

基于深度学习的傅里叶叠层显微成像

陈奕灿, 吴霞*, 罗志, 杨恢东, 黄波**

暨南大学信息科学技术学院电子工程系, 广东 广州 510632

摘要 傅里叶叠层显微成像(FPM)是一种能够重建宽视场和高分辨率图像的新型成像技术。传统的 FPM 重建算法计算成本高,重建高质量的图像需要较大的图像采集量,这些缺点使得传统重建算法的成像性能和效率较低。因此,提出一种基于深度学习的傅里叶叠层显微成像的神经网络模型,对图像进行低分辨率到高分辨率的端到端映射,有效提高成像性能和效率。首先,借助菱形采样方法进行图像采集,加速低分辨率图片采集过程。其次,结合残差结构、密集连接以及通道注意力机制等模块,拓展网络深度、挖掘有用特征,增强网络模型的表达能力和泛化能力。然后,使用子像素卷积进行高效地上采样,恢复高清图像。最后,采用主观和客观的评价方法对重建结果进行评估。结果显示,本文提出的网络模型对比传统重建算法重构效果更优,且降低了计算复杂度,平均重建时间更短。同时,在保证图像重建效果不变的情况下,低分辨率图像的采集数量比传统算法减少了约一半。

关键词 成像系统; 计算成像; 深度学习; 傅里叶叠层显微; 密集连接; 通道注意力

中图分类号 O436

文献标志码 A

doi: 10.3788/LOP57.221106

Fourier Ptychographic Microscopy Reconstruction Based on Deep Learning

Chen Yican, Wu Xia*, Luo Zhi, Yang Huidong, Huang Bo**

College of Information Science and Technology, Jinan University, Guangzhou, Guangdong 510632, China

Abstract Fourier ptychographic microscopy (FPM) is a newly developed imaging technology, which is capable of reconstructing images with a wide field of view and high resolution. However, the reconstruction based on traditional reconstruction algorithms has high calculation cost, large amount of image acquisition, and low efficiency. Therefore, we propose a deep learning-based neural network model of FPM that performs end-to-end mapping from low-resolution to high-resolution to effectively improve imaging performance and efficiency. First, the diamond sampling method is used to speed up the process of image acquisition. Second, the combination of residual structure, dense connection, and channel attention mechanism is used to expand the network depth, mine useful features, and enhance the expression and generalization ability of the network model. Then, sub-pixel convolution is used for efficient upsampling and restoring high-resolution images. Finally, subjective and objective evaluation methods are used to evaluate the reconstruction results. The results show that, compared with the traditional reconstruction algorithm, the proposed network model has better reconstruction effect, lower computational complexity, and shorter average reconstruction time. At the same time, the number of low-resolution images is reduced by about half compared with the traditional algorithm.

Key words imaging systems; computational imaging; deep learning; Fourier ptychographic microscopy; dense connection; channel attention

OCIS codes 110.1758; 200.4260; 110.0180

1 引言

传统光学成像系统受到空间带宽积(SBP)的限

制。为了实现图像的高分辨率,必须使用高数值孔径(NA)物镜成像,但空间分辨率的提高和视场的扩大经常是一对难以调和的矛盾^[1-2]。傅里叶叠层

收稿日期: 2020-03-26; 修回日期: 2020-04-24; 录用日期: 2020-04-27

基金项目: 国家自然科学基金(61307080)

* E-mail: wuxia_liao@qq.com; ** E-mail: abohuang@jnu.edu.cn

显微成像(FPM)是一种强大的成像技术,可以通过计算来规避这种物理限制,实现高分辨率和大视场的成像。傅里叶叠层显微成像系统使用LED阵列作为光源,通过依次点亮各个位置处的LED,从不同照射角度对目标样本进行照明,采集一组含有不同频域信息的低分辨率强度图像,然后使用相位恢复算法,在频域中对采集图像的频谱值进行拼接,从而重建出一幅高分辨率、大视场的图像,应用前景广泛^[3-6]。

然而,FPM是牺牲了时间来获取宽视场高分辨率图像,采集图像时间过长,而且重建时间较长,计算成本比较高。为了提高FPM的效率,降低计算复杂度,学者们提出了很多方法,大体可以归纳为两种类型:一类是对FPM的系统设置如照明结构或者方法进行改进。例如,Tian等^[7]通过修改LED点亮照明模式,每次 N 个LED灯被随机点亮,且每个LED仅点亮一次,则采集图像的数目比顺序点亮的方法减少了 N 倍,但其重构算法的计算复杂度仍比较高。林子强等^[8]使用弧形阵列LED光源装置代替平面阵列LED光源,以此提高边缘LED灯大角度照明的信噪比,由于引入了机械位移,所以这种设计的照明角度的精度受到影响。李通等^[9]提出了一种基于LED角度照明优化模式的高效成像方法,设计出一种基于菱形采样方法来加速FPM的实现过程。然而,上述方法改变了照明结构或编码照明方式,在硬件实现上增加了复杂度,算法实现的复杂度也没有得到根本的改变。另一类方法是通过改进重构算法,提高重构效率。一般可以将重构方法大致分为传统的相位恢复算法和深度学习重构算法。例如,Bian等^[10]提出wirtinger-flow优化算法,该算法在较少的曝光时间下仍可重构出高清图像并且具有一定的抗噪性能。Zuo等^[11]提出自适应步长策略,加快传统梯度下降法的收敛速度,提高重构效率。Kappeler等^[12]提出PtychNet,将深度学习的方法用于FPM,该网络模型使用三层卷积神经网络重构高分辨率图像,但是网络深度有限,重构效果较差。2018年,Jiang等^[13]通过卷积神经网络对FPM进行建模,通过反向传播解决FPM的重构问题,但该方法是通过神经网络进行迭代计算完成的,针对不同的待重构图像需要重新训练网络,泛化能力较差。

近年来,随着数据量的急剧增长和计算能力的不断提高,人工智能特别是深度学习技术迅速发展,并被广泛应用于计算机视觉的各个领域,如计算成

像^[12-14]、目标检测^[15]、图像超分辨等^[16-19]。深度学习模型可以通过深度神经网络(DNN)在输入和输出之间找到正确的数学映射^[20-21]。在给定大量的训练数据的情况下,DNN可以被训练用于学习低清(LR)图像到高清(HR)图像的端到端映射,处理性能较高,运行速度快。因此,本文使用深度学习的方法进行傅里叶叠层成像图像重构,使用残差结构^[22]和密集连接^[23-24],引入通道注意力机制^[25],构造残差密集连接与通道注意力模块(RDCA),并堆叠RDCA模块组成傅里叶叠层显微成像网络模型(FPRDCA)。FPRDCA对原始低分辨率图像中各层次的特征进行充分提取,保留、放大信息量大的特征,使得信息传输更加完整和高效,并减小网络深度带来的副作用。FPRDCA中的残差结构和密集连接能够将浅层特征和深层特征结合在一起,使这些特征信息易于训练,同时通道注意力机制能有效减少特征冗余,有利于得到精确的端到端网络模型。本研究主要贡献有以下方面:

- 1) 使用RDCA模块,充分利用低分辨率图像中的分层特征,保留并放大有价值的特征信息,提高特征的利用率,减小网络深度带来的副作用。
- 2) 借助深层网络的拟合能力和生成能力,FPRDCA重建图像达到了更好的效果。
- 3) 使用子像素卷积模块进行上采样,进一步加快图像重建速度,与传统重建算法比较,FPRDCA的重建速度更快。
- 4) 借助菱形采样方法实施原始图像的采集,经过FPRDCA的重建得到与全采样几乎无异的重建效果,可以减少约一半的采样图像数量,提高了FPM的重建效率。

2 FPM基本原理

FPM作为一种经典的计算成像方法,主要包括前向成像过程和恢复过程^[2-5]。在前向成像过程中,样品被来自LED矩阵的倾斜平面波照射,然后相机通过物镜捕获射出的波,通过依次照亮矩阵上的不同LED,可以获得一系列低分辨率强度图像。在恢复过程中,用低分辨率强度图像重建高分辨率图像。图1为用于捕获低分辨率图像的典型FPM系统装置图。

2.1 前向成像过程

在前向成像过程中,薄样品可以用其传递函数 $o(r)$ 表示,其中 $r=(x,y)$ 表示二维空间坐标。假设LED距离样品台足够远,则照明波近似为倾




图 1 典型 FPM 的系统装置图

Fig. 1 Diagram of a typical FPM system

斜平面波。对于第 n 盏 LED 灯,其波向量可以表示为

$$\mathbf{k}_n = \left(\frac{\sin \theta_{xn}}{\lambda}, \frac{\sin \theta_{yn}}{\lambda} \right), n = 1, 2, 3, \dots, N_{LED}, \quad (1)$$

式中: $(\theta_{xn}, \theta_{yn})$ 为第 n 盏 LED 灯的入射角; λ 为入射光波长; 进入样本平面的复振幅分布可表示为 $\exp(i\mathbf{k}_n r)$ 。当第 n 个 LED 照亮样本时,穿过样本的出射场为 $o(r) \exp(i\mathbf{k}_n r)$ 。通过应用傅里叶变

换,出射场表示为 $\mathcal{F}\{o(r) \exp(i\mathbf{k}_n r)\} = O(\mathbf{k} - \mathbf{k}_n)$ 。使用带有波矢量的倾斜平面波照亮样品等效于样品光谱 $O(\mathbf{k})$ 移动 \mathbf{k}_n 。当通过物镜时,该场被物镜光瞳函数 $C(\mathbf{k})$ 低通滤波。此时, FPM 的前向成像过程可以表示为

$$I_{nc}(r) = |g_{nc}(r)|^2 = |\mathcal{F}^{-1}\{C(\mathbf{k})O(\mathbf{k} - \mathbf{k}_n)\}|^2, \quad (2)$$

式中: $I_{nc}(r)$ 表示相机传感器上的强度; $g_{nc}(r)$ 表示传感器上的复振幅分布; $O(\mathbf{k} - \mathbf{k}_n)$ 表示由具有波矢量 \mathbf{k}_n 平面波照射的样品的光谱; $\mathbf{k} = (k_x, k_y)$ 表示二维频率坐标; \mathcal{F}^{-1} 表示傅里叶逆变换。为了模拟使用更大的镜头捕获图像,通过依次点亮全部 LED 以覆盖傅里叶光谱的较大部分。数据获取的示例如图 2 所示,图 2(a) 为原始高清蝴蝶图像,图 2(b) 为对应蝴蝶图像的傅里叶频谱图。FPM 使用 LED 阵列作为光源,通过依次点亮各个位置处的 LED,从不同照射角度对蝴蝶图像进行照明,采集一组含有不同频域信息的低分辨率强度图像,图 2(c) 为一组与蝴蝶图像对应的低分辨率图像。图 2(d) 为这组低分辨率图中四个不同位置 LED 扫描到的图像,包括一个中心位置获得的较大细节图像与三个边缘位置的低信息图像。




图 2 FPM 采集 7×7 低分辨率图像的示例图。(a) 原图; (b) 傅里叶频谱图; (c) 低分辨率图像; (d) 不同位置 LED 观察到的图像

Fig. 2 Examples of 7×7 low-resolution images acquired by FPM. (a) Original image; (b) Fourier spectrogram; (c) low-resolution image; (d) images observed by LEDs in different positions

2.2 恢复过程

在恢复过程中, FPM 可以通过合成具有不同频

域信息的图像来获得高分辨率复振幅分布 $o_e(r) = \mathcal{F}^{-1}\{O_e(\mathbf{k})\}$ 。通常, FPM 通过经典的迭代投影

(AP)的重建算法来恢复高分辨率图像,该方法迭代地估计复振幅图像并使用捕获的强度图像对其进行更新。一次迭代可以表示为

$$g_{nc}(r) = \mathcal{F}^{-1} \{ C(\mathbf{k}) O_c(\mathbf{k} - \mathbf{k}_n) \}, \quad (3)$$

$$C(\mathbf{k}) O_c(\mathbf{k} - \mathbf{k}_n) = \mathcal{F} \left\{ g_{nc}(r) \frac{\sqrt{I_{nc}(r)}}{|g_{nc}(r)|} \right\}. \quad (4)$$

(3)式用于估计与每次 LED 灯照明相对应的高分辨率图像。(4)式是使用捕获的低分辨率强度图像更新高分辨率图像。重复(3)式和(4)式的运算直到被估计的频谱收敛,迭代初始的 $g_{nc}(r)$ 可以采用随机噪声或者某个低分辨率的图像。最后,通过逆傅里叶变换,将被估计的光谱 $O_c(\mathbf{k})$ 变换成 $o_c(r)$, 从 $o_c(r)$ 中提取出高分辨率图像。

3 FPM 重构网络结构

本文提出的基于卷积神经网络的 FPM 网络模型将一组低分辨率强度图像 I_{LR} 作为网络的输入,并输出单个高分辨率图像 I_{HR} 。通过从不同的照明角度的 LED 照射真实样品图片 I_{GT} 来捕获低分辨率图像 I_{LR} ,模型的最终目标是重建出与 I_{GT} 尽可能接近的高清图像 I_{HR} 。如图 3 所示,本文的模型主要分为 4 个部分:浅层特征提取模块、残差密集模块与通道注意力模块、上采样重建模块。如图 4 所示,单层卷积神经网络(Conv.)紧跟着线性整流函数(ReLU)组成卷积模块 CR,而浅层特征提取模块由

两个 CR 模块组成,其中第一个 CR 模块为后面更深的特征提取以及模型的全局残差学习做准备。模型通过引入全局残差学习,将浅层特征和深层特征结合在一起,使特征信息能够尽可能多的得到利用,从而可以从原始低分辨图像中获得全局密集特征。浅层特征提取模块中第二个 CR 模块的输出,将作为后面紧接着的 RDCA 模块的输入。在经过了 N 个 RDCA 模块对各等级特征的提取后,模型引入了全局特征融合。全局特征融合自适应地整合来自模型中所有 RDCA 模块的输出特征来获取全局特征。全局特征融合是将特征信息合并操作,再经过一个卷积核为 1×1 的卷积层^[26],它可以起到减少参数量并自适应融合特征的作用。接着是 3×3 的卷积层,该卷积层做进一步的特征提取以提供给全局残差学习。在对低分辨空间进行各等级特征提取之后,本文在重建高分辨空间堆叠出一个上采样重建模块。如图 5 所示,受到高效子像素卷积神经网络(ESPCN)^[27]的启发,本文对上采样重建模块采用 ESPCN 模型中提出的子像素卷积,又被称为像素洗牌(PS),并随后连接一个 CR 模块,如此“PS-CR”的结构堆叠重复两次,从而实现 4 倍上采样的效果。常见的上采样方法有插值法、转置卷积法等。相比于上述方法,本文使用的子像素卷积法计算量较小,且重建速度较快,精度较高。

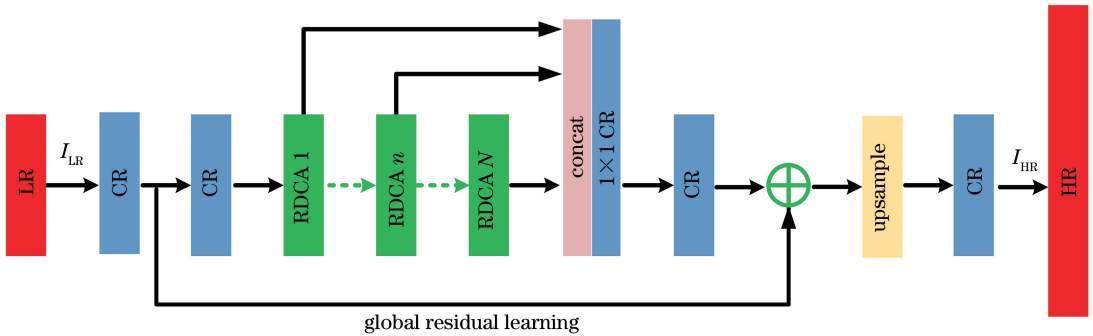


图 3 本文提出的傅里叶叠层显微成像网络模型结构图

Fig. 3 Structure diagram of proposed Fourier stacked microscopy imaging network model




图 4 卷积模块

Fig. 4 Convolution module




图 5 上采样重建模块

Fig. 5 Upsampling reconstruction module

3.1 残差密集模块与通道注意力模块

如图 6 所示,本文提出的 RDCA 模块包含以下部分:密集连接层、局部特征融合、局部残差学习和

通道注意力模块。传统的密集连接结构能提高特征的重用率,有效防止梯度弥散,可以用于训练更深的模型,相对于相同深度网络需求的参数量更少。与

传统密集连接不同,本文的密集连接块去除了批量归一化^[28]以及池化层,允许前一个 RDCA 模块的输出直接连接当前 RDCA 模块中的每一个 CR 模块,并且用局部特征融合代替传统密集连接中的过渡层^[23],这样不仅能够降低网络的计算复杂度(批量归一化层会带来与卷积层相同的显卡资源消耗),增强信息的流动性,而且能够保持和探索更多的像素级别的有效信息。局部特征融合可以自适应地融合来自先前 RDCA 模块的特征以及当前 RDCA 模块中全部 CR 模块提取的特征信息,它是把特征信息经过合并操作 Concat 之后,再经过一个卷积核为 1×1 的卷积层,之后连接通道注意力(CA)模块。在密集连接中,特征通道数量是随着网络层数增加而快速增长的,引入局部特征融合之后,通道数量过多的问题暂时得以解决。但随之而来的问题是,低分辨输入以及特征中包含了丰富的低频信息,而模型均等地对待这些特征通道,阻碍了神经网络更进

一步地表达。为了使网络更专注于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,模型引入了通道注意力机制。如图 7 所示,CA 模块由全局平均池化层、全连接层(FC)、ReLU 激活层和 sigmoid 激活层堆叠组成。假设输入是一个 $H \times W \times C$ 的特征,CA 模块先进行一个空间的全局平均池化得到一个 $1 \times 1 \times C$ 的通道描述,接着,经过两个全连接层,分别作为通道下采样和上采样层,得到每一个通道的权重系数,将权重系数和原来的特征相乘得到缩放后的新特征。整个过程实际上就是对不同通道的特征重新进行了加权分配,其中,全连接层是利用 1×1 卷积层来实现的,下采样层的通道数减少 r 倍。由于一个 RDCA 模块中包含了多个卷积层,为了更进一步改善信息流动,RDCA 中引入局部残差学习。CA 模块之后提取到的特征将进一步给局部残差学习利用。




图 6 具有通道注意力机制的残差密集模块

Fig. 6 Residual dense module with channel attention mechanism




图 7 通道注意力模块

Fig. 7 Channel attention module

3.2 模型具体参数

对于本文提出的模型,在全局特征融合、局部特征融合层与 CA 模块中的通道下采样和上采样层中,卷积核大小为 1×1 ,除此之外模型中其他卷积层的卷积核大小都是 3×3 。对于卷积核为 3×3 大小的卷积层,零填充的方法用于保持特征图大小固定。浅层特征提取层、全局特征融合与局部特征融合层、通道上采样层中有 64 个滤波器。通道下采样层中有 $\frac{C}{r} = 4$ 个滤波器,下采样系数 r 设置为 16。在 RDCA 模块中的其他卷积层有 G 个

滤波器, G 是 RDCA 模块中 CR 模块产生特征图的数量,也被定义为成长率^[23]。由于模型输出是灰度图像,最后一层卷积层只有一个输出通道,来获得最终的高清恢复图像。该网络也能够处理彩色图像。

4 实验数据准备与参数设置

4.1 实验数据与评价方法

实验数据包括训练集和测试集。训练集和测试集都包括低分辨率样本和真实图片,训练样本和真实图片是成对存在的。训练集的制作采用了文

献^[17]中提到的 DIV2K 数据集,其训练集中共有 800 张高分辨率图片。对于测试集,本文选用了 5 个基准数据集 Set5^[29]、Set14^[30]、B100^[31]、Urban100^[32]、Manga109^[33],共有 328 张高清图,提高了实验数据的权威性。原始高清图被转换成灰度图像,并且按照 128×128 大小分块裁剪进行数据增强,得到真实图片 I_{GT} 。其中训练集包括 2 万张真实图片,

测试集含有将近 1 万张真实图片。利用 2.1 节中的 FPM 前向成像过程,对 I_{GT} 进行仿真,每一个 I_{GT} 可以获得 L 个 32×32 大小的低分辨率图像, L 是前向成像过程中 LED 灯的数量。利用这 L 个低分辨率图像拼接成 $32 \times 32 \times L$ 的图像块,从而得到低分辨率样本作为模型的输入。图 8 为构建和使用训练数据集的示例图。




图 8 构建和使用训练数据集的示例图

Fig. 8 Example graph for building and using training datasets

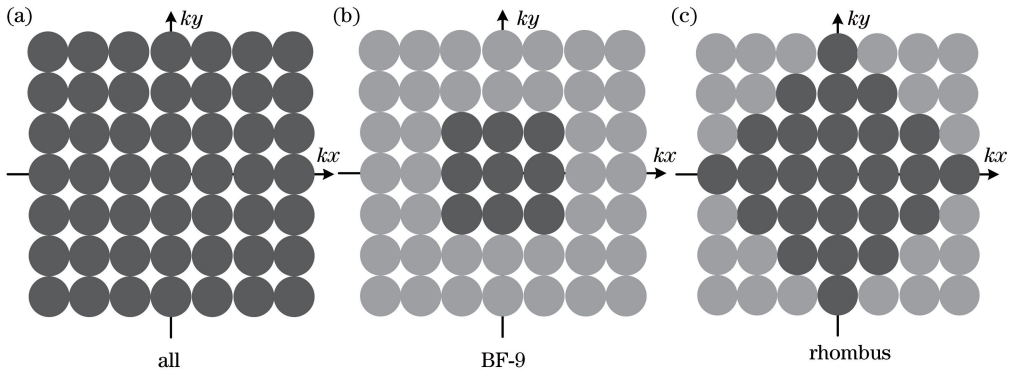


图 9 三种 LED 照明方式的示意图。(a) 点亮全部 LED; (b) 点亮亮场区域 LED; (c) 点亮菱形区域 LED

Fig. 9 Schematic of three LED lighting modes. (a) Turn on all LEDs; (b) turn on bright-field area LEDs; (c) turn on rhombus area LEDs

为了系统地研究重建分辨率与采样方法之间的关系,以及探索更加高效的采样方式,如图 9 所示,本文进行了三种不同 LED 点亮方式的采样,颜色较深的圆点表示 LED 灯点亮。LED 灯总数量设置为 49,图 9(a)为逐个点亮全部 LED 灯,图 9(b)为只点亮亮场区域 9 个 LED 灯(BF-9),图 9(c)为点亮方阵内菱形区域的 LED 灯。李通等^[9]提出的基于角

度照明优化的 FPM 策略中,设计出了一种基于菱形采样方法来加速 FPM 的实现过程。本文借鉴了这种采样方法,并在其基础上,不点亮 LED 阵列四个角落的 LED 灯,进一步减少采样数量至 25。对不同采样方法得到的数据集进行实验,将峰值信噪比(PSNR)和结构相似度(SSIM)作为客观评价指标。

4.2 实验设置

如前面所介绍,将 $32 \times 32 \times L$ 的图像块作为模型输入,输出 128×128 的清晰图像。批次大小设置为 32,而一个训练周期包含 625 次模型参数迭代更新。本研究在 TensorFlow 1.8 深度学习框架上搭建网络模型,其中损失函数采用平均绝对值误差,也称为 L1 loss,运用 Adam 优化器更新损失函数。整个模型的初始学习率设置为 10^{-4} ,并且每过 100 个训练周期减小一半。每个模型的训练在单块 GTX 1080ti 设备上耗时 24~36 h,期间经历 200 个训练周期。

在模拟 FPM 采集图像的过程时,LED 阵列板大小为 7×7 ,LED 阵列板与样本之间的距离为 90 mm,两个相邻 LED 灯的间距为 4 mm,数值孔径 $NA = 0.1$,放大倍数为 4 倍,照明波长为 630 nm,图像传感器像元尺寸为 $2.75 \mu\text{m}$ 。

5 实验结果分析与讨论

除 4.1 节介绍的不同采样方法进行对比实验之外,本文将探究网络结构的基本参数:RDCA 模块的数量 N 、每个 RDCA 模块中 CR 模块的数量 I 以及 RDCA 模块的成长率 G 。本文还对通道注意力 CA 模块做消融实验,探究 CA 模块对重建效果的影响。此外,也对各种参数组合的 FPRDCA 与

PtychNet、AP 算法在重建效果和恢复时间上进行了对比实验分析。

5.1 FPRDCA 的基本参数探究

探究了模型的基本参数 N 、 I 和 G 不同值对重建分辨率的影响。如图 10(a)~(c)所示,曲线图纵坐标表示 PSNR 值,横坐标表示训练步数,也称迭代次数。表 1 为 5 个基准数据集上各个模型的平均 PSNR 和 SSIM,其中粗体表示最佳性能,“14-8-64”代表基础参数为 $N=14, I=8, G=64$ 的模型,“* 14-8-64”表示没有采用 CA 模块的模型 FPRD。AP 算法在训练集上的表现(虚线代表 AP 算法在数据集上重建的 PSNR 平均值)被作为基准以供参考。一方面,如表 1 和图 10(a)、(b)所示,更大的 N 或 I 使模型表现更好,这主要是因为网络随着 N 或 I 的增大而不断加深,而在密集连接和残差结构等帮助下,更深的网络可以帮助模型较稳定地收敛,从而获得更好的重建效果。此外,如图 10(c)所示,RDCA 模块中的成长率 G 越大,模型的重建效果越好,特别是 G 增加至 64 之后 PSNR 有较大幅度的提升。RDCA 模块中采用的局部特征融合允许模型接受更大的成长率,局部特征融合中的 1×1 卷积层能起到很好的降维功能。但在另一方面,随着 N 、 I 或 G 的减小,FPRDCA 在训练中会遭受一些性能下降,不过 FPRDCA 的表现仍然胜过 AP 算法。

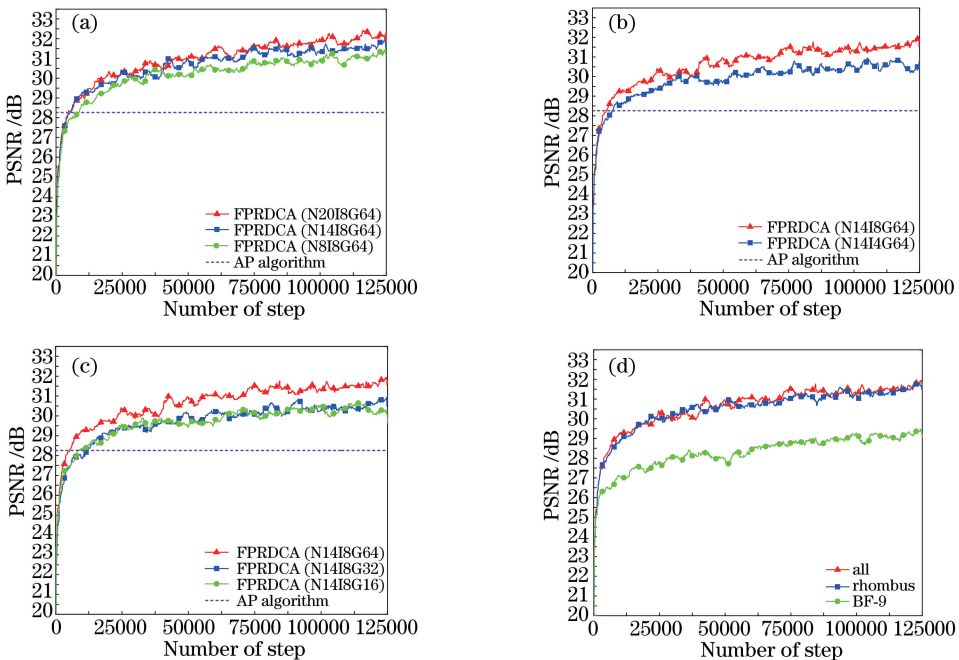


图 10 N 、 I 和 G 不同值的 FPRDCA 以及三种采样方式的收敛性分析。
Fig. 10 Convergence analysis of FPRDCA with different values of N , I , and G and three sampling patterns.

(a) N ; (b) I ; (c) G ; (d) three sampling patterns

5.2 三种采样方式的重建对比

为了研究重建分辨率与采样方法之间的关系,以及探索更加高效的采样方式,本研究实施三种采样方式:全采样(All)、明场采样(BF-9)和菱形采样,它们的LED灯点亮数量是49、9和25。从本节开始,FPRDCA的基础参数设置是 $N=14$, $I=8$ 和 $G=64$,三种采样方式得到的数据集对应训练三个不同的模型(以下由采样方式为模型命名)。如图10(d)所示,模型All和Rhombus的PSNR训练收敛曲线几乎重叠,均取得较好的重建效果。如表1和图12所示,模型Rhombus的PSNR、SSIM测试结果与模型All相差无几,重建图像视觉效果上都取得最好的效果,几乎无异,这说明菱形采样能和全采样取得几乎相同的

表1 5个基准数据集上各个模型的平均PSNR和SSIM

Table 1 Average PSNR and SSIM of each model on 5 benchmark datasets

| Method | Set5 | | Set14 | | Urban100 | | Manga109 | | B100 | |
|----------|--------------|---------------|--------------|---------------|--------------|---------------|--------------|---------------|--------------|---------------|
| | PSNR /dB | SSIM | PSNR /dB | SSIM | PSNR /dB | SSIM | PSNR /dB | SSIM | PSNR /dB | SSIM |
| PtychNet | 25.33 | 0.8088 | 24.32 | 0.7209 | 22.46 | 0.6752 | 23.36 | 0.7966 | 23.58 | 0.6605 |
| AP | 30.19 | 0.9124 | 28.36 | 0.8424 | 26.09 | 0.8253 | 29.64 | 0.9012 | 27.03 | 0.8227 |
| BF-9 | 29.05 | 0.8703 | 26.75 | 0.7628 | 24.76 | 0.7286 | 27.86 | 0.8676 | 24.87 | 0.6869 |
| 14-4-64 | 33.17 | 0.9339 | 29.87 | 0.8582 | 28.07 | 0.8463 | 32.22 | 0.9366 | 28.01 | 0.8309 |
| 8-8-64 | 33.21 | 0.9355 | 29.94 | 0.8524 | 28.06 | 0.8399 | 32.23 | 0.9295 | 28.02 | 0.8250 |
| 20-8-64 | 33.57 | 0.9361 | 29.97 | 0.8693 | 28.18 | 0.8476 | 32.38 | 0.9380 | 28.16 | 0.8402 |
| *14-8-64 | 33.18 | 0.9351 | 29.86 | 0.8596 | 27.99 | 0.8379 | 32.16 | 0.9282 | 27.88 | 0.8312 |
| Rhombus | 33.16 | 0.9354 | 29.83 | 0.8577 | 28.07 | 0.8460 | 32.05 | 0.9369 | 27.87 | 0.8283 |
| 14-8-16 | 33.02 | 0.9319 | 29.80 | 0.8581 | 27.94 | 0.8349 | 31.94 | 0.9247 | 27.93 | 0.8304 |
| 14-8-32 | 33.33 | 0.9354 | 29.91 | 0.8615 | 28.10 | 0.8398 | 32.26 | 0.9285 | 28.09 | 0.8306 |
| 14-8-64 | 33.46 | 0.9354 | 29.97 | 0.8602 | 28.19 | 0.8486 | 32.27 | 0.9384 | 28.11 | 0.8319 |

表2 基于5个基准数据集使用不同模型重构单张大小 128×128 图像的平均运行时间

Table 2 Average running time for reconstructing a single 128×128 image with different models based on 5 benchmark datasets

| Method | AP | PtychNet | 14-8-64 | 8-8-64 | 20-8-64 | 14-8-32 | 14-4-64 | 14-8-16 |
|----------|-----|----------|---------|--------|---------|---------|---------|---------|
| Time /ms | 730 | 20.1 | 44.4 | 30.2 | 51.7 | 43.4 | 28.8 | 39.6 |

5.3 CA模块的消融实验以及FPRDCA与PtychNet、AP算法的对比

如图11和表1所示,图11对比了模型FPRDCA和未加入通道注意力机制的模型FPRD, FPRDCA的收敛曲线比FPRD的更加平滑,且PSNR值约高出1 dB,说明FPRDCA训练过程更加稳定、效果更佳。而在测试集的表现上,FPRDCA的PSNR和SSIM都高于FPRD,重建效果更好。这说明模型FPRDCA能够专注于信息量较大的特征通道,利用特征通道之间的相互依赖性,使其表达能力得到了进一步的释放,端到端的映射能力更强。

重建精度,也更进一步说明菱形采样是一种高效的FPM采样方法。在本文中,菱形采样可以节省约49%的采样数量。另一方面,模型BF-9与All、Rhombus的重建效果相差约4 dB,重建效果不佳,这说明在重建过程中,暗场的低分辨率图像也是不可缺少的。明场的低分辨率图像携带大量、冗余的低频信息,这些低频信息代表图像的整体性,更加扁平化,而暗场的图像通常携带高频分量信息,这些高频信息通常是区域性的,充满边缘、纹理和其他细节。为了保证重建的精度,模型必须得到明场、暗场图像数量上合理的组合搭配。通过对比三个模型可知,Rhombus验证了菱形采样方法的明、暗场图像数量组合是比较合理的,能够取得与全采样几乎相同的重建效果。

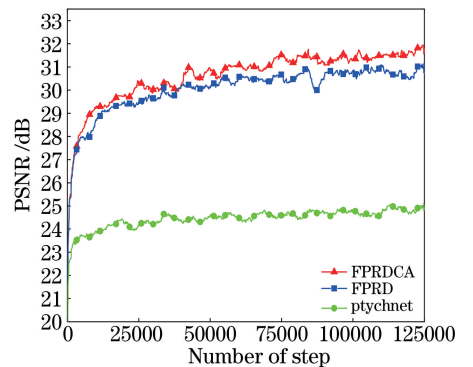


图11 FPRDCA、FPRD与PtychNet的收敛性分析
Fig. 11 Convergence analysis of FPRDCA, FPRD, and PtychNet

如图 10(a)~(c)和图 11 所示,模型 FPRDCA 训练的 PSNR 值约在第 10000 步迭代之后超过了 AP 算法并保持到训练结束,而几乎整个过程都保持高于 PtychNet 的 PSNR 值。表 1 提供了不同方法下 5 个权威基准数据集的客观评价结果。由表 1 可以看出,模型 FPRDCA 可以有效重构图像,基础参数设置是 $N=14, I=8$ 和 $G=64$ 的 FPRDCA 比 AP 算法在 5 个数据集上的平均 PSNR 值提高了 2.138 dB,平均 SSIM 值提高了 0.0221,而与模型 PtychNet 相比平均 PSNR 值提高了 6.59 dB,平均 SSIM 值提高了 0.1505。表 2 提供了不同方法下重构单张大小 128×128 图像的运行时间。由表 2 可以看出,本文模型在运行时间上也有优势,基础参数设置是 $N=14, I=8$ 和 $G=64$ 的 FPRDCA 略慢于

模型 PtychNet,比 AP 算法缩短了 685.6 ms,大大加快了重建速度。为了增强说服力,图 12 为各个方法下不同数据集测试后重构的展示图(粗体表示最佳性能),第一列是从数据集随机选取的未分割的原始图像,第二列代表原始高清图像。对于模型 PtychNet,在图 12 第三列出现模糊的伪影,并且细节信息有所丢失。对于 AP 算法,在图 12 第四列分别出现了不同程度的波纹以及网格状的伪迹,细节信息相对模型 PtychNet 丢失程度较小,但纹理和轮廓信息也有严重损失,如 *img_01, img_02* 和 *img_039*。而对于模型 FPRDCA,重构的图像对比 AP 和 PtychNet 方法更接近于原始高清图像,细节保留更加完整,纹理和轮廓清晰,视觉效果比较好。综合来看,本文网络结构在较短时间内重建图像的质量

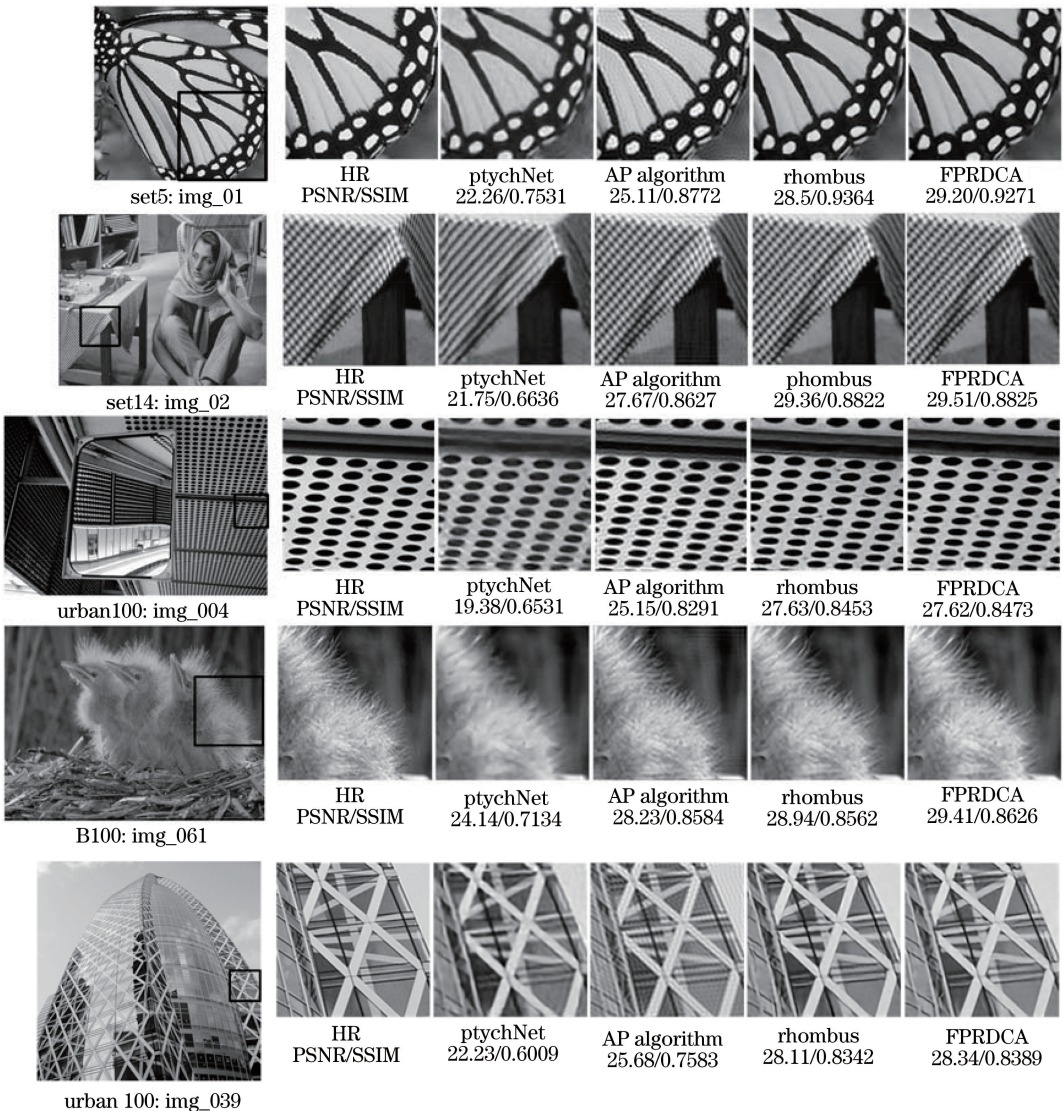


图 12 各个方法在数据集上测试的效果展示图

Fig. 12 Test results of each method on the dataset

优于传统 AP 算法,而相比于神经网络模型 PtychNet,重建质量有大幅度提高。

6 结 论

本文提出一种基于深度学习的傅里叶叠层显微成像的神经网络模型。通过残差结构、密集连接以及通道注意力机制的联合作为基本模块 RDCA,构建一个极深的具有通道注意力机制的残差密集网络 FPRDCA。RDCA 模块的结构不仅稳定了更深网络的训练,还能保持并放大地利用更加有价值的特征信息,提高特征的利用率。在上采样网络中使用子像素卷积加速了重建的过程。除此之外,本文还引入了菱形采样方法以达到减少采集数量的目的。综上所述,FPRDCA 在结合这些方法后取得了更优的性能,同时缩短了重建时间,减少了低分辨样本的采集数量。

本文的不足之处在于两个方面:一个是未在仿真实验中考虑真实采集环境下存在的噪声,比如高斯噪声、泊松噪声等,这涉及到对数据集构造以及网络模型的优化与调试;另一个是本文采用的损失函数可能无法完全约束训练过程,而具有更多统计信息的损失函数可能会引导出更好的结果。以上这些不足是未来工作的重点方向。

参 考 文 献

- [1] 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.
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.
- [2] Zheng G A, Horstmeyer R, Yang C. Wide-field, high-resolution Fourier ptychographic microscopy [J]. *Nature Photonics*, 2013, 7(9): 739-745.
- [3] Zheng G. Fourier ptychographic imaging: a MATLAB tutorial [M]. San Rafael: Morgan & Claypool Publishers, 2016:10-22.
- [4] Fienup J R. Phase retrieval algorithms: a personal tour[J]. *Applied Optics*, 2013, 52(1): 45-56.
- [5] Gerchberg R W. A practical algorithm for the determination of phase from image and diffraction plane pictures[J]. *Optik*, 1972, 35(2): 237-246.
- [6] Zhao M, Wang X M, Zhang X H, et al. Experimental research on macroscopic Fourier ptychography super-resolution imaging[J]. *Laser &*

Optoelectronics Progress, 2019, 56(12): 121101.

赵明, 王希明, 张晓慧, 等. 宏观傅里叶叠层超分辨率成像实验研究[J]. *激光与光电子学进展*, 2019, 56(12): 121101.

- [7] Tian L, Li X, Ramchandran K, et al. Multiplexed coded illumination for Fourier ptychography with an LED array microscope [J]. *Biomedical Optics Express*, 2014, 5(7): 2376-2389.
- [8] Lin Z Q, Ma X, Lin J X, et al. Fourier ptychographic microscopy based on rotating arc-shaped array of LEDs[J]. *Laser & Optoelectronics Progress*, 2018, 55(7): 071102.
林子强, 马骁, 林锦新, 等. 基于弧形阵列 LED 光源旋转照明装置的傅里叶叠层显微术[J]. *激光与光电子学进展*, 2018, 55(7): 071102.
- [9] Li T, Zhao J F, Mao H F, et al. An efficient Fourier ptychographic microscopy imaging method based on angle illumination optimization [J]. *Laser & Optoelectronics Progress*, 2020, 57(8): 081106.
李通, 赵巨峰, 毛海锋, 等. 基于角度照明优化的傅里叶叠层显微成像方法[J]. *激光与光电子学进展*, 2020, 57(8): 081106.
- [10] Bian L H, Suo J L, Zheng G A, et al. Fourier ptychographic reconstruction using wirtinger flow optimization[J]. *Optics Express*, 2015, 23(4): 4856-4866.
- [11] Zuo C, Sun J S, Chen Q. Adaptive step-size strategy for noise-robust Fourier ptychographic microscopy [J]. *Optics Express*, 2016, 24(18): 20724-20744.
- [12] Kappeler A, Ghosh S, Holloway J, et al. Ptychnet: CNN based Fourier ptychography [C] // 2017 IEEE International Conference on Image Processing (ICIP). September 17-20, 2017, Beijing, China. New York: IEEE Press, 2017: 1712-1716.
- [13] Jiang S W, Guo K K, Liao J, et al. Solving Fourier ptychographic imaging problems via neural network modeling and TensorFlow [J]. *Biomedical Optics Express*, 2018, 9(7): 3306-3319.
- [14] 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.
- [15] Girshick R. Fast R-CNN [C] // 2015 IEEE International Conference on Computer Vision (ICCV). December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 1440-1448.
- [16] Dong C, Loy C C, He K M, et al. Image super-resolution using deep convolutional networks [J].

- IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(2): 295-307.
- [17] 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 (CVPR). July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 105-114.
- [18] Shi Z T, Wang Z R, Wang R, et al. Single image super-resolution based on convolutional neural network [J]. Laser & Optoelectronics Progress, 2018, 55(12): 121001.
史紫腾, 王知人, 王瑞, 等. 基于卷积神经网络的单幅图像超分辨率[J]. 激光与光电子学进展, 2018, 55(12): 121001.
- [19] Sun C, Lü J W, Gong J, et al. Image super-resolution method combining wavelet transform with deep network[J]. Laser & Optoelectronics Progress, 2018, 55(12): 121006.
孙超, 吕俊伟, 宫剑, 等. 结合小波变换与深度网络的图像超分辨率方法[J]. 激光与光电子学进展, 2018, 55(12): 121006.
- [20] LeCun Y, Bengio Y, Hinton G. Deep learning [J]. Nature, 2015, 521(7553): 436-444.
- [21] Schmidhuber J. Deep learning in neural networks: an overview [J]. Neural Networks, 2015, 61: 85-117.
- [22] 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.
- [23] Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 2261-2269.
- [24] Tong T, Li G, Liu X J, et al. Image super-resolution using dense skip connections [C] // 2017 IEEE International Conference on Computer Vision (ICCV). October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 4809-4817.
- [25] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 7132-7141.
- [26] Lin M, Chen Q, Yan S C. Network in network [EB/OL]. (2014-03-04) [2020-03-25]. <https://arxiv.org/abs/1312.4400>.
- [27] Shi W Z, Caballero J, Huszár F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 1874-1883.
- [28] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift [EB/OL]. (2015-03-02) [2020-03-25]. <https://arxiv.org/abs/1502.03167>.
- [29] Bevilacqua M, Roumy A, Guillemot C, et al. Low-complexity single-image super-resolution based on nonnegative neighbor embedding [C] // Proceedings of the British Machine Vision Conference 2012. Surrey. British Machine Vision Association, 2012: 135.
- [30] Zeyde R, Elad M, Protter M. On single image scale-up using sparse-representations [M] // Curves and surfaces. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012: 711-730.
- [31] Martin D, Fowlkes C, Tal D, et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics [C] // Proceedings Eighth IEEE International Conference on Computer Vision. ICCV 2001. July 7-14, 2001, Vancouver, BC, Canada. New York: IEEE Press, 2001: 416-423.
- [32] Huang J B, Singh A, Ahuja N. Single image super-resolution from transformed self-exemplars [C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 5197-5206.
- [33] Matsui Y, Ito K, Aramaki Y, et al. Sketch-based manga retrieval using manga109 dataset [J]. Multimedia Tools and Applications, 2017, 76(20): 21811-21838.