

基于离焦光栅的单帧深度学习相位反演算法

邱学晶^{1,2,3}, 赵旺^{1,2}, 杨超^{1,2,3}, 程涛^{1,2,3}, 王帅^{1,2}, 许冰^{1,2}

1. 中国科学院光电技术研究所自适应光学重点实验室, 四川成都 610209;
2. 中国科学院光电技术研究所, 四川成都 610209;
3. 中国科学院大学, 北京 100049)

摘要: 针对目前相位差法收敛速度慢以及需要 CCD 在焦面以及离焦面多次测量的问题, 提出了基于离焦光栅的单帧深度学习相位反演算法。该算法用离焦光栅对入射波前进行调制, 可同时在透镜焦平面上获得正负离焦以及焦面远场光强分布; 此外算法引入卷积神经网络替代原有的多次扰动寻优过程, 波前复原算法耗时大大降低。仿真结果表明: 算法可根据单帧透镜焦面远场光强分布实现高精度快速波前复原, 残差波前的均方根为入射波前均方根的 6.7%, 算法进行一次波前复原所需时间可小于 0.6 ms。

关键词: 波前复原; 离焦光栅; 卷积神经网络; 相位差法

中图分类号: O439 **文献标志码:** A **DOI:** 10.3788/IRLA20200273

A single-frame deep learning phase retrieval algorithm based on defocus grating

Qiu Xuejing^{1,2,3}, Zhao Wang^{1,2}, Yang Chao^{1,2,3}, Cheng Tao^{1,2,3}, Wang Shuai^{1,2}, Xu Bing^{1,2}

1. Key Laboratory of Adaptive Optics, Institute of Optics and Electronics, Chinese Academy of Sciences, Chengdu 610209, China;
2. Institute of Optics and Electronics, Chinese Academy of Sciences, Chengdu 610209, China;
3. University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: Aiming at drawbacks of slow convergence rate and multiple measuring on focal or defocus plane by CCD in phase diversity algorithm, a single-frame deep learning phase retrieval algorithm based on defocus grating was proposed. Algorithm used a defocus grating to modulate incident wavefront, far-field intensity distribution of focal and positive/negative defocus plane can be acquired on focal plane of lens at the same time. In addition, convergence rate was improved when algorithm applied CNN to replace multiple perturbation optimization process. Numerical simulations indicate that the proposed method can achieve precise high-speed wavefront reconstruction with a single far-field intensity distribution, root mean square (RMS) of residual wavefront is 6.7% of that of incident wavefront, computing time for algorithm to perform wavefront reconstruction can be less than 0.6 ms.

Key words: wavefront reconstruction; defocus grating; convolutional neural network; phase diversity

收稿日期: 2020-07-10; 修订日期: 2020-08-15

基金项目: 国家自然科学基金 (61805251, 61875203, 11704382)

作者简介: 邱学晶 (1997-), 男, 硕士生, 主要从事自适应光学相关工作。Email: qxj_ioe@qq.com

导师简介: 许冰 (1960-), 男, 教授, 主要从事自适应光学相关工作。Email: bingxu@ioe.ac.cn

0 引言

相位反演 (Phase Retrieval, PR) 技术根据远场光强分布重构波前相位信息, 它对环境不敏感, 无需波前传感器, 在天文观测、光束质量评价、自适应光学、相位恢复^[1-4]等领域有广泛应用。Gerchberg-Saxton (GS) 算法是一类经典的 PR 算法^[5]。GS 算法利用角谱传输理论, 根据远场复振幅和近场复振幅的傅里叶变换关系多次迭代计算波前像差, 它结构简单易于实现, 但由于存在同一远场对应多个波前的多解问题^[6], GS 算法易陷入局部极值, 收敛精度低。

为了克服 GS 算法中的多解问题, Gonsalves 利用焦面和离焦多帧远场光强信息反演波前相位^[7], 进而提高收敛精度, 这类算法被称为相位差 (Phase diversity, PD) 法。PD 法需要 CCD 在焦面和离焦面多次测量。此外, PD 法仍需多次迭代才能收敛, 实时性差。Alexandra 引入非冗余掩膜实现单帧焦面图像相位反演^[8], 无需 CCD 在焦面和离焦面多次测量。然而, 非冗余掩膜需要多次进出光路, 系统结构复杂, 该算法在实际波前探测中应用有限。

近年来有学者开始利用卷积神经网络 (Convolutional Neural Network, CNN) 的非线性拟合特性来提高 PR 的收敛速度与收敛精度: Ju Guohao 等人引入 Tchebichef 矩提取一对焦面和离焦远场图像的位置特征并将 Tchebichef 矩作为网络的输入^[9], 虽然这种方法简化了网络结构, 但由于需要对图像进行预处理, 系统实时性变差; 有学者尝试根据单帧焦面远场光强分布利用 CNN 预测波前像差, 但由于多解问题^[6]的存在, 目前仅能在小像差下进行高精度波前复

原^[10-12]; Guo Hongyang 等人利用 PD 的思想, 将 CNN 最后的全连接层替换成解卷积层, 网络经一次计算直接输出相位屏, 免去了 Zernike 模式拟合带来的误差^[13], 但此方法需要 CCD 在焦面和离焦面多次采样, 系统结构复杂。

文中提出了基于离散光栅的单帧深度学习 PR 算法: 将离焦光栅引入光路, 此时 CCD 在透镜焦面测量时可同时获得正负离焦和焦面远场光强分布; 此外算法引入 CNN 直接输出波前信息, 无需多次迭代寻优。

1 工作原理

离焦光栅由 Blanchard 等人发明^[14], 它的光学特性如图 1(a) 所示, 示意图如图 1(b) 所示。离焦光栅可看成离轴的 Fresnel 波带片, 它存在对称分布的 ± 1 级衍射光轴且 1 级衍射光轴上存在一对共轭的焦距。在 ± 1 级衍射光轴上, 当离焦光栅与短焦距透镜密接使用时, 离焦光栅对透镜聚焦能力进行微调, 此时 ± 1 级衍射光轴上的焦距分别稍短和稍长于透镜焦距, 短焦距透镜的焦平面在 ± 1 级衍射轴上的截面是前后对称的离焦面。因此, 当 CCD 置于短焦距透镜焦平面处时, CCD 可同时测量入射波前在焦面与前后对称的离焦面上对应的远场光强分布。

当入射波前如图 2(a) 所示时, 置于短焦距透镜焦面处的 CCD 探测到的远场光强分布如图 2(b1) 所示, 从图 2(b1) 中提取出正负离焦以及焦面远场光强分布, 正离焦远场光强分布、焦面远场光强分布以及负离焦远场光强分布分别如图 2(b2)、(b3)、(b4) 所示。在设计 CNN 架构时将提取出的正负离焦以及焦面远场光强分布分为 3 个通道作为网络输入而不是直接




图 1 离焦光栅光学特性 (a) 以及离焦光栅示意图 (b)

Fig.1 Optical properties(a) and schematic diagram(b) of defocus grating

输入 CCD 测量到的短焦距透镜焦面远场光强分布 (如图 2(b1) 所示), 这样既可以减小算法的计算量, 也可以降低噪声对算法的影响。在波前探测中一组

180° 旋转翻转对称的入射波前对应同一远场光强分布, 单个离焦面无法克服这类多解问题, 而用相位差法进行波前复原时则不存在这类多解问题。

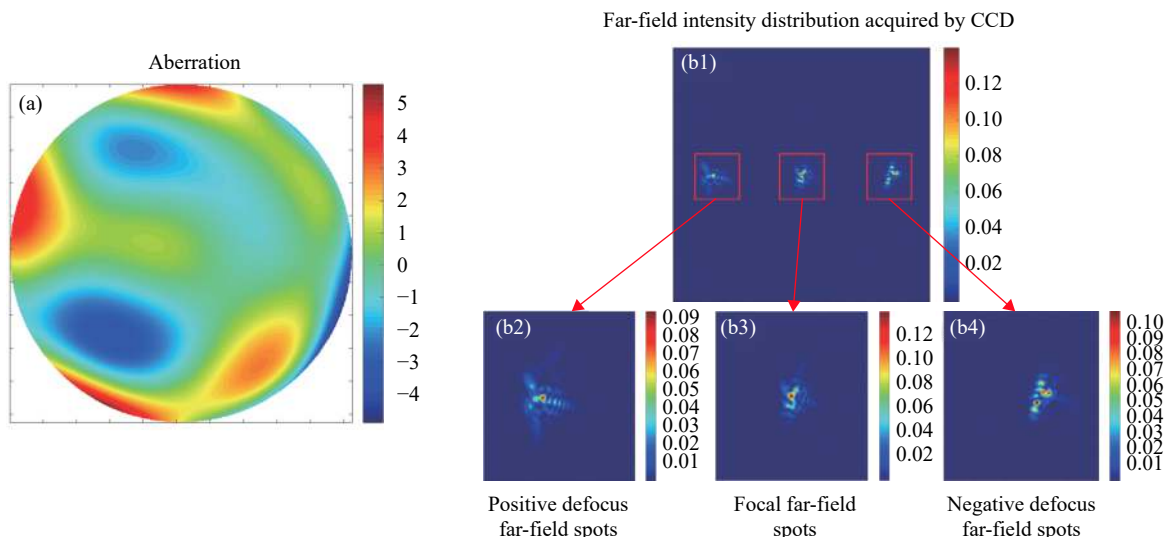


图 2 入射像差为 (a) 时对应的远场光强分布 (b1) 以及正离焦光斑 (b2)、焦面光斑 (b3)、负离焦光斑 (b4)

Fig.2 Far-field intensity distribution acquired by CCD (b1) and corresponding positive defocus spots (b2), focal plane spots (b3), negative defocus spots (b4) when incident aberration is (a)

基于离焦光栅的单帧深度学习 PR 算法工作原理如图 3 所示, CNN 用于拟合样本到相应的 Zernike 系数的非线性映射关系。在对 CNN 进行训练时, CNN 预测的系数与目标系数间的差值作为成本函数的输入, CNN 根据成本函数的梯度信息进行调参。训练完成后的 CNN 根据输入的样本直接输出 Zernike 系数, 实现快速波前复原。

文中所用 CNN 架构如图 4 所示, 它共有 15 层, 其中有 4 层卷积层, 4 层 Batch 正则化层, 4 层池化层, 2 层全连接层。超参数设置见图 4: 输入层通道数为 3, 输入图像大小为 100 pixel×100 pixel; 卷积层的通道数分别为 16、16、32、32; 卷积核大小分别为 5×5、5×5、4×4、4×4; 池化层选用步长为 2 的最大池化; 全连接层的神经元个数分别为 300、20。CNN 选用 ReLU 函数作为激活函数, 它连接在全部卷积层以及第一个全连接层之后。

2 仿真验证

仿真相关参数如下: 入射光波长 1 064 nm, 通光口径 8 mm, 离焦光栅边长 16 mm, 离焦光栅焦距 7.5 mm, 离焦光栅的扭曲光栅狭缝相对于规则线光栅

狭缝位移 33.75 mm, 短焦距透镜焦距 200 mm, CCD 像素大小 12 μm×12 μm, 离焦光栅相位台阶深度分别为 0.639π 与 2π, CCD 上开窗大小 100 pixel×100 pixel, CNN 训练时 batchsize 设置为 100, epoch 设置为 200, 选用均方误差函数为 CNN 损失函数, Adam 函数为梯度下降函数, 工作站配置为 Intel Core i7 9700 K 3.6 GHz, Kingston 64 GB, NVIDIA GeForce RTX2080Ti。仿真中, 训练过程和测试过程均在 GPU 上完成。算法大概需要 10 min 去完成 CNN 训练, 训练好后的 CNN 进行一次波前复原大概需要 0.6 ms。当工作站配置更高时, 算法耗时更少。

2.1 生成数据集

像差倾斜项大小可根据焦面质心计算获得, 因此文中不考虑第 2 与第 3 阶 Zernike 模式。根据第 4~23 阶 Zernike 系数随机生成 10 000 组入射波前, 入射波前经离焦光栅调制后经 CCD 测量获得短焦距透镜焦面远场光强分布, 从短焦距透镜焦面远场光强分布中提取出正负离焦以及焦面远场光强分布作为样本, 各阶 Zernike 系数的范围在 ±0.5 μm 以内。训练集与测试集的样本独立同分布, 从这 10 000 组样本中随机抽取 9 000 组样本以及相应的 Zernike 系数分别作为

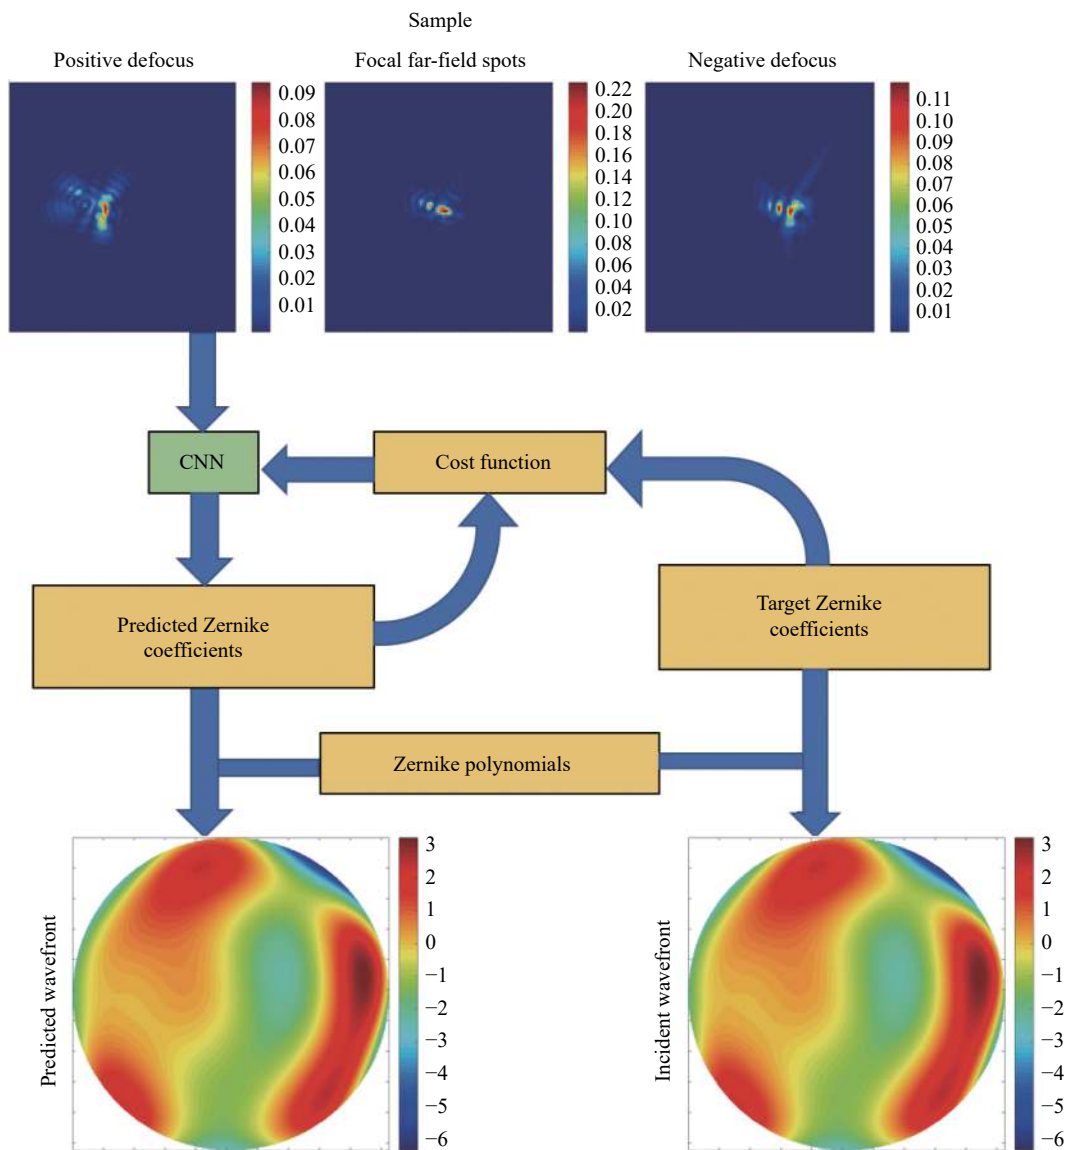


图 3 基于离焦光栅的单帧深度学习 PR 算法工作原理示意图

Fig.3 Schematic diagram of single-frame deep learning PR algorithm based on defocus grating

训练集中的样本和标签, 剩余的 1 000 组样本以及相应的 Zernike 系数分别作为测试集中的样本和标签。图 5 给出了训练集中一组样本以及对应的标签和此时的入射波前。由图 5(c) 知, 样本由 3 个通道组成, 3 个通道分别为从短焦距透镜焦面远场光强分布中提取出的正离焦远场光强分布、焦面远场光强分布以及负离焦远场光强分布。

2.2 评价指标

为验证仿真结果, 选取残差波前的方均根 (Root Mean Square, RMS) 作为评价指标, 它的表达式为:

$$RMS = \sqrt{\frac{1}{\pi} \int_0^{2\pi} \int_0^1 [w - \bar{w}]^2 r dr d\theta} \quad (1)$$

式中: w 表示残差波前; \bar{w} 表通光口径内残差波前平均值。RMS 的单位是波长 λ 。残差波前 RMS 越小, 算法预测的波前形状越接近入射波前形状。

引入均方根误差 (Root Mean Square Error, RMSE) 衡量 CNN 预测的 Zernike 系数拟合的好坏, 它的表达式为:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{\text{predict}}^{(i)} - y_{\text{label}}^{(i)})^2} \quad (2)$$

式中: n 为 Zernike 阶数; 上标 (i) 为第 i 阶 Zernike

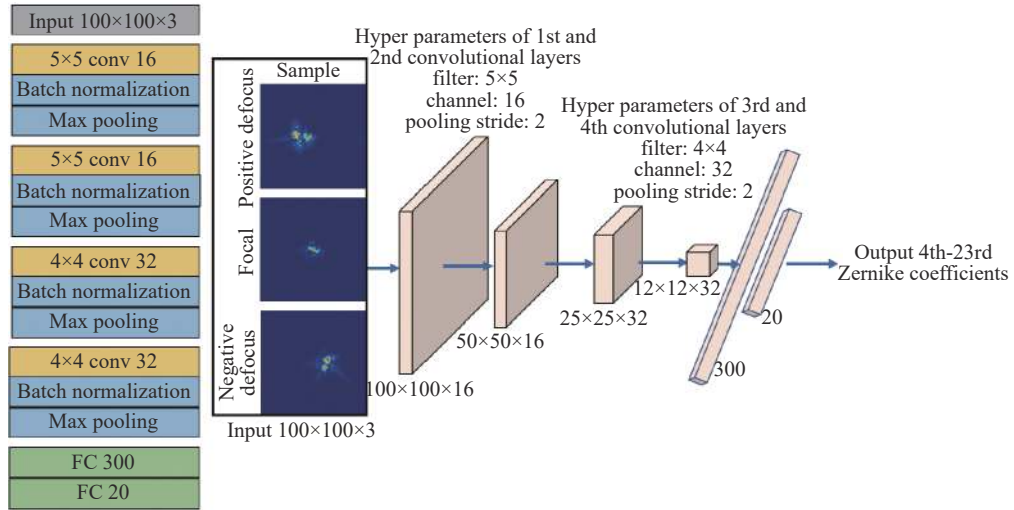


图 4 CNN 架构示意图

Fig.4 Schematic diagram of CNN architecture




图 5 训练集中的一组样本 (c) 及其标签 (b) 以及对应的入射波前 (a)

Fig.5 A sample from training set(c) and corresponding label(b), corresponding incident wavefront(a)

系数; y_{predict} 为 CNN 预测的各阶 Zernike 系数; y_{label} 为测试集中样本对应的标签, 即真实值。文中, CNN 输出第 4~23 阶 Zernike 系数, $n=20$ 。RMSE 的单位是微米。RMSE 越小, 算法预测的 Zernike 系数与标签真实值拟合的越好, 复原精度越高。

2.3 仿真结果与分析

图 6 为 1 000 组测试样本对应的入射波前进行波前复原前后的入射波前 RMS 与残差波前 RMS 变化情况。由图 6 可知, 1 000 组测试样本对应的入射波前的平均 RMS 为 1.289λ , 波前复原后残差波前平均 RMS

降到 0.087λ , 残差波前 RMS 为入射波前 RMS 的 6.7%。

从测试集中任意抽取 2 个样本, 图 7 中 (a1)~(a4) 分别为第 30 组样本对应的 Zernike 系数拟合情况、入射波前、CNN 预测波前和残差波前, (b1)~(b4) 分别为第 799 组样本对应的 Zernike 系数拟合情况、入射波前、CNN 预测波前和残差波前。

由图 7 知, 第 30 组样本初始波前 $RMS=1.043\lambda$, CNN 预测波前 $RMS=1.036\lambda$, 残差波前 $RMS=0.05\lambda$, CNN 预测的各阶系数与真实值间的 $RMSE=0.0346\mu\text{m}$, 各阶 Zernike 模式系数均实现了良好拟合。第 799 组样本对应的入射波前 $RMS=1.089\lambda$, CNN 预测波前 $RMS=1.072\lambda$, 残差波前 $RMS=0.056\lambda$, CNN 预测的各

阶系数与真实值间的 $RMSE$ 等于 $0.0251\mu\text{m}$, 各阶 Zernike 模式系数均实现了良好拟合。




图 6 1000 组测试样本的复原情况

Fig.6 Reconstruction accuracy of 1000 test samples

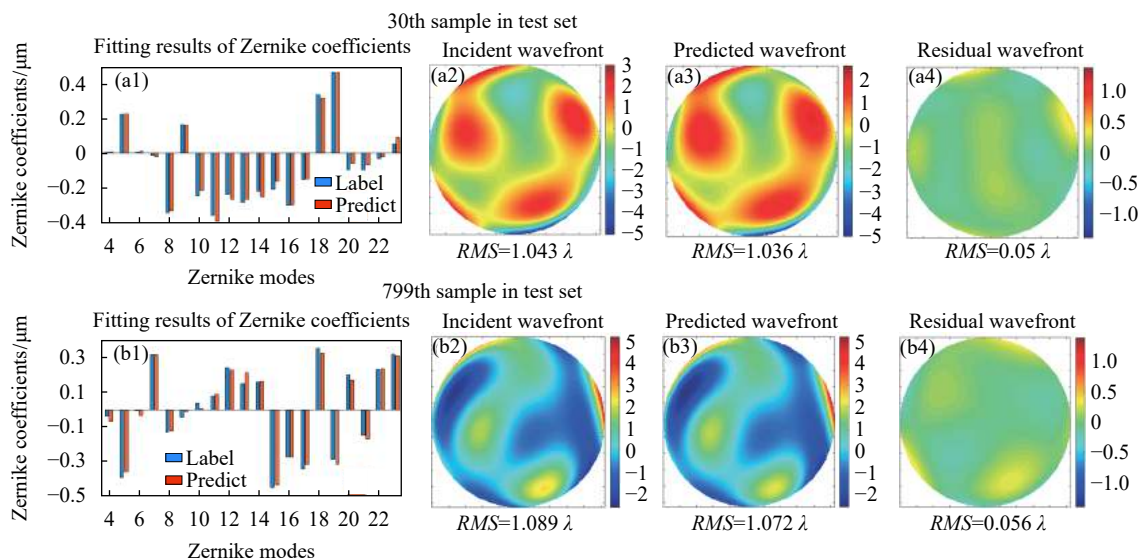


图 7 测试集中第 30 组和第 799 组样本对应的 Zernike 系数拟合情况、入射波前、CNN 预测波前和残差波前

Fig.7 Fitting results of Zernike coefficients, incident wavefront, predicted wavefront and residual wavefront of 30th sample and 799th samples in test set

由图 6 和图 7 知, CNN 预测波前与入射波前近似一致, 残差波前 RMS 远小于入射波前 RMS , 算法预测的 Zernike 模式系数与真实值拟合的很好, 算法实现了高精度波前复原。

2.4 高阶像差复原精度分析

由 2.1 节知, 训练集和测试集的入射波前均根据第 4~23 阶 Zernike 多项式随机生成, 各阶 Zernike 模式系数范围在 $\pm 0.5\mu\text{m}$ 以内, 此时训练好后的 CNN 可根据单帧短焦距透镜焦面远场光强分布经一次计算精确复原波前。此节为了验证高阶像差的波前复原精度, 额外分别生成仅包含第 19 阶、第 20 阶、第

21 阶、第 22 阶、第 23 阶 Zernike 多项式的像差各 100 组, 各阶 Zernike 模式系数范围在 $\pm 0.5\mu\text{m}$ 以内。按照 2.1 节的描述, 根据这 500 组入射波前生成一个新的测试集。用 2.2 节中训练好的 CNN 对这 500 组入射波前进行拟合, 图 8 给出了这 500 组入射波前的拟合情况。由图 8 知, 算法预测的第 19~23 阶 Zernike 系数与真实值间的 $RMSE$ 分别为 0.0391 、 0.0397 、 0.0354 、 0.0322 、 $0.0308\mu\text{m}$, 预测值与真实值间的差距很小, CNN 实现了良好拟合。算法进行一次波前复原所需时间仍约为 0.6ms 。

从这 500 组样本里随机抽取 5 组样本, 它们分别

仅由第 19 阶、第 20 阶、第 21 阶、第 22 阶、第 23 阶 Zernike 多项式生成。图 9 给出了这 5 组样本对应的入射波前、CNN 预测波前以及残差波前的面形以及 RMS。

由图 9 可知,由各阶 Zernike 多项式生成入射波前与 CNN 相应的预测波前面形几乎一致,第 19~23 阶 Zernike 多项式对应的残差波前 RMS 分别为 0.087λ 、 0.088λ 、 0.079λ 、 0.072λ 、 0.068λ ,残差波前很小,训练好后的 CNN 可对单阶高阶像差进行高精度波前复原。




图 8 额外生成的 500 组样本的复原情况

Fig.8 Reconstruction accuracy of another 500 samples

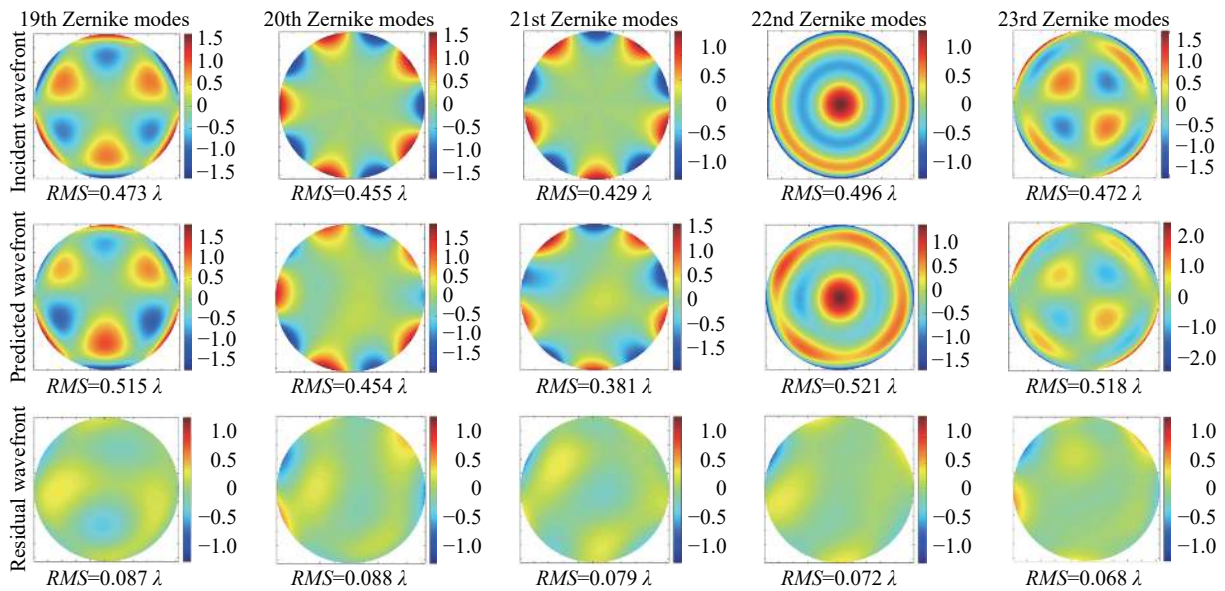


图 9 第 19~23 阶 Zernike 多项式对应的入射波前、CNN 预测波前以及残差波前

Fig.9 Incident wavefront, wavefront predicted by CNN and residual wavefront corresponding to 19th-23rd Zernike modes

3 结 论

文中提出了一种基于离焦光栅的单帧深度学习相位反演算法,建立了一种新的单帧焦面远场光强分布到 Zernike 系数的映射关系。算法引入离焦光栅对入射波前进行调制;离焦光栅与短焦距透镜密接使用时,离焦光栅 ± 1 级衍射光的焦距方向相反且分别稍短和稍长于透镜焦距,此时 CCD 可在短焦距透镜焦面上同时测量正负离焦以及焦面远场光强分布。算法还利用 CNN 的非线性拟合特性,引入 CNN 替代 PR 算法的迭代寻优过程,充分训练后的 CNN 仅需一次计算即可给出波前相位信息,极大提高了 PR 算法的收敛速度。数值仿真表明:文中提出的算法可根据离焦光栅调制后的单帧焦面远场光强分布实现高精

度快速波前复原,残差波前 RMS 为入射波前 RMS 的 6.7%,系统进行一次波前复原所需时间可小于 0.6 ms。

参考文献:

- [1] Fienup J R, Marron J C, Schulz T J, et al. Hubble Space Telescope characterized by using phase-retrieval algorithms [J]. *Applied Optics*, 1993, 32(10): 1747.
- [2] Nicolas Védrenne, Mugnier Laurent M, Vincent Michau, et al. Laser beam complex amplitude measurement by phase diversity [J]. *Optics Express*, 2014, 22(4): 4575-4589.
- [3] Gao C, Zhang S, Fu S, et al. Adaptive optics wavefront correction techniques of vortex beams [J]. *Infrared and Laser Engineering*, 2017, 46(2): 0201001.
- [4] Cheng H, Xiong B, Wang J, et al. Phase retrieval technology

- based on chromatic dispersion and transport of intensity equation in lens model [J]. *Infrared and Laser Engineering*, 2019, 48(6): 0603018.
- [5] Misell D L. An examination of an iterative method for the solution of the phase problem in optics and electron optics: I. Test calculations [J]. *Journal of Physics D Applied Physics*, 1973, 6(18): 2200-2216.
- [6] Fienup J R, Wackerman C. Phase-retrieval stagnation problems and solutions [J]. *Journal of Optical Society of America A*, 1986, 3(11): 1897-1907.
- [7] Gonsalves R A. Phase retrieval and diversity in adaptive optics [J]. *Optical Engineering*, 1982, 21(5): 829-832.
- [8] Greenbaum A Z, Sivarakrishnan A. In-focus wavefront sensing using non-redundant mask-introduced pupil diversity [J]. *Optics Express*, 2016, 24(14): 15506-15521.
- [9] Ju G, Qi X, Ma H, et al. Feature-based phase retrieval wavefront sensing approach using machine learning [J]. *Optics Express*, 2018, 26(24): 31767-31783.
- [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] Qinghua T, Chenda L, Bo L, et al. DNN-based aberration correction in a wavefront sensorless adaptive optics system [J]. *Optics Express*, 2019, 27(8): 10765-10776.
- [13] Guo H, Xu Y, Li Q, et al. Improved machine learning approach for wavefront sensing [J]. *Sensors*, 2019, 19(16): 3533-3545.
- [14] Blanchard Paul M, Greenaway Alan H. Simultaneous multiplane imaging with a distorted diffraction grating [J]. *Applied Optics*, 1999, 38(32): 6692-6699.