

## 基于深度学习的自适应光学技术研究进展及展望

胡逸雯<sup>1</sup>, 刘鑫<sup>1</sup>, 匡翠方<sup>1,2</sup>, 刘旭<sup>1,2</sup>, 郝翔<sup>1\*</sup>

<sup>1</sup>浙江大学光电科学与工程学院, 浙江 杭州 310027;

<sup>2</sup>之江实验室智能感知研究中心, 浙江 杭州 311100

**摘要** 自适应光学是一种校正波前误差的技术,在地基望远镜、生物成像、人眼像差校正、激光通信等领域中已经有了广泛的应用。与此同时,深度学习技术的快速发展为各个领域带来了全新的方法。为了进一步提升传统自适应光学系统的性能,研究者将自适应光学技术与深度学习相结合,从实时性、抗噪声干扰能力等角度对已有自适应光学系统进行了改进。首先对目前常用的人工神经网络架构进行了介绍,然后详细阐述了近五年深度学习与自适应光学技术相结合的方法,最后对已有方法进行了总结,并对该技术未来的发展方向进行了展望。

**关键词** 激光光学; 自适应光学; 深度学习; 人工神经网络; 波前校正

中图分类号 O436

文献标志码 A

DOI: 10.3788/CJL230470

### 1 引言

自适应光学(AO)是一种通过实时测量并补偿光传播媒介引起的波前误差来提高成像质量的技术,已经在地基望远镜、生物成像、人眼像差校正、激光通信等领域<sup>[1-5]</sup>中得到了广泛的应用。

目前的AO系统可根据有无波前传感器(WFS)分为两个大类。其中,无WFS型AO技术利用恢复算法基于光强分布信息获取光瞳相位信息,通常可以分为单张图像型和相位差型。单张图像型是指基于单张强度图像测量波前误差,然而单幅强度图像反演得到的光瞳平面的相位分布呈一对多的映射关系,因此原始的单张图像型AO技术通常精度较低。相位差型AO技术通过采集焦面和离焦面的图像信息来唯一确定输入平面上光场的相位分布,检测精度更高。但是传统的无WFS型AO技术都需要通过大量的迭代和测量来获取最佳结果,不适用于对波前校正效率要求很高的场景。有WFS的AO方法采用基于干涉原理或传统几何光学原理的WFS对波前进行探测和复原,例如移相干涉WFS、夏克-哈特曼WFS(SHWFS)、金字塔WFS(PyWFS)等。传统移相干涉WFS测量精度高,但其实时性较差且易受环境干扰。SHWFS被广泛应用于AO系统中,探测光路结构简单,易于操作,但由于其光瞳分割机制,空间分辨率较低,能够测量的动态范围小<sup>[6-7]</sup>。PyWFS相比于SHWFS而言,可以探测光

强更弱的天体,然而PyWFS的顶尖和棱边的质量以及表面粗糙度将对系统的测量灵敏度造成巨大影响,因此对加工的设备提出了很高的要求<sup>[8-9]</sup>,且在未调制模式下其线性范围较小<sup>[10]</sup>。总的来说,目前的AO技术主要存在校正速度慢、校正结果不精确等问题。

与此同时,人工智能技术的快速发展给各个领域带来了全新的方法,而深度学习作为其中一个重要分支,在搜索技术、数据挖掘、机器翻译、语音以及其他相关领域中都彰显出强大的能力。深度学习利用人工神经网络模型,通过修改权重和偏置,基于给定的样本进行学习,经过大量数据训练后,可以得到准确的输入输出关系。虽然训练时间较长,但训练完成后的网络推理时间很短,优异的性能使之成为了各个领域的热门话题。由此可见,深度学习适用于解决目前AO技术中的问题。具体而言:对于无WFS型AO技术,深度学习可提高其校正效率;干涉WFS型AO技术则可通过深度学习实现快速降噪和波前恢复,提高计算精度和效率;SHWFS型AO技术可通过深度学习提高质心定位精度与波前重构精度,实现更加准确的相位恢复;PyWFS型AO技术利用深度学习实现波前的非线性重建,可在提高动态范围的同时保持高灵敏度。因此,将AO技术与深度学习相结合可以实现更快速、更准确的波前校正,从而进一步提高AO技术的性能。

本文主要分为三个部分:首先简单介绍了深度学习的发展历程并详细介绍了目前常用的神经网络架

收稿日期: 2023-01-31; 修回日期: 2023-04-09; 录用日期: 2023-05-10; 网络首发日期: 2023-05-20

基金项目: 国家重点研发计划(2018YFA0701400)、国家自然科学基金重大研究计划培育项目(92050115)、浙江省自然科学基金重点项目(LZ21F050003)、浙江省科技厅浙江省“领雁”研发攻关计划(2022C01077)、中央高校基本科研业务费专项资金(226-2022-00137)

通信作者: \*haox@zju.edu.cn

构;然后总结了近五年深度学习与AO系统相结合的技术的研究进展,根据有无WFS将AO系统分为两个大类,对其进行了详细介绍,并介绍了一种新型神经网络与AO相结合的技术;最后对这些技术进行了总结和展望。

## 2 深度学习神经网络模型

神经网络和机器学习的诞生可以追溯到1957年,Rosenblatt<sup>[11-12]</sup>开发了感知机即大脑神经元的简化数学模型。感知机实验的成功使许多科学家都相信,创造像人类一样思考的机器是可以实现的。然而,人们很快就发现感知机无法解决一系列问题,其中最著名的例子是异或<sup>[13]</sup>。相比于或算子,异或运算符不能线性分离,这导致感知机的处理效果不理想。因此,在很长一段时间内,几乎没有人愿意投入时间或金钱进行相关的研究。直到20世纪80年代,人们才慢慢意识到多层感知机能够解决或者部分解决单层感知机存在的问题,此时基于神经网络的机器学习方法重新引起了人们的关注。后来,AlexNet模型在ImageNet大规模视觉识别挑战中取得了压倒性胜利<sup>[14-15]</sup>,基于神经网络

的围棋程序AlphaGo击败了世界级专业棋手<sup>[16-17]</sup>,人们对神经网络的研究兴趣持续增长。

近年来,各种各样的神经网络架构逐渐被开发出来。此处将介绍一些与AO技术相结合的神经网络架构。

第一个架构是多层感知机,也被称为全连接神经网络。一个全连接神经网络模型包含一个输入层、一个输出层和多个隐藏层,每一层神经网络有若干个神经元,层与层之间的神经元全部相互连接,同一层的神经元互不相连。图1(a)是一个三层的全连接神经网络,第一层为输入层,第二层为隐藏层,第三层为输出层。对于相邻两层,上一层的输出为下一层的输入,每个节点都包含权重、偏置和激励函数三部分,其中权重和偏置会在训练过程中不断更新,网络通过迭代训练出最优的参数。常用的激励函数包括线性整流(ReLU)函数、sigmoid函数和tanh函数,图2所示为随着自变量 $z$ 变化的激励函数图像。虽然仅由全连接层组成的神经网络有一定的学习能力和非线性拟合能力,但它们在处理更复杂的数据(如图像)时表现不佳。

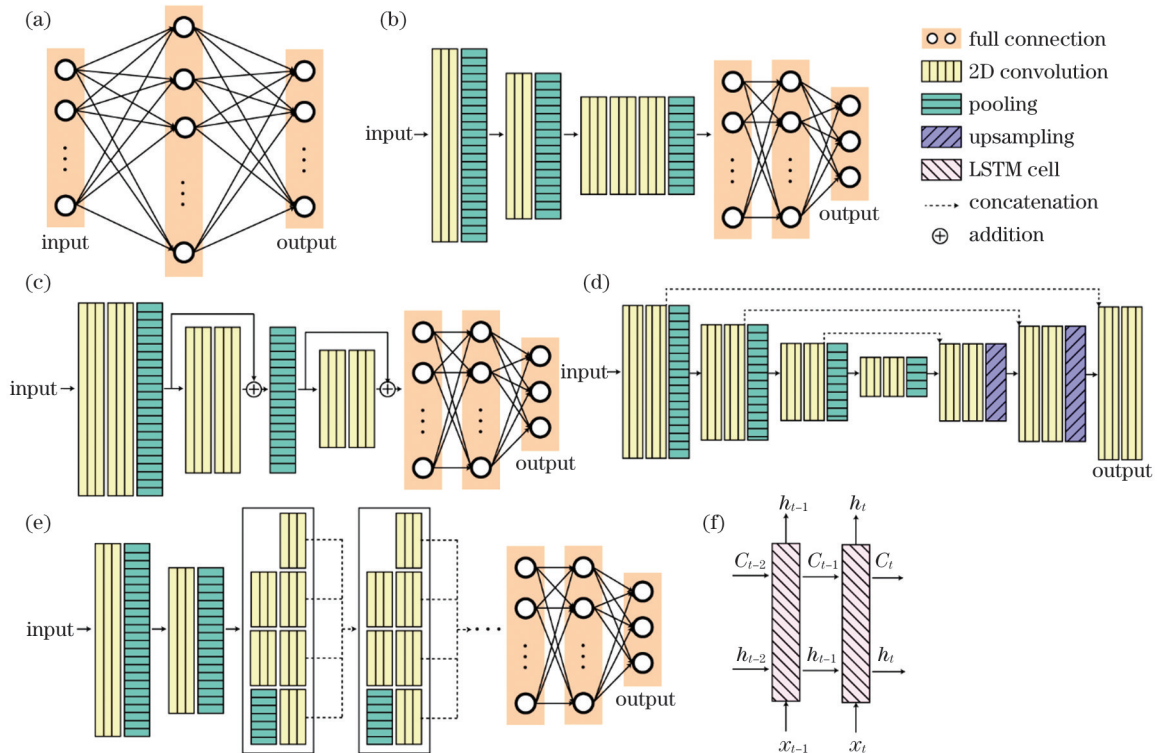


图1 常用的人工神经网络模型。(a)全连接神经网络;(b)卷积神经网络;(c)残差网络;(d)U-Net架构;(e)Inception架构;(f)长短期记忆网络

Fig. 1 Commonly used artificial neural network models. (a) Fully connected neural network; (b) convolutional neural network; (c) residual network; (d) U-Net architecture; (e) Inception architecture; (f) long short-term memory network

由于图像处理在天文学、生物成像等许多领域中都是至关重要的,因此产生了一种更为有效的用于分析图像的神经网络。图1(b)所示为第二个架构即卷积神经网络(CNN)。CNN是深度学习神经网络的一

种类型,被广泛应用于图像处理领域。相比于传统感知机,CNN包含卷积层,其对输入的图像进行卷积运算。输入图像通过一个或多个二维卷积层后,网络进行池化操作,也称为下采样。卷积运算所获取的特征




图2 常用的激励函数。(a)ReLU函数;(b)sigmoid函数;(c)tanh函数

Fig. 2 Commonly used activation function. (a) ReLU function; (b) sigmoid function; (c) tanh function

图的所有单元共用同一个卷积滤波器,图像特征得到有效提取<sup>[18]</sup>。卷积层的权重共享极大地减少了参数的数量和过拟合的风险,从而系统获得了更好的泛化能力<sup>[19]</sup>。通常较深的层比较浅的层含有更多的滤波器,卷积层的层数取决于输入的数据。最后一个卷积层的输出会被平摊成一个一维向量并送入全连接层,全连接层将特征映射中的所有单元与输出张量连接。输出的数据取决于待解决的问题。

随着更多复杂问题的出现,神经网络需要层数更多的网络结构。然而,在某些情况下,并非层数越多网络的性能就越好,相反,神经网络的性能可能有所退化。当网络退化时,浅层网络能够达到比深层网络更好的训练效果。基于此,残差神经网络(ResNet)<sup>[20]</sup>被开发出来。在ResNet中,较浅的层和较深的层之间具有跳跃连接,这些跳跃连接给较深的层提供了较浅层的输出 $y$ ,形成残差块。如图1(c)所示,将较深层的变换 $F(y)$ 与较浅层的输出 $y$ 相加,得到较深层的输出,即 $H(y)=F(y)+y$ ,解决了深度神经网络退化的问题。

在医学图像处理方面,Ronneberger等<sup>[21]</sup>提出了U-Net网络。如图1(d)所示,该网络分为编码部分、解码部分和跳跃连接部分。首先输入图像经过一系列二维卷积和空间下采样步骤(编码部分);然后,对特征图进行上采样或反卷积操作,直到输出与输入具有相同的空间尺度(解码部分)。同时,跳跃连接的引入将编码部分通过特征提取得到的语义信息及时传递给对应的解码端,完整地保留了编码部分获取到的图像特征。

Inception型网络<sup>[22]</sup>如图1(e)所示。输入图像首先经过初始的二维卷积和空间下采样操作,然后进入Inception模块。每个Inception模块利用 $1\times 1$ 、 $3\times 3$ 、 $5\times 5$ 等不同像素尺寸的卷积核进行多个单独的卷积操作,通常为以下四个操作: $1\times 1$ 卷积; $1\times 1$ 卷积, $3\times 3$ 卷积; $1\times 1$ 卷积, $5\times 5$ 卷积; $3\times 3$ 最大池化, $1\times 1$ 卷积。这些卷积在Inception模块之后沿着过滤器轴连接。Inception模块的数量根据待解决问题的不同而

不同。

上述架构都属于CNN的变体,而最后一种架构是递归神经网络(RNN)的变体即长短期记忆(LSTM)网络<sup>[23]</sup>,它不仅具有记忆性,还能够解决梯度消失的问题<sup>[24-25]</sup>。简而言之,当使用前馈神经网络时,神经网络会认为 $t$ 时刻输入的内容与 $t+1$ 时刻输入的内容完全无关。但是对于某些情景,运用 $t$ 或 $t$ 之前的输入来处理 $t+n$ 时刻的输入序列可以更好地利用输入信息并保留先前的状态。为了应用时间维度上信息,人们设计了RNN,它在短时间序列数据的分析方面具有优势,但却无法解决长期依赖问题。而使用LSTM可以有效地传递和表达长时间序列中的信息并且不会导致长时间前的有用信息被遗忘,同时还可以解决RNN中的梯度消失/爆炸问题。如图1(f)所示,LSTM由各个单元模块构成,其中 $t-2$ 、 $t-1$ 、 $t$ 分别代表不同时刻, $C$ 代表某时刻的记忆单元状态, $x$ 和 $h$ 分别代表某时刻记忆单元的输入值和输出值。LSTM单元具有维持内存状态的能力且能有选择地记住或遗忘信息,传播过程中的无关信息将被遗忘丢弃。因此LSTM常用于处理与文本和序列相关的问题。

### 3 无WFS型AO技术

传统无WFS型AO技术的波前恢复算法包括迭代变换法和参数法。迭代变换法包括随机并行梯度下降算法<sup>[26-27]</sup>、模拟退火算法<sup>[28]</sup>、遗传算法<sup>[29]</sup>、混合输入输出算法<sup>[30]</sup>和Gerchberg-Saxton算法<sup>[31-32]</sup>。然而,这些方法通常需要通过大量的迭代和测量才能完成全局优化,因此它们难以应用于实时像差校正系统<sup>[33-34]</sup>。参数法通过建立目标函数来校正参数化的波前误差,然后用非线性优化方法最小化目标函数。这两类迭代方法都很耗时,不适用于对效率要求很高的场景。此外,这些方法的结果部分依赖于迭代变换过程中所需的原始值,存在停滞问题<sup>[35]</sup>。

为了克服传统无WFS型AO系统速度慢、精度低的缺点,Angel等<sup>[1]</sup>最早利用人工神经网络来获取大气湍流干扰信息,确定低阶像差,同时解决了传统WFS



在波前不连续情况下难以使用的难题。随着湍流效应的增强,目前有更多复杂的神经网络应用于 AO 领域,可实现像差校正。

### 3.1 单张图像型

单张图像型 AO 技术,即基于单张图像测量波前误差。传统无 WFS 型 AO 技术的波前恢复效果依赖于算法迭代变换过程中所需的初始值,因此如何确定更优的初始值是研究热点之一。针对此问题,2018 年 Paine 和 Fienup<sup>[36]</sup>提出了基于深度学习寻找优化算法的波前初始估计方法。他们利用微调后的 Inception v3 架构,实现了从单张点扩散函数 (PSF) 图像到泽尼克 (Zernike) 多项式的映射,利用计算得到的泽尼克系数可以获得初始相位分布。实验结果表明,将深度学习计算得到的初始值作为 Broyden-Fletcher-Goldfarb-Shanno 算法<sup>[37]</sup>的初始值进行非线性优化比利用随机初始值进行优化更容易收敛。但是,由于传统的迭代优化算法较慢,该方法仍然存在难以实时补偿波前的问题。

因此,除利用深度学习对传统算法的初始相位进

行优化之外,还可以直接利用深度学习算法获取像差,训练完成后的网络能够实现比传统算法更快的波前恢复。2018 年, Jin 等<sup>[2]</sup>提出了一种应用于生物组织成像的无 WFS 像差校正方法。该方法利用 AlexNet 实现了从单张校正过倾斜模式的 PSF 图像到泽尼克系数 (4~10 项) 的非线性映射,根据泽尼克系数生成了补偿相位图。结果表明,该方法的校正精度可达到 90% 左右。在 200 次重复中,每个泽尼克系数的平均均方误差为 0.06。此外,该方法还被证明可以有效地补偿 1 mm 厚的活体样品和 300  $\mu\text{m}$  厚的小鼠脑切片引起的像差,其重构时间小于 0.2 s。与之相似, Tian 等<sup>[34]</sup>选用含有 7 层卷积层的 CNN,用于天文方面的像差校正,具体网络如图 3 所示。输入是尺寸为 224 pixel $\times$ 224 pixel 的单张 PSF 强度图像,输出为 2~400 阶泽尼克系数。与文献<sup>[2]</sup>所述方法相比,该方法无须进行倾斜模式补偿。2021 年, Wang 等<sup>[38]</sup>提出了一种应用于自由空间光通信的基于单幅光瞳平面强度图像恢复波前的方法,该方法通过训练 EfficientNet-B0<sup>[39]</sup>来实现入射光光瞳的强度图和泽尼克系数之间的映射。

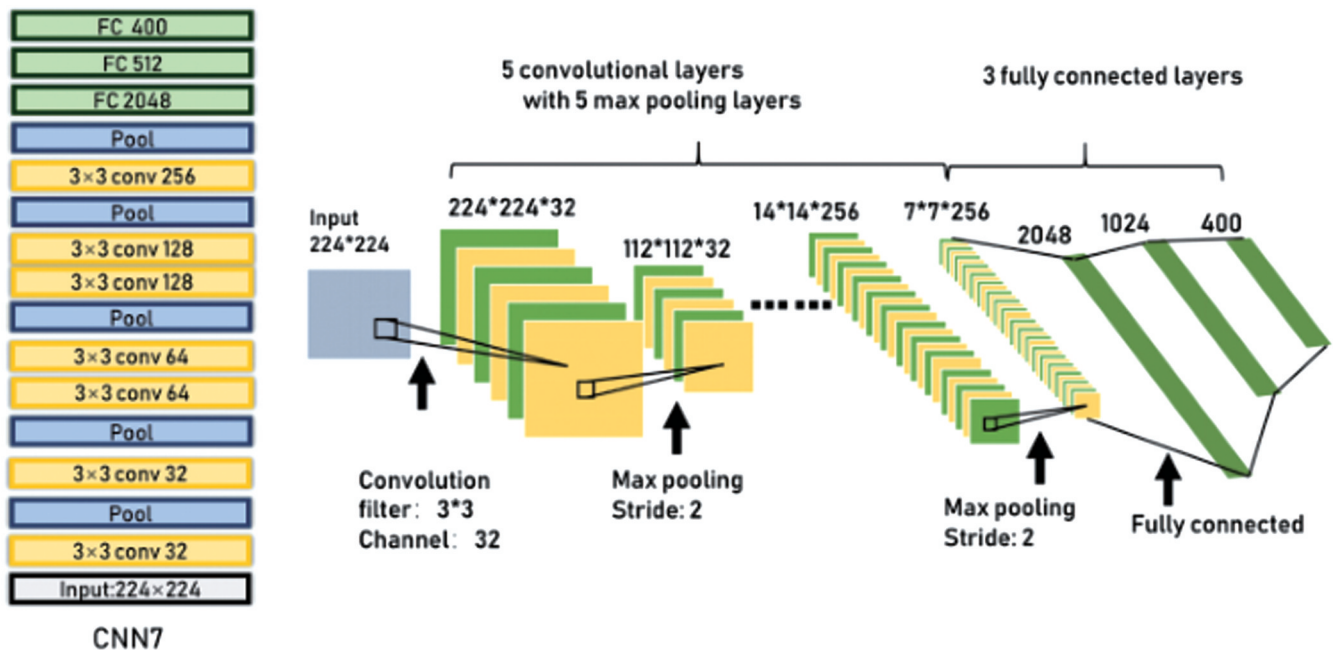


图 3 CNN7 模型结构<sup>[34]</sup>

Fig. 3 Structure of CNN7 model<sup>[34]</sup>

然而,由于单张图像型技术固有的强度到相位的一对多映射问题,单张图像型技术通常精度不高。为了进一步提高基于单张图像的像差校正的准确性, Nishizaki 等<sup>[40]</sup>利用预处理后的单张图像进行波前恢复,通过过曝、离焦和散射等预处理增加单张图像中的信息像素数,进而提高 WFS 的性能,并利用改进后的 Xception<sup>[41]</sup>估计 2~32 阶泽尼克系数。同时,该方法还被证明可以用来估计光源为点源或者扩展源时系统中的像差。实验结果表明,过曝、离焦和散射都不同程度地降低了估计泽尼克系数的均方根误差 (RMSEs)。

考虑到生物组织的多样性和异质性, Jin 等<sup>[42]</sup>提出了一种基于迁移学习的无 WFS 波前重建方法,解决了训练集与目标测试集之间的差异所带来的域漂移问题。其原理图如图 4 所示,该方法构建了一个权重共享的双流 CNN 框架,将大量随机生成的标记样本 (PSF 图像与对应的泽尼克系数) 作为源域数据,同时将未标记的特定样本作为目标域数据,通过引入协方差损失<sup>[43]</sup>,减小了源域和目标域分布之间的差距。通过对标记数据和未标记目标域数据进行训练来预测泽尼克系数,该网络在目标组织样本上表现出了更好的

性能。实验结果表明,在几乎相同的训练时间和处理时间下,该方法的准确率比传统的 AlexNet 提高了

18.5%, PSF 峰值强度提高了 20% 以上。但是域自适应可能会在一定程度上降低源域的精度。




图 4 权重共享双流 CNN 框架的训练架构<sup>[42]</sup>

Fig. 4 Training architecture of weights-sharing two-stream CNN framework<sup>[42]</sup>

### 3.2 相位差型

由于基于单幅强度图像反演得到光瞳平面的相位分布呈一对多的映射关系,因此仅基于一个焦平面图像的波前恢复算法通常精度较低。为了保证相位解的唯一性,通常需要同时采集具有一定相位差的多幅强度图像,这正是相位差型 AO 技术的原理。相位差型 AO 技术通过采集焦面和离焦面的图像信息来唯一确定输入平面上光场的相位分布,具有结构简单、易于实现的优点,且检测精度高、对环境要求低。

2019 年, Ma 等<sup>[33]</sup>利用改进后的 AlexNet 建立了光强图像与泽尼克系数之间的关系以进行像差校正,选择了一对聚焦和离焦的强度图像作为网络输入。结果表明,基于 CNN 的 AO 补偿极大地提高了 Strehl 比。与之相似, Andersen 等<sup>[44]</sup>以 2~4 m 级的望远镜为研究重点,在仿真上利用神经网络同时分析了聚焦和离焦图像并进行了波前恢复。该方法使用 Inception v3, 输出了估计的泽尼克项系数。Wu 等<sup>[45]</sup>利用改进后的 LeNet-5<sup>[46]</sup>从输入聚焦和离焦的 PSF 图像中获得了 3~15 阶泽尼克系数,并在此基础上提出 TensorRT 可提高算法的实时性。

除上述直接利用聚焦和离焦的强度图像来获取泽尼克像差系数的工作之外,还有工作是在对聚焦和离焦图像进行预处理后再对像差进行校正,实现了深度学习神经网络结构的简化。2018 年, Ju 等<sup>[47]</sup>提出了一种基于特征的波前恢复方法。该方法引入了切比雪夫矩<sup>[48]</sup>作为几何特征,利用切比雪夫矩可以将二维图像

数据转换为一维特征向量。通过提取一对 PSF 图像(聚焦和离焦平面)的几何特征作为神经网络的输入,可有效压缩图像数据,大大简化神经网络的结构。其算法原理如图 5 所示,该方法采用三层全连接网络,输入为经过预处理的切比雪夫矩,输出为泽尼克像差系数。实验结果表明,其精度比传统的迭代相位恢复方法略低,但网络结构简单,计算量较小,具有较高的效率和鲁棒性。受该方法启发, Xin 等<sup>[49]</sup>通过在频域提取一个与原始物体无关且仅由像差决定的特征(在这个过程中需要一对到焦面距离已知的图像),进行了波前恢复。该方法的特点在于能够实现点源波前恢复,同时也适用于任意扩展源波前的恢复。点源在许多成像场景中是不可用的,例如在天文中有大量的双星,此时点源的成像方式可能会导致结果不准确。该方法利用深度 LSTM 网络,在提取的与原始物体无关的特征图像与像差系数之间建立了精确的非线性映射。该特征( $f_0$ )可表示为

$$f_0 = \left| F^{-1} \left[ \frac{F(i_a)}{F(i_b)} \right] \right|, \quad (1)$$

式中:  $F(\cdot)$  表示傅里叶变换运算;  $F^{-1}(\cdot)$  表示傅里叶逆变换运算;  $i_a$  和  $i_b$  分别表示两张到焦面距离已知的图像的强度分布。如图 6 所示,扩展场景下重建图像的分辨率有了很大提高,与原始扩展图像的分辨率相当。

针对扩展目标的像差校正, 2022 年 Lu 等<sup>[50]</sup>提出了一种基于注意力的 AO 方法,该方法将非局部模块与



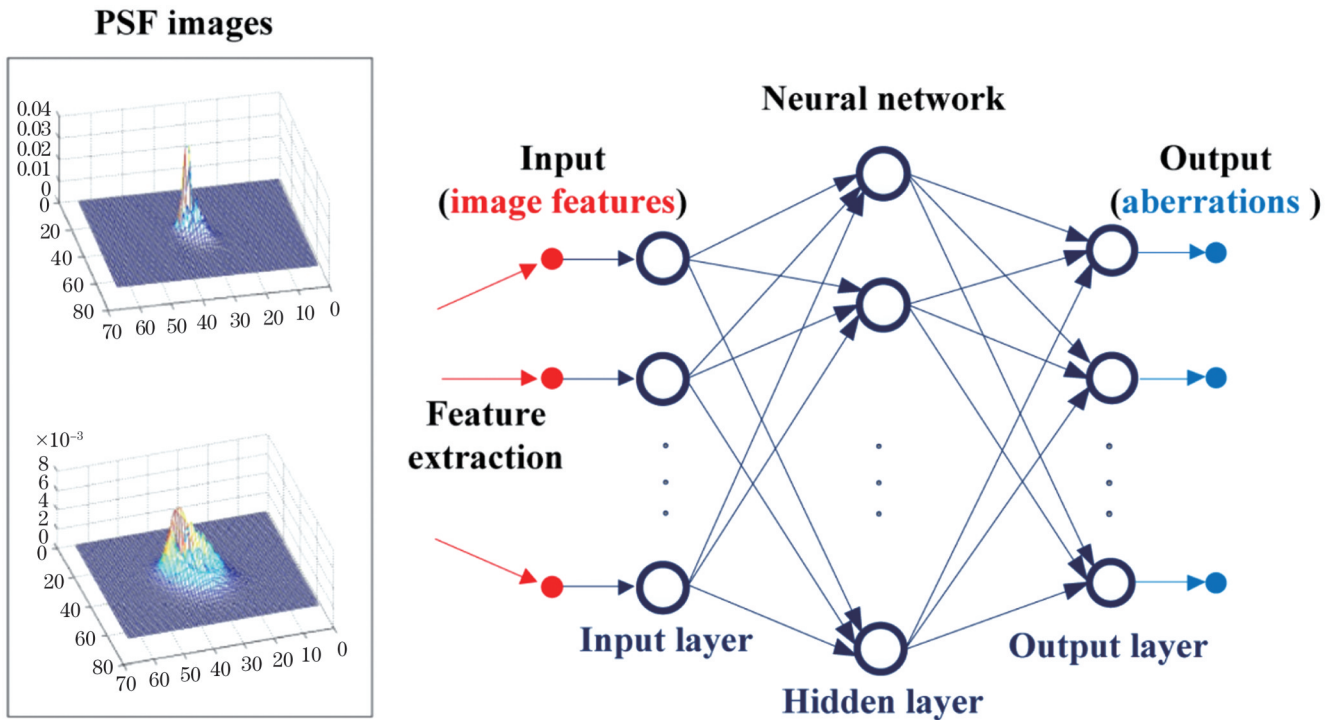


图 5 基于特征的波前恢复方法示意图<sup>[47]</sup>  
 Fig. 5 Sketch map of feature-based wavefront retrieval approach<sup>[47]</sup>

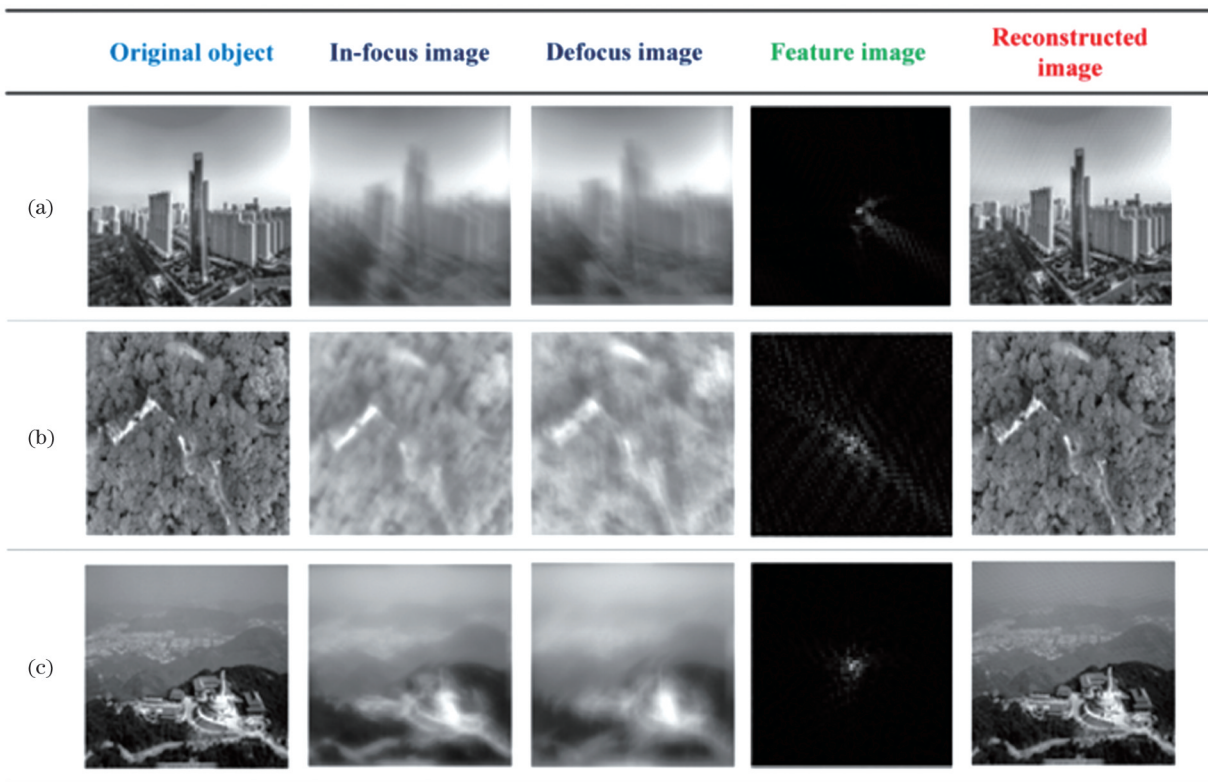


图 6 重建图像的仿真结果<sup>[49]</sup>  
 Fig. 6 Simulation results of reconstruction images<sup>[49]</sup>

CNN相结合,基于扩展目标的聚焦图像和离焦图像恢复了泽尼克像差系数。此处的非局部模块可以通过计算图片中任意两个位置的相互作用来直接捕获长距离依赖关系,是一个很好的特征提取器。该方法先拼接

聚焦与离焦的两幅图像,利用非局部网络进行特征提取,然后用CNN将提取到的特征映射到泽尼克系数。但是该方法的扩展对象是从MNIST数据集中选取的,当扩展对象改变时,相应的网络可能需要重新训练。

## 4 有 WFS 型 AO 技术

### 4.1 基于 SHWFS

传统 SHWFS 利用透镜阵列获取波前信息,入射到透镜阵列上的波面被分割为若干子波,每个子波对应的微透镜会聚于焦点,然后分别成像到相机上,经过处理可以计算得到光斑重心位置,从而获得入射波前的斜率信息,再利用波前恢复算法重构波前。其中,影响待测波前精度的主要因素是光斑质心位置的计算精度和波前重构精度<sup>[51]</sup>。

2006 年,Guo 等<sup>[4]</sup>首次将神经网络与 SHWFS 相结

合,提出了一种利用神经网络基于 SHWFS 光斑位移获取像差泽尼克系数的方法。受该方法的启发,近年来出现了众多将深度学习与 SHWFS 相结合的方法。

2018, Li 等<sup>[52]</sup>从提高质心定位精度的角度出发,提出了一种适用于强环境光和噪声污染的 AO 系统的 SHWFS 质心计算方法 (SHNN)。该方法利用三层全连接神经网络,将光斑检测问题转换为分类问题,输入为子孔径图像的 625 个像素的强度,输出是使用 625 个节点来表示所有这些类别。如图 7 所示,与传统方法相比,SHNN 的性能显著提高,更适用于极端情况下的 AO 系统。

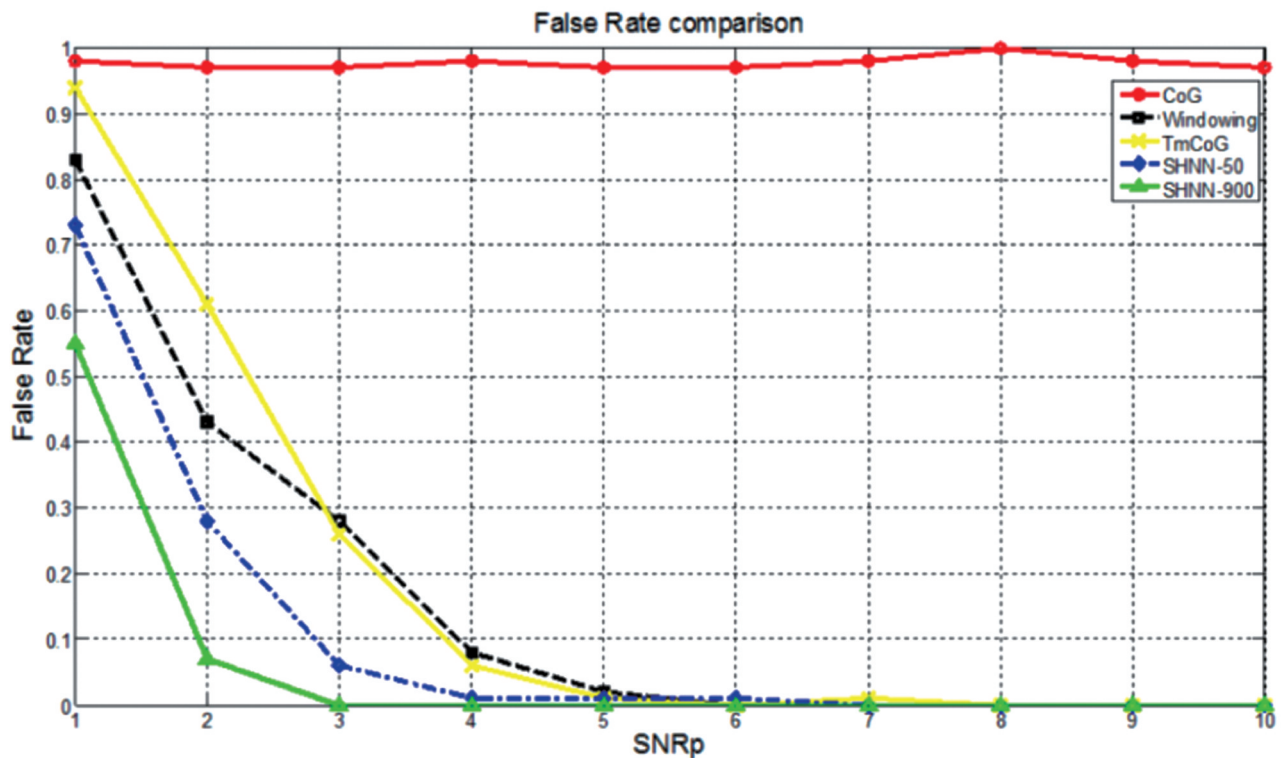


图 7 不同方法在低信噪比情况下的错误率<sup>[52]</sup>

Fig. 7 False rates of different methods under low signal-to-noise ratio<sup>[52]</sup>

除利用深度学习提高光斑质心位置的计算精度之外,也有研究者利用深度学习提高波前重构精度。在之前的工作<sup>[4,53]</sup>中,人们会利用神经网络输出的泽尼克像差系数来重构波前。然而,当利用泽尼克系数输出波前时,泽尼克项数的限制会导致高频细节丢失的问题。针对此问题,Swanson 等<sup>[54]</sup>提出了一种利用 SHWFS 的斜率分布图直接输出相位图的方法,利用改进后的 U-Net 架构,输入一组横向斜率和纵向斜率图,最后直接输出相位图。由于湍流效应和低信噪比条件,残余波前均方根 (RMS) 仍然较大。同时,SHWFS 测量的子孔径斜率平均值由穿过子孔的光束强度决定<sup>[55-56]</sup>。当大气湍流闪烁<sup>[55]</sup>、非各向同性后向散射<sup>[56]</sup>或其他原因引起光束强度变化时,若不考虑光束强度,可能会导致错误的波前重建。针对这一问题,2020 年 Dubose 等<sup>[57]</sup>在文献<sup>[54]</sup>的基础上开发了强度/

斜率网络 (ISNet),如图 8 所示,相比于已有方法,ISNet 增加了第三个编码器臂,利用了每个子孔径下的总强度,输入为对应子孔径的横向斜率、纵向斜率和强度信息,并使用了密集块结构<sup>[58]</sup>。实验结果表明,该方法极大地改善了波前重构效果。与 Swanson 等<sup>[54]</sup>的工作相比,ISNet 的波前误差更低。

传统波前重构算法是基于 SHWFS 图像中质心位置进行相位恢复,遗漏了传感器图像中对应于高频信息的 PSF 形状。针对此问题,Hu 等<sup>[53]</sup>提出了一种基于学习的 SHWFS (LSHWS)。该方法基于 AlexNet 的模型,直接输入传感器获得的图片,可以估计大像差图像的前 120 个泽尼克系数。网络训练完成后,可以在 10.9 ms 内预测 120 个泽尼克系数,模型精度为 95.56%。在 300  $\mu\text{m}$  厚的小鼠大脑切片上验证了该方法的像差检测性能,与传统 SHWFS 相比,该方法的峰



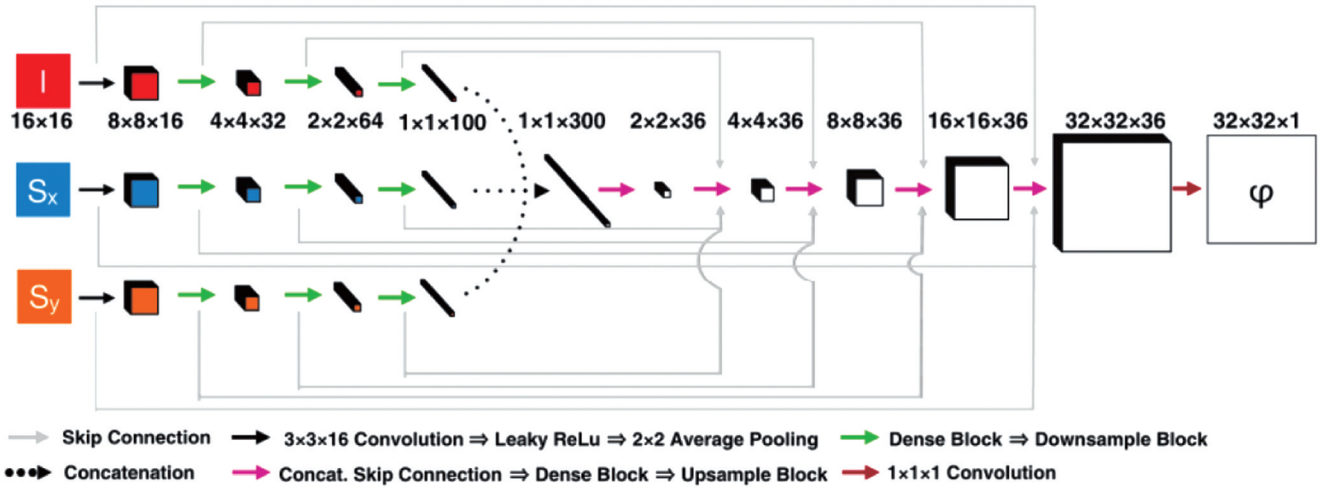


图 8 ISNet 架构<sup>[57]</sup>

Fig. 8 ISNet architecture<sup>[57]</sup>

背景比提高了 30%~40%。

受文献[54]的启发,2020年Hu等<sup>[59]</sup>提出了一种直接从SHWFS图中获取相位分布图的方法,称之为SH-Net。该方法基于改进后的ResUnet<sup>[60]</sup>,如图9所示。利用该方法测试了3种不同类型的相位恢复效果,第一种是由前2~120项泽尼克系数生成的泽尼克相位屏,第二种是在0~2π范围内随机生成的相位屏,第三种是混合相位屏,即在泽尼克相位屏的基础上加入了随机相位屏。实验结果表明,与已有方法比较,SH-Net得到了较低RMS波前误差和标准差。SH-Net探测到的混合相位屏的平均RMSE为0.0168λ(λ为波长),比LSHWS<sup>[53]</sup>的结果(0.0893λ)低81.19%左右,比文献[54]的结果(0.1366λ)低87.70%左右,比模

式法<sup>[61]</sup>的结果(0.1616λ)低89.60%左右,比区域法<sup>[62]</sup>的结果(0.1790λ)低90.61%左右。在探测速度方面,SH-Net基于SHWFS图像预测波前的平均时间为40.2ms,比LSHWS模式(0.1225s)快了67.18%左右,比模式法(0.1294s)快了68.93%左右,但比文献[54]的方法(22.6ms)慢了77.88%左右,比区域法(26.3ms)慢了52.85%左右。

2021年,Hu等<sup>[63]</sup>提出了一种基于PSF图像得到波前的两步波前检测方法,该方法致力于提高复杂波前的恢复能力。该方法包括两个CNN,一个CNN用于估计泽尼克多项式的前28个系数,重建每个子孔径下的局部波前,在进行拼接之后得到初步预测的波前,另一个CNN从初步预测的波前中恢复最终的连续波前。

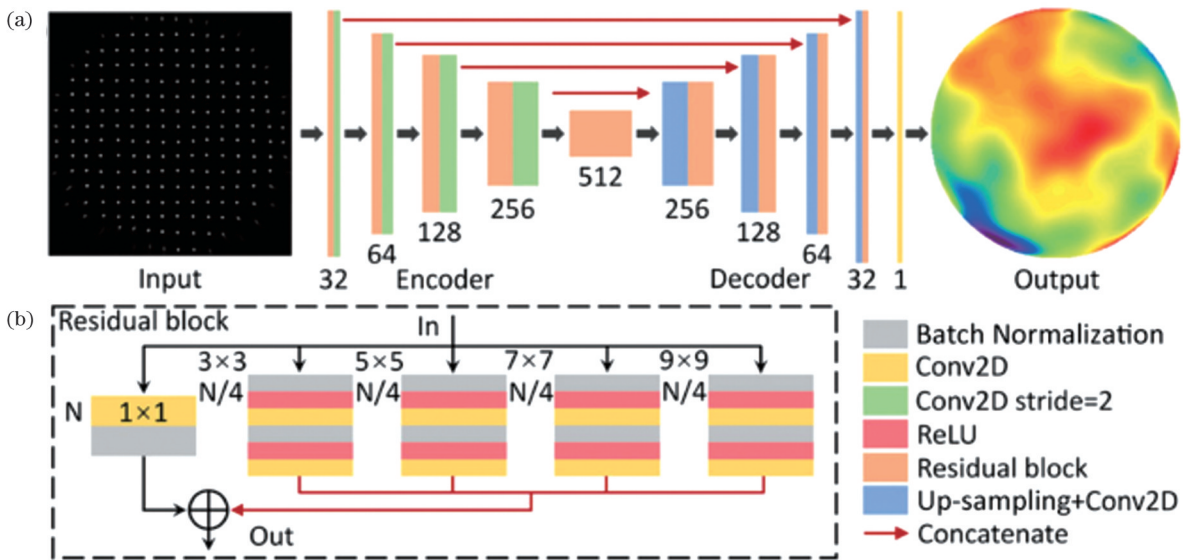


图 9 SH-Net 体系结构<sup>[59]</sup>。(a) 相位恢复流程;(b) 残差块结构

Fig. 9 Architecture of SH-Net<sup>[59]</sup>. (a) Process of phase retrieval; (b) residual block architecture

针对扩展目标波前的检测,2022年De Bruijine等<sup>[64]</sup>通过将盲去卷积和深度学习相结合进行了SHWFS图像的处理。该方法利用盲去卷积算法中的

切向迭代投影(TIP)算法,通过对SHWFS图像进行预处理,去除了扩展场景的影响,并返回估计的点源SHWFS图像,将该图像用于改进后的U-Net以重建



波前。与文献[59]的方法相比,该方法的评估时间和对内存的要求更低。然而,由于TIP算法偶尔会在估计的SHWFS图像中引入偏移,因此该方法无法校正波前的倾斜模式。同时,此方法目前仅适用于被黑暗背景包围的扩展对象,限制了它在卫星或监视成像等方面的应用。

#### 4.2 基于其他 WFS

SHWFS的子孔径较多,因此其不太适用于弱光条件。相比之下,PyWFS,也称棱锥传感器,可将光分为较少数量的子光束,因此可以探测光强较弱的天体,是一种很有前途的天文学WFS<sup>[65-66]</sup>。但与SHWFS相比,目前将PyWFS与深度学习结合的技术还未引起人们的广泛关注。2008年,Alvarez Diez等<sup>[3]</sup>采用三棱锥作为WFS(非调制模式),利用人工神经网络校正人眼像差,输入为PyWFS的像平面图像,输出为变形镜模式基的多项式。经过训练AO系统可将瞳径为6 mm、RMS小于200 nm的波前校正为RMS小于60 nm的波前。

与PyWFS相类似的是广义光学微分WFS(g-ODWFS),它的提出是为了扩大PyWFS的动态范围,同时保持灵敏度。2020年,Landman等<sup>[10]</sup>使用g-ODWFS进行波前重建,并将CNN与现有的矩阵向量乘法(MVM)模型结合。在此框架中,MVM模型用于线性预测波前,CNN用于预测非线性残差,这样的操作提高了Strehl比,适用于需要恢复大像差的场景,且组合模型比单独的两个模型表现得更好。但是该方法的实际应用仍然具有挑战,需要后续进一步的改进。2023年,Chen等<sup>[67]</sup>提出了一种将深度学习应用于全光WFS(PWFS)的方法。PWFS是介于SHWFS和PyWFS之间的一种传感器<sup>[68]</sup>。针对PWFS的斜率响应存在的明显阶跃变化导致的波前检测性能较差<sup>[69-70]</sup>问题,该方法利用ResUnet从PWFS的斜率测量数据(横向和纵向上的两个斜率图)中恢复相位图。数值模拟结果表明,该方法的统计残余波前RMSE为 $(0.0810 \pm 0.0258)\lambda$ 。该方法在实现相位恢复的过程中消耗了1.2 ms,但是此推理时间没有考虑质心估计

和数据传输时间。因此,该方法在实际应用中应该考虑使用压缩和加速技术来减少计算成本。

除此之外,还有一些将基于干涉原理的WFS与深度学习相结合的例子。2020年,Li等<sup>[71]</sup>采用U-Net来恢复两个随机移相干涉图的包裹相位。同年,Whang等<sup>[72]</sup>使用GoogleNet从两个相移 $\pi/4$ 的干涉图中预测泽尼克系数。2021年,Liu等<sup>[73]</sup>采用改进的AlexNet从单帧干涉图中提取泽尼克系数。但是这些方法并非仅用于AO,因此此处不作详细介绍。

## 5 基于衍射神经网络的AO技术

深度学习作为人工智能技术的一个重要分支,已经在各个领域有了广泛的应用。上述提到的方法都是基于计算机的深度学习技术,网络的训练、验证及测试过程均在计算机上完成。2018年,Lin等<sup>[74]</sup>提出了一种新型的全光衍射深度神经网络,该网络的训练由计算机实现,训练完成后的网络由3D打印的衍射层构成,可以以光速完成神经网络的推理过程。相比于传统神经网络,该方法具有直接以光速进行信息处理、能耗低的优点,在短短几年的时间内得到了快速发展。图10所示为这种新型衍射神经网络的结构,与传统神经网络相似,衍射神经网络由一个输入层、一个输出层和若干隐藏层(衍射光学元件)构成,隐藏层中的一个像素代表一个神经元节点,此处的衍射神经网络含有三层隐藏层。对应于传统神经网络中可学习的权重和偏置,衍射神经网络的权重及偏置分别代表光相位和振幅的改变(与层和层之间的距离有关)及衍射层透射或反射系数。需要注意的是,衍射神经网络的偏置与传统神经网络的偏置不同,传统神经网络中的偏置是与加权数据相加,而衍射神经网络的偏置是与加权数据相乘。虽然衍射神经网络具有与传统神经网络相似的结构,但是衍射神经网络并不能实现传统神经网络的参数优化,因此训练过程仍然需要通过计算机来完成。

近年来也有一些工作通过结合新型衍射神经网络技术进行波前恢复。2022年,Goi等<sup>[75]</sup>开发了一款基




图10 衍射神经网络

Fig. 10 Diffractive neural network

于多层衍射神经网络打印在成像传感器上的紧凑光电模块,该模块能够基于入射 PSF 直接恢复光瞳的相位分布。该方法提出的集成衍射深度神经网络将四个衍射光学元件与成像传感器的非线性检测相结合,实现了具有相位恢复能力的混合光电集成深度神经网络。该方法的输入为复值 PSF,输出为光瞳平面的相位。与基于计算机的神经网络不同,该网络采用非线性激活函数作为网络的最后一层。受衍射深度神经网络的启发,2023 年 Pan 等<sup>[76]</sup>提出了一个可以实时校正波前的衍射 AO 系统(DAOS)。该方法直接以未经处理的波前作为输入,经过一组透射衍射层后,输出校正的光场图像,无需波前传感和波前重建。测试了两种 DAOS 的波前校正效果,第一个 DAOS 旨在同时校正轴上和离轴视场的像差,第二种 DAOS 仅校正轴上视场的像差。仿真结果表明,针对轴上视场设计的系统将平均成像 Strehl 比从 0.32 提高到 0.94,针对多视场设计的系统将双星的可分辨概率从 30.5% 提高到 69.5%。

虽然衍射神经网络具有无源、计算速度快等优点,但是需要注意的是,一旦制造出无源器件,衍射神经网络的物理参数将不会改变,因此在设计过程中必须充分考虑应用场景。另外,衍射层之间应尽量对准以降低装配造成的与理论设计之间的误差。衍射神经网络目前并不能完全替代基于计算机的神经网络,其物理参数的设计仍需依赖传统的基于计算机的技术。

## 6 结束语与展望

AO 是一种校正光学波前误差的技术,在许多领域中已经有了广泛的应用。与此同时,深度学习技术具有快速、准确的优点,成为了各个领域的热门话题。因此,近年来产生了许多通过将 AO 与深度学习相结合来提升 AO 系统性能的方法。

与深度学习相结合的 AO 可根据有无 WFS 分为两个大类。其中,无 WFS 型具有结构简单、成本低的优点,可以分为单张图像型和相位差型。单张图像型仅利用单张图像恢复波前,但由于强度图像与相位呈一对多的映射关系,因此计算结果不够准确;相位差型是根据两张已知相位差的图像恢复波前,相比于单张图像型更为准确。利用深度学习可以提高无 WFS 型 AO 技术的实时性。有 WFS 型 AO 中基于 SHWFS 的方法较多,它们利用深度学习网络进行加速并进一步提升质心定位精度和波前重构精度。除此之外,基于其他传感器的波前测量方法也逐步与深度学习技术结合。

在未来,我们相信,深度学习将与其他技术(如强化学习)相结合并应用于其他类型的传感器(如 PyWFS)中,其优势得到进一步发展。同时,AO 也将与新型光学神经网络相结合,进一步提升其性能。除此之外,目前大多数工作是基于仿真数据进行测试的,因此还需要进一步评估其在实际应用中的表现。同

时,除了对点源波前误差的校正研究之外,对扩展源波前误差的探测也是未来的研究方向。

## 参 考 文 献

- [1] 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.
- [2] Jin Y C, Zhang Y Y, Hu L J, et al. Machine learning guided rapid focusing with sensor-less aberration corrections[J]. *Optics Express*, 2018, 26(23): 30162-30171.
- [3] Alvarez Diez C, Shao F, Bille J. Pyramid and Hartmann-Shack wavefront sensor with artificial neural network for adaptive optics [J]. *Journal of Modern Optics*, 2008, 55(4/5): 683-689.
- [4] Guo H, Korablinova N, Ren Q S, et al. Wavefront reconstruction with artificial neural networks[J]. *Optics Express*, 2006, 14(14): 6456-6462.
- [5] Wang N, Zhu L C, Ma S, et al. Research on distortion wavefront prediction technique for laser communication system based on LSTM network[J]. *Proceedings of SPIE*, 2022, 12169: 121693D.
- [6] 刘锋伟, 吴永前, 陈强, 等. 大口径光学非球面镜先进制造技术概述[J]. *光电工程*, 2020, 47(10): 65-87.
- [7] Liu F W, Wu Y Q, Chen Q, et al. Overview of advanced manufacturing technology of large-aperture aspheric mirror[J]. *Opto-Electronic Engineering*, 2020, 47(10): 65-87.
- [8] 姜文汉, 鲜浩, 沈锋. 夏克-哈特曼波前传感器的探测误差[J]. *量子电子学报*, 1998, 15(2): 218-227.
- [9] Jiang W H, Xian H, Shen F. Detecting error of shack-hartmann wavefront sensor[J]. *Chinese Journal of Quantum Electronics*, 1998, 15(2): 218-227.
- [10] Ragazzoni R, Ghedina A, Baruffolo A, et al. Testing the pyramid wavefront sensor on the sky[J]. *Proceedings of SPIE*, 2000, 4007: 423-430.
- [11] Ghigo M, Diolaiti E, Perennes F, et al. Use of the LIGA process for the production of pyramid wavefront sensors for adaptive optics in astronomy[J]. *Proceedings of SPIE*, 2003, 5169: 55-61.
- [12] Landman R, Haffert S Y. Nonlinear wavefront reconstruction with convolutional neural networks for Fourier-based wavefront sensors [J]. *Optics Express*, 2020, 28(11): 16644-16657.
- [13] Rosenblatt F. The perceptron, a perceiving and recognizing automaton project para[M]. Washington, D. C.: Cornell Aeronautical Laboratory, 1957.
- [14] Rosenblatt F. The perceptron: a probabilistic model for information storage and organization in the brain[J]. *Psychological Review*, 1958, 65(6): 386-408.
- [15] Olazaran M. A sociological study of the official history of the perceptrons controversy[J]. *Social Studies of Science*, 1996, 26(3): 611-659.
- [16] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[J]. *Communications of the ACM*, 2017, 60(6): 84-90.
- [17] Deng J, Dong W, Socher R, et al. ImageNet: a large-scale hierarchical image database[C] // 2009 IEEE Conference on Computer Vision and Pattern Recognition, June 20-25, 2009, Miami, FL, USA. New York: IEEE Press, 2009: 248-255.
- [18] Silver D, Huang A, Maddison C J, et al. Mastering the game of go with deep neural networks and tree search[J]. *Nature*, 2016, 529(7587): 484-489.
- [19] Silver D, Schrittwieser J, Simonyan K, et al. Mastering the game of go without human knowledge[J]. *Nature*, 2017, 550(7676): 354-359.
- [20] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444.
- [21] Huang J T, Li J Y, Gong Y F. An analysis of convolutional neural networks for speech recognition[C] // 2015 IEEE International Conference on Acoustics, Speech and Signal Processing



- (ICASSP), April 19-24, 2015, South Brisbane, QLD, Australia. New York: IEEE Press, 2015: 4989-4993.
- [20] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [21] 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.
- [22] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions [C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015.
- [23] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [24] Gers F A, Schmidhuber J, Cummins F. Learning to forget: continual prediction with LSTM[J]. Neural Computation, 2000, 12(10): 2451-2471.
- [25] Greff K, Srivastava R K, Koutnik J, et al. LSTM: a search space odyssey[J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(10): 2222-2232.
- [26] Vorontsov M A, Carhart G W, Cohen M, et al. Adaptive optics based on analog parallel stochastic optimization: analysis and experimental demonstration[J]. Journal of the Optical Society of America A, 2000, 17(8): 1440-1453.
- [27] Weyrauch T, Vorontsov M A. Atmospheric compensation with a speckle beacon in strong scintillation conditions: directed energy and laser communication applications[J]. Applied Optics, 2005, 44(30): 6388-6401.
- [28] Zommer S, Ribak E N, Lipson S G, et al. Simulated annealing in ocular adaptive optics[J]. Optics Letters, 2006, 31(7): 939-941.
- [29] Yang P, Ao M W, Liu Y, et al. Intracavity transverse modes controlled by a genetic algorithm based on Zernike mode coefficients[J]. Optics Express, 2007, 15(25): 17051-17062.
- [30] Yin X L, Chang H A, Cui X Z, et al. Adaptive turbulence compensation with a hybrid input-output algorithm in orbital angular momentum-based free-space optical communication[J]. Applied Optics, 2018, 57(26): 7644-7650.
- [31] Chang H, Yin X L, Cui X Z, et al. Adaptive optics compensation of orbital angular momentum beams with a modified Gerchberg-Saxton-based phase retrieval algorithm[J]. Optics Communications, 2017, 405: 271-275.
- [32] Li M, Li Y P, Han J W. Gerchberg-Saxton algorithm based phase correction in optical wireless communication[J]. Physical Communication, 2017, 25: 323-327.
- [33] 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.
- [34] 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.
- [35] Dean B H, Aronstein D L, Smith J S, et al. Phase retrieval algorithm for JWST Flight and Testbed Telescope[J]. Proceedings of SPIE, 2006, 6265: 626511.
- [36] Paine S W, Fienup J R. Machine learning for improved image-based wavefront sensing[J]. Optics Letters, 2018, 43(6): 1235-1238.
- [37] Byrd R H, Lu P H, Nocedal J, et al. A limited memory algorithm for bound constrained optimization[J]. SIAM Journal on Scientific Computing, 1995, 16(5): 1190-1208.
- [38] 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.
- [39] Tan M X, Le Q V. Efficientnet: rethinking model scaling for convolutional neural networks[C]//Proceedings of the 36th International Conference on Machine Learning 2019, June 9-15, 2019, Long Beach, California, USA. Cambridge: JMLR, 2019: 6105-6114.
- [40] Nishizaki Y, Valdivia M, Horisaki R, et al. Deep learning wavefront sensing[J]. Optics Express, 2019, 27(1): 240-251.
- [41] Chollet F. Xception: deep learning with depthwise separable convolutions[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 1800-1807.
- [42] Jin Y C, Chen J J, Wu C X, et al. Wavefront reconstruction based on deep transfer learning for microscopy[J]. Optics Express, 2020, 28(14): 20738-20747.
- [43] Sun B C, Saenko K. Deep CORAL: correlation alignment for deep domain adaptation[M]//Hua G, Jégou H. Computer vision-ECCV 2016 workshops. Lecture notes in computer science. Cham: Springer, 2016, 9915: 443-450.
- [44] Andersen T, Owner-Petersen M, Enmark A. Neural networks for image-based wavefront sensing for astronomy[J]. Optics Letters, 2019, 44(18): 4618-4621.
- [45] Wu Y, Guo Y M, Bao H A, et al. Sub-millisecond phase retrieval for phase-diversity wavefront sensor[J]. Sensors, 2020, 20(17): 4877.
- [46] 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.
- [47] 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.
- [48] Mukundan R, Ong S H, Lee P A. Image analysis by Tchebichef moments[J]. IEEE Transactions on Image Processing, 2001, 10(9): 1357-1364.
- [49] 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.
- [50] Lu C D, Tian Q H, Zhu L, et al. Mitigating the ambiguity problem in the CNN-based wavefront correction[J]. Optics Letters, 2022, 47(13): 3251-3254.
- [51] 师亚萍, 刘绳牢. 提高夏克-哈特曼波前传感器光斑质心的定位精度[J]. 激光与光电子学进展, 2017, 54(8): 081201.
- Shi Y P, Liu C L. Positioning accuracy improvement of spot centroid for shack-hartmann wavefront sensor[J]. Laser & Optoelectronics Progress, 2017, 54(8): 081201.
- [52] 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.
- [53] 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.
- [54] Swanson R, Lamb M, Correia C, et al. Wavefront reconstruction and prediction with convolutional neural networks[J]. Proceedings of SPIE, 2018, 10703: 107031F.
- [55] Barchers J D, Fried D L, Link D J. Evaluation of the performance of Hartmann sensors in strong scintillation[J]. Applied Optics, 2002, 41(6): 1012-1021.
- [56] Akondi V, Steven S, Dubra A. Centroid error due to non-uniform lenslet illumination in the Shack-Hartmann wavefront sensor[J]. Optics Letters, 2019, 44(17): 4167-4170.
- [57] 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.
- [58] Huang G, Liu Z, Van Der Maaten L, et al. Densely connected convolutional networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 2261-2269.
- [59] 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.
- [60] Zhang Z X, Liu Q J, Wang Y H. Road extraction by deep residual

- U-net[J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 15(5): 749-753.
- [61] Antonello J. Optimisation-based wavefront sensorless adaptive optics for microscopy[EB/OL]. (2014-11-10)[2023-01-02]. <https://repository.tudelft.nl/islandora/object/uuid:f98b3b8f-bdb8-41bb-8766-d0a15dae0e27?collection=research>.
- [62] Dai G M. Wavefront optics for vision correction[M]. Bellingham: SPIE Press, 2008.
- [63] Hu S W, Hu L J, Gong W, et al. Deep learning based wavefront sensor for complex wavefront detection in adaptive optical microscopes[J]. *Frontiers of Information Technology & Electronic Engineering*, 2021, 22(10): 1277-1288.
- [64] de Bruijne B, Vdovin G, Soloviev O. Extended scene deep learning wavefront sensing[J]. *Journal of the Optical Society of America A*, 2022, 39(4): 621-627.
- [65] Ragazzoni R, Farinato J. Sensitivity of a pyramidal Wave Front sensor in closed loop adaptive optics[J]. *Astronomy and Astrophysics*, 1999, 350: L23-L26.
- [66] Véronaud C. On the nature of the measurements provided by a pyramid wave-front sensor[J]. *Optics Communications*, 2004, 233(1/2/3): 27-38.
- [67] Chen H, Wei L, He Y, et al. Deep learning assisted plenoptic wavefront sensor for direct wavefront detection[J]. *Optics Express*, 2023, 31(2): 2989-3004.
- [68] Jiang P Z, Xu J P, Liang Y H, et al. Comparison of the Shack-Hartmann and plenoptic sensor in closed-loop adaptive optics system[J]. *Optical Engineering*, 2016, 55(3): 033105.
- [69] Clare R M, Lane R G. Phase retrieval from subdivision of the focal plane with a lenslet array[J]. *Applied Optics*, 2004, 43(20): 4080-4087.
- [70] Clare R M, Lane R G. Wave-front sensing from subdivision of the focal plane with a lenslet array[J]. *Journal of the Optical Society of America A*, 2005, 22(1): 117-125.
- [71] Li Z Q, Li X Y, Liang R G. Random two-frame interferometry based on deep learning[J]. *Optics Express*, 2020, 28(17): 24747-24760.
- [72] Whang A J W, Chen Y Y, Chang C M, et al. Prediction technique of aberration coefficients of interference fringes and phase diagrams based on convolutional neural network[J]. *Optics Express*, 2020, 28(25): 37601-37611.
- [73] Liu X, Yang Z M, Dou J T, et al. Fast demodulation of single-shot interferogram via convolutional neural network[J]. *Optics Communications*, 2021, 487: 126813.
- [74] Lin X, Rivenson Y, Yardimci N T, et al. All-optical machine learning using diffractive deep neural networks[J]. *Science*, 2018, 361(6406): 1004-1008.
- [75] Goi E, Schoenhardt S, Gu M. Direct retrieval of Zernike-based pupil functions using integrated diffractive deep neural networks[J]. *Nature Communications*, 2022, 13: 7531.
- [76] Pan X S, Zuo H, Bai H, et al. Real-time wavefront correction using diffractive optical networks[J]. *Optics Express*, 2023, 31(2): 1067-1078.

## Research Progress and Prospect of Adaptive Optics Based on Deep Learning

Hu Yiwen<sup>1</sup>, Liu Xin<sup>1</sup>, Kuang Cuifang<sup>1,2</sup>, Liu Xu<sup>1,2</sup>, Hao Xiang<sup>1\*</sup>

<sup>1</sup>*College of Optical Science and Engineering, Zhejiang University, Hangzhou 310027, Zhejiang, China;*

<sup>2</sup>*Research Center for Intelligent Sensing, Zhejiang Lab, Hangzhou 311100, Zhejiang, China*

### Abstract

**Significance** Adaptive optics (AO) technology enhances imaging quality by measuring and compensating for wavefront errors. It has been widely used in ground-based telescopes, biological imaging, ocular aberration correction, and laser communication, and so on.

Current AO systems can be categorized into two groups depending on the presence or absence of a wavefront sensor (WFS). Wavefront sensorless (WFSless) AO technology acquires the pupil phase via a retrieval algorithm based on the light intensity distribution. This type of technology can be divided into two kinds: single-image-based and phase-diversity-based technology. Single image-based technology measures the wavefront errors through a single intensity image. However, the phase distribution obtained from a solitary intensity image follows a one-to-many mapping relationship, resulting in limited accuracy. On the other hand, the phase-diversity-based AO technique can determine the phase distribution of the optical field on the input plane by collecting image information of the focal plane and the defocusing plane, resulting in a higher detection accuracy. However, a large number of iterations and measurements are required to obtain optimal results using traditional WFSless AO technology, making it unsuitable for high-speed and real-time scenarios. WFS AO technology employs a WFS based on the interference principle or a traditional geometric optics principle to measure the wavefront. Examples of WFSs used include phase-shifting interference WFSs, Shack-Hartmann WFSs (SHWFSs), and pyramid WFSs (PyWFSs). A high measurement accuracy is achieved using the traditional phase-shifting interference WFS method, but its real-time performance is suboptimal and is susceptible to environmental disturbances. The SHWFS is widely used in AO systems due to its simple structure and ease of operation. However, as a result of its pupil segmentation mechanism, the spatial resolution of the image is low and the dynamic range is small. While the PyWFS can detect weaker light than SHWFS AO technology, it is expensive and has a small linear range in the unmodulated mode.

Recently, the rapid development of artificial intelligence has accelerated development in various fields. Deep learning technology, a significant branch of artificial intelligence, has exhibited remarkable capabilities in search, data mining, machine translation, and speech recognition. Deep learning algorithms are founded on artificial neural networks, which optimize weights and biases based on the given sets of samples. The neural network, after being trained with vast amounts of data, can accurately establish



the input-output relationship. Despite the prolonged training time, results can be inferred quickly, making it useful in a multitude of technical domains. The combination of AO and deep learning technology is expected to overcome the issues encountered in conventional AO techniques. It is hypothesized that deep learning can lead to faster and more precise wavefront correction, thereby enhancing the performance of AO technology.

**Progress** This review introduces several popular artificial neural networks (Fig. 1) used in deep learning. The ways in which deep learning has been combined with AO technology are classified into two categories: techniques with and techniques without WFS. The WFSless category is subdivided into single-image-based (Figs. 3–4) and phase-diversity-based (Figs. 5–6) technologies, while the WFS category includes examples of SHWFSs (Figs. 7–9) and other WFS technologies combined with deep learning. Moreover, the review introduces a new diffraction neural network (Fig. 10), building on the traditional neural network, and provides examples of how this diffraction neural network has been combined with AO technology. The review notes that, over the past five years, examples of deep learning combined with AO technology have focused on improving the real-time performance and accuracy of traditional AO techniques. Finally, the review discusses the future development directions for deep learning-based AO technology.

**Conclusions and Prospects** Utilizing deep learning with WFSless AO technology provides several favorable advantages, such as its simple structure and low cost. While the single-image-based method only uses one image to correct the aberration, the corresponding phase of the intensity image reveals a one-to-many mapping, ultimately resulting in inaccurate calculations. On the other hand, the phase-diversity-based method uses two images with known phase differences to determine the size of the aberrations, yielding more accurate results than via the single-image-based method. Within the WFS AO technology field, numerous SHWFS-based methods exist. With a focus on improving the accuracies of centroid position and wavefront reconstruction, the application of deep learning networks has accelerated and further improved accuracy. Wavefront measurement methods based on sensors other than the SHWFS have gradually been integrated with deep-learning technology.

In the future, deep learning algorithms will be combined with other technologies, including reinforcement learning, and applied to other types of sensors such as the PyWFS to further enhance AO performance. Furthermore, AO will likely be integrated with a novel optical neural network to optimize its performance. Despite the growing body of literature on deep-learning based AO, most studies have been limited to simulation data; thus, it is imperative to evaluate deep-learning based AO using real-world scenarios. Moreover, while current AO technology focuses on the correction of point-source wavefront errors, the detection of extended-source wavefront errors should also be explored in future developments.

**Key words** laser optics; adaptive optics; deep learning; artificial neural network; wavefront correction