验训练数据由 DIV2K 数据集^[24]仿真得到,其中,300 张用于制作训练集,100 张制作验证集,提高了实验数据的权威性。由于数据集中的图像尺寸大小不一致,首先将图像裁剪成 512×512 大小并转化为灰度图像作为对抗网络输入的真值图像,再通过模拟 FPM 前向成像模型得到 67500 张 128×128 的图像用于训练。模拟前向成像过程中,相关光学参数设置如下:LED 矩阵大小为 15×15 ,样本距 LED 的距离为 70 mm,LED 小灯泡之间距离为 4 mm,小灯泡波长 $\lambda = 630 \text{ nm}$,数值孔径设置为 0.1,放大倍数为 4。

4.2 实验参数

本实验采用 PyTorch 深度学习框架,编程语言为 Python 3.9。CPU 型号为 AMD Ryzen 7 5800H with Radeon Graphics, GPU 型号为 NVIDIA GeForce RTX 3060 Laptop GPU,操作系统为 Windows 11。将上述 128×128 大小的数据集作为生成器网络输入进行网络训练,经过上采样之后得到一组 512×512 的预测值,并与真值图像输入鉴别器网络中指导生成器拟合。使用随机裁剪以及中心裁剪进行数据增强,批次大小设置为 16。通过实验获取损失函数权重: $\lambda_1 = 5$, $\lambda_2 = 5$, $\lambda_3 = 1$, $\lambda_4 = 6 \times 10^{-3}$, $\lambda_5 = 2 \times 10^{-8}$ 。生成器中密集块和残差块连接层数 $n = 4$ 。使用 Adam 优化

器更新损失函数,生成器学习率设置为 10^{-3} ,鉴别器学习率设置为 10^{-4} ,将制作好的数据集输入神经网络进行学习,共训练 300 个 epoch。

4.3 结果分析

为了验证所提损失函数的有效性,在使用相同的实验数据和模型参数下对损失函数进行消融实验:对抗损失和 MSE 损失记为 A;傅里叶均方误差损失和 MSE 损失记为 B;对抗损失、感知损失、MSE 损失以及傅里叶均方误差损失记为 C;加权损失和记为 D。在实验过程中,针对不同任务所使用的损失函数,首先使用默认参数进行实验,在大量实验过程中进行微调来确定各个损失函数的权重。其中,对抗损失和 MSE 损失作为消融实验的基准,各个损失组合的损失曲线以及重建图像的峰值信噪比(PSNR)曲线如图 5 和图 6 所示。从图 5 可以看出,仅使用 MSE 损失和对抗损失虽然在 20 个 epoch 后趋于收敛,但重建后的图像峰值信噪比始终处于 11 dB~12 dB 之间,效果最差。随后在 MSE 损失函数基础上引入 FMSE,从图 5 可以看到,损失函数曲线从 40 轮学习后开始逐渐趋于平稳,但是在 120 轮左右有明显的跳变,并且在 260 个 epoch 后峰值信噪比值浮动过大,图像质量有所下降,因此重建质量也不理想。

在上述基础上将感知损失和对抗损失加入后,前




图 5 不同损失函数组合的损失曲线

Fig. 5 Loss curves for different combinations of loss functions




图 6 不同损失函数组合的峰值信噪比曲线

Fig. 6 PSNR curves for different loss function combinations

260 个 epoch 损失曲线较为平稳,重建峰值信噪比有所缓和,但是在此之后损失函数开始波动。从图 6 也可以看出,重建峰值信噪比开始下降,反映在图像上即与真值图像间像素差距越来越大,有严重的伪影,反而使图像细节丢失。当使用所提加权损失和进行训练时,可以看出,当模型迭代 40 次后,损失值降到较低的数值,并保持下降,当 epoch 到达 300 时,损失值保持相对稳定水平。改进后模型整体收敛性比较好,峰值信噪比整体也趋于平稳,训练效果较理想。

为充分验证所提网络性能,以相同的硬件环境和数据集对不同方法进行实验对比,使用原始的 SRGAN 作为参照,通过添减密集块和残差块数量进行实验。表 1 中对比了不同方法的重建结果。原始 SRGAN 以残差结构为基本框架,将前层输入和后层输出直接相连,保证了加深网络后网络性能不会差,但表中实验结果显示最终重建结果不佳,不适用于 FPM。相比较而言,所提 FPSRGAN 模型针对傅里叶叠层成像问题有较好的重构效果,在增加密集块连接后,以前向传播方式将每一层与其余层密集连接,可以确保各层之间的信息流动达到最大,将所有层的特征图在维度上直接相加连接在一起,平均 PSNR 达到 26 dB 左右,结构相似性(SSIM)也能反映出重建图像与真值非常接近。对比所提模型与 Chen 等^[12]提出的 FPNET 模型可看出,所提模型重建速度上略慢于 FPNET,在验证集上的 PSNR 提高了 2.94 dB,SSIM 提高了 0.0413。随后比较不同层数密集块残差块对重建的影响:不难看出若减少 1 层,重建时间与 4 层 DB-RB 相同,而平均 PSNR 下降了 0.66,SSIM 下降了 0.0067;若增加到 5 层,FPSRGAN 的性能会有一些下降,平均 PSNR 下降到 25.03,SSIM 也下降到 0.9518,内存占用率非常大,随着计算量的增加重建结果质量反而有所下降。将 4 层 DB-RB 去掉前端 SE 层的模型与所提模型比较可发现,PSNR 以及 SSIM 评价指标均有所下降,说明前层 SE 模块能够弥补网络中的特征

表 1 验证集上各个模型重建的时间、平均 PSNR、SSIM 以及内存占用

Table 1 Reconstruction time, average PSNR, SSIM, and memory of each model on the validation set

| Method | Time /s | PSNR /dB | SSIM | Memory /MB |
|----------------------------|---------|----------|--------|------------|
| SRGAN | 6 | 12.76 | 0.5954 | 4763 |
| FPNET | 8 | 23.18 | 0.9247 | 5127 |
| FPSRGAN-DR ₄ | 14 | 24.87 | 0.9598 | 5627 |
| FPSRGAN-SE-DR ₃ | 14 | 25.46 | 0.9593 | 5509 |
| FPSRGAN-SE-DR ₄ | 14 | 26.12 | 0.9660 | 5641 |
| FPSRGAN-SE-DR ₅ | 15 | 25.03 | 0.9518 | 6190 |
| AP | 22 | 15.01 | 0.9537 | |
| GS | 52 | 11.71 | 0.7826 | |

丢失,提升网络的性能。综合来看,所提网络较传统的 AP、GS 模型不论在重建时间上还是质量上都有提升。

最后使用仿真的 USAF-1951 分辨率板与传统算法进行对比实验。图 7 为不同方法重建仿真的 USAF-1951 结果细节图。将原始图像图 7(a)进行中心裁剪得到原始真值图像图 7(b),随后同样对其进行前向成像仿真获得一组大小为 128×128 的低分辨率图像并进行重建,放大倍数为 4,重建后的图像大小尺寸为 512×512 。传统的 AP 算法和 GS 算法获得的重建结果相较于真值图像差距较大,GS 算法在细节上有严重的丢失现象,同样虽然 AP 算法在清晰

度上有着优势,但和 GS 算法同样与真值图像有着明显的明暗差距。图 7(g1)为所提方法重建的图像,同一数据集上重建结果较 GS 算法 PSNR 提高了 11.94 dB,SSIM 提高了 0.1933,较 AP 算法 PSNR 提高了 11.93 dB,SSIM 提高了 0.0248,与真实 USAF-1951 图像在视觉上最为接近,图像的细节丰富程度也最高,同样较高的 SSIM 也证明重建的图像与原图最为接近,且大大减少了伪影,恢复效果最好。4 层 DB-RB 的 FPSRGAN 模型恢复速度较 AP 算法缩短了 8 s,较 GS 算法缩短了 40 s,极大缩短了重建时间。

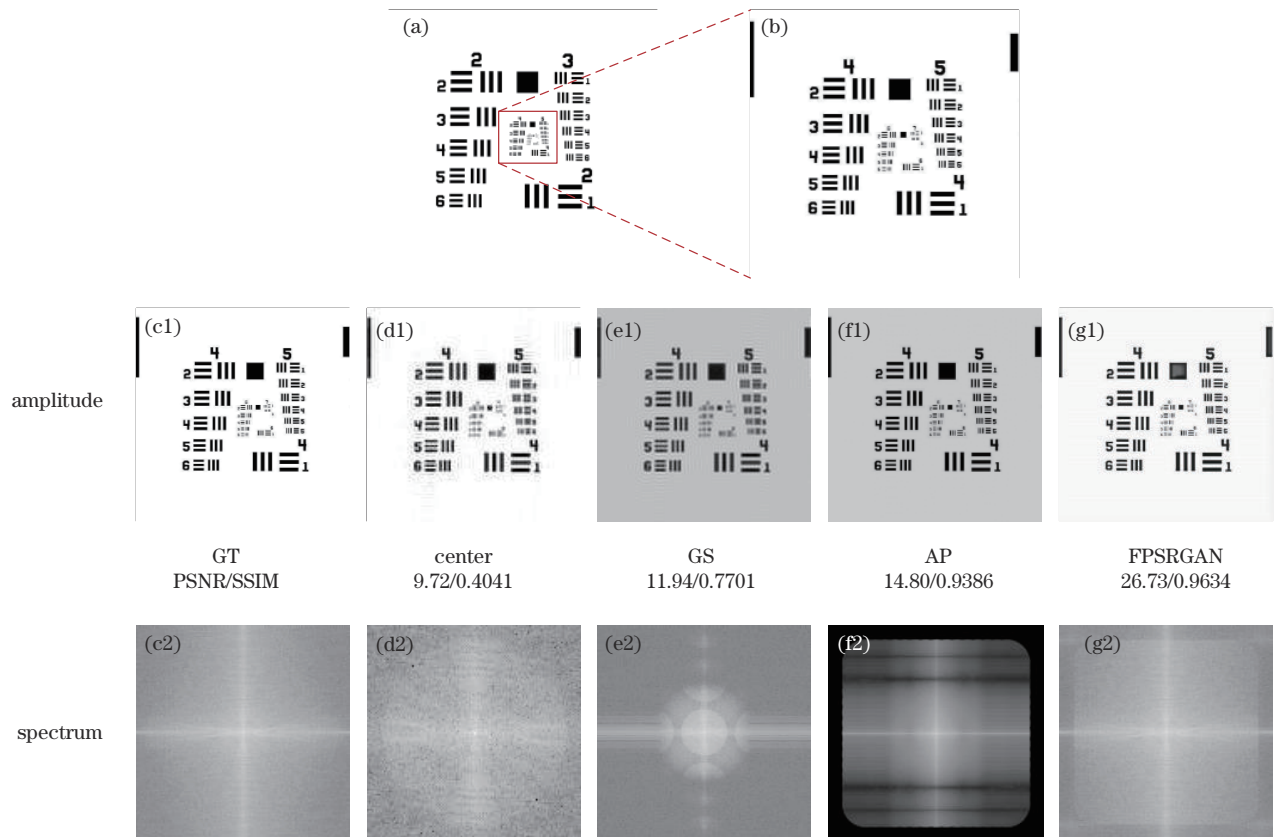


图 7 不同 FPM 重构算法仿真实验结果振幅与频谱图。(a)原始 USAF1951 图像;(b)USAF1951 中心裁剪图像;(c1)(c2)真值图像;(d1)(d2)前向成像模型中央低分辨率图像;(e1)(e2)GS 算法重建图像;(f1)(f2)AP 算法重建图像;(g1)(g2)FPSRGAN 算法重建图像

Fig. 7 Amplitude and spectrum of simulation experiment results of different FPM reconstruction algorithms. (a) Original USAF1951 image; (b) center crop image of USAF1951; (c1) (c2) ground truth images; (d1) (d2) low-resolution images of the center of the forward imaging model; (e1) (e2) reconstruction images of the GS algorithm; (f1) (f2) reconstruction images of the AP algorithm; (g1) (g2) reconstruction images of the FPSRGAN algorithm

5 结 论

以 SRGAN 模型为基础,提出一种傅里叶叠层成像重建网络 FPSRGAN。在原有生成器基础上增加密集块与残差块并拼接各层特征图,对 FPM 前向成像获得的低分辨率图像进行重建,使用多个模块组合进行图像的特征复用与特征融合并使用鉴别器网络对生成器

网络进行约束以逼近真值图像。通道注意力机制不仅可以防止网络深度过深带来的过拟合问题,还能更大程度上提高有效特征信息的利用率。所提加权损失函数在像素级上得到了更好的重建结果,在 USAF1951 数据集上重建结果的 PSNR 值较传统 AP 算法有很大提高且结构相似性趋近 1,有更佳视觉效果,同时大大缩短了重建时间,验证了所提方法的有效性。

参 考 文 献

- [1] Zheng G A, Horstmeyer R, Yang C. Wide-field, high-resolution Fourier ptychographic microscopy[J]. *Nature Photonics*, 2013, 7(9): 739-745.
- [2] Zhang J Z, Xu T F, Shen Z Y, et al. Fourier ptychographic microscopy reconstruction with multiscale deep residual network[J]. *Optics Express*, 2019, 27(6): 8612-8625.
- [3] Ou X Z, Horstmeyer R, Yang C, et al. Quantitative phase imaging via Fourier ptychographic microscopy[J]. *Optics Letters*, 2013, 38(22): 4845-4848.
- [4] Rodenburg J M. Ptychography and related diffractive imaging methods[J]. *Advances in Imaging and Electron Physics*, 2008, 150: 87-184.
- [5] 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.
- [6] Hillman T R, Gutzler T, Alexandrov S A, et al. High-resolution, wide-field object reconstruction with synthetic aperture Fourier holographic optical microscopy[J]. *Optics Express*, 2009, 17(10): 7873-7892.
- [7] Di J L, Zhao J L, Jiang H Z, et al. High resolution digital holographic microscopy with a wide field of view based on a synthetic aperture technique and use of linear CCD scanning[J]. *Applied Optics*, 2008, 47(30): 5654-5659.
- [8] Meinel A B. Aperture synthesis using independent telescopes[J]. *Applied Optics*, 1970, 9(11): 2501-2504.
- [9] Fienup J R. Phase retrieval algorithms: a comparison[J]. *Applied Optics*, 1982, 21(15): 2758-2769.
- [10] Elser V. Phase retrieval by iterated projections[J]. *Journal of the Optical Society of America A*, 2003, 20(1): 40-55.
- [11] 王飞, 王昊, 卞耀明, 等. 深度学习在计算成像中的应用[J]. *光学学报*, 2020, 40(1): 0111002.
Wang F, Wang H, Bian Y M, et al. Applications of deep learning in computational imaging[J]. *Acta Optica Sinica*, 2020, 40(1): 0111002.
- [12] Chen Y C, Luo Z, Wu X, et al. U-Net CNN based fourier ptychography[EB/OL]. (2020-03-16) [2022-09-10]. <https://arxiv.org/abs/2003.07460>.
- [13] Bian L H, Suo J L, Dai Q H, et al. Fourier ptychography for high space-bandwidth product microscopy[J]. *Advanced Optical Technologies*, 2017, 6(6): 449-457.
- [14] 张瑾华, 张继洲, 李佳男, 等. 基于叠层衍射成像的傅里叶叠层显微像差校正方法[J]. *光学学报*, 2021, 41(10): 1011001.
Zhang J H, Zhang J Z, Li J N, et al. Aberration correction of Fourier ptychographic microscopy based on ptychographical iterative engine[J]. *Acta Optica Sinica*, 2021, 41(10): 1011001.
- [15] 张韶辉, 周国城, 崔柏岐, 等. 傅里叶叠层显微成像模型、算法及系统研究综述[J]. *激光与光电子学进展*, 2021, 58(14): 1400001.
Zhang S H, Zhou G C, Cui B Q, et al. Review of Fourier ptychographic microscopy: models, algorithms, and systems[J]. *Laser & Optoelectronics Progress*, 2021, 58(14): 1400001.
- [16] Zheng G. Fourier ptychographic imaging a MATLAB tutorial[M]. Bristol: IOP Publishing, 2016.
- [17] 孙佳嵩, 张玉珍, 陈钱, 等. 傅里叶叠层显微成像技术: 理论、发展和应用[J]. *光学学报*, 2016, 36(10): 1011005.
Sun J S, Zhang Y Z, Chen Q, et al. Fourier ptychographic microscopy: theory, advances, and applications[J]. *Acta Optica Sinica*, 2016, 36(10): 1011005.
- [18] Zheng G A, Shen C, Jiang S W, et al. Concept, implementations and applications of Fourier ptychography [J]. *Nature Reviews Physics*, 2021, 3(3): 207-223.
- [19] Wu J J, Yu B, Zhang S W, et al. Super-resolution fluorescence blinking imaging using modified Fourier ptychography[J]. *Optics Express*, 2018, 26(3): 2740-2748.
- [20] Ledig C, Theis L, Huszár F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 105-114.
- [21] Zhu Y, Newsam S. DenseNet for dense flow[C]//2017 IEEE International Conference on Image Processing, September 17-20, 2017, Beijing, China. New York: IEEE Press, 2017: 790-794.
- [22] Iandola F, Moskewicz M, Karayev S, et al. DenseNet: implementing efficient ConvNet descriptor pyramids[EB/OL]. (2014-04-07) [2022-01-05]. <https://arxiv.org/abs/1404.1869>.
- [23] Pathak D, Krähenbühl P, Donahue J, et al. Context encoders: feature learning by inpainting[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 2536-2544.
- [24] Bevilacqua M, Roumy A, Guillemot C, et al. Low-complexity single-image super-resolution based on nonnegative neighbor embedding[EB/OL]. [2022-09-18]. https://web.archive.org/web/20190307134645id_/http://pdfs.semanticscholar.org/e14b/8db1f680134ba52e54dea509ab9c0efa3bd5.pdf.