



·激光大气传输技术·

# 基于远场信息和卷积神经网络的波前重构方法\*

史宗佳<sup>1,2</sup>, 向振佼<sup>1</sup>, 杜应磊<sup>1</sup>, 万敏<sup>1</sup>, 顾静良<sup>1</sup>, 李国会<sup>1</sup>,  
向汝建<sup>1</sup>, 游疆<sup>1,2</sup>, 吴晶<sup>1</sup>, 徐宏来<sup>1</sup>

(1. 中国工程物理研究院应用电子学研究所, 四川绵阳 621900; 2. 中国工程物理研究院研究生院, 北京 100088)

**摘要:** 探测波前相位信息是实现自适应光学波前补偿的关键, 使用卷积神经网络(CNN)代替波前传感器进行波前重构, 系统简单易于实现, 同时重构过程不依赖迭代运算, 快速实时。为准确提取远场中的波前特征, CNN需要事先使用大量样本进行训练。研究中根据4~30阶大气湍流泽尼克像差系数与其远场强度的对应关系, 仿真制作样本数据集, 训练CNN从输入的一帧远场图像中预测出畸变波前的泽尼克像差系数, 重构原始波前。验证结果表明, 该方法能快速实时地还原出波前相位信息, 重构波前较原始波前具有极高的波面吻合度和较小的残差剩余量, 有望实现实际自适应光学系统中的闭环校正。

**关键词:** 自适应光学; 深度学习; 卷积神经网络; 泽尼克模式; 远场光斑; 波前重构  
**中图分类号:** O439 **文献标志码:** A **doi:** 10.11884/HPLPB202133.210040

## Wavefront reconstruction method based on far-field information and convolutional neural network

Shi Zongjia<sup>1,2</sup>, Xiang Zhenjiao<sup>1</sup>, Du Yinglei<sup>1</sup>, Wan Min<sup>1</sup>, Gu Jingliang<sup>1</sup>, Li Guohui<sup>1</sup>,  
Xiang Rujian<sup>1</sup>, You Jiang<sup>1,2</sup>, Wu Jing<sup>1</sup>, Xu Honglai<sup>1</sup>

(1. Institute of Applied Electronics, CAEP, Mianyang 621900, China;  
2. Graduate School of China Academy of Engineering Physics, Beijing 100088, China)

**Abstract:** Detecting wavefront phase information is the key to realize adaptive optics wavefront compensation. Using convolutional neural network (CNN) instead of wavefront sensor for wavefront reconstruction, the system can be simple and easy to implement, and the reconstruction process is fast and real-time without iteration. To extract the wavefront features from the far field accurately, CNN needs to use a large number of samples for training in advance. In the study, according to the corresponding relationship between Zernike aberration coefficient of orders 4 to 30 and its far-field intensity, the sample data set was simulated, CNN was trained to predict the Zernike aberration coefficient of the distorted wavefront from an input far-field image, then reconstruct the original wavefront. The experimental results show that this method can restore the phase information of wavefront quickly and in real time. Compared with the original wavefront, the reconstructed wavefront has higher wavefront coincidence and smaller residual. It is expected to realize the closed-loop correction in practical adaptive optics systems.

**Key words:** adaptive optics; deep learning; convolutional neural network; Zernike model; far-field spot; wavefront reconstruction

自适应光学(AO)是实时消除光学系统像差和改善光束传输波前畸变的技术<sup>[1]</sup>。传统的自适应光学系统是由波前传感器、波前控制器、波前校正器组成的闭环系统, 校正过程主要依赖波前传感器对畸变波前相位信息的探测<sup>[2]</sup>。在此基础上发展出的无波前探测自适应光学技术, 使用包括遗传算法、模拟退火算法、SPGD、爬山法等波前重构算法, 直接优化远场像质评价函数, 无需波前传感器, 降低了系统复杂度<sup>[3-6]</sup>。但这些波前重构算法需要多次迭代或复杂的方程求解计算, 无法实现高速实时波前重构, 难以达到系统闭环带宽需求。

\* 收稿日期: 2021-02-04; 修订日期: 2021-04-02

基金项目: 中国工程物理研究院创新发展基金项目(CX2020033); 国防科技创新特区课题项目(193A221011101)

作者简介: 史宗佳(1995—), 男, 硕士研究生, 从事自适应光学方面的研究。

通信作者: 杜应磊(1988—), 男, 学士, 助理研究员, 从事激光系统主动光学技术研究。

近年来深度学习技术在自适应光学中获得广泛应用<sup>[7-9]</sup>,卷积神经网络(CNN)可以从远场强度图提取出畸变波前相位信息,代替波前传感器实现波前重构,系统简单且快速实时。2017年, Paine Scott W.等训练卷积神经网络校正了詹姆斯·韦伯空间望远镜第2~5阶泽尼克像差<sup>[10]</sup>。2019年, Yohei Nishizaki 等从焦平面上远场单帧强度图像中识别出32阶泽尼克像差系数,测试集系数原始值和估计值的均方根误差(RMSE)达到0.142<sup>[11]</sup>。同年,田清华等提出了一种基于CNN网络的无波前探测自适应光学系统像差校正方法,重构后的波前残差为原波前的26%~41%<sup>[12]</sup>。2020年,马慧敏等使用卷积神经网络从焦平面和离焦平面两帧光强图像中准确预测出35阶泽尼克像差<sup>[13]</sup>。

本文利用光波远场强度与近场波前的对应关系,采用ResNet模型训练CNN从远场强度信息中重构波前相位畸变,CNN只需远场焦平面上帧强度的输入,便可在5ms以内预测出波前第4~30项泽尼克像差系数,获得了更高的系数预测精度和更少量的重构波前残差。最终实现了网络对远场强度图和波前的4~30阶泽尼克像差的端到端输入输出,较以往有更高的预测精度和更少的预测时间。

### 1 基于CNN的波前重构方法

基于CNN的波前重构系统如图1所示,CNN以远场相机CCD采集到的远场强度图像为输入,预测出大气传输湍流像差的各阶泽尼克系数。系统中CNN需要预先经过大量样本训练,优化网络节点上的参数,以拟合远场强度图到泽尼克系数矢量间的映射关系。训练完成后的CNN网络,可以直接根据输入的远场图像,结合网络参数计算,预测出近场波前的模式系数。深度残差网络(ResNet)通过残差块中直接连接的方式解决了深层网络的退化问题,能在回归问题上获得极高的精确度,是目前广泛使用的一类网络。本研究使用的CNN是深度为18、34、50、101的四种不同深度的ResNet<sup>[14]</sup>,深度的差异是由于在模块conv1到conv4中使用不同数量的残差单元。同时,不同深度的ResNet用到两种不同结构的残差单元,在如ResNet18和ResNet34的浅层网络中使用图2(a)中的残差单元,在更深层次的ResNet50和ResNet101中为减少网络参数与运算量,使用图2(b)所示残差单元。使用时修改网络的全连接层使之与输出泽尼克系数向量维度相适应。

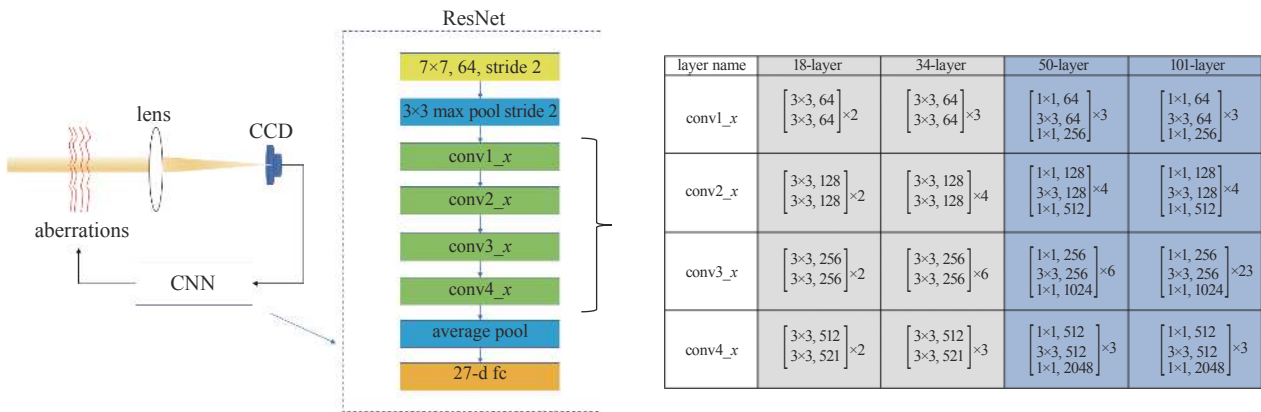


Fig. 1 Wavefront reconstruction system based on CNN

图 1 基于CNN的波前重构系统

CNN波前重构的基本流程如图3所示,首先根据远场光强与近场波前的对应关系建立样本对,再使用样本数据优化不同架构的CNN网络,使网络各节点参数达到最优,并进行网络预测结果的评估,选取最好的CNN网络最终进行远场光强图像的近场波前重构。

### 2 样本数据的产生

大气湍流相位屏描述光传输过程中由于湍流带来的随机相位扰动,谱反演法根据大气湍流的功率谱密度函数描述大气扰动的相位分布<sup>[15-16]</sup>,是常用的大气相位屏数值模拟方法,其基本原理是使用大气湍流的功率谱对随机复高斯矩阵滤波,再对其逆傅里叶变换获得空间域的大气相位扰动 $\varphi$ 。

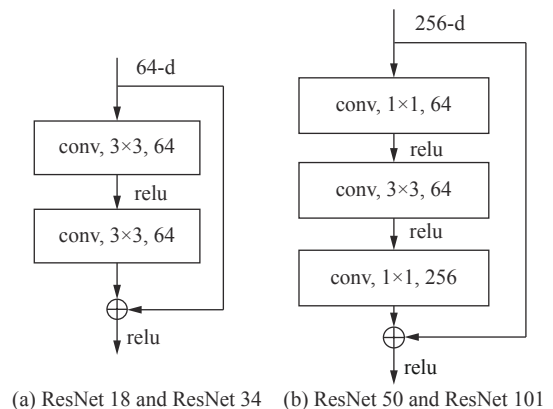


Fig. 2 Different residual elements

图 2 不同的残差单元

大气折射率功率谱密度采用 von Karman 谱, 为改善谱反演法低频部分表达不足的缺点, 对 5 阶低频次谐波重采样插值合并, 以补偿相位屏低频特性<sup>[17]</sup>。

谱反演法产生的畸变相位 $\varphi$ 可分解为单位圆内连续正交的泽尼克模式<sup>[18]</sup>, 即

$$\varphi = \sum_{n=1}^k a_n z_n + o \quad (1)$$

式中:  $o$  为分解后高阶模式的误差小量;  $z_n$ 、 $a_n$  为第  $n$  阶泽尼克多项式及其系数。光波受相位扰动 $\varphi$ 传递到远场时, 其复振幅分布  $U$  可以由入射光场  $U_0$  的傅里叶变换表示

$$U = C\mathcal{F}(U_0) = C\mathcal{F}[E_0 \exp(i\varphi)] \quad (2)$$

式中:  $\mathcal{F}$  表示傅里叶变换;  $C$  表示复常数;  $E_0$  为入射光场的振幅。远场强度分布  $I$  与由泽尼克系数表示的大气畸变相位的函数关系为

$$I = |U|^2 = \left| C\mathcal{F} \left[ E_0 \exp \left( i \sum_{n=1}^{\infty} a_n z_n \right) \right] \right|^2 \quad (3)$$

由此便建立起同一畸变相位 $\varphi$ 影响下远场强度分布与近场各阶泽尼克模式向量的对应关系。

对式(3)中远场强度与近场泽尼克像差系数的函数关系进行仿真, 仿真程序可以随机特定的大气相干长度下一系列大气相位屏, 并分别计算出相位屏作用下的远场光强分布图和对应的泽尼克像差系数向量, 以此作为 ResNet 训练使用的输入输出样本对。实际自适应光学系统中, 第 1~3 阶泽尼克项代表的平移和倾斜易由快反镜校正, 且波前校正器(变形镜)无法校正过高阶的泽尼克像差<sup>[19]</sup>。选取第 4~30 阶泽尼克系数表征谱反演法生成波前, 图 4 为某一随机样本的远场强度图和各阶泽尼克系数。




Fig. 4 Far-field and wavefront Zernike coefficients of a sample

图 4 某一样本远场和波前泽尼克系数

### 3 网络训练与波前重构结果展示

本研究在一台搭载了 8 块 Nvidia GeForce 2080 GPU 的 Ubuntu 服务器上搭建 PyTorch 深度学习环境, 实现 ResNet 的并行训练。训练 ResNet 的数据集包含 30 万训练集样本和 6 万验证集样本, 每一个训练轮次(Epoch)中分批(Batch)使用训练集对网络进行参数更新并使用验证集对网络性能进行评估, batch 的大小为 1024, 每个 batch 中对训练集样本计算 L1 误差(Loss)并反向传播更新神经网络参数, 对验证集样本只计算 L1 Loss 进行输出评估, 不参与网络参数的更新。初始学习率为 0.1, 并随着一定的 epoch 进行衰减。对样本进行归一化处理, 并在卷积层间进行批归一化(Batch Normalization), 防止梯度弥散, 加快 ResNet 的收敛。

实验中训练了 ResNet18、ResNet34、ResNet50 和 ResNet101 四种不同深度的模型, 如图 5 为训练过程中训练集与验证集误差的变化曲线, 其横轴表示训练中的迭代轮次, 纵轴表示预测系数较真实系数的 L1 误差值, 经过 295 轮的训练, 四种模型的训练误差均稳定保持在较低的水平, 说明网络对训练集能做到较好的收敛。验证集的

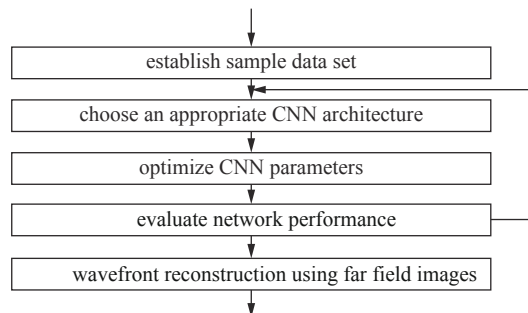


Fig. 3 Flow chart of CNN wavefront reconstruction

图 3 CNN 波前重构流程图




Fig. 5 The L1 loss change process of the four ResNet models in training is shown in (a) the training set and (b) the verification set

图 5 训练中四种 ResNet 模型的 L1 loss 变化过程, (a) 图为训练集, (b) 图为验证集

误差反映出网络的泛化性能,从曲线上来看 ResNet50 的泛化性能最差; ResNet18 与 ResNet101 性能相似但 ResNet18 更加稳定; ResNet34 具有最好的泛化性能,最终 Loss 稳定在 0.005 左右,较初始下降了两个数量级。在不同深度的 ResNet 上使用不同的残差单元造成了网络性能的差异表现。一般而言,提升网络的深度会提高网络性能,当前训练情境下使用图 2(b) 残差单元需要在更深的深度下才能达到图 2(a) 残差单元相近的精确度水平。与此同时,更深的网络增加了网络参数,消耗了更多的计算资源,并使训练过程更加的不稳定,各网络的单帧图像预测时间如图 6 所示。



Fig. 6 Single frame image prediction time of ResNet

图 6 网络的单帧图像预测时间

选取验证集表现最好的 ResNet34 网络对新生成的 1000 个样本的测试集进行波前重构,网络根据输入的远场光强图像快速预测出其波前的各阶泽尼克系数,单帧波前预测时间不超过 5 ms。样本归一化的泽尼克系数预测值与真实值的均方根误差(RMSE)绝大多数保持在 0.005 左右的较低水平,网络能对波前泽尼克系数准确预测。

使用预测出的泽尼克系数重构波前,用波前的峰值(PV, Peak Value)和均方根值(RMS, Root-Mean-Square)表示与理想面的偏移程度。图 7 为测试集中某一波前重构结果。(a)为重构结果的系数折线图,true、pre 和 error 三

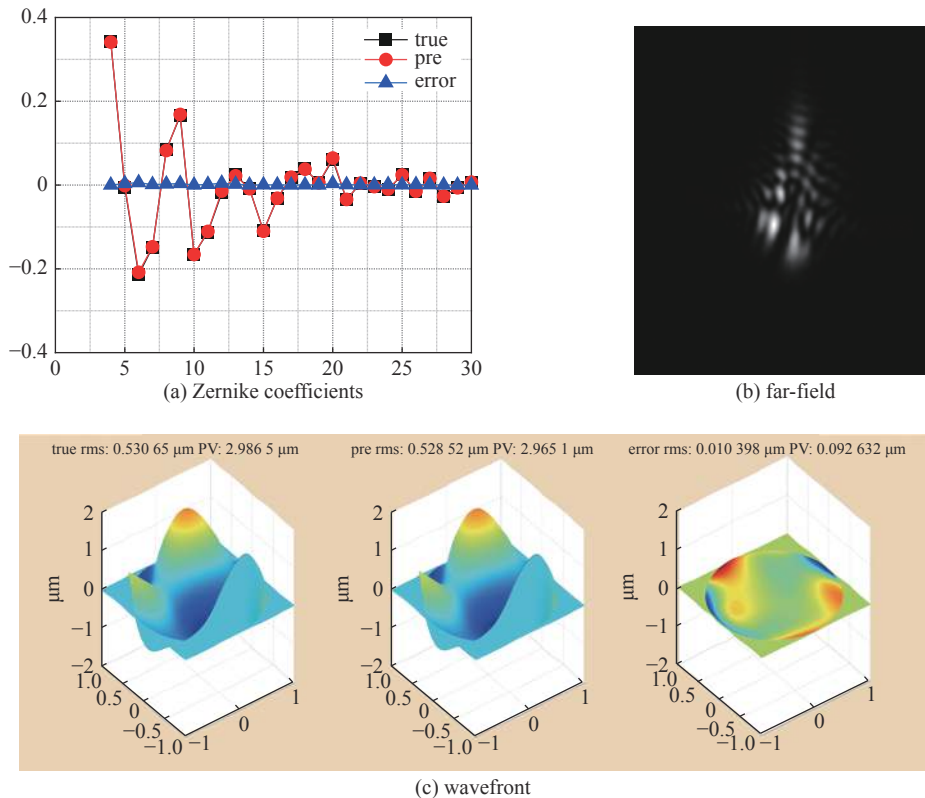


Fig. 7 Wavefront reconstruction results of a sample in the test set

图 7 测试集中某一样本的波前重构结果



条折线分别代表样本的原始泽尼克系数、ResNet 预测出的泽尼克系数和系数预测值与原始值的绝对误差，网络对样本泽尼克像差系数预测结果吻合度相当高；(b)为输入 ResNet 的远场光强图；(c)为原始波前、使用泽尼克系数重构出的预测波前和波前残差。原始波前的 PV 和 RMS 为  $2.98\ \mu\text{m}$  和  $0.53\ \mu\text{m}$ ，经过 ResNet 重构后，波前残差的 PV 和 RMS 仅为  $0.09\ \mu\text{m}$  和  $0.01\ \mu\text{m}$ ，残差约占原始波前的 3% 左右，可准确的恢复出原始波前的畸变相位。

测试集中各样本原始波前与重构波前残差的 PV 和 RMS 值如图 8 所示，对于 PV 和 RMS 较为分散地分布在  $(3\pm 1)\ \mu\text{m}$  和  $(0.5\pm 0.3)\ \mu\text{m}$  左右的原始波前，重构后残差的 PV 和 RMS 均下降到  $0.05\ \mu\text{m}$  以下的较小范围内。为评价 CNN 的波前重构情况，以测试集样本残差与原始波前 PV 和 RMS 的百分比作为评价标准，图 9(a) 为各样本残差与原波前的 PV 和 RMS 比值情况，为更直观的反映出网络对测试集的整体波前重构表现，在图 9(b) 中统计了低于残差与原波前的 PV 和 RMS 各比值下样本的数量。从图中可以看出，ResNet 对 98% 以上的样本能获得残差 10% 以下的重构精度，75% 以上的样本能获得 7% 以下的极高波前重构精度。在大气湍流仿真样本上，基于 CNN 从远场信息中重构波前获得了较高的预测精度。

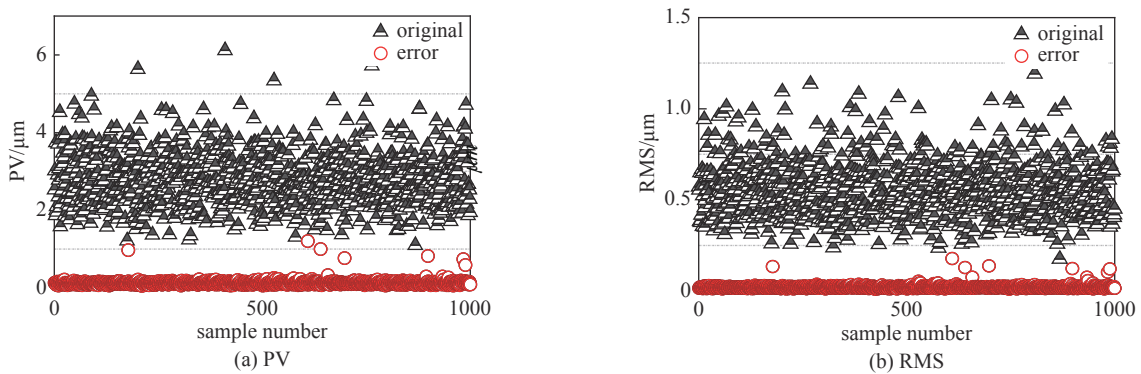


Fig. 8 Scatter plot of PV and RMS of original wavefront and wavefront residuals of test set samples

图 8 测试集样本原始波前和波前残差 PV 和 RMS 的散点图

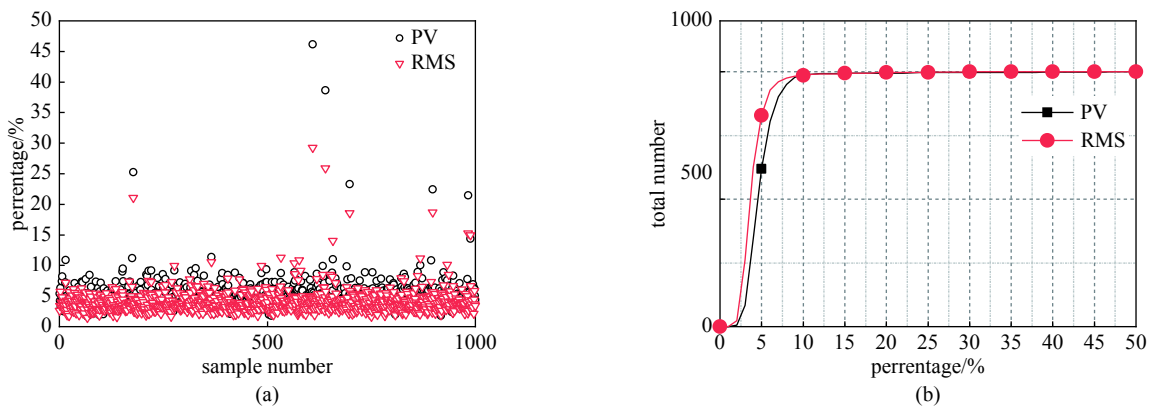


Fig. 9 Ratio of PV and RMS of sample wavefront residuals to original wavefront of test set

图 9 测试集样本波前残差与原始波前的 PV 和 RMS 比值

大气湍流的强度随大气相干长度  $r_0$  的减少而增强，为验证 ResNet 对不同强度的湍流的预测结果，实验中针对两种不同  $r_0$  的样本训练 ResNet 并进行波前重构，详细结果如表 1 所示，训练中均使用 30 万训练集样本和 6 万验证集样本，并对 1 千测试集样本进行波前重构验证。表中测试集样本原始波前和重构后波前残差的 PV 和 RMS 均表

表 1 不同强度湍流的重构波前结果

Table 1 Wavefront reconstruction results of turbulence with different intensities

$R_0$	far field image size/pixel	L1 error	normalized coefficient RMSE	PV of the test set samples' original wavefront/ $\mu\text{m}$	RMS of the test set samples' original wavefront/ $\mu\text{m}$	PV of reconstructed wavefront residuals/ $\mu\text{m}$	RMS of reconstructed wavefront residuals/ $\mu\text{m}$	residual PV to original wavefront ratio (90% of sample)/%	residual RMS to original wavefront ratio (90% of sample)/%
1	140×140	0.0040	0.0051	2.67±1.63	0.54±0.37	0.12±0.07	0.02±0.01	6	5
0.5	200×200	0.0204	0.0266	5.06±2.76	1.0±0.55	1.14±0.75	0.20±0.13	30	27

示样本 PV 和 RMS 的整体分布范围,可以观察到 $r_0 = 0.5$ 的样本较 $r_0 = 1$ 的样本结果明显变差,这是由于强湍流下远场强度分布与近场波前的变化更加多样,ResNet 需要更大数量的样本来进行训练。可以预见,提升样本容量可以进一步提高 $r_0 = 0.5$ 时的波前重构精确度。

## 4 结 论

本文利用大气湍流的谱反演法生成畸变波前,制作远场光强与泽尼克像差系数的样本对,训练卷积神经网络。训练完成的卷积神经网络能够从远场强度图中识别出波前的4~30阶泽尼克系数,以较高的精度快速重构出畸变波前,实现在无波前自适应光学系统中的波前校正。目前,主要使用仿真样本对卷积神经网络进行重构波前的训练和验证,下一步将采集实际光学系统中的样本进行波前重构,进而实现在实际无波前自适应光学闭环校正系统的应用。

**致 谢** 感谢中国工程物理研究院应用电子学研究所主动光学组全体职工给予的指导和帮助。

## 参 考 文 献:

- [1] 周仁忠. 自适应光学[J]. 中国光学, 1997(5): 98-99. (Zhou Renzhong. Adaptive optics[J]. Optics of China, 1997(5): 98-99)
- [2] Hardy J W. Adaptive optics: a progress review[C]//Proceedings of SPIE Active and Adaptive Optical Systems. San Diego, CA, USA: SPIE, 1991: 1542.
- [3] Yasuno Y, Wiesendanger T F, Ruprecht A K, et al. Wavefront-flatness evaluation by wavefront-correlation-information-entropy method and its application for adaptive confocal microscope[J]. Optics Communications, 2004, 232(1/6): 91-97.
- [4] 母杰, 景峰, 王逍, 等. 相干合成中基于SPGD算法的平移误差和倾斜误差控制[J]. 中国激光, 2014, 41: 0602002. (Mu Jie, Jing Feng, Wang Xiao, et al. Error control of piston and tilt based on SPGD in coherent beam combination[J]. Chinese Journal of Lasers, 2014, 41: 0602002)
- [5] Vorontsov M A, Carhart G W, Ricklin J C. Adaptive phase-distortion correction based on parallel gradient-descent optimization[J]. Optics Letters, 1997, 22(12): 907-909.
- [6] Débarre D, Booth M J, Wilson T. Image based adaptive optics through optimisation of low spatial frequencies[J]. Optics Express, 2007, 15(13): 8176-8190.
- [7] Kendrick R L, Acton D S, Duncan A L. Phase-diversity wave-front sensor for imaging systems[J]. Applied Optics, 1994, 33(27): 6533-6546.
- [8] Guo Hong, Korablinova N, Ren Qiushi, et al. Wavefront reconstruction with artificial neural networks[J]. Optics Express, 2006, 14(14): 6456-6462.
- [9] 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.
- [10] Paine S W, Fienup J R. Machine learning for improved image-based wavefront sensing[J]. Optics Letters, 2018, 43(6): 1235-1238.
- [11] Nishizaki Y, Valdivia M, Horisaki R, et al. Deep learning wavefront sensing[J]. Optics Express, 2019, 27(1): 240-251.
- [12] 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.
- [13] 马慧敏, 焦俊, 乔焰, 等. 一种基于光强图像深度学习的波前复原方法[J]. 激光与光电子学进展, 2020, 57: 081103. (Ma Huimin, Jiao Jun, Qiao Yan, et al. Wavefront restoration method based on light intensity image deep learning[J]. Laser & Optoelectronics Progress, 2020, 57: 081103)
- [14] He Kaiming, Zhang Xiangyu, Ren Shaoqing, et al. Deep residual learning for image recognition[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [15] 徐瑞超, 高明. 大气湍流等效相位屏的仿真研究[J]. 西安工业大学学报, 2018, 38(2): 108-113. (Xu Ruichao, Gao Ming. Simulation of the equivalent phase screen distorted by atmospheric turbulence[J]. Journal of Xi'an Technological University, 2018, 38(2): 108-113)
- [16] Yan Haixing, Li Shushan, Zhang Deliang, et al. Numerical simulation of an adaptive optics system with laser propagation in the atmosphere[J]. Applied Optics, 2000, 39(18): 3023-3031.
- [17] Lane R G, Glindemann A, Dainty J C. Simulation of a Kolmogorov phase screen[J]. Waves in Random Media, 1992, 2(3): 209-224.
- [18] Yang Ping, Ao Mingwu, Liu Yuan, et al. Intracavity transverse modes controlled by a genetic algorithm based on Zernike mode coefficients[J]. Optics Express, 2007, 15(25): 17051-17062.
- [19] 粘伟, 刘兆军, 李博. 大口径空间望远镜变形镜校正能力分析[J]. 科学技术与工程, 2018, 18(23): 219-223. (Nian Wei, Liu Zhaojun, Li Bo. Correction quality analysis of deformable mirror for large aperture space telescope[J]. Science Technology and Engineering, 2018, 18(23): 219-223)