

基于双向多尺度特征融合的湍流退化图像快速复原

郭一鸣^{1,2,3}, 吴晓庆^{1,3*}, 苏昶东^{1,2,3}, 张世泰^{1,2,3}, 毕翠翠^{1,2,3}, 陶志炜^{1,2}¹中国科学院合肥物质科学研究院大气光学重点实验室, 安徽 合肥 230031;²中国科学技术大学, 安徽 合肥 230026;³先进激光技术安徽省实验室, 安徽 合肥 230037

摘要 提出一种基于双向多尺度特征融合的生成对抗网络(GAN),利用该网络对各种地基望远镜拍摄的受大气湍流影响的目标天体图像直接进行盲复原处理。首先通过长曝光大气湍流退化模型与清晰图片进行卷积来构建数据集,并进行网络训练,在模拟湍流图像数据集中测试网络性能。同时,实际获取了Munin地基望远镜(卡塞格林型望远镜)拍摄的受湍流影响的国际空间站图片,并用所提神经网络模型进行测试。各项图像复原评价指标表明:所设计的网络实时性较强,在0.5 s内可以输出复原结果,相比传统非神经网络复原方法要快10倍以上;所提网络的峰值信噪比(PSNR)提高2 dB~3 dB,结构相似性(SSIM)提高9.3%左右,对受真实湍流影响的退化图像也有较好的复原效果。

关键词 双向多尺度特征融合;神经网络;大气湍流退化模型;盲复原

中图分类号 O435.1;TP391.4

文献标志码 A

DOI: 10.3788/LOP202259.2201001

Rapid Restoration of Turbulent Degraded Images Based on Bidirectional Multi-Scale Feature Fusion

Guo Yiming^{1,2,3}, Wu Xiaoqing^{1,3*}, Su Changdong^{1,2,3}, Zhang Shitai^{1,2,3}, Bi Cuicui^{1,2,3}, Tao Zhiwei^{1,2}

¹Key Laboratory of Atmospheric Optics, Hefei Institutes of Physical Science, Chinese Academy of Sciences, Hefei 230031, Anhui, China;

²University of Science and Technology of China, Hefei 230026, Anhui, China;

³Advanced Laser Technology Laboratory of Anhui Province, Hefei 230037, Anhui, China

Abstract This study proposes a generative adversarial network (GAN) based on bidirectional multi-scale feature fusion to reconstruct target celestial images captured by various ground-based telescopes, which are influenced by atmospheric turbulence. This approach first constructs a dataset for network training by convolving a long-exposure atmospheric turbulence degradation model with clear images and then validates the network's performance on a simulated turbulence image dataset. Furthermore, images of the International Space Station collected by the Munin ground-based telescope (Cassegrain-type telescope) that were influenced by atmospheric turbulence are included in this study. These images were sent to the proposed neural network model for testing. Different image restoration assessment shows that the proposed network has a good real-time performance and can produce restoration results within 0.5 s, which is more than 10 times faster than standard nonneural network restoration approaches; the peak signal to noise ratio (PSNR) is improved by 2 dB–3 dB, and structural similarity (SSIM) is enhanced by 9.3%. Simultaneously, the proposed network has a pretty good restoration impact on degraded images that are influenced by real turbulence.

Key words bidirectional multi-scale feature fusion; neural network; atmospheric turbulence degraded model; blind restoration

1 引言

一直以来,通过地基望远镜对目标天体进行观测

是人类太空探索的重要手段。根据瑞利准则^[1],望远镜的口径越大,其衍射极限分辨率越高。但事实上,受地球大气湍流影响,地基望远镜实际成像能力大大降

收稿日期: 2021-09-09; 修回日期: 2021-09-17; 录用日期: 2021-09-27

基金项目: 国家自然科学基金(91752103)

通信作者: *xqwu@aiofm.ac.cn

低。由于地球大气不断加热和冷却,空间目标发出的光线经地球大气时,大气湍流使光线发散。波前被随机扰动干扰不再是平面,而是动态干扰成曲面,这对空间目标的直接影响是成像模糊,对分辨率的影响是口径再大的天文望远镜的分辨率都不会超过口径为 0.1~0.2 m 的望远镜的分辨率。所以要使地基望远镜拥有更好的观测能力,必须消除大气湍流对目标天体的影响。传统解决方法是在地基望远镜中安装自适应光学(AO)系统,但受限于波前传感器对强湍流波前的复原能力,以及充当波前校正器的变形镜是分段线性拟合的,对连续波前进行拟合时存在残差。因此需要借助事后图像处理技术来进一步提高分辨率,在 20 世纪 60 年代中期,逆卷积首先被用于湍流退化图像的复原中。1970 年,Labeyrie^[2]提出一种斑点干涉测量方法,该方法叠加了大量短曝光图像的功率谱,但由于相位谱的损失,对退化图像的复原效果并不好。1978 年,Fienup^[3]改进了 Gerchberg-Saxton 算法,应用傅里叶变换与傅里叶逆变换进行交替迭代运算和相位恢复,该复原算法也被称为迭代傅里叶变换算法。1990 年,Primot 等^[4]提出了一种图像解卷积算法,该复原算法通过波前传感器记录波前信息,之后对得到的波前信息进行去卷积,脱离了对自适应光学系统的依赖。1988 年,Ayers 等^[5]提出了一种基于单帧的迭代盲卷积复原方法,称为 IBD 算法。非迭代类的算法主要有幸运成像算法^[6]和 The Additive System of Photographic Exposure(APEX)复原法^[7]。

然而不管是迭代类还是非迭代类的事后图像复原算法,这些算法虽能取得不错的复原效果,但实时性较差,一般需要数秒至数十秒以上方能完成对空间目标的退化复原,尤其在应对视频流的观测任务时,无法满足实时校正的要求。近年来,随着深度学习相关算法在图像处理领域的成功运用,尤其是深度卷积神经网络在图像特征提取领域取得了显著优势,越来越多的研究者开始将深度学习运用到大气湍流退化图像处理任务中。2019 年,英国布里斯托大学视觉信息研究团队^[8]认为湍流退化图像不仅包含着模糊同时包含着光强闪烁产生的畸变,将神经网络运用到近地面远距离湍流退化图像复原中,取得一定复原效果。2020 年,杨小珊等^[9]利用改进的 YOLOv3 模型进行空间目标检测。西华大学 Chen 等^[10]提出了结合 UNET 的深度自编码器神经网络模型,该模型对大气湍流退化的空间目标进行盲复原处理,但由于对特征图不加以区分只是进行简单估计,所以并不能充分提取不同强度的湍流退化特征。

因此,本文提出一种基于双向多尺度特征融合的生成对抗网络。利用端到端的网络处理机制,将经大气湍流退化和受噪声影响的目标图像作为输入送入网络,通过网络中双向多尺度特征融合机制对退化图像的低层特征与高层特征分别进行有效提取,同时重复

应用自顶向下和自底向上的多尺度特征融合,并且引入了从输入到输出的跳跃连接,以便学习重点关注残差。最终复原出较为清晰的空间目标图像,由于网络使用轻量型的预训练模型作为主干网络,网络推理时间变得极短,一般会在 0.5 s 内输出结果。因此所提网络对空间目标湍流图像复原具有较强的实时性。同时各项图像复原评价指标表明,所提神经网络模型复原的真实空间目标湍流退化图像较为理想,能够有效恢复目标天体图像的边缘和细节,同时也可以对图像退化过程中产生的系统噪声进行一定程度的抑制。

2 湍流退化图像

2.1 湍流退化图像模型

在绝大多数情况下,可以假设点扩散函数 $h(x, y)$ 具有空间线性不变性。因此可将大气湍流退化过程看作是空间线性不变系统,此时大气湍流退化模型^[11]可表示为

$$g(x, y) = h(x, y) * f(x, y) + n(x, y), \quad (1)$$

式中: * 代表卷积; $g(x, y)$ 为经大气湍流退化后的图像; $f(x, y)$ 为初始图像; $n(x, y)$ 代表加性噪声,一般使用高斯噪声来表示。

当光学成像系统的曝光时间达几秒到几十秒时,则将图像记录为一个时间平均像,即为长曝光大气湍流退化图像,其传递函数可表示为

$$H(u, v) = e^{\left[-3.44 \left(\frac{\lambda f \sqrt{v_u^2 + v_v^2}}{r_0} \right)^{\frac{5}{3}} \right]}, \quad (2)$$

式中: $\sqrt{v_u^2 + v_v^2}$ 代表频率; λ 和 f 分别表示望远镜观测系统的波长和焦距; r_0 表示大气相干长度。当 $k = -3.44 \left(\frac{\lambda f}{r_0} \right)^{\frac{5}{6}}$, 可得到长曝光大气湍流退化函数^[10], 表示为

$$H(u, v) = e^{-k(v_u^2 + v_v^2)^{\frac{5}{6}}}. \quad (3)$$

所以,此时的大气湍流退化系统可以视为一个高斯分布, k 表征了大气湍流退化模型中的湍流强度因子。

2.2 数据集构成

由于天基望远镜拍摄到的目标天体不会受到大气湍流影响,可以作为数据标签。而哈勃望远镜作为第一台天基光学望远镜,在轨运行时间长,同时拍摄了大量的空间目标图像。因此本文数据集的原始标签均来自 Hubble 官网,共计 500 张,图片尺寸均为 600×600 像素。图像包含了土星、火星、木星、星团、螺旋星系等,部分示例图片如图 1 所示。

但由于仅仅从 Hubble 官网 (<https://esahubble.org/images/>) 获取的数据量较少,利用 albumations 数据增强库^[12]对标签数据进行随机裁剪、翻转、平移、缩放等变换,共得到 2000 张图片。同时对这些图片分




图1 Hubble官网下载的目标天体图像

Fig. 1 Downloaded target celestial images from Hubble official website

别与 $k=0.001, 0.0025, 0.005$ 时的不同湍流强度因子进行卷积,并对所有图片添加均值为 0、方差为 0.001 的高斯噪声作为加性噪声。最后共计得到 6000 张图

片作为数据集,将其中的 4800 张图片作为训练集,600 张图片作为验证集,600 张图片作为测试集。部分数据集图片示例如图 2 所示。

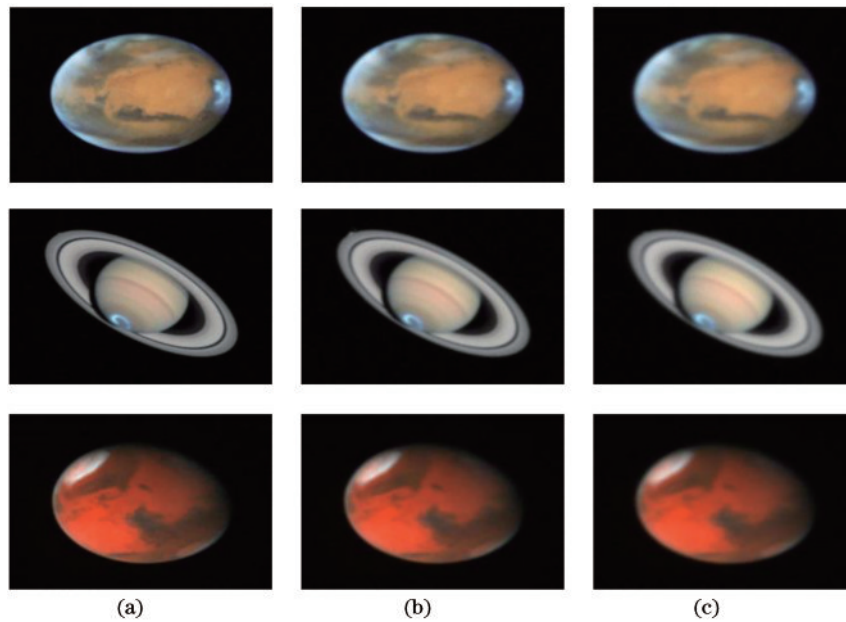


图2 模拟目标天体受不同强度大气湍流的退化图片。(a) $k=0.001$ 时的退化图像;(b) $k=0.0025$ 时的退化图像;(c) $k=0.005$ 时的退化图像

Fig. 2 Degraded images of simulated target celestial bodies subjected to atmospheric turbulence with different intensities. (a) Degraded images when $k=0.001$; (b) degraded images when $k=0.0025$; (c) degraded images when $k=0.005$

3 所提方法内容

3.1 生成对抗网络介绍

所提网络在仅仅知道湍流退化的目标天体图像的情况下,通过生成对抗网络(GAN)中的生成器先训练后估计每个大气湍流退化图像对应的清晰图像。

GAN的结构^[13]如图3所示。

GAN模型中包含一个生成器(G)和一个判别器(D),生成器主要用于捕获数据分布,判别器主要用于估计样本来自真实数据而不是生成器生成数据的概率。 z 为隐变量输入,这里可以认为是输入的退化图像, x 为 z 对应的清晰原图,即为 z 的数据标签。整个

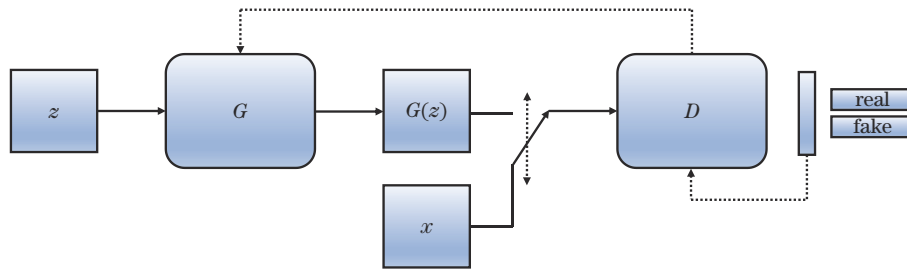


图 3 生成式对抗网络

Fig. 3 Generative adversarial network

网络模型通过反向传播算法进行对抗训练, GAN 的目标函数^[14]定义为

$$\min_G \max_D V(D, G) \equiv \min_G \max_D \left\{ E_{x \sim P_{\text{data}}(x)} [\log D(x)] + E_{z \sim P_{\text{data}}(z)} \log \{1 - D[G(z)]\} \right\} \quad (4)$$

通过式(4)可以看出, 判别器 D 会尽可能地区分真实样本与虚假样本, 所以当 $D(x)$ 越大, $D[G(z)]$ 越小, 则 $V(D, G)$ 越大。从生成器 G 来看, 它希望生成的样本尽可能不被 D 识别, 即 $D[G(z)]$ 越大, 则 $V(D, G)$

越小。判别器 D 与生成器 G 相互对抗, 最后使得整个网络输出达到全局最优, 且 GAN 在训练过程中由于只使用了反向传播, 不需要使用复杂的马尔可夫链, 训练时也不需要对待变量做判断, 可以有效提高训练效率。

3.2 双向多尺度特征融合

在生成器部分, 首次提出了基于双向多尺度特征融合 (Bmff) 的网络用于目标天体湍流图像复原。多尺度特征融合网络最先用于目标检测与图像分割的任务中^[15], 多尺度特征融合的过程如图 4 所示。

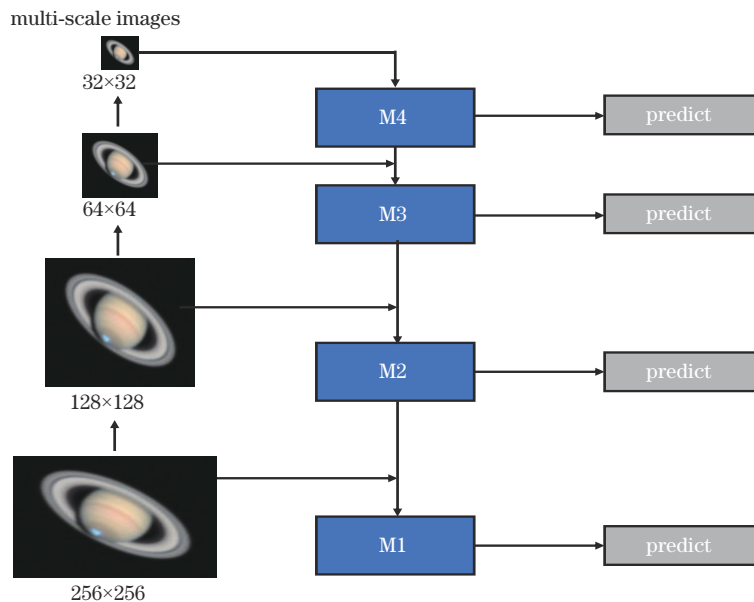


图 4 多尺度特征融合

Fig. 4 Multi-scale feature fusion

多尺度特征融合中, 高层网络的感受野^[16]比较大, 语义信息表征能力强, 但是特征图的分辨率低, 对几何信息的表征能力弱 (空间几何特征细节缺乏); 低层网络的感受野比较小, 几何细节信息表征能力强, 虽然分辨率高, 但是对语义信息的表征能力弱。因此, 为了更好地提取湍流退化图像的模糊特征, 在网络的生成器中引入了一种加权的双向多尺度特征融合, 它通过添加可学习的权值来学习不同输入特征的重要性, 同时重复应用自顶向下和自底向上的特征融合。传统的自上而下的多尺度特征融合会受单向信息流的限制, 相

比之下, 双向多尺度特征融合将每个双向 (自顶向下 & 自底向上) 路径视为一个特征网络层, 并多次重复同一层, 从而实现更高级别的特征融合, 因此对不同强度湍流退化的模糊特征提取得更加充分, 使得空间目标湍流退化图像复原效果更好。同时使用在 ImageNet^[17] 上预先训练好的模型 Inception V2^[18] 作为整个网络的主干网络, 这样可以快速获取整个网络的最终模型, 并且可以加快网络的训练速度。

3.3 所提网络的结构

图 5 为所提网络中的生成器架构, 将经湍流退化

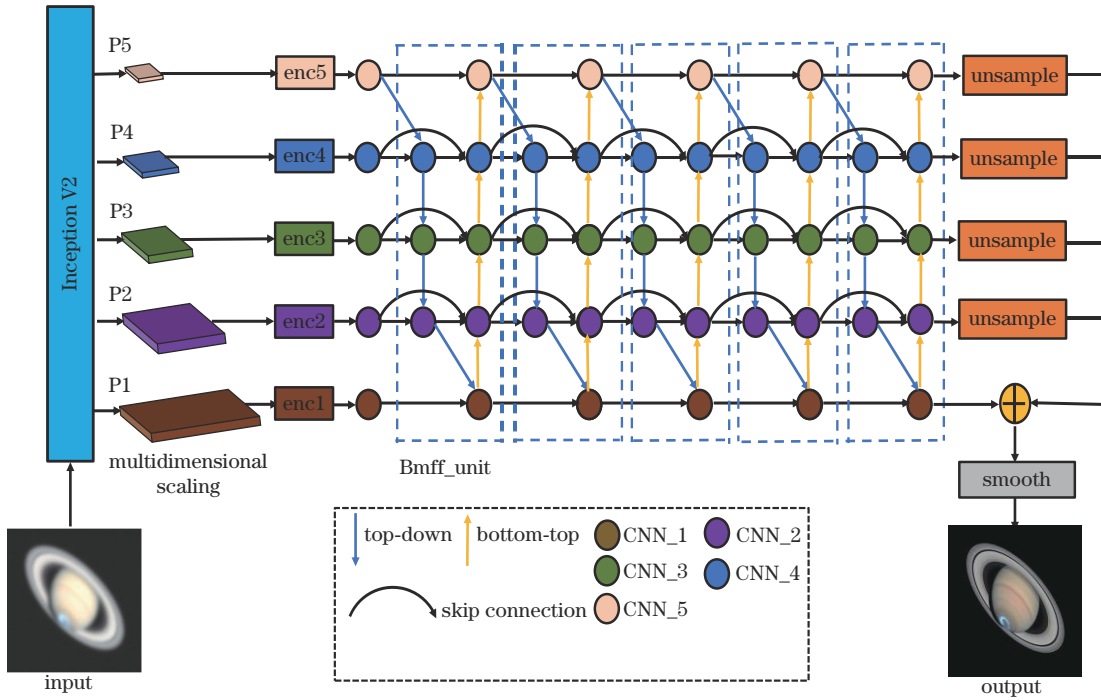


图 5 生成网络架构的拓扑结构

Fig. 5 Topology diagram of generated network architecture

的空间目标图像送入到 Inception V2^[18] 主干网络中, 并经过 5 层多尺度变换, 而后送入到双向多尺度特征融合单元即 Bmff_unit。这里提出的双向多尺度特征融合单元是作为湍流特征提取网络的, 依次经过 5 个 Bmff_unit 进行自顶向下和自底向上的特征提取, 保证目标天体的湍流退化特征可以被网络充分学习。同时为了保证输出图像与输入图像的尺寸相同, 在 Bmff_unit 输出单元进行上采样处理, 并且对生成器输出图像进行平滑处理。而后将生成器获取的输出图像送入到判别器 D 中与初始图像(即图 6 中的 Sharp 图像)进行对抗训练, 在训练期间, 判别网络将复原图像和初始清晰图像作为输入并估计它们之间的距离。同时, 采用的损失函数为对抗损失与内容损失的组合损

失函数, 表达式为

$$L = L_{GAN} + \lambda \cdot L_X, \quad (5)$$

$$L_{GAN} = \sum_{n=1}^N \left\{ -D_{\theta_n} \left[G_{\theta_n} (I^B) \right] \right\}, \quad (6)$$

$$L_X = \frac{1}{W_{i,j} H_{i,j}} \sum_{x=1}^{W_{i,j}} \sum_{y=1}^{H_{i,j}} \left\{ \left[\phi_{i,j} (I^S)_{x,y} - \phi_{i,j} \left[G_{\theta_n} (I^B) \right]_{x,y} \right]^2 \right\}, \quad (7)$$

式中: L 代表总的损失函数; L_{GAN} 为对抗损失, 用 WGAN-GP^[20] 来表示; $\lambda \cdot L_X$ 为内容损失; I^B 为输入的湍流退化图像; I^S 为输出的湍流复原图像; G_{θ_n} 为生成器; D_{θ_n} 为判别器; $\phi_{i,j}$ 是在 VGG19 网络^[21] 内的第 i 个最大化层之前通过第 j 个卷积(激活之后)获得的特征图; $W_{i,j}$ 和 $H_{i,j}$ 为图的维度。

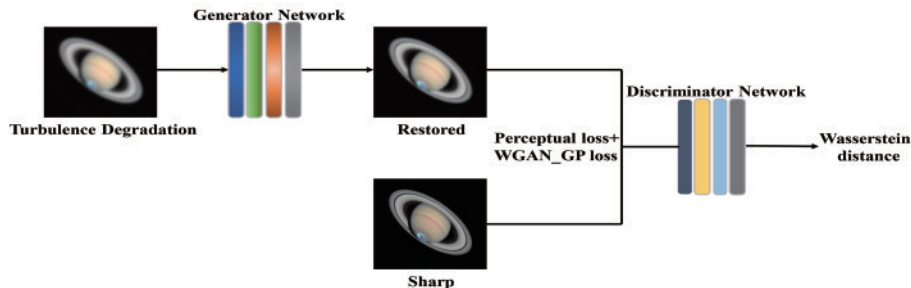


图 6 BmffGAN 整体网络的拓扑结构^[19]

Fig. 6 Topology structure diagram of BmffGAN overall network^[19]

3.4 网络的训练过程

使用 PyTorch1.5 深度学习框架^[22] 来实现所提网络, 采用一张 NVIDIA GTX 1080Ti GPU 进行训练。由于网络刚开始训练时模型的权重是随机初始化的,

此时选择一个较大的初始学习率会使模型发生振荡, 因此使用 Warmup^[23] 学习率预热。Warmup^[23] 是在 ResNet^[23] 中提到的一种学习率预热方法, 在训练开始时先使用一个较小的学习率, 使模型慢慢趋于稳定。

本文在训练 3 个 epochs 后,再采用设置的初始学习率 0.0005 进行训练。图 7 为 BmffGAN 训练过程的损失函数与评价函数曲线,小矩形曲线代表训练集损失函数和峰值信噪比(PSNR)随网络迭代次数变化而变化的情况,小圆形曲线代表验证集损失函数和 PSNR 随网络迭代次数变化而变化的情况。由图 7 可知,当训练达 135 epochs 左右,验证集的损失函数曲线已经趋于稳定,不再继续向下收敛,即此时所提网络模型达到最小收敛标准。网络模型采用 Adam 自适应矩估计优化器进行优化,Adam 优化器^[24]是一种对目标函数执

行一阶梯度优化的算法,它具有很高的计算效率和较低的内存需求,Adam 优化器可以加快模型训练时间和优化模型输出的网络参数。网络的 batch_size 为 1,即对于每一个 epoch,每次训练获取一张图片,每个 epoch 训练 4800 次后再进入下一个 epoch。为了使所提网络适应于受不同大气湍流强度影响的空间目标图像,在网络的实际训练中采用混合训练机制,即将湍流强度因子为 0.001,0.0025,0.005 的训练集随机打乱送入网络进行训练,使网络能充分学习不同的湍流强度特征。

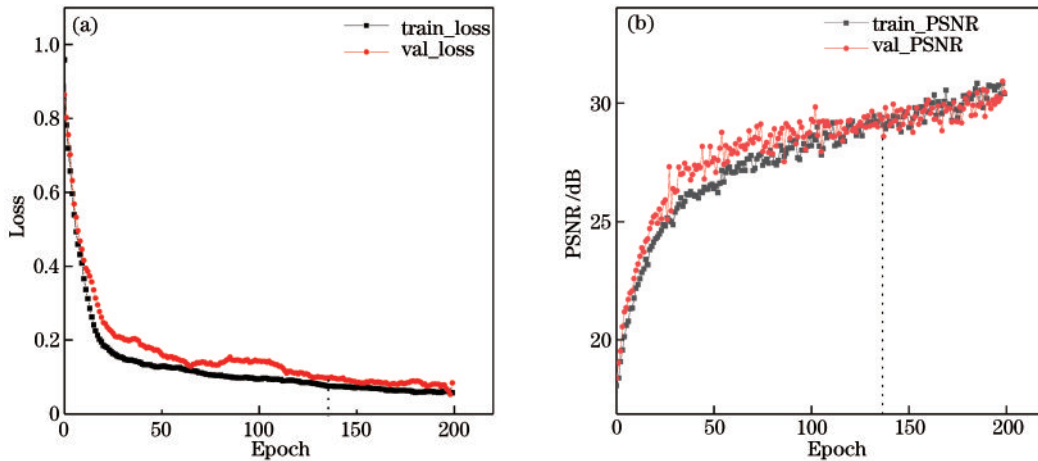


图 7 BmffGAN 训练过程。(a)损失函数随训练次数变化而变化的曲线;(b) PSNR 随训练次数变化而变化的曲线

Fig. 7 Process of BmffGAN training. (a) Curve of loss function changing with epoch; (b) curve of PSNR changing with epoch

结合损失函数曲线和评价函数曲线可知:所提网络在经过大概 135 epochs 训练后趋于稳定,135 epochs 到 200 epochs 之间曲线变化幅度较小;所提网络模型中训练集的损失函数曲线随着迭代次数增加从 0.9 降到了 0.1 左右,评价函数曲线峰值信噪比从 17 dB 上升到 33 dB。同时通过曲线变化情况可以看出:不管是针对训练集还是验证集,所提 BmffGAN 均有较大幅度的改善,因此可以证明其可以有效复原空间目标湍流退化图像。

4 湍流图像复原对比实验

4.1 对比实验复原算法

根据训练过程得到网络 BmffGAN 的模型参数,为了测试所提网络的具体性能,将所提网络与 4 种经典的湍流图像复原方法进行充分对比。其中三种传统湍流图像复原方法为 CLEAR^[25]、SGL^[26]、IBD^[5]。CLEAR 算法^[25]为 Anantrasirichai 等使用的基于二叉树的小波变换的区域级融合算法,解决湍流退化问题;SGL 算法^[26]为加州大学洛杉矶分校的 Lou 等使用 Sobolev 梯度算子来锐化单个湍流影响的图片帧的算法;IBD 算法^[5]通过盲反卷积直接估计退化图像的模糊核,输出复原图像。另外一种神经网络算法是 DNCNN^[27],DNCNN^[27]是苏黎世联邦理工学院的

Zhang 等在 2017 年提出的,在 2019 年被英国布里斯托大学视觉信息团队证明其可在湍流退化图像复原中发挥作用。

4.2 对比实验评价指标

为了更好地评价不同算法对空间目标湍流退化图像的复原效果,这里引入了三种有参考图像评价指标,包括 PSNR、结构相似性(SSIM)、梯度幅相似性偏差(GMSD)^[28],两种无参考图像复原评价指标,包括空间频率(SpaceFrequency)和平均梯度(AverageGradient)。有参考图像复原评价指标中:PSNR 表征了信号最大可能功率与背景噪声的比值;SSIM 是一种衡量两幅图像结构相似度的指标,一般值越大,两幅图像的相似度越高;GMSD^[28]可以更好地反映两幅图像结构信息的相似度,尤其是对某些细微结构的比较^[24]。两种无参考图像复原评价指标中:SpaceFrequency 更多地侧重图像高频信息的分布,从而确定整幅图像是否清晰;AverageGradient 则更多地强调图像的层次感以及图像细节信息是否丰富。同时,由于实时性的图像复原越来越引起人们的重视,输出复原图像的时间也是一个重要指标。一些评价指标的具体公式如下所示。PSNR 的公式为

$$R_{\text{PSN}} = 10 \log_{10} \frac{C_{\text{max}I}^2}{E_{\text{MS}}}, \quad (8)$$

$$E_{MS} = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [I(i,j) - k(i,j)]^2, \quad (9)$$

式中: E_{MS} 代表两幅图像的均方差; $I(i,j)$ 表示参考图像; $k(i,j)$ 表示复原后的图像; mn 代表图像大小; C_{max} 为图像点颜色的最大数值。SSIM 的公式为

$$S_{SIM}(x,y) = \frac{(2u_x u_y + c_1)(2\sigma_{xy} + c_2)}{(u_x^2 + u_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)}, \quad (10)$$

式中: x, y 分别表示两幅图像; u_x 代表 x 的均值, u_y 代表 y 的均值; σ_x^2 代表 x 的方差, σ_y^2 表示 y 的方差; σ_{xy} 表示 x 和 y 的协方差; c_1 和 c_2 表示稳定性的常数。SpaceFrequency 的公式为

$$F_R = \sqrt{\frac{1}{m \times n} \sum_{i=1}^m \sum_{j=2}^n (f_{i,j} - f_{i,j-1})^2}, \quad (11)$$

$$F_C = \sqrt{\frac{1}{m \times n} \sum_{i=2}^m \sum_{j=1}^n (f_{i,j} - f_{i-1,j})^2}, \quad (12)$$

$$F_S = \sqrt{F_R^2 + F_C^2}, \quad (13)$$

式中: F_R 代表空间行频率; F_C 代表空间列频率; F_S 代表图像整体的空间频率值; $f(i,j)$ 代表图像像素 (i,j)

的灰度值。AverageGradient 的公式为

$$\bar{G} = \frac{1}{m \times n} \sum_{i=1}^m \sum_{j=1}^n \left[\frac{\left(\frac{\partial f_{i,j}}{\partial x_i} \right)^2 + \left(\frac{\partial f_{i,j}}{\partial y_j} \right)^2}{2} \right]^{1/2}. \quad (14)$$

4.3 测试模拟空间目标湍流退化图像

从测试集 600 张图片中选取未经训练的不同强度模拟湍流退化图像进行测试。 k 代表湍流强度因子, k 越大, 图像退化越明显。具体测试结果如图 8~10 所示。相关指标计算如图 11 所示。

由图 11 各项评价指标可以看出: BmffGAN 在峰值信噪比、结构相似性、梯度幅相似性偏差上相比其他传统复原方法均取得不错的结果; 在峰值信噪比上, 相比传统方法, BmffGAN 提高了 2 dB~3 dB, 结构相似性上提高了 0.08~0.17, 梯度幅相似性偏差减少了 0.01~0.03; 在输出时间上, BmffGAN 可以在 0.5 s 左右输出复原结果, 比 DNCNN^[27] 还要快 4 倍以上, 相比其他传统复原方法, 时间优势则更为明显。因此后面可以考虑针对湍流退化视频流的复原任务。

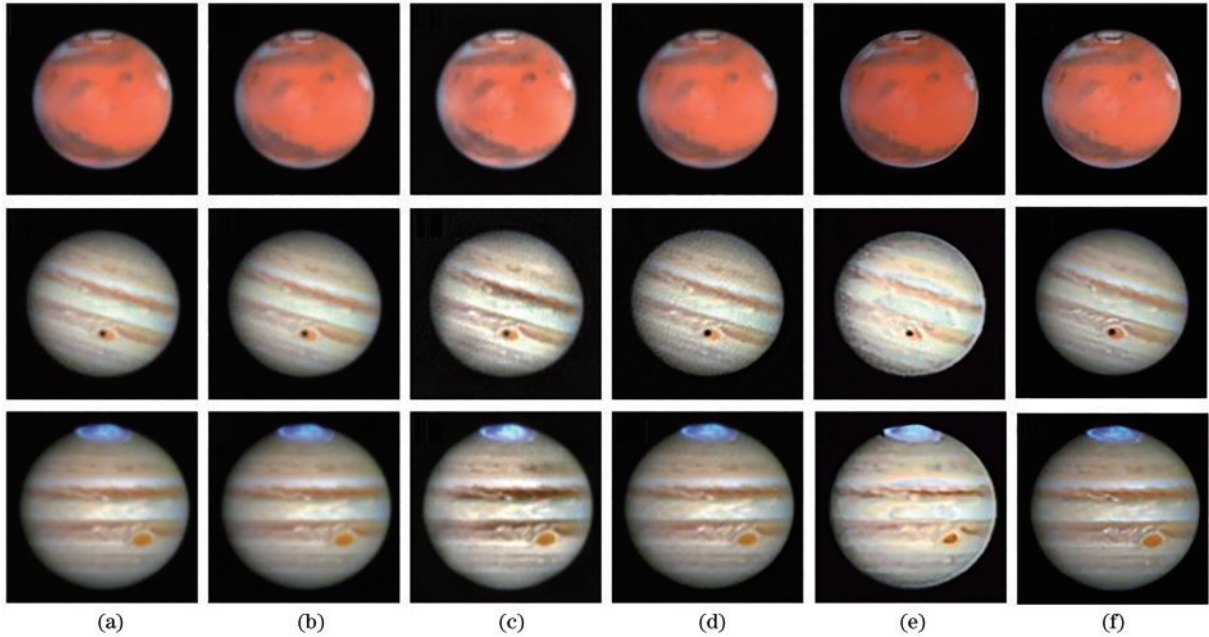


图 8 $k=0.005$ 时, 不同算法对模拟大气湍流图像的复原效果对比。(a) 加性噪声均值为 0、方差为 0.001 时的退化图像;

(b) SGL 算法; (c) CLEAR 算法; (d) IBD 算法; (e) DNCNN 算法; (f) BmffGAN

Fig. 8 Comparison of restoration effects of different algorithms on simulated atmospheric turbulence images under $k=0.005$.

(a) Degraded images when the additive noise mean is 0, and the variance is 0.001; (b) SGL algorithm; (c) CLEAR algorithm;

(d) IBD algorithm; (e) DNCNN algorithm; (f) BmffGAN

4.4 测试受真实大气湍流影响的空间目标

为了测试所提网络对真实大气湍流退化图像的复原效果, 实际获取了 Munin 地基望远镜对国际空间站 (ISS) 的观测图像, Munin 地基望远镜与星图软件如图 12 所示。Munin 望远镜直径为 80 cm, 焦距为 8 m。图片拍摄日期为 2010 年 6 月 28 日, 图像中含有真实的

大气湍流。将受真实湍流影响的国际空间站图像送入网络和其他对比算法中进行测试, 并通过人眼和无参考指标进行评估, 结果如图 13 所示。具体相关指标计算结果如表 1 所示。

通过人眼主观对复原图像的效果进行评价, 结果表明: SGL 算法^[26] 与 CLEAR 算法^[25] 对受湍流退化影

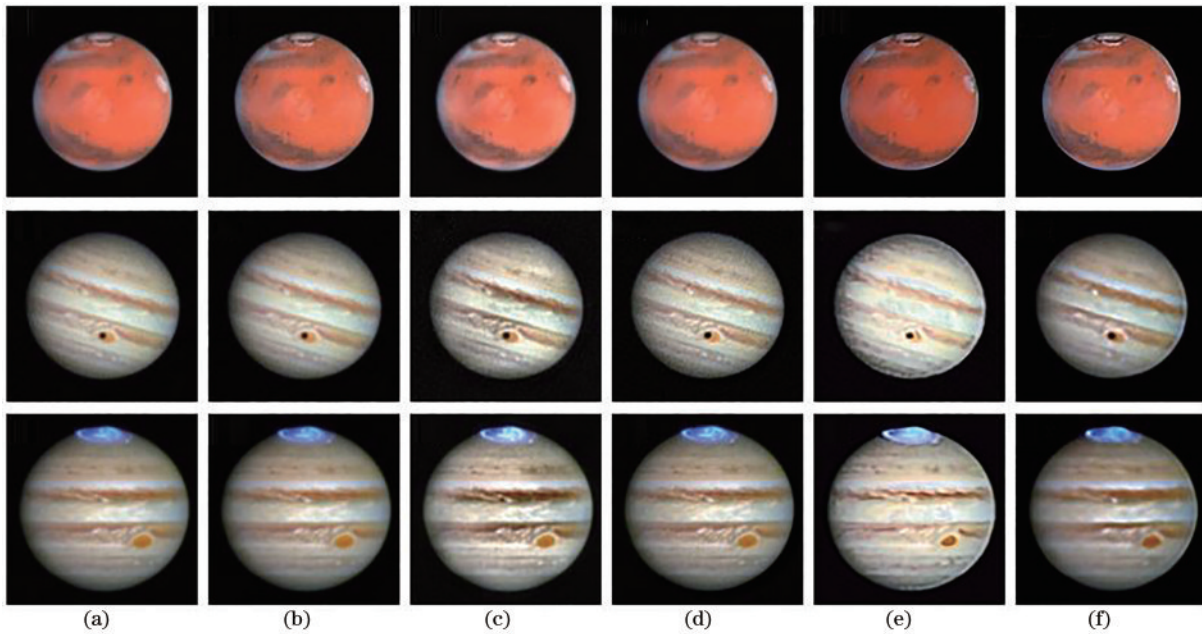


图 9 $k=0.0025$ 时,不同算法对模拟大气湍流图像的复原效果对比。(a)加性噪声均值为 0、方差为 0.001 时的退化图像;
(b)SGL 算法;(c)CLEAR 算法;(d)IBD 算法;(e)DNCNN 算法;(f)BmffGAN

Fig. 9 Comparison of restoration effects of different algorithms on simulated atmospheric turbulence images under $k=0.0025$.
(a) Degraded images when the additive noise mean is 0, and the variance is 0.001; (b) SGL algorithm; (c) CLEAR algorithm;
(d) IBD algorithm; (e) DNCNN algorithm; (f) BmffGAN




图 10 $k=0.001$ 时,不同算法对模拟大气湍流图像的复原效果对比。(a)加性噪声均值为 0、方差为 0.001 时的退化图像;
(b)SGL 算法;(c)CLEAR 算法;(d)IBD 算法;(e)DNCNN 算法;(f)BmffGAN

Fig. 10 Comparison of restoration effects of different algorithms on simulated atmospheric turbulence images under $k=0.001$.
(a) Degraded images when the additive noise mean is 0, and the variance is 0.001; (b) SGL algorithm; (c) CLEAR algorithm;
(d) IBD algorithm; (e) DNCNN algorithm; (f) BmffGAN

响的国际空间站图像复原效果有限,且耗时较长,尤其是在太阳能电池板以及舱体外部均残留较为明显的模糊与伪影;SGL^[26]、CLEAR^[25]、IBD^[5]在不同程度上均对图像包含的噪声有放大作用,这直接影响了复原图像的清晰度;DNCNN^[27]在复原图像过程中会出现一

定程度的失真,这可能与网络本身的泛化能力不足有关;所提网络对空间站细节与边缘部分恢复效果较好。

通过无参考图像评价指标来分析:由于图像的 SpaceFrequency 特性反映的是图像空间变化的快慢,清晰图像意味着拥有更多的高频空间成分,即空间频

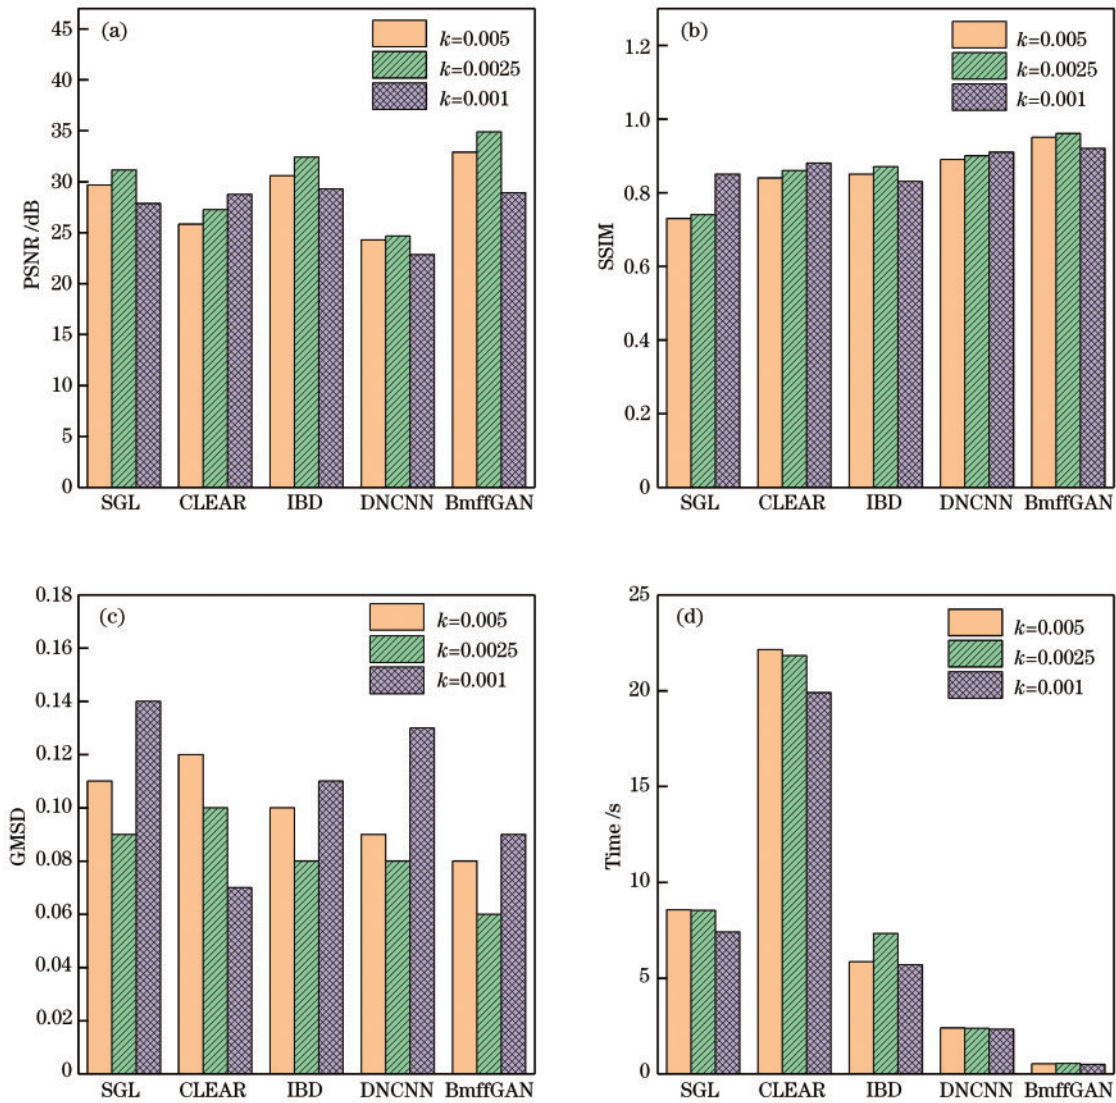


图 11 不同算法对不同强度的模拟大气湍流图像复原的评价指标(均值)。(a) PSNR; (b) SSIM; (c) GMSD; (d) 复原时间
 Fig 11 Evaluation indexes of different algorithms for restoration of simulated atmospheric turbulence images with different intensities (average value). (a) PSNR; (b) SSIM; (c) GMSD; (d) recovery time

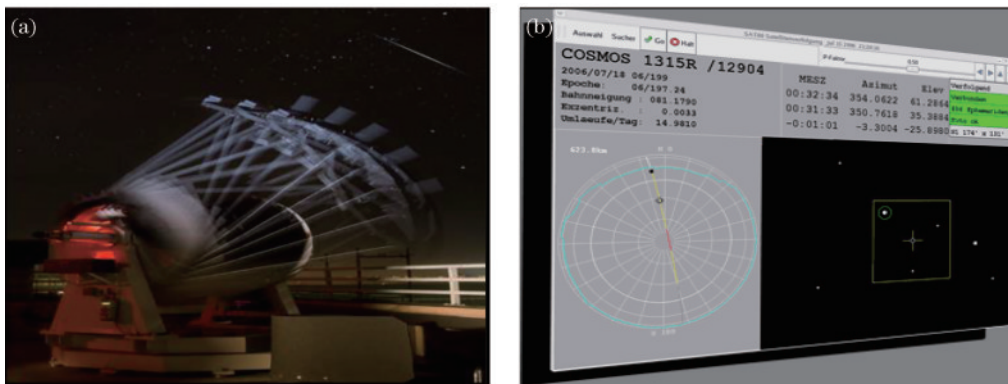


图 12 Munin地基望远镜与星图软件
 Fig. 12 Munin ground-based telescope and star chart software

率值越大,图像越清晰明亮,而模糊图像低频空间成分相对占比更大,因此BmffGAN与DNCNN^[27]在空间频率指标上均取得不错的效果;而AverageGradient指标

反映的是图像微小细节反差与纹理特征变换,该值越大,图像层次感越明显,图像就显得越丰富清晰,通过该指标来看,所提网络仍取得不错的效果。而在复原




图 13 不同算法对受真实湍流影响的国际空间站图像的复原效果对比图。(a)受真实湍流影响的空间站图像；(b) SGL 算法；(c) CLEAR 算法；(d) IBD 算法；(e) DNCNN 算法；(f) BmffGAN

Fig. 13 Comparison experiment for restoring the ISS images affected by real turbulence. (a) ISS images affected by real turbulence; (b) SGL algorithm; (c) CLEAR algorithm; (d) IBD algorithm; (e) DNCNN algorithm; (f) BmffGAN

表 1 不同复原网络的客观评价(均值)
Table 1 Objective evaluation of different networks
(average value)

Network	SpaceFrequency	AverageGradient	Time /s
SGL ^[26]	4.51	1.37	7.83
CLEAR ^[25]	5.46	1.83	21.41
IBD ^[5]	5.70	1.72	5.97
DNCNN ^[27]	8.20	2.19	2.33
BmffGAN	8.61	2.05	0.40

图像的输出时间上, BmffGAN 相比其他算法具有较大领先优势, 一般可在 0.5 s 内输出结果, 近似满足图像的实时复原要求。

5 结 论

提出了一种基于双向多尺度特征融合的生成对抗网络 BmffGAN, 用于复原不同强度的大气湍流对空间目标的退化影响。该网络包含一个生成器与判别器, 其中生成器中引入了双向多尺度特征融合机制, 使得网络可以对不同湍流退化图像的特征进行充分提取。同时, 通过对哈勃官网下载的空间目标天体进行卷积, 生成不同强度的湍流退化模拟图像数据集, 将数据集送入网络进行混合训练, 提高网络对不同大气湍流强度特征的鲁棒性与适应性。相关实验以及客观评价指标表明, 相比传统复原方法, BmffGAN 的 PSNR 提高了 2 dB~3 dB, SSIM 提高了 9.3% 左右。BmffGAN 的最大优势是在 ImageNet 数据集^[17]上预先训练了轻

量级的 Inception V2^[18] 作为整个网络的主干部分, 因此网络的实时性较强, 可在 0.5 s 内输出图像复原结果。基于上述研究, 所提网络在受真实湍流影响的空间目标上进行验证, 并取得不错的复原效果。然而, 目前获取的受真实湍流影响的退化图像较少, BmffGAN 的泛化能力仍有待进一步验证。接下来, 将利用实验室配备的卡塞格林型光学望远镜获取更多目标天体湍流退化图像和近地面的湍流图像数据, 从而来更好地验证所提网络的泛化能力和鲁棒性。

参 考 文 献

- [1] den Dekker A J, van den Bos A. Resolution: a survey[J]. Journal of the Optical Society of America A, 1997, 14 (3): 547-557.
- [2] Labeyrie A. Attainment of diffraction limited resolution in large telescopes by Fourier analysing speckle patterns in star images[J]. SPIE Milestone Series, 1970, 28: 427-429.
- [3] Fienup J R. Reconstruction of an object from the modulus of its Fourier transform[J]. Optics Letters, 1978, 3(1): 27-29.
- [4] Primot J, Rousset G, Fontanella J C. Deconvolution from wave-front sensing: a new technique for compensating turbulence-degraded images[J]. Journal of the Optical Society of America A, 1990, 7(9): 1598-1608.
- [5] Ayers G R, Dainty J C. Iterative blind deconvolution method and its applications[J]. Optics Letters, 1988, 13 (7): 547-549.
- [6] Fried D L. Probability of getting a lucky short-exposure image through turbulence[J]. Journal of the Optical

- Society of America, 1978, 68(12): 1651-1657.
- [7] Carasso A S. APEX blind deconvolution of color Hubble space telescope imagery and other astronomical data[J]. *Optical Engineering*, 2006, 45(10): 107004.
- [8] Gao J, Anantrasirichai N, Bull D. Atmospheric turbulence removal using convolutional neural network [EB/OL]. (2019-12-22)[2021-02-05]. <https://arxiv.org/abs/1912.11350>.
- [9] 杨小姗, 潘雪峰, 苏少杰, 等. 数据驱动的空间目标图像信息感知技术[J]. *光学学报*, 2021, 41(3): 0315002.
Yang X S, Pan X F, Su S J, et al. Data-driven awareness technology for space target image information [J]. *Acta Optica Sinica*, 2021, 41(3): 0315002.
- [10] Chen G P, Gao Z S, Wang Q L, et al. U-net like deep autoencoders for deblurring atmospheric turbulence[J]. *Journal of Electronic Imaging*, 2019, 28(5): 053024.
- [11] Li D L, Simske S. Atmospheric turbulence degraded-image restoration by kurtosis minimization[J]. *IEEE Geoscience and Remote Sensing Letters*, 2009, 6(2): 244-247.
- [12] Buslaev A, Iglovikov V I, Khvedchenya E, et al. Albumentations: fast and flexible image augmentations [J]. *Information*, 2020, 11(2): 125.
- [13] 林懿伦, 戴星原, 李力, 等. 人工智能研究的新前线: 生成式对抗网络[J]. *自动化学报*, 2018, 44(5): 775-792.
Lin Y L, Dai X Y, Li L, et al. The new frontier of AI research: generative adversarial networks[J]. *Acta Automatica Sinica*, 2018, 44(5): 775-792.
- [14] Goodfellow I J, Abadie J P, Mirza M, et al. Generative adversarial nets[C]//*Proceedings of the 27th International Conference on Neural Information Processing Systems (NIPS)*, December 8-13, 2014, Montreal, Canada. New York: Curran Associates, 2014: 2672-2680.
- [15] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection[C]//*2017 IEEE Conference on Computer Vision and Pattern Recognition*, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 936-944.
- [16] 谢学立, 李传祥, 杨小冈, 等. 基于动态感受野的航拍图像目标检测算法[J]. *光学学报*, 2020, 40(4): 0415001.
Xie X L, Li C X, Yang X G, et al. Dynamic receptive field-based object detection in aerial imaging[J]. *Acta Optica Sinica*, 2020, 40(4): 0415001.
- [17] Deng J, Dong W, Socher R, et al. ImageNet: a large-scale hierarchical image database[C]//*2009 IEEE Conference on Computer Vision and Pattern Recognition*, June 20-25, 2009, Miami, FL, USA. New York: IEEE Press, 2009: 248-255.
- [18] Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the inception architecture for computer vision[C]//*2016 IEEE Conference on Computer Vision and Pattern Recognition*, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 2818-2826.
- [19] Kupyn O, Budzan V, Mykhailych M, et al. DeblurGAN: blind motion deblurring using conditional adversarial 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: 8183-8192.
- [20] 牟迪, 蒙文, 赵尚弘, 等. 基于 Wasserstein 生成对抗网络的智能光通信[J]. *中国激光*, 2020, 47(11): 1106005.
Mu D, Meng W, Zhao S H, et al. Intelligent optical communication based on Wasserstein generative adversarial network[J]. *Chinese Journal of Lasers*, 2020, 47(11): 1106005.
- [21] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2014-09-04)[2021-05-06]. <https://arxiv.org/abs/1409.1556>.
- [22] Paszke A, Gross S, Chintala S, et al. Automatic differentiation in pytorch[C]//*Proceedings of the 27th International Conference on Neural Information Processing Systems(NIPS)*, December 4-10, 2017, Long Beach, California, USA. New York: Curran Associates, 2017.
- [23] 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*, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [24] Kingma D P, Ba J L. Adam: a method for stochastic optimization[EB/OL]. (2014-12-22) [2021-02-05]. <https://arxiv.org/abs/1412.6980>.
- [25] Anantrasirichai N, Achim A, Kingsbury N G, et al. Atmospheric turbulence mitigation using complex wavelet-based fusion[J]. *IEEE Transactions on Image Processing*, 2013, 22(6): 2398-2408.
- [26] Lou Y F, Kang S H, Soatto S, et al. Video stabilization of atmospheric turbulence distortion[J]. *Inverse Problems & Imaging*, 2013, 7(3): 839-861.
- [27] Zhang K, Zuo W M, Chen Y J, et al. Beyond a Gaussian denoiser: residual learning of deep CNN for image denoising[J]. *IEEE Transactions on Image Processing*, 2017, 26(7): 3142-3155.
- [28] Xue W F, Zhang L, Mou X Q, et al. Gradient magnitude similarity deviation: a highly efficient perceptual image quality index[J]. *IEEE Transactions on Image Processing*, 2014, 23(2): 684-695.