



·激光大气传输技术·综述·

## 基于深度学习的无波前探测自适应光学系统研究进展

张之光, 杨慧珍, 刘金龙, 李松恒, 苏杭, 罗宇湘, 魏谢文

(江苏海洋大学 电子工程学院, 江苏 连云港 222005)

**摘 要:** 近年来自适应光学(AO)系统向着小型化和低成本化趋势发展,无波前探测自适应光学(WFSless AO)系统由于结构简单、应用范围广,成为目前相关领域的研究热点。硬件环境确定后,系统控制算法决定了 WFSless AO 系统的校正效果和系统收敛速度。新兴的深度学习及人工神经网络为 WFSless AO 系统控制算法注入了新的活力,进一步推动了 WFSless AO 系统的理论发展与应用发展。在回顾前期 WFSless AO 系统控制算法的基础上,全面介绍了近年来卷积神经网络(CNN)、长短期记忆神经网络(LSTM)、深度强化学习在 WFSless AO 系统控制中的应用,并对 WFSless AO 系统中各种深度学习模型的特点进行了总结。概述了 WFSless AO 技术在天文观测、显微成像、眼底成像、激光通信等领域的应用。

**关键词:** 自适应光学; 无波前探测; 深度学习; 人工神经网络

中图分类号: TN929.12

文献标志码: A

doi: 10.11884/HPLPB202133.210295

## Research progress in deep learning based WFSless adaptive optics system

Zhang Zhiguang, Yang Huizhen, Liu Jinlong, Li Songheng, Su Hang, Luo Yuxiang, Wei Xiewen

(School of Electrical Engineering, Jiangsu Ocean University, Lianyungang, 222005, China)

**Abstract:** In recent years, Adaptive Optics (AO) system is developing towards miniaturization and low cost. Because of its simple structure and wide application range, wavefront sensorless (WFSless) AO system has become a research hotspot in related fields. Under the condition that the hardware environment is determined, the system control algorithm determines the correction effect and convergence speed of WFSless AO system. The emerging deep learning and artificial neural network have injected new vitality into the control algorithms of WFSless AO system, and further promoted the theoretical and practical development of WFSless AO. On the basis of summarizing the previous control algorithms of WFSless AO system, the applications of convolution neural network (CNN), long-term memory neural network (LSTM) and deep reinforcement learning in WFSless AO system control in recent years are comprehensively introduced, and characteristics of various deep learning models in WFSless AO system are summarized. Applications of WFSless AO system in astronomical observation, microscopy, ophthalmoscopy, laser telecommunication and other fields are outlined.

**Key words:** adaptive optics; wavefront sensorless; deep learning; artificial neural networks

自适应光学(AO)是一种通过校正入射波前像差来改善光学系统性能的技术<sup>[1]</sup>。按照系统结构大致可以分为两类:常规 AO 系统和无波前探测(WFSless)AO 系统。常规 AO 系统包括波前传感器(WFS)、波前控制器和波前校正器三部分,其中 WFS 用来探测入射波前,波前控制器根据控制算法将波前感知信息转换为波前校正器(如变形镜 DM、空间光调制器 SLM)所需要的控制信号,波前校正器补偿波前畸变。常规 AO 系统发展相对成熟,已在天文观测等领域得到成功应用<sup>[2]</sup>。但在传输路径上湍流较强、水平传输距离较长、暗弱目标以及显微成像等场景中,常规 AO 系统有其局限性,WFSless AO 技术为这些场景中的应用提供了可能。WFSless AO 系统不再需要波前探测环节,直接利用图像传感器获得的光强信息设计控制算法,产生波前校正器所需要的控制信号,实现波前畸变

\* 收稿日期:2021-07-19; 修订日期:2021-08-11

基金项目:国家自然科学基金项目(11573011);江苏省“六大人才高峰”高层次人才项目(KTHY-058);江苏省“333”高层次人才培养项目(BRA2019244)

作者简介:张之光(1988—),男,讲师,博士,主要从事自适应光学与激光雷达研究。

通信作者:杨慧珍(1973—),女,教授,博士,主要从事自适应光学技术及其应用方面的研究。

校正。WFSless AO 系统具有结构简单、可靠性高、体积小等特点。

按照控制算法的不同, WFSless AO 系统大致可分为无模型优化系统<sup>[3,4]</sup>和有模型优化系统<sup>[5,6]</sup>两大类。无模型优化系统直接采用各种盲优化算法作为系统控制算法, 如随机并行梯度下降 (SPGD)<sup>[7]</sup>、模拟退火<sup>[8]</sup>、遗传算法<sup>[9]</sup>等。该类控制算法收敛速度较慢<sup>[10]</sup>, 难以应用于实时像差校正系统。有模型优化系统, 又称为基于模型的 WFSless AO 系统, 通常基于某种原理建立系统模型, 进而确定相应的控制算法。与无模型优化系统相比, 有模型优化系统由于利用了模型信息, 系统收敛速度相对较快。该类算法大致可以分为模式法<sup>[6,11-13]</sup>和非线性优化方法<sup>[14-16]</sup>, 模式法在校正不同大小的像差时需要事先定义不同类型的基函数; 非线性优化算法首先建立表征系统输入输出模型的非线性方程, 然后基于该方程多次读取强度信息, 再利用非线性最小二乘法求解。该类系统在波前校正之前需要清除系统像差。以上两类方法在实际应用时实现手段相对复杂。

近年来随着人工智能领域的发展, 深度学习及神经网络被引入 WFSless AO 系统用以校正波前像差。基于深度学习的 WFSless AO 系统控制算法一般先从光强图像反演出波前像差或是其 Zernike 系数, 再将上述信息转化为波前校正器所需驱动信号, 实现波前校正。自 1990 年感知机首次应用于 AO 以来, 神经网络技术经历了长足的发展。近年来深度学习及神经网络被广泛应用于 WFSless AO 领域, 推动了 WFSless AO 系统理论及应用的发展, 取得了一些有代表性的成果。下文首先介绍基于卷积神经网络 (CNN)、长短期记忆神经网络 (LSTM)、深度强化学习的 WFSless AO 系统, 然后概述 WFSless AO 系统在天文观测、显微成像、眼底成像、激光通信等领域的应用, 最后对全文进行总结。

## 1 基于深度学习的无波前探测自适应光学系统波前像差校正方法

1990 年, Angel 与 Sandler 等<sup>[17]</sup>发表于《Nature》的论文最早展示了神经网络可以用于获取大气湍流导致的波前畸变, 并给出了针对亚利桑那州多镜面阵列望远镜的数值仿真结果。该神经网络为感知机类型, 仅包含一个隐藏层。通过参考星或者人工导星聚焦与离焦的两幅图像来估计相位。应用该模型后, 波前均方差从  $2.27 \text{ rad}^2$  降低到  $0.41 \text{ rad}^2$ 。

Sandler<sup>[18]</sup>于 1991 年发表在《Nature》的另一篇论文展示了用于相位复原的感知机式人工神经网络, 如图 1 所示。该感知机输入层节点数为  $16 \times 16 \times 2 = 512$ , 包含一个隐藏层, 输出层为 10 阶 Zernike 系数。在美国新墨西哥州地基 1.5 m 单镜天文望远镜实测的织女星图像上应用该模型, 波前均方差从  $1.77 \text{ rad}^2$  降低到  $0.78 \text{ rad}^2$ 。该神经网络还在 1993 年被用于估计哈勃空间望远镜的相位畸变<sup>[19]</sup>。

在 Angel 和 Sandler 之前的 WFSless AO 系统研究中, 神经网络仅用于加速现有的算法。Sandler 和 Angel 率先将运算全部交给神经网络, 实现从图像到波前的映射。随着半导体行业的飞速发展和算力的显著提升, 结构简单的感知机逐渐淡出视野, 深度卷积神经网络 (CNN)、长短期记忆神经网络 (LSTM)、深度强化学习等更加复杂的人工神经网络被应用于 WFSless AO 系统控制, 实现波前像差校正。

### 1.1 卷积神经网络 (CNN)

CNN 比感知机更适于处理图像类任务, 因为它针对图像的二维像素区域进行学习。在波前畸变较大的情况下, 对于基于梯度的优化算法而言, 当初始猜测相位和真实相位偏差大时优化算法容易不收敛, 为此需要更准确的初始猜测相位。2018 年, 美国 Rochester 大学光学研究所的 Paine 和 Fienup<sup>[20]</sup>提出采用 CNN 来获取比随机方式更好的波前初始猜测相位。该神经网络来自于 Google 知名的 Inceptionv3 模型<sup>[21]</sup>, 经过修改用于回归分析, 如图 2 所示。模型的输入为 PSF 图像, 输出为 Zernike 系数。根据 Zernike 系数生成相位, 作为 Broyden-Fletcher-Goldfarb-Shanno 迭代优化算法<sup>[22]</sup>的初始猜测相位。以 CNN 推测迭代优化算法初始相位的方案显著减小了迭代不收敛的可能性。另一方面, 该方法存在的缺点是计算速度慢。部署于桌面电脑时, 对于较大尺寸的目标图像, CNN 推测初始猜测相位耗时 0.2 s, 迭代优化算法平均耗时 16 s, 难以应用于实时波前感知。

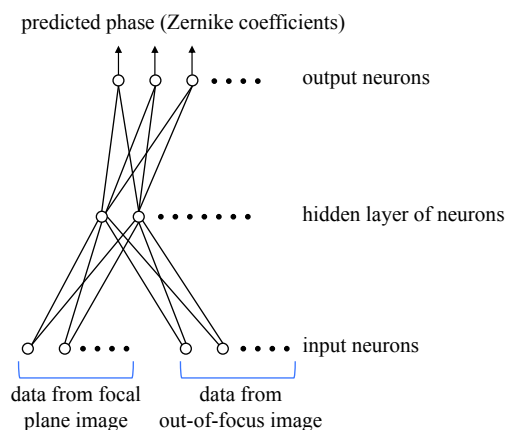


Fig. 1 Perceptron artificial neural network for phase retrieval<sup>[18]</sup>

图 1 用于相位复原的感知机式人工神经网络<sup>[18]</sup>



 Fig. 2 Modified Inception v3CNN model for predicting Zernike coefficients<sup>[20]</sup>

 图 2 用于推测 Zernike 系数的修改版 Inception v3CNN 模型<sup>[20]</sup>

日本大阪大学的 Nishizaki<sup>[23]</sup> 等提出采用当时领先的 Xception<sup>[24]</sup> CNN 模型直接从单幅光强图像估计 Zernike 系数, 不经任何迭代优化处理。鉴于图像传感器动态范围有限, Nishizaki 还提出先对光强图像进行预处理, 使得目标能量在图像传感器上展开, 以此让图像传感器上更多的像素单元采集到信息。预处理方法包括: 过曝、离焦和散射, 对三种预处理方法分别进行了实验验证。Xception 神经网络采用 Keras 深度学习 API 实现, 模型输入为  $256 \times 256$  像素图像, 模型输出为 32 阶 Zernike 系数。训练数据集规模为  $10^5$ , 采用 Adam 优化算法<sup>[25]</sup> 对模型进行训练。实验发现, 光强图像经过预处理后, 估计出的 Zernike 系数与真实值的吻合度明显提升。未经预处理与经过曝预处理时得到的 Zernike 系数分别如图 3、图 4 所示。采用三种不同预处理方法估计出的 Zernike 系数准确度见表 1, 由定量数据可知采用过曝、离焦、散射任一方法预处理后, Zernike 系数估计准确度显著提升。预处理方法对点目标与扩展目标均适用。



 Fig. 3 Zernike coefficients predicting results of focused target<sup>[23]</sup>


 图 3 聚焦点目标的 Zernike 系数估计结果<sup>[23]</sup>

 Fig. 4 Zernike coefficients predicting results of overexposed target<sup>[23]</sup>

 图 4 经过曝预处理点目标的 Zernike 系数估计结果<sup>[23]</sup>

 表 1 采用过曝、离焦、散射预处理后估计出的 Zernike 系数准确度 (均方差)<sup>[23]</sup>

 Table 1 Accuracy of Zernike coefficients (RMS) with overexposure, defocus and scattering preprocessing<sup>[23]</sup>

	Zernike coefficients			
	in-focus	overexposure	defocus	scatter
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

北京邮电大学的 Qinghua Tian 等<sup>[26]</sup> 针对当前 WFSless AO 无模型优化算法迭代次数过多造成的延迟问题, 采用深度 CNN 获取波前畸变并进行补偿。系统构成如图 5 所示, 主要包括变形镜、CCD、控制器三部分。其中控制器的核心为 CNN 模型, 模型输入为单幅光强图像, 输出为 Zernike 系数, 可表示为

$$f: I \rightarrow \mathbf{a} \quad (1)$$




Fig. 5 WFSless system architecture<sup>[26]</sup>  
图 5 WFSless AO 系统结构<sup>[26]</sup>

其中  $f$  代表神经网络模型,  $I$  为光强图像,  $a$  为 Zernike 系数向量, 最终根据 Zernike 系数生成变形镜的控制信号<sup>[27]</sup>。采用的 CNN 包含 7 个卷积层和 3 个全连接层, 如图 6 所示。尽管神经网络在训练时耗费运算资源, 一旦完成训练, 应用神经网络进行波前畸变校正只涉及推测模型输出和 Zernike 系数转换成控制信号所耗费的时间。对于不同程度的湍流采用相同的 CNN, 延迟时间均为 2 ms。相较于 SPGD, CNN 在系统延迟上实现了两个数量级的改善。

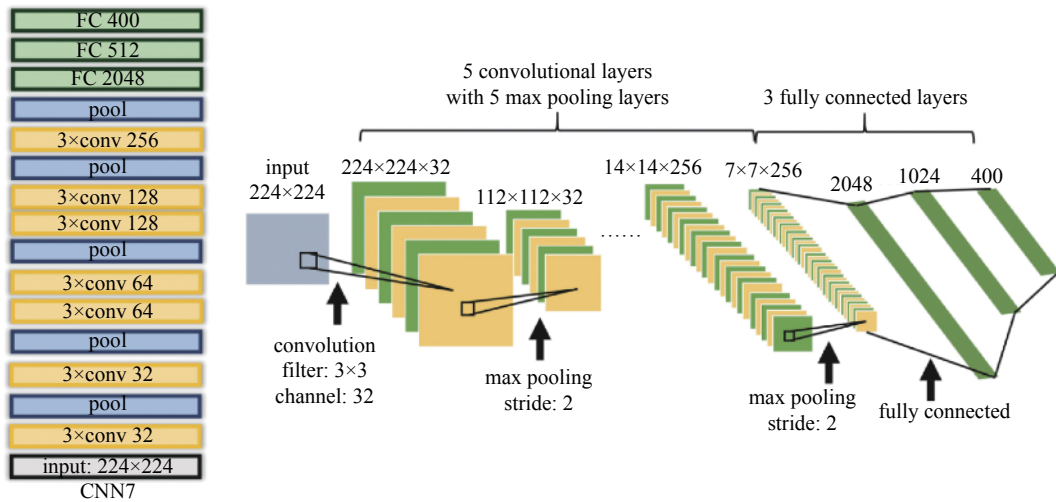


Fig. 6 Architecture of CNN<sup>[26]</sup>  
图 6 CNN 结构<sup>[26]</sup>

受相位差异<sup>[28]</sup>方法启发, 安徽农业大学的马慧敏等<sup>[29]</sup>将对聚焦与离焦光强图像作为训练数据, 以波前像差的 Zernike 系数作为标签, 训练了用于 WFSless AO 系统控制的 CNN。该模型的数据流如图 7 所示, 训练阶段输入数据包括成对的光强图像和相应的 Zernike 系数, 推测阶段根据一对测试图像生成相应的 Zernike 系数, 间接得到

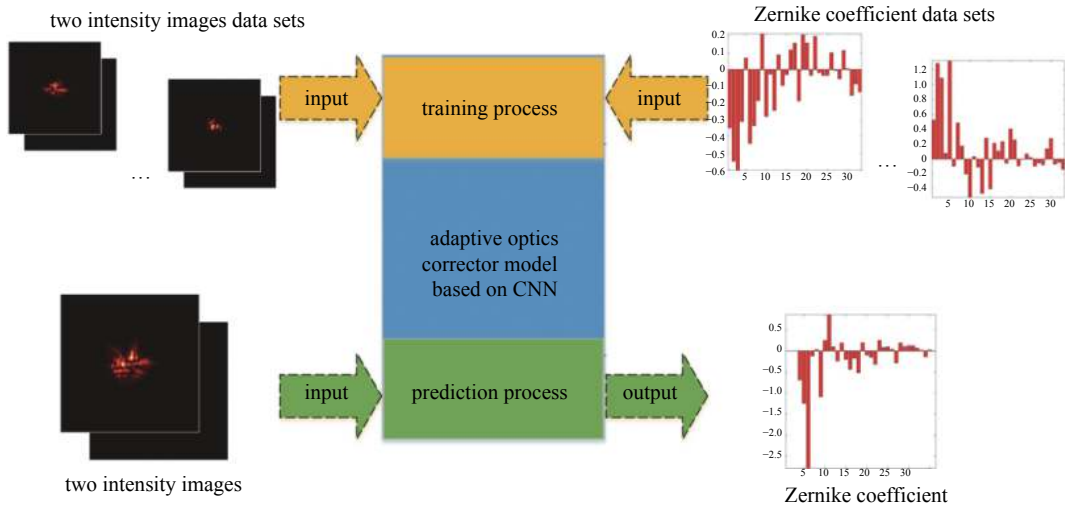


Fig. 7 Data flow of training and predictions<sup>[29]</sup>

图 7 训练与推测过程的数据流<sup>[29]</sup>

波前像差。成对光强图像到 Zernike 系数的映射模型可以表示为

$$f : (I_1, I_2) \rightarrow \mathbf{a} \quad (2)$$

所采用的 CNN 模型由业界知名的 AlexNet<sup>[30]</sup> 修改而成，输入层被改为 224×224×2 的尺寸，其中 224×224 为单幅光强图像的像素数，2 倍代表聚焦面和离焦面的两幅图像。训练数据集的规模为 15000 样本，标签为 35 阶 Zernike 系数向量。CNN 模型采用 Google TensorFlow 框架构建，部署于 Core i9 CPU 桌面电脑，15000 样本的训练时长为 69.8 h。通过推测的 Zernike 系数实现相位补偿，推测阶段平均耗时 160 ms。仿真了不同湍流程度下 ( $D/r_0 = 1 \sim 15$ ) 经过 CNN 补偿和未经补偿时的残留波前，如图 8 所示，经过相位补偿后波前得到了明显的改善。

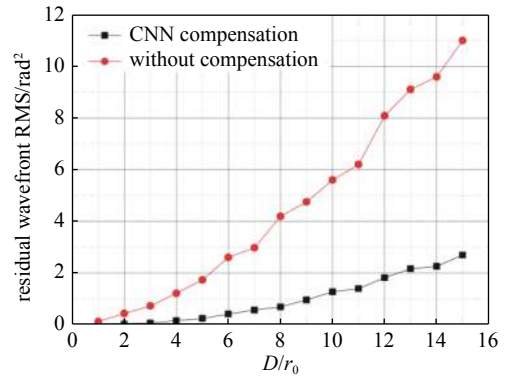


Fig. 8 Residual wavefront RMS with and without compensation under different turbulence levels<sup>[29]</sup>

图 8 不同湍流程度下有无补偿时的残留波前方差<sup>[29]</sup>

马慧敏等<sup>[31]</sup> 还探讨了训练数据的一致性对波前复原性能的影响。仿真了三种不同湍流强度下的训练数据集，如表 2 所示。用三种训练数据集分别训练 CNN，得到三个不同参数的模型。针对这三个模型，用不同湍流强度的数据进行测试，推测 Zernike 系数，结果如图 9 所示。仿真结果表明各模型应用于与训练时相仿的湍流条件时能够获得最优准确度。因此在实际应用中如果能够对大气湍流水平有预判，则采用相应湍流条件训练的模型能够获得更优的推测准确度。

表 2 三种不同湍流强度数据集<sup>[31]</sup>

Table 2 Dataset of three different turbulence levels<sup>[31]</sup>

dataset No.	$D/r_0$	training dataset			test dataset		
		$D/r_0$ interval	data volume/interval	total data volume	$D/r_0$ interval	data volume/interval	total data volume
1	5	—	100	15000	—	10	1500
2	15	—	100	15000	—	10	1500
3	1-15	1	100	15000	1	10	1500

中国科学院光电技术研究所的 Guo 等<sup>[32]</sup> 通过加入解卷积层改造了 VGG<sup>[33]</sup> CNN 网络模型，采用聚焦面与离焦面上成对的 PSF 图像直接预测波前相位图，该 CNN 被命名为 De-VGG 网络。网络包含 5 个卷积层、3 个解卷积层、1 个 softmax 输出层。网络输入为 224×224 像素的 PSF 图像，输出为 135×135 像素的波前相位图。以仿真和实验分别对 De-VGG 网络进行了验证。仿真表明，在  $D/r_0 = 20$  湍流强度下，波前像差均方根为  $0.1307\lambda$  (表 3)，比见刊

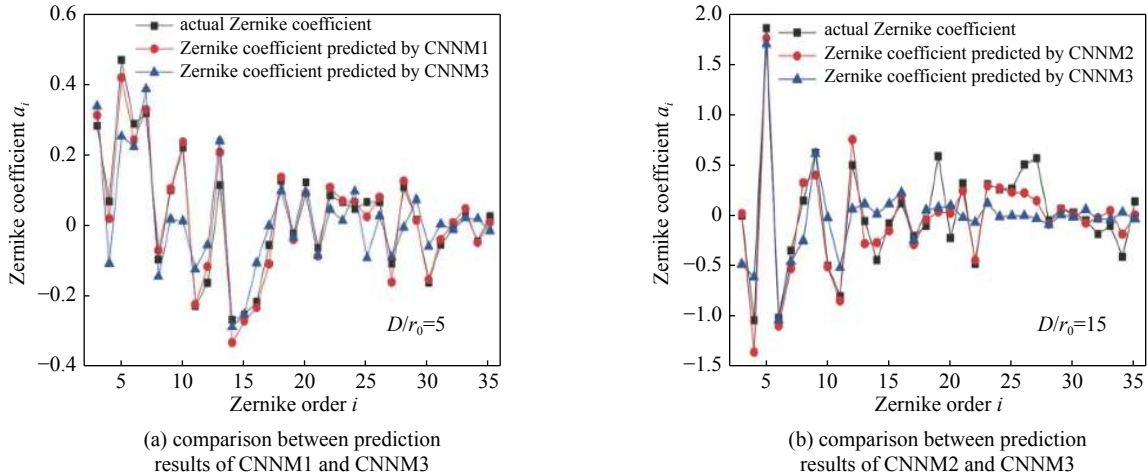


Fig. 9 Zernike coefficients prediction results by models trained with dataset of different turbulence levels<sup>[31]</sup>

图 9 以不同湍流强度数据训练得到的模型推测 Zernike 系数<sup>[31]</sup>

表 3 仿真不同湍流条件时波前复原误差 ( NPMS: 归一化像素均方 RMS: 均方根 )<sup>[32]</sup>

Table 3 Simulation results of wavefront restoration error under different turbulence levels (NPMS: Normalized Pixel Mean Square; RMS: Root Mean Square)<sup>[32]</sup>

$D/r_0$	NPMS	RMS/ $\lambda$
20	0.006 7	0.130 7
15	0.004 1	0.090 9
10	0.002 9	0.071 8
6	0.002 5	0.070 3

时其他人工神经网络性能更优。 $D/r_0 = 15$ 湍流强度时波前像差均方根为  $0.0909\lambda$ ,  $D/r_0 = 10$ 时波前像差均方根为  $0.0718\lambda$ , 在弱湍流和中等程度湍流条件下有实用价值。搭建了实验平台, 通过实验得到  $D/r_0 = 20$ 湍流强度下波前像差均方根为  $0.1304\lambda$ (表 4), 与仿真结果高度吻合, 强湍流条件下 De-VGG 模型仍然能够适用。

表 4 实验得到波前复原误差与运算时间 ( NPMS: 归一化像素均方 RMS: 均方根 )<sup>[32]</sup>

Table 4 Wavefront restoration error and time consumption of experiments (NPMS: Normalized Pixel Mean Square; RMS: Root Mean Square)<sup>[32]</sup>

$D/r_0$	NPMS	RMS/ $\lambda$	running time/ms
20	0.006 6	0.130 4	~12

中国科学院光电技术研究所的 Wu 等<sup>[34]</sup>提出了一种实时波前感知方法, 使用相位差异卷积神经网络 (PD-CNN)建立了从光强图像到误差相位的映射。采用 TensorRT<sup>[35]</sup>对模型进行了优化, 实现了亚毫秒级的相位复原时间。TensorRT 是 NVIDIA 公司推出的深度学习推测优化器与运行环境, 适用于 NVIDIA 的 GPU 产品。TensorRT 通过数据精度重校、网络层与张量融合、动态张量内存、并行化等策略实现低延迟、高吞吐的深度学习推测应用, 如图 10 所示。Wu 等提出的 PD-CNN 来自于 LeNet-5 模型, 包含 3 个卷积层与 2 个全连接层。模型输入为成对的聚焦与离焦 PSF 图像, 尺寸  $128 \times 128$ ; 输出为 13 阶 Zernike 系数。以往用于 WFSless AO 的深度学习模型推测相位耗时 10 ms 到若干秒不等, Wu 则通过 TensorRT 将相位复原时间缩短为 0.5 ms 左右, 显著提升了模型的实时性。为了展示模型的性能, 进行了如下方面的对比: (1) PD-CNN 与 Xception<sup>[24]</sup>模型推测时间对比。(2) 经 TensorRT 优化前后的推测时间对比。(3) 只使用聚焦图像、只使用离焦图像、使用成对聚焦离焦图像训练模型的推测准确度对比。结果显示, 在未经 TensorRT 优化时, PD-CNN 模型的推测时间约为 2 ms, 是 Xception 推测时间 10 ms 的 1/5 左右, 如表 5 所示。使用 TensorRT 对模型进行优化后, 采用不同类型输入图像的模型的推测速度均获得了约 5 倍的提升, 推测时间从 2.5 ms 左右缩减为 0.5 ms 量级, 如表 6 所示。采用成对聚焦与离焦图像进行训练时获得的模型推测准确度最高。

针对波前探测 CNN 模型训练时间长、推测延迟大的问题, Vera 等<sup>[36]</sup>详细分析了减小训练时间与推测时间的

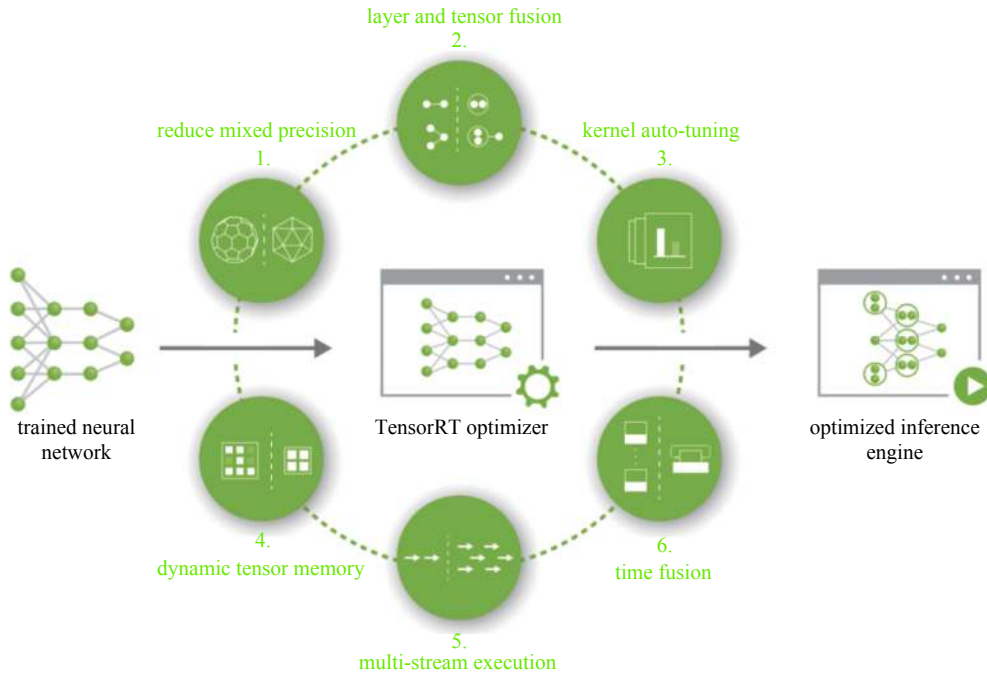


Fig. 10 Trained neural network is optimized by TensorRT to build the inference engine for implementation<sup>[35]</sup>

图 10 训练后的神经网络经 TensorRT 优化生成用于部署的推测引擎<sup>[35]</sup>

表 5 PD-CNN 和 Xception 模型推测时间对比<sup>[34]</sup>

Table 5 Comparison of inference time of PD-CNN with that of Xception<sup>[34]</sup>

network	focal model/ms	defocused model/ms	PD model/ms
PD-CNN	2.2495	2.2989	2.5591
Xception	10.469	10.1108	10.469

表 6 经 TensorRT 优化前后的推测时间对比<sup>[34]</sup>

Table 6 Comparison of inference time with and without optimization by TensorRT<sup>[34]</sup>

model	before acceleration/ms	after acceleration/ms	acceleration ratio
focal model	2.2495	0.4678	4.8091
defocused model	2.2989	0.4406	5.2178
PD model	2.5591	0.4909	5.2135

方法。在此研究中, Vera 等提出了波前网络 WFNet<sup>[37]</sup>, 如图 11 所示。采用一维卷积核在水平方向与垂直方向提取特征, 减少了网络权重的数量, 由此减少模型训练与推测时间。模型的输入为单幅 PSF 图像, 输出为 Zernike 系数。与 De-VGG<sup>[32]</sup>、Xception<sup>[24]</sup> 网络相比, WFNet 更为紧凑与高效, 消耗更少的运算资源, 能够实现超过 1 kHz 的波

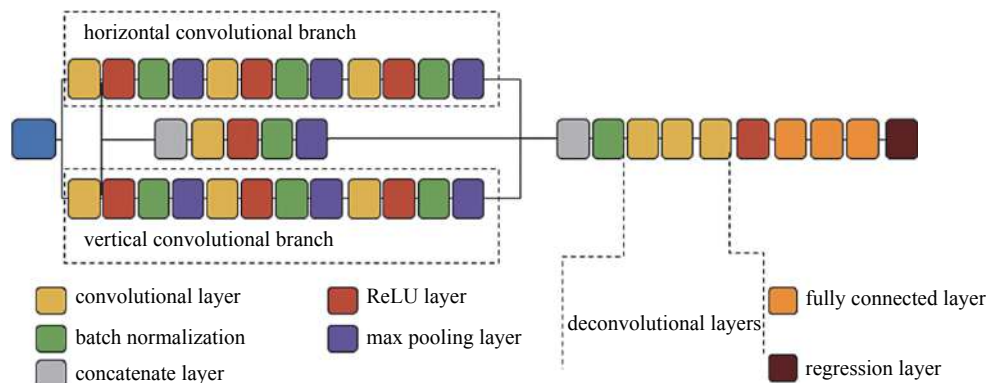


Fig. 11 Wavefront Net (WFNet)<sup>[36]</sup>

图 11 波前网络 (WFNet)<sup>[36]</sup>

前探测更新率,追踪湍流的动态变化。分析表明:(1)训练时间和推测时间与 Zernike 系数阶数无关,只依赖于图像尺寸。图像尺寸越大,训练与推测耗时越长。(2)采用更大尺寸图像能够获得更好的预测准确度。(3)对于确定尺寸的图像数据,过多阶 Zernike 系数会导致预测准确度降低。这是由于过多阶 Zernike 系数造成了过拟合,导致泛化能力减弱。合适的 Zernike 系数阶数与图像尺寸的选取带来模型实时性的提升。

西北工业大学的王凯强等<sup>[38]</sup>对比了直接预测相位和预测 Zernike 系数两种方案,相应地提出了两种神经网络结构并进行了实验验证。神经网络结构如图 12 所示,其构造受到 ResNet 残差网络<sup>[39]</sup>和 Inception 网络<sup>[21]</sup>启发。用于直接预测相位的人工神经网络(图 12 a)结构包含左侧编码路径、中间桥梁、右侧解码路径,编码路径和解码路径均包含残差模块(图 12 c)。用于预测 Zernike 系数的神经网络(图 12 b)由前述神经网络的编码路径加上全连接层构成。两个神经网络中相同结构的网络层参数相同。采用 Python 语言及 Pytorch 深度学习框架实现神经网络。通过仿真实验,发现图 12 a 直接预测相位的网络结构更适于控制空间光调制器,图 12 b 预测 Zernike 系数的网络结构更适于控制变形镜。搭建了实验系统对图 12 a 网络结构进行了实验验证,从第 500 帧开始采用神经网络预测的相位进行相位畸变校正,校正后相位标准差显著减小,波前更为平坦,如图 13 所示。

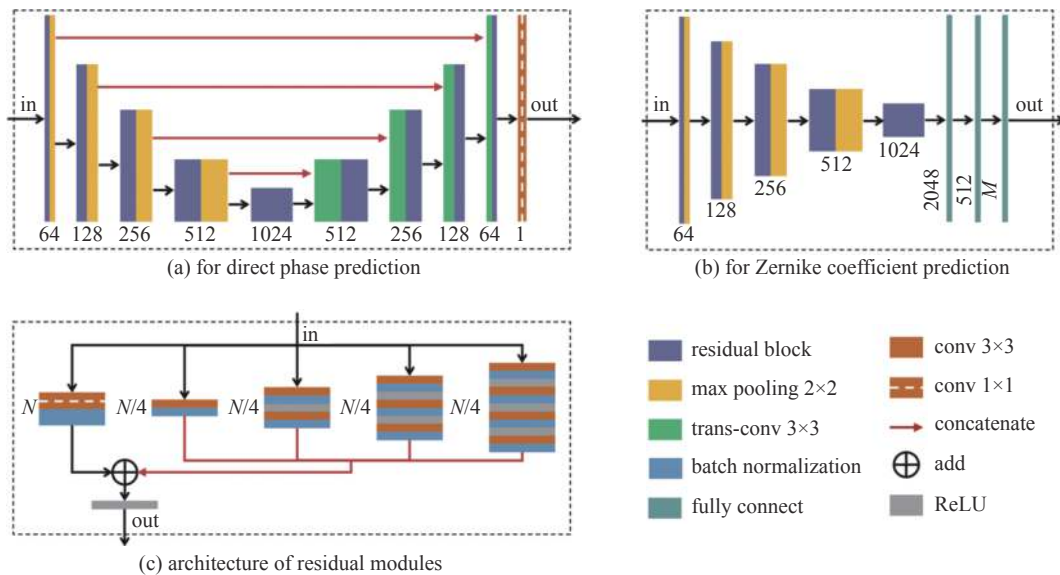


Fig. 12 CNN architecture<sup>[38]</sup>

图 12 CNN 结构<sup>[38]</sup>

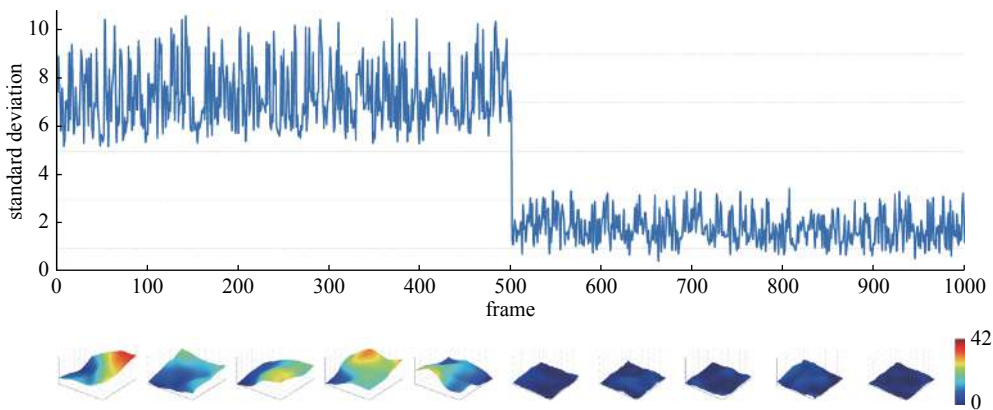


Fig. 13 Standard deviation of phase before and after phase aberration revision<sup>[38]</sup>

图 13 相位畸变校正前后的相位标准差<sup>[38]</sup>

## 1.2 长短期记忆神经网络 ( LSTM )

LSTM<sup>[40]</sup>是一种特殊的循环神经网络,主要用于解决长序列训练过程中的梯度消失和梯度爆炸问题。长春光机所的 Xin 等<sup>[41]</sup>提出一种同时适用于点目标和扩展目标的波前感知方法,该方法采用深度 LSTM。Xin 等首先在频域提取特征,该特征与目标本身无关,只与相位畸变有关。然后采用 LSTM 建立从所提取的频域特征图像到相位畸变的非线性映射。提取频域特征时用到成对的聚焦图像 $i_a$ 与离焦图像 $i_b$ ,通过如下方案提取特征 $f_0$ ,即



$$f_0 = \left\{ \mathcal{F}^{-1} \left\{ \frac{\mathcal{F}\{i_a\}}{\mathcal{F}\{i_b\}} \right\} \right\} \quad (3)$$

其中 $\mathcal{F}\{\cdot\}$ 为傅里叶变换,  $\mathcal{F}^{-1}\{i_a\}$ 为傅里叶逆变换。在相同相位畸变情况下提取的特征相同, 与目标形态无关, 因此该方法能够同时适用于点目标与扩展目标。值得注意的是, 特征图像 $f_0$ 的能量集中于中心区域, 因此还可进行剪裁, 仅保留中间部分图像作为 LSTM 的输入, 以此减小运算量。总体的波前感知流程如图 14 所示。首先从一对聚焦与离焦图像中提取特征图像, 然后将特征图像序列化, 将序列输入 LSTM 网络, 经由全连接层输出波前像差的第 2~9 阶 Zernike 系数。通过 Python 编程语言与 Keras 深度学习 API 进行了仿真。目标图像尺寸为  $64 \times 64$ , 提取特征后将特征图像剪裁为  $32 \times 32$ , 并将其序列化为 32 段。根据 LSTM 预测的 Zernike 系数进行图像复原的结果如图 15 所示, 各扩展目标场景均实现了有效的相位复原。

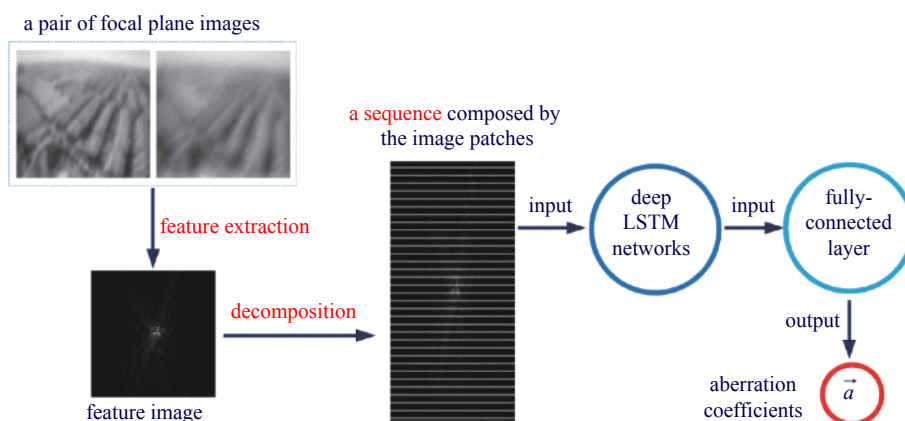


Fig. 14 An object irrelevant wavefront sensing scheme using LSTM neural network<sup>[41]</sup>

图 14 采用 LSTM 神经网络的与目标无关的波前感知方法流程图<sup>[41]</sup>




Fig. 15 Image restoration results based on wavefront error inferred by LSTM<sup>[41]</sup>

图 15 根据 LSTM 推测的波前像差进行图像复原仿真结果<sup>[41]</sup>

以上应用均为单一时刻的波前复原, LSTM 网络结构天然适合处理时间序列数据, 因此 LSTM 还可用于预测接下来时间帧变形镜或空间光调制器的控制信号, 实现未来时刻的波前预测。传统的预测控制算法采用卡尔曼滤波及其变体, 需要依赖物理模型。而 LSTM 能够用于变形镜的预测控制, 实现 AO 系统无物理模型的波前预测。LSTM 的采用赋予了预测器自主调节能力, 这在变化的湍流环境下至关重要。Durham 大学的 Liu 等<sup>[42]</sup>研究了 LSTM 的波前预测能力, 提出了一种非线性预测器, 根据过往观测的时间序列预测下一时间点的波前。晋中学院的 Chen<sup>[43]</sup>通过仿真验证了经由 LSTM 预测后斯特列尔比(SR)得到提升。加拿大多伦多大学的 Swanson 等<sup>[44]</sup>采用 OOMAO(面向对象的 MATLAB 自适应光学工具箱)软件仿真生成数据, 构建了 LSTM 神经网络预测波前, 通过仿

真验证了 LSTM 根据当前 5 帧波前预测接下来 5 帧波前的能力, 预测结果如图 16 所示。

### 1.3 深度强化学习

强化学习是机器学习的一个分支, 关注的是智能体 (Agent) 如何根据环境的状态 (State) 做出动作 (Action) 以使得累计的奖励 (Reward) 最大化。强化学习与有监督学习、无监督学习并列为机器学习三大范式。深度强化学习则将强化学习与深度学习结合<sup>[45]</sup>, 通常用深度神经网络处理高维图像数据, 生成可供强化学习利用的环境状态。深度强化学习已成功应用于机器人、视频游戏、自然语言处理、计算机视觉等领域。通过建立合适的智能体、状态、动作、奖励模型, 深度强化学习可以应用于 WFSless AO 领域。

中国科学院光电技术研究所的 Hu 等<sup>[46-47]</sup> 研究了基于深度强化学习的 WFSless AO 系统自学习控制。将相位校正过程表达为马尔可夫决策过程 (MDP), 以变形镜的控制电压作为“动作”, 以 CCD 上光强分布灰度图像作为“状态”, 以图像锐度作为“奖励” (图 17), 采用演员-评论员 (Actor-Critic) 算法<sup>[48]</sup> 进行自主学习。相比于 SPGD, 该方法将相位校正速度提升了 9 倍, 同时相位校正准确度与 SPGD 相当。波前校正前后的点目标光强分布如图 18 所示。




Fig. 16 Prediction results of the next 5 frames wavefront made by LSTM<sup>[44]</sup>

图 16 LSTM 对将来 5 帧波前的预测结果<sup>[44]</sup>




Fig. 17 Reinforcement Learning (RL) of WFSless AO<sup>[47]</sup>

图 17 WFSless AO 的强化学习<sup>[47]</sup>

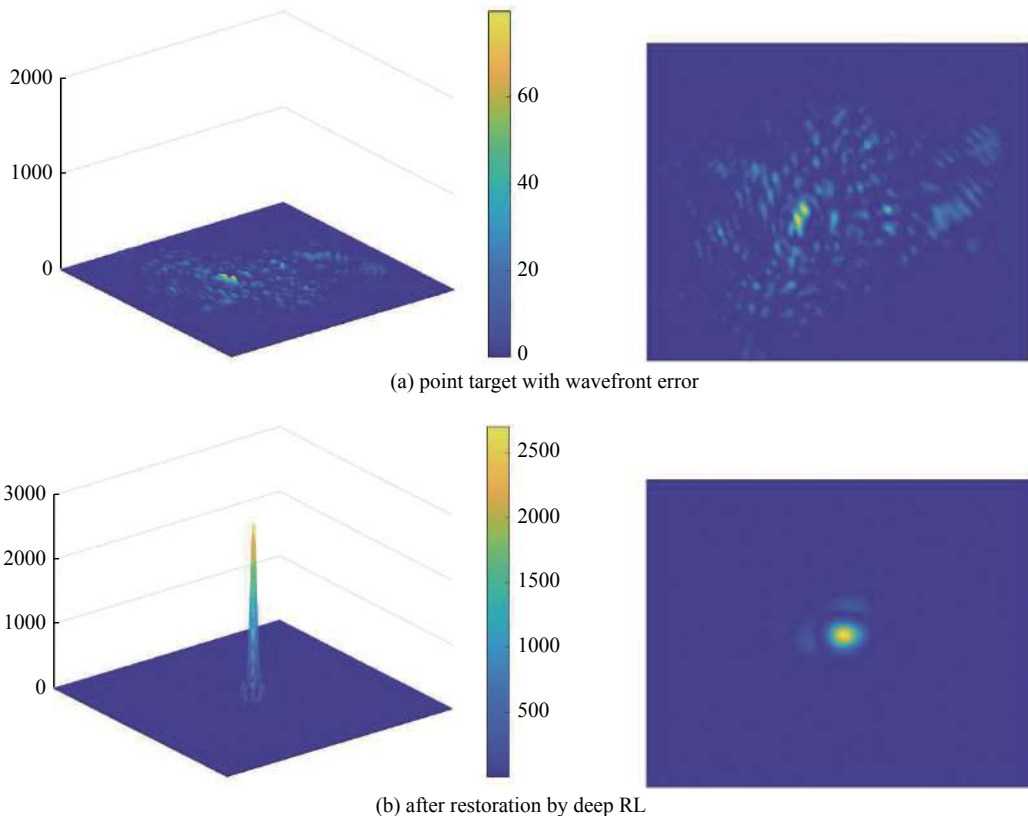


Fig. 18 Intensity distribution of point target with wavefront error and that after restoration by deep RL<sup>[47]</sup>

图 18 存在波前像差时点目标光强分布与经深度强化学习校正波前像差后的点目标光强分布<sup>[47]</sup>

芬兰的 Nousiainen 等<sup>[49]</sup>采用 OOMAO 模拟 AO 系统环境,采用 PyTorch 框架构建深度强化学习模型,验证了深度强化学习以若干秒为时间尺度进行连续学习,适应系统校准误差与变化湍流的能力。除了大气湍流,地基天文望远镜还面临两个现实问题,一是波前感知与校正之间的时延,即伺服滞后;二是变形镜等设备的振动。伺服滞后会导致图像质量恶化<sup>[50]</sup>,设备振动会降低长曝光图像的分辨率。为了解决这些问题,荷兰 Leiden 大学的 Landman 等<sup>[51]</sup>用深度强化学习实现了变形镜低阶模式控制信号的自主学习。针对变形镜的倾斜 (tip-tilt) 控制进行了仿真和实验,结果表明深度强化学习能够有效应对湍流变化、伺服滞后、变形镜振动,实现波前畸变校正。对于变化的环境,该方法不需要在线更新控制策略,由数据驱动 AO 预测控制。将 AO 控制问题代入强化学习框架时,“智能体”为变形镜控制器,“动作” $a_t$ 为 DM 的控制电压增量,“状态” $s_t$ 为当前时刻的观测 $o_t$ 与前一时刻的动作 $a_{t-1}$ ,其中 $o_t$ 为焦平面 PSF 图像质心,表达为:  $s_t = (o_t, a_{t-1})$ ,  $o_t = (x_t, y_t)$ ,其中 $(x_t, y_t)$ 为 PSF 图像质心坐标。“奖励” $r_t$ 为 PSF 质心偏差平方和的负数

$$r_t = -\frac{x_t^2 + y_t^2}{b^2} \quad (4)$$

其中 $b$ 是比例系数。智能体根据状态和奖励确定下一步的动作,即变形镜的控制电压增量。采用 Python 与 HCIPy<sup>[52]</sup>AO 仿真程序包进行了仿真。与经典的最优增益积分控制方法<sup>[53]</sup>相比,深度强化学习显著降低了各振动频率的功率谱密度(图 19)并显著消除了残留相位(图 20)。后续研究中该方法将用于控制变形镜的高阶模式。

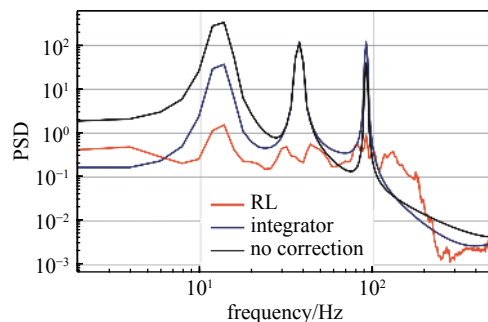


Fig. 19 PSD of different vibration frequency<sup>[51]</sup>

图 19 不同振动频率的功率谱密度<sup>[51]</sup>




Fig. 20 Residual phase<sup>[51]</sup>

图 20 残留相位<sup>[51]</sup>

基于深度学习的 WFSless AO 系统的研究离不开 AO 系统仿真软件和深度学习框架,一方面 AO 系统仿真软件能够仿真的系统参数、环境参数更加丰富;另一方面深度学习框架与代码日臻完善,如 PyTorch 的问世显著降低了实现深度学习模型的门槛,WFSless AO 领域开展科学研究的途径更为多样。有代表性的 AO 系统仿真软件和可用的深度学习框架如表 7 所示<sup>[54-56]</sup>。表中 AO 系统仿真软件均为开源软件,内置变形镜、WFS、大气湍流、人工导星、噪声、倾斜镜、Zernike 系数等仿真模块,可采用 MATLAB 或 Python 等高级编程语言进行二次开发,能够为常规 AO、WFSless AO 提供丰富的仿真数据。深度学习框架则为实现深度神经网络等模型提供了便利,用户仅需描

表 7 WFSless AO 仿真软件  
Table 7 WFSless AO simulation software

AO simulation tool	deep learning framework
Soapy <sup>[21]</sup>	PyTorch ( <a href="http://www.pytorch.org">www.pytorch.org</a> )
HCIPy <sup>[52]</sup>	Keras ( <a href="http://www.keras.io">www.keras.io</a> )
OOMAO <sup>[54]</sup>	TensorFlow ( <a href="http://www.tensorflow.org">www.tensorflow.org</a> )
YAO <sup>[55]</sup>	MATLAB + Deep Learning Toolbox
DASP <sup>[56]</sup>	Caffe ( <a href="https://caffe.berkeleyvision.org/">https://caffe.berkeleyvision.org/</a> )

Soapy: Simulation 'OptiqueAdaptative' with Python      HCIPy: High Contrast Imaging for Python  
OOMAO: Object-Oriented MATLAB Adaptive Optics Toolbox      YAO: Yorick Adaptive Optics  
DASP: Durham Adaptive Optics Simulation Platform

述模型结构、参数、代价函数等,模型的训练与优化可交由深度学习框架完成。

将深度学习应用于 WFSless AO 系统时,如下几个方面需要根据具体应用决定:1、模型输出为 Zernike 系数还是相位图。深度神经网络既可以输出 Zernike 系数后根据它表达出相位,也可以直接输出相位图。两种方式的数据量具有显著差异,并且 Zernike 系数为向量,而相位图为图像,采用这两种方案时所设计的模型结构不同。另外,Zernike 系数阶数的选取需要权衡相位表示精度与模型泛化能力,过多阶和过少阶都不可取<sup>[36]</sup>。2、模型输入为单幅光强图像还是成对的聚焦与离焦图像。以成对的聚焦与离焦图像进行训练有相位差异法作为理论支撑,实现了更优的推测准确度,然而该方法模型训练时间与推测时间均比单幅图像更长<sup>[34]</sup>。3、图像预处理时剪裁还是外扩。当点目标图像能量集中时,剪裁掉暗区图像能够减小数据量,缩减模型训练时间<sup>[40]</sup>。如果算力强大或者对实时性没有特殊要求,则可以对光强图像进行过曝、离焦、散射等预处理,使得目标能量在图像传感器上尽量展开,充分利用硬件资源挖掘图像数据<sup>[24]</sup>。

## 2 无波前探测自适应光学系统的应用

### 2.1 天文观测

自 1989 年 AO 技术首次在地基天文望远镜上成功实现衍射极限天文观测以来, AO 系统已逐渐发展成为地基大口径天文望远镜必备的组件之一。AO 空间分辨率高、灵敏度高的特点使其非常适合对密近多天体、密集星场等进行精确的科学观测。当今天文观测对仪器性能的要求愈发苛刻, AO 系统也在不断发展,多种新型 AO 系统陆续问世,如激光导星 AO 系统、多层共轭 AO 系统、极限 AO 系统、近地层 AO 系统等<sup>[2]</sup>。中国科学院光电技术研究所的 Zhu 等<sup>[57]</sup>将 WFSless AO 技术应用于薄膜衍射望远镜,实验结果表明 WFSless AO 能够有效提升薄膜衍射望远镜的成像质量,尤其适于消除系统组装及运作过程中扰动造成的像差。

近年来随着人类太空活动日益频繁,太空垃圾快速积累, AO 及 WFSless AO 技术还可用于跟踪和拍摄低轨道上卫星和碎片的图像。通过向天空投射一束跟踪激光,测量它返回地球所需的时间来确定卫星或碎片与地球间的精确距离。AO 系统在激光束穿过湍流大气之前进行预处理,人工加入畸变以抵消湍流的影响,使得激光束离开大气后无失真。除了追踪太空碎片,研究人员还希望能够在太空物体将要发生碰撞时利用这项技术将其推离轨道。该应用的原理是激光光子从碎片表面反射时所产生的微弱压力可以改变物体的轨道, AO 及 WFSless AO 技术可以用于精确地将激光束聚焦到期望的位置。这种系统将在全球范围内使用,以帮助管理空间环境。

### 2.2 显微成像

光学显微镜长期以来在生物医学研究中发挥着重要作用,能够以非侵入方式提供标本的多维结构和功能信息。显微镜依靠高质量的光学系统以最佳分辨率工作。对于传统显微镜而言,最佳分辨率由衍射极限决定。然而,即使有完美的光学元件,显微镜的性能还会受到样品光学特性的影响。当光线穿过样品深入生物组织时,折射率的空间变化会引起像差,这些像差会影响显微镜图像的分辨率和对比度,最终限制成像的实际深度。为了克服这一局限性, AO 及 WFSless AO 被引入到显微镜中,并已成为高分辨率显微镜的重要部分<sup>[58]</sup>。AO 可以校正样品折射率引起的像差,这对于需要获取生物组织标本深层图像的应用尤其有用。在 AO 显微镜系统中,采用变形镜或空间光调制器等动态校正元件补偿样品引起的像差<sup>[59]</sup>,如图 21 所示。WFSless AO 显微系统具有小型化、成本低、不需要精确校准的特点,适合显微成像应用场景,受到美国 UC Berkeley 大学 Ji 等研究人员的青睐<sup>[58]</sup>。牛津大学的 Hussain 等<sup>[60]</sup>首次展示了 WFSless AO 在孔径相关转盘式显微镜中的应用。由于样品内部折射率的变化,显微镜受

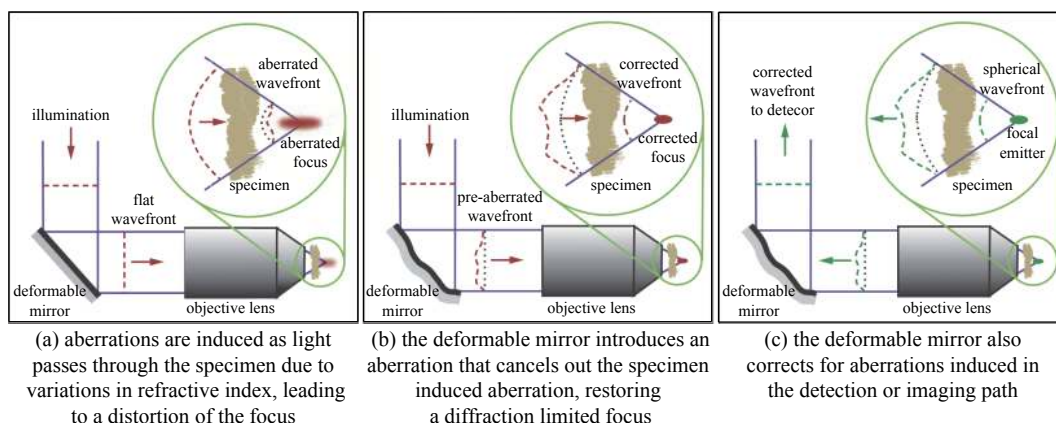


Fig. 21 Principle of aberration correction in high resolution optical microscopes<sup>[59]</sup>

图 21 高分辨率光学显微镜像差校正原理<sup>[59]</sup>

到像差影响。采用 WFSless AO 校正像差带来了信号电平、对比度和分辨率的提高。西安电子科技大学的刘立新等<sup>[61]</sup>综述了近年来 WFSless AO 在宽场成像显微镜与点扫描成像显微镜中的应用。

### 2.3 眼底成像

视网膜作为大脑的一个窗口,是中枢神经系统中唯一可以通过光学成像进行无创观测的部分。眼睛蕴藏着与大脑和脊髓相似的免疫反应,眼部症状常常先于传统的中枢神经系统疾病诊断出现,如阿尔茨海默病、帕金森病和多发性硬化症。因此,视网膜结构的活体形态和功能成像不仅为了解眼部疾病提供了一种无创的途径,而且也能解释中枢神经退行性病变的发病机制。然而,眼睛的光学像差降低了成像分辨率,阻碍了亚细胞视网膜结构的显示。香港理工大学的 Qin 等<sup>[62]</sup>开发了一种自适应光学双光子激发荧光显微镜(AO-TPEFM)系统,基于非线性荧光导星校正像差。通过波前像差校正, AO-TPEFM 实现了对小鼠视网膜进行亚  $\mu\text{m}$  分辨率的结构和功能成像。

加拿大 Simon Fraser University 大学的 Jian 等<sup>[63]</sup>通过将 WFSless AO 技术与双变形透射光学元件结合,提出了一种基于紧凑透镜的光学相干断层扫描(OCT)系统。不含 WFS 的方案更容易与基于透镜的经典光学系统兼容,设计更为简单,同时占空间更小。该系统成像波长为 1060 nm,用于高分辨率视网膜成像。使用了一种新型的多致动器自适应透镜来校正像差,从而在视网膜上实现接近衍射极限的成像性能。该透镜能够校正 4 阶径向 Zernike 多项式像差。利用并行处理计算平台,实现了高分辨率的视网膜横截面和切面图像的实时采集和显示。系统结构如图 22 所示。其中 MAL 为多致动器透镜, VFL 为可变聚焦透镜, VFL 的电压根据视网膜上的聚焦情况进行控制,实现像差校正。该系统的性能经过了临床验证。




Fig. 22 Schematic diagram of MAL-WSAO-SS-OCT system<sup>[63]</sup>

图 22 多致动器 WFSless AO 扫描源光学相干断层扫描系统原理图<sup>[63]</sup>

### 2.4 激光通信

AO 能够校正由大气湍流引起的波前畸变,可用于自由空间光通信(FSO)系统,提高 FSO 系统光纤耦合效率、降低误码率(BER)。然而在大气光通信没有信标光以及存在强闪烁现象的情况下,采用 WFS 的常规 AO 控制技术的应用受到限制,需要采用 WFSless AO<sup>[11]</sup>。西安电子科技大学的牛超君等<sup>[64]</sup>对基于差分进化、SPGD 和模拟退火算法的 WFSless AO 技术在 FSO 系统中的应用进行了模拟仿真,分析对比了波前像差校正前后 FSO 系统的光纤耦

合效率、BER 及光强起伏的变化情况。结果表明,三种算法均能有效提高 FSO 系统通信性能,其中差分进化算法尽管迭代速度稍慢,却具有最优的波前校正能力,实现了最低的通信误码率、最高的斯特列尔比,适合在强湍流情况下采用。常规 AO 及 WFSless AO 还是保障星地通信可靠性的重要手段,服务于天地一体化信息网络的构建。中国电子科学研究所的徐晓帆等<sup>[65]</sup>综述了用于保障星地激光通信可靠性的 AO 技术研究现状。

### 3 结 论

WFSless AO 在不需要 WFS 的前提下校正波前像差,改善光学系统性能。具有结构简单、体积小、成本低等特点,在天文观测、显微成像、眼底成像、激光通信等领域发挥了重要作用。近年来,深度学习及人工神经网络为 WFSless AO 注入了新的活力。CNN, LSTM、深度强化学习等模型在 WFSless AO 领域已被用于波前像差校正、变形镜控制预测,取得了一系列有代表性的成果。在以上几类深度学习模型中, CNN 适于处理二维光强图像,以训练后的 CNN 推测 Zernike 系数或相位的方法无须迭代优化,具有实时性强的特点。采用 Tensor RT 等工具对网络模型进一步优化后部署,能够实现亚毫秒级的相位复原。LSTM 适合处理时间序列,可以用于预测后续时刻变形镜与空间光调制器的控制信号,或用于直接预测将来时刻的波前。深度强化学习能够以较大时间尺度连续学习,不断适应环境,具备适应 WFSless AO 系统校准误差与变化湍流的能力。随着太空探索的深入、星地激光通信的普及、超分辨率光学显微镜的进步, WFSless AO 将迎来更广泛的关注,产生更深远的影响。

#### 参考文献:

- [1] Shorter R S. Principles of adaptive optics, 3rd edn., by Robert K. Tyson[J]. Contemporary Physics, 2011, 52(5): 501-502.
- [2] 冯麓, 张玉佩, 宋菲君, 等. 夜天文中的自适应光学[J]. 物理, 2018, 47(6): 355-366. (Feng Lu, Zhang Yupei, Song Feijun, et al. Adaptive optics for night astronomy[J]. Physics, 2018, 47(6): 355-366)
- [3] Yazdani R, Hajimahmoodzadeh M, Fallah H R. Adaptive phase aberration correction based on imperialist competitive algorithm[J]. Applied Optics, 2014, 53(1): 132-140.
- [4] 杨慧珍, 陈波, 李新阳, 等. 自适应光学系统随机并行梯度下降控制算法实验研究[J]. 光学学报, 2008, 28(2): 205-210. (Yang Huizhen, Chen Bo, Li Xinyang, et al. Experimental demonstration of stochastic parallel gradient descent control algorithm for adaptive optics system[J]. Acta Optica Sinica, 2008, 28(2): 205-210)
- [5] Facomprez A, Beaurepaire E, Débarre D. Accuracy of correction in modal sensorless adaptive optics[J]. Optics Express, 2012, 20(3): 2598-2612.
- [6] Huang Linhai, Rao Changhui. Wavefront sensorless adaptive optics: a general model-based approach[J]. Optics Express, 2011, 19(1): 371-379.
- [7] 方舟, 徐项项, 李鑫, 等. 自适应增益的SPGD算法[J]. 红外与激光工程, 2020, 49: 20200274. (Fang Zhou, Xu Xiangxiang, Li Xin, et al. SPGD algorithm with adaptive gain[J]. Infrared and Laser Engineering, 2020, 49: 20200274)
- [8] Zommer S, Ribak E N, Lipson S G, et al. Simulated annealing in ocular adaptive optics[J]. Optics Letters, 2006, 31(7): 939-941.
- [9] 杨平, 许冰, 姜文汉, 等. 遗传算法在自适应光学系统中的应用[J]. 光学学报, 2007, 27(9): 1628-1632. (Yang Ping, Xu Bing, Jiang Wenhan, et al. Study of a genetic algorithm used in an adaptive optical system[J]. Acta Optica Sinica, 2007, 27(9): 1628-1632)
- [10] Yang Huizhen, Li Xinyang. Comparison of several stochastic parallel optimization algorithms for adaptive optics system without a wavefront sensor[J]. Optics & Laser Technology, 2011, 43(3): 630-635.
- [11] Booth M J. Wavefront sensorless adaptive optics for large aberrations[J]. Optics Letters, 2007, 32(1): 5-7.
- [12] 杨慧珍, 吴健, 龚成龙. 基于模型的无波前探测自适应光学系统[J]. 光学学报, 2014, 34: 0801002. (Yang Huizhen, Wu Jian, Gong Chenglong. Model-based sensorless adaptive optics system[J]. Acta Optica Sinica, 2014, 34: 0801002)
- [13] Wen Lianghua, Yang Ping, Wang Shuai, et al. A high speed model-based approach for wavefront sensorless adaptive optics systems[J]. Optics & Laser Technology, 2018, 99: 124-132.
- [14] Huang Linhai. Coherent beam combination using a general model-based method[J]. Chinese Physics Letters, 2014, 31: 094205.
- [15] Wen Lianghua, Yang Ping, Yang Kangjian, et al. Synchronous model-based approach for wavefront sensorless adaptive optics system[J]. Optics Express, 2017, 25(17): 20584-20597.
- [16] Song Hong, Fraanje R, Schitter G, et al. Model-based aberration correction in a closed-loop wavefront-sensor-less adaptive optics system[J]. Optics Express, 2010, 18(23): 24070-24084.
- [17] Angel J R P, Wizinowich P, Lloyd-Hart M, et al. Adaptive optics for array telescopes using neural-network techniques[J]. Nature, 1990, 348(6298): 221-224.
- [18] Sandler D G, Barrett T K, Palmer D A, et al. Use of a neural network to control an adaptive optics system for an astronomical telescope[J]. Nature, 1991, 351(6324): 300-302.
- [19] Barrett T K, Sandler D G. Artificial neural network for the determination of Hubble Space Telescope aberration from stellar images[J]. Applied Optics, 1993, 32(10): 1720-1727.
- [20] Paine S W, Fienup J R. Machine learning for improved image-based wavefront sensing[J]. Optics Letters, 2018, 43(6): 1235-1238.
- [21] Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the inception architecture for computer vision[C]//Proceedings of the IEEE Conference on Computer

- Vision and Pattern Recognition. 2016: 2818-2826.
- [22] Byrd R H, Lu Peihuang, Nocedal J, et al. A limited memory algorithm for bound constrained optimization[J]. *SIAM Journal on Scientific Computing*, 1995, 16(5): 1190-1208.
- [23] Nishizaki Y, Valdivia M, Horisaki R, et al. Deep learning wavefront sensing[J]. *Optics Express*, 2019, 27(1): 240-251.
- [24] Chollet F. Xception: Deep learning with depthwise separable convolutions[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 1251-1258.
- [25] Kingma D, Ba J. Adam: A method for stochastic optimization[DB/OL]. arXiv preprint, arXiv: 1412.6980, 2014.
- [26] 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.
- [27] Polo A, Haber A, Pereira S F, et al. An innovative and efficient method to control the shape of push-pull membrane deformable mirror[J]. *Optics Express*, 2012, 20(25): 27922-27932.
- [28] Gonsalves R A. Phase retrieval and diversity in adaptive optics[J]. *Optical Engineering*, 1982, 21: 215829.
- [29] Ma Huimin, Liu Haiqiu, Qiao Yan, et al. Numerical study of adaptive optics compensation based on convolutional neural networks[J]. *Optics Communications*, 2019, 433: 283-289.
- [30] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[C]//Proceedings of the 25th International Conference on Neural Information Processing Systems. 2012: 1097-1105.
- [31] 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)
- [32] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[DB/OL]. arXiv preprint, arXiv: 1409.1556, 2014.
- [33] Guo Hongyang, Xu Yangjie, Li Qing, et al. Improved machine learning approach for wavefront sensing[J]. *Sensors*, 2019, 19(16): 3533.
- [34] Wu Yu, Guo Youming, Bao Hua, et al. Sub-millisecond phase retrieval for phase-diversity wavefront sensor[J]. *Sensors*, 2020, 20(17): 4877.
- [35] Nvidia Tensor RT[EB/OL]. (2021-07-09). <https://developer.nvidia.com/tensorrt>.
- [36] Vera E, Guzmán F, Weinberger C. Boosting the deep learning wavefront sensor for real-time applications [Invited][J]. *Applied Optics*, 2021, 60(10): B119-B124.
- [37] Weinberger C, Guzmán F, Vera E. Improved training for the deep learning wavefront sensor[C]//Proceedings Volume 11448, Adaptive Optics Systems VII. 2020, 11448: 114484G.
- [38] Wang Kaiqiang, Zhang Mengmeng, Tang Ju, et al. Deep learning wavefront sensing and aberration correction in atmospheric turbulence[J]. *PhotonIX*, 2021, 2: 8.
- [39] He Kaiming, Zhang Xiangyu, Ren Shaoqing, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016: 770-778.
- [40] Hochreiter S, Schmidhuber J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [41] Xin Qi, Ju Guohao, Zhang Chunyue, et al. Object-independent image-based wavefront sensing approach using phase diversity images and deep learning[J]. *Optics Express*, 2019, 27(18): 26102-26119.
- [42] Liu Xuewen, Morris T, Saunter C. Using long short-term memory for wavefront prediction in adaptive optics[C]//Proceeding of the 28th International Conference on Artificial Neural Networks. Munich: Springer, 2019: 537-542.
- [43] Chen Ying. LSTM recurrent neural network prediction algorithm based on Zernike modal coefficients[J]. *Optik*, 2020, 203: 163796.
- [44] Swanson R, Lamb M, Correia C, et al. Wavefront reconstruction and prediction with convolutional neural networks[C]//Proceedings Volume 10703, Adaptive Optics Systems VI. 2018, 10703: 107031F.
- [45] Mnih V, Kavukcuoglu K, Silver D, et al. Human-level control through deep reinforcement learning[J]. *Nature*, 2015, 518(7540): 529-533.
- [46] Hu Ke, Xu Bing, Xu Zhenxing, et al. Self-learning control for wavefront sensorless adaptive optics system through deep reinforcement learning[J]. *Optik*, 2019, 178: 785-793.
- [47] Hu Ke, Xu Zhenxing, Yang Wei, et al. Build the structure of WFSless AO system through deep reinforcement learning[J]. *IEEE Photonics Technology Letters*, 2018, 30(23): 2033-2036.
- [48] Konda V R, Tsitsiklis J N. Actor-critic algorithms[C]//Proceedings of Advances in Neural Information Processing Systems. 2000: 1008-1014.
- [49] Nousiainen J, Rajani C, Kasper M, et al. Adaptive optics control using model-based reinforcement learning[J]. *Optics Express*, 2021, 29(10): 15327-15344.
- [50] Cantalloube F, Farley O, Milli J, et al. Wind-driven halo in high-contrast images. I. Analysis of the focal-plane images of SPHERE[J]. *Astronomy and Astrophysics*, 2020, 638: A98.
- [51] Landman R, Haffert S Y, Radhakrishnan V M, et al. Self-optimizing adaptive optics control with reinforcement learning[C]//Proceedings Volume 11448, Adaptive Optics Systems VII. 2020, 11448: 1144849.
- [52] Por E H, Haffert S Y, Radhakrishnan V M, et al. High Contrast Imaging for Python (HCIPy): an open-source adaptive optics and coronagraph simulator[C]//Proceedings Volume 10703, Adaptive Optics Systems VI. 2018, 10703: 1070342.
- [53] Gendron E, Léna P. Astronomical adaptive optics. II. Experimental results of an optimized modal control[J]. *Astronomy and Astrophysics Supplement Series*, 1995, 111: 153-167.

- [54] Conan R, Correia C. Object-oriented Matlab adaptive optics toolbox[C]//Proceedings Volume 9148, Adaptive Optics Systems IV. 2014, 9148: 91486C.
- [55] Rigaut F, Van Dam M. Simulating astronomical adaptive optics systems using YAO[C]//Third AO4ELT Conference - Adaptive Optics for Extremely Large Telescopes. 2013.
- [56] Basden A G, Bharmal N A, Jenkins D, et al. The Durham Adaptive Optics Simulation Platform (DASP): Current status[J]. *SoftwareX*, 2018, 7: 63-69.
- [57] Zhu Licheng, Wen Lianghua, Yang Ping, et al. Aberration correction based on wavefront sensorless adaptive optics in membrane diffractive optical telescope[J]. *Optics Communications*, 2019, 451: 220-225.
- [58] Marx V. Microscopy: hello, adaptive optics[J]. *Nature Methods*, 2017, 14(12): 1133-1136.
- [59] Booth M J. Adaptive optical microscopy: the ongoing quest for a perfect image[J]. *Light: Science & Applications*, 2014, 3: e165.
- [60] Hussain S A, Kubo T, Hall N, et al. Wavefront-sensorless adaptive optics with a laser-free spinning disk confocal microscope[J]. *Journal of Microscopy*, 2020.
- [61] 刘立新, 张美玲, 吴兆青, 等. 自适应光学在荧光显微镜中的应用[J]. *激光与光电子学进展*, 2020, 57: 120001. (Liu Lixin, Zhang Meiling, Wu Zhaoqing, et al. Application of adaptive optics in fluorescence microscope[J]. *Laser & Optoelectronics Progress*, 2020, 57: 120001)
- [62] Qin Zhongya, He Sicong, Yang Chao, et al. Adaptive optics two-photon microscopy enables near-diffraction-limited and functional retinal imaging in vivo[J]. *Light: Science & Applications*, 2020, 9: 79.
- [63] Jian Yifan, Lee Sujin, Ju M J, et al. Lens-based wavefront sensorless adaptive optics swept source OCT[J]. *Scientific Reports*, 2016, 6: 27620.
- [64] 牛超君, 于诗杰, 韩香娥. 无波前探测自适应光学对光通信性能影响分析[J]. *激光与光电子学进展*, 2015, 52: 080102. (Niu Chaojun, Yu Shijie, Han Xiang'e. Analysis about effect of wavefront sensorless adaptive optics on optical communication[J]. *Laser & Optoelectronics Progress*, 2015, 52: 080102)
- [65] 徐晓帆, 陆洲. 星地激光通信可靠性保障技术研究现状[J]. *中国电子科学研究院学报*, 2018, 13(6): 650-657. (Xu Xiaofan, Lu Zhou. Research status of mitigation techniques to assure the reliability of satellite-to-ground laser communications[J]. *Journal of CAEIT*, 2018, 13(6): 650-657)