

基于深度学习的傅里叶叠层成像技术

沙浩¹, 刘阳哲², 张永兵^{1*}

¹ 哈尔滨工业大学(深圳)计算机科学与技术学院, 广东 深圳 518055;

² 清华大学深圳国际研究生院, 广东 深圳 518055

摘要 傅里叶叠层成像技术(FP)可重构出宽视场、高分辨率的物体幅值和相位分布,随着深度学习技术的不断发展,神经网络已成为求解计算成像中非线性逆问题的重要手段之一。针对 FP 系统数据特异性强、数据量少等特点,提出了一种结合计算成像先验知识和深度学习的算法,设计了基于物理模型的神经网络框架,并对仿真样本进行了验证。此外,还搭建了远场透射系统,对宏观物体的图像序列进行 FP 重建验证。实验结果表明,该系统能用有限的仿真与真实数据集重构出高分辨率样本的复振幅分布,且对光学像差与背景噪声的鲁棒性较强。

关键词 成像系统; 傅里叶叠层成像技术; 光学超分辨率; 计算成像; 深度学习

中图分类号 O436

文献标志码 A

doi: 10.3788/LOP202158.1811020

Fourier Ptychography Based on Deep Learning

Sha hao¹, Liu Yangzhe², Zhang Yongbing^{1*}

¹ School of Computer of Science and Technology, Harbin Institute of Technology (Shenzhen), Shenzhen, Guangdong 518055, China;

² Tsinghua Shenzhen International Graduate School, Tsinghua University, Shenzhen, Guangdong 518055, China

Abstract Fourier ptychography (FP) can reconstruct the amplitude and phase distribution of objects with a wide field of view and high. With the continuous development of deep learning, neural network has become one of the important methods to deal with the nonlinear inverse problems in computational imaging. Aiming at the characteristics of FP system such as strong data specificity and small amount of data, this paper proposes an algorithm combining computational imaging prior knowledge and deep learning, to design a neural network framework based on physical model, and verifies it on simulation samples. Furthermore, a far-field transmission system is constructed to verify the FP reconstruction of image sequences of macroscopic objects. Experimental results show that the system can reconstruct the complex amplitude distributions of high-resolution samples using limited simulation and real data sets, with high robustness to optical aberration and background noise.

Key words imaging systems; Fourier ptychography; optical super-resolution; computational imaging; deep learning

OCIS codes 110.1758; 100.5070; 100.6640

1 引言

受限于透镜式成像机制,传统光学显微镜的成像性能逐渐不能满足人们的需求。随着计算机技术

和光电子器件的不断发展,基于计算成像机制的显微成像技术得到了广泛应用。计算成像将传统光学显微系统的单次成像过程拆分为图像采集及特征提取两个步骤,通过收集图像处理算法所需的信息

收稿日期: 2021-06-02; 修回日期: 2021-07-15; 录用日期: 2021-07-20

基金项目: 国家自然科学基金(61922048, 62031023)、广东特支计划(2019TX05X187)、深圳市基础研究项目(JCYJ20200109142808034)

通信作者: *ybzhang08@hit.edu.cn

对成像结果进行后处理,从而弥补传统成像的不足,具有成像系统结构简单(低成本、无透镜)、图像质量高(对比度高)、可突破光学系统的物理限制(空间分辨率、景深)、成像系统的性能指标好等优点。

基于合成孔径和相位恢复的空域叠层成像技术(PIE)^[1]主要应用于无透镜成像系统中,通过采集的一系列低分辨率图像基于迭代拼接的思想求解高分辨率样本的复振幅分布^[2]。傅里叶叠层成像技术(FP)显微镜^[3]主要应用于有透镜光学系统中,在采集图像时,FP通过发光二极管(LED)进行波前调制,采集物体傅里叶域频谱中不同位置的强度图。因此,PIE的支撑域约束为物体在空间域中的位置,振幅约束为采集的傅里叶域衍射图像;而FP的支撑域约束为频谱中子孔径的位置,振幅约束为空间域中采集的图像。FP与PIE算法的原理相似,因此,可将FP视为PIE的傅里叶域对偶形式。Horstmeyer等^[4]论证了FP与PIE在数学分布空间中的一致性,为将PIE的相关技术移植到FP中提供了理论依据。FP在成像性能、实现方式、成像模式等基础理论研究方面取得了丰硕的成果^[5-6],但成像系统的差异性,使FP在某些场景如远距离成像中的应用仍需要进行深入探索。

随着人工智能理论及计算机视觉技术的发展,深度学习算法具有的特征提取能力和结构多样性使其在多个领域中得到了广泛应用。光学显微作为生物医学图像获取的主要手段,也逐渐与深度学习进行交叉融合^[7]。目前,基于深度学习的FP根据重建原理主要可分为数据驱动型网络和物理模型类网络两种。数据驱动型网络将成像场景局限在特定的光学系统中,Kappeler等^[8]和陈奕灿等^[9]通过实验验证了将深度学习应用于FP的可行性,但仅利用仿真数据训练Ptychnet模型,且构建数据集时忽略了物体的相位分布。Zhang等^[10]设计了多尺度残差神经网络(MDRAN),将真实样本物体的复振幅分布作为网络输入,然后重构出幅值和相位。实验结果表明,傅里叶过程神经网络(FPNN)在多项图像评价指标上的表现优异且能大幅缩短图像的重建时间。Nguyen等^[11]将条件生成对抗网络(cGAN)应用于活体细胞检测场景中,其输入为原始FP数据,标签数据为传统FP的求解结果,该模型重建图像仅需25 s,可用于实时活细胞检测。杨学苗^[12]用网络优化FP的照明模式,得到比手工设计更合理的信息编码方式,可提升图像的采集效率。尽管数据驱动网络的重建速度较快,且在部分特定的光学

系统中有着优秀的表现,但模型的可解释性不强,当系统噪声误差较大时,模型难以满足实际需要。物理模型类网络基于传统计算成像的先验知识,将传统算法展开到神经网络,在网络训练过程中更新和优化参数,使网络具有强大学习能力的同时保持较强的可解释性和鲁棒性。Seifert等^[13]将PIE迭代恢复过程用神经网络的方式展开,用相干光照明物体,利用远场衍射公式得到传感器平面的预测分布,通过计算样本预测分布与真实分布的误差指导样本参数的更新。Jiang等^[14]将初始样本与点扩散函数进行卷积,获得随入射波角度变换的预测光瞳函数,该模型从尺寸为 $128 \times 128 \times 81$ (81为通道数)的图像序列中完成重构仅需30 s。相比数据驱动型网络,物理模型类神经网络的可解释性强、图像恢复过程中无需预训练且不需要参考图像,可直接迭代优化样本参数。

本文基于FP的物理模型类神经网络框架,弥补了传统数据驱动神经网络算法在不同光学系统中难以迁移的不足。通过仿真实验验证了FP算法在微观场景中的有效性和普适性,并在实验室场景下搭建了FP的宏观成像装置,验证了本算法在宏观透射场景下的性能。

2 傅里叶叠层理论

2.1 FP的正向成像过程

FP作为数值计算方法,主要分为正向成像模型与图像重构两个过程。FP的正向成像模型如图1所

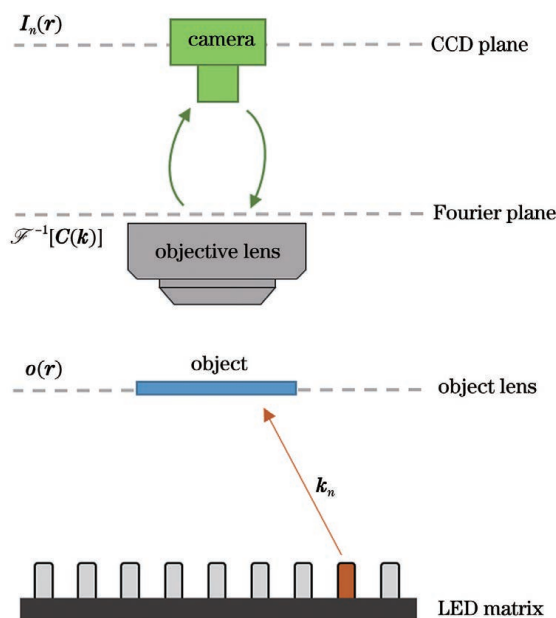


图 1 FP正向成像的模型

Fig. 1 Model of the FP forward imaging

示,在 FP 图像采集过程中,放置在载物台上的物体受 LED 矩阵中不同位置点光源的倾斜平面波照射,样本的出射光场经光学透镜传播,在图像传感器 CCD 平面聚焦成像。倾斜平面波能对物体进行相位调制,使传感器采集到系统截止频率外的高频信息。依次点亮 LED 矩阵中不同位置的点光源,使 FP 采集到不同入射角度下的低分辨率强度图像,以用于后续的图像重构。

图 1 中, $\mathbf{r}=(x, y)$ 为空间域中的二维坐标。假设被检测物体的传播函数为 $\mathbf{o}(\mathbf{r})$, 点亮照明矩阵中第 n 个 LED 相干光源, 则物体平面的出射波为 $\mathbf{o}(\mathbf{r}) \odot \exp(i\mathbf{k}_n)$, 其中, \odot 为矩阵相乘, $\mathbf{k}_n=(k_x^n, k_y^n)$ 为第 n 个入射光照角度的波矢。FP 为相干成像系统, 出射波在像平面的脉冲响应与复振幅呈线性关系。CCD 只能记录光照的强度变化, 因此, CCD 平面捕获的最终样本图像可表示为

$$I_n(\mathbf{r}) = |[\mathbf{o}(\mathbf{r}) \odot \exp(i\mathbf{k}_n)] * h_1(\mathbf{r})|^2, \quad (1)$$

式中, $I_n(\mathbf{r})$ 为第 n 个 LED 点亮时像平面的测量结果, $h_1(\mathbf{r})$ 为相干系统的脉冲响应函数, $*$ 为卷积符号。将(1)式的正向传播过程进行傅里叶变换,

得到

$$I_n(\mathbf{r}) = |\mathcal{F}^{-1}[\mathbf{O}(\mathbf{k} - \mathbf{k}_n) \odot \mathbf{C}(\mathbf{k})]|^2, \quad (2)$$

式中, \mathcal{F}^{-1} 为傅里叶逆变换符号, $\mathbf{k}=(k_x, k_y)$ 为傅里叶域的二维频域坐标, $\mathbf{O}(\mathbf{k})$ 为目标样本 $\mathbf{o}(\mathbf{r})$ 在傅里叶域中的表达式, $\mathbf{C}(\mathbf{k}) = \mathcal{F}[h_1(\mathbf{r})]$ 为脉冲响应的频域形式, 也被称为相干传递函数(CTF)。基于傅里叶变换的频移特性, 空间域中样本与相移调制因子 $\exp(i\mathbf{k}_n)$ 的乘积等于样本频谱在傅里叶域中的位移 $(-\mathbf{k}_n)$ 。对于圆形光学透镜, CTF 则为频谱上的圆形低通滤波器, 可表示为

$$C_{\text{circle}}(\mathbf{k}) = \begin{cases} 1, & k_x^2 + k_y^2 < (NA \cdot k_0)^2 \\ 0, & k_x^2 + k_y^2 \geq (NA \cdot k_0)^2 \end{cases}, \quad (3)$$

式中, NA 为成像系统的数值孔径, $k_0 = 2\pi/\lambda$, λ 为相干光源的波长。

2.2 FP 图像的重建过程

FP 图像的重建过程如图 2 所示。首先, 需要初始化高分辨率图像, 并在傅里叶频谱中平移截取由 CTF 确定的子光瞳区域; 然后, 通过交替投影方法, 交替更新子光瞳区域的频谱信息; 最后, 计算得到物体的高分辨率复振幅分布。

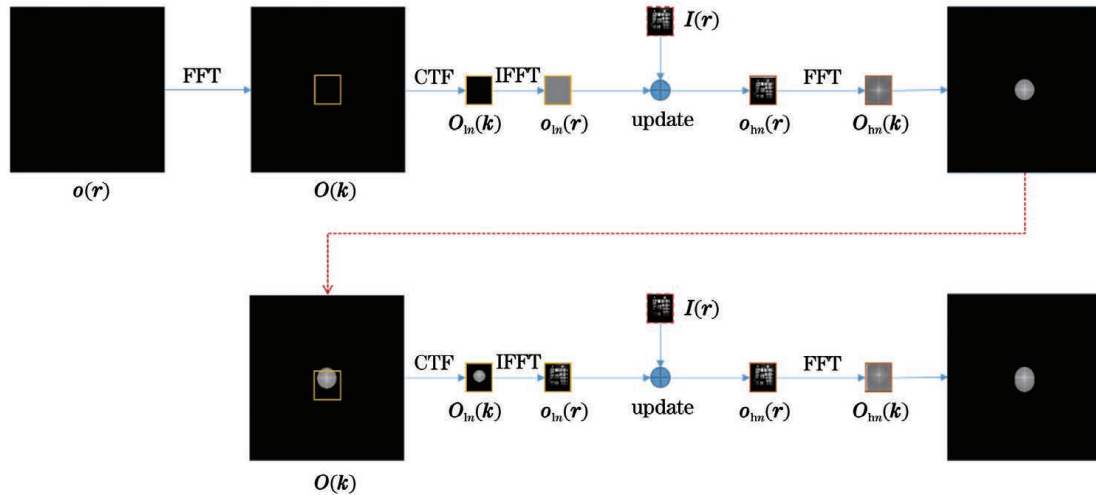


图 2 FP 图像的重建过程

Fig. 2 Reconstruction process of the FP image

基于 ePIE(extended PIE)算法的 FP 图像重构迭代过程如下。

1) 在空间域中, 将中心 LED 照明下采样的图像进行上采样。将上采样的图像作为物体复振幅分布的初始估计 $\mathbf{o}(\mathbf{r})$ (相位为 0) 并对其进行快速傅里叶变换(FFT), 得到初始解 $\mathbf{O}(\mathbf{k})$ 。

2) 在第 n 个 LED 照射下, 位置 \mathbf{k}_n 的频谱信息被移至光学系统截止频率范围内。将平移后的物体频谱与相干传递函数 $\mathbf{C}(\mathbf{k})$ 相乘, 得到正向传播后截

取的低分辨率频谱信息 $\mathbf{O}_{in}(\mathbf{k})$, 可表示为

$$\mathbf{O}_{in}(\mathbf{k}) = \mathbf{O}(\mathbf{k} - \mathbf{k}_n) \odot \mathbf{C}(\mathbf{k}). \quad (4)$$

3) 对 $\mathbf{O}_{in}(\mathbf{k})$ 进行快速傅里叶逆变换(IFFT), 得到空间域中待更新的低分辨率图像 $\mathbf{o}_{in}(\mathbf{r})$; 保持 $\mathbf{o}_{in}(\mathbf{r})$ 的相位不变, 将其幅值用采集图像 $I_n(\mathbf{r})$ 进行更新, 得到替换后的空域图像 $\mathbf{o}_{lm}(\mathbf{r})$, 更新过程可表示为

$$\mathbf{o}_{lm}(\mathbf{r}) = \sqrt{I_n(\mathbf{r})} \odot \frac{\mathbf{o}_{in}(\mathbf{r})}{|\mathbf{o}_{in}(\mathbf{r})|}. \quad (5)$$

4) 对 $\mathbf{o}_{ln}(\mathbf{r})$ 进行傅里叶变换, 将其转换到频域并替换原始频谱, 以更新当前照射角度下的子光瞳

频谱信息。为了弥补像差, 在更新频谱信息时, 需对光学像差进行补偿, 更新过程可表示为

$$\mathbf{O}_{update}(\mathbf{k}) = \mathbf{O}(\mathbf{k}) + \alpha \frac{\mathbf{C}(\mathbf{k})}{|\mathbf{C}(\mathbf{k})|_{\max}^2} [\mathbf{O}_{hr}(\mathbf{k}) - \mathbf{O}_{ln}(\mathbf{k})], \quad (6)$$

$$\mathbf{C}_{update}(\mathbf{k}) = \mathbf{C}(\mathbf{k}) + \beta \frac{\mathbf{O}(\mathbf{k})}{|\mathbf{O}(\mathbf{k})|_{\max}^2} [\mathbf{O}_{hr}(\mathbf{k}) - \mathbf{O}_{ln}(\mathbf{k})], \quad (7)$$

式中, $\mathbf{O}(\mathbf{k})$ 为高分辨率频谱估计, α, β 为步长。

5) 重复步骤 2)~步骤 4), 更新不同照明角度下的子光瞳区域, 将不同的子区域交叠扩展, 以提升物体的分辨率。

6) 重复步骤 2)~步骤 5) 的迭代更新过程, 使 FP 算法逐渐收敛。

3 基于物理模型的 FP 神经网络框架

3.1 FP 神经网络的基本框架

图像处理领域中主流的深度学习算法大多依赖于复杂的模型框架, 通过堆叠多个卷积层或应用其他结构如 Transformer、多层感知机 (MLP) 提高网络的泛化能力, 从而学习输入与输出之间的高级映射关系。但这种算法需要大量的数据进行训练, 且模型的可解释性不强。因此, 提出了一种基于 FP 的神经网络模型, 从 FP 的重构理论出发, 将 ePIE 算法中的各步骤逐级转化为网络的隐藏层, 以模拟整个应用场景, 并基于迭代方式求解图像的逆问题, 具有较强的可解释性。

在基于 ePIE 算法的样本超分辨率流程中引入交

替投影法, 可表示为

$$\boldsymbol{\varphi}'_n(\mathbf{k}) = \mathcal{F} \left\{ \sqrt{I_n(\mathbf{r})} \odot \exp \{ i \cdot \angle \{ \mathcal{F}^{-1} [\boldsymbol{\varphi}_n(\mathbf{k})] \} \} \right\}, \quad (8)$$

式中, $\boldsymbol{\varphi}_n(\mathbf{k}) = \mathbf{O}_{ln}(\mathbf{k})$ 和 $\boldsymbol{\varphi}'_n(\mathbf{k})$ 分别为第 n 个子光瞳区域使用交替投影前后的傅里叶频谱, \angle 为物体复振幅的相位。根据 (8) 式设计的 FP 神经网络模型如图 3 所示, 其中, FPNet 为 ePIE 算法的重建流程, 该模块涉及到损失函数的计算及平移处理、傅里叶变换、傅里叶逆变换、复振幅相位的求解等常规数字图像处理操作, 不涉及参数的更新。迭代神经网络模块 (INN) 为单个图像序列的迭代更新过程, 共迭代 N (采集的低分辨率图像数量) 次。网络的输入为随机初始化的高分辨率图像 $\mathbf{O}^{(0)}$ 和相干传递函数 $\mathbf{C}^{(0)}$ 。为简化计算, 网络模型用全连接神经网络进行预测, 每张低分辨率图像对应的网络层权值可共享, 其权重为预测图像; 整个网络叠加 M 个 INN 模块, 每个 INN 模块均会更新 N 次网络权重, 即网络权重的更新次数为 $N \times M$ 。网络需要预测高分率图像和相干传递函数, 且两个预测分支结构完全一致。

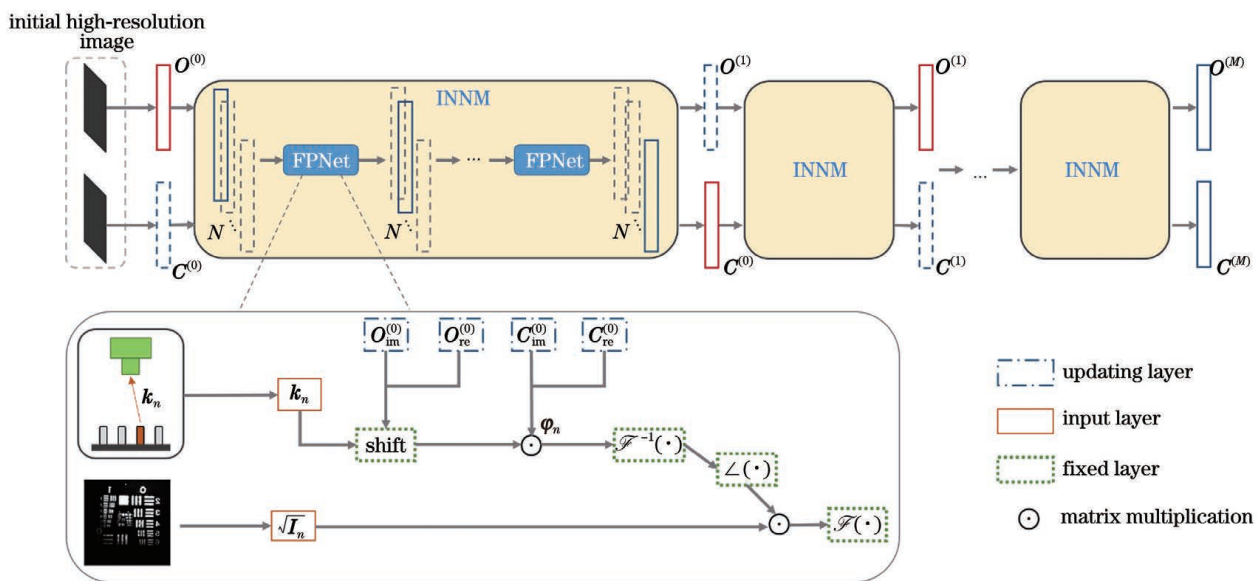


图 3 基于物理模型的 FP 神经网络

Fig. 3 FP neural network based on physical model

以预测 $\mathbf{O}(\mathbf{k})$ 为例,网络将高分辨率图像 $\mathbf{O}(\mathbf{k})$ 建模成网络的隐藏层参数,将低分辨率图像 $\sqrt{\mathbf{I}_n(\mathbf{r})}$ 和入射波矢量 \mathbf{k}_n 依次输入 FPNet 中,通过(4)式和(8)式的前向传播过程生成 $\boldsymbol{\varphi}_n(\mathbf{k})$ 和 $\boldsymbol{\varphi}'_n(\mathbf{k})$ 。两个子光瞳区域傅里叶频谱的差值 $|\boldsymbol{\varphi}'_n(\mathbf{k}) - \boldsymbol{\varphi}_n(\mathbf{k})|$ 作为网络的输出,模型收敛时,该差值趋向于0,此时,

$$\boldsymbol{\varphi}_n(\mathbf{k}) = [\mathbf{O}_{re}(\mathbf{k} - \mathbf{k}_n) + i \times \mathbf{O}_{re}(\mathbf{k} - \mathbf{k}_n)] \odot [\mathbf{C}_{re}(\mathbf{k}) + i \times \mathbf{C}_{im}(\mathbf{k})] = (\mathbf{O}_{re} \odot \mathbf{C}_{re} - \mathbf{O}_{im} \odot \mathbf{C}_{im}) + i \times (\mathbf{O}_{re} \odot \mathbf{C}_{im} + \mathbf{O}_{im} \odot \mathbf{C}_{re}), \quad (10)$$

式中,下标 re 和 im 分别表示实部和虚部。

3.2 光学像差补偿

在光学像差的相位补偿上,常用 Zernike 多项式描述平面波波前畸变^[15]。Zernike 多项式由一系列定义在单位圆内部且彼此正交的无穷级数多项式组成,假设 i 和 j 为非负整数,且 $i \geq j$,则奇、偶两类

网络能重构出样本的高分辨率复振幅分布。网络的损失函数可表示为

$$X_{\text{loss}} = \sum_n \|\boldsymbol{\varphi}'_n(\mathbf{k}) - \boldsymbol{\varphi}_n(\mathbf{k})\|_2^2. \quad (9)$$

值得注意的是,由于 FP 能同时重构样本的幅值和相位,因此网络整体定义在复数域中,(4)式根据复数运算法可表示为

Zernike 多项式可表示为

$$Z_i^j(\rho, \Psi) = R_i^j(\rho) \cos(j\Psi), \quad (11)$$

$$Z_i^{-j}(\rho, \Psi) = R_i^j(\rho) \sin(j\Psi), \quad (12)$$

式中, $0 \leq \rho \leq 1$ 为径向距离, Ψ 为方位角, $R_i^j(\rho)$ 为径向多项式,可表示为

$$R_i^j(\rho) = \begin{cases} \sum_{k=0}^{(i-j)/2} (-1)^k \frac{(-1)^k (i-k)!}{k! \left(\frac{i-j}{2} - k\right)! \left(\frac{i+j}{2} - k\right)!} \cdot \rho^{i-2k}, & i-j \text{ is even} \\ 0, & i-j \text{ is odd number} \end{cases}. \quad (13)$$

每个 Zernike 多项式严格对应波前畸变的某种特定类型,如 Z_0^0 为平均光程差, Z_2^0 为离焦。研究表明,前 10 项 Zernike 多项式可完整表示光学系统中常见的像差种类。传统 FP 算法为了将 Zernike 多项式引入迭代更新的过程中,单独计算每个多项式的梯度,并大幅度调整参数的更新过程。但在神经网络模型中,通过搭建合适的网络表达该过程,自动微分则由网络优化器实现。用引入的 Zernike 多项式替换相干传递函数 $\mathbf{C}(\mathbf{k})$ 的相位部分,从而增强网络对复杂像差的补偿能力,同时将神经网络需要更新的参数量从图像尺寸大小降低为常数量级。由于网络只需更新固定的像差模式组合,针对性更强、更容易收敛。引入 Zernike 多项式后相干传递函数 $\mathbf{C}(\mathbf{k})$ 可表示为

$$\angle \mathbf{C}(\mathbf{k}) = \sum_l c_l Z_l(\mathbf{k}), \quad (14)$$

$$\mathbf{C}(\mathbf{k}) = |\mathbf{C}(\mathbf{k})| \odot \exp[i\angle \mathbf{C}(\mathbf{k})], \quad (15)$$

式中, $Z_l(\mathbf{k})$ 为不同阶数 l 的 Zernike 多项式, c_l 为对应系数, $|\mathbf{C}(\mathbf{k})|$ 为 CTF 的幅值部分, $\exp[i\angle \mathbf{C}(\mathbf{k})]$ 为光学像差部分。

3.3 正则化约束

正则化(Regularization)主要针对损失函数进行优化,通过增加 L1 或 L2 范数项抑制过大的模型参数,是机器学习中提高模型性能的常用方法。根据 FP 应用场景的特点,引入全差分(TV)项对损失函数进行补偿。TV 项是图像去噪领域中常用的图像空域光滑度评价指标^[16],对图像的垂直梯度与水平梯度进行求和,得到图像被噪声干扰的程度。对样本幅值和相位分布引入正则项,可以有效抑制高频信息缺失导致的背景噪声,从而提高成像质量。TV 项 X_{TV} 及改进后的网络损失函数 X_{loss} 可表示为

$$X_{\text{TV}}[\mathbf{o}(\mathbf{r})] = \sum (|\mathbf{o}_{x+1,y} - \mathbf{o}_{x,y}|^2 + |\mathbf{o}_{x,y+1} - \mathbf{o}_{x,y}|^2)^{\eta/2}, \quad (16)$$

$$X_{\text{loss}} = \sum_n \|\boldsymbol{\varphi}'_n(\mathbf{k}) - \boldsymbol{\varphi}_n(\mathbf{k})\|_2^2 + \alpha_1 X_{\text{TV}}[|\boldsymbol{\varphi}'_n(\mathbf{r})|] + \alpha_2 X_{\text{TV}}[\angle \boldsymbol{\varphi}'_n(\mathbf{r})], \quad (17)$$

式中, η 为 TV 项的幂指数,通常设为 1; α_1, α_2 分别

为样本幅值和相位部分的 TV 项权重,权重越大,表

明对应部分重构的图像越光滑。

4 实验设计

4.1 实验装置

为了验证模型性能,分别设计了仿真和远场透射两个实验场景。为了降低大像差扰动情况下相干传递函数与样本复振幅分布之间的相互干扰,模型使用交替更新策略,即在梯度反向传播过程中将像差 $C(k)$ 与样本 $O(k)$ 分离,每次只更新其中一项,使网络更专注当前路径的特征,加快网络的收敛速度。测试训练时,用深度学习服务器进行模型的训练和测试,硬件参数:GPU 为 GeForce GTX Titan X, RAM 为 32 GB, CPU 为 Intel(R) Core(TM) i9-9820X。训练过程中交替更新样本与 CTF 各 5 次,每次包含 20 个 epoch,样本 $O(k)$ 的初始学习率为 0.3,像差 $C(k)$ 的初始学习率为 0.001,权重衰减为 0.9,TV 项的权重均为 10。

4.2 仿真实验

在仿真数据集上进行实验验证,为方便区别本算法与其他对比算法,将本算法中的深度学习 FP 模型命名为 INNМ。在仿真实验中,将 15×15 的可

编程 LED 矩阵放置在光学显微装置最下方作为相干光源,LED 点光源的间距为 4 mm。LED 矩阵与样本平面的距离约为 90 mm,整个系统可视为相干成像系统。将一个 $NA=0.1$ 的 $2 \times$ 物镜正对样本中心,通过长为 200 mm 的镜头在相机像平面处成像。相机采集的图像分辨率为 $3.45 \mu\text{m}$,FP 相邻子孔径的重叠率为 78%,对采集的 225 张图像进行合成处理,合成孔径 $NA_{\text{sync}}=0.50$,可将系统的分辨率提升 5 倍。训练过程中选取两张尺寸为 128×128 的标准图像作为原始图像的幅值和相位,并生成 225 张尺寸为 32×32 的仿真图像。此外,仿真实验中假定样本采集时存在离焦像差,且离焦距离 $z_0=50 \mu\text{m}$,使仿真实验更符合真实场景。仿真实验的结果如图 4 所示,可以发现,用交替更新训练策略和全差分损失(tv_loss)后的 INNМ 网络能重建出准确的样本幅值和相位分布,同时能很好地拟合光学像,使模型达到收敛。相比传统的 ePIE、正则化 PIE(rPIE)和半隐式松弛 Douglas-Rachford (sDR)算法^[17],本算法重建的图像幅值质量与 ePIE 和 rPIE 算法相当,但在消除背景伪影方面的效果更好。

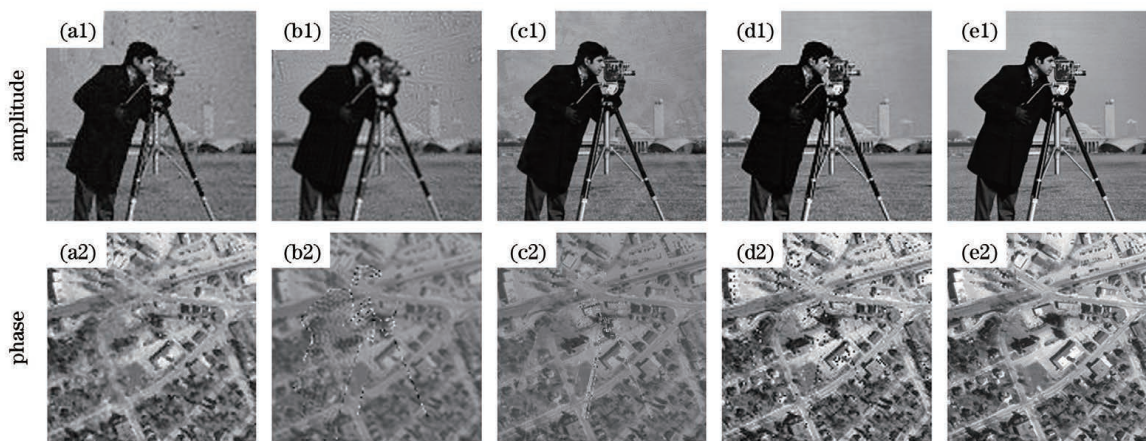


图 4 不同算法的仿真结果。(a)INNМ;(b)ePIE;(c)原始高分辨率图像;(d)sDR;(e)真实图像

Fig. 4 Simulation results of different algorithms. (a) INNМ; (b) ePIE; (c) original high-resolution image; (d) sDR; (e) real image

FP 的孔径交叠率会影响成像效率和成像速度,不同孔径交叠率下,傅里叶域子孔径的交叠情况如图 5 所示。可以发现,当孔径交叠率为 25%时,FP 的重构图像质量较低;随着孔径交叠率的增加,FP 重构图像的质量也得到了一定提升。文献[18]的研究结果表明,孔径交叠率不低于 35%时才能保证算法收敛。在实际采集过程中,为了兼顾图像质量,FP 的孔径交叠率通常设置在 60%~75%之间。

为了对比 Zernike 模块和正则项损失对 INNМ

模型性能的影响,进行了消融实验,结果如图 6 所示。对比图 6(a)和图 6(b)发现,引入 Zernike 多项式可以更好地拟合像差,减少重构像差中出现的周期性噪点;同时,在复振幅分布上引入 Zernike 多项式比未引入时的空间噪声更少。TV 正则项的存在使重构图像的梯度变化更平滑,能够有效抑制背景噪声。对比图 6(b)和图 6(c)发现,随着 TV 项的引入,样本复振幅分布比未引入 TV 项时更真实,背景伪影已基本被消除,成像质量有明显提升。




图 5 不同孔径交叠率的仿真结果。(a)真实图像;(b)25%;(c)50%;(d)70%;(e)85%

Fig. 5 Simulation results of different aperture overlap ratios. (a) Real image; (b) 25%; (c) 50%; (d) 70%; (e) 85%




图 6 消融实验的重建结果。(a)没有引入 Zernike 多项式和 TV 项;(b)单独引入 Zernike 多项式;(c)同时引入 Zernike 多形式和 TV 项;(d)原始高分辨率图像

Fig. 6 Reconstruction results of ablation experiments. (a) Zernike polynomial and TV term are not introduced; (b) Zernike polynomial is introduced separately; (c) Zernike polynomial and TV term are introduced at the same time; (d) original high-resolution image

4.3 远场透射实验

远场透射 FP 系统如图 7 所示,其中,宏观成像中光源与相机位于样本两侧,入射光经物体表面透射后由相机镜头成像。相机镜头包含内置孔径,用

于限制入射光的范围。FP 的图像采集过程中,保持样本与光源的相对位置不变,将相机平移至不同空间位置采集远场物体图像。为保证傅里叶域的支撑域约束,需要设计光路使相机镜头孔径位于透射光路中的傅里叶面。此时,镜头孔径在空间域上的扫




图 7 宏观 FP 的光路

Fig. 7 Optical path of the macro FP

描等效于在物体傅里叶面中进行扫描,从而采集物体不同位置的频谱信息,以用于 FP 高分辨率成像。

实际采集装置如图 8 所示,用激光光源 (THORLABS S4FC520) 产生稳定的单模光源,经光纤加持器固定在工作台上。调整衰减片 (ND filter) 和凸透镜位置,使凸透镜将会聚的入射激光

照射到远场样本物体上,然后由相机 (Nikon, AF NIKKOR 50 mm $f/1.8D$) 在传感器 (DMK 33UX183, 像元尺寸为 $2.4 \mu\text{m}$) 平面聚焦成像。通过二维平移台 (型号 GCD-202050M, 行程为 50 mm, 重复定位精度小于 $50 \mu\text{m}$) 将相机平移至不同位置,并采集物体的强度图像。

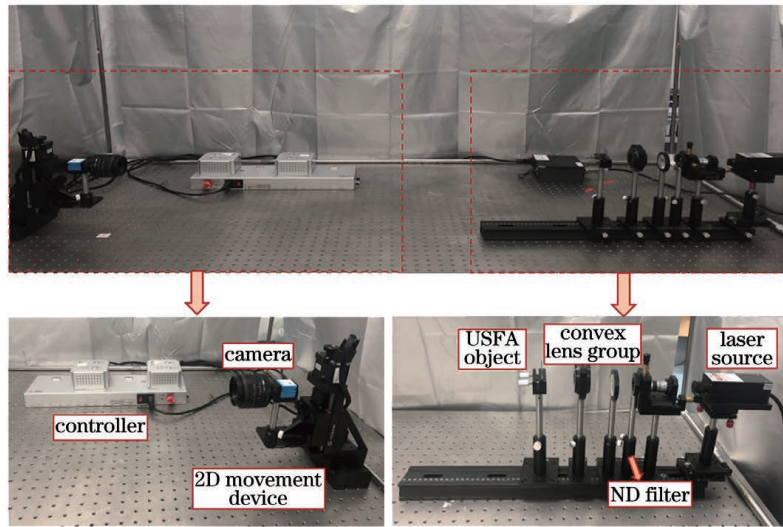


图 8 宏观 FP 的实验装置

Fig. 8 Experimental setup of the macro FP

在实际装置中,入射光源的波长 λ 为 520 nm,凸透镜的焦距 f_1 为 150 mm,透镜到远场物体的距离 z_1 约为 0.055 m,远场物体到成像平面的距离 z_2 约为 1 m。为使物体焦平面位于孔径平面上,实际操作中需要微调光源与透镜的距离,保证在孔径平面看到夫琅禾费衍射图案。相机镜头的焦距 f_2 为 50 mm,光圈数 F 为 16,对应相机孔径的直径 $d_{\text{apt}} = 3.125 \text{ mm}$,FP 的合成孔径 $d_{\text{sync}} = 11.53 \text{ mm}$,相当于将孔径尺寸扩大了 3.7 倍;裁剪后的图像尺寸为 460×460 ;平移台每次的平移步长为 0.6 mm,共采集 225 张低分辨率强度图像。

实验对象为 USAF 分辨率测试卡,通常包含 3 层,共 6 组图案。较大的 1 组图案构成第 1 层,位

于外围。较小层的图案形状不变,从外围向中心逐步缩小。每组包含 6 个图元,以数字 1 至 6 编号,用 (a, b) 来表示,其中, a 为组别, b 为图元编号。组别及组别中的图元编号数值越大,表示分辨率越高。每次采集时用包围曝光的方式采集不同曝光时间下的物体图像,并用高动态范围 (HDR) 方法对图像进行处理,保证采集图像具有较高的对比度。由于采用孔径平移方式采集图像,相机与光源的位置会时刻发生变化,不同子孔径对应的物体信息位于相机视场的不同区域,因此需对采集图像进行配准对齐。平移台每次平移的脉冲距离确定,仅存在 x 或 y 方向上的平移,不存在旋转或缩放,因此,采用图像互相关^[19]的方式对图像进行对齐与

裁剪。

图 9 为原始图像以及 ePIE 算法、INNMM 算法宏观透射场景下对 USAF 分辨率测试卡的重建效果。为分析不同算法的图像重建质量,设置镜头的光圈数 $F=4$,镜头孔径直径 $d_{ref}=12.5\text{ mm}$,将该参数下采集的图像作为参考图像。可以发现,原始图像中线条与背景噪声混杂在一起,仅能区分分辨率小于(1,4)、(2,1)的数据。ePIE 算法和 INNMM

算法均对重构图像的分辨率有一定程度的提升,但由于远场透射存在衍射,ePIE 算法重构的图像中含有大量伪影,能勉强分辨出数据(2,1);INNMM 算法恢复出来的图像可以清晰分辨出数据(2,1),但难以区分分辨率大于(2,3)的数据。虽然 INNMM 重建算法对原始采集图像的分辨率有一定提升,但在远场透射场景下 INNMM 算法的重建图像对比度还有一定的提升空间。




图 9 USAF 分辨率靶标的重建结果。(a)低分辨率图像;(b)USAF 的放大细节 1;(c) ePIE;(d) INNMM;(e)USAF 的放大细节 2;(f)参考图像

Fig. 9 Reconstruction result of USAF resolution target. (a) Low-resolution image; (b) enlarged detail 1 of the USAF; (c) ePIE; (d) INNMM; (e) enlarged detail 2 of the USAF; (f) reference image

5 结 论

针对计算成像方法数据特异性强、数据量少等特点,设计并搭建了基于 FP 正向成像模型的增强型物理模型类神经网络框架,从而在有限的 FP 采集数据中进行图像的高性能重建。将待恢复的物体、光学像差建模成网络内置参数,利用梯度反向传播进行自主更新,从而实现图像的超分辨。为提升网络的性能,在模型中嵌入 Zernike 多项式、TV 等多种增强模块,从不同角度为网络添加约束,减弱了光学像差与背景伪影对重建图像质量的影响。为验证算法的性能,设计了仿真实验并搭建了宏观透射物体远场成像实验装置。结果表明,本算法能有效提升镜头孔径,改善成像分辨率,同时提高对复杂光学像差与相干噪声的鲁棒性。但目前在实际应用中,基于 FP 孔径扫描的图像采集效率较低,因此,提高图像采集效率或使用更少的图像完成重建还需进行深入研究。

参 考 文 献

- [1] Rodenburg J M, Faulkner H M L. A phase retrieval algorithm for shifting illumination [J]. Applied Physics Letters, 2004, 85(20): 4795-4797.
- [2] Yao Y D, Liu C, Pan X C, et al. Research status and development trend of PIE imaging method [J]. Chinese Journal of Lasers, 2016, 43(6): 0609001. 姚玉东, 刘诚, 潘兴臣, 等. PIE 成像方法技术现状及发展趋势 [J]. 中国激光, 2016, 43(6): 0609001.
- [3] Zheng G A, Horstmeyer R, Yang C. Wide-field, high-resolution Fourier ptychographic microscopy [J]. Nature Photonics, 2013, 7(9): 739-745.
- [4] Horstmeyer R, Yang C. A phase space model of Fourier ptychographic microscopy [J]. Optics Express, 2014, 22(1): 338-358.
- [5] Ou X, Horstmeyer R, Yang C, et al. Quantitative phase imaging via Fourier ptychographic microscopy [J]. Optics Letters, 2013, 38(22): 4845-4848.
- [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] 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
- 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
- [8] 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.
- [9] Chen Y C, Wu X, Luo Z, et al. Fourier ptychographic microscopy reconstruction based on deep learning[J]. Laser & Optoelectronics Progress, 2020, 57(22): 221106.
- 陈奕灿, 吴霞, 罗志, 等. 基于深度学习的傅里叶叠层显微成像[J]. 激光与光电子学进展, 2020, 57(22): 221106.
- [10] 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.
- [11] Nguyen T, Xue Y J, Li Y Z, et al. Deep learning approach for Fourier ptychography microscopy [J]. Optics Express, 2018, 26(20): 26470-26484.
- [12] Yang X M. Research on Fourier ptychographic imaging algorithm based on deep learning [D]. Qinhuangdao: Yanshan University, 2019: 10-13.
- 杨学苗. 基于深度学习的傅里叶叠层成像方法研究 [D]. 秦皇岛: 燕山大学, 2019: 10-13.
- [13] Seifert J, Bouchet D, Loetgering L, et al. Efficient and flexible approach to ptychography using an optimization framework based on automatic differentiation [J]. OSA Continuum, 2021, 4(1): 121-128.
- [14] 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.
- [15] Thibos L N, Applegate R A, Schwiegerling J T, et al. Standards for reporting the optical aberrations of eyes [J]. Journal of Refractive Surgery, 2002, 18(5): 652-660.
- [16] Kappeler A, Yoo S, Dai Q Q, et al. Video super-resolution with convolutional neural networks [J]. IEEE Transactions on Computational Imaging, 2016, 2(2): 109-122.
- [17] Pham M, Rana A, Miao J W, et al. Semi-implicit relaxed Douglas-Rachford algorithm (sDR) for ptychography [J]. Optics Express, 2019, 27(22): 31246-31260.
- [18] Dong S Y, Bian Z C, Shiradkar R, et al. Sparsely sampled Fourier ptychography [J]. Optics Express, 2014, 22(5): 5455-5464.
- [19] Guizar-Sicairos M, Thurman S T, Fienup J R. Efficient subpixel image registration algorithms [J]. Optics Letters, 2008, 33(2): 156-158.