

## 基于双光斑的深度学习波前复原及校正

许元斋<sup>1,2</sup>, 唐秋艳<sup>3</sup>, 王小军<sup>1</sup>, 郭亚丁<sup>1</sup>, 张林<sup>1\*</sup>, 魏花<sup>3</sup>, 彭钦军<sup>1</sup>, 吕品<sup>4</sup><sup>1</sup>中国科学院理化技术研究所, 北京 100190;<sup>2</sup>中国科学院大学, 北京 100049;<sup>3</sup>中国科学院软件研究所, 北京 100191;<sup>4</sup>中国科学院自动化研究所, 北京 100190

**摘要** 探索了深度学习算法求解光强反演波前的非线性映射, 实现了基于深度学习的波前探测(DLWFS)在自适应光学波前校正中的应用。采用聚焦和离焦双光斑反演波前, 既简化了探测器结构, 又减小了探测器体积。由于光强反演波前的过程在物理上不存在显式解, 因此可以利用深度学习模型 cGAN, 通过类似图像处理的方式, 建立光强-相位的非线性映射, 将光斑的强度分布反演为波前分布, 最终使波前校正系统配备较为紧凑的波前探测器。训练数据集通过物理衍射仿真获得, 模型在测试集上的波前复原的最小残差  $RMS < 0.3 \mu\text{m}$ 。在实验中, DLWFS 与参考哈特曼波前探测器波前的残差  $RMS$  在  $0.0965 \sim 0.1531 \mu\text{m}$  之间。在自适应光学波前校正实验中, 将 DLWFS 作为自适应光学闭环校正过程中的波前探测器, 验证了 DLWFS 的实用效果, 光束质量因子从 10.83 校正至 3.61。此外, 还讨论了 DLWFS 的参数敏感性。

**关键词** 自适应光学; 波前复原; 深度学习; 光束质量

中图分类号 O436.1

文献标志码 A

DOI: 10.3788/CJL231202

## 1 引言

光强反演波前以其在自适应光学(AO)系统中所具有的硬件简单、成本较低等优势而被广泛研究, 同时也拓展了自适应光学在生物医学成像、天文观测和光束净化等领域的应用<sup>[1-3]</sup>。本文研究了基于深度学习的波前复原方法及其在自适应光学校正激光波前中的应用。

在激光光束会聚为焦点过程中, 波前分布会影响焦点的光强分布, 但是难以通过物理过程解析建立焦点光强分布到波前分布的反向映射关系。传统方法, 如 G-S 算法<sup>[4]</sup>及其改进算法<sup>[5-6]</sup>, 虽然提供了像平面与衍射平面间的迭代傅里叶变换算法, 但较大的计算量以及对像差的限制使得其在自适应光学中的应用十分有限。由于聚焦过程压缩了波前信息<sup>[7]</sup>, 加之相机采集能力限制了对光强的分辨率, 故这一反演过程需要一个具有更强大理解、分析能力的模型来解决。深度学习算法, 如条件对抗神经网络(cGAN)<sup>[8]</sup>, 能从输入光强信息  $I_r$  中提取出深层特征信息, 实现光强反演波前。

基于光强-波前的映射关系, 笔者采用深度学习实现波前复原, 并以此建立基于深度学习的波前探测器(DLWFS)。深度学习对模糊目标和抽象方程具有较强的适应性, 甚至能在一定程度上像人类一样理解输入数据的结构<sup>[9-10]</sup>, 将反演映射问题视为光强向波前的

图像复原问题, 可用于处理光强反演波前。DLWFS 同时采集在焦、离焦的“双光斑”光强分布并将其作为输入, 输出复原波前, 因而可以作为激光光束波前校正的自适应光学系统中的波前探测器。

近几年, 研究人员利用深度学习算法对成像的波前进行了探测和校正<sup>[11-14]</sup>, 尤其是对大气扰动进行校正<sup>[12]</sup>后, 成像精度显著提升。其中, 通过对点扩散函数进行分析获得波前或 Zernike 多项式系数的研究, 拓展了通过强度反演波前的应用<sup>[11, 13-14]</sup>。而通过引入已知的相位差<sup>[15]</sup>、过曝<sup>[11]</sup>等特定探测条件, 可以降低强度反演波前过程中对被成像物的输入限制<sup>[11, 13]</sup>, 提高复原精度。此外, 在入射光束的波前探测方面, 有许多以多种空间分布光强作为输入, 经过深度学习模型输出波前或校正信号的研究。如: a) 以焦点阵列的强度分布作为输入(即输入类似哈特曼波前探测器(SHWFS)分布的阵列焦点)复原波前<sup>[16-18]</sup>; b) 以单焦点光斑光强分布作为输入, 利用卷积神经网络(CNN)<sup>[19-20]</sup>直接基于焦点光斑反演波前; c) 以双光斑光强分布作为输入(即将焦点和焦后光斑光强作为输入), 通过 CNN 计算 Zernike 多项式系数输出, 从而校正波前残差<sup>[21]</sup>, 或者通过三层人工神经网络(ANN)计算波前像差<sup>[22]</sup>; d) 以多光斑光强分布作为输入(即输入 6 组平行分布孔径的在焦、离焦光斑), 用 ANN 实现 piston 误差和光

收稿日期: 2023-09-14; 修回日期: 2023-10-20; 录用日期: 2023-11-09; 网络首发日期: 2023-11-17

通信作者: \*zhanglin@mail.ipc.ac.cn

瞳对准<sup>[23]</sup>,或者采集光路上一定间隔的 15 个光斑,实现波前复原<sup>[24]</sup>;e) 采用相位差法提取波前分布,即,采集不同离焦量的焦点、离焦光斑并将其作为输入(如将经过指数滤波器后的光强作为输入,则不需要迭代计算)<sup>[25]</sup>,或者用光栅产生多个不同离焦量的光斑<sup>[26]</sup>,实现波前分布的提取。这些研究表明,带有一定空间信息的强度分布可以通过深度学习算法实现波前复原,这为激光自适应光学系统中波前探测器的小型化和成本降低创造了可能性。

板条固体激光器,如 Textron 公司的 ThinZag<sup>[27]</sup>, Northrop Grumman 公司推出的 2~3 倍衍射极限的矩形光斑激光器<sup>[28]</sup>,通用原子公司开发的分布式增益激光器<sup>[29]</sup>,因具有优异的性能而备受关注。带有自适应光学校正系统的固体激光器可以产生更加均匀的近场分布和更集中的远场分布<sup>[1,30]</sup>。方形光斑因形状特殊,不适合用圆域 Zernike 多项式等传统的波前分析方法进行波前重构,而深度学习可以用于对不同形状的光斑进行波前重构。激光器的紧凑结构限制了波前探测器的体积,而 DLWFS 仅需要采集两个焦点附近的光斑,具有较好的光学适应性和结构紧凑性,能够在板条激光器的自适应光学系统中作为波前探测器。

为了检验深度学习方法的波前复原能力,笔者比较了 DLWFS 和参考 SHWFS 的波前复原结果,随后在自适应光学波前校正闭环过程中应用 DLWFS 的波前数据,验证其实用性。

## 2 原理

DLWFS 的基本原理如图 1 所示,即:将光轴上的在焦、离焦双光斑光强分布反演为波前分布。波前畸变所影响的焦点光斑的强度分布可以通过基于标量的衍射传输方程<sup>[31]</sup>解释,即

$$I_t(u, v) \propto \left| \int_{-\infty}^{\infty} W_A(x, y) \cdot \exp \left[ -j \frac{2\pi}{\lambda f} (xu + yv) \right] dx dy \right|^2, \quad (1)$$

式中:  $W_A$  为波前分布信息;  $\lambda$  为波长;  $f$  为聚焦透镜焦距;  $u$  和  $v$  分别为焦平面坐标,  $x$  和  $y$  分别为初始平面坐

标。光强分布  $I_t$  中包含了积分时压缩过的波前分布信息  $W_A$ 。由式(1)中光强分布的定义可知,  $W_A(\pm x, \pm y)$  在积分过程中会丢失正负坐标的差异性<sup>[7]</sup>,即在聚焦的衍射传输中旋转对称位置的相位信息会被积分过程压缩。为了获得更好的信息理解和特征提取效果,在单光斑的基础上增加焦前光斑,通过增加位置信息来提高波前复原能力。焦前光斑尚未被完全压缩,增加这部分光强分布信息可以提高波前复原的准确性。实际上,这一方法利用了沿着光轴空间分布的光强信息。类似地, SHWFS 利用的是垂直于光轴分布的阵列光强信息。

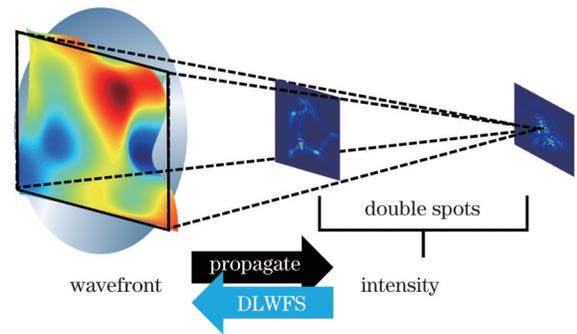


图 1 DLWFS 原理示意图

Fig. 1 Schematic diagram of DLWFS

本文采用的 cGAN 在图像复原(如 Pix2pix<sup>[8]</sup>)方面具有较好的效果。这一模型由生成式对抗神经网络<sup>[32]</sup>(GAN)改进而来,在训练判别器(D)时增加了输入的条件。其中,生成器(G)由 U-Net<sup>[33]</sup>结构构成,U-Net 能够将高分辨率的信息通过特征编码过程提炼出来,故生成器具备提取深层特征信息的能力,能够理解数据之间的内在联系。因此,在理论上,cGAN 具备将两种具有内在联系的结构建立起非线性映射的能力。入射波前与光强分布的正向映射关系也向 cGAN 提供了反向映射的物理内在联系。训练就好比是使模型积累观察光斑的经验,进而从分布的样式上推断像差。

### 2.1 深度学习模型训练

本文采用的 cGAN 模型结构示意图如图 2 所示。在训练过程中,将输入的光强分布  $x(x_1, x_2)$  通过一个由

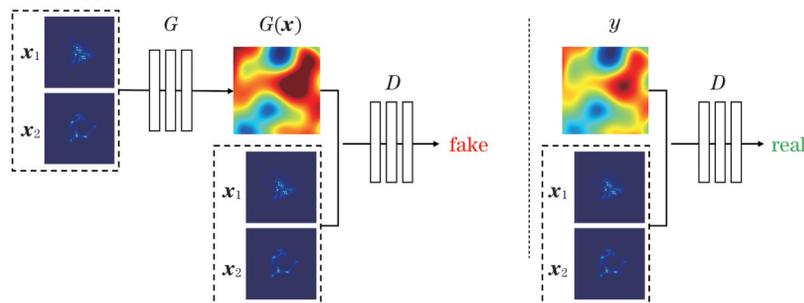


图 2 DLWFS 模型结构,其中  $x(x_1, x_2)$  为输入的双光斑光强分布数据,  $G$  为生成器,  $D$  为判别器,  $y$  是用于训练判别器的输入波前真实值

Fig. 2 DLWFS model structure, where  $x(x_1, x_2)$  is input double spots intensity data,  $G$  is the Generator,  $D$  is Discriminator, and  $y$  is input random wavefront data as "real" data to train Discriminator

8个卷积层的编码器和7个卷积层的解码器构成的U-Net生成器 $G$ 复原为波前输出 $G(x)$ ;判别器由6个卷积层构成,训练判别器识别生成器的结果和输入 $(G(x), x)$ 为伪,识别真实输入值 $(y, x)$ 为真,每次判别输入的 $x$ 即为条件。

训练数据包括 $50\text{ mm} \times 50\text{ mm}$ 方形光斑和直径为 $50\text{ mm}$ 的圆形光斑,它们的强度均匀分布。将随机产生的波前分布(即真实值 $y$ )代入初始光斑,通过理想聚焦透镜(焦距 $f=1000\text{ mm}$ )和衍射传输仿真产生焦点和焦前双光斑的光强分布,即 $x(x_1, x_2)$ 。其中,焦前光强分布 $x_2$ 是在 $0.98$ 倍焦距位置处采集的光斑。在较大像差下, $0.98$ 倍焦距处光斑的直径比焦点处的大 $2\sim 3$ 倍,可以在相机靶面上获得信息足够丰富的图像,并且两个位置处光斑的图像尺寸差异较小。实际采集的焦前光斑图像尺寸为 $512\text{ pixel} \times 512\text{ pixel}$ ,将其降采样至 $256\text{ pixel} \times 256\text{ pixel}$ ,与焦点光强为 $x_1$ 的光斑的图像尺寸一致,以提高映射计算的精度。

目标函数结合了cGAN和L1正则化<sup>[8]</sup>,具体为

$$\mathcal{L}_{L1}(G) = \mathbb{E}_{x,y,z} (\|y - G(x, z)\|_1), \quad (2)$$

$$\mathcal{L}_{cGAN} = \mathbb{E}_{x,y} [\lg D(x, y)] + \mathbb{E}_{x,z} \left\{ \lg \left\{ 1 - D[x, D(x, z)] \right\} \right\}, \quad (3)$$

$$G^* = \arg \min_G \max_D \mathcal{L}_{cGAN}(G, D) + \lambda \mathcal{L}_{L1}(G). \quad (4)$$

为使训练结果更准确,目标函数的权重 $\lambda$ 取 $100$ 。每种光斑的训练数据有 $25000$ 组,将其中的 $23000$ 组作为训练集,剩下的 $2000$ 组为测试集。训练周期(epoch)取 $250$ 次;丢弃率(dropout)取 $0.2$ ,以避免过拟合;使用学习速率为 $0.0001$ 的Adam优化器。

相较于纯编码-解码(encode-decode)结构的CNN生成器,cGAN前期的学习速率较低,损失函数收敛速度较慢,但其在 $117$ 个训练周期后具有更好的收敛效果,如图3所示。在第 $250$ 个训练周期后,cGAN的损

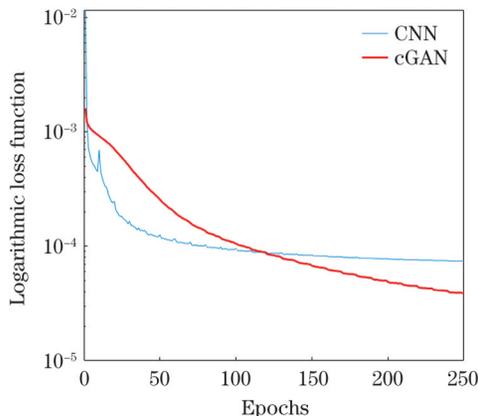


图3 cGAN和纯编码-解码CNN在训练过程中的损失函数变化次数的变化

Fig. 3 Loss function varying in training process of cGAN compared with CNN of encode-decode only

失函数约为CNN的一半。

训练所得的生成器 $G$ 在测试集上的表现如图4所示。生成的波前 $G(x)$ 与真实波前 $y$ 的分布基本一致。在图4中,最后一列图中标明了残差均方根(RMS)值。如第1组数据所示,当输入波前的峰值(PV值)为 $22.90\text{ }\mu\text{m}$ 时,复原的残差RMS值最低为 $0.5197\text{ }\mu\text{m}$ ;如第5组数据所示,当输入波前PV值为 $2.29\text{ }\mu\text{m}$ 时,复原的残差RMS值最低为 $0.2372\text{ }\mu\text{m}$ 。这些数据表明DLWFS具备在不同像差输入下的波前复原能力。

分析以上数据可知复原的残差可能来自以下两方面:1) 高空间频率的像差在主光斑周围产生弥散斑,导致光斑强度分布的变化较小,从而使得基于强度较为集中的焦点光强分布反演波前的方法很难实现高频波前像差的复原。2) 在低PV像差下,焦点和焦前衍射光斑类似于理想光斑,此时理想光斑的衍射环类分布反而成为复原波前所需信息的噪声,光强分布中所包含的波前信噪比(SNR)更低,有可能导致波前复原效果不及高PV像差下的复原效果。若采集过曝的光斑<sup>[11]</sup>,或能改善该信噪比问题。

## 2.2 DLWFS探测结果与参考波前的对比

如图5所示,分光棱镜将入射波前等分给参考SHWFS和DLWFS分别进行采集,其中反射光经过再次反射,使得透射光和反射光波前分布的方向一致。DLWFS的离焦位相机精确调节至焦点前 $20\text{ mm}$ 处,分光镜反射光用于采集离焦光斑,反射光的离焦光斑与透射光的焦点光斑在水平方向左右镜像,采集后需要左右翻转使离焦光斑与焦点光斑坐标方向一致。实验中采用的相机型号为Basler Aca2500-65um,参考SHWFS的型号为HASO3-128,缩束系统为6倍望远镜系统。

离焦光斑的强度比焦点光斑更低,离焦位相机的曝光时间设置得更长,以便能采集足够分辨率信息的强度分布。为使两光斑不受绝对强度的影响,采集的光强分布都进行归一化处理。在采集光斑时,裁切了光斑附近一定范围内相机靶面的图像,补偿了不影响双光斑形态的轻微倾斜量,降低了对光路调节精度的要求。另外,光斑质心相较于标准光源光斑在相机靶面上的相对偏移量也可以进一步作为倾斜量进行探测。

将DLWFS探测的波前结果与参考SHWFS的波前探测结果进行比较,数据展示于图6中。由对比结果可见,DLWFS的波前结果更为平滑,其波前幅值和分布形状与参考结果相近,残差RMS在 $0.0965\sim 0.1531\text{ }\mu\text{m}$ 之间。这一结果表明,DLWFS可以从光强中提取波前,与参考SHWFS具有可比性。

上述实验结果体现了DLWFS的探测敏感性。两者探测结果的差异主要集中在光斑边缘,而且越接近

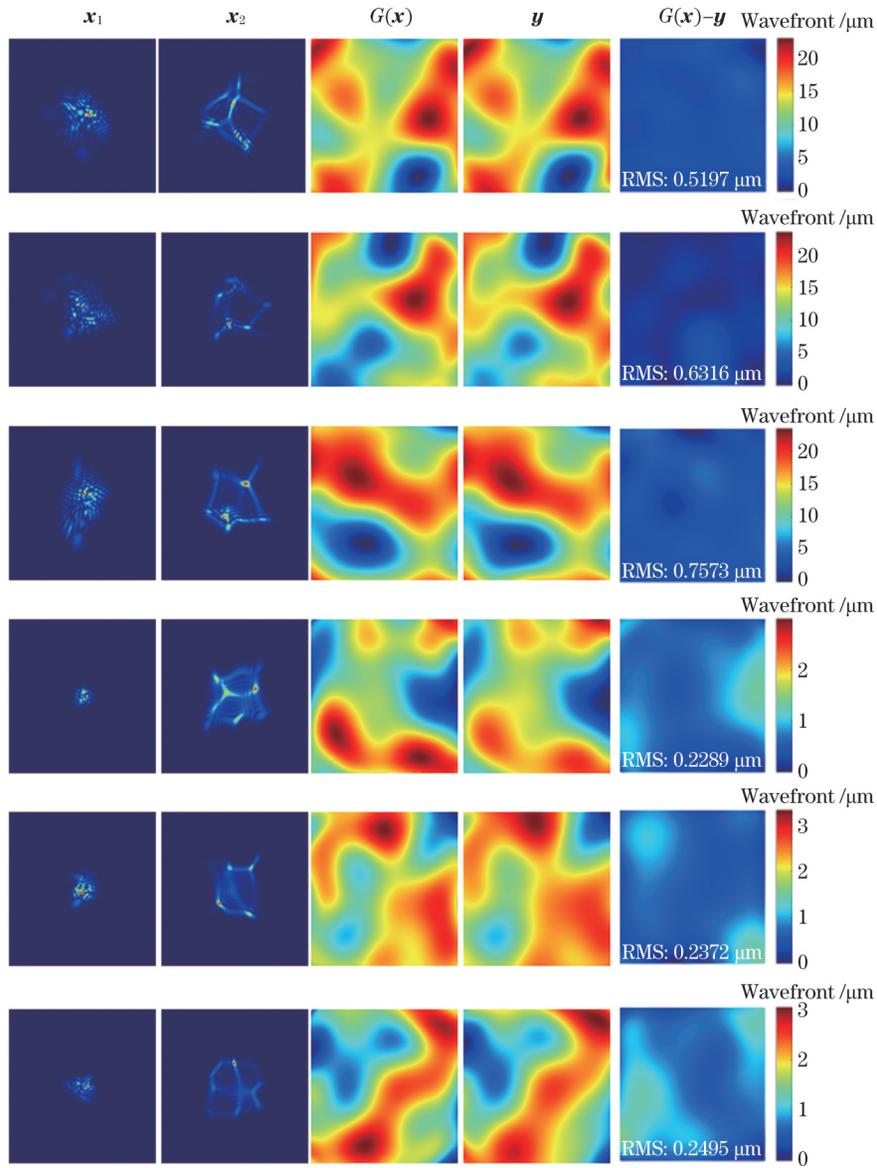


图4 DLWFS测试数据集及波前复原结果对比(第1、2列分别为在焦和离焦双光斑强度分布,第3、4列分别为DLWFS复原波前  $G(x)$  与真实波前  $y$ ,第5列为复原波前与真实值的残差)

Fig. 4 Test data sets and wavefront recovery results comparison of DLWFS ( columns 1 and 2 are the intensity data of on-focus spots and defocus spots, columns 3 and 4 are the recovered wavefront  $G(x)$  by DLWFS and the input real wavefront  $y$ , column 5 is the residual between the recovered wavefront and the real wavefront)

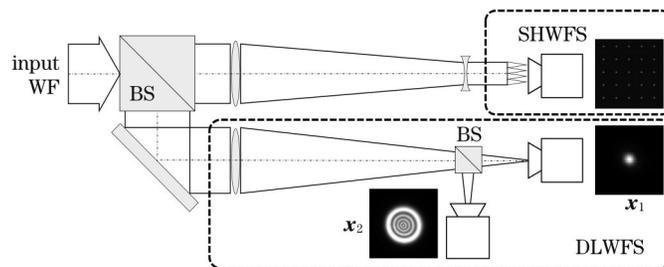


图5 DLWFS和SHWFS同步采集平台。分光镜的透射光波前由带望远镜缩束系统的参考SHWFS采集;反射光波前经再次反射后进入DLWFS,聚焦后的光束再次经过分光镜分别进入焦点位相机采集  $x_1$  和离焦位相机采集  $x_2$ 。BS:50/50分光镜

Fig. 5 Synchronized acquisition setup of DLWFS and referencing SHWFS. The transmitted beam is collected by referencing SHWFS behind an telescope beam reducer, the reflected beam is reflected again into DLWFS, then the converged beam is split by another BS into focus camera to collect  $x_1$  and into defocus camera to collect  $x_2$ . BS: 50/50 beam splitter prism

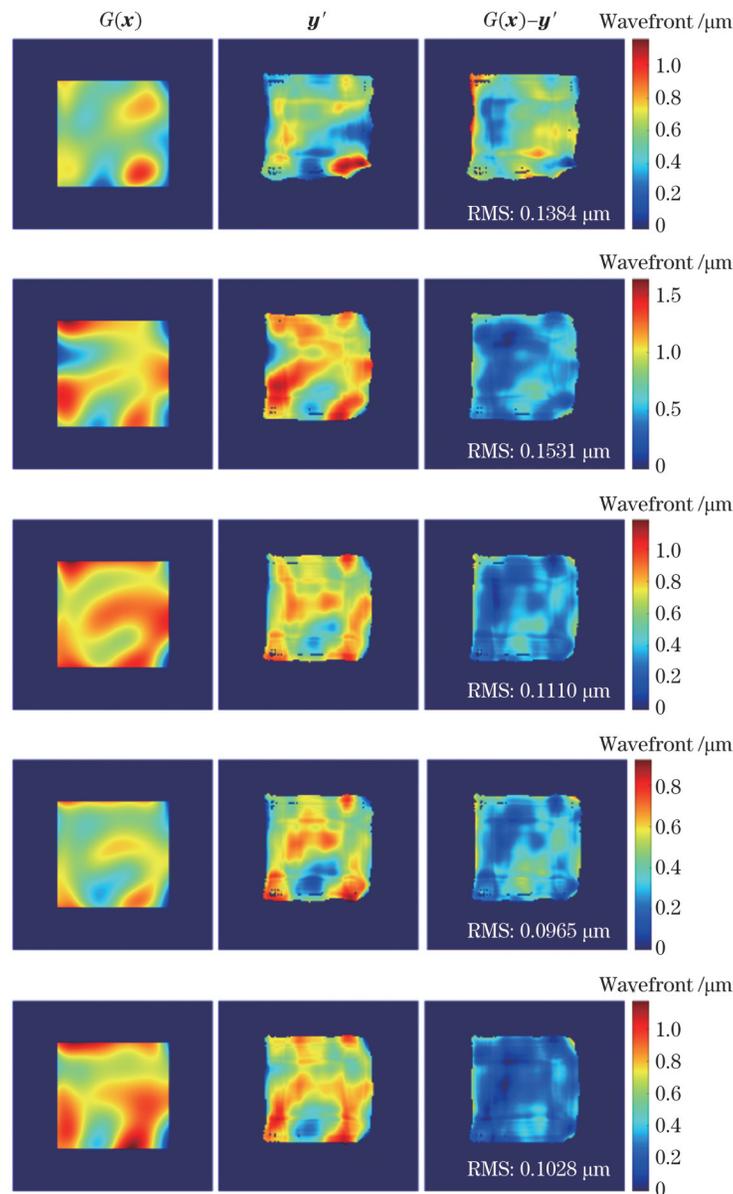


图6 DLWFS与参考SHWFS的波前探测结果。从左至右依次为DLWFS探测的波前 $G(x)$ 、参考SHWFS探测的波前 $y'$ 以及两者的残差

Fig. 6 Reconstructed wavefront by DLWFS and reference SHWFS. Three columns from left to right are wavefront  $G(x)$  retrieved by DLWFS,  $y'$  by reference SHWFS, and the residual error between two results

光斑中心,差异越小。在衍射传输过程中,矩形光斑边缘的衍射效应更强。本次验证实验中省略了成像系统,导致以变形镜为物的人射光光斑没有在DLWFS中的聚焦透镜前和SHWFS中的微透镜阵列前等效地成像。此外,DLWFS的训练数据都由绝对规则的矩形光斑生成,实际光斑边缘不规则的强度分布会影响波前探测的结果。如前文所述,较大的空间频率像差以及低PV像差光斑较低的波前SNR也可能会导致DLWFS探测的波前残差。

### 3 自适应光学波前校正

为了验证DLWFS在自适应光学系统中的应用效果,笔者将DLWFS作为自适应光学校正系统中的波

前探测器,在闭环校正中验证波前探测的效果。分别尝试对方形光斑(50 mm×50 mm)和圆形光斑(直径50 mm)进行了校正,校正结果表明DLWFS具备在自适应光学闭环系统中进行有效波前探测的能力。

#### 3.1 自适应光学系统平台

光源采用的是由焦距为1000 mm的凸透镜准直的激光。准直激光先后被两个变形镜(DM)反射,其中变形镜1(DM1)作为产生像差的扰动镜,变形镜2(DM2)作为校正像差的校正镜。激光经过分光棱镜(50/50)后分别进入参考SHWFS和DLWFS中采集波前。当DM1不上电时,可测量DM2的响应函数;当DM1上电并产生扰动像差时,DM2根据所测响应函数在闭环程序中校正像差。光路及测试平台结构示意图

图如图 7 所示。

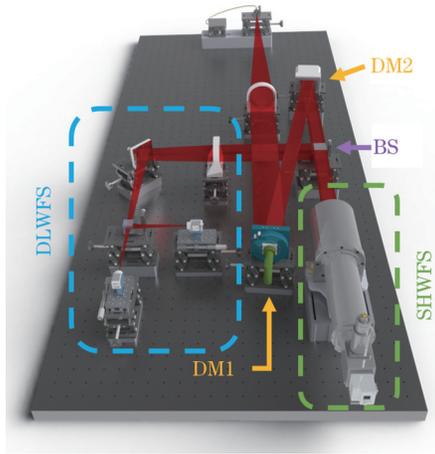


图 7 实验平台示意图(DM1:扰动镜;DM2:校正镜)

Fig. 7 An overview of the total experiment platform (DM1: disturbing deformable mirror; DM2: correcting deformable mirror)

为实现校正效果,校正器件的空间分辨率应高于像差,故而各器件的空间分辨率沿光路逐级升高。对于  $50\text{ mm} \times 50\text{ mm}$  的方形光斑,波前探测的空间分辨率高于校正镜 DM2,校正镜的空间分辨率高于扰动镜 DM1。各器件的空间分辨率如表 1 所示。其中:DM1 的促动点间隔为  $12\text{ mm}$ ;DM2 的促动点间隔为  $10\text{ mm}$ ;SHWFS 的子孔径周期为  $0.114\text{ mm}$ ,按照 6 倍缩束缩放后为  $0.684\text{ mm}$ ;对于 DLWFS,  $50\text{ mm}$  (方形光斑边长或圆形光斑直径) 尺寸对应 256 个数据点,即相邻点间隔约为  $0.195\text{ mm}$ 。

表 1 自适应光学系统中各器件的空间分辨率

Table 1 Spatial resolution of each component in the AO system

Component	Elements distance /mm	Spatial resolution / $\text{mm}^{-1}$
DM1	12	0.0833
DM2	10	0.1
SHWFS	$6 \times 0.114 = 0.684$	1.46
DLWFS	$50 \div 256 \approx 0.195$	5.12

### 3.2 自适应光学波前校正实验

DLWFS 直接从双光斑光强  $x(x_1, x_2)$  中映射波前分布  $G(x)$ , 可用于实现波前闭环校正过程中变形镜控制信号的计算, 类似于 SHWFS 采用直接斜率法通过各子孔径内聚焦光斑质心偏量计算控制信号。

首先采集由变形镜中  $n$  个促动点的单位电压波前响应  $W_i$  构造的响应函数  $R$ , 计算其广义逆  $R^\dagger$  并将其作为传递函数; 而后将采集的波前左乘传递函数  $R^\dagger$ , 得控制电压向量  $V$ 。具体计算过程为

$$\begin{cases} W_i = R V_i & i = 1 \rightarrow n \\ R^\dagger = (R^T R)^{-1} R^T \\ V = R^\dagger W \end{cases} \quad (5)$$

考虑到校正的稳定性,在闭环过程中取每次修改电压的闭环增益系数  $g$  为 0.5。每次迭代时,将电压向量  $V$  的一部分增加到前次迭代的电压  $V_{\text{prev}}$  中,便可得到每次迭代的输出电压  $V_{\text{out}}$ , 即

$$V_{\text{out}} = V_{\text{prev}} + gV \quad (6)$$

校正闭环逻辑如图 8 所示。控制函数  $R$  由 SHWFS 对 DM2 每个促动点的单位电压的波前响应  $W_i$  构成,如图中实线所示;将 DLWFS 采集的波前映射至与 SHWFS 相同大小的矩阵中,就可以在校正时离线用 SHWFS 响应函数和 DLWFS 采集的波前计算变形镜的控制电压,如图中虚线所示。

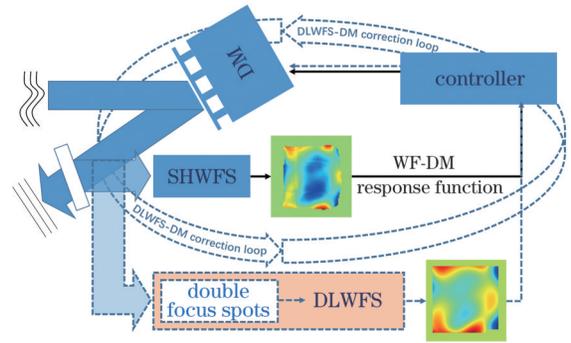


图 8 校正逻辑示意图(变形镜响应函数由 SHWFS 测得,在图中用实线表示;自适应光学闭环控制校正的波前由 DLWFS 测得,在图中用虚线表示)

Fig. 8 Control logic in wavefront correction(DM response function is collected by SHWFS, as shown by solid lines. While the AO closed-loop control corrected wavefront is detected by DLWFS, as shown by dashed lines)

自适应光学波前校正过程记录了光强分布  $x_1, x_2$  以及  $G(x)$  在校正前后的变化。在多次实验中调试校正参数,利用 3D 打印的方形 ( $50\text{ mm} \times 50\text{ mm}$ )、圆形 (直径  $50\text{ mm}$ ) 光阑在同一个光路中验证不同光斑的校正效果。

计算焦点光强分布  $x_1$  的光束质量因子  $\beta$ , 将其定义为实测光斑的远场发散角与理想衍射光斑的发散角之比<sup>[34-35]</sup>, 即

$$\beta = \frac{\theta_{\text{actual}}}{\theta_{\text{ideal}}} \quad (7)$$

理想衍射光斑的发散角由同尺寸光斑的衍射仿真结果计算得到。

如图 9 所示,在相似的像差输入条件下,分别以 SHWFS 和 DLWFS 作为波前探测器进行校正后的  $\beta$  值分别为 1.69 和 1.97, 光束质量结果近似,以 DLWFS 作为波前探测器进行校正的结果略逊于以 SHWFS 作为波前探测器进行校正的结果。在 DM1 起扰动作用的 DLWFS 的波前校正实验中,方形光斑的  $\beta$  值由 10.83 校正至 3.61, 圆形光斑的  $\beta$  值由 8.18 校正至 2.40。光斑强度分布和对应的 DLWFS 波前分布如图 10 所示,该结果证明了 DLWFS 可应用于自适应光学波前校正。

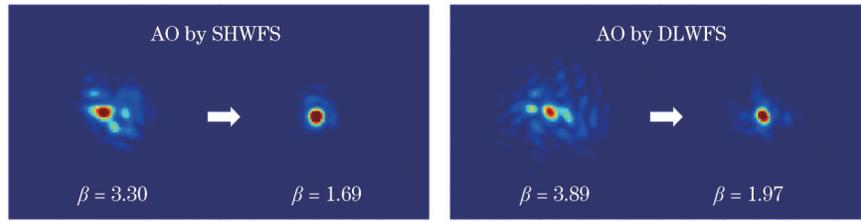


图9 以DLWFS和SHWFS为波前探测器的校正波前结果对比

Fig. 9 Comparison of wavefront correction result using DLWFS and SHWFS as WFS

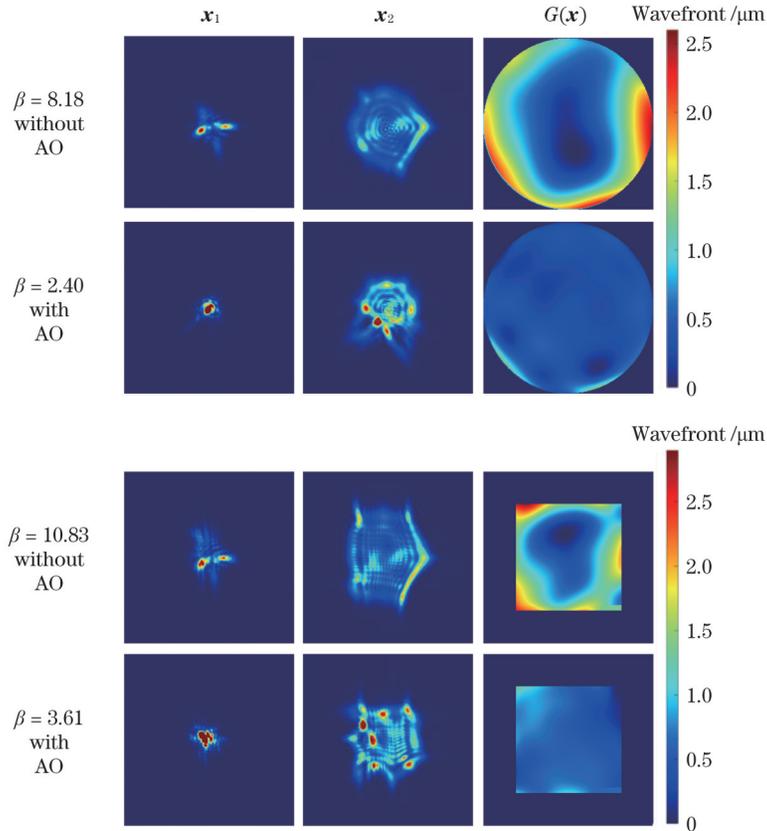


图10 基于DLWFS的自适应光学闭环校正结果。前两行为直径50 mm圆形光斑校正前后的对比,后两行为50 mm×50 mm方形光斑校正前后的对比;强度分布已分别归一化,以更好地展示光斑的形状

Fig. 10 Results of AO closed-loop correction with DLWFS. The first two rows illustrate the comparison before and after correction for circular beams of 50 mm in diameter, and the last two rows are the comparison before and after correction for squared beam of 50 mm×50 mm. The intensity distribution of each spot is normalized for better view of the whole shape

## 4 讨 论

根据以上实验结果,相较于参考SHWFS的波前探测结果,DLWFS所得波前仍有一定偏差。具体原因分析如下:

a) 焦点位置敏感性。训练DLWFS的数据来自精确的焦点位置光强分布,且在仿真数据验证集上的效果尚可。但在实验中,焦点的位置是根据相机上焦点光斑成像最小时确定的,存在一定的位置偏移,这会引入额外的离焦误差。此外,虽然离焦相机依靠螺旋测微器以极小的误差精确移动了20 mm,但其在移动前的焦点位置是由两相机光斑效果在目测一致时确定的,存在一定的相对位置偏差。分析仿真结果时发现,

每产生0.2%的位置偏移量(如在1000 mm聚焦下位置偏移2 mm),就会使复原波前在RMS值上发生约0.1 μm的偏差。

b) 像差SNR敏感性。如前文所述,焦点附近的的光斑强度分布在小像差下接近理想衍射光斑,能量集中在光斑中心,高空间频率的像差和低PV值的像差对光斑强度分布的影响较小,光强分布所包含的波前信息较少,SNR较低,这可能是高频像差和低PV像差在波前复原后出现复原残差偏高的原因。其中,像差中的高频分量产生的弥散斑有可能被淹没在采集相机的噪声中。这些影响因素通过采集适当过曝的光斑,将较弱的强度分布与噪声区分开来,或者采用低噪声、高动态范围的相机采集光斑,有可能得以削弱。另外,

通过采用网络规模更大的学习算法或增大训练数据集的数量,也有可能降低 SNR 的影响。

c) 近场光强及形状的敏感性。在仿真所得的数据中,近场光强分布被认为是均匀等强的,外形也为规则的正方形或正圆形。但在实际应用中,这些条件并不能被满足。如图 6 所示的波前分布,具有不规则外轮廓的光斑在畸变波前作用下的衍射被缩束系统放大,导致 SHWFS 丢失了边缘部分的波前信息。为了探测光强分布中相对更暗的区域的波前,延长了曝光时间,从而导致局部点过曝,丢失了个别子孔径内的波前信息。目前,由光强分布不均和不规则形状带来的误差并不能被 DLWFS 有效地处理,在后续研究中需要增加非理想情况下的波前分析能力。

上述三方面将会在后续研究中进行补充。采用实测的光斑数据,结合改进的模型结构,或许能在将来的工作中提高模型处理实际光斑的能力。

## 5 结 论

基于 DLWFS 的自适应光学校正系统适用于结构紧凑的全固态激光器的波前校正,可以缩小探测器体积,降低探测成本。笔者利用深度学习模型建立光强反演波前的非线性映射,利用可以提取图像深层特征信息的 cGAN 模型,将图像复原过程应用于波前反演问题的求解中。

为了从聚焦过程压缩的光斑中获得更多的信息,同时提取了焦点  $x_1$  和焦前  $x_2$  的光强分布并将其作为 cGAN 的条件值  $x(x_1, x_2)$ 。通过物理衍射传输仿真获得了包含波前和光强分布的训练数据集,训练生成器  $G$  实现光强映射至波前,训练判别器  $D$  识别生成输入  $(G(x), x)$  为伪,识别真实输入  $(x, x)$  为真。测试数据集的最小残差  $RMS < 0.3 \mu\text{m}$ ,表明 DLWFS 具备探测波前的能力。与参考 SHWFS 的波前相比,DLWFS 的波前残差 RMS 在  $0.0965 \sim 0.1531 \mu\text{m}$  之间,复原的波前具有一定的参数敏感性,即焦点位置敏感性、像差 SNR 敏感性以及近场光强一致性和形状敏感性。如果将实验采集的光斑作为训练数据集,使用低噪声或动态范围更大的相机,使用训练网络规模更大的深度学习模型,或许能在后续研究中进一步完善和提高 DLWFS 的实际处理能力。

在自适应光学波前校正系统的实际应用方面,以离线的方式通过 SHWFS 采集变形镜的响应函数,将 DLWFS 采集的波前数据转化成变形镜的控制电压,成功地将方形光斑的  $\beta$  值由 10.83 校正至 3.61,将圆形光斑的  $\beta$  值由 8.18 校正至 2.40,验证了 DLWFS 在自适应光学校正系统内作为波前探测器的可行性。

## 参 考 文 献

- [1] Tyson R. Principles of adaptive optics[M]. 3rd ed. Boca Raton: CRC Press, 2011: 4.
- [2] Booth M J, Neil M A A, Juskaitis R, et al. Adaptive aberration correction in a confocal microscope[J]. Proceedings of the National Academy of Sciences of the United States of America, 2002, 99(9): 5788-5792.
- [3] Wei K, Li M, Jiang C C, et al. LGS adaptive optics system with long-pulsed sodium laser on Lijiang 1.8 meter telescope 2014–2016 observation campaign[J]. Proceedings of SPIE, 2016, 9909: 99095G.
- [4] Gerchberg R W, Saxton W O. A practical algorithm for the determination of phase from image and diffraction plane pictures[J]. Optik, 1972, 35: 237-246.
- [5] Yang G Z, Dong B Z, Gu B Y, et al. Gerchberg-Saxton and Yang-Gu algorithms for phase retrieval in a nonunitary transform system: a comparison[J]. Applied Optics, 1994, 33(2): 209-218.
- [6] Roddier F, Roddier C. Wavefront reconstruction using iterative Fourier transforms[J]. Applied Optics, 1991, 30(11): 1325-1327.
- [7] Sandler D G, Barrett T K, Fugate R Q. Recovery of atmospheric phase distortion from stellar images using an artificial neural network[J]. Proceedings of SPIE, 1992, 1543: 491-499.
- [8] Isola P, Zhu J Y, Zhou T H, et al. Image-to-image translation with conditional adversarial networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 5967-5976.
- [9] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [10] LeCun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [11] Nishizaki Y, Valdivia M, Horisaki R, et al. Deep learning wavefront sensing[J]. Optics Express, 2019, 27(1): 240-251.
- [12] Wang K Q, Zhang M M, Tang J, et al. Deep learning wavefront sensing and aberration correction in atmospheric turbulence[J]. Photonix, 2021, 2(1): 1-11.
- [13] Xin Q, Ju G H, Zhang C Y, et al. Object-independent image-based wavefront sensing approach using phase diversity images and deep learning[J]. Optics Express, 2019, 27(18): 26102-26119.
- [14] Norris B R M, Wei J, Betters C H, et al. An all-photonic focal-plane wavefront sensor[J]. Nature Communications, 2020, 11: 5335.
- [15] Védrenne N, Mugnier L M, Michau V, et al. Laser beam complex amplitude measurement by phase diversity[J]. Optics Express, 2014, 22(4): 4575-4589.
- [16] He Y L, Liu Z W, Ning Y, et al. Deep learning wavefront sensing method for Shack-Hartmann sensors with sparse sub-apertures[J]. Optics Express, 2021, 29(11): 17669-17682.
- [17] García Riesgo F, Suárez Gómez S L, Santos J D, et al. Overview and choice of artificial intelligence approaches for night-time adaptive optics reconstruction[J]. Mathematics, 2021, 9(11): 1220.
- [18] Hu S W, Hu L J, Zhang B W, et al. Simplifying the detection of optical distortions by machine learning[J]. Journal of Innovative Optical Health Sciences, 2020, 13(3): 2040001.
- [19] Vera E, Guzmán F, Weinberger C. Boosting the deep learning wavefront sensor for real-time applications[J]. Applied Optics, 2021, 60(10): B119-B124.
- [20] Zhang B W, Zhu J Z, Si K, et al. Deep learning assisted zonal adaptive aberration correction[J]. Frontiers in Physics, 2021, 8: 621966.
- [21] Wang M H, Guo W, Yuan X H. Single-shot wavefront sensing with deep neural networks for free-space optical communications [J]. Optics Express, 2021, 29(3): 3465-3478.
- [22] Cumming B P, Gu M. Direct determination of aberration functions in microscopy by an artificial neural network[J]. Optics Express, 2020, 28(10): 14511-14521.
- [23] Paxman R G, Fienup J R. Optical misalignment sensing and image reconstruction using phase diversity[J]. Journal of the Optical Society of America A, 1988, 5(6): 914-923.
- [24] Almoró P, Pedrini G, Osten W. Complete wavefront

- reconstruction using sequential intensity measurements of a volume speckle field[J]. *Applied Optics*, 2006, 45(34): 8596-8605.
- [25] Nakajima N. Reconstruction of phase objects from experimental far field intensities by exponential filtering[J]. *Applied Optics*, 1990, 29(23): 3369-3374.
- [26] Luo Q, Huang L H, Gu N T, et al. Experimental study of a modified phase diversity with a diffraction grating[J]. *Optics Express*, 2012, 20(11): 12059-12066.
- [27] Mandl A, Klimek D E. Textron's J-HPSSL 100 kW ThinZag (R) Laser Program[C]//Conference on Lasers and Electro-Optics (CLEO)/Quantum Electronics and Laser Science Conference (QELS), May 16-21, 2010, San Jose, California, United States. Washington, DC: OSA, 2010: JThH2.
- [28] Goodno G D, Komine H, McNaught S J, et al. Coherent combination of high-power, zigzag slab lasers[J]. *Optics Letters*, 2006, 31(9): 1247-1249.
- [29] Perry M D, Banks P S, Zweiback J, et al. Laser containing a distributed gain medium: US7103078[P]. 2006-09-05.
- [30] Kane T J, Eggleston J M, Byer R L. The slab geometry laser-part II: thermal effects in a finite slab[J]. *IEEE Journal of Quantum Electronics*, 1985, 21(8): 1195-1210.
- [31] Goodman J W. *Introduction to Fourier optics*[M]. San Francisco: McGraw-Hill, 1968.
- [32] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[EB/OL]. (2014-06-10)[2023-04-05]. <https://arxiv.org/abs/1406.2661>.
- [33] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[M]//Navab N, Hornegger J, Wells W M, et al. *Medical image computing and computer-assisted intervention-MICCAI 2015. Lecture notes in computer science*. Cham: Springer, 2015, 9351: 234-241.
- [34] Siegman A E. Defining, measuring, and optimizing laser beam quality[J]. *Proceedings of SPIE*, 1993, 1868: 2-12.
- [35] Mahajan V N. Strehl ratio for primary aberrations: some analytical results for circular and annular pupils[J]. *Journal of the Optical Society of America*, 1982, 72(9): 1258-1266.

## Double Spots Based Deep Learning Wavefront Reconstruction and Correction

Xu Yuanzhai<sup>1,2</sup>, Tang Qiuyan<sup>3</sup>, Wang Xiaojun<sup>1</sup>, Guo Yading<sup>1</sup>, Zhang Lin<sup>1\*</sup>, Wei Hua<sup>3</sup>, Peng Qinjun<sup>1</sup>, Lü Pin<sup>4</sup>

<sup>1</sup>*Technical Institute of Physics and Chemistry, Chinese Academy of Sciences, Beijing 100190, China;*

<sup>2</sup>*University of Chinese Academy of Sciences, Beijing 100049, China;*

<sup>3</sup>*Institute of Software, Chinese Academy of Sciences, Beijing 100191, China;*

<sup>4</sup>*Institute of Automation, Chinese Academy of Sciences, Beijing 100190, China*

### Abstract

**Objective** The thermal effects and mechanical deformation of high-power lasers impede the output performance of laser systems. Compact laser systems, such as solid lasers, increasingly rely on adaptive optics (AO) featuring simpler structured wavefront sensors to improve beam quality. Unlike the traditional methods that retrieve wavefront from intensity distribution, deep learning, which is well-suited for nonlinear mapping, holds significant potential in this regard. In this article, we present a deep learning wavefront sensor (DLWFS) and demonstrate its applications in AO wavefront corrections. We use conditional generative adversarial networks (cGAN) to extract high-level features from the entire input intensity and retrieve wavefront from the intensity distribution. In other words, we view this intensity-to-wavefront nonlinear mapping as an image-translating problem. To overcome the compression of the wavefront information due to the diversity of coordinates during focusing propagation with a converged beam, the DLWFS relies on acquiring intensity from both the focal spot and the spot just before the focus, also called “double spots”, as input intensity distribution. By comparing the wavefront reconstruction results of DLWFS with those of commercial Shack-Hartmann wavefront sensor (SHWFS), and applying DLWFS in AO closed-loop of wavefront correction, the practicability of DLWFS can be proved.

**Methods** We simulated the propagation of random initial wavefront through physical diffraction to obtain the intensity of spots on focus and defocus (0.98 times focal length) as training data and testing data of DLWFS. Network model cGAN was constructed by a generator ( $G$ ) and discriminator ( $D$ ).  $G$  had a U-Net structure comprising encoder-decoder convolutional neural networks (CNNs). It was trained to generate wavefront  $G(\boldsymbol{x})$  from input intensity distribution  $x(x_1, x_2)$ , considering both on focus ( $x_1$ ) and defocus ( $x_2$ ) intensity data. The discriminator with a U-Net structure of encoder-decoder was trained to distinguish between tuple ( $G(\boldsymbol{x}), \boldsymbol{x}$ ) of generated results  $G(\boldsymbol{x})$  with condition  $x$  as fake, and tuple ( $\boldsymbol{y}, \boldsymbol{x}$ ) of real wavefront  $\boldsymbol{y}$  with condition  $x$  as real. The training of the generator was considered completed when  $G$  was able to successfully fool  $D$ . The concept is shown in Fig. 2 and is expressed mathematically in Eqs. (2)–(5). We built an experimental platform of deformable mirrors (DM) for disturbing and correcting, and referencing SHWFS for comparison, as shown in Fig. 7. DLWFS exhibits superior resolution compared to SHWFS, and SHWFS, in turn, offers higher resolution than DM for the purpose of wavefront correction. The laser beam was split 50/50 into SHWFS and DLWFS separately, to compare the wavefront results. Furthermore, by computing the wavefront response function of the DM, the

closed-loop of AO used the wavefront generated from DLWFS for wavefront correction. Therefore, these experiments can serve to demonstrate the practicability of DLWFS as a wavefront sensor in AO systems.

**Results and Discussions** DLWFS is capable of retrieving wavefront data with a root mean square (RMS) residual error of less than  $0.3\ \mu\text{m}$  at best, as shown in Fig. 4. When comparing the wavefront results of DLWFS with those from SHWFS experiments, as shown in Fig. 6, it becomes clear that the DLWFS generated wavefront results are smoother than referencing SHWFS, but both results have similar magnitude and shape of distribution. The RMS residual error is approximately  $0.0965\text{--}0.1531\ \mu\text{m}$  in this comparison. The most noticeable disparities are observed near edges, with a significant reduction in disparity toward central areas. We conduct multiple AO wavefront correction experiments through controlling parameters and utilizing different 3D-printed apertures inducing circle and square shapes of beams. The correction results obtained by utilizing DLWFS as the wavefront sensor closely resemble the results obtained from SHWFS, as shown in Fig. 9. The results of utilizing DLWFS in the correction of wavefront distortion induced by DM1 are shown in Fig. 10. The first two rows depict the results with and without AO correction of the 50 mm diameter circular beam, while the last two rows depict the results of the 50 mm $\times$ 50 mm square beam. We improve the circle beam quality from  $\beta=8.18$  without AO to  $\beta=2.40$  with AO, while we improve the square beam quality from  $\beta=10.83$  without AO to  $\beta=3.61$  with AO. These results demonstrate the practicability of using DLWFS in AO. Based on the experimental results mentioned earlier, we find that in retrieving wavefronts, the DLWFS shows a certain degree of deviation when compared to SHWFS. The primary causes of this deviation can be attributed to the sensitivity of DLWFS in these aspects: the parametric sensitivity of focal point position when acquiring spots, SNR of the wavefront with high frequency or small stroke aberrations, nonuniform distributed near-field intensity, and irregularly shaped beams. Hence, the performance of DLWFS can be improved by using the real data acquired by experiments conducted using an improved model.

**Conclusions** Compact wavefront sensor is highly suitable for improving the beam quality of compact solid lasers in AO systems. In this article, we introduce DLWFS as a new method of nonlinear mapping from intensity distribution of focus and defocus spots into wavefront. The model is trained using simulated data. By using cGAN-based generator to retrieve wavefront from input focus and defocus spots, we compare wavefront results of DLWFS with those of SHWFS. The residual error falls in the range of  $0.0965\text{--}0.1531\ \mu\text{m}$ . We also apply DLWFS for AO wavefront correction and correct square and circle beams with beam quality  $\beta=3.61$  and  $\beta=2.40$  separately. Although there is a noticeable deviation in wavefront results compared with the reference wavefront, the wavefront correction results demonstrate the practicability of DLWFS. We believe that future improvements in the model structure and the utilization of experimentally acquired training data will enhance the performance of DLWFS in future studies.

**Key words** adaptive optics; wavefront reconstruction; deep learning; beam quality