

一种基于光强图像深度学习的波前复原方法

马慧敏*, 焦俊, 乔焰, 刘海秋, 高彦伟

安徽农业大学信息与计算机学院, 安徽 合肥 230031

摘要 基于深度学习的波前复原方法是利用训练好的卷积神经网络(CNN)模型并直接根据输入的光强图像得到波前像差的 Zernike 系数,不需要进行迭代计算,方法简单易于实现,便于快速获取相位。CNN 的训练是通过大量畸变远场光强图像和其对应的 Zernike 波前系数数据进行训练,自动提取光强图像特征,学习光强和 Zernike 系数的关系。本研究基于 35 阶 Zernike 大气湍流像差,建立了基于 CNN 的波前复原模型,通过分析该方法对静态波前畸变的复原能力,验证了基于 CNN 的波前复原方法的可行性及复原能力。

关键词 成像系统; 自适应光学; 波前复原; 深度学习; 卷积神经网络; 非迭代复原方法

中图分类号 O436

文献标志码 A

doi: 10.3788/LOP57.081103

Wavefront Restoration Method Based on Light Intensity Image Deep Learning

Ma Huimin*, Jiao Jun, Qiao Yan, Liu Haiqiu, Gao Yanwei

College of Information and Computer, Anhui Agriculture University, Hefei, Anhui 230031, China

Abstract Wavefront restoration based on deep learning is to obtain Zernike coefficients of wavefront aberration directly from the input light intensity image using the trained convolutional neural network (CNN) model. This method has many advantages, such as without iterative calculation, simple and easy to implement, and easy to quickly obtain phase. The training of CNN is carried out by training a large number of light intensity images of distorted far field and their corresponding Zernike wavefront coefficients, automatically extracting the characteristics of light intensity images, and learning the relationship between light intensity and Zernike coefficients. In this paper, a CNN-based wavefront restoration model is established based on the 35-order Zernike-atmospheric turbulence aberration. By analyzing the ability of this method to restore static wavefront distortion, the feasibility and restoring ability of the CNN based wavefront restoration are verified.

Key words imaging systems; adaptive optics; wavefront restoration; deep learning; convolutional neural network; non-iterative restoration method

OCIS codes 110.1085; 010.1080; 200.4260

1 引言

自适应光学是补偿成像过程中由大气湍流或其他因素造成的波前畸变的有力手段。由测量的光强信息来恢复丢失的相位信息的技术是一类成像系统结构简单的复原技术。1972 年 Gerchberg 等^[1]提出根据已知像平面和衍射平面上的强度分布来重构波前的相位分布,即 GS 算法。1973 年, Misell^[2]仿照 GS 算法,提出由已知两个具有不同离焦值的离

焦像的强度分布重构出波函数的相位分布。1982 年 Gonsalves^[3]提出相位差异(PD)技术,其核心思想是利用焦面和离焦面上的两个 CCD 传感器同时采集目标图像,通过极大似然估计理论构建迭代优化模型,联合估计目标图像和波前相位。2011 年杨慧珍等^[4]在 PD 方法的基础上,把模式分解和随机并行梯度下降算法结合起来实现波前相位的复原。上述这类基于光强测量的波前复原方法对待测波前是否连续没有要求,既可用于连续波前测量,也可用

收稿日期: 2019-09-02; 修回日期: 2019-09-09; 录用日期: 2019-09-12

基金项目: 国家自然科学基金(61905002)、安徽省高校自然科学研究资助项目(KJ2019A0210)

* E-mail: huiminma@ahau.edu.cn

于非连续波前的测量,但是这类方法计算量大,迭代速度慢,不利于实时应用。

1990年,Angel等^[5]建立了基于三层全连接神经网络的自适应光学波前复原仿真模型,实现了多望远镜系统波前畸变中的 piston 及倾斜像差的复原。1991年,Sandler等^[6-7]实现了该系统的闭环运行,证明了基于人工神经网络自适应光学复原低阶大气湍流像差的可行性,Zernike 阶数达到 11 阶。1993年,Barrett等^[7]将该技术用于哈勃望远镜的低价像差校正中。对于这类复原方法,在线的自适应光学闭环只需光强图像测量,利用线下已经训练好的模型就可以快速进行复原波前。但是对于高阶像差的复原,以光强图像数据作为网络输入,会使光斑扩展,输入节点参量呈非线性增加,网络的训练变得极为困难,极易陷入局部极值并出现过拟合问题。

自从 2012 年 Krizhevsky 等^[8]建立了一个 8 层卷积神经网络(CNN)以来,CNN 在图像识别方面取得了很大的进展,其对图像分类的准确度已经远超其他传统的分类方法,基于 CNN 深度学习的发展也开启了一个人工智能的新时代。AlexNet 以及后续涌现出的 VGGNet^[9]、GoogLeNet^[10]、ResNet^[11]等优秀网络,均已在人脸识别^[12]、目标识别^[13]、运动分析^[14]、自然语言处理^[15]等方面有所突破,并且在人工智能方面取得了突飞猛进的发展。自 2017 年,国内外研究者也初步开始了深度学习在光学工程方面的研究。Nguyen 等^[16]提出基于深度学习的数字全息显微镜获得无像差定量相位成像,通过构建 U 型 CNN 自动检测背景区域,以此代替了传统的手动检测,再结合 Zernike 多项式拟合共轭相位以补偿大多数像差。Fei 等^[17]提出了一种基于 CNN 的眼底图像清晰化算法,实现了不重建点扩展函数的盲解卷积。Zhang 等^[18]提出了一种利用 U 型 CNN 恢复显微样品原始相位的快速数字聚焦方法,将该方法应用于实时离轴数字全息显微镜的构建,在成像速度上取得了重大突破。Park 等^[19]通过连续性方程表明图像湍流和光子传输之间的联系,设计了基于 CNN 的解码方法并与传统的方法进行对比,结果表明新方法可以获得相似的误码率,计算量仅为原来的 1/90。Lohani 等^[20-21]基于 CNN 并利用光强图像实现了对拉盖尔-高斯光束模式轨道角动量(OAM)的分类,同时结合梯度下降优化算法构建光学反馈网络,通过数值仿真证明该网络能够实现湍流对 OAM 影响的校正。Paine 等^[22]实现了基于 GoogLeNet 的像差复原,利用焦平面单帧光

强图像来预测畸变波前的 Zernike 系数,研究认为使用机器学习操作点扩展函数可以估计波前初始值。本文在 PD 复原方法的理论基础上,基于焦平面和离焦平面两帧光强图像,利用 CNN 自动提取光强图像特征实现非迭代复原相位,即线下利用焦平面和离焦平面两帧光强图像作为输入、畸变波前的 Zernike 系数作为输出训练 CNN,最终实现线上从两帧光强图像到畸变波前 Zernike 系数端到端的直接输出。本研究拟建立基于 CNN 的波前复原仿真模型,探索基于 CNN 的波前复原能力,能够为新型的自适应光学波前复原技术的发展提供新思路。

2 基于 CNN 的波前复原方法

2.1 CNN 波前复原方法

基于 CNN 的波前复原基本原理如图 1 所示,光路示意图如图 1(a)所示。初始的畸变波前以正交的 Zernike 多项式作为展开基函数来表示,可以写为^[23]

$$\varphi(x, y) = \sum_{i=1}^N a_i z_i(x, y), \quad (1)$$

式中: $\varphi(x, y)$ 表示生成的相位; a_i 为第*i*项 Zernike 多项式的系数; $z_i(x, y)$ 为第*i*项 Zernike 多项式; N 为 Zernike 阶数。当平面波从携带该像差的介质透射时,产生入射初始畸变光场 $U_0(x, y)$,光波成像于远场的两 CCD 上,分别形成焦平面和离焦面的光强图像,焦平面光场复振幅 $U_1(f_x, f_y)$ 可以通过对入射光场 $U_0(x, y)$ 作傅里叶变换得到,即

$$U_1(f_x, f_y) = C_1 \mathfrak{F}[U_0(x, y)], \quad (2)$$

式中: C_1 为复常数; \mathfrak{F} 为傅里叶变换。离焦面的光场复振幅 $U_2(f_x, f_y)$ 可以表示为

$$U_2(f_x, f_y) = C_2 \mathfrak{F}\{U_0(x, y) \exp[-i\varphi_d(x, y)]\}, \quad (3)$$

式中: C_2 为复常数; $\varphi_d(x, y)$ 为离焦波前。焦平面和非焦平面的光强为光场复振幅的平方,即

$$I_1(x, y) = U_1^2(f_x, f_y), \quad I_2(x, y) = U_2^2(f_x, f_y). \quad (4)$$

焦平面和离焦平面的图像信息包含了波前误差信息,对该系统采用 CNN 来提取 Zernike 系数,然后对波前进行拟合,从而得到系统的波前信息。CNN 的训练和预测数据结构如图 1(b)所示。CNN 需要对大量数据进行离线训练,将大量的静态畸变波前的 Zernike 系数和其对应的 CCD 上的光强图像数据作为 CNN 的输入,利用设计好的 CNN 模型进行训练。基于 CNN 的波前复原过程可以等价

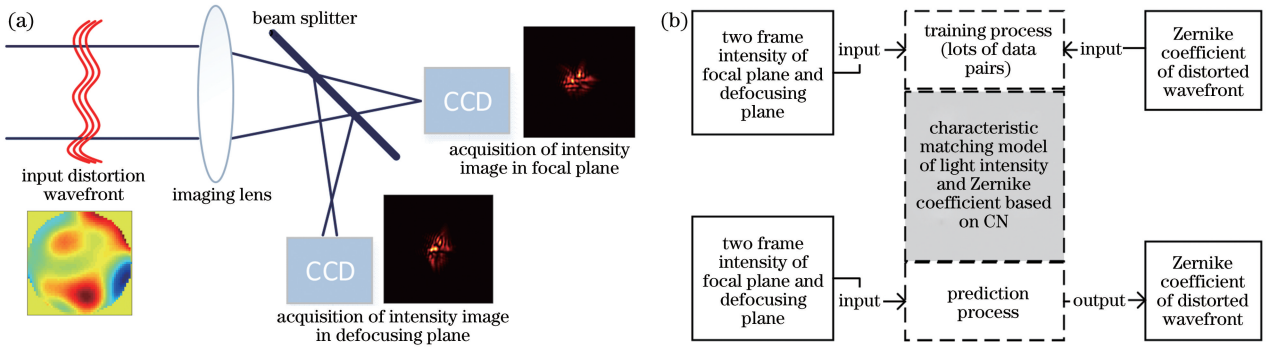


图 1 基于 CNN 波前复原的基本原理图。(a)光路示意图;(b) CNN 的训练和预测数据结构

Fig. 1 Basic principle diagram of wavefront restoration based on CNN. (a) Diagram of optical path; (b) training and prediction data structure of CNN

一个非线性变换,将两幅光强数据 $I_1(x, y)$ 、 $I_2(x, y)$ 作为输入,则其对应的畸变波前 Zernike 系数 $\{a_1, a_2, \dots, a_N\}$ 通过训练好的模型后可表示为

$$\{a_1, a_2, \dots, a_N\} = f_{\text{CNN}}[I_1(x, y), I_2(x, y)], \quad (5)$$

式中: $f_{\text{CNN}}(\cdot)$ 为 CNN 模型。波前预测过程中,实

时测量的两帧光强图像作为输入,预测的畸变的 Zernike 系数是网络的输出。

2.2 CNN 方法原理

CNN 的基本结构如图 2 所示,其主要包括输入层、卷积层、池化层、全连接层以及 Softmax 层等层级结构组。




图 2 用于波前复原的 CNN 结构示意图

Fig. 2 Diagram of CNN structure used for wavefront restoration

卷积层中通常包含若干个特征平面(map),每个特征平面由一些矩形排列的神经元组成,一个神经元只与部分邻层神经元连接,同一特征平面的神经元共享权值,共享的权值就是卷积核。卷积核一般以随机小数矩阵的形式进行初始化,在网络的训练过程中卷积核将通过学习得到合理的权值。共享权值(卷积核)带来的直接好处是减少网络各层之间的连接,同时又降低了过拟合的风险。卷积层的工作过程可表示为^[24]

$$x_j^l = f\left(\sum_{i \in M_i} x_i^{l-1} \times k_{ij}^l + b_j^l\right), \quad (6)$$

式中: $f(\cdot)$ 为 ReLU 激励函数; M_i 是输入特征 map 的集合; b_j^l 为额外偏置项; x_j^l 为第 l 层第 j 个元素; x_i^{l-1} 为第 $l-1$ 层第 i 个元素; k_{ij}^l 为第 l 层元素 ij 对应的权重系数。在该过程中,对上一个层级的 map 进行卷积核处理后,再利用激励函数便可以得到新一层的特征 map。

池化层也叫降采样层,通常有均值降采样和最大值降采样两种形式。降采样可以看作一种特殊的卷积过程,其过程可以表示为

$$x_j^l = \text{down}(x_j^{l-1}), \quad (7)$$

式中: $\text{down}(\cdot)$ 表示下采样。在最大值降采样模式中,每次只取出 1 个指定大小为 $n \times n$ 的滤子中的最大值,进而重新构成新的特征 map。卷积和降采样操作可以大大简化模型复杂度,减少模型的参数。

最后经过 Softmax 分类,在本研究中分类的结果就是畸变波前的 Zernike 系数,因此在归一化后得出 1 个长度为 N 的向量。在训练过程中通过随机梯度下降法(SGD),使得互熵损失函数达到最小。损失函数为

$$f_{\text{loss}} = \sum_i (y_i - y_{\text{predicted},i})^2 + \sum_i |y_i - y_{\text{predicted},i}|, \quad (8)$$

式中: y_i 为真实的 Zernike 系数; $y_{\text{predicted},i}$ 为预测的 Zernike 系数。模型训练时采用 SGD 算法使每一次迭代使用所述样本进行参数学习和更新, 每一代的参数学习和更新可表示为

$$V_{i+1} = \mu V_i - \alpha \nabla f_{\text{loss}}(W_i), \quad (9)$$

$$W_{t+1} = W_t + V_{t+1}, \quad (10)$$

式中: W_t 为 t 时刻的参数; V_t 为 t 时刻的增量; α 为学习速率; μ 为前一次更新的权重; $\nabla f_{\text{loss}}(W_i)$ 为损失函数的偏微分。

3 CNN 模型的建立与训练实施

3.1 数据集生成方法

CNN 的样本数据集生成方法如下。

根据 Kolmogorov 湍流理论, 可以得到 Zernike 多项式系数向量 $\mathbf{A} = \{a_1, a_2, \dots, a_N\}$ 的协方差矩阵 $\mathbf{C}^{[25]}$, 则有

$$\langle a_i, a_j \rangle = c_{ij} \left(\frac{D}{r_0} \right)^{5/3}, \quad (11)$$

式中: c_{ij} 为协方差系数; a_i, a_j 分别为第 i, j 阶

表 1 训练及测试的数据量描述

Table 1 Description of training and testing data volumes

Dataset No.	D/r_0	Training dataset			Test dataset		
		D/r_0 interval	Data volume/ interval	Total data volume	D/r_0 interval	Data volume/ interval	Total data volume
1	5	—	100	15000	—	10	1500
2	15	—	100	15000	—	10	1500
3	1-15	1	100	15000	1	10	1500

3.2 CNN 模型构建

本研究中采用的 CNN 模型的网络层数为 8 层, 其结构示意图如图 3 所示。

各个层的参数汇总如表 2 所示, 每一层的输出是下一层的输入, 第一层和最后一层分别为数据输

Zernike 系数; D 是光斑直径; r_0 是大气相干长度, $r_0 = (0.423k^2 C_n^2 z)^{-3/5}$, $k = \frac{2\pi}{\lambda}$, λ 是波长, C_n^2 为大气湍流结构常数。系数矩阵 \mathbf{A} 可由 Karhunen-Loeve 多项式求得

$$\begin{cases} \mathbf{C} = \mathbf{V}\mathbf{S}\mathbf{V}^T \\ \mathbf{A} = \mathbf{V}\mathbf{B} \end{cases}, \quad (12)$$

式中: \mathbf{S} 是对角阵; \mathbf{V} 是 Karhunen-Loeve 多项式系数矩阵; \mathbf{B} 是相位 $\varphi(x, y)$ 的系数。生成 \mathbf{A} , 再由 $\varphi(x, y) = \sum_{i=1}^{\infty} a_i z_i(x, y)$ 得到符合 Kolmogorov 湍流谱的大气湍流畸变波前。畸变波前对应的焦平面和非焦平面的光强图像通过(4)式计算得到。本研究中为训练及测试准备了三组数据集, 其详细数据量如表 1 所示。仿真中, 随机生成的 15000 组 Zernike 系数 $\{a_1, a_2, \dots, a_N\}$ 和光强图像 $I_1(x, y)$ 、 $I_2(x, y)$ 的数据作为样本输入用于网络训练, 并以同样方式生成 1500 组测试样本数据, 测试样本和训练样本没有重复数据。

入层和分类输出层, 具体包括:

数据准备, 用于接收光强图像, 数据输入层的大小为 $224 \times 224 \times 2$, 即 224×224 的二通道图像, 其中一个通道是一帧焦平面上的光强亮度图像, 另一个通道是一帧离焦面的光强亮度图像。




图 3 用于波前复原的 8 层 CNN 模型

Fig. 3 Eight-layer CNN model for wavefront restoration

第一层是 Conv1 层, 这一层的操作包括一次卷积操作、一次池化操作和一次归一化操作, 卷积核的大小为 11×11 , 卷积移动步长为 4, 卷积核数为 64, 池化方式为最大值池化, 池化卷积核的尺寸为 $3 \times$

3, 移动步长为 2, 并且使用 ReLU 函数对神经元激活函数进行归一化。

第二层是 Conv2 层, 这一层的操作包括一次卷积操作、一次池化操作和一次归一化操作, 卷积核的

大小为 5×5 , 卷积移动步长为 1, 边缘填充为 1, 卷积核数为 192, 池化方式为最大值池化, 池化卷积核的尺寸为 3×3 , 移动步长为 2, 并且使用 ReLU 函数作为神经元激活函数进行归一化。

第三层是 Conv3 层, 这一层的操作包括一次卷积操作和一次归一化操作, 卷积核的大小为 3×3 , 边缘填充为 1, 卷积核数为 384, 使用 ReLU 函数对神经元激活函数进行归一化。

第四层是 Conv4 层, 这一层的操作包括一次卷积操作和一次归一化操作, 卷积核的大小为 3×3 , 边缘填充为 1, 卷积核数为 384, 使用 ReLU 函数为神经元激活函数进行归一化。

第五层是 Conv4 层, 这一层的操作包括一次卷积操作、一次池化操作和一次归一化操作, 卷积核的大小为 3×3 , 边缘填充为 1, 卷积核数为 256, 池化方式为最大值池化, 池化卷积核的尺寸为 3×3 , 移动步长为 2, 并且使用 ReLU 函数对神经元激活函数进行归一化。

第二至五层用于提取光强图像局部特征, 并缩小模型的大小, 提高计算速度, 同时提高所提取特征的鲁棒性。

第六层和第七层均为全连接层, 用于将上述提取到的局部特征综合起来。

第八层为分类输出层, 使用的激活函数为 tanh 函数, 输出层的大小为 $N \times 1$ 。

表 2 用于波前复原的 CNN 网络模型参数表

Table 2 Parameters of CNN network model for wavefront restoration

Layer No.	Type	Image size	Filter size	Stride	Padding	Number of kernels
0	Input	$224 \times 224 \times 2$	—	—	—	—
	Conv1	$224 \times 224 \times 2$	11×11	4	—	64
1	Pooling1	$55 \times 55 \times 64$	3×3	2	—	—
	ReLU	$55 \times 55 \times 64$	—	—	—	—
	Conv2	$27 \times 27 \times 64$	5×5	1	2	256
2	Pooling2	$27 \times 27 \times 192$	3×3	2	—	—
	ReLU	$13 \times 13 \times 192$	—	—	—	—
	Conv3	$13 \times 13 \times 192$	3×3	—	1	384
3	ReLU	$13 \times 13 \times 384$	—	—	—	—
	Conv3	$13 \times 13 \times 384$	3×3	—	1	384
4	ReLU	$13 \times 13 \times 384$	—	—	—	—
	Conv4	$13 \times 13 \times 384$	3×3	—	1	256
5	Pooling4	$13 \times 13 \times 256$	3×3	2	—	—
	ReLU	$13 \times 13 \times 256$	—	—	—	—
6	Fully connected	$6 \times 6 \times 256$	—	—	—	—
7	Fully connected	4096×1	—	—	—	—
8	Tanh and output	$N \times 1$	—	—	—	—

4 仿真结果与分析

4.1 模型训练结果

本仿真中, CNN 的实施采用 julia 语言的 flux 深度学习库^[26], 实验所用计算机为 Windows7 系统, 硬件环境为: Inter 酷睿 I5-4590 CPU, 主频 3.3 GHz, 8 GB DDR3 RAM, Geforce 1050 GPU。仿真中, 针对 3.1 节建立的三组数据集分别进行训练, α 初始值分别设为 1×10^{-5} , 1×10^{-5} , 2×10^{-6} , Batch 大小为 60, 每个 Epoch 需要 250 次迭代, 训练的三组模型记为 CNNM1, CNNM2, CNNM3, 每个模型的训练时间为 7×24 h。图 4 给出了三组数据集网络训练及测试过程中的损失函数变化曲线, 实线为训练集损失函数变化, 虚线为测试集损失函数

变化。从结果可以看出, 对于 CNNM1、CNNM2 和 CNNM3 三个模型的训练, 400 个 Epoch 训练的结果中训练损失值和测试损失值都趋于稳定。

4.2 波前复原结果

随机生成的一帧 $D/r_0 = 5$ 的波前畸变及相应的复原效果如图 5 所示, 待复原波前峰谷 (PV) 值为 4.8047 λ , 均方根 (RMS) 为 0.1483 λ 。图 5(a) 为待复原波前图, 图 5(b1)、5(b2) 为焦平面和离焦面的两帧光强, 复原时将图 5(b1)、5(b2) 两幅图输入训练好的模型矩阵中进行计算, 即可得到复原的波前。图 5(c1) 为 CNNM1 复原的波前, 图 5(c2) 为 CNNM1 复原后的残余像差, 其 PV 值为 0.7412 λ , RMS 为 0.0282 λ ; 图 5(d1)、(d2) 分别为 CNNM3 复原的结果和复原后的残余像差, 其 PV 值为

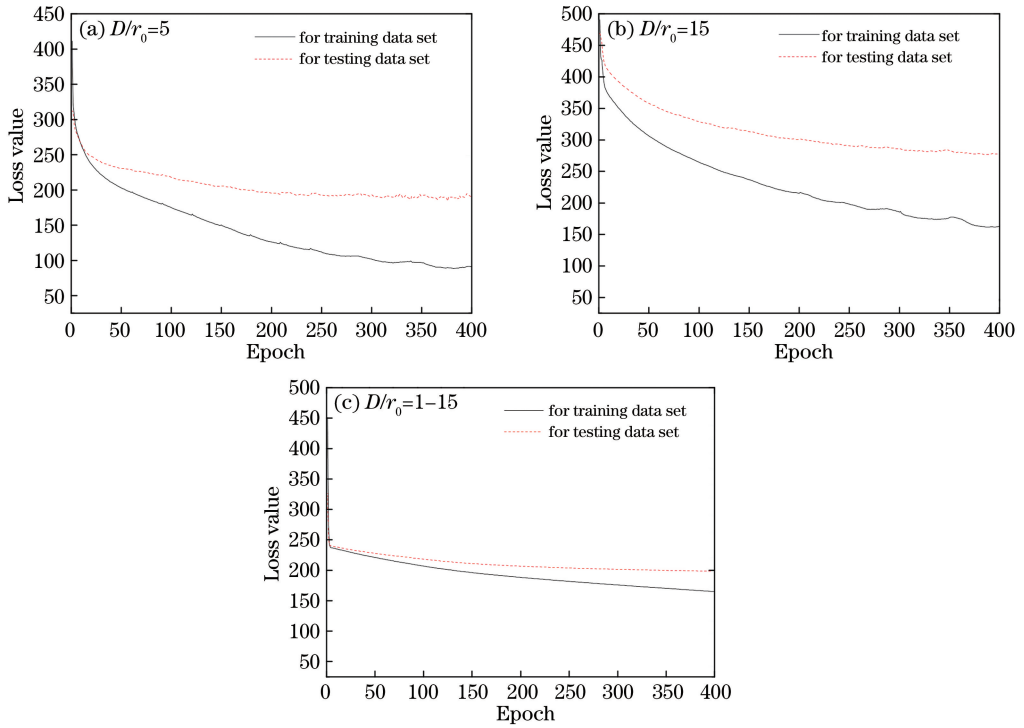


图 4 网络训练及测试过程中的损失函数变化曲线。(a) $D/r_0=5$; (b) $D/r_0=15$; (c) $D/r_0=1\sim 15$

Fig. 4 Loss function curves in network training and testing processes. (a) $D/r_0=5$; (b) $D/r_0=15$; (c) $D/r_0=1\sim 15$

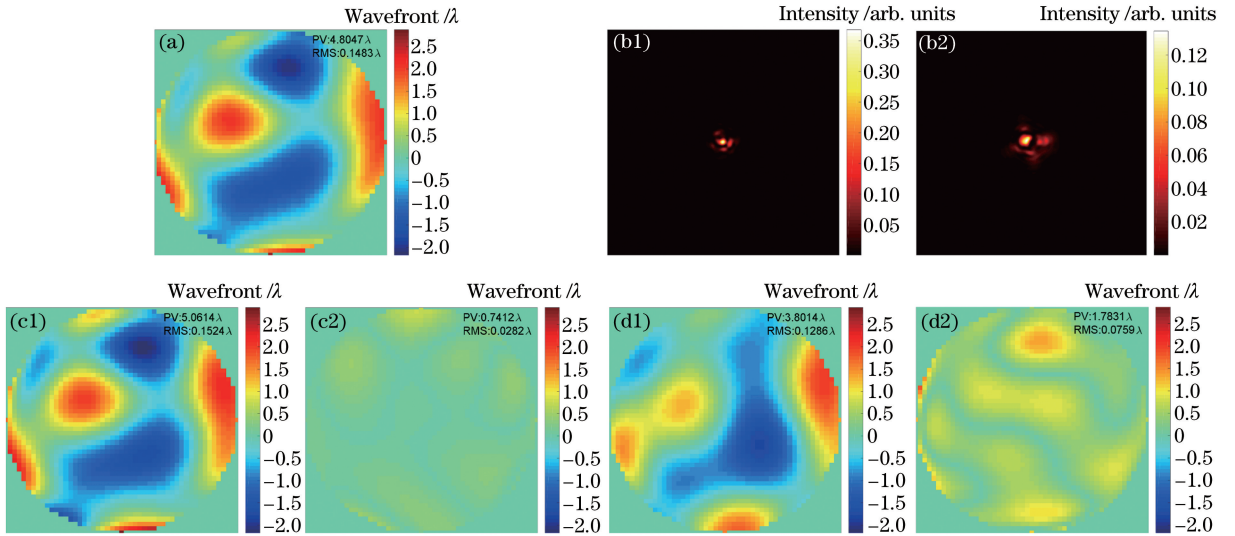


图 5 $D/r_0=5$ 随机生成的一帧像差和复原结果。(a) 待复原波前图; (b1) 焦平面和 (b2) 离焦面的两帧光强; (c1) CNNM1 复原的波前; (c2) CNNM1 复原后的残余像差; (d1) CNNM3 复原的结果; (d2) CNNM3 复原后的残余像差

Fig. 5 Single-frame aberration randomly generated at $D/r_0=5$ and its restoration results. (a) Wavefront to be restored; intensity images of (b1) focal plane and (b2) defocus plane; (c1) wavefront restored by CNNM1; (c2) residual aberration restored by CNNM1; (d1) wavefront restored by CNNM3; (d2) residual aberration restored by CNNM3

1.7831 λ , RMS 为 0.0759 λ 。同上,图 6 是随机生成一帧 $D/r_0=15$ 的波前畸变及相应的复原效果。图 6(c1)为 CNNM2 复原的波前,图 6(c2)为 CNNM2 复原后的残余像差,其 PV 值为 6.7277 λ , RMS 为 0.1612 λ ;图 6(d)为 CNNM3 复原的结果,复原后的残余像差,其 PV 值为 6.2761 λ , RMS 为 0.2630 λ 。

从图 5、图 6 可以看出:CNNM1 对 $D/r_0=5$ 的初始畸变有很好的复原效果,CNNM2 对 $D/r_0=15$ 的初始畸变也有较好的复原效果,复原出的波前和原始波前形状有很好的相似性;CNNM3 对 $D/r_0=5$ 和 $D/r_0=15$ 初始畸变也有一定的复原效果,但是效果不如前者。

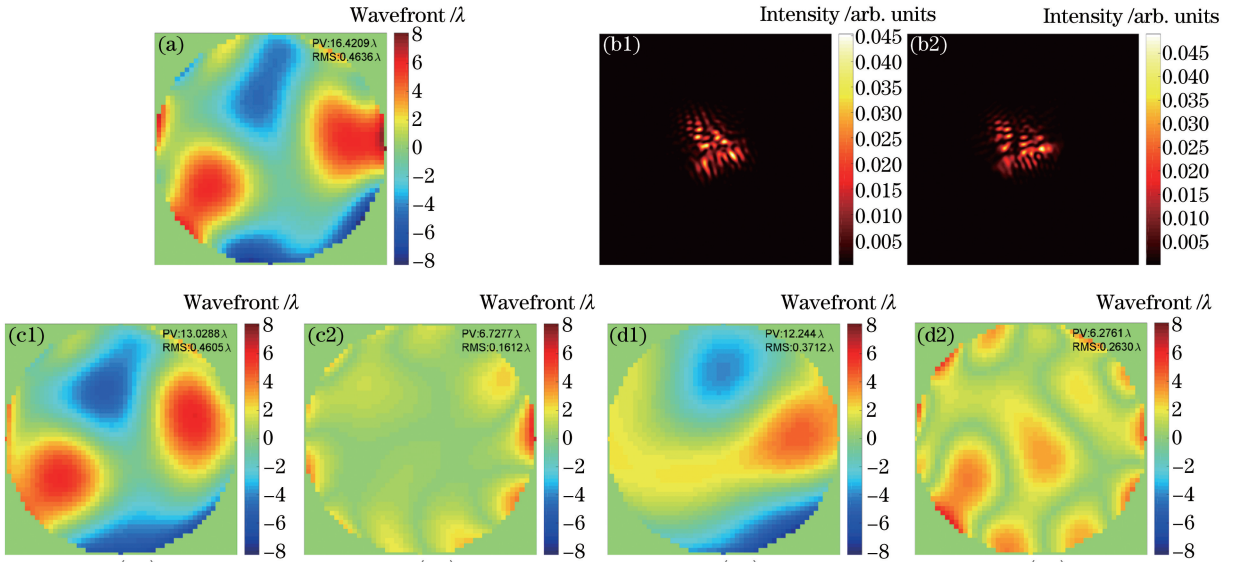


图 6 $D/r_0=15$ 随机生成的一帧像差和复原结果。(a)待复原波前图;(b1)焦平面和(b2)离焦面的两帧光强;

(c1) CNNM2 复原的波前;(c2) CNNM2 复原后的残余像差;(d1) CNNM3 复原的结果;(d2) CNNM3 复原后的残余像差
Fig. 6 Single-frame aberration randomly generated at $D/r_0=15$ and its restoration results. (a) Wavefront to be restored; intensity images of (b1) focal plane and (b2) defocus plane; (c1) wavefront restored by CNNM2; (c2) residual aberration restored by CNNM2; (d1) wavefront restored by CNNM3; (d2) residual aberration restored by CNNM3

图 7 为待复原波前的真实 Zernike 系数和 CNN 复原的 Zernike 系数对比,从图中可以看出,对于

$D/r_0=5$ 和 $D/r_0=15$ 的像差,CNNM1 和 CNNM2 要比 CNNM3 预测的 Zernike 系数误差小。

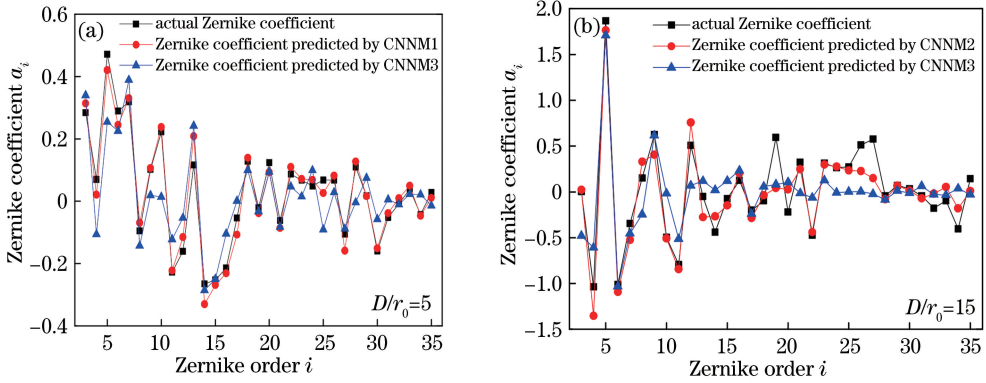


图 7 CNNM1、CNNM2 和 CNNM3 预测的 Zernike 系数和实际 Zernike 系数的对比。(a) $D/r_0=5$;(b) $D/r_0=15$

Fig. 7 Comparison between actual Zernike coefficient and predicted Zernike coefficients by CNNM1, CNNM2, and CNNM3. (a) $D/r_0=5$; (b) $D/r_0=15$

图 8 给出了利用三组训练好的 CNN 模型分别对 1500 组测试数据集进行测试后的远场光强轴上 Strehl 比的统计结果,圆形数据点为初始畸变对应的 Strehl 比,方形数据点为经 CNN 模型复原后残余波前对应的 Strehl 比。图 8(a)是网络 CNNM1 对 1500 组 $D/r_0=5$ 的畸变波前的复原结果,图中共给出 15 组数据点,每个数据点均是测试集中 100 组结果的平均;同样,图 8(b)给出了网络 CNNM2 对 1500 组 $D/r_0=15$ 的畸变波前的复原结果;图 8(c)是网络 CNNM3 对 1500 组 $D/r_0=1\sim 15$ 的畸

变波前的复原结果。从图中可以看出:对于 $D/r_0=5$ 的畸变,使用 CNNM1 和 CNNM3 时 Strehl 比能够从 0.25 分别提高到 0.9 和 0.8 左右;对于 $D/r_0=15$ 的畸变,使用 CNNM2 和 CNNM3 时 Strehl 比能够从 0 分别提高到 0.25 和 0.15 左右。

从图 5~图 8 可以看出:训练好的 CNN 模型对 Kolmogorov 湍流谱的大气湍流畸变波前有一定的复原能力;使用单一 D/r_0 数据集训练的模型要比多 D/r_0 数据集训练的模型复原的波前精度高,即该 CNN 模型对单一的 D/r_0 数据集的学习能力高

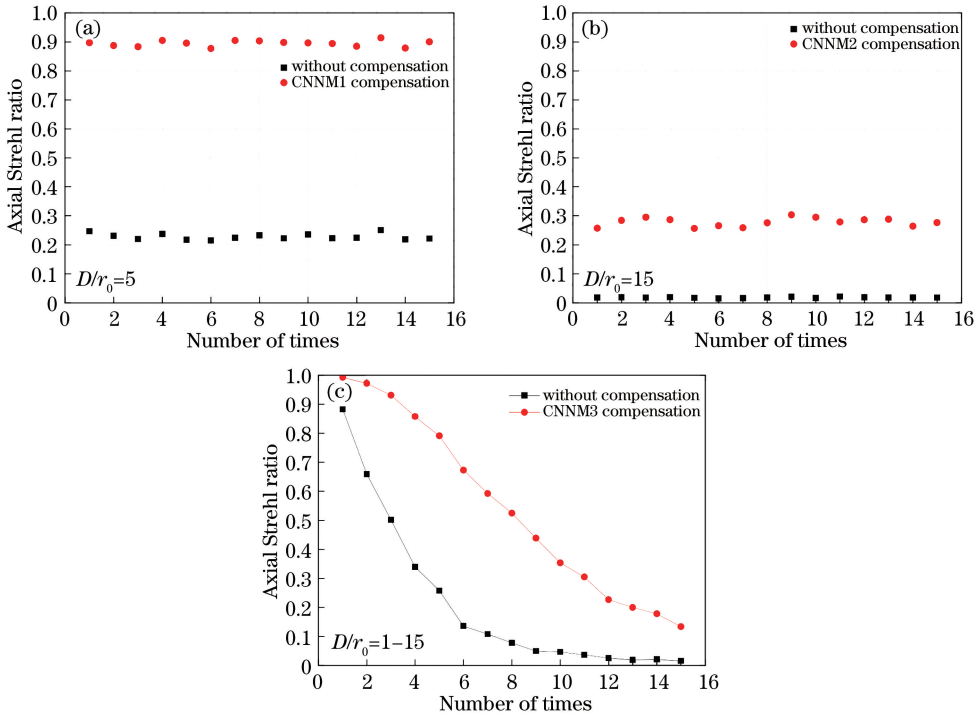


图 8 畸变波前补偿前后的轴上光强 Strehl 比。(a) $D/r_0 = 5$; (b) $D/r_0 = 15$; (c) $D/r_0 = 1 \sim 15$

Fig. 8 Strehl ratio of axial light intensity before and after distortion wavefront compensation.

(a) $D/r_0 = 5$; (b) $D/r_0 = 15$; (c) $D/r_0 = 1 \sim 15$

于多 D/r_0 数据集。在实际应用场景中,若提前测量 D/r_0 范围,则可以选用合适的模型来复原波前;若 D/r_0 范围无法获得,则可选用适用多 D/r_0 范围的 CNNM3。在本仿真测试中,复原计算的平均时间为 1.3 s,包括两帧光强图像的计算时间和网络预测相位的计算时间。

5 结 论

建立了基于 CNN 的波前复原方法,利用训练好的 CNN 模型直接根据输入的光强图像得到波前像差的 Zernike 系数。CNN 的训练是通过对大量畸变远场光强图像和其对应的 Zernike 波前系数数据进行训练,自动提取光强图像特征,学习光强和 Zernike 系数的关系。基于 35 阶 Zernike 大气湍流像差,建立了基于 CNN 的波前复原模型,针对 $D/r_0 = 5$ 、 $D/r_0 = 15$ 和 $D/r_0 = 1 \sim 15$ 三组像差数据集训练了三个模型,验证了基于 CNN 的波前复原方法的可行性和复原能力。结果表明:使用单一 D/r_0 数据集训练的模型要比多 D/r_0 数据集训练的模型复原的波前精度高,但是在实际中如果无法得知 D/r_0 ,则需要选用多 D/r_0 数据集训练的模型。下一步的研究工作将继续探索改进模型的方法,以提高多 D/r_0 数据集训练模型的波前复原精度。

该研究将人工智能深度学习的图像识别新方法应用于基于光强图像测量的波前复原中,提出的基于 CNN 的非迭代相位复原方法有助于相位信息的快速获取,能够为新型的自适应光学波前复原技术的发展提供新思路。但是该研究刚刚起步,还有很多问题有待该领域的学者进行深入研究,如构建适用于光强图像特征学习的网络、进一步优化网络模型提高复原精度、引入实际测量图像的噪声对网络的影响、湍流效应引起的光强闪烁对该方法复原的影响等。

参 考 文 献

- [1] Gerchberg R W, Saxton W O. A practical algorithm for the determination of phase from image and diffraction plane pictures [J]. *Optik*, 1972, 35(2): 237-246.
- [2] Misell L D. A method for the solution of the phase problem in electron microscopy [J]. *Journal of Physics D: Applied Physics*, 1973, 6(1): L6-L9.
- [3] Gonsalves R A. Phase retrieval and diversity in adaptive optics [J]. *Optical Engineering*, 1982, 21(5): 829-832.
- [4] Yang H Z, Gong C L. Phase retrieval for a kind of wavefront sensor based on pupil phase diversity [J].

- Acta Optica Sinica, 2011, 31(11): 1112002.
- 杨慧珍, 龚成龙. 一种基于瞳面相位差的波前传感器相位恢复[J]. 光学学报, 2011, 31(11): 1112002.
- [5] Angel J R P, Wizinowich P, Lloyd-Hart M, et al. Adaptive optics for array telescopes using neural-network techniques[J]. Nature, 1990, 348(6298): 221-224.
- [6] Sandler D G, Barrett T K, Palmer D A, et al. Use of a neural network to control an adaptive optics system for an astronomical telescope[J]. Nature, 1991, 351(6324): 300-302.
- [7] Barrett T K, Sandler D G. Artificial neural network for the determination of Hubble Space Telescope aberration from stellar images[J]. Applied Optics, 1993, 32(10): 1720-1727.
- [8] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[C]// Advances in Neural Information Processing Systems, December 3-6, 2012, Lake Tahoe, Nevada, United States. Canada: NIPS, 2012: 1097-1105.
- [9] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[J/OL]. (2015-04-10) [2019-09-01]. <https://arxiv.xile sou. top/abs/1409.1556>.
- [10] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions [C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE, 2015: 15523970.
- [11] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 770-778.
- [12] Long X, Su H S, Liu G H, et al. A face recognition algorithm based on angular distance loss function and convolutional neural network [J]. Laser & Optoelectronics Progress, 2018, 55(12): 121505.
龙鑫, 苏寒松, 刘高华, 等. 一种基于角度距离损失函数和卷积神经网络的人脸识别算法[J]. 激光与光电子学进展, 2018, 55(12): 121505.
- [13] Xie J R, Li F M, Wei H, et al. Infrared target simulation method based on generative adversarial neural networks[J]. Acta Optica Sinica, 2019, 39(3): 0311002.
谢江荣, 李范鸣, 卫红, 等. 基于生成对抗式神经网络的红外目标仿真方法[J]. 光学学报, 2019, 39(3): 0311002.
- [14] Zan B F, Kong J, Jiang M. Human action recognition based on discriminative collaborative representation classifier[J]. Laser & Optoelectronics Progress, 2018, 55(1): 011010.
管宝锋, 孔军, 蒋敏. 基于判别协作表征分类器的人体行为识别[J]. 激光与光电子学进展, 2018, 55(1): 011010.
- [15] Graves A, Mohamed A R, Hinton G. Speech recognition with deep recurrent neural networks[C]// 2013 IEEE International Conference on Acoustics, Speech and Signal Processing, May 26-31, 2013, Vancouver, BC, Canada. New York: IEEE, 2013: 6645-6649.
- [16] Nguyen T, Bui V, Lam V, et al. Automatic phase aberration compensation for digital holographic microscopy based on deep learning background detection [J]. Optics Express, 2017, 25(13): 15043-15057.
- [17] Fei X, Zhao J L, Zhao H X, et al. Deblurring adaptive optics retinal images using deep convolutional neural networks[J]. Biomedical Optics Express, 2017, 8(12): 5675-5687.
- [18] Zhang G, Guan T, Shen Z Y, et al. Fast phase retrieval in off-axis digital holographic microscopy through deep learning[J]. Optics Express, 2018, 26(15): 19388-19405.
- [19] Park S R, Cattell L, Nichols J M, et al. Demultiplexing vortex modes in optical communications using transport-based pattern recognition[J]. Optics Express, 2018, 26(4): 4004-4022.
- [20] Lohani S, Glasser R T. Turbulence correction with artificial neural networks[J]. Optics Letters, 2018, 43(11): 2611-2614.
- [21] Lohani S, Knutson E M, O'Donnell M, et al. On the use of deep neural networks in optical communications[J]. Applied Optics, 2018, 57(15): 4180-4190.
- [22] Paine S W, Fienup J R. Machine learning for improved image-based wavefront sensing[J]. Optics Letters, 2018, 43(6): 1235-1238.
- [23] Yang P, Ao M W, Liu Y, et al. Intracavity transverse modes controlled by a genetic algorithm based on Zernike mode coefficients [J]. Optics Express, 2007, 15(25): 17051-17062.
- [24] Goodfellow I, Bengio Y, Courville A. Deep learning [M]. Zhao S J, Li Y J, Fu T F, et al., Transl. Beijing: Posts & Telecom Press, 2017: 100-128.
Goodfellow I, Bengio Y, Courville A. 深度学习

- [M]. 赵申剑, 黎彧君, 符天凡, 等, 译. 北京: 人民邮电出版社, 2017: 100-128.
- [25] Roddier N A. Atmospheric wavefront simulation using Zernike polynomials [J]. *Optical Engineering*, 1990, 29(10): 1174-1180.
- [26] Innes M. Flux: elegant machine learning with Julia [J]. *Journal of Open Source Software*, 2018, 3(25): 602.