一种简单自适应光学系统高分辨计算成像技术

岳 丹[1],王崇帅[1],杨亚廷[1],聂海涛[2],揣雅惠[1]

(1.长春理工大学 物理学院,长春 130022;2.中国科学院 长春光学精密机械与物理研究所,长春 130033)

摘 要:针对当前基于硬件的自适应光学技术存在的波前校正器像差校正不完全、硬件成本高及系统结构复杂等问题,本研究提出了一种全新的简单自适应光学高分辨计算成像技术。该技术在硬件上完全摒弃了传统的波前探测器件及校正器件,利用计算成像技术直接在图像层面通过深度学习算法对波前像差导致的畸变进行校正。首先,基于深度学习算法,利用一幅系统焦面退化图像一次性解算出大气湍流像差;然后,基于解算的波前像差对退化图像进行解卷积操作,从而获得观测目标的高分辨重建。结果表明,在配置的硬件环境下基于提出的深度神经网络能够快速、高精度地解算出大气湍流像差,基于解算像差利用解卷积策略复原的图像与未校正的图像相比,其成像质量有大幅度提升,实现了完全无硬件的简单自适应光学高分辨成像。

关键词:自适应光学;简单成像系统;计算成像;深度学习

中图分类号:O436 **文献标志码**:A **文章编号**:1671-5497(2026)02-0543-12

DOI:10.13229/j.cnki.jdxbgxb.20240835

High resolution computational imaging technology for a simple adaptive optics system

YUE Dan[1],WANG Chong-shuai[1],YANG Ya-ting[1],NIE Hai-tao[2],CHUAI Ya-hui[1]

(1. *College of Physics, Changchun University of Science and Technology, Changchun* 130022, *China*; 2. *Changchun Institute of Optics, Precision Mechanics and Physics, Chinese Academy of Sciences, Changchun* 130033, *China*)

Abstract: Aimed at the problems of current hardware-based adaptive optics including incomplete wavefront correction, high hardware cost, and complexity of the system structure, this paper proposed a new simple adaptive optics to achieve high resolution imaging of the observed target. It completely abandoned the traditional wavefront detection and correction devices, while used computational imaging technology to directly correct the wavefront aberrations at the image level through deep learning algorithm. Firstly, based on deep learning algorithm, a system focal plane degraded image is used to calculate atmospheric turbulence aberrations once and for all. Then based on the resolved turbulence aberrations, a deconvolution is processed to the degraded image to obtain high-resolution reconstruction of the observed object. The simulation results show that the proposed deep neural network can solve the atmospheric turbulence

收稿日期:2024-07-24.

基金项目:国家自然科学基金项目(61905023、62204024);吉林省科技发展计划项目(20220101027JC);吉林省科技厅项目(20240304129SF).

作者简介:岳丹(1989-),女,副教授,博士.研究方向:自适应光学,主动光学.E-mail:yuedan@cust.edu.cn

通信作者:聂海涛(1986-),男,副研究员,博士.研究方向:人工智能技术在光电解译.E-mail:kelek2@126.com

aberrations with high accuracy and high speed under the configured hardware environment. The quality of the image recovered by the deconvolution strategy based on the solved aberrations is greatly improved compared with the degraded image without correction, and the high-resolution imaging for the proposed simple adaptive optics without hardware is realized

Key words: adaptive optics; simple imaging system; computational imaging; deep learning

0 引 言

自适应光学技术是补偿光学成像系统,可改善地基望远系统在成像过程中由大气湍流造成的波前畸变,可分为传统的有波前探测的自适应光学技术和无波前探测的自适应光学技术[1]。有波前探测的传统自适应光学系统由波前传感器(如Shack-Hartmann波前传感器)、波前校正器(如变形镜)和控制单元组成[2,3]。无波前探测的自适应光学技术去除了传统的波前传感器件,将波前校正器所需要的控制信号直接作为优化参数,以成像清晰度、接收光能量等系统性能指标作为控制算法的目标函数,优化得到接近理想的校正效果[4,5]。与有波前探测的自适应光学技术相比,无波前探测技术在一定程度上简化了硬件光路,能用于如激光腔内像差校正等不适于安放波前探测器的应用场景中,但本质上仍属于基于硬件的自适应光学技术。然而,由于硬件条件的限制,变形镜没有足够的自由度很好地恢复复杂波前相位,波前校正器不能实现对波前像差的完全校正,从而导致最终的成像质量降低[6]。另外,由于自适应光学技术在望远镜上的广泛应用,随着望远镜口径的增大,变形镜的单元数会不断增加,系统复杂度和成本都呈指数上升。

近年来,简单光学系统计算成像技术兴起。它通过放松前端光学系统设计中的成像质量要求,在后端利用图像复原算法去除系统的残余像差,从而使系统得到简化,在保证高像质的同时,实现前端光学系统的低成本、小型化的目的[7,8];而人工智能与深度学习技术的飞跃式发展,又为计算光学成像技术提供了支持。不同于传统计算成像方法所依赖的物理驱动,深度学习下的计算成像是一类由数据驱动的方法,它不仅解决了许多过去计算成像领域难以解决的难题,还在信息获取能力、成像功能、核心性能指标(如成像空间分辨率、时间分辨率、灵敏度等)上都获得了显著提升[9-13]。

基于此,本文提出一种全新的简单自适应光学计算成像技术,在硬件上完全摒弃传统的波前探测器件及波前校正器件,直接将成像器件获取的图像交给计算机,在图像层面通过算法对波前像差带来的畸变进行校正。在进行计算成像时,首先通过深度神经网络构建自适应光学系统的退化图像和大气湍流像差之间的精确网络映射模型,利用一幅系统焦面退化图像一次性解算出大气湍流像差。其次,基于解算的波前像差对退化图像进行解卷积操作,从而获得观测目标的高分辨重建,实现简单自适应光学系统的高分辨计算成像。

1 基本原理

1.1 简单自适应光学系统模型及算法总体流程

本文基于简单光学系统计算成像技术原理,设计了一种全新的简单自适应光学系统,在硬件上完全摒弃了传统的波前探测器件及波前校正器件,系统中无主动光学器件和动态器件,以计算成像方法代替机械变形镜等像差补偿结构,直接在图像层面通过算法对波前像差带来的畸变进行校正,实现对观测目标的自适应高分辨成像。构建的系统模型如图1所示。

本文提出的算法总体流程如图2所示。首先,要建立光学系统模型,包括简单自适应光学系统模型建立和大气湍流模型建立,通过设置模型参数即可产生对应的大气湍流像差,再选定特定的观测目标,即可建立目标退化图像和湍流像差的数据集。其次,通过构建神经网络模型,并利用数据集对网络进行训练,基于训练完成后的网络

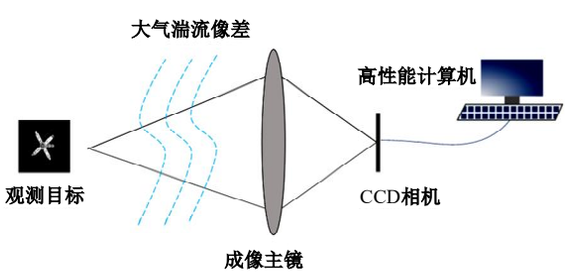

图1 简单自适应光学系统模型图

Fig. 1 Diagram of the simple adaptive optics system model

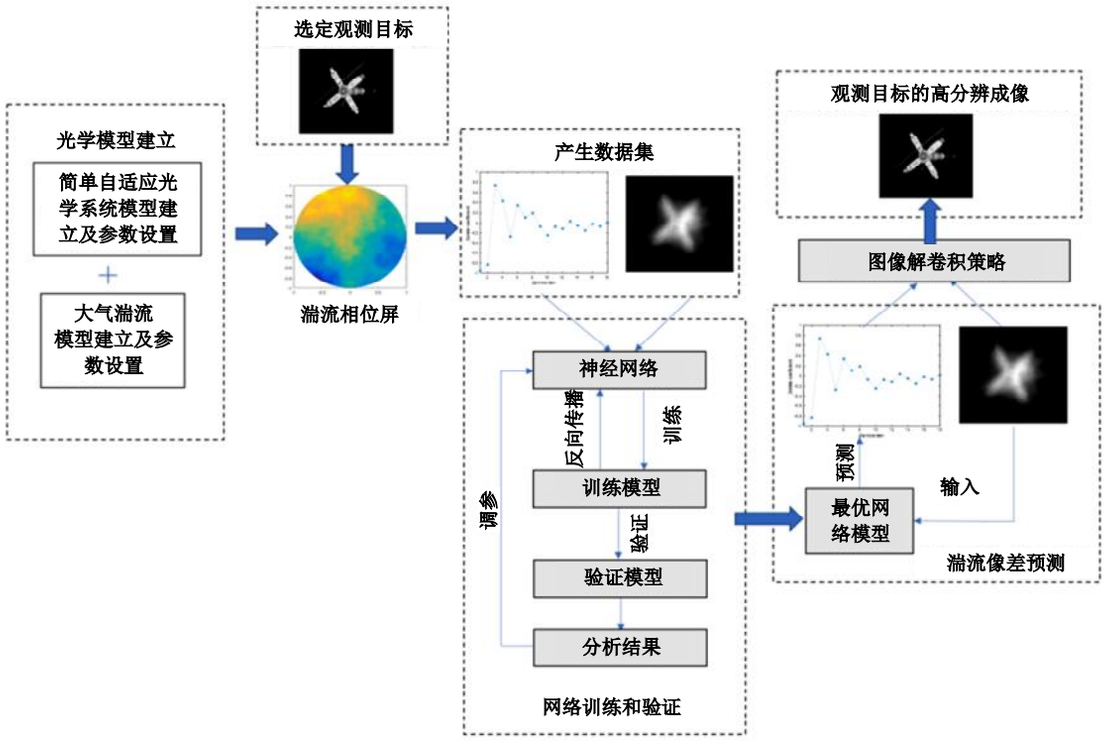

图 2　算法总体流程

Fig. 2　General flow chart of the proposed algorithm

可实现基于一幅退化图像对湍流像差的预测。最后,设计图像解卷积策略,将退化图像和预测的湍流像差输入图像解卷积策略中,可实现完全无硬件的简单自适应光学系统观测目标的高分辨计算成像。

1.2　数据集的建立

本文利用深度学习算法构建湍流像差和退化图像的网络映射模型,实现对大气湍流像差的高精度解算。深度学习算法是基于数据驱动的方法,为保证算法的精度,需要构建出大量可靠的系统焦面退化图像和大气湍流像差的数据集。本文构建数据集的方法如下。

首先,基于 Kolmogorov 大气湍流模型,模拟出大气湍流相位屏[14,15]。本文使用 Zernike 多项式作为扩展基函数描述湍流相位屏:

$$\phi(\varepsilon,\eta)=\sum_{i=1}^{N}a_i\cdot z_i(\varepsilon,\eta) \tag{1}$$

式中:(ε,η)为瞳面坐标;$\phi(\varepsilon,\eta)$为大气湍流波前相位;$z_i(\varepsilon,\eta)$为第 i 项 Zernike 多项式;a_i 为第 i 项 Zernike 多项式的系数;N 为 Zernike 项的数量。用 $\boldsymbol{A}$ 表示 Zernike 多项式系数向量,根据 Kolmogorov 大气湍流理论,可以得到 Zernike 系数向量 $\boldsymbol{A}$ 的协方差矩阵 $\boldsymbol{C}$:

$$c_{ij}=E(a_i,a_j)=\frac{K_z\delta_{mm'}\Gamma\left[\left(n+n'-5/3\right)/2\right](D/r_0)^{5/3}}{\Gamma\left[\left(n-n'+17/3\right)/2\right]\Gamma\left[\left(n'-n+17/3\right)/2\right]\Gamma\left[\left(n+n'+23/3\right)/2\right]} \tag{2}$$

$$\delta_{mm'}=(m=m')\wedge\left(\overline{\text{parity}(i,j)}\vee(m=0)\right) \tag{3}$$

式中:c_{ij} 为系数协方差矩阵 $\boldsymbol{C}$ 的第 i 行和第 j 列的元素;$E(a_i,a_j)$为 Zernike 系数 a_i 和 a_j 之间的协方差;$\Gamma(\ )$为 Gamma 函数;n、m、n' 和 m' 分别为第 i 阶和第 j 阶 Zernike 多项式的径向频数和角向频数;$\delta_{mn'}$ 为一个逻辑 Kronecker 符号,当 i 和 j 的奇偶性相同时,$\overline{\text{parity}(i,j)}$等于 1,否则等于 0。$K_z$ 可由以下给出的径向频数和角向频数计算:

$$K_z=2.268\,9(-1)^{(n+n'-2m)/2}\sqrt{(n+1)(n'+1)} \tag{4}$$

同时,式(2)中使用 D/r_0 表示湍流强度,D 是望远镜孔径,r_0 是大气相干长度。大气相干长度可由下式计算得到:

$$r_0=\left[0.423\left(\frac{2\pi}{\lambda}\right)^2\sec\beta\int_0^L C_n^2(h)\,\mathrm{d}h\right]^{-3/5} \tag{5}$$

式中:λ为光波波长;β为天顶角;L为光波的传输距离;h为海拔高度,单位m;C_n^2为大气透射率结构常数。

由于Zernike系数协方差矩阵$\boldsymbol{C}$是一个Hermittian矩阵,因此存在酉矩阵$\boldsymbol{U}$($\boldsymbol{U}^{-1}=\boldsymbol{U}^{\mathrm{T}}$)使$\boldsymbol{U}\cdot\boldsymbol{C}\cdot\boldsymbol{U}^{\mathrm{T}}$为对角阵,酉矩阵$\boldsymbol{U}$可通过对协方差矩阵C进行奇异值(SVD)分解计算得到。对任何SVD分解均存在两个矩阵,分别为酉矩阵$\boldsymbol{V}$和对角矩阵S,有$\boldsymbol{C}=\boldsymbol{V}\cdot\boldsymbol{S}\cdot\boldsymbol{V}^{\mathrm{T}}$。因此可以得出:

$$\boldsymbol{V}^{\mathrm{T}}\cdot\boldsymbol{C}\cdot\boldsymbol{V}=\boldsymbol{V}^{\mathrm{T}}\cdot\boldsymbol{V}\cdot\boldsymbol{S}\cdot\boldsymbol{V}\cdot\boldsymbol{V}^{\mathrm{T}}=\mathrm{S} \tag{6}$$

式中:·表示点乘运算,则酉矩阵$\boldsymbol{U}$等于$\boldsymbol{V}^{\mathrm{T}}$。定义新的向量$\boldsymbol{B}$,令$\boldsymbol{B}=\boldsymbol{U}\cdot\boldsymbol{A}$,则$B$的协方差矩阵为:

$$\begin{aligned}E\left[\boldsymbol{B}\cdot\boldsymbol{B}^{\mathrm{T}}\right]&=E\left[\boldsymbol{U}\cdot\boldsymbol{A}\cdot\boldsymbol{A}^{\mathrm{T}}\cdot\boldsymbol{U}^{\mathrm{T}}\right]\\&=\boldsymbol{U}\cdot E\left[\boldsymbol{A}\cdot\boldsymbol{A}^{\mathrm{T}}\right]\cdot\boldsymbol{U}^{\mathrm{T}}=\boldsymbol{S}\end{aligned}. \tag{7}$$

可以看出,向量$\boldsymbol{B}$的协方差矩阵是一个对角矩阵,因此向量$\boldsymbol{B}$中的数据服从高斯随机分布且统计独立。满足该统计规律的有Karhunen-Loève多项式的系数,因此可以将该多项式的N阶系数赋予向量$\boldsymbol{B}$。在确定向量$\boldsymbol{B}$后,可得到Zernike系数向量$\boldsymbol{A}$:

$$\boldsymbol{A}=\boldsymbol{U}^{-1}\cdot\boldsymbol{B}=\boldsymbol{U}^{\mathrm{T}}\cdot\boldsymbol{B} \tag{8}$$

基于上述推导可知,通过设置Zernike多项式的阶数N和大气湍流强度D/r_0,便可得到描述湍流强度的Zernike系数,再将Zernike系数代入式(1)中便可得到在不同强度下的湍流数值相位屏。本文中除去了平移和倾斜像差这前3项,使用第4项到21项的Zernike项描述湍流像差,原因是文献[16]指出,计算描述湍流波前的Zernike系数的方差作为Zernike项的能量分布,在忽略前3项的情况下,前10项Zernike多项式的能量占总能量的85.1%,前18项Zernike多项式的能量占总能量的92.5%,因此用18项Zernike系数,即从$a_4\sim a_{21}$就足够描述湍流波前。

在得到描述湍流波前的相位屏$\phi(u,v)$之后,基于傅里叶光学原理,可得到系统的退化点扩散函数PSF(x,y):

$$\mathrm{PSF}(x,y)=\left|\Im\left[A(\varepsilon,\eta)\exp\left(i\phi(\varepsilon,\eta)\right)\right]\right|^2 \tag{9}$$

式中:$A(\varepsilon,\eta)$为光瞳的形状函数;$\Im$为傅里叶变换;(x,y)为像面坐标。

若观测目标为$o(x,y)$,此时得到系统焦面退化图像为:

$$i(x,y)=o(x,y)*\mathrm{PSF}(x,y)+n(x,y) \tag{10}$$

式中:*为卷积运算;$n(x,y)$为模拟相机上的噪声。

由此可见,通过设置相应的光学系统参数即可构建出湍流像差和退化图像的数据集。

1.3 深度神经网络模型的建立

为实现基于一幅焦面退化图像一次性完成对湍流像差的精确预测,本文采用EfficientNet系列网络构建深度神经网络模型。EfficientNet网络提出了一种多维度混合的模型缩放法,可同时在网络宽度、网络深度和图像分辨率3个方面调整不同的组合缩放系数,实现网络性能的提高[17-19]。该网络目前存在B0~B7 7种不同算力的缩放尺度,以EfficientNet-B0网络为例,其网络结构如图3所示。

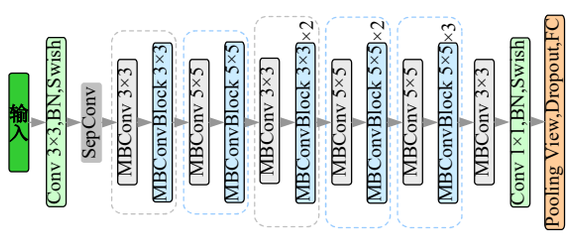

图3 EfficientNet-B0网络结构

Fig. 3 EfficientNet-B0 network structure

图3网络结构中的SepConv模块,是对输入的数据进行DWConv和通道注意力机制(Squeeze and excitation,SE)等操作后输出与输入数据具有相同通道数的特征图,然后再利用多个1×1的卷积操作融合每个通道的特征图,其作用是在不改变特征图通道数的情况下,提取更多特征信息,可起到提升网络宽度的作用。SepConv模块结构如图4所示,其中DWConv卷积模块由深度卷积(Depthwise Convolution)和逐点卷积(Pointwise Convolution)两部分组成。DWConv卷积将通道操作分开计算,对输入数据的每个通道基于不同的卷积核进行卷积计算,目的是希望耗费较少的参数量学习更多的数据特征。

另一模块MBConv同样使用了ResNet网络中的残差模块,不同的是改变了原来残差模块中使用卷积操作实现短连接的部分,转而通过使用SE层实现数据融合连接。SE模块是将输入的特征图和其经过卷积操作后的输出数据的各通道权重进行二维矩阵相乘,只需增加少量计算即可提升网络对通道特征信息的敏感度。同时,该模块的最后一层Drop_connect层代替了传统的drop-

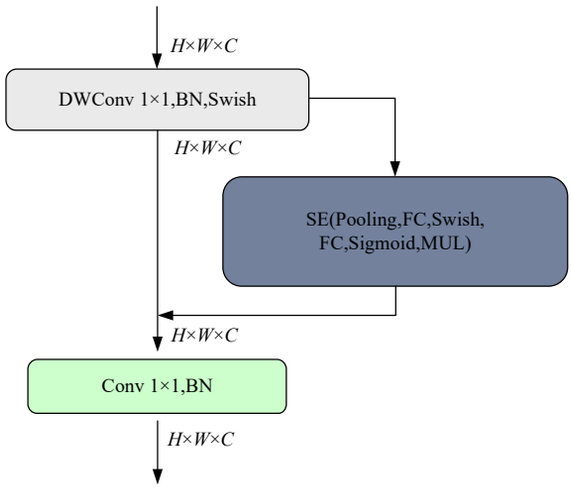

图 4　SepConv 模块图

Fig. 4　SepConv module diagram

out 方法，不再对隐藏层节点的输出进行随机丢弃，而是对隐含层的输入进行随机丢弃，起到防止网络过拟合的作用。MBConvBlock 模块结构如图 5 所示。

1.4　解卷积的图像处理策略

利用建立数据集对构建的 EfficientNet_B0 网络进行有效训练，完成训练后可利用一幅焦面退化图像实现对大气湍流像差的高精度快速求解，解算出湍流像差等价于已知系统的退化点扩散函数 PSF，因此可以采用解卷积的图像后处理策略实现自适应光学系统的高分辨成像。利用该计算成像方法代替传统机械变形镜等像差补偿结构实现对波前像差的校正，能有效避免波前校正器带来的不完全校正误差，实现完全无硬件的简单自适应光学。

由于在形成系统焦面退化图像时，既存在大气湍流像差的退化作用，又在系统中存在未知噪声。在已知退化函数而噪声未知的情况下，采用维纳滤波可以得到较好的图像复原效果，因此本文采用维纳滤波作为解卷积的图像后处理策略[20]。

若设原始观测目标为 $f(x,y)$，其傅里叶变换光谱为 $F(u,v)$，则维纳滤波函数 $H_w(u,v)$ 为：

$$H_w(u,v)=\frac{1}{H(u,v)}\frac{\left|H(u,v)\right|^2}{\left|H(u,v)\right|^2+S_n(u,v)/S_f(u,v)} \tag{11}$$

式中：$H(u,v)$ 为系统退化函数 $h(x,y)$ 的傅里叶变换；$S_n(u,v)=\left|N(u,v)\right|^2$ 为噪声函数功率谱；$S_f(u,v)=\left|F(u,v)\right|^2$ 为原始图像功率谱。在实际应用中，$S_n(u,v)$ 与 $S_f(u,v)$ 均是未知函数，故在计算中使用常数矩阵 C 代替功率谱之比，则维纳滤波函数可表示为：

$$H_w(u,v)=\frac{1}{H(u,v)}\frac{\left|H(u,v)\right|^2}{\left|H(u,v)\right|^2+C} \tag{12}$$

式中：$H(u,v)$ 可由网络预测的 Zernike 系数进行计算，功率谱比 C 可根据实验结果通过评价指标不断调整大小，一般小于 1。利用维纳滤波复原后的图像记为 $g'(x,y)$，则有：

$$g'(x,y)=\Im^{-1}\{G'(u,v)\}=\Im^{-1}\{H_w(u,v)\cdot I(u,v)\} \tag{13}$$

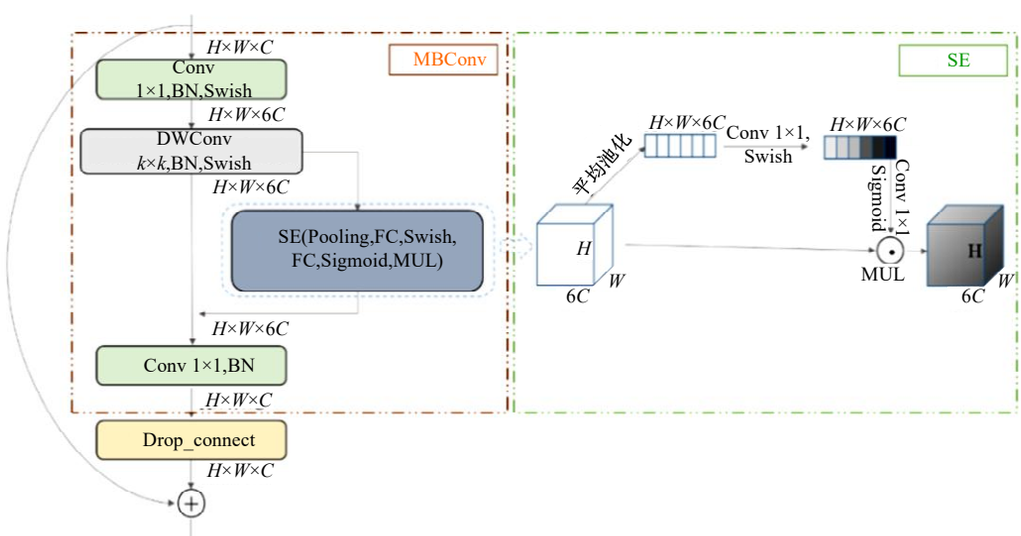

图 5　MBConvBlock 模块图

Fig. 5　MBConvBlock module diagram

式中:$G'(u,v)$为复原图像$g'(x,y)$的傅里叶光谱;$I(u,v)$为系统焦面采集到的退化图像$i(x,y)$的傅里叶光谱。由此可见,基于维纳滤波的图像解卷积策略可实现对大气湍流的校正,完成对退化图像的高分辨率复原。

2 分析与讨论

本文构建的模拟简单自适应光学系统的具体参数如下:系统主镜口径D设置为2 m,系统$F^{\#}$设置为14,观测波长λ设置为632.8 nm,CCD像素尺寸设置为8 μm,输出图像像素设置为224 pixels×224 pixels。为了模拟不同强度下的湍流像差,本文通过设置不同的大气相干常数r_0,得到4种典型的湍流强度$D/r_0=5$、10、15、20。D/r_0的数值越大,表示大气湍流效应越强。当选定观测目标时,通过设置湍流强度可得到对应的湍流像差系数及系统焦面退化图像。图6分别给出了针对"卫星"这一观测目标4种湍流强度下对应的一组随机Zernike系数及退化图像。图6(a)为原始观测目标,图6(b)(e)(h)(k)分别为大气湍流强度$D/r_0=5$、10、15、20这4种情况下对应的18项

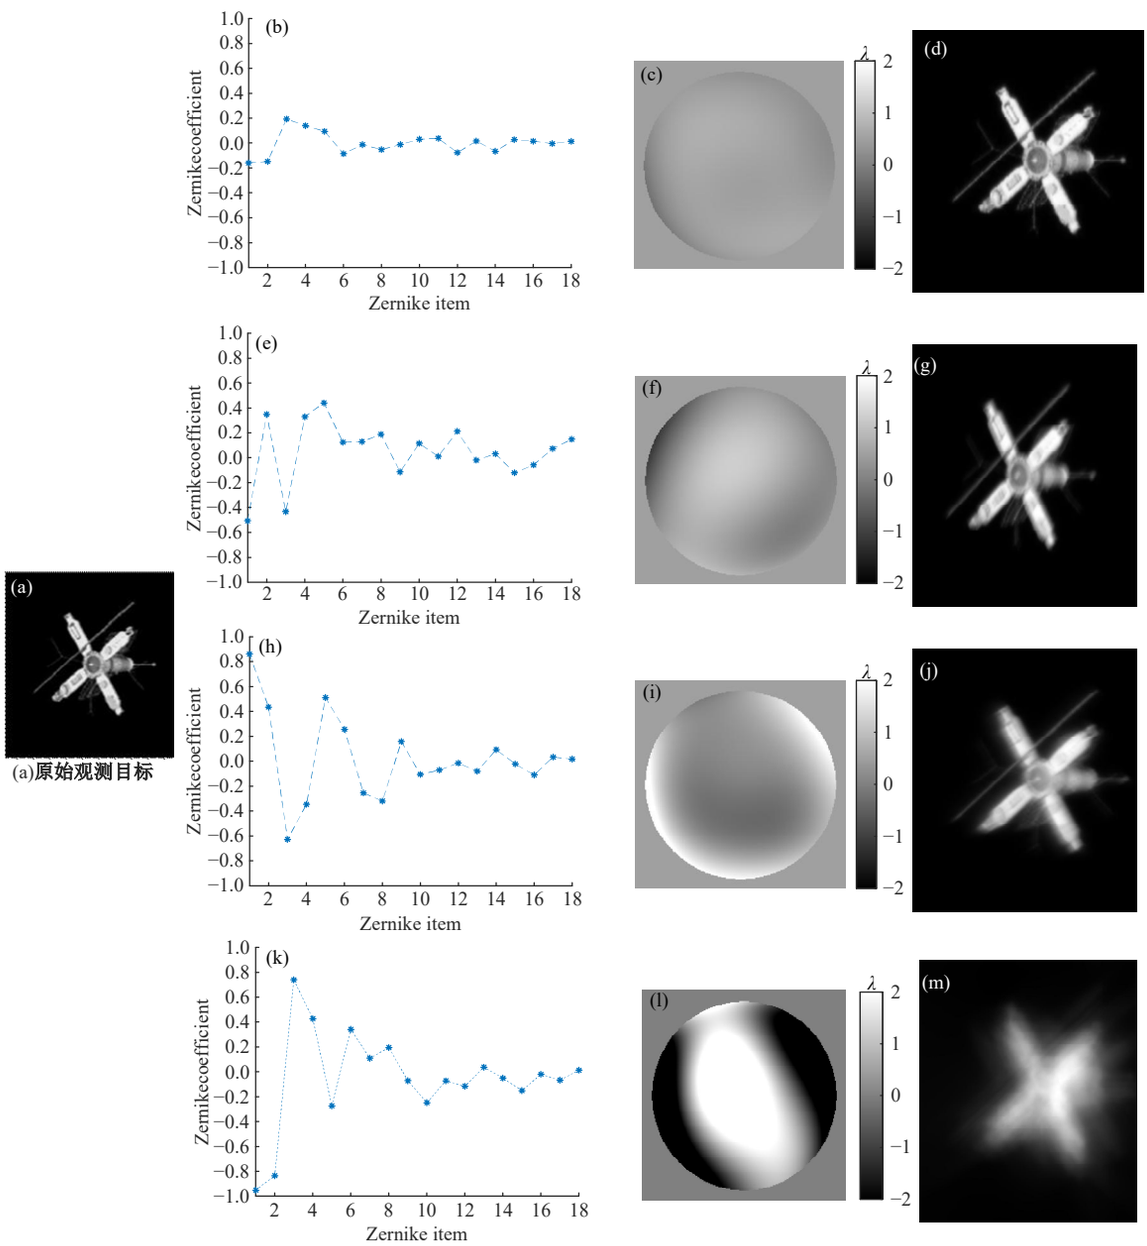

图6 数据集产生过程

Fig .6 Data set generation process

Zernike 系数;图 6(c)(f)(i)(l)分别为系数对应的湍流波前相位屏;图 6(d)(g)(j)(m)分别为 4 种湍流情况下对应的系统焦面退化图像。

循环以上步骤,即可生成需要的数据集。对每个湍流强度 D/r_0,分别生成 25 000 组数据对作为训练集,5 000 组数据对作为验证集,500 组数据对作为测试集,故全部训练集有 100 000 组数据对,验证集有 20 000 组数据对,测试集有 2 000 组数据对。每组数据对由焦面退化图像及其相应的标签组成,本实验中构建的标签是 18 项 Zernike 多项式系数,范围为[$-\lambda$,λ],其中 λ 为观测波长。

在完成数据集的建立后,本实验在 Nvidia GeForce 2080 GPU 的 Ubuntu 服务器上搭建了 PyTorch 深度学习环境,并完成了 EfficientNet-B0 网络的构建。EfficientNet-B0 网络模型训练参数具体设置情况如表 1 所示。

表 1　EfficientNet-B0 网络模型训练参数

Table 1　Training parameters of EfficientNet-B0 network

CNN 网络	输入	Epochs	优化函数	学习率	批处理数	损失函数
EfficientNet-B0	224×224	300	Adam	0.000 05	64	MSE

使用产生的 100 000 个训练集对 EfficietNet-B0 网络展开训练,并使用 20 000 个验证集验证训练后的网络。训练过程和验证过程的损失函数收敛曲线分别如图 7(a)和(b)所示。由图 7 可知,随着训练时间的增加,损失函数逐渐减小收敛,最终达到稳定状态。损失函数表示模型对训练集和验证集的拟合程度,损失函数的稳定值越小,表示网络的拟合程度越高。由此可见,EfficientNet-B0 网络对湍流像差和退化图像之间的关系模型具有较好的拟合度。

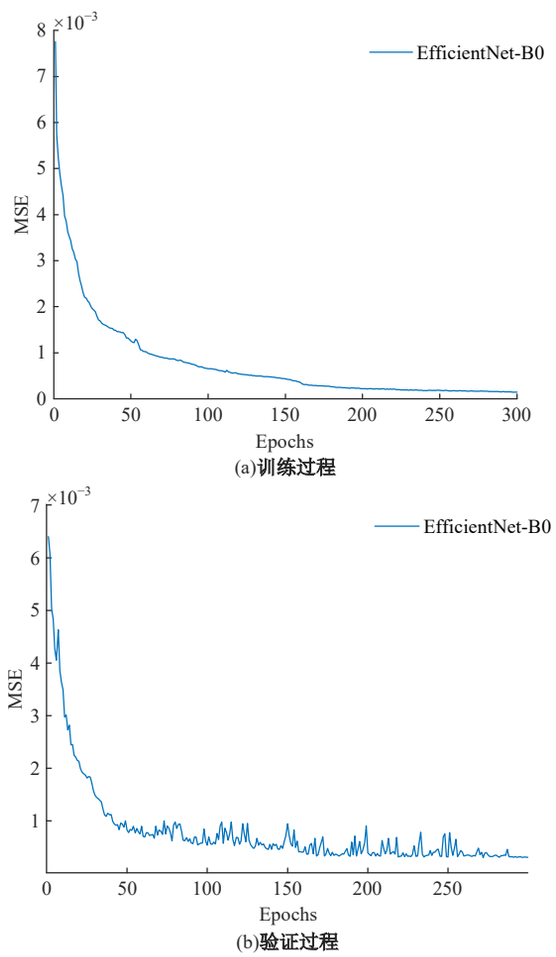

图 7　EfficientNet-B0 网络的损失函数变化过程

Fig. 7　Loss functions of EfficientNet-B0 network

当网络训练完成后,使用预先建立的 2 000 个测试集进行测试,图 8 显示了在 4 种湍流强度下,即 $D/r_0=5$、10、15、20 时,由 EfficientNet-B0 计算得到的一组湍流像差系数的预测结果,对应的波前检测结果如图 9 所示。

通过计算图 9 中的湍流波前 RMSE 值可知,当大气湍流强度 $D/r_0=5$ 时,原始波前 RMSE 为 0.501 2λ,EfficientNet-B0 网络预测的波前和残余波前 RMSE 值分别为 0.500 7λ 和 0.008λ;当 $D/r_0=10$ 时,原始波前 RMSE 为 0.560 6λ,EfficientNet-B0 网络预测的波前和残余波前 RMSE 值分别为 0.557 4λ 和 0.010 7λ;当 $D/r_0=15$ 时,原始波前 RMSE 为 0.660 7λ,EfficientNet-B0 网络预测的波前和残余波前 RMSE 值分别为 0.656λ 和 0.014λ;当 $D/r_0=20$ 时,原始波前 RMSE 为 0.824 7λ,EfficientNet-B0 网络预测的波前和残余波前 RMSE 值分别为 0.821 8λ 和 0.029λ。

图 10 给出了在 4 种湍流强度下利用训练好的 EfficientNet-B0 网络针对生成的 2 000 组测试集的波前检测结果,该图以波前检测精度 RMSE 值对 4 种湍流强度下的检测结果进行分类统计。

为了进一步验证 EfficientNet-B0 网络的湍流像差检测精度,将 EfficientNet-B0 网络同当前常用的 ordinary CNN 网络和 ResNet 网络系列中 ResNet-50 网络性能进行对比。基于建立的数据

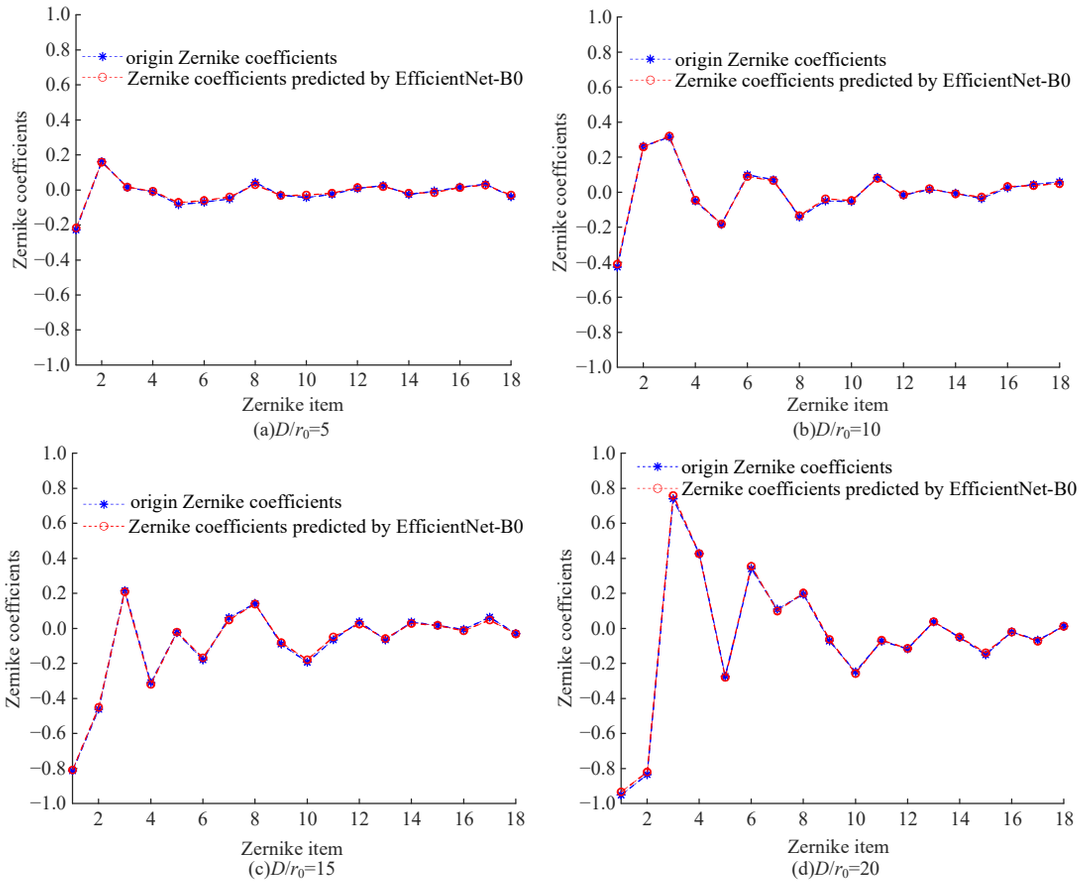

图 8　4种湍流强度下一组 Zernike 系数预测结果

Fig. 8　One set of Zernike coefficients prediction results under four turbulence intensities

集,对 ordinary CNN 网络和 ResNet-50 网络进行训练,训练完成后使用 2 000 组测试集进行测试。在 4 种湍流强度下,3 个网络的平均波前检测精度如图 11 所示。由此可见,EfficientNet-B0 网络具有更高的波前检测精度,能够为后续的图像解卷积操作提供更为准确的图像退化模型。

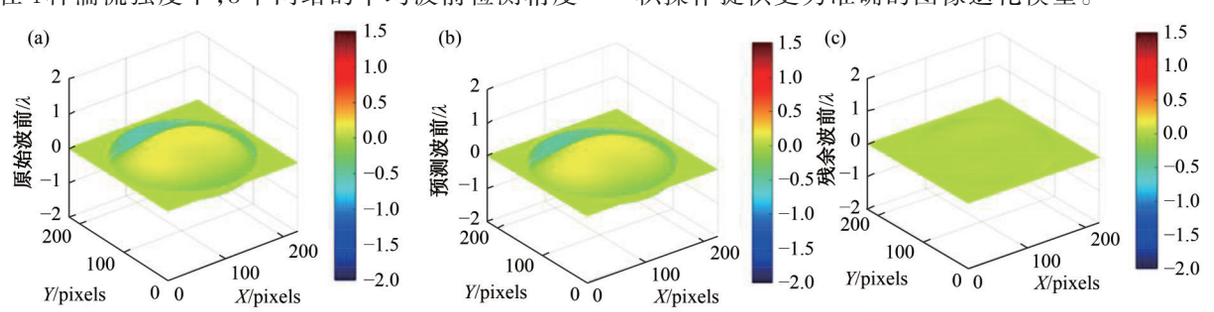

(a)~(c)分别为D/r_0=5时的原始波前、预测波前及残余波前

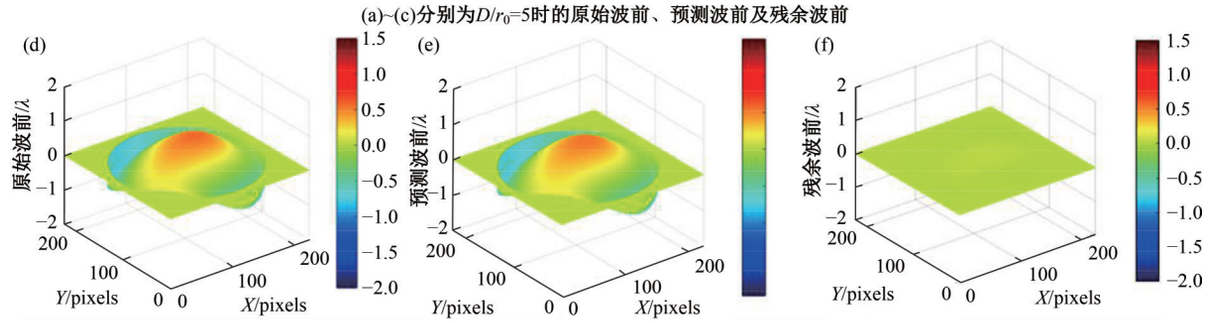

(d)~(f)分别为D/r_0=10时的原始波前、预测波前及残余波前

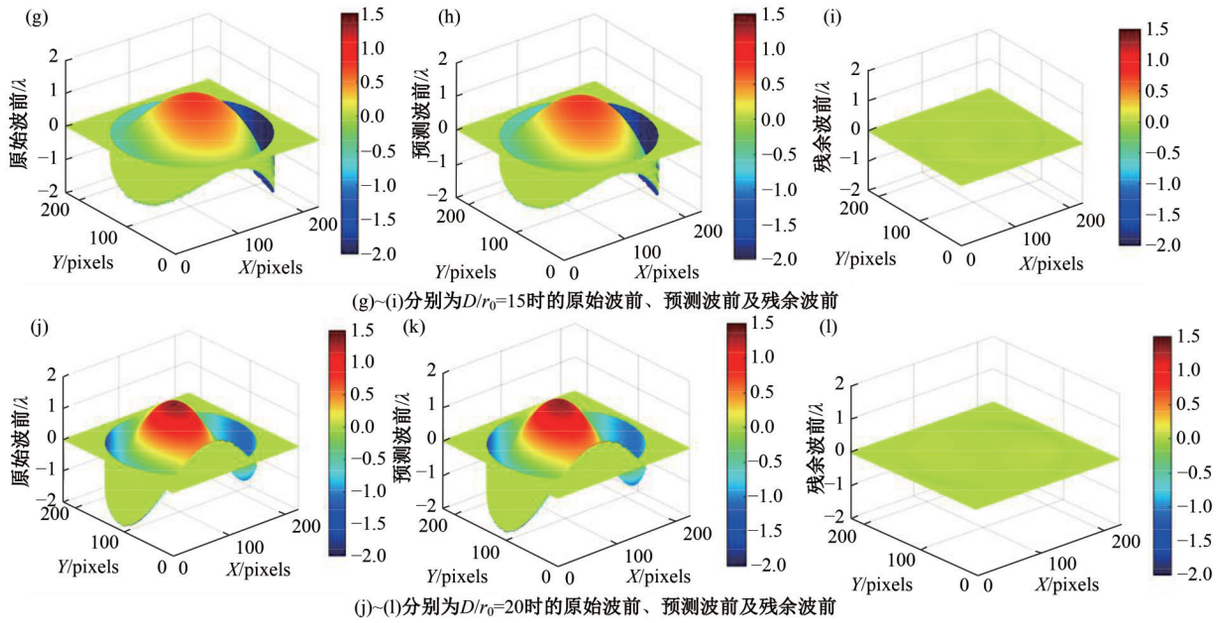

图 9　4 种湍流强度下预测的 Zernike 系数对应的湍流波面图

Fig. 9　Turbulent wavefront corresponding to the predicted Zernike coefficients under the four turbulence intensitie

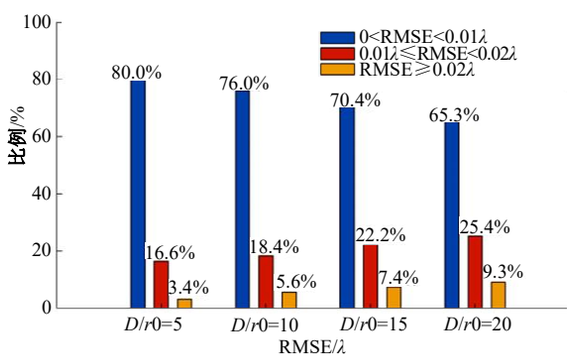

图 10　2 000 组测试集的 EfficientNet-B0 网络波前预测结果统计

Fig. 10　Statistical results of the wavefront predictions for the constructed 2,000 test data sets by EfficientNet-B0 network

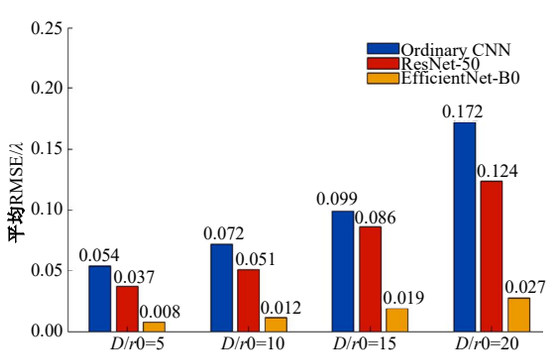

图 11　不同网络在 4 种湍流强度下平均波前检测精度

Fig. 11　Average wavefront detection accuracy of different networks under four turbulence intensities

由上可知,基于单张退化图像深度利用 EfficientNet-B0 网络可以预测出畸变波前的 Zernike 系数,然后可计算出维纳滤波方程 $H_w(u,v)$。通过设置不同的功率谱比,可利用式(12)和式(13)进行退化图像复原计算。复原过程中,可使用均方误差(MSE)和峰值信用噪比(PSNR)对复原效果进行评价,依据评价结果调整功率谱比以实现最优的观测目标高分辨恢复。其中,MSE 及 PSNR 分别由下式进行计算:

$$\mathrm{MSE}=\frac{1}{mn}\sum_{i=0}^{m-1}\sum_{j=0}^{n-1}\left[g(x,y)-g'(x,y)\right]^2 \tag{14}$$

$$\mathrm{PSNR}=10*\lg\left(\frac{\mathrm{MAX}^2}{\mathrm{MSE}}\right) \tag{15}$$

式中:$g(x,y)$为原始观测目标图像;$g'(x,y)$为复原图像;m、n为图像像素个数;MAX 为图像像素最大值。MSE 值越小,PSNR 值越大,代表误差越小,复原效果越好。

在 4 种大气湍流强度下,随机抽取了一组测试数据,基于 EfficientNet-B0 网络预测的退化信息,依据评价指标函数 MSE 和 PSNR 的结果调整功率谱比 C,利用维纳滤波算法实现了图像复原。不同功率谱下的复原效果如表 2 所示,评价指标计算结果如表 3 所示。

为验证算法的普适性,针对另一观测目标“分辨率板”展开了同样的实验:通过构建数据集对

表2 4种湍流强度下“卫星”观测目标的复原效果

Table 2 Image recovery effect of observation target “satellite” under four turbulence intensities

原始图像	原始波前	退化图像	预测波前	复原图像(C=0.01)	复原图像(C=0.000 1)	复原图像(C=0.000 01)
	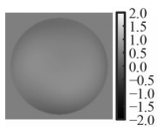		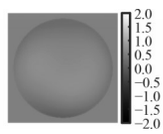			
	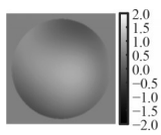		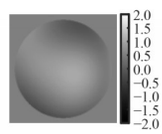			
	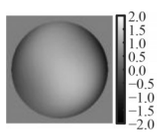		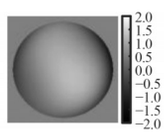			
	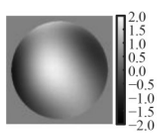		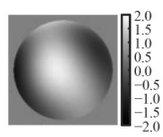			

表3 4种湍流强度下“卫星”观测目标的复原效果评价指标具体数值

Table 3 Specific values of the image recovery evalua-tion indexes for the observation target “satellite“ under the four turbulence intensities

大气湍流D/r_0	退化图像		功率谱比C	复原图像	
	MSE	PSNR/dB		MSE	PSNR/dB
5	240.98	24.31	0.01	18.61	35.43
			0.000 1	0.60	50.34
			0.000 01	0.62	50.21
10	364.23	22.52	0.01	41.11	32.00
			0.000 1	14.60	36.49
			0.000 01	16.61	35.93
15	542.53	20.79	0.01	124.24	27.19
			0.000 1	44.19	31.68
			0.000 01	73.31	29.48
20	721.64	17.18	0.01	173.68	22.21
			0.000 1	58.34	26.37
			0.000 01	79.57	25.08

EfficientNet-B0网络进行训练,基于一幅湍流退化图像利用训练好的网络进行波前Zernike系数的求解,从而得到维纳滤波函数。最后,通过设置不同的功率谱比,实现对观测目标的高分辨重建。针对“分辨率板”的一组实验结果如表4所示,具体的评价指标如表5所示。

通过仿真结果可知,本文提出的算法不仅具有较好的观测目标高分辨重建效果,还具有较低的计算复杂度。因为所用的EfficientNet-B0网络有着高效的模型设计和组件选择,其浮点运算次数较低、参数数量及模型都较小,在本实验配置的硬件环境下,该网络模型所占用内存为18 MB,当网络训练完成后,从输入一幅退化图像到输出湍流像差系数,仅需要3.4 ms。在已知图像退化模型时,采用了比较简单有效的维纳滤波算法进行图像解卷积操作,其占用内存仅2 KB,在输入湍流像差系数到完成观测目标重建的时间仅为1.6 ms。由此可见,相比于传统基于硬件的自适应光学技术,本方法能有效避免因为迭代校正带来的系统校正误差和校正时间长的缺点。

表 4　4种湍流强度下“分辨率板”观测目标的复原效果

Table 4　Image recovery effect of observation target "resolution plate" under four turbulence intensities

原始图像	原始波前	退化图像	预测波前	复原图像（C=0.01）	复原图像（C=0.000 1）	复原图像（C=0.000 01）
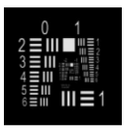	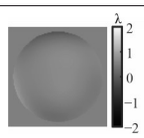	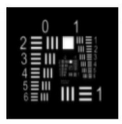	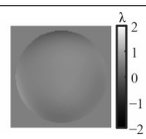	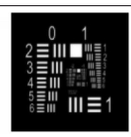	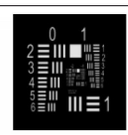	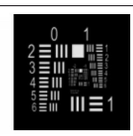
	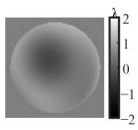	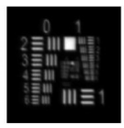	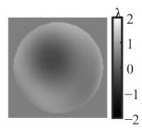	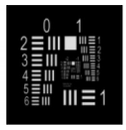	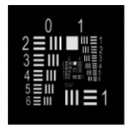	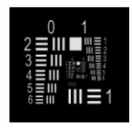
	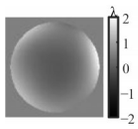	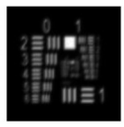	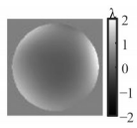	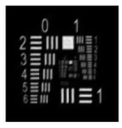	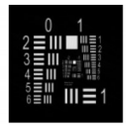	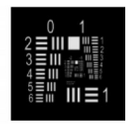
	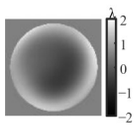	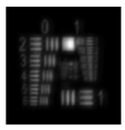	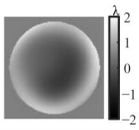	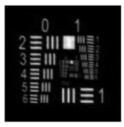	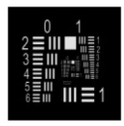	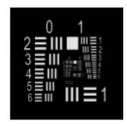

表 5　4种湍流强度下观测目标“分辨率板”的复原效果评价指标具体数值

Table5　Specific values of the image recovery evaluation indexes for the observation target "resolution plate" under four turbulence intensities

大气湍流 D/r_0	退化图像 MSE	退化图像 PSNR/dB	功率谱比 C	复原图像 MSE	复原图像 PSNR（dB）
5	234.14	24.44	0.01	5.24	41.12
			0.000 1	1.06	47.87
			0.000 01	5.06	42.29
10	403.28	22.37	0.01	248.73	23.95
			0.000 1	22.04	38.57
			0.000 01	28.92	36.52
15	720.32	13.33	0.01	357.28	22.78
			0.000 1	42.76	34.83
			0.000 01	48.76	32.79
20	896.47	9.68	0.01	420.14	19.66
			0.000 1	62.63	31.92
			0.000 01	67.47	30.15

3　结束语

针对当前自适应光学技术中存在的硬件成本高、效率低及像差检测不完全等技术缺陷,本文提出一种全新的简单自适应光学计算成像技术。该技术通过构建湍流退化图像和波前像差系数的网络模型,直接在图像层面通过深度学习算法代替波前探测器件对波前像差进行解算。然后,基于解算波前像差对退化图像进行解卷积操作代替波前校正器,从而实现对观测目标的高分辨率恢复。实验结果表明,利用本文提出的技术,可实现用一幅系统焦面退化图像一次性高精度解算出大气湍流像差,并基于解算出的像差利用维纳滤波算法实现对观测目标的高质量恢复。该方法完全摆脱了基于硬件的自适应光学,极大降低了系统的硬件成本且无需迭代,能有效避免迭代校正带来的系统不完全校正误差和校正时间长的缺点,为自适应光学领域提供一种可参考的、有效的简单自适应光学高分辨计算成像技术。

参考文献:

[1] 姜文汉. 自适应光学技术[J]. 自然杂志, 2006, 28(1): 7-13.
Jiang Wen-han. Adaptive optics technology[J]. Natural Science Journal, 2006, 28(1): 7-13.

[2] 张雨东, 饶长辉, 李新阳. 自适应光学及激光操控[M]. 北京: 国防工业出版社, 2016.

[3] 杨尚君, 梁静远, 吴加丽, 等. 逆向传输标定法校正自适应光学非共光路像差[J]. 光学学报, 2023, 43(12): 102-112.
Yang Shang-jun, Liang Jing-yuan, Wu Jia-li, et al. Calibration of adaptive pptics non-coaxial optical path aberrations by reverse transmission method[J]. Acta Optica Sinica, 2023, 43(12): 102-112.

[4] 吴加丽, 柯熙政. 无波前传感器的自适应光学校正[J]. 激光与光电子学进展, 2018, 55(3): 133-139.
Wu Jia-li, Ke Xi-zheng. Adaptive optical correction

of wavefront free sensor[J]. Laser and Optoelectronics Progress, 2018, 55(3): 133-139.

[5] Song H, Fraanje R, Schitter G, et al. Model-based aberration correction in a closed-loop wavefront-sensor-less adaptive optics system[J]. Optics Express, 2010, 18(23): No. 24070.

[6] 雍佳伟, 田雨, 许克峰,等. 一种结合图像复原技术的自适应光学系统控制方法[J]. 物理学报, 2020, 69(6): 253-262.
Yong Jia-wei, Tian Yu, Xu Ke-feng, et al. An adaptive optical system control method combined with image restoration [J]. Acta Physica Sinica, 2020, 69(6): 253-262.

[7] 刘有海, 秦天翔, 王英策, 等. 简单光学成像技术及其研究进展[J]. 物理学报, 2023, 72(8): 119-144.
Liu You-hai, Qin Tian-xiang, Wang Ying-ce, et al. Simple optical imaging technology and its research progress[J]. Acta Physica Sinica, 2019, 72(8): 119-144.

[8] 王新华, 郝建坤, 黄玮, 等. 基于简单透镜计算成像的图像复原重建[J]. 吉林大学学报: 工学版, 2017, 47(3): 965-972.
Wang Xin-hua, Hao Jian-kun, Huang Wei, et al. Image restoration and reconstruction based on simple lens computational imaging[J]. Journal of Jilin University (Engineering and Technology Edition), 2017, 47 (3):965-972.

[9] Nishizaki Y, Valdivia M, Horisaki R, et al. Deep learning wavefront sensing[J]. Optics Express, 2019, 27(1): 240-251.

[10] Tian Q H, Lu C D, Liu B, et al. DNN-based aberration correction in a wavefront sensorless adaptive optics system[J]. Optics Express, 2019, 27(8): 10765-10776.

[11] Guo H Y, Xu Y J, Li Q, et al. Improved machine learning approach for wavefront sensing[J]. Sensors, 2019, 19(16): No. s19163533.

[12] 石保顺, 吴一凡, 练秋生. 基于内-外部互补先验的亚像素分辨率衍射成像算法研究[J]. 燕山大学学报, 2023, 47(4): 347-358.
Shi Bao-shun, Wu Yi-fan, Lian Qiu-sheng. Sub-pixel resolution diffraction imaging algorithm based on internal-external complementary prior[J]. Journal of Yanshan University, 2023, 47(4): 347-358.

[13] 石保顺, 吴一凡, 练秋生. 基于无监督学习的编码衍射成像方法研究[J]. 燕山大学学报, 2023, 47(1): 54-63.
Shi Bao-shun, Wu Yi-fan, Lian Qiu-sheng. Research on coding diffraction imaging based on unsupervised learning[J]. Journal of Yanshan University, 2023, 47(1): 54-63.

[14] 陈欣欣, 苑克娥, 时东锋, 等. 大气湍流对空基光学成像系统影响的仿真研究[J]. 光学学报, 2022, 42(18): 1-9.
Chen Xin-xin, Yuan Ke-e, Shi Dong-feng, et al. Simulation study on the effect of atmospheric turbulence on space-based optical imaging system[J]. Acta Optica Sinica, 2022, 42(18): 1-9.

[15] 饶瑞中, 袁仁民. 实验室湍流模拟装置在大气光学中的应用[J]. 光学学报, 2023, 43(12): 9-15.
Rao Rui-zhong, Yuan Ren-min. Application of laboratory turbulence simulator in atmospheric optics[J]. Acta Optica Sinica, 2023, 43(12): 9-15.

[16] 陈民安. 基于神经网络的无线光波前校正理论与实验研究[D]. 合肥: 中国科学技术大学信息科学技术学院, 2020.
Chen Min-an. Theoretical and experimental research of wireless light wavefront correction based on neural network[D]. Hefei: School of Information Science and Technology, University of Science and Technology of China, 2020.

[17] 林嘉. 基于EfficientNet的行人重识别及目标识别研究[D]. 南京: 南京邮电大学通信与信息工程学院, 2024.
Lin Jia. Research on pedestrian re-recognition and Ntarget recognition based on EfficientNet [D]. Nanjing: School of Communication and Information Engineering, Nanjing University of Posts and Telecommunications, 2024.

[18] 宝音图, 刘伟, 牛朝阳, 等. 联合集成学习与EfficientNet的光学遥感图像场景分类[J]. 计算机工程, 2021, 47(10): 226-235.
Bao Yin-tu, Liu Wei, Niu Zhao-yang, et al. Optical remote sensing image scene classification based on combined ensemble learning and EfficientNet[J]. Computer Engineering, 2021, 47(10): 226-235.

[19] Michael J A, Peter A, Marfo Y M, et al. The use of Efficientnet_b0 network to identify COVID-19 in chest X-ray images[J]. Journal of Electrical Systems and Information Technology, 2024, 11(1): No. s43067.

[20] 王允森, 王勇, 左晨, 等. 基于维纳滤波和综合评价因子的遥感图像复原[J]. 空间电子技术, 2021, 18(3): 13-20.
Wang Yun-sen, Wang Yong, Zuo Chen, et al. Remote sensing image restoration based on Wiener filter and comprehensive evaluation factor[J]. Space Electronics Technology, 2021, 18(3): 13-20.