

DOI: 10.19650/j.cnki.cjsi.J2413294

基于望远系统的光学-神经网络联合 优化超分辨成像方法*

孙友红¹, 张涛², 刘嘉楠¹, 刘建华¹, 王超¹

(1. 长春理工大学空间光电技术研究所 长春 130022; 2. 中国空间技术研究院(CAST)遥感卫星总体部 北京 100094)

摘要:光学望远镜是获取远距离物体光学信息的重要工具,在天文观测、遥感和光学监视领域具有广泛的应用。分辨率是衡量望远镜观测物体细节能力的重要指标,传统提高望远镜分辨率的方法是建造更大口径的望远镜,这导致建造和维护成本大幅增加。本文提出一种光学-神经网络联合优化方法,通过将望远系统的点扩散函数等效为一个单核卷积层,集成到图像超分辨重建网络前端进行联合训练,并在光路引入相位掩模重构训练得到的点扩散函数,从而实现两者协同优化,有效提高了观测图像的分辨率。本文还构建一种高性能的生成对抗网络,其训练参数小于现有几种无监督网络,重建速度远高于现有几种无监督网络。此网络采用双鉴别器架构提高了网络提取细节特征的能力,设计的级联残差块充分利用了各级提取的特征信息,扩展了信息的传播路径,提高了重建效率。仿真结果表明,本文与单纯的深度学习方法相比,联合优化方法重建的超分辨率图像PSNR和SSIM在仿真数据集中分别提高了3.98和0.06,图像细节丰富,容易分辨。验证实验表明,本文的联合优化方法重建的条纹图像对比度最高,更容易分辨。

关键词:超分辨成像;联合优化;望远系统;无监督网络

中图分类号: O439 TH743 文献标识码: A 国家标准学科分类代码: 410.7070

A joint optimization super-resolution imaging method of optical-neural network based on a telescopic system

Sun Youhong¹, Zhang Tao², Liu Jianan¹, Liu Jianhua¹, Wang Chao¹

(1. Changchun University of Science and Technology Institute of Space Optoelectronics Technology, Changchun, 130022, China;

2. The Institute of Remote Sensing Satellites, China Academy of Space Technology(CAST), Beijing, 100094, China)

Abstract: Optical telescope is an important tool to obtain optical information of distant objects, and has wide application in astronomical observation, remote sensing, and optical surveillance. Resolution is an important indicator of a telescope's ability to observe objects in detail, and the traditional way to improve the resolution of a telescope is to build a larger aperture telescope, which leads to a significant increase in construction and maintenance costs. In this paper, an optic-neural network joint optimization method is proposed. The point diffusion function of the telescopic system is equivalent to a single-core convolution layer, which is integrated into the front end of the image super-resolution reconstruction network for joint training, and the point diffusion function obtained by phase mask reconstruction training is introduced into the optical path, so as to achieve collaborative optimization of the two, and effectively improve the resolution of the observed image. In this paper, a high-performance generative adversarial network is constructed, whose training parameters are smaller than the existing unsupervised networks, and the reconstruction speed is much faster than the existing unsupervised networks. This network adopts double discriminator architecture to improve the ability to extract detailed features. The designed cascade residuals make full use of the extracted feature information at all levels, expand the information propagation path, and improve the reconstruction efficiency. The simulation results show that compared with the simple deep learning method, the PSNR and SSIM of the super-resolution image reconstructed by the joint optimization method in this paper are increased by 3.98 and 0.06 respectively in the simulation data set, and the image details are rich and easy to distinguish. Verification experiments show that the fringe image reconstructed by the joint optimization method in this paper has the highest contrast and is easier to distinguish.

Keywords: super-resolution imaging; joint optimization; telescopic system; unsupervised network

收稿日期: 2024-09-19 Received Date: 2024-09-19

* 基金项目: 国家自然科学基金(62375027, 62127813)、重庆市自然科学基金(CSTB2023NSCQ-MSX0504)、吉林省自然科学基金(YDJ202201ZYTS411, 222621JC010498735)、吉林省教育厅资助(JJKH20240920KJ)项目资助

0 引 言

光学望远镜作为一种获取远距离目标光学信息的重要工具,广泛应用于天文观测、遥感和光学监视^[1-3]。空间分辨率是反映了其区分两个临近物体的能力,是衡量其观察物体细节能力的一个重要指标。更高的分辨率通常意味着更丰富的物体细节。提高望远系统分辨率的传统方法是建造更大口径的望远镜^[4-5],如詹姆斯·韦伯太空望远镜(James Webb space telescope, JWST)^[6]和 30 m 望远镜(thirty meter telescope, TMT)^[7]。然而随着光学口径的增大,制造和后续维护的成本也随之成平方关系增长^[8]。为了在提高分辨率的同时尽量缩小望远系统的体积重量成本,已经提出了一些创新的方法,如傅里叶变换望远镜^[9]、合成孔径望远镜^[10]。合成孔径望远镜通过组合多个单独的光学系统构成一个相控阵列,每个子孔径测量和存储各自的振幅信息,最后在远场进行相干叠加,实现高分辨成像^[11-12]。合成孔径的分辨率超过任何单个元件的分辨率。相比于单一的大型主望远镜,它的制造、测试和对准难度大大降低,但是由于元件总数大于单个望远镜,故障的可能性更大。此外,孔径合成具有很多技术难点,比如每个子孔径望远镜必须产生相同放大率的图像,实现和保持多个子孔径系统的光路匹配等^[13-14]。傅里叶望远镜将合成孔径技术与主动照明相结合,利用几种特定频率的激光同时对物体进行照射,通过解调反射光波的频谱信息重建物体的高分辨图像^[9]。这种技术从理论上解决了分辨率受光学口径限制的问题,大大提高了望远镜的分辨率。但是发射激光的光强波动和非同步、观测物体之外的反射信号干扰等问题容易造成成像模糊^[15]。此外,物体距离望远镜越远,对发射激光的功率要求越高以及单次成像时间较长等问题,限制了傅里叶望远镜的应用。超分辨率(super resolution, SR)技术可以通过一个或多个低分辨率(low resolution, LR)观测图像重建高分辨率(High resolution, HR)图像^[16-23],在不增大望远系统口径的情况下提高图像的分辨率。

近年来,随着深度学习的蓬勃发展,大量的神经网络不断涌现。通过组合不同的卷积层、线性层和激活函数等,深度神经网络可以学习最复杂的函数特征,从而解决许多领域中无法解决的问题^[24-27]。它已被广泛应用于天文望远系统,如天文图像去噪声和超分辨率^[27]。2022 年 Hemmati 等^[28]利用改进的生成对抗网络模型将斯巴鲁望远镜地面观测图像的分辨率提升到哈勃太空望远镜的分辨率。大多数基于卷积神经网络的方法需要配对数据进行监督训练,考虑到天文观测中制作配对数据的成本通

常较高,而算法合成的图像中存在一些不真实的细节,影响了模型的泛化能力。相比之下,无监督网络打破了监督学习网络依赖 LR-HR 配对数据来提高图像分辨率的限制^[29-30],它可以从具有相似天体环境的高分辨星图中学习分布信息,将其作为一种先验信息来提高遥远星系的观测图像的分辨率。

从光学成像的整体过程来看,光学系统的成像过程本质上等同于光学计算^[31-33]。联合优化方法是指通过将“光学系统”和“数字图像后处理”两者协同优化,实现光学系统与图像处理算法的最优匹配,从而获得更好的成像效果^[34-35]。2019 年 Peng 等^[35-36]提出了一种从光学系统到图像处理的端到端设计方法,实现了光学系统的消色差景深拓展和超分辨率成像。2021 年 Liu 等^[37]提出一种结合光学设计与深度学习的端到端成像方法,仅通过一个非球面透镜即可实现小光圈数下的大景深成像。同年, Tseng 等^[38]提出一种端到端相机设计方案,通过构建可学习的复合光学正向模型联合优化光学系统与神经网络,在汽车目标检测领域实现优于最先进的自动驾驶汽车相机设计的效果。2023 年 Zhang 等^[39]设计一种集成显微镜,采用渐进式优化方案系统地优化非球面透镜和编码相位板,大大减少了显微镜尺寸,在宽视场上实现 3 μm 的光学分辨率。与本文相近的研究中, Sun 等^[40]使用端到端框架,同时优化单透镜成像系统和重建网络,从原始测量数据中重建超分辨率图像。渐进式优化方案先利用传统光学设计的优点缩小整体设计空间,再通过图像后处理器优化整个系统,增加了优化的步骤和实施难度,且优化过程中无法同时更新光学系统和神经网络的参数,难以实现两者的最佳匹配。端到端联合优化方法将光学系统和图像后处理器的参数整合到可学习的复合光学模型中,利用损失或误差函数迭代优化整个框架,改善了成像效果。然而现有联合优化通常采用监督学习网络,考虑到天文观测等难以制作配对数据的场景,本文将无监督网络应用于端到端联合优化方法,拓宽该框架的应用范围。

在这项工作中,为了提高望远系统观测图像的分辨率,提出一种光学-神经网络联合优化方法。首先将与望远系统点扩散函数(point spread function, PSF)等效的深度卷积层集成于神经网络的前端,通过深度学习训练过程协同优化 PSF 与网络参数。训练完成后设计一种相位掩模在光路中重建网络训练的 PSF。考虑到相位掩模重构的实际 PSF 与网络训练的 PSF 之间的误差,需要在望远系统中加入相位掩模并采集其观测图像,重新训练网络来对网络参数进行微调。最后采用图像质量评价指标来评估重建图像的质量。通过设计高性能的无监督网络以及协同优化网络参数和望远系统 PSF,可以快速重建出 HR 星图。

1 光学-神经网络联合优化方法

1.1 望远系统非相干成像模型与协同优化

首先介绍望远系统的非相干成像模型与深度学习的卷积层之间的关系。望远系统的照明光源通常为非相干光,属于一种被动式成像^[41-42]。望远系统对一个物体进行非相干成像时,线性空间不变成像模型可以表示为^[43]。

$$I_{im}(u, v) = |h(u, v)|^2 * I_g(u, v) \quad (1)$$

其中, u 和 v 是图像平面的空间坐标, $I_g(u, v)$ 是理

想的几何辐照图像, $|h(u, v)|^2$ 通常被称为 PSF, $*$ 表示二维卷积。望远系统的成像过程可以建模为物体与系统的 PSF 的空间不变卷积。

根据现有理论,单色照明的非相干成像模型可以建模为深度学习的卷积层^[44],本文讨论的单色照明的望远系统成像模型可以建模为一种卷积层:翻转 PSF 作为卷积层的卷积核,输入和输出特征通道数都是 1,输入和输出特征图分别对应于物体和像面图像。因此,本文使用一个单核卷积层来模拟光学系统的 PSF,将此卷积层集成于神经网络的前端,如图 1 所示。




图1 联合优化方法的框架

Fig. 1 The framework of the joint optimization method

为提升望远系统对遥远天体的观测能力,将具有相似天体环境的高分辨率星体图像作为原始的 HR 图像(图 1)。将此 HR 图像输入联合优化网络进行训练,即将高分辨图像与该等效卷积层进行卷积合成 LR 图像,这相当于望远系统的非相干成像过程;再将合成的 LR 图像输入到深度学习网络中,重建出超分辨图像。计算网络输出的超分辨图像与高分辨图像之间的损失函数,并通过梯度反馈同时更新网络和等效卷积层(光学系统的 PSF)的参数。重复训练过程,直到实现光学系统编码与神经网络解码的最优匹配。训练完成后将等效卷积层的权重参数导出作为光学系统的 PSF。

接下来,需要在光路中物理的实现网络训练的 PSF,实现物理意义上的光学-深度学习联合优化。本文利用一种相位掩模来调制光场中的二维相位分布,从而在像面获得理想的 PSF。

1.2 相位掩模求解

采用双胶合望远物镜(double glued telescopic objective, DGTO)代替实际的望远系统,简化推导过程。如图 1 左下角所示,在 DGTO 的后表面放置一个相位掩

模,其通光孔径与 DGTO 相同,探测器被放置在 DGTO 的焦平面上。以最后一片透镜后表面中心为原点,水平方向为 x 轴,竖直方向为 y 轴,垂直透镜表面沿光轴传播方向为 z 轴,建立三维坐标系,因此 (x_1, y_1) 为望远系统后表面上的位置坐标。考虑到相位掩模紧贴望远系统的后表面,且一般厚度较小, (x_1, y_1) 也表示相位掩模表面的位置坐标。同理,以探测器像面中心为原点建立三维坐标系, (x, y) 表示像面的位置坐标。

假设物体表面的点光源发出的光传播到望远系统,在最后一个透镜后表面形成的光场的初始振幅为 $u_1(x, y)$,初始相位为 $\psi(x_1, y_1)$ 。假设相位掩模的调制相位为 $\phi(x_1, y_1) + \frac{-k}{2z_1}(x_1^2 + y_1^2)$, z_1 表示望远系统的后表面与像面之间的距离。根据标量衍射理论^[43,45],像面上的光场为:

$$U(x, y) = \frac{\exp(ikz_1)}{i\lambda z_1} \iint_{\Sigma} u_1(x_1, y_1) \exp[i\psi(x_1, y_1)] \exp[i\phi(x_1, y_1)] \exp\left[\frac{-ik}{2z_1}(x_1^2 + y_1^2)\right]$$

$$\exp\left[\frac{-ik}{2z_1}((x-x_1)^2+(y-y_1)^2)\right]dx_1dy_1 \quad (2)$$

其中, $k=2\pi/\lambda$ 为波数, 可简化为:

$$U(x,y) = \frac{\exp(ikz_1)}{i\lambda z_1} \exp\left[\frac{-ik}{2z_1}(x^2+y^2)\right] \iint_{\Sigma} u_1(x_1, y_1) \exp[i\psi(x_1, y_1)] \exp[i\phi(x_1, y_1)] \exp\left[\frac{-ik}{2z_1}(xx_1+yy_1)\right] dx_1 dy_1 \quad (3)$$

求解光强时, 指数函数可自动消去; 只考虑相对分布时, 常数项可以忽略。以上方程可看成一个傅里叶变换, 系统的 PSF 可以表示为:

$$PSF = |U(x,y)|^2 \propto |F\{u_1(x_1, y_1) \exp[i\psi(x_1, y_1)] \exp[i\phi(x_1, y_1)]\}|^2 \quad (4)$$

根据式(4), 将望远系统的 PSF 设置为网络训练的 PSF。在光学设计软件的非序列模式下搭建望远系统, 然后从点光源处追踪 100 万条网格射线, 在系统的最后一块透镜后表面设置一个探测器, 记录所有光线对应的平面波形成的光场, 从而获得式(2)的初始光场 $u_1(x_1, y_1) \exp[i\psi(x_1, y_1)]$ 。

接下来利用格尔伯格-萨克斯顿 (Gerchberg-Saxton, GS) 相位恢复算法^[46]求解光场的调制相位 $\phi(x_1, y_1)$ 。GS 相位恢复算法是一种通过迭代来恢复目标相位的方法。它具有较强的抗干扰能力, 是相位恢复的重要工具^[46-47]。利用算法迭代求解满足式(4)的调制相位 $\phi(x_1, y_1)$ 。

最后, 根据相位差与衍射光学元件^[43, 48]的厚度之间的关系, 在折射率为 n 的玻璃基底上制作一个关于物理厚度的掩模板, 即相位掩模。如式(5)所示。

$$\phi(x_1, y_1) = (n-1) \frac{2\pi}{\lambda} h(x_1, y_1) \quad (5)$$

其中, λ 是点光源的波长, (x_1, y_1) 表示相位掩模的空间位置坐标。

考虑到实际恢复的 PSF 与网络训练的 PSF 之间的误差, 将制造的相位掩模加入望远系统, 采集天体的观测图像作为低分辨率数据, 重新训练网络以微调重建网络的参数。

2 无监督图像超分辨网络

本文提出的基于深度学习的联合优化方法是利用设计的无监督网络-基于生成对抗网络的轻量级级联残差网络 (lightweight cascaded residual networks based on generative adversarial networks, LCR-GAN) 作为高效重建超分辨率图像的基础。LCR-GAN 具有参数轻量 and 重构速度快的优点, 易于应用在移动低成本设备的实时任务中, 有利于联合优化方法的实际应用。LCR-GAN 的模型

框架如图 2 所示, 它由生成器、鉴别器和损失函数 3 部分组成, 这 3 个部分分别在 2.2 和 2.3 节中阐述。

2.1 网络结构

生成对抗网络通过生成接近真实图像的生成器和区分虚假图像的鉴别器之间的博弈学习来获得真实的图像, 这是最有前途的无监督学习方法之一^[48-49]。本文采用生成对抗网络模型构建无监督网络, 如图 2 所示。为了提高生成器提取细节特征的能力, 本文添加了 1 个细节鉴别器, 使网络能够更多的关注输入图像中的高频分量, 从而使重建的图像纹理更加清晰。为此, 在第 2 个鉴别器之前引入了 1 个巴特沃斯高通滤波器来过滤出输入图像中的高频分量, 然后使用第 2 个鉴别器来区分由生成器产生的虚假细节。




图 2 所提出的 LCR-GAN 的总体结构

Fig. 2 The overall structure of the proposed LCR-GAN

在 LCR-GAN 中, 生成器从输入图像中提取不同层次的特征, 通过上采样层进行融合, 并重建与真实图像相同大小的图像。鉴别器将重建的图像和真实图像作为输入, 其功能是区分生成器生成的虚假图像。两个鉴别器具有相同的结构。

2.2 生成器与鉴别器

基于生成对抗网络的超分辨率网络 (super-resolution using a generative adversarial network, SRGAN) 由于可以在上采样因子较大时重建精细的纹理细节, 在图像超分辨率的方向上得到广泛关注^[50-51]。为此, 本文基于 SRGAN 框架构建了一个新的超分辨率网络, 如图 3 所示, 以实现 HR 图像的高速重建。对 SRGAN 进行如下修改: 首先, 将 SRGAN 网络中的 16 层残差块修改为设计的 7 层级联块。级联块可以充分利用各级提取的特征信息, 优化和扩展信息的传播路径, 从而减少了网络的参数冗余, 提高了模型的重构效率。其次, 激活函数参数化修正线性单元 (parametric rectified linear unit, PRELU) 被激活函数高斯误差线性单元 (Gaussian error linear unit, GELU) 所取代。GELU 具有更平滑的非线性特性, 可以提高模型的性能, 加快模型的收敛速度。

如图 3 所示, 该网络被分为 3 个部分。分别为浅层特征提取模块、深层特征提取模块和图像重建模块。 K 表示网络中级联块的数量, 经过多次实验确定为 7。将低分辨率图像输入网络后, 使用 7 个级联块提取深层特




图3 LCR-GAN的生成器的结构

Fig.3 Generator architecture of the LCR-GAN

征信息。然后,图像重建模块融合所有提取的特征来重建超分辨率的图像。

级联块的结构如图3所示。其中,残差块负责从输入的特征图中提取特征信息,级联算子收集从不同层中提取的特征信息。逐点卷积层融合了从前面各层中提取的特征图,并压缩了特征通道的数量,从而减少了后续残差块的训练参数量。残差块首先从输入大小为 $C \times H \times W$ 的特征图 F_1 上提取特征信息,然后与特征图 F_1 级联得到大小为 $2C \times H \times W$ 的特征图像 F_2 ,经过逐点卷积层压缩特征通道数,重复进行2次残差块提取特征信息、级联算子收集特征图和逐点卷积层压缩特征通道的过程后,最终得到了一个尺寸为 $C \times H \times W$ 的深层特征。为了提取更深层次的特征,本文使用了两个串联的残差单元来形成一个残差块,如图3的右下角所示。

考虑到马尔可夫判别器通过将输入图像切割成小块来训练鉴别器分别进行区分,增强了图像的局部纹理细节^[52]。本文使用马尔可夫判别器作为鉴别器,这两个鉴别器具有相同的架构,网络模型如图4所示。输入依次通过每个卷积层,并最终被映射成一个 $N \times N$ 矩阵,其中每个点代表输入图像中的一个图像块。最后,利用激活函数 sigmoid 来区分不同斑块为真的概率。




图4 PatchGAN的结构

Fig.4 The structure of PatchGAN

2.3 损失函数

为了准确地重建超分辨率的图像,本文使用以下损失函数来训练生成器:

$$Loss_G = L_p + \lambda_1 L_G^1 + \lambda_2 L_G^2 \quad (6)$$

其中, $Loss_G$ 是像素损失 L_p , 第1个鉴别器的生成对抗性损失 L_G^1 和第2个鉴别器的对抗性损失 L_G^2 的加权组

合, λ_1 和 λ_2 分别为两个损失的权重。像素损失 L_p 的表达式为:

$$L_p = \frac{1}{N} \sum_N |I_{SR} - B_{LR}| \quad (7)$$

其中, I_{SR} 表示网络的输出图像, B_{LR} 表示输入的低分辨率图像的双三次插值结果。

第1个鉴别器的生成对抗性损失 L_G^1 的表达式为:

$$L_G^1 = \frac{1}{N} \sum_N |1 - D_1(I_{SR})| \quad (8)$$

其中, I_{SR} 表示网络的输出图像, D_1 表示第1个鉴别器的输出结果。第2个鉴别器的生成对抗性损失 L_G^2 的表达式为:

$$L_G^2 = \frac{1}{N} \sum_N |1 - D_2(W_2(I_{SR}))| \quad (9)$$

其中, D_2 表示第2个鉴别器的输出, W_2 表示巴特沃斯高通滤波器的卷积核的权重。

为了更好地区分生成器的重建图像和真实图像,第1个鉴别器使用以下损失函数进行训练:

$$Loss_{D1} = \frac{1}{N} \sum_N \left| \frac{|D_1(I_{SR})| + |1 - D_1(I_{HR})|}{2} \right| \quad (10)$$

其中, I_{HR} 表示真实图像,其他参数如上所述。

为了更好地区分生成器重建的虚假的细节特征,第2个鉴别器使用以下损失函数进行训练:

$$Loss_{D2} = \frac{1}{N} \sum_N \left| \frac{|D_2(W_2(I_{SR}))| + |1 - D_2(W_2(I_{HR}))|}{2} \right| \quad (11)$$

其中, D_2 表示第2个鉴别器的输出结果, W_2 表示巴特沃斯高通滤波器的卷积核的权重。

3 联合优化方法的仿真

为了验证联合优化方法的性能,本文分别以深度学习和联合优化两种方式对退化图像进行超分辨率重建和图像质量评价。具体来说,本文首先以两种方式制作相应的星图数据集,利用制作的数据集分别对两种最新的无监督图像超分辨率-基于生成对抗网络的直接无监督超分辨率 (direct unsupervised super-resolution using generative adversarial network, DUS-GAN)、(metric learning based interactive modulation for real-world super-resolution, MM-RealSR)、LCR-GAN 和联合优化方法的 LCR-GAN 进行训练,直至网络收敛。之后将测试集中的退化星图输入训练好的网络,分别重建深度学习超分辨图像和联合优化超分辨图像,采用图像质量评价指标峰值信噪比 (peak signal-to-noise ratio, PSNR)、结构相似性 (structure similarity index measure, SSIM) 和学习感知图像块相似度 (learned perceptual image patch similarity, LPIPS) 对重建

效果进行评估。PSNR 和 SSIM 越大,LPIPS 越小,一般意味着重建的图像质量越高。

3.1 制作训练数据

采用实际的天文望远系统进行仿真验证,此系统主要用于对空间点目标进行识别和追踪,光路图如图 5 所示。入瞳直径为 250 mm,焦距为 2 990 mm,波长为 $0.623\text{ }\mu\text{m}$ 。当物体高度设置为 0.1° 时,目标表面为 $5.23\text{ mm}\times 5.23\text{ mm}$,图像大小为 192×192 ,则相邻像素之间的间距约为 $27.24\text{ }\mu\text{m}$ 。在 NASA 网站上选择 300 张清晰易分辨的高分辨星图,网址为:<https://images.nasa.gov/>。这些星图是由不同的天文望远镜捕获的天体图像,保证了数据的真实性。这些数据是公开的,数据集可以作为附件提供。将这些星图转换为灰度图,作为原始高分辨星图。




图 5 天文望远系统的光路图

Fig. 5 Optical path diagram of the astronomical telescopic system

其次,本文介绍制作深度学习和联合优化方法的退化图像或低分辨图像的两种方法。传统深度学习的重建方法需要低分辨星图。为此,本文在光学设计软件中构建了实际天文望远系统的 1:1 成像光路,根据实际成像场景设置相应的参数,利用图像模拟功能得到望远系统的像平面图像。而对于本文的联合优化方法,如 2.2 节所述,利用一个可学习的单核卷积层(卷积内核大小是 23×23 ,步长是 1)作为实际望远系统的 PSF,并与原始高分辨图像卷积生成低分辨图像,匹配望远系统的非相干成像过程。对两种方法获得的图像进行 4 倍降采样作为最终的图像,来匹配可能存在的低采样率探测器。本文鉴于望远系统的物距较大,以及天文恒星在现实中难以再现的事实,权衡数据的保真度和制作成本,本文使用这两种方法来生成本文所需的低分辨图像。

根据以上深度学习的退化数据制作方法,可以很容易地获得 300 对 LR-HR 配对星图。为了收集足够的数据进行训练,采用随机旋转 90° 和翻转进行数据增强,获得的 1 200 对数据,选取 960 对作为训练集,120 对作为验证集,120 对作为测试集。然后,本文从

训练数据集中分别随机裁剪 $48\text{ pixels}\times 48\text{ pixels}$ 和 $192\text{ pixels}\times 192\text{ pixels}$ 的未配对图像块,用于训练超分辨率网络 DUS-GAN、MM-RealSR、LCR-GAN。

根据以上联合优化方法的退化数据制作方法,将原始的高分辨星图随机旋转 90° 和翻转来进行数据增强,获得的 1 200 张图像随机裁剪成 $192\text{ pixels}\times 192\text{ pixels}$ 的图像块,其中 960 张用作训练集的高分辨星图,120 张用作验证集的高分辨星图,120 张用作测试集的高分辨星图。将训练集中的高分辨星图与可学习的单核卷积层进行卷积,然后对得到的图像进行 4 次降采样,生成低分辨率图像,用于联合优化方法的超分辨率网络 LCR-GAN 训练。如 2.2 节所述,训练完成后,将 GS 算法恢复的 PSF 作为实际望远系统的 PSF。将测试集中的高分辨星图与该 PSF 进行卷积,然后通过 4 次降采样生成测试集的低分辨星图。

3.2 仿真结果分析

图 6 为 2.2 节的 GS 算法的实施结果。从图 6(d) 可以看出,算法生成的 PSF 与网络训练的 PSF 之间的平均绝对误差快速收敛,计算出两者最终的均方根误差(root mean square error, RMSE)为 0.018 9,误差平方和(sum of square error, SSE)为 0.009 7,说明 GS 算法求解的调制相位可以较准确地实现网络训练的 PSF。




图 6 GS 相位恢复算法的实施结果

Fig. 6 Results of the GS phase retrieval algorithm implementation

训练完成后,分别从深度学习和联合优化的测试集中各随机抽取 60 组数据,将其中的低分辨图像输入相应的网络重建超分辨星图,采用 3 种定量图像质量评估指标 PSNR、SSIM 和 LPIPS 评价重建性能。

表 1 列出了不同方法的重建图像的平均指标。可以发现,LCR-GAN 的 PSNR 和 SSIM 值优于 MM-RealSR 和插值上采样,与 DUS-GAN 相当,这表明 LCR-GAN 重建的图像失真较少,结构相似性较好,图像质量高。LCR-GAN 的图像重建时间远小于其他两种网络,超快的重建速度有利于实时重建。LCR-GAN 和插值上采样方法在 PSNR、SSIM 和 LPIPS 上表现相当,都显著低于联合优化方法,这表明联合优化方法重建的超分辨率图像相比其他上采样重构方法,更加接近真实图像。

表 1 3 种方法重建的超分辨率图像的平均 PSNR、SSIM 和 LPIPS 对比

Table 1 Comparison of PSNR, SSIM, LPIPS, and total reconstruction times for some up-sampling methods				
方法	PSNR	SSIM	LPIPS	总时间/s
双三次插值	28.17	0.85	0.32	
DUS-GAN	27.86	0.83	0.28	4.11
MM-RealSR	21.76	0.77	0.12	4.63
LCR-GAN	28.35	0.85	0.31	0.32
联合优化	32.33	0.91	0.11	

本文比较了几个主要的无监督网络的训练参数,如表 2 所示(M 表示百万)。LCR-GAN 的参数要小于其他无监督网络。精简的模型不仅提高了图像重建速度,还可以部署于低成本的计算设备,有利于深度学习的实际应用。

表 2 无监督网络参数对比

Table 2 Comparison of unsupervised network parameters					
模型	CinCGAN	USISResNet	DUS-GAN	MM-RealSR	LCR-GAN
参数	>43 M	5.1 M	15.9 M	26.1 M	3.7 M

从图 7 中可以看出,由于系统像差等原因,以及 4 倍降采样导致的细节信息丢失,LR 中相邻的微弱星点难以区分。LCR-GAN 重建图像中相邻的微弱星点易于区分,




图 7 几种方法重建的超分辨率图像对比

Fig. 7 Comparison of super-resolution images reconstructed by various methods

说明 LCR-GAN 具有良好的图像超分辨率效果。相比于 DUS-GAN,LCR-GAN 重建的超分辨率星图谱具有相对清晰的星点和纹理;而相比于 MM-realSR,其微弱星点保存得较好。与 LCR-GAN 相比,联合优化方法重建的星图细节丰富,星云纹理更清晰,相邻的微弱星点可轻易区分。本文解释为联合优化方法重构了望远系统的 PSF,使系统采集尽可能多的信息,从而重建结果更接近原始 HR 图像。

4 验证实验

4.1 验证实验设计

利用深度学习、Sun 方法和本文的联合优化方法对分辨率板进行超分辨率重建实验,来验证本文的联合优化方法的性能。为了模拟望远系统对星体的成像,设计验证实验光路,如图 8 所示。图 8 中“①”代表发光二极管;“②”代表窄带滤光片;“③”代表衰减片;“④”代表分辨率板;“⑤”代表单透镜;“⑥”代表光阑;“⑦”代表分光棱镜;“⑧”代表空间光调制器;“⑨”代表双胶合成像物镜;“⑩”代表 CCD 相机。基于 1.2 节的衍射理论,采用 LED(发光二极管)发射中心波长为 623 nm 的强散射光,然后用窄带滤光片过滤出 623 nm 的单色光。利用衰减片调整光束的强度,光束通过分辨率板的孔隙形成许多散射的点光源,模拟星体发出的散射光。单透镜与分辨率板的距离为一倍焦距 f ,用于将点光源发出的光校正为平行光,来模拟星体与地球近似无限大的距离。分光棱镜将光分成 2 束,其中一束传输到空间光调制器的表面,经过相位调制后反射回分光棱镜。然后分光棱镜将这束反射光偏转到入射光的垂直方向,由双胶合物镜成像于后焦面,被像平面上的低照度相机记录。从波形调制的作用来说,望远系统等价于一块任意调制波面形状的透镜,因此本文采用双胶合物镜这种非理想透镜代替实际望远系统来验证联合优化方法。双胶合物镜的焦距为 200 mm。探测器的像素尺寸为 $3.45\text{ }\mu\text{m}$ 。空间光调制器的长度约为 13 mm,宽度约为 8 mm。




图 8 联合优化方法验证实验光路图

Fig. 8 Optical path diagram of the joint optimization method validation experiment

如图 1 左下角所示,与 1.2 节中的望远系统不同,由于入射到双胶合物镜上的光为平面波,且双胶合透镜的厚度较小,因此将空间光调制器放置于双胶合物镜的前面。由于分辨率板的条纹宽度小于 $30\text{ }\mu\text{m}$,在实验中使用分辨率板代替星图来更清晰的表征联合优化方法的性能。另外,如 3.1 节所述数据制作过程,本文在原始高分辨图像中增加了分辨率板的图像,并对相应的网络进行再训练,以帮助重建分辨率板的超分辨率图像。

为了验证联合优化方法的性能。本文根据第 2 节的方法生成一个相位掩模,根据 Sun 等^[40]的基于理想透镜的联合优化方法求解对应的相位掩模,空间光调制器根据相位掩模的灰度图像调制光场的相位。将不同的相位掩模图像输入到空间光调制器中,在空间光调制器的关闭和打开状态下,探测器分别采集无相位掩模、加入 Sun 方法的相位掩模和本文的联合优化方法的相位掩模的像面图像,作为各自网络的输入,分别重建出深度学习、Sun 方法和本

文的联合优化方法对应的超分辨率图像。

实验结果如图 9 所示,图中条纹的实际宽度为 $13.5\text{ }\mu\text{m}$ 。对比不加相位掩模的相位掩模的实验光路的像面图像图 9(b)和采用 LCR-GAN 重建的超分辨率图像图 9(e)可以看出,LCR-GAN 的超分辨效果不理想。本文归因于在成像过程中丢失了大量的细节,噪声干扰不可忽略。对比采用加联合优化方法的相位掩模的实验光路的像面图像图 9(d)和采用联合优化方法重建的超分辨率图像图 9(g)可以看出,本文的联合优化方法重建的超分辨率图像细节丰富,条纹清晰可辨,大幅度提高了观测图像分辨率。对比采用 Sun 方法重建的超分辨率图像图 9(f)和采用联合优化方法重建的超分辨率图像图 9(g)可以看出, Sun 方法重建的图像的超分辨率效果低于联合优化方法。本文解释为双胶合物镜与理想透镜的调制相位存在差异,用 Sun 方法求解的相位掩模存在误差,导致在像面上采集的图像中丢失了一些高频信息。这些结果验证了仿真结论。




图 9 不同成像方法的超分辨率重建的实验结果

Fig. 9 Experimental results of super-resolution reconstruction using different imaging methods

为了定量展示分辨率提升效果,本文对重建图像中的条纹取切线,位置对应于如图 9(a)中黑线处。以像素位置作为 x 轴,将切线处的灰度值作图,图 10 右上角的图例显示不同重建方法对应的曲线。为了便于比较,本文对实拍图像进行了 4 倍插值上采样,以匹配其他超分辨重建方法的上采样倍率。由于条纹之间的间距相同,本文通过计算图中 7 对清晰的波峰和波谷之间的平均绝对误差来衡量条纹的对比度。插值上采样、LCR-GAN、Sun 方法和联合优化方法的波峰和波谷平均绝对误差分别为 17、17.7、68.7 和 71.4。本文的联合优化方法具有最高的对比度,验证了仿真结果。




图 10 几种重建图像的条纹切片的灰度曲线

Fig. 10 Gray value curves for the fringe slices of various reconstructed images

5 结 论

本文提出一种基于望远系统的光学-神经网络联合优化方法,该方法通过联合优化望远系统的 PSF 与神经网络,实现两者的最优匹配,提高了观测图像的分辨率。本文还构建了一种无监督网络 LCR-GAN,它采用双鉴别器架构提高了网络提取细节特征的能力,设计的级联残差块充分利用各级提取的特征信息,提高了图像重建效率。LCR-GAN 具有参数轻量、重构速度快的优点,有利于应用在移动计算设备的实时任务中。仿真和实验表明,联合优化方法重建的星图细节丰富易于分辨,无需增加复杂的硬件设备便可以提高观测图像的分辨率。然而,本文的联合优化方法是基于单色光源,未来的工作将探讨重建 PSF 的误差补偿,以拓宽联合优化方法的适用带宽。

参考文献

- [1] WANG CH T, TANG D L, WANG Y Q, et al. Super-resolution optical telescopes with local light diffraction shrinkage[J]. Scientific Reports, 2015, 5(1): 18485.
- [2] 郭崇岭,陈佳夷,陈传志,等. 大口径空间光学望远镜桁架结构关键技术研究进展[J]. 南京航空航天大学学报,2024,56(1):31-43.
GUO CH L, CHEN J Y, CHEN CH ZH, et al. Review on critical technologies for truss structure of large-aperture space optical telescope[J]. Journal of Nanjing University of Aeronautics and Astronautics, 2024, 56(1): 31-43.
- [3] 单博闻,辛宏伟,陈长征. 空间太阳望远镜调焦机构的设计与分析[J]. 仪器仪表学报,2021,42(6): 1-8.
SHAN B W, XIN H W, CHEN CH ZH. Design and analysis for focusing mechanism of space solar telescope[J]. Chinese Journal of Scientific Instrument, 2021, 42(6): 1-8.
- [4] XU B, WANG ZH Q, HE J P, et al. Super-resolution imaging via aperture modulation and intensity extrapolation [J]. Scientific Reports, 2018, 8(1): 15216.
- [5] 周健文,姚纳,赵汗青,等. 大气湍流下超振荡望远成像的理论研究[J]. 激光技术,2023,47(1):115-120.
ZHOU J W, YAO N, ZHAO H Q, et al. Theoretical study of super-oscillation telescope imaging with atmospheric turbulence [J]. Laser Technology, 2023, 47(1): 115-120.
- [6] RIEKE G H, WRIGHT G S, BÖKER T, et al. The mid-infrared instrument for the James Webb space telescope, I: Introduction[J]. Publications of the Astronomical Society of the Pacific, 2015, 127(953): 584-594.
- [7] LIU F. Thirty meter telescope (TMT) project status[M]. Ground-based and Airborne Telescopes IX, SPIE, 2022, 12182: 121821B.
- [8] LI ZH, PENG Q Y, BHANU B, et al. Super resolution for astronomical observations[J]. Astrophysics and Space Science, 2018, 363(5):92.
- [9] TEGMARK M, ZALDARRIAGA M. Fast Fourier transform telescope [J]. Physical Review D, 2009, 79(8): 083530.
- [10] HIROSE M, MIYAMURA N. Experimental demonstration of scene-based cophasing in optical synthetic aperture imaging using the SPGD algorithm[J]. Applied Optics, 2024, 63(15): 4157-4164.
- [11] ZHOU CH H, WANG ZH L. Optical design of optical synthetic aperture telescope [C]. SPIE, 2018, 10710: 655-662.
- [12] 张银胜,童俊毅,陈戈,等. 基于多尺度特征增强的合成孔径光学图像复原[J]. 物理学报,2024,73(6): 141-153.
ZHANG Y SH, TONG J Y, CHEN G, et al. Synthetic aperture optical image restoration based on multi-scale feature enhancement [J]. Acta Physica Sinica, 2024, 73(6):141-153.
- [13] FENDER J S. Synthetic apertures: An overview [J]. Synthetic Aperture Systems I, 1984, 440: 2-7.
- [14] 李晟,王博文,管海涛,等. 远场合成孔径计算光学成像技术:文献综述与最新进展[J]. 光电工程,2023, 50(10):4-30.
LI SH, WANG B W, GUAN H T, et al. Far-field computational optical imaging techniques based on synthetic aperture: A review[J]. Opto-Electronic Engineering, 2023, 50(10):4-30.
- [15] 董磊. 提升傅里叶望远镜成像性能的关键技术研究[D]. 中国科学院大学(中国科学院长春光学精密机械与物理研究所), 2019.
DONG L. Research on the key techniques for improving the imaging performance of Fourier telescope [D]. Chinese Academy of Sciences (Changchun Institute of Optics, Fine Mechanics and Physics), 2019.
- [16] PARK S C, PARK M K, KANG M G, et al. Super-resolution image reconstruction: A technical overview[J].

- IEEE Signal Processing Magazine, 2003, 20(3): 21-36.
- [17] 张博伟,何彦霖,王康,等. 基于全方位深层加权轻量化网络的冠脉造影图像超分辨率重建方法[J]. 仪器仪表学报, 2024, 45(7): 200-209.
- ZHANG B W, HE Y L, WANG K, et al. Super resolution reconstruction of coronary angiography images based on the omnidirectional deep weighted lightweight network[J]. Chinese Journal of Scientific Instrument, 2024, 45(7): 200-209.
- [18] 莫恒辉,魏霖静. 基于层次交互动态注意力与序列学习的图像超分辨率重建[J]. 国外电子测量技术, 2024, 43(6): 76-86.
- MO H H, WEI L J. Image super-resolution reconstruction based on hierarchical interactive dynamic attention and sequence learning[J]. Foreign Electronic Measurement Technology, 2024, 43(6): 76-86.
- [19] 刘建军,郝敏钗,李建朝,等. 融合图像局部和退化表征信息的盲超分辨重建[J]. 国外电子测量技术, 2023, 42(1): 112-118.
- LIU J J, HAO M CH, LI J CH, et al. Blind super-resolution reconstruction based on fusion of local information and degradation representation of image[J]. Foreign Electronic Measurement Technology, 2023, 42(1): 112-118.
- [20] 刘兰兰,万旭东,汪志刚,等. 基于超分辨率重建与多尺度特征融合的输电线路缺陷检测方法[J]. 电子测量与仪器学报, 2023, 37(1): 130-139.
- LIU L L, WAN X D, WANG ZH G, et al. Transmission line defect detection method based on super-resolution reconstruction and multi-scale feature fusion[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(1): 130-139.
- [21] 张进,李强,王冠,等. 傅里叶单像素显微超分辨成像系统设计[J]. 电子测量与仪器学报, 2022, 36(1): 174-179.
- ZHANG J, LI Q, WANG G, et al. Design of super resolution system for single pixel imaging results based on Fourier spectrum acquisition[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(1): 174-179.
- [22] 李轩,刘小祎. 通道可分离残差网络的图像超分辨率重建[J]. 电子测量技术, 2023, 46(6): 84-90.
- LI X, LIU X Y. Image super-resolution reconstruction based on channel-separable residual network[J]. Electronic Measurement Technology, 2023, 46(6): 84-90.
- [23] 杨彬,赵倩,赵琰. 融合边缘检测的遥感图像超分辨率重建算法[J]. 电子测量技术, 2023, 46(10): 136-143.
- YANG B, ZHAO Q, ZHAO Y. Super-resolution reconstruction of remote sensing image based on edge detection[J]. Electronic Measurement Technology, 2023, 46(10): 136-143.
- [24] WANG SH, JIANG X N, GUO H J, et al. Improved SNR and super-resolution reconstruction of multi-scale digital holography based on deep learning[J]. Optics Communications, 2023, 545: 129634.
- [25] 张耀,吴一全,陈慧娴. 基于深度学习的视觉同时定位与建图研究进展[J]. 仪器仪表学报, 2023, 44(7): 214-241.
- ZHANG Y, WU Y Q, CHEN H X. Research progress of visual simultaneous localization and mapping based on deep learning[J]. Chinese Journal of Scientific Instrument, 2023, 44(7): 214-241.
- [26] 林星羽,于瀛洁. 计算成像技术在光学检测领域的研究进展[J]. 仪器仪表学报, 2022, 43(10): 1-12.
- LIN X Y, YU Y J. Research progress of computational imaging in the field of optical measurement[J]. Chinese Journal of Scientific Instrument, 2022, 43(10): 1-12.
- [27] SWEERE S F, VALTCHANOV I, LIEU M, et al. Deep learning-based super-resolution and de-noising for XMM-newton images[J]. Monthly Notices of the Royal Astronomical Society, 2022, 517(3): 4054-4069.
- [28] HEMMATI S, HUFF E, NAYYERI H, et al. Deblending galaxies with generative adversarial networks[J]. The Astrophysical Journal, 2022, 941(2): 141.
- [29] CHANG J, WESTZSTEIN G. Deep optics for monocular depth estimation and 3D object detection[C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019:10192-10201.
- [30] 杨旭朝,雷志勇,王娇娇. 改进基于多相机的无监督学习图像拼接算法[J]. 国外电子测量技术, 2023, 42(2): 66-73.
- YANG X ZH, LEI ZH Y, WANG J J. Improved unsupervised learning based on multiple cameras image stitching algorithm[J]. Foreign Electronic Measurement Technology, 2023, 42(2): 66-73.
- [31] 袁睿,赵春竹,郭玉,等. 基于计算成像的机载共形

- 光学系统设计[J]. 激光与光电子学进展, 2020, 57(23): 291-296.
- YUAN R, ZHAO CH ZH, GUO Y, et al. Design of airborne conformal optical system based on computational imaging[J]. Laser & Optoelectronics Progress, 2020, 57(23): 291-296.
- [32] 胡浩, 郜鹏. 一种大视野超分辨结构光照明显微成像方法[J]. 仪器仪表学报, 2023, 44(5): 177-183.
- HU H, GAO P. Large-field super-resolution microscopic imaging based on structured illumination[J]. Chinese Journal of Scientific Instrument, 2023, 44(5): 177-183.
- [33] 顿雄, 张健, 冯诗淇, 等. 光学系统与图像处理端到端协同设计及其应用[J]. 光学精密工程, 2022, 30(21): 2827-2838.
- DUN X, ZHANG J, FENG SH Q, et al. End-to-end co-design of optics and image processing and its applications[J]. Optics and Precision Engineering, 2022, 30(21): 2827-2838.
- [34] 高金铭, 郭劲英, 孙越, 等. 星载反射式成像系统计算光学设计方法综述[J]. 航天返回与遥感, 2023, 44(6): 1-11.
- GAO J M, GUO J Y, SUN Y, et al. Overview of computational optics design for space-borne reflective imaging system[J]. Spacecraft Recovery & Remote Sensing, 2023, 44(6): 1-11.
- [35] PENG Y F, FU Q, AMATA H, et al. Computational imaging using lightweight diffractive-refractive optics[J]. Optics Express, 2015, 23(24): 31393-31407.
- [36] PENG Y F, SUN Q L, DUN X, et al. Learned large field-of-view imaging with thin-plate optics[J]. ACM Transactions on Graphics, 2019, 38(6): 219, 1-14.
- [37] LIU Y K, ZHANG CH Y, KOU T D, et al. End-to-end computational optics with a singlet lens for large depth-of-field imaging[J]. Optics Express, 2021, 29(18): 28530-28548.
- [38] TSENG E, MOSLEH A, MANNAN F, et al. Differentiable compound optics and processing pipeline optimization for end-to-end camera design[J]. ACM Transactions on Graphics (TOG), 2021, 40(2): 1-19.
- [39] ZHANG Y L, SONG X F, XIE J CH, et al. Large depth-of-field ultra-compact microscope by progressive optimization and deep learning[J]. Nature Communications, 2023, 14(1): 4118.
- [40] SUN Q L, ZHANG J, DUN X, et al. End-to-end learned, optically coded super-resolution SPAD camera[J]. Acm Transactions on Graphics (TOG), 2020, 39(2): 9, 1-14.
- [41] YANG M Y, FAN X W, WANG Y M, et al. Experimental study on the exploration of camera scanning reflective Fourier ptychography technology for far-field imaging[J]. Remote Sensing, 2022, 14(9): 2264.
- [42] 单博闻, 辛宏伟, 陈长征. 空间太阳望远镜调焦机构的设计与分析[J]. 仪器仪表学报, 2021, 42(6): 1-8.
- SHAN B W, XIN H W, CHEN CH ZH. Design and analysis for focusing mechanism of space solar telescope[J]. Chinese Journal of Scientific Instrument, 2021, 42(6): 1-8.
- [43] GOODMAN J W. Introduction to Fourier optics, Roberts and company publishers[J]. Englewood, USA, 2005.
- [44] CHANG J, SITZMANN V, DUN X, et al. Hybrid optical-electronic convolutional neural networks with optimized diffractive optics for image classification[J]. Scientific Reports, 2018, 8(1): 12324.
- [45] WANG K K, FU Q, WANG B SH, et al. Simplified analysis and suppression of polarization aberration in planar symmetric optical systems[J]. Optics Express, 2023, 31(19): 30750-30766.
- [46] GERCHBERG R W, O. A S W. A practical algorithm for the determination of phase from image and diffraction plane pictures[J]. Optik, 1972, 35: 237-250.
- [47] 刘宏展, 纪越峰. 一种基于角谱理论的改进型相位恢复迭代算法[J]. 物理学报, 2013, 62(11): 263-269.
- LIU H ZH, JI Y F. An ameliorated fast phase retrieval iterative algorithm based on the angular spectrum theory[J]. Acta Physica Sinica, 2013, 62(11): 263-269.
- [48] WANG CH, XING S Y, XU M, et al. The influence of optical alignment error on compression coding super-resolution imaging[J]. Sensors, 2022, 22(7): 2717.
- [49] 吴培良, 刘瑞军, 李瑶, 等. 一种基于生成对抗网络与模型泛化的机器人推抓技能学习方法[J]. 仪器仪表学报, 2022, 43(5): 244-253.
- WU P L, LIU R J, LI Y, et al. Robot pushing and grasping skill learning method based on generative adversarial network and model generalization[J]. Chinese Journal of Scientific Instrument, 2022, 43(5): 244-253.

[50] LEDIG C, THEIS L, HUSZÁR F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 105-114.

[51] 张博伟,何彦霖,王康,等. 基于全方位深层加权轻量化网络的冠脉造影图像超分辨率重建方法[J]. 仪器仪表学报,2024,45(7):200-209.

ZHANG B W, HE Y L, WANG K, et al. Super resolution reconstruction of coronary angiography images based on the omnidirectional deep weighted lightweight network[J]. Chinese Journal of Scientific Instrument, 2024,45(7):200-209.

[52] ISOLA P, ZHU J Y, ZHOU T H, et al. Image-to-image translation with conditional adversarial networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 5967-5976.

作者简介



孙友红,2018 年于淮阴工学院获得学士学位,2024 年于长春理工大学获得硕士学位,现于南京大学攻读博士学位,主要研究方向为超分辨率成像技术。

E-mail:2496851195@qq.com

Sun Youhong received B.Sc. degree from Huaiyin Institute of Technology in 2018 and M.Sc. degree from Changchun University of Science and Technology in 2024. He is currently pursuing his Ph.D. degree at Nanjing University, with

a main research focus on super-resolution imaging technology.

张涛,2003 年于长春理工大学获得学士学位,2006 年于于长春理工大学获得硕士学位,2018 年于长春理工大学获得博士学位,现为中国空间技术研究院遥感卫星总体部高工,主要研究方向为卫星总体设计技术。

E-mail:1768811682@qq.com.



Zhang Tao obtained his B.Sc. degree in 2003, his M.Sc. degree in 2006, and his Ph.D. degree in 2018, all from Changchun University of Science and Technology. He is currently a senior engineer in the Remote Sensing Satellite Overall Department of the China Academy of Space Technology, and mainly researches satellite overall design technology.



王超(通信作者),2009 年于哈尔滨工程大学获得学士学位,2014 年于中国科学院长春光学精密机械与物理研究所获得博士学位,现为长春理工大学教授,主要研究方向为先进光学系统设计与超分辨率成像技术。

E-mail:nicklo19992009@163.com

Wang Chao (Corresponding author) obtained B.Sc. degree from Harbin Engineering University in 2009. In 2014, she obtained her Ph.D. degree from Changchun Institute of Optics, Fine Mechanicand Physics, Chinese Academy of Sciences. She is currently a professor at Changchun University of Science and Technology, with a main research focus on advanced optical system design and super-resolution imaging technology.