

远场光斑反演波前相位的深度学习方法

张 阳, 何宇龙, 宁 禹, 孙 全, 李 俊, 许晓军

(国防科技大学 前沿交叉学科学院, 湖南 长沙 410073)

摘要: 自适应光学系统中, 波前传感器的准确性和鲁棒性极大地影响像差探测能力和闭环校正效果。在波前振幅分布不均匀或信标光能量不足的情况下, 哈特曼波前传感器由于存在子孔径缺光现象会导致传感精度下降, 而基于远场光斑反演波前相位的无波前传感自适应系统实时性难以满足实用需求。基于深度学习复原波前的方法是通过输入远场光强图像直接求取像差, 可以作为自适应光学系统的有效补充。文中通过数值模拟, 证明了深度残差神经网络能够通过远场光斑直接预测波前相位的 Zernike 系数。实验验证了输入与重构波前相位之间校正后残差 RMS 为 0.08λ , GPU 加速后的平均计算耗时小于 2 ms。该方法能较准确地预测入射波前畸变的 Zernike 系数, 具有一定像差校正能力, 适合在传统自适应光学技术中, 用于测量并校正波前畸变的主要成分, 或为优化式自适应光学提供良好的初始波前估计。

关键词: 波前相位反演; 自适应光学; 无波前传感自适应校正; 深度残差网络

中图分类号: O439 **文献标志码:** A **DOI:** 10.3788/IRLA20200363

Method of inverting wavefront phase from far-field spot based on deep learning

Zhang Yang, He Yulong, Ning Yu, Sun Quan, Li Jun, Xu Xiaojun

(College of Advanced Interdisciplinary Studies, National University of Defense Technology, Changsha 410073, China)

Abstract: In the adaptive optics system, the accuracy and robustness of wavefront sensor greatly affect the ability of aberration detection and closed-loop correction. In the condition of the nonuniformity of amplitude distributions or insufficient of beacon light energy, it will cause accuracy decrease of Hartmann wavefront sensing due to the lack of sub-aperture light. Meanwhile, the real-time performance of the wavefront sensing-free adaptive system based on far-field spot inversion cannot meet the practical requirements. The method of the wavefront inversion based on deep learning is to directly obtain aberrations by inputting the far-field light intensity image, which can be used as an effective supplement to the adaptive optical system. Through numerical simulation, this paper proved that the deep residual neural network could directly predict the Zernike coefficient of the wavefront phase through the far-field spot. And experimental demonstrated the corrected residual RMS between input and reconstructed wavefront phase was 0.08 waves, the average computation time was less than 2 ms by GPU acceleration. This method can predict the Zernike coefficient of incident wavefront distortion more accurately, and has a good aberration correction capability, suitable for measuring and correcting the main components of wavefront distortion in traditional adaptive optics method, or providing a good initial wavefront estimation for optimized adaptive optics.

收稿日期: 2020-09-20; 修订日期: 2020-10-22

作者简介: 张阳, 男, 硕士生, 主要从事自适应光学光束控制方面的研究。

导师简介: 宁禹, 女, 副研究员, 博士, 主要从事高能激光光束控制方面的研究。

Key words: wavefront phase inversion; adaptive optics; adaptive wavefront sensing-less correction; deep residual network

0 引言

自适应光学系统能够动态检测入射波前相位变化、通过实时补偿像差并将输出波面转变为平面波,使光学系统具有自动使用环境变化、克服动态扰动的能力,能够得到接近衍射极限的目标像或使激光发射系统有效地将光束聚焦在目标上^[1],极大地提高了光学系统性能。

自适应光学系统能够对不断变化的波前畸变进行校正,必须对波前畸变实现精准和实时的探测。波前传感器用来测量系统中入射光束波前误差情况,系统的畸变校正能力与波前传感器的响应速度和测量精度密切相关。哈特曼波前传感器由于测量精度高、使用方法简单等优势,是目前应用最广泛的波前传感器之一^[2]。但在实际应用中,哈特曼波前传感器的测量精度受到多种因素影响,例如接收的信标光较弱、光强度分布不均匀或受到大气湍流等传输过程中的随机干扰影响。在这些情况下,某些子孔径接收的光能量微弱^[3],低于探测器能够有效提取信号的能量阈值,直接影响到波前传感器的测量精度,导致较大的波前测量误差,影响自适应光学系统的闭环校正能力。图 1 所示为实际应用中,不同激光束在哈特曼波前传感器子孔径光斑分布情况。在这些系统中,虽然引起波前畸变的物理机制各不相同,但都遇到波前传感器探测信号不理想的问题,即子孔径存在较低的信噪比或缺光现象。常用的解决方法是对缺光子孔径斜率置零或在进行波前复原过程中将这部分子孔径去除,但这些方法都会增加波前复原误差^[4]。

另一方面,无波前探测自适应光学系统能够基于远场光强分布情况,是通过优化算法迭代校正波前像差^[5-7]。无波前探测自适应光学系统不需要波前像差测量和相位重构,对入射波前的振幅非均匀分布并不敏感,但由于收敛速度较慢,不适合用于实时性要求较高的系统^[8]。

20 世纪 90 年代, D.S 等用人利用同时拍照的焦点位置和离焦位置的图像,可以通过简单的神经网络模型训练,快速重构光斑的像散、离焦和彗差。Hubble 天文望远镜使用三层神经网络作为训练模型,




图 1 不同激光束在夏克哈特曼波前传感器的子孔径光斑分布。

(a) Nd^{3+} : YAG 板条激光器光束净化; (b) DF 化学激光器光束净化

Fig.1 Distribution of sub-aperture spot of different laser beams on the target of Shack-Hartmann-wavefront sensor. (a) Nd^{3+} : YAG slab laser beam cleanup; (b) DF chemical laser beam cleanup

分别输入一张离焦图像和一张焦点处图像,输出预测波前的 Zernike 系数,实验效果与相位迭代算法几乎相同,但对高阶像差的复原具有一定的困难性^[9-10]。近年来,深度学习算法和应用得到飞速发展,国内外相关研究者也将深度学习在自适应光学领域的应用进行了研究。Nguyen 等使用深度学习实现数字全息显微镜的像差补偿,可以避免忽略主成分分析方法自动像差补偿时对部分高阶像差的校正^[11]。Xin 等使用递归神经网络的波前传感方法,该方法可以实现扩展目标像差估计^[12]。Theodore 等分别使用哈特曼波前传感器子孔径 x 方向、 y 方向质心偏移量和曝光后的子孔径聚焦图像作为 U 型网络的输入,用以预测波前

相位^[13]。Tian 等人使用 5 层卷积神经网络进行仿真实验,用光强图像直接反演波前,有效提高了无波前探测自适应光学搜索时间,能够在自由空间光学通信中得到应用^[14]。

文中主要用于验证深度学习波前传感方法的有效性,首先通过模拟实验和实验验证说明该方法具有静态畸变的校正能力,并通过模拟仿真探索了深度学习在非理想条件下的波前复原能力。具体来说,是通过线下使用远场图像和对应波前信息作为样本数据,通过训练拟合远场图像与波前相位之间的非线性关系,最终实现线上输入新的远场光斑,经过训练好的模型计算波前相位。此方法具有算法简单,计算速度快的特点,能够作为哈特曼波前传感器在测量不准确条件下的有效补充,或为无波前探测的自适应光学系统提供初值。

1 入射波前相位预测神经网络模型

在均匀照明的情况下,远场光强和波前畸变的关系可以表示为:

$$I(\theta) \propto \left| \int w(r) \exp[i\phi(r)] \exp\left(\frac{2\pi i}{\lambda} \theta \cdot r\right) dr \right|^2 \quad (1)$$

式中: $I(\theta)$ 表示远场光斑图像; $\phi(r)$ 是自适应光学系统中入射光的波前畸变; λ 是波长; r 是位置矢量; $w(r)$ 是光瞳函数。同时,波前畸变 $\phi(r)$ 可以用正交的 Zernike 多项式表示为:

$$\phi(x) = \sum_{i=1}^n a_i z_i(x, y) \quad (2)$$

式中: $z_i(x, y)$ 表示第 i 项 Zernike 多项式; a_i 是第 i 项 Zernike 多项式系数。由此,从远场光斑图像到波前畸变的 Zernike 多项式存在非线性映射关系。

深度学习作为一种模拟人脑神经的典型方法,可以通过神经网络结构建立输入和输出的非线性映射。其中卷积神经网络是一种结构较深的深度学习模型,被广泛应用于图像识别、自然语言处理等领域^[15],尤其在大规模图像特征提取任务取得很大的成功,适合图像处理任务。卷积神经网络通过多个卷积层和池化层,可以从输入中提取图像细节特征信息,再通过全连接层建立特征与输出之间的联系。

卷积运算主要目的是从输入图像中提取特征。卷积层中包含有多个卷积核,网络中输入的图像和卷

积核进行卷积运算得到新的图像,新图像上每个卷积核所覆盖的区域中都包含上层图像特征,多层卷积的叠加能够很好地提取图像抽象特征。卷积神经网络的第 l 层卷积可表示为:

$$x^l = f(w^l \cdot x^{l-1} + b) \quad (3)$$

式中: x^{l-1} 表示网络第 $l-1$ 层的图像特征,是第 l 层卷积的输入; w^l 表示第 l 层网络的权重系数; b 为偏置项; $f(\cdot)$ 为激活函数,主要是为网络提供非线性运算; x^l 是第 l 层卷积得到的输出。通过多个卷积层堆叠,最终能够得到输入图像的特征矩阵。

池化层的主要作用是通过下采样操作减少每层特征的数量,该操作将卷积层得到的特征划分为多个 $m \times n$ 的滤子,并只保留每个滤子中最大值或平均值。第 l 层池化可以表示为:

$$x^l = \text{down}(x^{l-1}) \quad (4)$$

网络最终经过全连接层,可以将所提取的图像特征与长度为 N 的向量连接。网络的训练通过随机梯度下降算法,使得损失函数达到最小,损失函数表示为所有预测的 Zernike 项和真实 Zernike 项误差的平方和:

$$\text{loss} = \sum_N (y_{\text{predict}} - y_{\text{groundtruth}})^2 \quad (5)$$

网络模型经过训练,能够不断计算每层的梯度值并更新中间层的参数,使网络模型输出的预测值最大程度接近真实值。

自从 AlexNet^[16]引入以来,卷积神经网络结构变得越来越深。笔者所在团队选择了 Kaiming He^[17]的深度残差神经网络(ResNet)。考虑到准确性和前馈时间,选择了 ResNet-50 模型,其网络深度为 50 层。该网络模型引入了 shortcut 机制,网络架构如图 2 所示,其中图 2(a)中虚线所示为 shortcut 连接,这个机制跳过部分中间层,直接连接两个残差块,可以获得较原始的样本特征。因此网络梯度消失的问题得到了极大的缓解,使模型结构能够变得更深,拟合效果更加精准。图 2(b)所示为每个残差块的内部结构示意图,图像的特征提取是由多个残差块完成。

由于远场光强图像中包含了波前畸变信息,利用深度残差神经网络可以建立入射光的光强分布和波前相位之间的映射关系,直接求取相应的 Zernike 系数。算法流程示意图如图 3 所示。首先通过产生随




图 2 ResNet-50 神经网络结构预测泽尼克系数。(a) 网络结构示意图; (b) 残差块的示意图

Fig.2 ResNet-50 architecture to estimate Zernike coefficients. (a) Composition of the network; (b) Structure of residual block

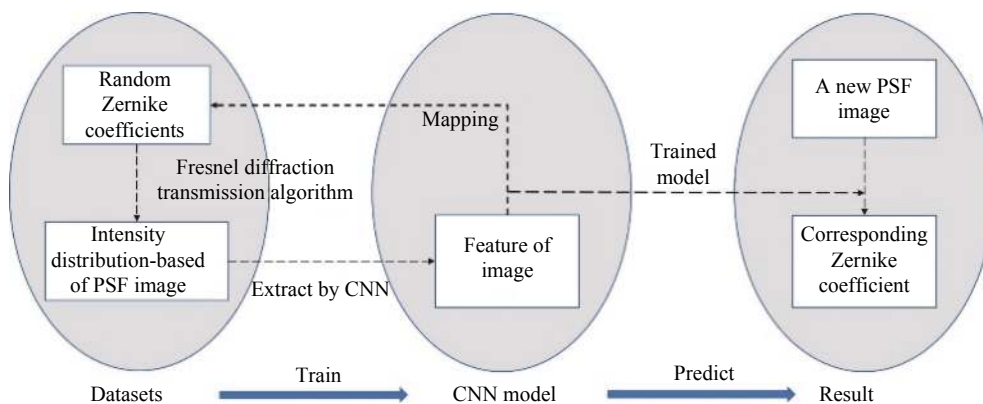


图 3 利用深度学习方法通过光强分布预测波前相位示意图

Fig.3 Schematic diagram of intensity distribution-based wavefront phase sensing with deep learning

机的 Zernike 多项式对应远场光强分布图像作为训练数据, 将远场图像作为卷积神经网络的输入, 对应的波前畸变的 Zernike 系数作为输出, 对网络模型进行训练。当新的远场图像输入到经过训练的网络模型中, 可以直接输出相应的波前 Zernike 系数。

在训练的过程中, 使用 MXNet^[18] 作为模型训练框架。使用最小批量为 32 的输入, 所有数据训练了 40 个轮次。损失函数使用的是预测的 Zernike 系数和真实 Zernike 系数之间的均方误差。优化器使用 Adam^[19] 进行训练, 初始学习率^[20] 的值为 0.01, Adam 能够根据模型训练状况自动调整学习率值。为了避免过拟合, 网络中使用了 dropout^[19] 和数据归一化层。提取特征后, 网络末尾加入全连接层, 主要用于在所提取的远场图像特征和对应的 Zernike 系数之间建立映射。

2 数值模拟

2.1 基于深度学习的波前探测模拟实验

在数值模拟中, 首先随机产生了多组 Zernike 多项式, 多项式长度分别为 15, 21, 28, 36, 45, 55, 66 (活塞项置零), 并计算相应的相位屏, 然后利用菲涅耳衍射积分的角谱传输形式^[21-22] 产生 256×256 像素的远场图像。每组产生 30000 个样本对, 其中 29000 个样本数据用于训练, 另外 1000 个样本用于验证。实验生成数据和训练网络所用计算机硬件环境为 Intel i7-8700 CPU, NVIDIA GTX 2080 GPU。

图 4 所示为一组模拟数据波前像差及校正结果示意图, 从图中可以看出, 通过深度残差神经网络复原的波前与输入波前有很高的相似性, 原输入的远场图像与重构的远场图像几乎一致, 且校正后波前残差量

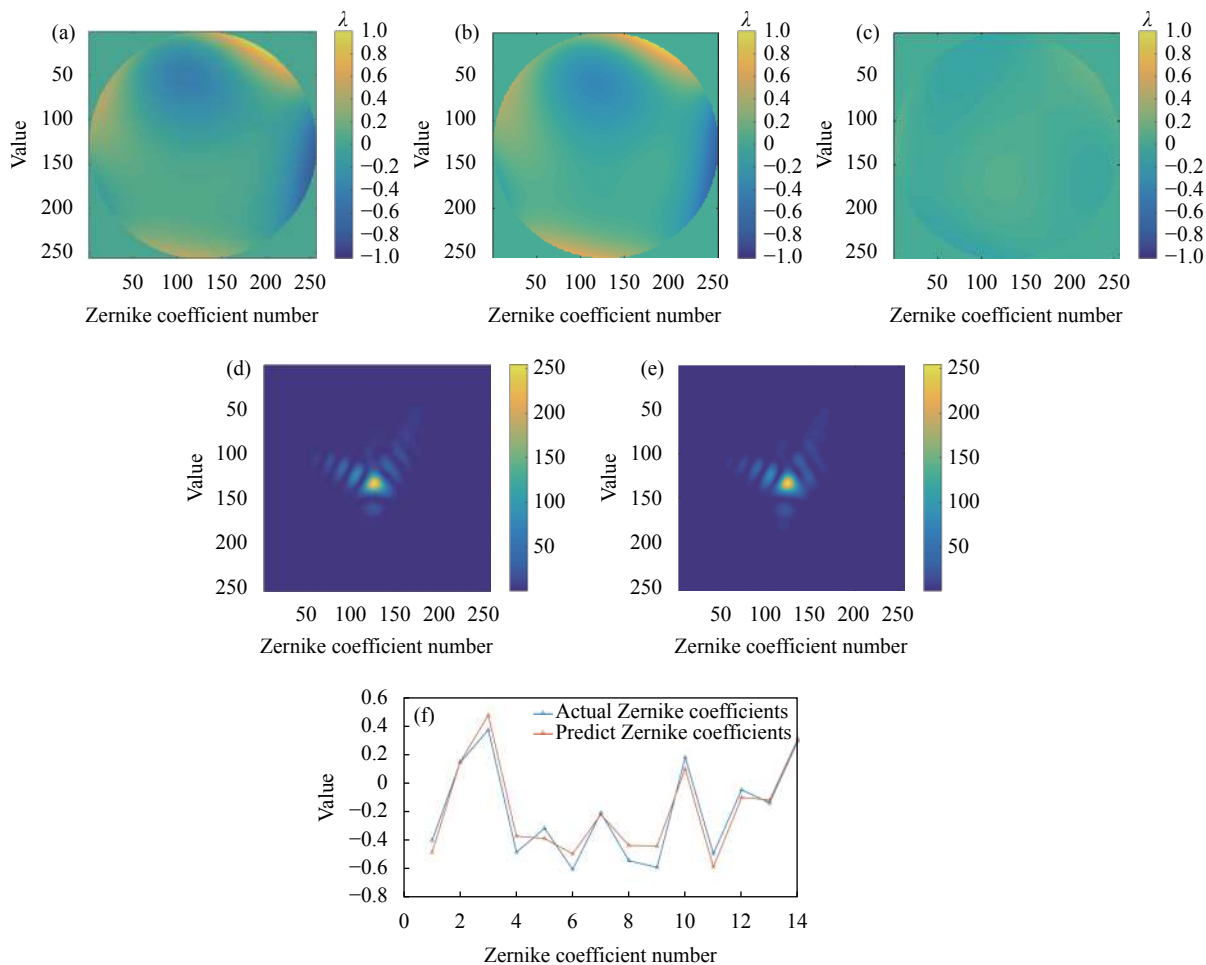


图 4 模拟数据波前像差及校正结果。(a) 输入波前; (b) 重构波前; (c) 校正后波前残差; (d) 输入的光强分布图像; (e) 重构的光强分布图像; (f) 真实的 Zernike 系数和预测的 Zernike 系数对比图

Fig.4 Wavefront aberration and correction result of a simulation data. (a) Input wavefront; (b) Reconstructed wavefront; (c) Residual wavefront after correction; (d) Intensity distribution of input; (e) Intensity distribution of reconstructed; (f) Comparison of actual Zernike coefficients and predict Zernike coefficients

较小。图 4(f) 为此数据每一项真实的 Zernike 系数和预测的 Zernike 系数对比, 两者具有很高的相似性。

经过计算, 不同长度 Zernike 多项式的波前输入 RMS、校正后波前残差 RMS 和计算用时结果如表 1 所示, 其中预测时间为每组数据的网络前馈平均

耗时。相比波前输入 RMS, 所有校正后波前残差 RMS 明显降低, 且预测时间较短。结果表明, 经过大量数据训练的深度残差神经网络, 对畸变波前具有较好的复原效果。同时, 随着 Zernike 多项式维度的增加, 此方法所预测波前的精度有所下降。经过 40 个

表 1 模拟数据训练结果

Tab.1 Training result of the simulation data

Zernike	RMS (input)	RMS (residual)	Mean predict time/ms	Training time/min
15	0.1425λ	0.0243λ	1.53	190
21	0.2010λ	0.0353λ	1.51	191
28	0.2523λ	0.0320λ	1.50	190
36	0.3093λ	0.0599λ	1.52	191
45	0.3569λ	0.0808λ	1.52	192
55	0.3976λ	0.0906λ	1.50	191
66	0.4194λ	0.1075λ	1.51	191

*Intel i7-8700 CPU, NVIDIA GTX-2080 GPU

轮次的训练, 每组训练时间大致相同约为 190 min。平均预测的时间约 1.5 ms, Zernike 多项式长度变化对波前预测时间的影响忽略不计。

2.2 波前探测影响因素分析

2.2.1 噪声影响

在自适应光学中, 噪声是影响系统波前畸变校正的主要因素之一。噪声影响哈特曼波前传感器和光电探测器的测量准确性, 进而影响到整个自适应光学系统性能。为了检测噪声对深度学习波前探测的影响, 在实验中, 使用高斯噪声和泊松噪声模拟噪声对远场光斑图像的影响。具体方法是在 Zernike 前 15 项所生成的 30000 组模拟数据产生的远场图像中加入高斯噪声和泊松噪声, 分别训练对比结果。其中高斯噪声的标准差为 0.02。

利用残差网络对含有高斯噪声和泊松噪声的远场图像分别训练, 实验结果如表 2 所示。实验结果表明, 网络具有一定的鲁棒性, 因此一定程度上能够对波前的 Zernike 多项式系数进行预测, 但会对网络模型的预测精度造成一定的影响。能够猜想, 当网络输入的随机噪声越来越占的主导因素时, 该方法对像差预测的能力将会变差。

表 2 加入不同噪声训练结果

Tab.2 Training results with different noise

Item	RMS (input)	RMS (residual)
Original image	0.142 5λ	0.024 3λ
Gaussian noise	0.142 5λ	0.036 7λ
Poisson noise	0.142 5λ	0.032 9λ

2.2.2 像差大小影响

为了验证不同大小像差对探测精度影响, 在仿真中通过改变 Zernike 多项式系数的取值范围, 生成了多组不同像差大小所对应的远场光斑图像。其中 Zernike 取前 15 项, 共产生 4 组对比数据, 每组数据包含 30000 个样本。模型的校验结果如表 3 所示, 仿真结

表 3 不同像差大小训练结果

Tab.3 Training results with different aberration

No.	RMS (input)	RMS (residual)
1	0.171 9λ	0.029 2λ
2	0.339 8λ	0.054 2λ
3	0.507 6λ	0.071 1λ
4	0.684 7λ	0.082 8λ

果表明, 不同像差大小的远场图像都可以利用深度学习波前反演。

2.2.3 自适应系统部分区域缺光影响

为了验证自适应系统部分区域缺光对深度学习波前传感探测能力的影响, 依据 Kolmogorov 湍流理论, 根据随机的 Zernike 多项式拟合不同幅值的相位屏产生畸变远场图像。在实验中, 共产生 3 组样本进行比较, 分别为 (a) 组、(b) 组、(c) 组, 每组共产生 30000 个样本, 其中 29000 个用于训练, 1000 个样本用于校验缺光情况对预测精度的影响。如图 5 左侧图像所示为湍流相位屏示意图, 右侧图像为同一组 Zernike 多项式在不同湍流相位屏下的哈特曼波前探测器子孔径的光斑分布图像。




图 5 湍流相位屏及对应哈特曼探测器子孔径光斑分布图像

Fig.5 Turbulence phase screen and corresponding Hartmann detector sub-aperture spot distribution

利用生成的数据集, 分别对 (a) 组、(b) 组、(c) 组训练和验证。预测结果如表 4 所示, 从表中可以看出, 当光强分布不均匀、哈特曼有部分子孔径能量较弱时, 该方法能够通过远场光强分布恢复波前, 具有较好的校正效果, 具有一定的实用性。

表 4 不同弱光区域训练结果

Tab.4 Training results with different low-light areas

Fig.5	RMS (input)	RMS (residual)
(a)	0.149 8λ	0.040 0λ
(b)	0.149 8λ	0.037 6λ
(c)	0.149 8λ	0.033 9λ

3 实验验证

笔者所在团队构建实验平台,用于验证方法的有效性。工作可以概括为两部分,第一部分是搭建光路,产生数据集,第二部分是数据训练及验证分析。实验的光路结构如图 6 所示。




图 6 实验中使用的光学系统的结构。HSWFS 和两个 CCD 记录 Zernike 系数和相应的远场图像

Fig.6 Structure of the optical system used in the experiment. Zernike coefficients and the corresponding far-field images are recorded by HSWFS and two CCDs

实验使用 650 nm 半导体激光器经过滤波准直后扩束成平行光,通过分束器 (BS1) 后,通过液晶空间光调制器 (LC-SLM) 引入波前像差。光束经 BS2 进入哈特曼波前传感器进行测量。透射光经过透镜汇聚由 CCD 探测器测量远场光强。两台 CCD 探测器主要作用是为了增加相机的动态范围。

在数据采集的过程中,利用 LC-SLM 产生不同成分、不同幅值的像差。PV 值的设置从 $0.1\lambda\sim 1\lambda$,平均分为 10 组,每组采集 3000 个样本对,总共采集 30000 个样本。其中每组数据中随机取 2900 个样本作为训练数据,100 个样本作为验证数据,故共 29000 个样本用作训练,1000 个样本用作验证。

笔者所在团队仍使用 Zernike 多项式 (去除活塞和倾斜项) 来表示波前像差。从光学系统收集的数据

样本用 Resnet-50 模型进行训练,其中网络的输入结构从单图像修改为两张图像,以便两个 CCD 所捕获的光斑信息能够同时提取特征,输出为哈特曼波前传感器采集光波波前的 Zernike 系数。

图 7 所示为一组实验数据波前像差及校正结果示意图,图 7(f) 为此数据每一项真实的 Zernike 系数和预测的 Zernike 系数对比。能够看出,深度残差神经网络有较高的拟合度,能够很大程度校正波前畸变。

模型经过训练,1000 组验证数据的实验结果如表 5 所示,经计算 1000 组验证数据输入 RMS 的平均值为 0.52λ ,残差 RMS 的平均值为 0.08λ 。在 GPU 加速下,训练时间为 201 min,验证集的平均预测时间为 1.67 ms,其中包含了图像读取和波前预测的时间。

为了验证深度学习反演波前的方法是否能够对畸变波前进行闭环校正,对畸变波前 RMS 分布和校正后残差波前 RMS 进行了对比,对比结果如图 8 所示。图中横轴表示波长的倍数,纵轴表示数量,其中红色部分表示输入波前 RMS 分布,蓝色部分表示残差波前 RMS 分布。由于在空间光调制器产生像差的过程中,所加载的光场 PV 值呈均匀分布,因此畸变波前 RMS 分布较均匀。经过训练的网络模型,校正后的波前残差分布较为集中,且远小于输入的畸变波前。

此外,笔者所在团队测试了模型对所选各项 Zernike 像差的拟合能力。图 9 显示了 1000 个验证数据中每项 Zernike 系数输入波前 RMS 和校正后残差波前 RMS。经过对比,所有估计的 Zernike 项都能较好地拟合原 Zernike 项,且每一项都具有几乎相同的估计误差。因此在深度网络模型输出时,不需要对任何一项 Zernike 系数添加权重。

另外,在实验中测试了不同像差大小下 Zernike 系数 (nm) 的残差。这组实验是将不同 PV 值大小的验证数据分为三组,像差由小到大得到的平均残差 RMS 为 35.21 nm, 58.23 nm 和 96.34 nm,即分别 0.054λ 、 0.089λ 、 0.148λ 。实验证明,小像差也可以有较高的波前像差预测精度。因此使用深度学习可以拟合多种像差、有效减小波前畸变量。这一特征可以有效运用于自适应光学系统中,深度学习反演波前的方法可以通过远场光强分布计算对应波前信息。在像差校正的过程中,波前畸变量不断减小,而此方法也能够

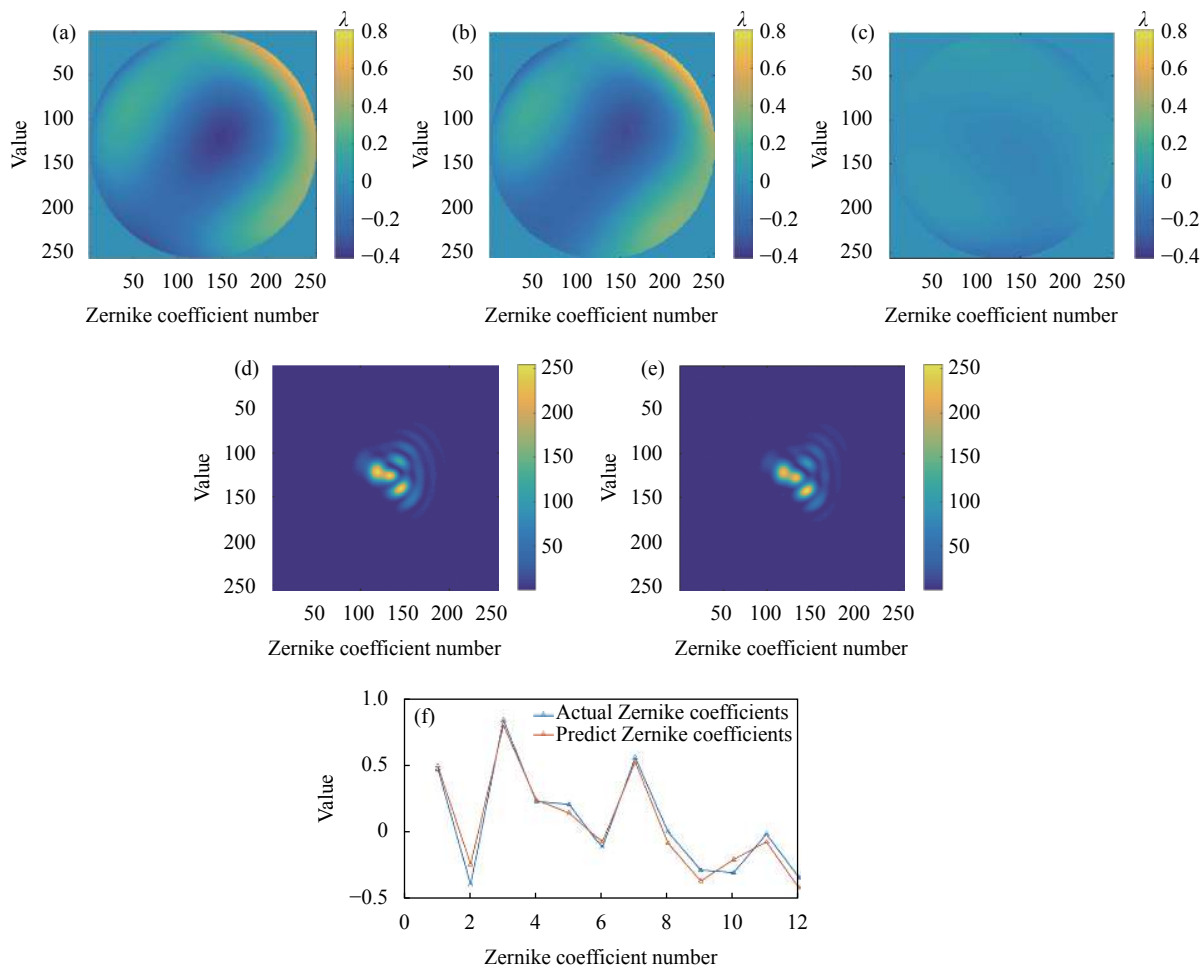


图 7 实验数据波前像差及校正结果。(a) 输入波前;(b) 重构波前;(c) 校正后波前残差;(d) 输入的光强分布图像;(e) 重构的光强分布图像;(f) 真实的 Zernike 系数和预测的 Zernike 系数对比图

Fig.7 Wavefront aberration and correction result of a experiment data. (a) Input wavefront; (b) Reconstructed wavefront; (c) Residual wavefront; (d) Intensity distribution of input; (e) Intensity distribution of reconstructed; (f) Comparison of actual Zernike coefficients and predict Zernike coefficients

表 5 实验数据训练结果

Tab.5 Training result of the experimental data

Zernike	RMS (input)	RMS (residual)	Mean predict time/ms	Training time/min
15	0.52λ	0.08λ	1.67	201




图 8 1000 组验证数据的 RMS 分布

Fig.8 RMS of 1000 groups of verification data




图 9 每一项泽尼克的 RMS (不包含活塞项和倾斜项)

Fig.9 RMS of the Zernike coefficient (the piston and tilt terms excepted)

较好地计算小像差的波前信息,适用于自适应光学闭环校正系统。

4 结 论

通过模拟实验,验证了通过深度残差神经网络,直接使用远场光强分布计算光的波前相位是有效的,并分别模拟了噪声、不同像差大小及部分区域缺光对测量精度的影响,证明了该方法具有较好的鲁棒性。经训练后的网络模型,可以在较短时间内估计光波波前。在实验验证中,分别使用 CCD 采集的远场图像和哈特曼波前传感器的波前测量值作为网络模型的输入和输出。经验证数据测试,输入波前 RMS 为 0.52λ ,残差波前 RMS 为 0.08λ 。通过实验测试了卷积神经网络对所有 Zernike 系数的估计能力,每项 Zernike 系数的估计误差几乎相等,并且该方法能够对小像差波前进行校正。

通过深度学习得到的波前相位可以直接作为入射光波前的测量值,或作为迭代算法的初始估计。此方法可以认为是一种基于远场图像的波前传感器,它能够解决非理想情况下波前传感器的错误测量问题,通过测量光斑远场就能根据经验得到波前相位的估计值,也能够为无波前自适应光学系统提供初始波前信息,减少系统的迭代时间,有助于快速求取相位信息。由于从光强度分布中提取特征的方法的灵活性和鲁棒性,可以在更广泛的场景中使用。

参考文献:

- [1] Jiang Wenhan. Progresses on adaptive optics techniques--a review of SPIE's 1991 international symposium on optical applied science and engineering [J]. *Opto-Electronic Engineering*, 1992, 19(4): 50-60. (in Chinese)
- [2] Zhao Feifei, Huang Wei, Xu Weicai, et al. Optimization method for the centroid sensing of Shack-Hartmann wavefront sensor [J]. *Infrared and Laser Engineering*, 2014, 43(9): 3005-3009. (in Chinese)
- [3] Barchers J D, Fried D L, Link D J. Evaluation of the performance of Hartmann sensors in strong scintillation [J]. *Appl Opt*, 2002, 41(6): 1012-1021.
- [4] Wei Ping, Li Xinyang, Luo Xi, et al. Influence of lack of light in partial subapertures on wavefront reconstruction for Shack-Hartmann wavefront sensor [J]. *Chinese Journal of Lasers*, 2020, 47(4): 0409002. (in Chinese)
- [5] Gonsalves R A. Phase retrieval and diversity in adaptive optics [J]. *Opt Eng*, 1982, 21(5): 829-832.
- [6] Gonsalves R A, Chidlaw R. Wavefront sensing by phase retrieval[C]//Proc SPIE, Applications of Digital Image Processing III, 1979, 0207: 32-39.
- [7] Paxman R G, Schulz T J, Fienup J R. Joint estimation of object and aberrations by using phase diversity [J]. *Journal of the Optical Society of America A*, 1992, 9(7): 1072-1085.
- [8] Yang Huizhen, Liu Rong, Liu Qiang. Model wavefront-sensorless adaptive optics system based on eigenmodes of deformable mirror [J]. *Infrared and Laser Engineering*, 2015, 44(12): 3639-3644. (in Chinese)
- [9] 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: 300-302.
- [10] Barrett T K, Sandler D G. Artificial neural network for the determination of Hubble Space Telescope aberration from stellar images [J]. *Appl Opt*, 1993, 32(10): 1720-1727.
- [11] Nguyen T, Bui V, Lam V, et al. Automatic phase aberration compensation for digital holographic microscopy based on deep learning background detection [J]. *Opt Express*, 2017, 25(13): 15043-15057.
- [12] Xin Q, Ju G, Zhang C, et al. Object-independent image-based wavefront sensing approach using phase diversity images and deep learning [J]. *Opt Express*, 2019, 27(18): 26102-26119.
- [13] DuBose T B, Gardner D F, Watnik A T. Intensity-enhanced deep network wavefront reconstruction in Shack-Hartmann sensors [J]. *Optics Letters*, 2020, 45(7): 1699-1702.
- [14] Tian Qinghua, Lu Chenda, Liu Bo, et al. DNN-based aberration correction in a wavefront sensorless adaptive optics system [J]. *Optics Express*, 2019, 27(8): 10765-10776.
- [15] Yang Nan, Nan Lin, Zhang Dingyi, et al. Research on image interpretation based on deep learning [J]. *Infrared and Laser Engineering*, 2018, 47(2): 203002. (in Chinese)
- [16] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [J]. *Communications of the ACM*, 2017, 60(6): 84-90.
- [17] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016.
- [18] Chen Tianqi, Li Mu, Li Yutian, et al. MXNet: A flexible and efficient machine learning library for heterogeneous distributed systems [J]. *arXiv e-prints*, 2015: 1512.01274.

- [19] Yang Guanci, Yang Jing, Li Shaobo, et al. Modified CNN algorithm based on dropout and ADAM optimizer [J]. *Journal of Huazhong University of Science and Technology(Nature Science Edition)*, 2018, 46(7): 122-127. (in Chinese)
- [20] Fang Zhiying, Guo Zhengchu, Zhou Dingxuan. Optimal learning rates for distribution regression [J]. *Journal of Complexity*, 2020, 56: 101426.
- [21] Voelz D G, Roggemann M C. Digital simulation of scalar optical diffraction: Revisiting chirp function sampling criteria and consequences [J]. *Appl Opt*, 2009, 48(32): 6132-6142.
- [22] Delen N, Hooker B. Free-space beam propagation between arbitrarily oriented planes based on full diffraction theory: A fast Fourier transform approach [J]. *Journal of the Optical Society of America A*, 1998, 15(4): 857-867.