

# 中国激光

## 基于机器学习的激光自适应光学技术研究进展

程涛<sup>1</sup>, 郭思成<sup>1,2</sup>, 王宁<sup>1,2</sup>, 赵孟孟<sup>1,2</sup>, 王帅<sup>1\*\*</sup>, 杨平<sup>1\*</sup>

<sup>1</sup>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;

<sup>2</sup>中国科学院大学, 北京 100049

**摘要** 高功率激光是自适应光学的重要应用领域,通过控制高功率激光系统实现高光束质量的激光输出是激光自适应光学技术的一项重要目标。自适应光学主要是利用波前传感器和波前校正器来完成对激光畸变波前的探测与校正。近年来,人工智能的发展为自适应光学技术特别是应用于激光领域的自适应光学技术在波前复原、波前预测以及波前校正方面提供了新的思路 and 工具。梳理了当前自适应光学的智能化发展概况,介绍了机器学习方法在波前复原、波前预测、相位反演和波前控制四个方面取得的研究进展,并对当前研究方法在高功率激光领域中的应用潜力与面临的挑战进行了讨论。

**关键词** 激光光学; 自适应光学; 高功率激光; 机器学习

中图分类号 O436 文献标志码 A

DOI: 10.3788/CJL230522

### 1 引言

自适应光学是一种动态波前像差的主动补偿技术。其最初的设想是由美国天文学家 Babcock<sup>[1]</sup>于 1953 年提出,通过对大气湍流进行实时探测与补偿来克服大气湍流像差对天文观测成像质量的影响。但受限于当时的探测器件、校正器件以及实时计算机,自适应光学技术在提出后的二十年内并未实现。美国于 20 世纪 60 年代后期开始资助自适应光学研究,主要有两个方向:激光传输和对卫星成像。1972 年,美国成功研制了第一套实时大气补偿实验成像系统<sup>[2]</sup>。1982 年,美国在夏威夷附近的毛伊岛安装了世界上首台用于空间目标监测的 1.6 m 自适应望远镜,该系统在 0.6  $\mu\text{m}$  工作波长的情况下实现了衍射极限的成像质量<sup>[3]</sup>。自此,自适应光学由理论走向实践,经过数十年的发展,已在空间目标高分辨率监测<sup>[4-6]</sup>、激光大气传输<sup>[7-8]</sup>、光束整形<sup>[9-10]</sup>、激光光束净化<sup>[11-12]</sup>、人眼眼底细胞高分辨成像<sup>[13-14]</sup>等多个领域中得到了有效应用。

高功率激光是自适应光学的重要应用领域<sup>[15-17]</sup>,高功率激光作用于靶目标的效能与光束质量的平方成反比<sup>[18]</sup>,利用自适应光学技术提升激光光束质量对推动高功率激光应用具有重要意义。在高功率激光传输至靶目标的过程中,利用自适应光学首先对高功率激光器因功率提升而出现的腔内热效应像差进行校正以获得高功率高光束质量的激光光源,其次对高功率激

光传输至发射装置出口前的传输通道中的热效应像差和光学器件像差进行校正,最后对发射装置出口与靶目标之间由于大气湍流、热晕等因素而出现的畸变像差进行校正。因此,自适应光学是保障高功率激光在靶目标处的光束质量的核心技术。

当前,自适应光学已将多型高功率激光光源的光束质量提升至近衍射极限。以美国为例,DF 化学激光器 MIRACL 在 1 MW 功率输出时光束质量达到了 2 倍衍射极限<sup>[19-20]</sup>。7 链路激光相干合成、功率达到 105 kW 的固态激光实现了平均光束质量约为 2.9 的激光输出<sup>[21]</sup>。但在推动不同体制高功率激光器在不同工作场景下的实际应用时,自适应光学仍面临以下技术需求: 1) 在高功率激光光源方面,不同体制高功率激光器在提升功率时,如板条固体激光器,其近场光强呈动态非均匀特性,局部产生大梯度像差,需自适应光学在自身校正能力约束下实现对像差的最优校正; 2) 在高功率激光传输方面,强湍流下畸变波前具备高时空频率特性,波前探测器信号存在动态缺失,自适应光学应具备波前信息动态缺失条件下的高精度波前重构能力以及高带宽的像差校正能力; 3) 在暗弱目标方面,暗弱目标的信标回光弱、噪声背景强将造成波前探测器信噪比低、空域分辨率低,自适应光学应具备低信噪比、低空域分辨率下高空域频率像差的高精度复原能力; 4) 在环境适应性方面,自适应光学系统所处平台在受环境振动、温度变化等扰动时,系统参数应具备自适应调节能力。

收稿日期: 2023-02-14; 修回日期: 2023-03-30; 录用日期: 2023-04-18; 网络首发日期: 2023-04-28

基金项目: 国家自然科学基金(62005285, 62105336)、国防科技卓越青年人才基金、中国科学院“西部青年学者”A 类项目

通信作者: \*pingyang2516@163.com; \*\*wangshuai@ioe.ac.cn

近年来,人工智能领域发展迅速,以深度学习、强化学习为代表的机器学习方法在粒子物理<sup>[22]</sup>、高分子材料<sup>[23]</sup>以及生物医学<sup>[24]</sup>等多个基础科研领域中取得了重大突破,为研究人员探索、认知和解决基础科学问题提供了新的思路 and 工具。在自适应光学方面,科研人员开展了基于机器学习的自适应光学技术研究,取得了一系列有代表性的研究成果,有望解决当前自适应光学在高功率激光领域中面临的多项难题。本文从波前重构、波前预测、相位反演和波前校正等四个方面对当前研究进展进行了介绍,并对当前研究方法在高功率激光领域中的应用潜力与面临的挑战进行了讨论。

## 2 基于机器学习的哈特曼波前重构技术

哈特曼传感器结构紧凑、波前复原速度快,是当前自适应光学系统中的常用波前传感器。为了实现从光源到目标全程高功率、高光束质量的激光传输,需利用哈特曼传感器对高功率激光光源像差、激光传输通道像差和激光在大气中传输时的湍流像差进行准确的测量与重构。然而,当激光器功率提升时,如板条固体激光器,其腔内热效应和增益介质的非均匀性将造成激光近场光强呈动态非均匀分布,激光在大气中传输时的强湍流效应将造成激光近场的强度起伏,此时哈特曼传感器探测到的光斑阵列图像存在动态缺光现象,须在缺失部分波前信息的条件下完成高

精度波前重构。此外,在面对暗弱目标时,弱信标和强噪声背景将限制哈特曼传感器的子孔径密度,需在低信噪比低空间分辨率下实现对高空间频率像差的波前复原。为实现低信噪比、低空间频率和部分子孔径动态缺光条件下的高空间频率像差的波前复原,研究人员开展了基于机器学习的哈特曼波前重构技术研究,对传统模式复原算法<sup>[25]</sup>中的质心提取、基于子孔径质心偏移的畸变波前模式系数的计算等进行了改进。

为提升质心计算精度,1996年 Montera 等<sup>[26]</sup>首次将神经网络用于哈特曼光斑质心定位,利用单隐藏层全连接网络实现了从子孔径图像到质心坐标的预测,在大动态范围的情况下,神经网络的质心定位精度明显高于传统质心定位方法。2018年, Li 等<sup>[27]</sup>借鉴图像分类思想,构建了图 1 所示的质心探测神经网络 SHNN,利用神经网络对哈特曼子孔径进行像素级的分类,以解决低信噪比下的光斑质心定位问题。该网络的输入和输出层数目是单个子孔径的像素数之和,每个神经元节点均对应一个像素的光强信息,在输出层对每一个像素进行分类判断,寻找计算质心的有效像素。隐藏层节点数目表征了不同的网络拟合能力,表 1 所示的不同信噪比(SNR)下的质心计算精度结果表明,SHNN-900 网络较 SHNN-50 在信噪比为 1~5 的条件下具备更高的质心计算精度,但对于全连接结构的神经网络,随着节点数据的增加,其训练和推理的成本时间将大大增加。

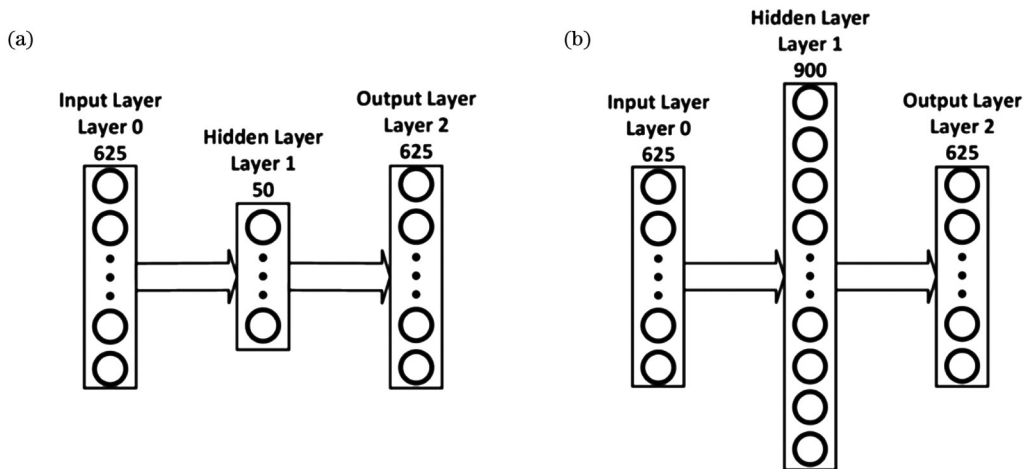


图 1 质心探测神经网络 SHNN<sup>[27]</sup>。(a) 隐含层 50 节点; (b) 隐含层 900 节点

Fig. 1 Centroid detection neural network SHNN<sup>[27]</sup>. (a) Hidden layer with 50 nodes; (b) hidden layer with 900 nodes

在基于质心偏移的畸变波前计算方面,2006年 Guo 等<sup>[28]</sup>利用反向传播(BP)神经网络,基于光斑质心偏移预测了畸变波前 Zernike 系数,通过训练、测试不同结构的网络模型,得出隐藏层中包含 90 个神经元的网络结构为最佳网络模型的结论,在  $8 \times 8$  子孔径数目下实现了对低阶 Zernike 系数(倾斜、离焦和像散)的精准预测。相比于最小二乘法和奇异分解法,神经网络

方法具有更高的波前复原精度。2020年, Xu 等<sup>[29]</sup>利用极限学习机(ELM)网络在  $6 \times 6$  的子孔径数目下实现了 65 阶 Zernike 模式像差的复原,初步探索了低子孔径密度下的高空间频率像差波前复原,在  $D/r_0=8$  ( $D$  为望远镜口径,  $r_0$  为大气相干长度)的像差样本条件下,复原误差相比于标准模式算法<sup>[25]</sup>降低了 80.72%。2018年, Swanson 等<sup>[30]</sup>利用 U-Net 网络直接从  $x, y$  斜

表 1 不同信噪比下的复原精度对比<sup>[27]</sup>

Table 1 Comparison of restoration accuracies under different SNRs<sup>[27]</sup>

SNR	False rate/%				
	CoG	Windowing	TmCoG	SHNN-50	SHNN-900
1	98	83	94	73	55
2	97	43	61	28	7
3	97	28	26	6	0
4	98	8	6	1	0
5	97	2	1	1	0

率输出了待测波前的相位,避免了模式系数计算过程造成的复原误差,相比于BP神经网络,U-Net网络输入层的波前斜率隐含了波前的位置信息,更有利于提升波前复原精度。2020年,Dubose等<sup>[31]</sup>提出了强度/斜率网络(ISNet),如图2所示,ISNet用DenseNet代替U-Net网络的标准卷积层,构建了更为复杂的深度卷积网络结构,同时将子孔径斜率信息和子孔径的总强度信息输入网络,以解决大气湍流闪烁、非均匀后向散射等因素引起的波前复原误差问题。

事实上,当哈特曼子孔径光斑弥散或信噪比降低

时,质心计算精度下降,进而波前复原精度降低。为避免质心计算误差对波前复原精度的影响,研究人员将哈特曼光斑阵列图像作为深度神经网络的输入。2019年Hu等<sup>[32]</sup>构建了哈特曼传感器的深度学习网络LSHWS,如图3(a)所示,LSHWS是AlexNet网络的变形,其输入是光斑阵列图像,输出为Zernike模式系数,在子孔径数目为 $16 \times 16$ 的哈特曼传感器中实现了对120阶模式系数的预测。在相同的实验环境下,相比于传统的Zernike模式复原算法<sup>[25]</sup>,LSHWS复原120阶Zernike系数的速度提升了约38.1%,单帧图像推理时间为10.9 ms,复原残差降低了约40.54%。2020年,Hu等<sup>[33]</sup>将U-Net网络与残差学习模块相结合,构建了图3(b)所示的深度学习网络SH-Net,基于 $256 \times 256$ 分辨率的SHWFS图像预测了 $256 \times 256$ 分辨率波前相位,在对120阶Zernike系数成像差进行复原对比时,SH-Net复原的均方根误差(RMSE)为 $0.0168\lambda$ ( $\lambda$ 为波长),比LSHWS方法<sup>[32]</sup>( $0.0893\lambda$ )低了约81.19%,比Swanson方法<sup>[30]</sup>( $0.1366\lambda$ )低了约87.70%。在推理时间方面,SH-Net的平均推理时间为40.2 ms,比LSHWS方法(0.1225 s)缩短了约67.18%,但比Swanson网络(22.6 ms)长了约77.88%。

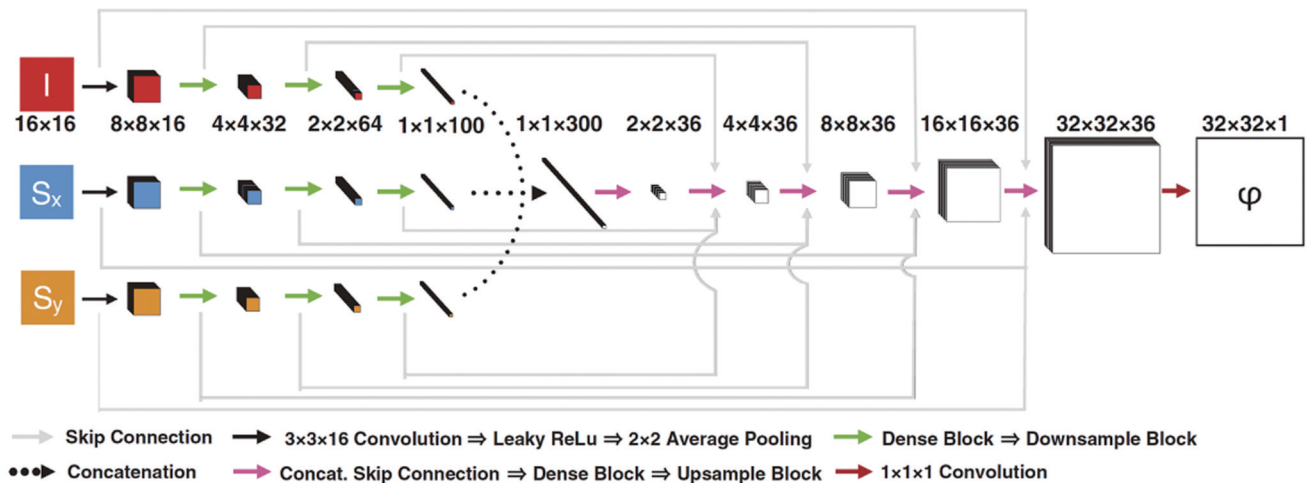


图 2 ISNet 波前重构示意图<sup>[31]</sup>

Fig. 2 Wavefront reconstruction diagram of ISNet<sup>[31]</sup>

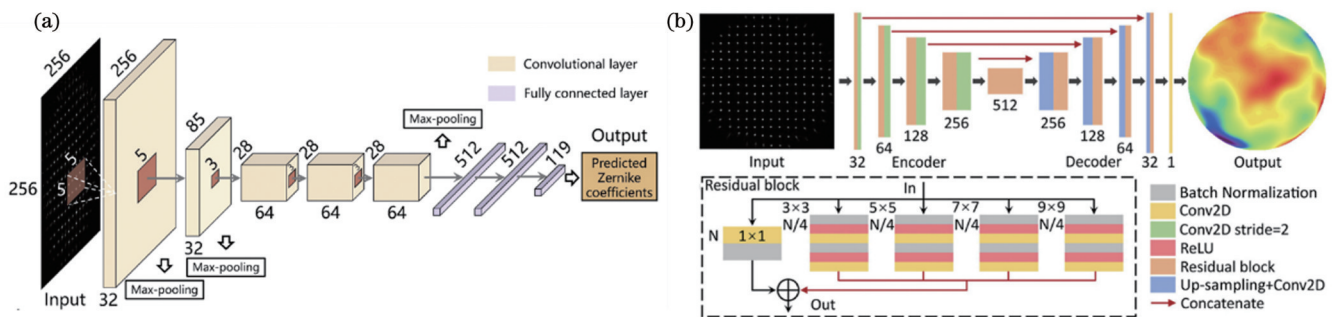


图 3 不同网络的波前重构示意图。(a)LSHWS<sup>[32]</sup>; (b)SH-Net<sup>[33]</sup>

Fig. 3 Wavefront reconstruction diagrams of different networks. (a) LSHWS<sup>[32]</sup>; (b) SH-Net<sup>[33]</sup>

2021 年, He 等<sup>[34]</sup>用 ResNet 网络构建了哈特曼传感器的深度学习网络 SH-ResNet, 如图 4(a) 所示, 该网络输入是仅含 7 个子孔径的光斑阵列图像, 输出是 88 阶 Zernike 系数。数值仿真表明, 在  $D/r_0=11$  的湍流强度下, 子孔径光斑弥散, 不满足哈特曼波前传感器探测像差时  $d/r_0 \approx 1$  ( $d$  是子孔径的直径) 的限制条件, SH-ResNet 的波前复原残差低至  $0.08\lambda$ , 如图 4(b) 所示。2021 年, Gu 等<sup>[35]</sup>在子孔径数目为  $15 \times 15$  的哈特曼传感器中对 ResNet50+ 网络的波前复原能力进行了分析, 网络输入为哈特曼传感器探测的光斑阵列图像, 将 Zernike 的复原阶次提升至 152, 且波前重构误差为

$0.0128 \mu\text{m}$ , 仅为原始波前均方根的 0.79%。2022 年, Guo 等<sup>[36]</sup>将哈特曼光斑阵列图像作为输入, 提出了基于卷积神经网络的超分辨波前复原方法 SH-CNN, 在子孔径数目为 100 的哈特曼波前传感器中将 Zernike 复原阶次提升至 299, 实现了哈特曼传感器的超分辨波前探测。在对 1~299 阶 Zernike 模式像差进行单阶像差复原对比时, SH-CNN 的波前复原残差整体优于 Unet; 此外, 在不同硬件平台下经 TensorRT (fp16) 加速后, 复原 299 阶 Zernike 系数的时间小于 1 ms, 1080Ti 显卡的推理时间为 0.6 ms, 3090 显卡的推理时间为 0.2 ms。

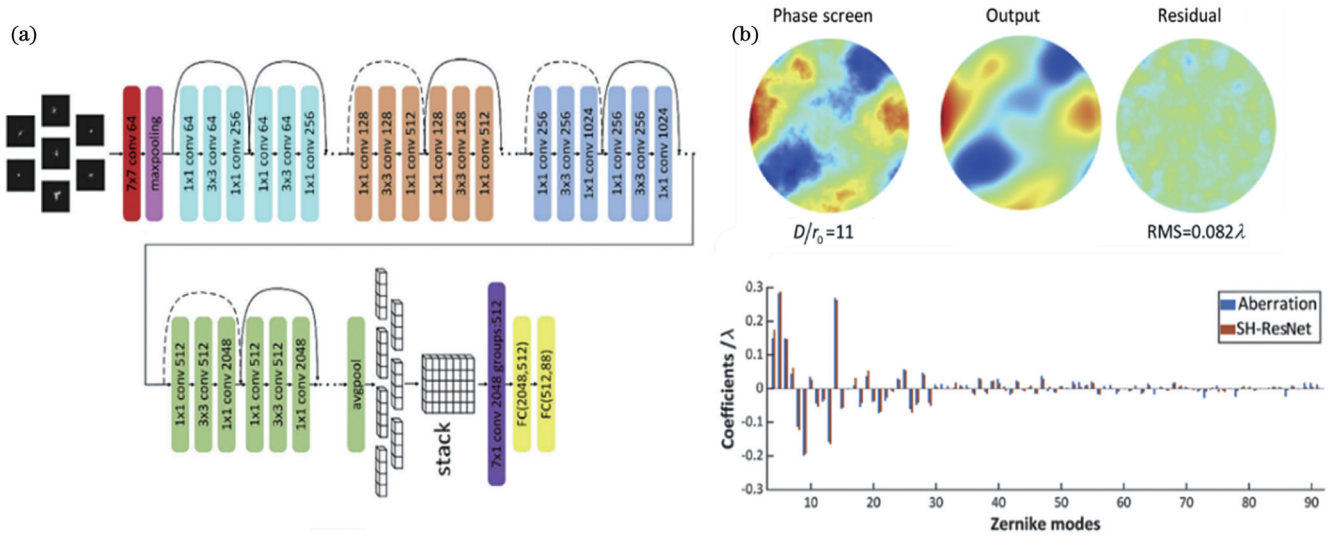


图 4 SH-ResNet 结构示意图及其波前复原验证<sup>[34]</sup>。(a) SH-ResNet 结构; (b)  $D/r_0=11$  时的波前复原验证

Fig. 4 Structural diagram of SH-ResNet and its wavefront restoration verification<sup>[34]</sup>. (a) Structural diagram of SH-ResNet; (b) verification of wavefront restoration when  $D/r_0=11$

在上述研究中, 哈特曼的探测信息均为全口径, 即不存在局部子孔径缺光现象。然而, 在高功率激光输出和激光大气传输过程中, 近场光强的非均匀分布和强湍流都会造成哈特曼传感器的光斑阵列图像出现局部子孔径缺光现象。针对这一问题, 2022 年本课题组基于 U-Net 网络构建了一种基于部分波前斜率计算全口径波前斜率的深度神经网络 SH-U-Net<sup>[37]</sup>, 如图 5(a) 所示, 不同于 Swanson 和 Dubose 等的研究, 该网络的输入是部分子孔径的波前斜率, 输出是全口径的波前斜率信息。实验结果表明, 在子孔径存在 50% 随机缺光的条件下, 传统 Zernike 模式的复原方法已然失效, 该方法仍具备较高的波前复原精度, 1000 组样本的平均波前复原误差低至  $0.05\lambda$ 。该方法实现了部分波前斜率信息下的波前复原, 有望克服激光近场光强非均匀分布和强湍流传输时哈特曼传感器动态缺光对波前复原精度的影响。

上述研究表明, 基于神经网络的哈特曼波前重构方法具有如下特点: 1) 在噪声抑制方面, 基于神经网络的方法可在低信噪比条件下将子孔径有效光斑和噪声

分离, 相比于传统的阈值处理方法, 具有更高的质心计算精度; 2) 在波前复原方面, 基于神经网络的波前重构方法不仅可避免质心计算误差和模式复原方法的模式混淆误差、截断误差, 还可在低空间分辨下实现高空间频率像差的复原, 或在部分子孔径动态缺光的条件下实现全口径的波前信息推定。因此, 基于深度学习的哈特曼波前重构方法有望解决高功率激光动态非均匀近场、强湍流、信标回光弱和强背景噪声等因素对哈特曼传感器波前探测的动态范围、空间分辨和重构精度的影响问题。

然而, 上述方法均属于监督学习, 训练样本对于算法的性能至关重要, 在高功率激光领域中的实际应用仍存在以下不足: 1) 训练样本泛化性。高功率激光出光时长有限, 不同应用场景下的噪声水平、类型存在差异, 采集样本难以表征不同场景下的波前特性。2) 训练样本准确性。如在强背景噪声条件下, 无法得到真实的无噪声图像, 面对高功率激光出光时的动态缺光现象, 准确的波前像差也难以获取。

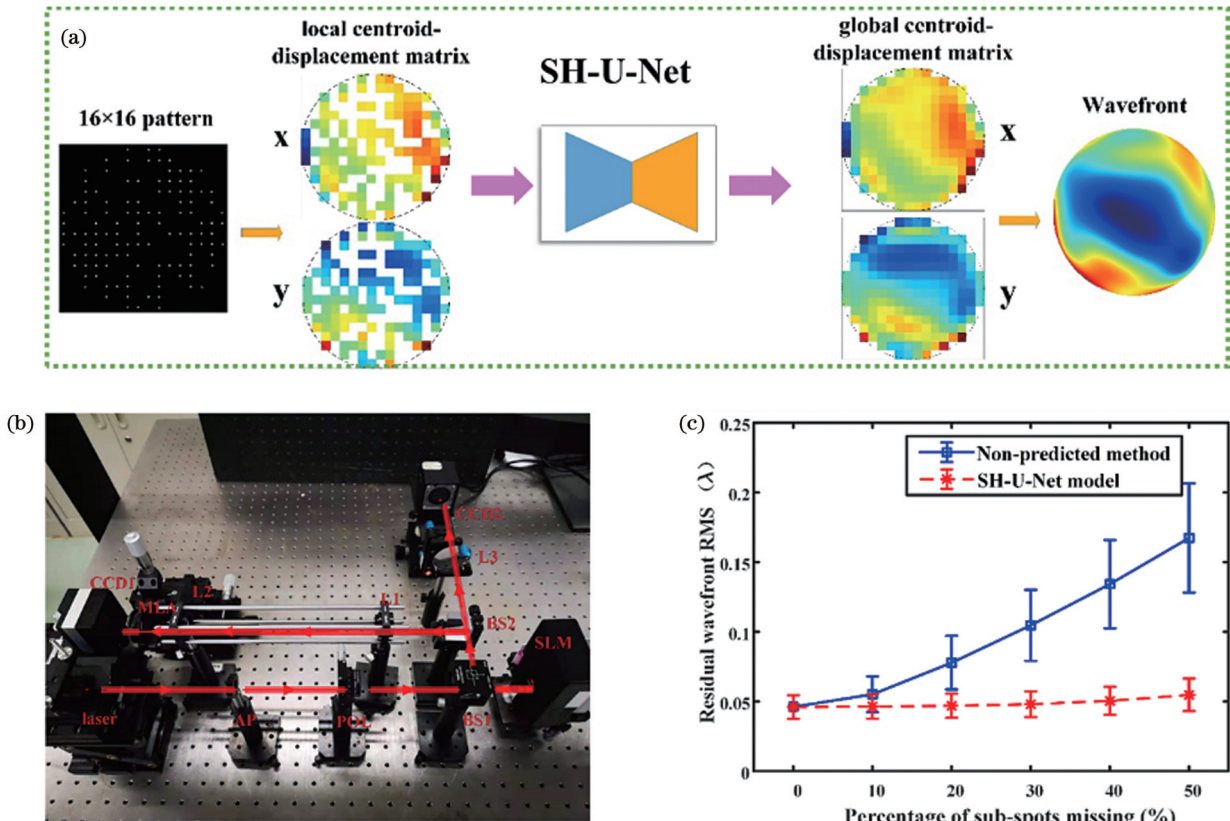


图 5 SH-U-Net 波前复原示意图及实验验证<sup>[37]</sup>。(a)SH-U-Net 波前复原示意图；(b)实验系统；(c)不同缺光比下 1000 组样本的波前复原

Fig. 5 Wavefront restoration diagram of SH-U-Net and experimental verification<sup>[37]</sup>. (a) Wavefront restoration diagram of SH-U-Net<sup>[37]</sup>; (b) experimental system; (c) wavefront reconstruction of 1000 samples under different scenarios of sub-spot missing

### 3 基于机器学习的波前预测技术

对激光传输过程中环境振动造成的光束高频指向抖动、强湍流造成的高时间频率像差进行快速、稳定的校正对于高功率激光至关重要,需自适应光学系统具有较高的控制带宽。文献[38]的研究结果表明,自适应光学系统是一类时间延时的伺服系统,存在 2~3 个采样周期的时间延时( $\tau$ ),控制系统带宽约为  $\frac{1}{10\tau}$ 。可以看出,系统延时时间  $\tau$  是限制控制带宽的主要因素,提升探测器的采样频率可提高自适应光学系统的控制带宽,但探测器的采样频率存在上限,因此需通过合理的算法实现畸变波前 2~3 个采样周期后的精确预测,以消除时间延时对自适应光学系统控制带宽的限制。

当前,自适应光学的波前预测技术主要分为基于模型的线性预测方法<sup>[39-40]</sup>、采用递归最小二乘(RLS)等方法的迭代预测算法<sup>[41-42]</sup>、基于神经网络的预测方法<sup>[43-45]</sup>。基于模型的线性预测方法需对湍流像差或环境扰动进行准确的辨识,利用精确的辨识模型可对多个采样周期后的湍流像差或环境扰动进行估计,进而实现高精度的预测补偿。但该方法的模型辨识过程是离线的,不适用于模型特征具有动态变化特性的湍流像差或环境扰动。迭代预测方法是对动态变化的湍流

像差或环境扰动进行在线迭代求解,理论上可实现对系统误差的最小化控制,但当像差的模式阶次较高时算法不易收敛。基于神经网络的预测方法是利用网络的非线性拟合能力建立历史数据和预测数据之间的端到端映射,最早由 Jorgenson 等<sup>[43]</sup>于 1992 年引入到自适应光学系统中,利用神经网络在开环条件下进行了畸变波前预测,结果表明引入预测可使波前校正误差降低 86%。2010 年, Yan 等<sup>[44]</sup>利用二层反向传播神经网络预测算法对变形镜的开环控制电压进行预测,在相同风速条件下,校正效果比 RLS 控制算法提高了 30 倍左右。2012 年,史晓雨等<sup>[45]</sup>提出了基于 Levenberg-Marquardt 学习算法的反向传播(LMBP)神经网络,对变形镜复原电压进行了非线性预测,相比于 RLS 控制算法具有更大的预测长度。基于神经网络的预测方法相比于 RLS 类的迭代控制算法在预测步长和预测精度上都具有更好的性能,但训练数据需求量大,且网络泛化能力低,在大气湍流条件发生变化时,神经网络的预测精度会降低。

近年来,循环神经网络(RNN)和长短期记忆(LSTM)网络展现出学习时间序列非线性特征的优势。2020 年, Chen 等<sup>[46]</sup>利用 LSTM 网络对开环控制电压进行了预测,其预测残差比 BP 网络降低了 87% 左右。2020 年, Liu 等<sup>[47]</sup>着重考虑了大气湍流的非平

稳特性,利用两个 LSTM 单元和一个全连接层搭建了图 6(a)所示的预测模型。在不同风速和风向下进行开环性能测试,结果如图 6(c)、(d)所示,在风速和风向参数每 10 frame 进行一次更新时,该预测模型的预测精度无显著抖动,可实现不同大气条件下的湍流

预测。同时,利用 1 frame 延迟条件下构造的训练模型进行了不同延迟周期的性能测试,如图 6(b)所示,可以看出,1 frame 延迟条件下构造的训练模型在 2 frame 延迟条件下的预测精度有所下降,但其校正效果相比于无延时补偿条件仍有显著提升。

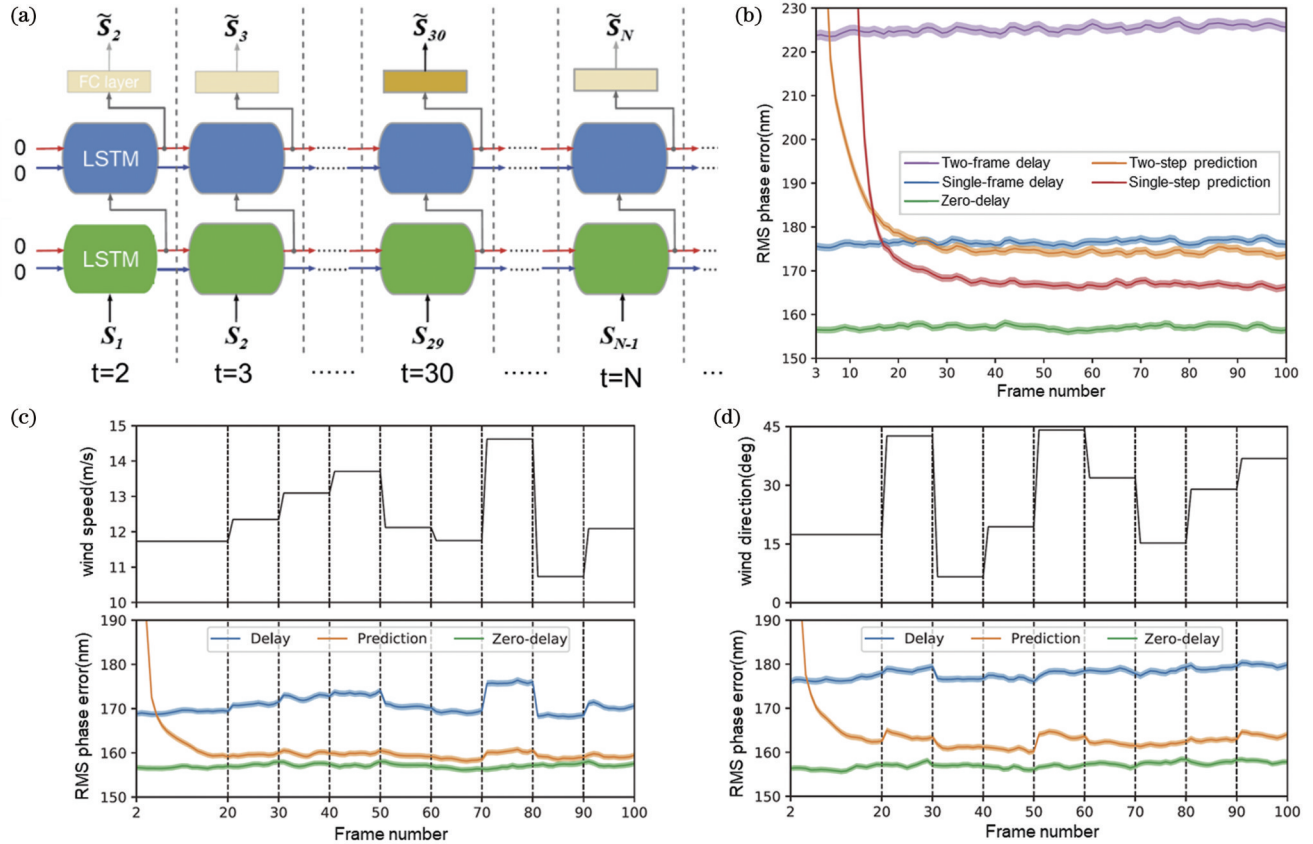


图 6 双 LSTM 预测网络模型及性能测试<sup>[47]</sup>。(a)基于双 LSTM 网络和全连接层的预测网络模型;(b)2 frame 延迟条件下单帧延迟预测方法的波前误差;(c)相位屏风向为 0 且风速变化时的波前误差;(d)相位屏风速为 15 m/s 且风向变化时的波前误差  
 Fig. 6 Dual LSTM predictive network model and its performance test<sup>[47]</sup>. (a) Predictive network model based on dual LSTM network and full connection layer; (b) wavefront error of single frame delay prediction method under 2 frame delay condition; (c) wavefront error when phase screen direction is 0 and wind speed changes; (d) wavefront error when wind speed of phase screen is 15 m/s and wind direction changes

2022 年, Wu 等<sup>[48]</sup>介绍了一种基于注意力机制和 LSTM 网络的深度卷积预测网络,网络结构如图 7(a)所示。该预测网络的输入是连续 10 frame 先验波前,在结构设计上同时考虑了大气湍流的时间和空间特征,可以很好地利用其时空耦合特性,相比于线性预测器(LP, RLS 类算法)和非线性预测器(NLP, BP 神经网络方法),预测精度得到显著提升,如图 7(b)所示。并利用真实湍流数据分析了预测网络的前向预测能力,结果表明,该预测网络的预测残差均方根(RMS)分布在 0~0.3  $\mu\text{m}$  区间,而 LP 和 NLP 的预测残差 RMS 分别分布在 1~3  $\mu\text{m}$  和 1~5  $\mu\text{m}$  区间,进一步证明了该方法的可行性。但随着延时周期的增加,预测的残差不断增大,预测的误差和难度增大,如图 7(c)所示。

为进一步提高预测精度,2022 年本课题组提出了

一种基于 ConvLSTM 的残差学习融合网络<sup>[49]</sup>,该网络采用 6 frame 先验开环波前进行延后 2 frame 的预测,网络结构如图 8 所示。其核心思想是:首先通过残差学习的方式消除相邻两帧畸变波前之间的冗余信息,然后通过 ConvLSTM 网络将精化后的特征进行融合,最后将各级特征再次融合得到预测结果。利用该方法在 1 km 激光传输条件下对湍流像差进行了波前预测性能测试,结果如图 8 所示,在  $D/r_0=7.6$  和  $D/r_0=13.6$  两种湍流像差水平下,该网络模型的平均波前预测误差分别是 0.0237 $\lambda$  和 0.0426 $\lambda$ ,是真实波前的 3.4% 和 3.8%。同时,利用 2 frame 延时条件下构造的训练模型在 3 frame 延时条件下进行了测试,在  $D/r_0=7.6$  和  $D/r_0=13.6$  两种湍流像差水平下,该网络模型的平均波前预测误差分别是 0.0311 $\lambda$  和 0.0609 $\lambda$ 。实验结果表明,该网络模型可实现不同湍流像差水平下的高精度

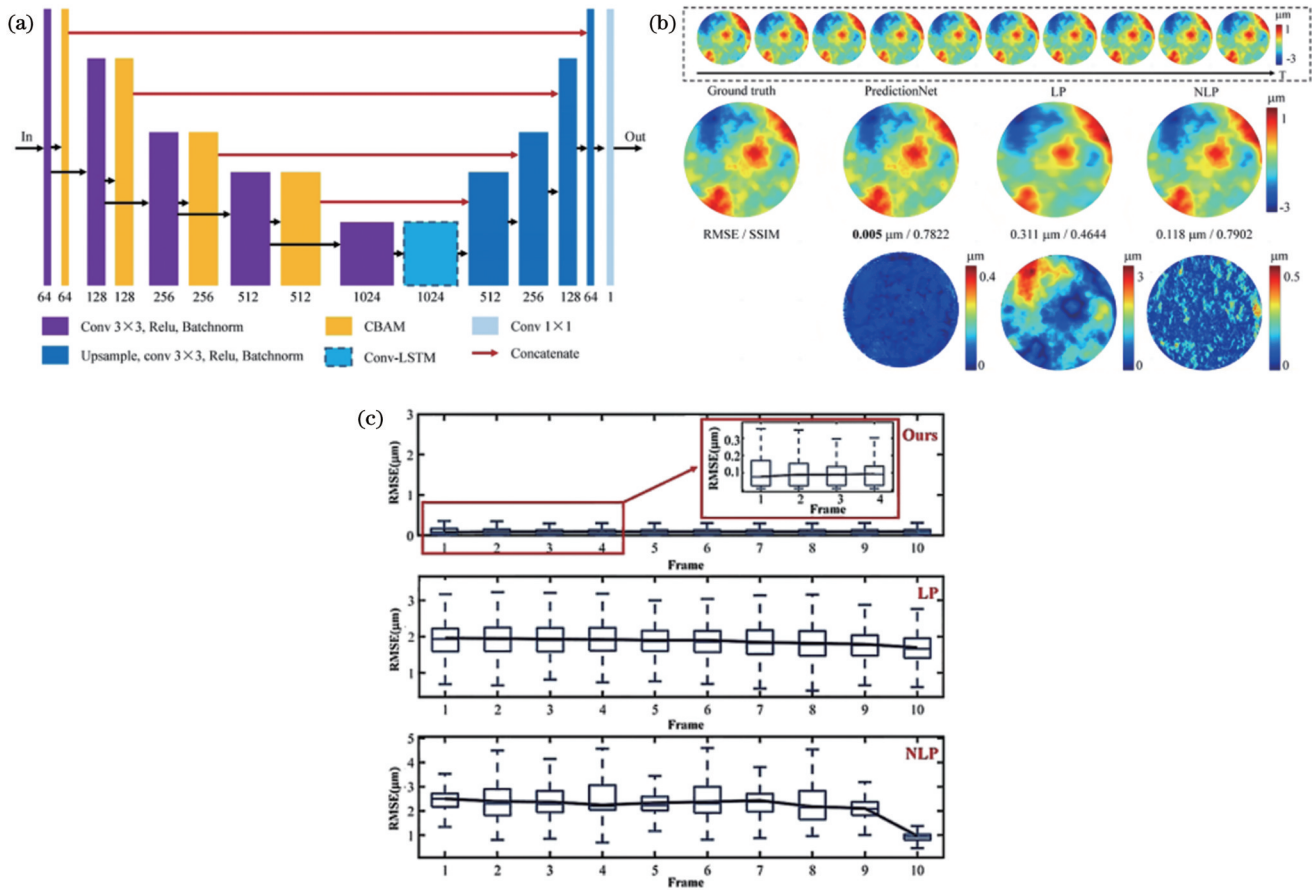


图 7 基于注意力机制和 LSTM 网络的预测网络模型及性能对比<sup>[48]</sup>。(a) 网络结构; (b) 不同网络的预测精度对比; (c) 不同网络的均方根误差对比

Fig. 7 Prediction network model based on attention mechanism and LSTM network and comparison of performances<sup>[48]</sup>. (a) Network structure; (b) comparison of prediction accuracies of different networks; (c) comparison of RMS errors of different networks

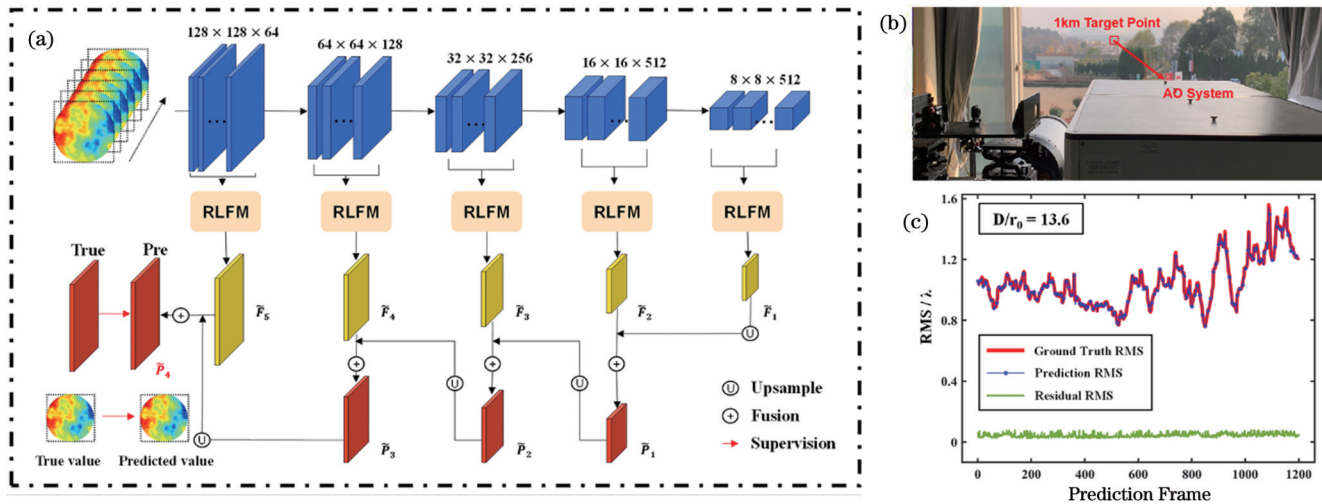


图 8 基于 ConvLSTM 的残差学习融合网络及其波前预测验证<sup>[49]</sup>。(a) 网络结构示意图; (b) 测试环境; (c)  $D/r_0=13.6$  时的波前预测结果

Fig. 8 Residual learning fusion network based on ConvLSTM and its wavefront prediction verification<sup>[49]</sup>. (a) Structural diagram of network; (b) test environment; (c) wavefront prediction result when  $D/r_0=13.6$

波前预测,且在延时周期发生变化时仍能保持较高的波前预测精度。

由上述研究结果可知,当前基于深度学习的波前预测方法主要是对大气湍流像差进行预测,并在不同

湍流强度下获得了较高的波前预测精度。文献[47]中算法在大气湍流模型参数发生变化的条件下仍具备一致的预测精度,实现了不同大气条件下湍流像差的稳定预测。文献[45]在 1 km 激光传输的实验条件下证

明了对于大气湍流像差预测的可行性。因此,在忽略深度神经网络模型推理时间的前提下,利用深度学习对大气湍流像差进行预测,有望提升自适应光学系统对高时间频率湍流像差的校正能力。但在高功率激光领域中的应用方面,仍有以下问题有待解决:1)当高功率激光在大气中传输时,热效应或热晕等因素是否会打破大气湍流的冻结假设,此时传输路径中的像差是否可预测;2)当前研究方法均是采集开环湍流数据进行离线训练,训练时长达数个小时以上,而高功率激光的应用场景变化快,如何优化深度学习网络结构或引入迁移学习方法,在不同应用场景下对网络参数进行微调,以减少训练时长。以上问题的解决对于促进基于机器学习的波前预测方法在高功率激光领域中的应用具有重要意义。

#### 4 基于机器学习的相位反演技术

高功率激光输出时的动态非均匀近场和局部大梯度像差及暗弱目标下的信标回光弱和强背景噪声都将给基于哈特曼传感器的波前探测带来较大误差,限制了自适应光学系统的校正性能<sup>[50-51]</sup>。基于优化算法的无波前自适应光学技术可以不受非均匀近场、局部大梯度像差以及哈特曼传感器空间分辨率的影响,以成像清晰度、斯特列尔比(SR)和环围能量等性能指标作为目标函数,直接对波前校正器的控制信号进行优化,以获得最优像差补偿效果<sup>[52-54]</sup>。但优化算法的迭代过程限制了无波前自适应光学系统的控制带宽,如果能避免迭代过程,利用远场图像信息直接解算出波前信息,将极大提升无波前自适应光学系统的像差校正性能。相位反演即是利用远场图像信息求解畸变波前,但其传统的求解方法如 Gerchberg-Saxton(GS)算法<sup>[55]</sup>

和相位差(PD)法<sup>[56]</sup>,仍需多次迭代求解波前相位信息,实时性差。深度学习可提取图像中的深层特征信息,有望实现由远场图像到波前相位的直接解算,提升相位反演的实时性。但在数理上,180°翻转对称入射波前对应同一焦面远场<sup>[57]</sup>,如正负离焦波前的远场相同,神经网络适用于输入和输出是一对一映射的情况,但难以实现一对多的问题求解。针对这一问题,研究人员分别将一组在焦和离焦的远场图像与单帧相位或光强调制的远场图像作为深度神经网络的输入,以实现基于机器学习的相位反演。

在 2 frame 远场图像作为深度学习网络输入方面,2018年, Ju 等<sup>[58]</sup>根据相位差法的思想,提取焦面和离焦图像的切比雪夫矩作为神经网络的输入,避免了传统相位反演算法的迭代求解过程,但该方法需对图像进行预处理,系统实时性差,精度提升有限。2019年, Ma 等<sup>[59-60]</sup>将一组在焦和离焦远场图像作为卷积神经网络的输入,输出为波前的 Zernike 系数,其采用的网络是 AlexNet 的变形,算法示意图如图 9 所示。数值仿真分析了在不同  $D/r_0$  湍流强度数据下训练模型的波前复原精度,利用  $D/r_0$  为 5 和 15 的训练模型分别对  $D/r_0$  为 5 和 15 的湍流强度像差进行复原时,复原精度高于  $D/r_0$  为 1~15 的训练模型,结果表明,多  $D/r_0$  数据下训练模型的复原性能比单一  $D/r_0$  数据下的训练模型差。2019年, Guo 等<sup>[61]</sup>用电荷耦合器件(CCD)在焦面和离焦面进行了两次测量,用 De-VGG 网络替代了 AlexNet 网络,获得了优于 Ma 等<sup>[59]</sup>所提方法的波前复原效果。利用  $D/r_0=20$  的湍流强度数据集训练的模型在  $D/r_0$  为 20、15、10、6 的测试集中均获得了较高的波前复原精度,表明由  $D/r_0=20$  的湍流强度数据集训练的模型适用于  $D/r_0 \leq 20$  的湍流强度下的波前预测。

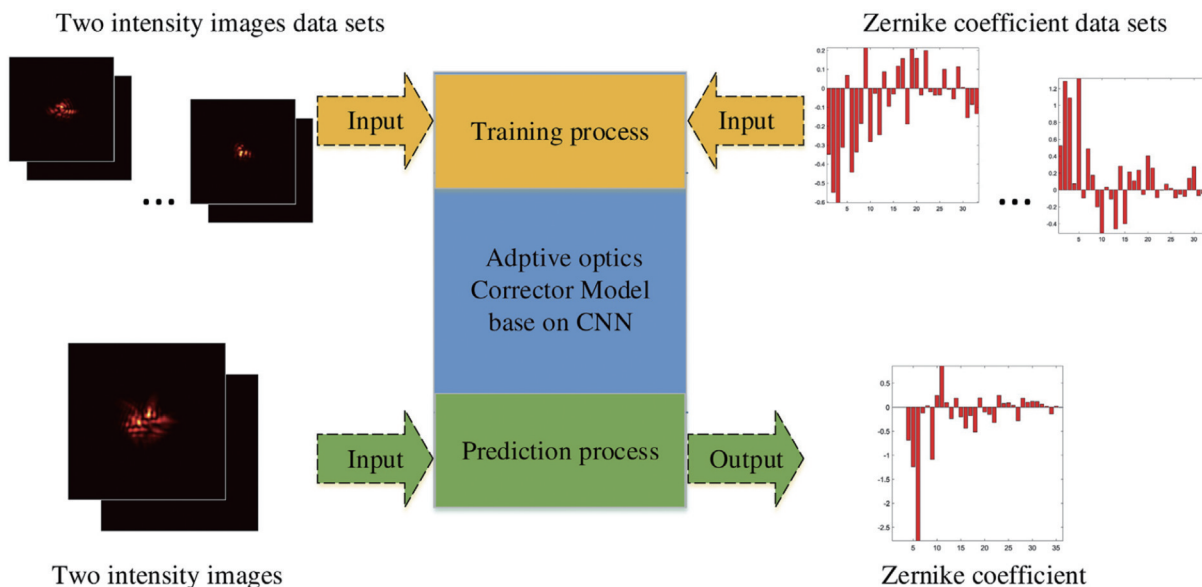


图 9 基于卷积神经网络的相位反演算法的训练与推理示意图<sup>[59]</sup>

Fig. 9 Schematics of training and reasoning of phase inversion algorithm based on convolutional neural network<sup>[59]</sup>



2020年, Wu等<sup>[62]</sup>将在焦、离焦远场图像作为深度卷积网络模型的输入, 预测了3~15阶Zernike系数, 利用TensorRT对深度卷积网络进行加速, 对比了LeNet-5和Xception网络的复原精度和推理速度。在1080 Ti显卡硬件条件下, 轻量级LeNet-5网络具有与Xception网络相同的复原精度, 但推理速度是Xception网络的5倍, 如表2所示, 经TensorRT加速后LeNet-5网络和Xception网络的推理时间均提升了5倍, LeNet-5网络的推理时间则达到了0.5 ms, 实现了

表2 LeNet-5和Xception模型的推理时间对比<sup>[62]</sup>

Table 2 Comparison of inference time between LeNet-5 and Xception models<sup>[62]</sup> unit: ms

Network	Focal model	Defocused model	PD model
LeNet-5	2.2495	2.2989	2.5591
Xception	10.469	10.1108	10.469

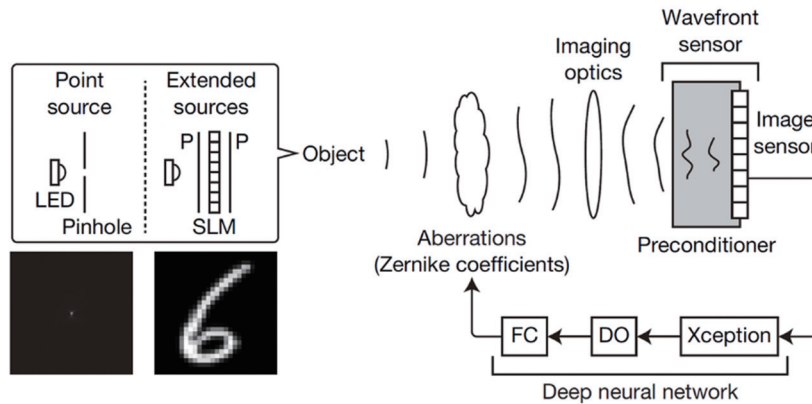


图10 基于Xception网络的波前复原测试示意图<sup>[64]</sup>

Fig. 10 Schematic of wavefront restoration test based on Xception network<sup>[64]</sup>

表3 点目标和扩展目标的波前复原误差<sup>[64]</sup>

Table 3 Wavefront restoration errors of point targets and extended targets<sup>[64]</sup>

Source	In-focus condition	Overexposure condition	Defocusing condition	Scatter condition
Point source	0.142±0.032	0.036±0.013	0.040±0.016	0.057±0.018
Extended source	0.288±0.024	0.214±0.051	0.099±0.064	0.195±0.064

2019年, Tian等<sup>[65]</sup>分析了不同大气湍流强度下卷积神经网络(CNN)对单帧焦面远场光强图像的波前复原能力。图11给出了不同大气湍流强度下算法的校正性能对比。由图11知, 当 $D/r_0=15$ 时, 算法校正后的残差波前大, RMS接近3 rad, 当 $D/r_0<3$ 时, 算法才具有较好的波前复原能力。研究表明, 在不对焦面远场图像进行光强或相位调制时, 采用深度学习网络对单帧焦面远场光强图像进行波前复原仅适用于湍流强度较小的波前像差。

2020年, 本课题组提出了一种基于四象限离散相位调制的深度学习相位反演法, 利用四象限离散相位调制解决了180°翻转对称入射波前的远场一致性问题, 将调制后的远场作为深度神经网络的输入<sup>[66]</sup>。该

亚毫秒级的相位复原。

在单帧远场图像作为深度学习网络输入方面, 2018年, Paine等<sup>[63]</sup>利用Inception网络实现了噪声情况下基于单帧焦面图像的波前Zernike系数估计, 并将该估值作为迭代寻优算法的初始值, 结果显示, 迭代寻优算法的收敛结果优于随机生成初始值的收敛结果, 有效解决了在入射波前过大时迭代寻优算法易收敛到局部极值的问题。2019年, Nishizaki等<sup>[64]</sup>基于Xception网络讨论了CCD在不同情况(在焦、离焦、过曝、散射)下点目标与扩展目标的单帧焦面图像的波前复原能力, 测试示意图如图10所示。表3列出了在焦、离焦、过曝、散射情形下网络模型的Zernike系数误差。结果表明: 当CCD在焦面时, 网络模型对点目标和扩展目标的波前复原误差较大; 当CCD分别在离焦、过曝、散射情况下, 网络模型对点目标的波前复原较准确, 而对扩展目标的复原仍存在较大的误差。

方法在图12所示的实验系统中得以验证, 入射波前由4~23项Zernike系数随机生成, 各项Zernike系数均在±0.5 μm以内, 经四象限离散相位调制器(FQDPM)调制后利用CCD测量获得焦面远场光强分布。1000组测试样本校正前后的平均残差波前RMS从1.276 μm下降到0.084 μm, 校正后的残差波前RMS为校正前的6.58%, 其中两组样本的波前复原结果如图12(c)所示。可以看出该方法复原精度高, 避免了单帧焦面图像复原的多解问题。

2021年, Wang等<sup>[67]</sup>提出了一种基于单帧光瞳平面强度图像的高精度相位反演方法, 利用波动光学模拟了二维Kolmogorov湍流相位屏的非涅耳衍射过程, 将得到的光瞳平面光场分布作为EfficientNet-B0网络




图 11 不同大气湍流强度下算法的校正结果<sup>[65]</sup>

Fig. 11 Correction results of algorithm under different atmospheric turbulence intensities<sup>[65]</sup>

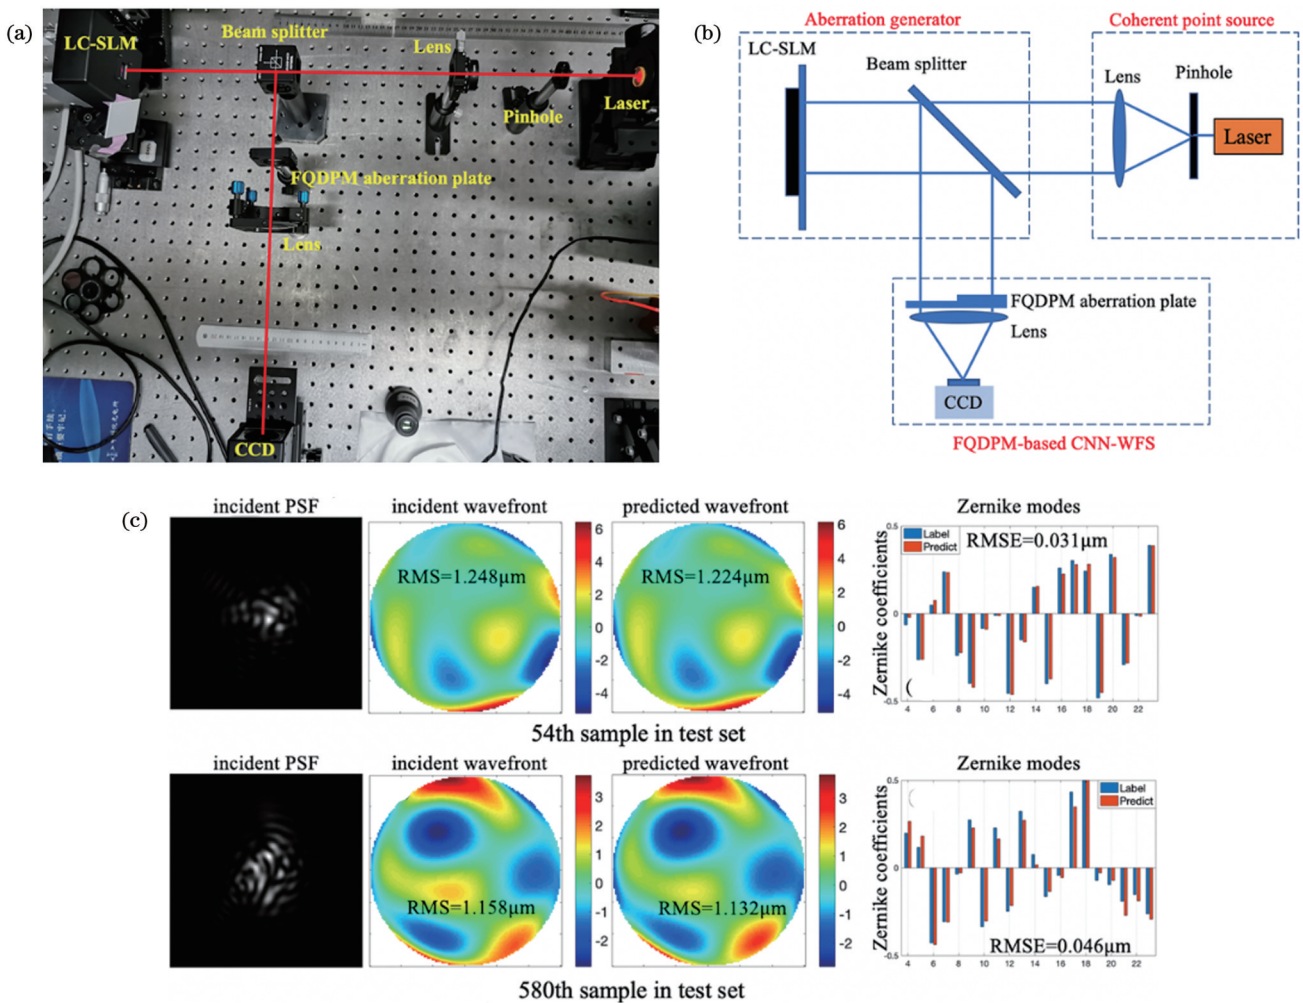


图 12 基于四象限离散相位调制的相位反演实验验证<sup>[66]</sup>。(a)实验系统实物图;(b)实验系统示意图;(c)两组样本的波前复原结果  
Fig. 12 Experimental verification of phase inversion based on four-quadrant discrete phase modulation<sup>[66]</sup>. (a) Physical diagram of experimental system; (b) schematic of experimental system; (c) wavefront restoration results of two groups of samples

的输入以实现与 Zernike 系数的映射。EfficientNet 模型的基础网络是基于神经架构搜索设计得到的, 其结构如图 13 所示, 通过扩展 7 个阶段的网络深

度、每一层的网络宽度和图像分辨率, 对 EfficientNet 基础模型进行缩放, 可得到 B0~B7 版本。在相同的实验环境下, 与 ResNet-50 和 Inception-V3 相比,

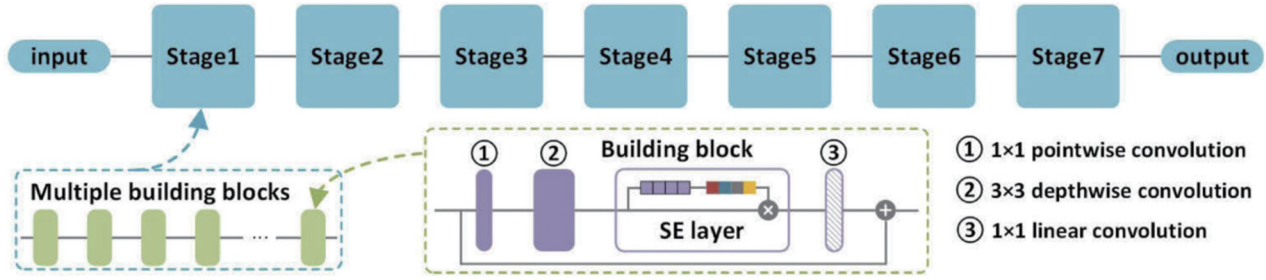


图 13 EfficientNet 结构示意图<sup>[67]</sup>

Fig. 13 Structural diagram of EfficientNet<sup>[67]</sup>

EfficientNet-B0 的参数数量减少近 80%，波前复原精度提升了 2 倍。

由上述研究可知,基于深度学习的相位反演方法可以利用远场图像直接求解波前信息,有望避免传统无波前自适应光学技术的迭代求解过程,提升无波前自适应光学系统的控制带宽。但需要注意的是,当前研究方法在无波前自适应光学系统的实际应用中,尤其是在高功率激光领域中,仍存在以下问题:1)高功率激光近场光强非均匀分布会造成远场光斑的强度分布和光斑形态不同,强背景噪声会淹没远场光斑图像的边缘细节,因此需分析光强起伏、背景噪声等因素对波前复原精度的影响;2)当前研究中训练样本多由液晶空间光调制器依据  $D/r_0$  参数生成,液晶空间光调制器的像差拟合能力强,保证了远场图像与像差之间的准确对应关系,而在实际的无波前自适应光学系统中,依赖变形镜的像差拟合能力难以生成准确的训练样本。此外,高功率激光输出时,其热效应像差的时空特性不同于根据  $D/r_0$  生成的像差,因此训练样本像差的幅值与空间频率分布也有待研究。

### 5 基于机器学习的波前校正技术

高功率激光在不同场景下应用时,激光器类型不同,所处平台不同,工作环境不同,这些都将对激光自适应光学系统带来各类型的内部和外部扰动,进而降低激光自适应光学系统对像差的校正性能。在内部扰

动方面,不同体制高功率激光器的谐振腔、增益介质和热管理方式不同,对应的热效应像差特性和近场光强分布特性不同。在外部扰动方面,机动平台的振动会造成波前校正器响应函数的变化,工作温度的不同会造成波前探测器参考零点的变化等。因此,为抑制内外扰动对自适应光学系统校正性能的影响,提升自适应光学系统对工作环境的智能感知与自适应调节能力,研究人员开展了多项基于机器学习的波前校正技术研究。

为实现自适应光学系统对波前校正器响应函数的动态调节,2019 年本课题组提出一种基于深度学习控制模型(DLCM)的自适应光学控制方法<sup>[68]</sup>,用参数化的非线性网络代替原始线性矩阵,通过梯度优化、参数共享等优化了系统的收敛精度和迭代速度,完成了对响应矩阵的在线识别和自适应控制。DLCM 的结构如图 14 所示,包含了 model net 和 actor net,二者具备相同的网络结构,均描述了波前残差信号到波前校正器控制信号的映射关系。动态闭环过程中 actor net 的输入和输出可为 model net 提供在线训练样本,而 model net 的参数可共享给 actor net,使其输出更准确的控制量。与传统比例积分(PI)控制方法相比,DLCM 方法可在波前校正器与波前传感器之间的位置匹配关系发生变化时对波前校正器的响应函数进行在线修正,保障了系统闭环稳定性。

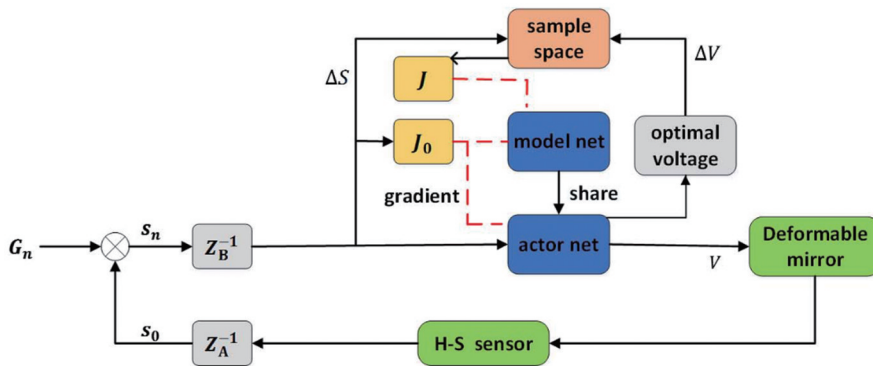


图 14 DLCM 控制器的结构示意图<sup>[68]</sup>

Fig. 14 Structural diagram of DLCM controller<sup>[68]</sup>

为在实验平台中实现对波前校正器响应矩阵的动态修正,2020年本课题组对 DLCM 控制器进行了改进,提出了一种自适应光学自学习(NI)控制模型<sup>[69]</sup>,该模型采用线性神经网络表征波前校正器的响应矩阵,闭环过程中的收敛速度快,更适用于实际自适应光学系统。在图 15(a)所示的实验系统中进行了该方法的性能验证,结果表明:当波前校正器的响应

矩阵无偏移时,传统 PI 控制器和 NI 控制模型均能获得较好的像差校正效果,如图 15(b)所示,但 NI 控制模型效果更好,这表明采用经 NI 控制模型修正的响应矩阵能更好地表征波前校正器的校正能力;当响应矩阵发生偏移时,传统 PI 控制器失效,而 NI 控制模型仍能稳定闭环,实现对像差的有效补偿,如图 15(c)所示。

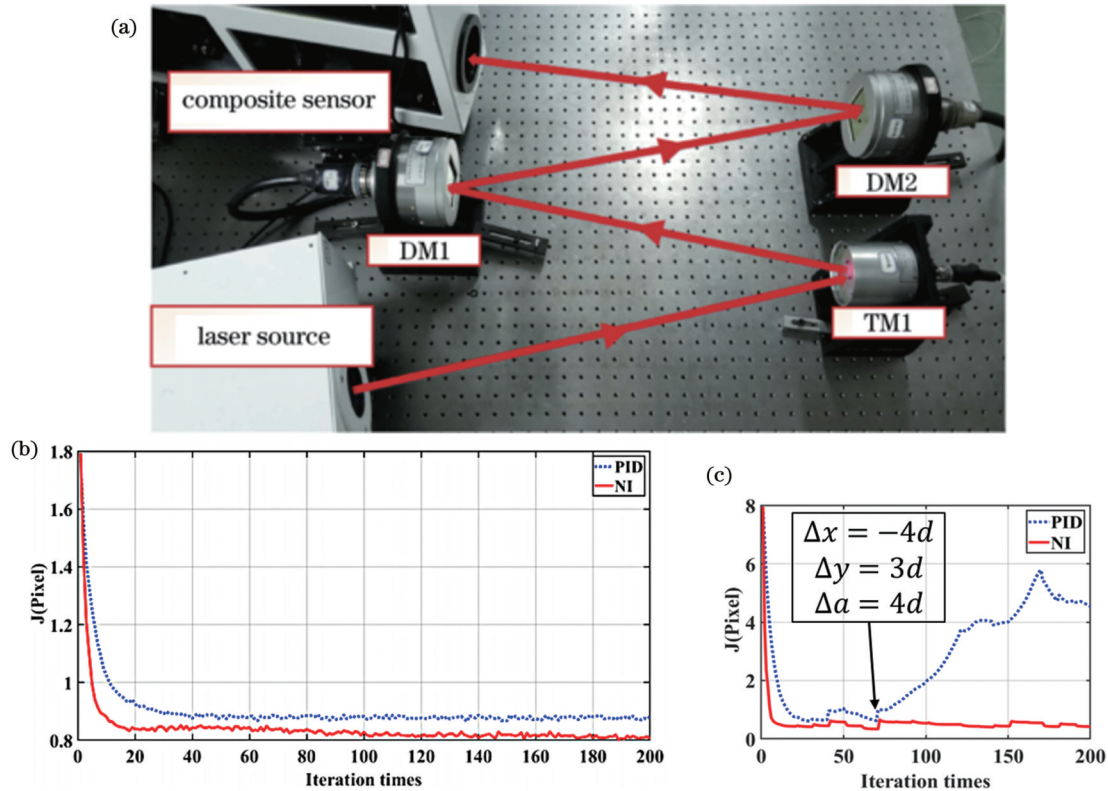


图 15 NI 控制模型的实验验证<sup>[69]</sup>。(a)实验平台;(b)响应矩阵无偏移时 PI 与 NI 控制性能的对比;(c)响应矩阵偏移时 PI 与 NI 控制性能的对比

Fig. 15 Experimental verification of NI control model<sup>[69]</sup>. (a) Experimental platform; (b) comparison of PI and NI control performances when response matrix is not offset; (c) comparison of PI and NI control performances when response matrix is offset

同年,为消除哈特曼波前传感器存在的缺光或者质心探测不理想问题对像差校正效果的影响,本课题组在 NI 控制模型的基础上,引入了远场图像指标,提出了基于远场指标梯度的自学习波前控制模型<sup>[70]</sup>,并在图 15(a)所示的实验平台中进行了性能验证。实验结果表明,当哈特曼传感器存在多个子孔径缺光现象时,如图 16(a)所示,传统直接斜率法的校正性能下降,而所提方法通过对波前校正器响应矩阵进行在线优化仍能获得与不缺光时一致的远场校正效果,闭环过程和远场指标对比分别如图 16(b)、(c)所示。

上述研究主要是采用神经网络方法建立自适应光学系统中波前校正器响应矩阵的动态表述,以实现自适应光学系统在面临系统输入或系统自身参数发生偏移时的自适应调节。与此同时,研究人员也尝试通过引入强化学习方法来提升自适应光学系统的智能化水平。2018,本课题组将深度强化学习中的确定性策略

梯度算法(DDPG)引入到无波前自适应光学控制系统中,实现了由远场光斑图像到控制电压的端到端控制结构<sup>[71]</sup>。数值仿真结果表明,该方法相比于 SPGD 算法<sup>[72]</sup>和 AOG 算法<sup>[73]</sup>,在相同的校正效果下将迭代速度提高了约 9 倍和 2.5 倍。2020 年, Landman 等<sup>[74]</sup>为消除高频抖动和时延误差对自适应光学控制系统带来的不利影响,介绍了一种基于无模型强化学习的循环神经网络控制器,对高频抖动和系统时延进行了有效控制。与积分控制器不同,该控制器模型在强化学习架构的基础上,使用 LSTM 网络处理时序信息,将历史控制输出和斜率观测作为输入,以点扩散函数的质心偏移作为奖励,最后输出倾斜镜控制电压。该方法在实验平台上得到验证,结果如图 17 所示,与最优参数的积分控制器相比,该方法将抖动残差 RMS 降低了约 83%,同时在不需要系统先验知识的情况下可以自主识别不同频率的抖动并加以补偿。2021 年, Durech

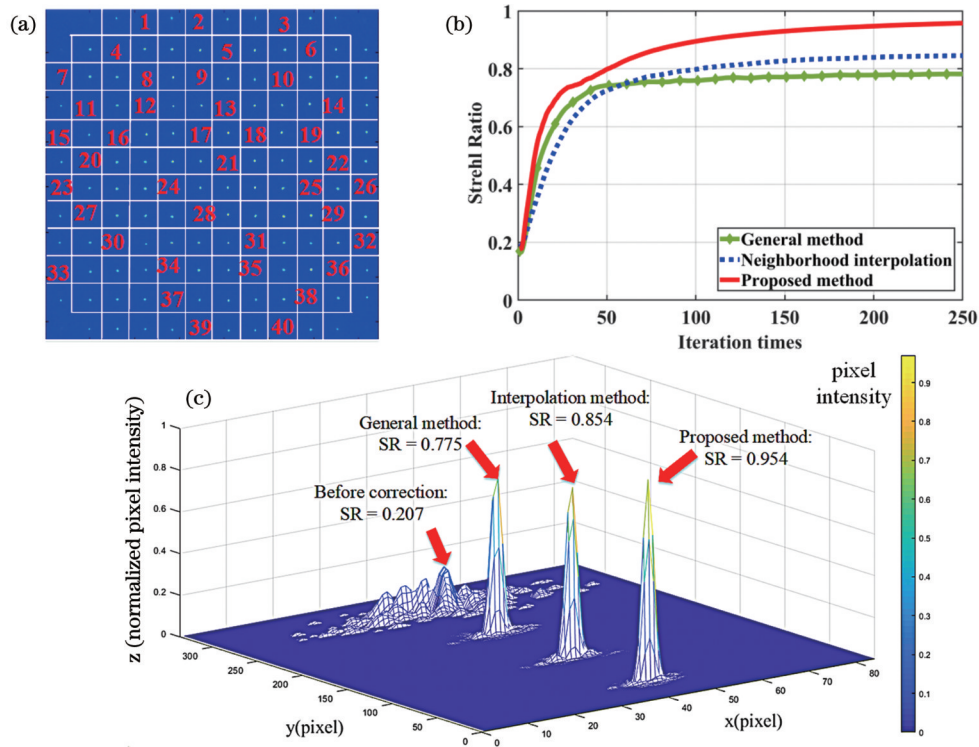


图 16 基于远场指标梯度的自学习波前控制模型的实验验证<sup>[70]</sup>。(a)40 个子孔径缺光时的光斑阵列图像；(b)闭环 SR 对比；(c)闭环远场 SR 及三维图像对比

Fig. 16 Experimental verification of self-learning wavefront control model based on far-field index gradient<sup>[70]</sup>. (a) Spot array image with 40 sub-aperture light deficiency; (b) comparison of closed-loop SR; (c) comparison of closed-loop far-field SR and 3D image

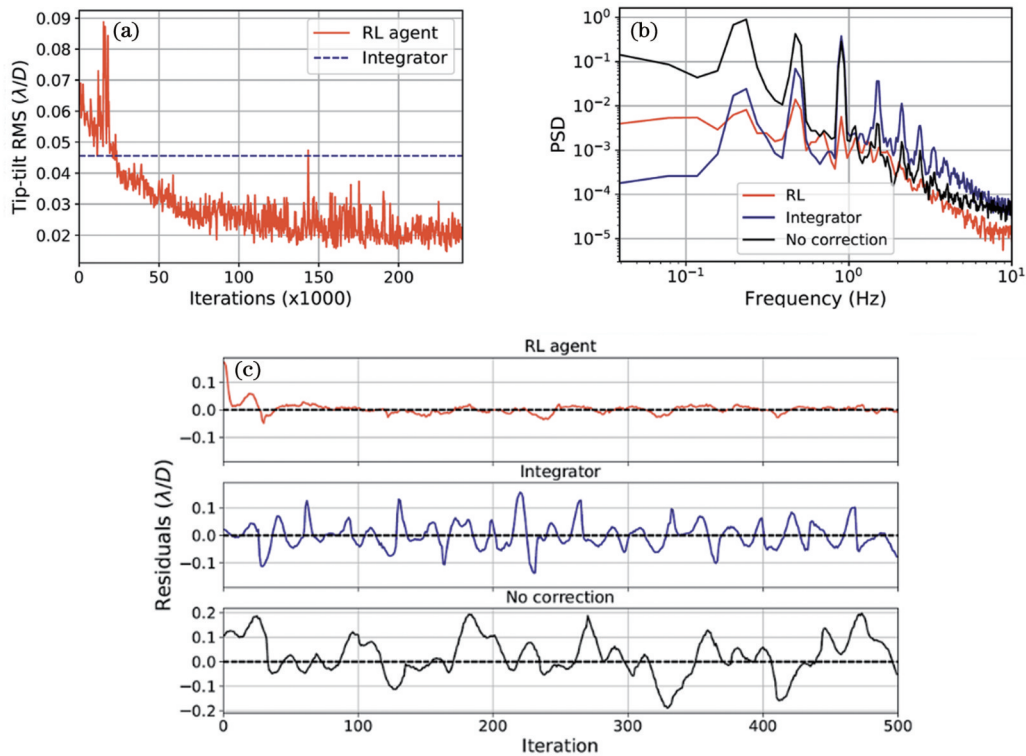


图 17 强化学习控制器和积分控制器抑制光束抖动的性能对比<sup>[74]</sup>。(a)包含三个频率抖动时强化学习控制器的训练曲线；(b) $x$ 方向上 2500 frame 采样数据的闭环功率谱密度 (PSD) 值对比；(c) $x$ 方向上 500 frame 采样数据的闭环残差对比

Fig. 17 Comparison of beam jitter suppression performance between reinforcement learning controller and integration controller<sup>[74]</sup>. (a) Training curve of reinforcement learning controller with three frequency jitters; (b) comparison of closed-loop power spectral density (PSD) values of 2500 frame sampled data in  $x$  direction; (c) comparison of closed-loop residuals of 500 frames sampled data in  $x$  direction

等<sup>[75]</sup>提出了一种用于无波前自适应光学校正的深度强化学习控制方法,采用DDPG算法框架提出了一种从图像质量指标到Zernike模式系数的控制策略,在小鼠视网膜成像系统中用该方法对5种低阶Zernike模式(离焦、水平慧差、垂直三叶草像差、垂直像散和45°像散)进行了有效校正,相比传统的爬山坐标搜索法(ZMHC),迭代速度提升了6~7倍。

2021年,Nousiainen等<sup>[76]</sup>将自适应光学控制问题描述成一种基于模型的强化学习(MBRL)问题,通过神经网络将系统动态模型参数化,在给定当前时刻状

态和动作下描述下一时刻状态的条件分布,基于训练好的状态转移模型,利用交叉熵算法优化动作选择的分布模型以实现最优控制。研究者仿真了MBRL在口径为8 m的望远镜上的自适应光学校正效果,对该方法的预测能力、噪声鲁棒性和失配自校准能力进行了分析。图18比较了系统时延对积分控制器和强化学习(RL)控制器的影响,仿真结果表明,MBRL控制的自适应光学能够预测湍流的时间演化,并对控制信号和探测信号之间的错配进行调整,获得了与无延时系统近似等价的校正效果。

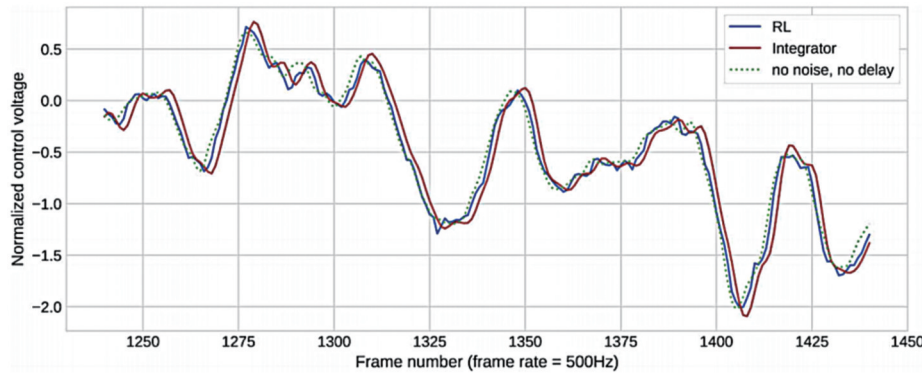


图 18 系统时延对不同算法校正性能的影响<sup>[76]</sup>

Fig. 18 Effect of system time delay on correction performances of different algorithms<sup>[76]</sup>

2022年,Nousiainen等<sup>[77]</sup>提出一种混合的自适应光学策略优化算法(PO4AO),包括利用监督学习训练动态模型和使用该模型评估优化策略网络。考虑到自适应光学系统控制信号的时空关联性,建立了由历史状态和动作到下一时刻状态的系统动态模型,利用该动态模型可以获取当前策略在几个时间延时后的状态,用于训练策略网络以获得针对系统延时的最优控制策略。PO4AO中的动态模型和策略网络均采用图19所示的端到端的网络架构,动态模型和策略网络的输入均包含 $k$ 个采样时间的动作

值和 $m$ 个采样时间的观测值,在输出层策略模型经KL模式滤波算法作用得到下一时刻的动作,动态模型输出乘以波前探测器(WFS)掩模得到下一时刻的观测值,为了统一观测值和动作值,使用重构矩阵将观测值投影到动作空间中。在口径为8 m和40 m的望远镜的自适应光学控制系统中对该方法进行了数值仿真验证,并成功应用于MagAO-X系统。仿真和实验结果表明,该方法能够在5~10 s的时间尺度内获得优于传统PI控制器的校正效果,且推理时间只有300  $\mu$ s左右。




图 19 PO4AO的神经网络架构<sup>[77]</sup>

Fig. 19 Neural network architecture of PO4AO<sup>[77]</sup>

2022 年, Pou 等<sup>[78]</sup>分析了强化学习方法应用于自适应光学控制系统时面临的诸多挑战, 提出了一种多智能体强化学习(MARL)方法, 其架构如图 20 所示。可以看到, 环境由大气、变形镜、WFS 和对 WFS 图像进行降噪的自编码器组成。以观测状态作为输入, 将其分离为  $N$  个决策过程, 分别使用不同的策略生成动作。所有这些动作将被组合成一个联合动作, 作为修正项对积分控制器的输出控制信号进行修正。研究者对自适应光学控制系统的时延误差、高维控制问题、噪声、环境动态演变等难题提出了解决思路。针对高维问题, MARL 方法利用一组正交模式对每一维控制量进行单独优化, 并设置了独立的奖励函数和观测量, 使其互不干扰; 针对噪声问题, MARL 方法使用自编码器网络对哈特曼子孔径图像预先进行去噪, 由于噪声只依赖于噪声水平而非大气条件, 因此自编码网络可以预先训练。通过口径为 8 m 的望远镜的自适应光学控制系统的仿真, 验证了 MARL 方法对不同条件下的大气湍流均具有较好的校正效果, 超过了积分控制器的平均水平, 与具有完美先验知识的线性二次型高斯(LQG)控制方法的水平相当, 证明了 MARL 方法的有效性。

由上述研究可知, 基于机器学习的波前控制方法

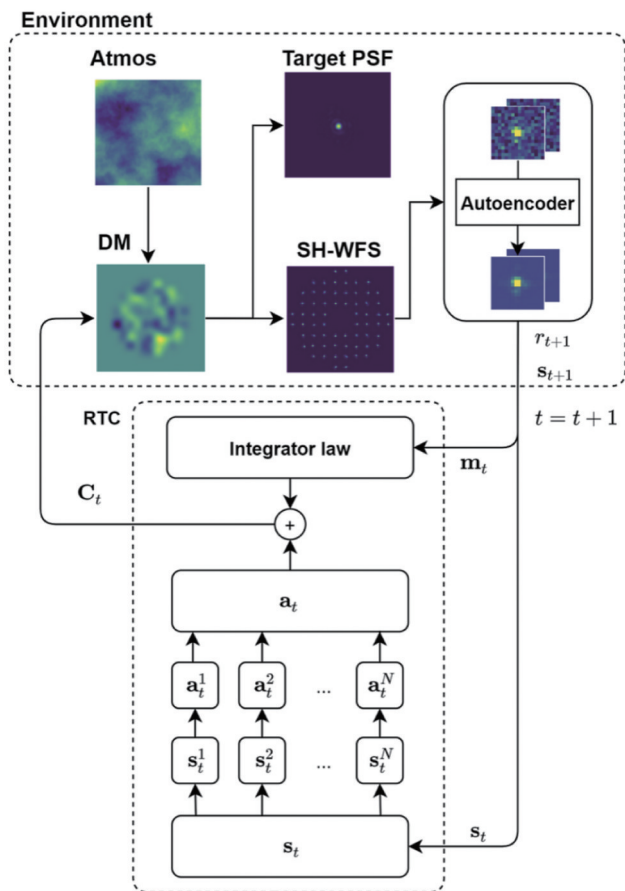


图 20 自适应光学的多智能体强化学习方法的网络架构<sup>[78]</sup>  
 Fig. 20 Network architecture of multi-agent reinforcement learning method for adaptive optics<sup>[78]</sup>

可以分为基于神经网络的在线学习方法、有模型的强化学习方法和无模型的强化学习方法, 本质上三者均属于最优化求解问题。不同的是, 基于神经网络的在线学习方法利用神经网络求解自适应光学系统部分动态响应的最优映射关系, 且以系统测量的响应关系作为学习的初始位置, 因此其收敛速度快。强化学习方法可在自适应光学系统面临外部环境扰动和内部模型扰动时进行最优控制策略求解, 因此理论上具有最优控制性能。但由于存在与环境交互的过程且自适应光学是高维连续空间控制, 其训练收敛较慢。当前有模型的强化学习方法和无模型的强化学习虽然已在天文成像领域中进行了数值仿真或实验验证, 取得了优于传统积分控制器的像差校正性能, 甚至与具有完美先验知识的 LQG 控制方法的性能相当, 但在高功率激光领域中应用时仍需注意以下问题: 1) 不同于天文观测, 高功率激光出光时长有限, 难以提供训练所需的交互环境, 且高功率激光出光时像差的时空特性与天文观测时的大气湍流像差的时空特性不同, 因此利用参考光源建立与高功率激光出光等价的训练环境, 并在此基础上进行无模型的强化学习波前控制有待深入研究; 2) 自适应光学是高维连续空间上的控制, 强化学习在面临高维连续空间上的控制问题时, 其训练时间较长, 且相比于天文观测目标, 高功率激光信标的照射时间短, 急需缩短强化学习应用于自适应光学系统时的训练时间。

## 6 结束语

分别从波前重构、波前预测、相位反演和波前校正四个方面, 对当前基于机器学习方法的自适应光学的相关研究进行了归纳与分析, 并讨论了相关研究在解决当前自适应光学技术中高功率激光输出、激光大气传输、暗弱目标探测及环境适应性等问题时的成果与不足。在哈特曼传感器的波前重构方面, 深度学习方法提升了哈特曼传感器对高空间频率像差的复原能力, 在低信噪比、缺光等条件下实现了高精度波前复原, 为暗弱目标、强光背景和强闪烁激光近场等场景下的高光束质量波前校正提供准确的波前输入。在波前预测方面, 多种改进的 LSTM 深度学习网络不仅具有学习动态湍流像差的能力, 且均获得了优于传统 RLS 迭代方法的波前预测精度, 有望打破系统延时对自适应光学系统控制带宽的限制, 提升了系统对高时空频率像差的校正能力。在相位反演方面, 先对远场图像的光强、相位等进行调制, 再结合深度学习方法的相位反演方法, 实现了由单帧光强图像到波前相位的直接解算, 避免了无波前自适应光学技术中的迭代过程, 实现了基于远场图像指标的最优像差校正。在波前校正方面, 利用深度学习网络对波前校正器响应函数的动态描述和强化学习方法对系统控制策略的动态求解, 可实现系统对输入和自身参数变化的自主识别和自适

应调节,提升自适应光学系统在不同机动平台和不同工作环境下的自适应能力。

虽然机器学习方法已对自适应光学技术的多个方面进行了改进,展现了其在大功率激光系统光束控制上的潜力,但在实际应用中还有以下问题有待研究: 1)训练样本采集问题。大功率激光出光时长有限,其热效应像差与大气湍流像差的时空特性不同,难以采集或生成符合大功率激光热效应像差特性的训练样本。此外,在大功率激光输出或强背景噪声条件下,难以获得对应的真实波前像差。2)训练环境与时长问题。相比于天文观测,大功率激光难以提供机器学习方法所需的交互环境,需在参考光条件下建立与大功率激光出光等价的交互环境。此外,激光信标照射时间有限且大气湍流像差特性随时间发生变化,急需缩短机器学习方法的训练时长。3)多方法融合问题。大功率激光的应用往往存在强背景噪声、动态缺光和高时空特性像差等多个问题,以波前重构为例,为了在保证波前复原精度和速度的同时,实现低信噪比和缺光条件下的高空间频率像差复原,需对现有网络方法进行融合与优化。

### 参 考 文 献

- [1] Babcock H W. The possibility of compensating astronomical seeing [J]. *Publications of the Astronomical Society of the Pacific*, 1953, 65(386): 229-236.
- [2] Hardy J W, Lefebvre J E, Koliopoulos C L. Real-time atmospheric compensation[J]. *Journal of the Optical Society of America A*, 1977, 67(3): 360-369.
- [3] Hardy J W. *Adaptive optics for astronomical telescopes*[M]. New York: Oxford University Press, 1998.
- [4] Merkle F, Hubin N N. Adaptive optics for the European very large telescope[J]. *Proceedings of SPIE*, 1991, 1542: 283-292.
- [5] Genetron E, Cuby J G, Rigaut F J, et al. Come-On-Plus project: an upgrade of the come-on adaptive optics prototype system[J]. *Proceedings of SPIE*, 1991, 1542: 296-307.
- [6] 任德清, 张天宇, 王钢. 改进型高性能静态像差校正技术[J]. *光电工程*, 2022, 49(3): 210319.
- [7] Ren D Q, Zhang T Y, Wang G. An optimized high-performance technique for adaptive optics static aberration correction[J]. *Opto-Electronic Engineering*, 2022, 49(3): 210319.
- [8] Spreen D E, Hogge C B. Characterizing high-altitude horizontal path optical propagation[J]. *Proceedings of SPIE*, 1994, 2120: 2-9.
- [9] Nemoto K, Fujii T, Goto N, et al. Transformation of a laser beam intensity profile by a deformable mirror[J]. *Optics Letters*, 1996, 21(3): 168-170.
- [10] El-Agmy R, Bulte H, Greenaway A H, et al. Adaptive beam profile control using a simulated annealing algorithm[J]. *Optics Express*, 2005, 13(16): 6085-6091.
- [11] Steiner T D, Merritt P H. *Airborne laser advanced technology*[M]. Bellingham: SPIE, 1998.
- [12] Greenwood D, Primmerman C A. Adaptive optics research at Lincoln Laboratory[J]. *Lincoln Laboratory Journal*, 1992, 5: 3-24.
- [13] 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.
- [14] Liang J, Williams D R, Miller D T. Supernormal vision and high-resolution retinal imaging through adaptive optics[J]. *Journal of the Optical Society of America A*, 1997, 14(11): 2884-2892.
- [15] Vargas-Martín F, Prieto P M, Artal P. Correction of the aberrations in the human eye with a liquid-crystal spatial light modulator: limits to performance[J]. *Journal of the Optical Society of America A*, 1998, 15(9): 2552-2562.
- [16] Hecht J. *Lasers, death rays, and the long, strange quest for the ultimate weapon*[M]. New York: Prometheus Books, 2019.
- [17] 刘泽金, 王红岩, 许晓军. 高能半导体泵浦气体激光器[J]. *中国激光*, 2021, 48(4): 0401001.
- [18] Liu Z J, Wang H Y, Xu X J. High energy diode pumped gas laser [J]. *Chinese Journal of Lasers*, 2021, 48(4): 0401001.
- [19] 周朴, 粟荣涛, 马阎星, 等. 激光相干合成的研究进展: 2011—2020[J]. *中国激光*, 2021, 48(4): 0401003.
- [20] Zhou P, Su R T, Ma Y X, et al. Review of coherent laser beam combining research progress in the past decade[J]. *Chinese Journal of Lasers*, 2021, 48(4): 0401003.
- [21] 刘泽金, 杨未强, 韩凯, 等. 激光武器设计准则探讨[J]. *中国激光*, 2021, 48(12): 1201001.
- [22] Liu Z J, Yang W Q, Han K, et al. Research on the design criteria of laser weapons[J]. *Chinese Journal of Lasers*, 2021, 48(12): 1201001.
- [23] Albertine J R. Recent high-energy laser system tests using the MIRACL/SLBD[J]. *Proceedings of SPIE*, 1993, 1871: 229-239.
- [24] Horkovich J, Pomphrey P. Recent advances in alpha high power chemical laser program[C]//AIAA 28th Plasmadynamics and Lasers Conference, June 23-25, 1997, Atlanta GA, USA. Reston: AIAA Press, 1997: 2409.
- [25] McNaught S J, Komine H, Weiss S B, et al. 100 kW coherently combined slab MOPAs[C]//2009 Conference on Lasers and Electro-Optics and 2009 Conference on Quantum electronics and Laser Science Conference, June 2-4, 2009, Baltimore, MD, USA. New York: IEEE Press, 2009.
- [26] Radovic A, Williams M, Rousseau D, et al. Machine learning at the energy and intensity frontiers of particle physics[J]. *Nature*, 2018, 560(7716): 41-48.
- [27] Segler M H S, Preuss M, Waller M P. Planning chemical syntheses with deep neural networks and symbolic AI[J]. *Nature*, 2018, 555(7698): 604-610.
- [28] Senior A W, Evans R, Jumper J, et al. Improved protein structure prediction using potentials from deep learning[J]. *Nature*, 2020, 577(7792): 706-710.
- [29] 李新阳, 姜文汉. 哈特曼传感器对湍流畸变波前的泽尼克模式复原误差[J]. *强激光与粒子束*, 2002, 14(2): 243-249.
- [30] Li X Y, Jiang W H. Zernike modal wavefront reconstruction error of Hartmann sensor on measuring the atmosphere disturbed wavefront[J]. *High Power Laser and Particle Beams*, 2002, 14(2): 243-249.
- [31] Montera D A, Welsh B M, Roggemann M C, et al. Use of artificial neural networks for Hartmann-sensor lenslet centroid estimation[J]. *Applied Optics*, 1996, 35(29): 5747-5757.
- [32] Li Z Q, Li X Y. Centroid computation for Shack-Hartmann wavefront sensor in extreme situations based on artificial neural networks[J]. *Optics Express*, 2018, 26(24): 31675-31692.
- [33] Guo H, Korablinova N, Ren Q S, et al. Wavefront reconstruction with artificial neural networks[J]. *Optics Express*, 2006, 14(14): 6456-6462.
- [34] Xu Z Q, Wang S, Zhao M M, et al. Wavefront reconstruction of a Shack-Hartmann sensor with insufficient lenslets based on an extreme learning machine[J]. *Applied Optics*, 2020, 59(16): 4768-4774.
- [35] Swanson R, Lamb M, Correia C, et al. Wavefront reconstruction and prediction with convolutional neural networks[J]. *Proceedings of SPIE*, 2018, 10703: 107031F.
- [36] 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.
- [37] Hu L J, Hu S W, Gong W, et al. Learning-based Shack-Hartmann wavefront sensor for high-order aberration detection[J]. *Optics Express*, 2019, 27(23): 33504-33517.



- [33] Hu L J, Hu S W, Gong W, et al. Deep learning assisted Shack-Hartmann wavefront sensor for direct wavefront detection[J]. *Optics Letters*, 2020, 45(13): 3741-3744.
- [34] 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.
- [35] Gu H, Zhao Z Y, Zhang Z G, et al. High precision wavefront reconstruction from Shack-Hartmann wavefront sensor data by a deep convolutional neural network[J]. *Measurement Science and Technology*, 2021, 32(8): 085101.
- [36] Guo Y M, Wu Y, Li Y, et al. Deep phase retrieval for astronomical Shack-Hartmann wavefront sensors[J]. *Monthly Notices of the Royal Astronomical Society*, 2022, 510(3): 4347-4354.
- [37] Zhao M M, Zhao W, Wang S, et al. Centroid-predicted deep neural network in Shack-Hartmann sensors[J]. *IEEE Photonics Journal*, 2021, 14(1): 6804810.
- [38] 李新阳, 姜文汉. 自适应光学控制系统的有效带宽分析[J]. *光学学报*, 1997, 17(12): 1697-1702.  
Li X Y, Jiang W. Effective bandwidth analysis of adaptive optics control system[J]. *Acta Optica Sinica*, 1997, 17(12): 1697-1702.
- [39] Kulcsár C, Raynaud H F, Petit C, et al. Minimum variance prediction and control for adaptive optics[J]. *Automatica*, 2012, 48(9): 1939-1954.
- [40] Poyneer L, Véran J P. Predictive wavefront control for adaptive optics with arbitrary control loop delays[J]. *Journal of the Optical Society of America. A, Optics, Image Science, and Vision*, 2008, 25(7): 1486-1496.
- [41] 张秀娟, 李新阳, 张慧敏. 利用复原电压预测大气湍流畸变波前方法[J]. *强激光与粒子束*, 2006, 18(5): 757-760.  
Zhang X J, Li X Y, Zhang H M. Prediction algorithm for atmosphere turbulence with control voltage of deformable mirror [J]. *High Power Laser and Particle Beams*, 2006, 18(5): 757-760.
- [42] 颜召军, 李新阳, 饶长辉. 一种自适应光学闭环系统预测控制算法的仿真研究[J]. *光学学报*, 2011, 31(1): 0101003.  
Yan Z J, Li X Y, Rao C. Numerical simulation of a prediction control algorithm for close-loop adaptive optical system[J]. *Acta Optica Sinica*, 2011, 31(1): 0101003.
- [43] Jorgenson M B, Aitken G J M. Prediction of atmospherically induced wave-front degradations[J]. *Optics Letters*, 1992, 17(7): 466-468.
- [44] 颜召军, 李新阳. 基于神经网络的自适应光学系统变形镜控制电压预测方法[J]. *光学学报*, 2010, 30(4): 911-916.  
Yan Z J, Li X Y. Neural network prediction algorithm for control voltage of deformable mirror in adaptive optical system[J]. *Acta Optica Sinica*, 2010, 30(4): 911-916.
- [45] 史晓雨, 冯勇, 陈颖, 等. 自适应光学系统变形镜控制电压预测[J]. *强激光与粒子束*, 2012, 24(6): 1281-1286.  
Shi X Y, Feng Y, Chen Y, et al. Predicting control voltages of deformable mirror in adaptive optical system[J]. *High Power Laser and Particle Beams*, 2012, 24(6): 1281-1286.
- [46] Chen Y. Voltages prediction algorithm based on LSTM recurrent neural network[J]. *Optik*, 2020, 220(9): 164869.
- [47] Liu X, Tim M, Chris S, et al. Wavefront prediction using artificial neural networks for open-loop adaptive optics[J]. *Monthly Notices*, 2020, 496(1): 456-464.
- [48] Wu J, Tang J, Zhang M M, et al. PredictionNet: a long short-term memory-based attention network for atmospheric turbulence prediction in adaptive optics[J]. *Applied Optics*, 2022, 61(13): 3687-3694.
- [49] Wang N, Zhu L C, Ma S, et al. Deep learning-based prediction algorithm on atmospheric turbulence-induced wavefront for adaptive optics[J]. *IEEE Photonics Journal*, 2022, 14(5): 8554310.
- [50] Primmerman C A, Price T R, Humphreys R A, et al. Atmospheric-compensation experiments in strong-scintillation conditions[J]. *Applied Optics*, 1995, 34(12): 2081-2088.
- [51] Su C X, Dong L Z, Lai B H, et al. Adaptive beam clean-up of high power slab lasers using least-squares wavefront reconstruction algorithm with performance-based filtering[J]. *Optics Communications*, 2021, 490: 126886.
- [52] 王小林, 王三宏, 周朴, 等. SPGD算法光束净化中光强起伏对校正效果的影响研究[J]. *光学学报*, 2010, 30(5): 1396-1401.  
Wang X L, Wang S H, (Piao Z, et al. Investigation on influence of laser intensity fluctuation on beam cleanup system based on stochastic parallel gradient descent algorithm[J]. *Acta Optica Sinica*, 2010, 30(5): 1396-1401.
- [53] 马士青, 杨平, 赖柏衡, 等. 基于高效随机并行梯度下降算法的板条激光光束净化[J]. *中国激光*, 2020, 47(8): 0805001.  
Ma S Q, Yang P, Lai B H, et al. Slab laser beam cleanup based on efficient stochastic parallel gradient descent algorithm[J]. *Chinese Journal of Lasers*, 2020, 47(8): 0805001.
- [54] 刘武杰, 元秀华, 周泽宇, 等. 混合模型算法在无波前传感自适应光学中的应用[J]. *光电工程*, 2022, 49(12): 220020.  
Liu W J, Yuan X H, Zhou Z Y, et al. Application of hybrid modal algorithm in wavefront sensorless adaptive optics[J]. *Opto-Electronic Engineering*, 2022, 49(12): 220020.
- [55] 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): 274-279.
- [56] Gonsalves R A. Phase retrieval and diversity in adaptive optics[J]. *Optical Engineering*, 1982, 21(5): 829-832.
- [57] 孔庆峰. 基于单帧焦面图像的波前相位反演方法研究[D]. 成都: 电子科技大学, 2019.  
Kong Q F. Research on wavefront phase inversion method based on single focal plane image[D]. Chengdu: University of Electronic Science and Technology of China, 2019.
- [58] Ju G H, Qi X, Ma H C, et al. Feature-based phase retrieval wavefront sensing approach using machine learning[J]. *Optics Express*, 2018, 26(24): 31767-31783.
- [59] Ma H M, Liu H Q, Qiao Y, et al. Numerical study of adaptive optics compensation based on Convolutional Neural Networks[J]. *Optics Communications*, 2019, 433: 283-289.
- [60] 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(8): 081103.  
Ma H M, Jiao J, Qiao Y, et al. Wavefront restoration method based on light intensity image deep learning[J]. *Laser & Optoelectronics Progress*, 2020, 57(8): 081103.
- [61] Guo H Y, Xu Y J, Li Q, et al. Improved machine learning approach for wavefront sensing[J]. *Sensors*, 2019, 19(16): 3533.
- [62] Wu Y, Guo Y M, Bao H, et al. Sub-millisecond phase retrieval for phase-diversity wavefront sensor[J]. *Sensors*, 2020, 20(17): 4877.
- [63] Paine S W, Fienup J R. Machine learning for improved image-based wavefront sensing[J]. *Optics Letters*, 2018, 43(6): 1235-1238.
- [64] Nishizaki Y, Valdivia M, Horisaki R, et al. Deep learning wavefront sensing[J]. *Optics Express*, 2019, 27(1): 240-251.
- [65] Tian Q H, Lu C D, Liu B, et al. DNN-based aberration correction in a wavefront sensorless adaptive optics system[J]. *Optics Express*, 2019, 27(8): 10765-10776.
- [66] Qiu X J, Cheng T, Kong L X, et al. A single far-field deep learning adaptive optics system based on four-quadrant discrete phase modulation[J]. *Sensors*, 2020, 20(18): 5106.
- [67] Wang M H, Yuan X H, Guo W. Single-shot wavefront sensing with deep neural networks for free-space optical communications [J]. *Optics Express*, 2021, 29(3): 3465-3478.
- [68] Xu Z X, Yang P, Hu K, et al. Deep learning control model for adaptive optics systems[J]. *Applied Optics*, 2019, 58(8): 1998-2009.
- [69] 许振兴, 杨平, 程涛, 等. 自适应光学系统的自学习控制模型及其验证[J]. *中国激光*, 2020, 47(1): 0105001.  
Xu Z X, Yang P, Cheng T, et al. Self-learning control model for adaptive optics systems and experimental verification[J]. *Chinese*

- Journal of Lasers, 2020, 47(1): 0105001.
- [70] 许振兴, 杨平, 程涛, 等. 基于远场指标梯度的自学习波前控制模型[J]. 中国激光, 2020, 47(4): 0405001.  
Xu Z X, Yang P, Cheng T, et al. Self-learning wavefront control model based on far-field index gradient[J]. Chinese Journal of Lasers, 2020, 47(4): 0405001.
- [71] Hu K, Xu Z X, Yang W, et al. Build the structure of WFSless AO system through deep reinforcement learning[J]. IEEE Photonics Technology Letters, 2018, 30(23): 2033-2036.
- [72] 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.
- [73] Wen L H, Ping Y, Yang K J, et al. Synchronous model-based approach for wavefront sensorless adaptive optics system[J]. Optics Express, 2017, 25(17): 20584-20597.
- [74] Landman R, Haffert S Y, Radhakrishnan V M, et al. Self-optimizing adaptive optics control with reinforcement learning[J]. Proceedings of SPIE, 2020, 11448: 1144849.
- [75] Durech E, Newberry W, Franke J, et al. Wavefront sensor-less adaptive optics using deep reinforcement learning[J]. Biomedical Optics Express, 2021, 12(9): 5423-5438.
- [76] Jalo N, Chang R, Markus K, et al. Adaptive optics control using model-based reinforcement learning[J]. Optics Express, 2021, 29(10): 15327-15344.
- [77] Nousiainen J, Rajani C, Kasper M, et al. Towards on-sky adaptive optics control using reinforcement learning[EB/OL]. (2022-08-09)[2023-01-06]. <https://arxiv.org/abs/2205.07554>.
- [78] Pou B, Ferreira F, Quinones E, et al. Adaptive optics control with multi-agent model-free reinforcement learning[J]. Optics Express, 2022, 30(2): 2991-3015.

## Research Progress of Laser Adaptive Optics Based on Machine Learning

Cheng Tao<sup>1</sup>, Guo Sicheng<sup>1,2</sup>, Wang Ning<sup>1,2</sup>, Zhao Mengmeng<sup>1,2</sup>, Wang Shuai<sup>1\*\*</sup>, Yang Ping<sup>1\*</sup>

<sup>1</sup>Key Laboratory on Adaptive Optics, Institute of Optics and Electronics, Chinese Academy of Sciences, Chengdu 610209, Sichuan, China;

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

### Abstract

**Significance** High power laser is an important application field of adaptive optics, and controlling a high-power laser system to achieve high-beam-quality laser output is an important goal of laser adaptive optics technology. To achieve high beam quality throughout the transmission of high-power laser to the target, adaptive optics must simultaneously correct the aberration of the high-power laser source, thermal effect and optical element aberration in the transmission channel, and atmospheric turbulence. Currently, adaptive optics has enabled the output beam of multimode high-power lasers to achieve near-diffraction limit beam quality; for example, the beam quality of a 1-MW DF chemical laser reaches twice the diffraction limit, and the average beam quality of a 105-kW solid-state laser is about 2.9. However, when promoting the practical application of high-power lasers with different systems in different working scenarios, adaptive optics still faces the following problems: 1) The near-field intensity distribution of high-power lasers is uneven, and there are large gradient aberrations locally. 2) In the case of strong turbulence transmission, the wavefront aberration has high spatio-temporal frequency characteristics, and some information of the wavefront is dynamically missing. 3) The signal-to-noise ratio and spatial resolution of the wavefront detector will be low due to the weak light and strong noise background of the dim target. 4) Platform vibration, temperature change, and other environmental factors will cause variation of the system model parameters. To solve these problems, researchers have developed a laser adaptive optics technique based on machine learning. This paper reviews the current intelligent development of laser adaptive optics based on machine learning in wavefront restoration, wavefront prediction, phase inversion, and wavefront correction, and the potential and challenges of current research methods used in the field of high-power laser are discussed.

**Progress** In this paper, the research progress of laser adaptive optics techniques based on machine learning are summarized from four aspects: wavefront reconstruction, wavefront prediction, phase inversion, and wavefront correction. Further, the potential and challenges of the current methods in the application of high-power laser are discussed. In terms of wavefront reconstruction of a Hartmann sensor, this paper introduces the improvement of a deep learning method based on the calculation process of wavefront reconstruction, such as centroid extraction, aberration coefficient calculated from wavefront slope, wavefront phase calculated from spot array image, and full aperture wavefront slope estimation calculated from partial wavefront slope information. Finally, high-precision centroid calculation under low signal-to-noise ratio is realized, as shown in Table 1. High spatial frequency aberration restoration under low spatial resolution is shown in Fig. 4. Full-aperture wavefront information presumption under light deficiency is shown in Fig. 5. In terms of wavefront prediction, a variety of wavefront prediction methods based on the improved long short term memory (LSTM) network are introduced to achieve high-precision wavefront prediction under different turbulence intensities and delay periods, as shown in Figs. 7 and 8, and the consistent prediction accuracy is still available when some parameters of the atmospheric turbulence model are changed, as shown in Fig. 6. In terms of phase inversion, deep learning-based phase inversion methods are introduced from two pairs of focal and defocusing far field images as well as a single frame image modulated from far-field images, which realizes the direct transformation of far field image information to wavefront information, as shown in Figs. 9 and 12; further, this avoids the iterative process in wavefront sensorless adaptive optics technology. In terms of wavefront correction, the dynamic description of the deep learning network for the local response relationship of the adaptive optical system and dynamic

solution of the system control strategy based on reinforcement learning are introduced, as shown in Figs. 15 and 17, respectively, realizing the self-identification and self-adaptive adjustment of the adaptive optical system when the system input and model parameters are changed.

**Conclusions and Prospects** Machine learning has demonstrated excellent potential in solving multiple problems faced by high-power laser systems in laser adaptive optics technology. Its contributions can be summarized as follows: 1) Achieving high-precision wavefront detection under weak targets, strong light background, and strong turbulence effects. 2) Breaking the limitation of system delay on the control bandwidth of the adaptive optical system and improving the correction accuracy of the system for high spatio-temporal frequency aberrations. 3) Avoiding the iterative process and improving the control bandwidth of the wavefront sensorless adaptive optics system. 4) Eliminating the influence of high-power laser applied in different scenarios on the correction performance of the adaptive optical system and improving the adaptive ability of the optical system in different maneuvering platforms and working environments.

However, the practical application of current research methods in high-power laser systems still has the following problems to be studied: 1) Training sample collection. The output time of high-power lasers is limited, and its thermal effect aberration characteristics are different from atmospheric turbulence aberration characteristics. It is difficult to collect or generate training samples conforming to the characteristics of high-power laser thermal effect aberration, and under the condition of high-power laser output or strong background noise, its corresponding real wavefront aberration is difficult to obtain. 2) Training environment and duration. Compared with the astronomical observation, it is difficult for high-power laser to provide the interactive environment required by machine learning. Therefore, an interactive environment that can simulate the states of high-power laser systems should be established with the reference light. In addition, the laser beacon irradiation time is limited, and characteristics of atmospheric turbulence aberration change with time, so it is urgent for machine learning methods to have a short training time. 3) Multi-method fusion. There are many problems in the application of high-power laser, such as strong background noise, dynamic light deficiency, and high spatio-temporal aberration. Taking wavefront reconstruction as an example, in order to realize the restoration of high spatial frequency aberration under complex conditions while ensuring the accuracy and speed of wavefront restoration, the existing network methods need to be integrated and optimized.

**Key words** laser optics; adaptive optics; high power laser; machine learning