



·激光大气传输技术·综述·

基于深度学习的自适应光学波前传感技术研究综述

李自强^{1,2}, 李新阳^{1,2}, 高泽宇^{1,2}, 贾启旺^{1,2}

(1. 中国科学院 自适应光学重点实验室, 成都 610209; 2. 中国科学院 光电技术研究所, 成都 610209)

摘 要: 波前传感是自适应光学系统的重要组成部分, 在地基大口径望远镜、激光大气传输、无线光通信、激光驱动核聚变等领域发挥了关键作用, 同时也常应用于自由曲面的光学测量中。与此同时, 深度学习作为一种较为通用的前沿技术, 成功在计算机视觉、自然语言处理等众多领域取得了革命性进展。使用深度学习的方法改进自适应光学系统中的波前传感器, 以期实现更精准的波前探测, 以及适应更复杂的应用场景是自适应光学的发展趋势, 也是深度学习应用领域的一个新课题。介绍了深度学习在自适应光学波前传感中的应用现状, 主要分析了在相位反演波前传感器和哈特曼波前传感器中的研究特点, 并在最后进行了总结和展望。

关键词: 自适应光学; 深度学习; 波前传感; 相位反演; 哈特曼波前传感器

中图分类号: O43; TP18

文献标志码: A doi: 10.11884/HPLPB202133.210158

Review of wavefront sensing technology in adaptive optics based on deep learning

Li Ziqiang^{1,2}, Li Xinyang^{1,2}, Gao Zeyu^{1,2}, Jia Qiwan^{1,2}

(1. Key Laboratory on Adaptive Optics, Chinese Academy of Sciences, Chengdu 610209, China;

2. Institute of Optics and Electronics, Chinese Academy of Sciences, Chengdu 610209, China)

Abstract: Wavefront sensing is an important part of adaptive optics system, which plays a key role in the fields of ground-based telescopes, laser transmission in atmosphere, wireless optical communication, laser nuclear fusion, and freeform surface optical measurement etc. Meanwhile, as a general advanced technology, deep learning has made revolutionary progress in many fields such as computer vision, natural language processing and so on. Using deep learning method to improve the wavefront sensor in adaptive optics system to achieve more accurate wavefront detection and adapt to more complex application scenarios is the development trend of adaptive optics, and also a new topic in the field of deep learning. This paper, introduces the application status of deep learning in adaptive optics wavefront sensing in detail. It also analyzes the research characteristics of different types of wavefront sensors, such as phase retrieval wavefront sensor and Shack-Hartmann wavefront sensor, and makes a summary at the end.

Key words: adaptive optics; deep learning; wavefront sensing; phase retrieval; Shack-Hartmann wavefront sensor

自适应光学(AO)是一种集光学、机械、电子、计算机和自动控制于一身的新兴技术,解决了时间和空间变化的光学像差控制问题^[1]。自适应光学技术的应用使得光学系统具有自动适应外界变化、克服动态扰动影响,从而始终保持良好工作状态的能力,因此被广泛应用于天文观测、激光传输、激光光束质量改善、激光驱动核聚变、自由空间光通信、生物医学等领域^[2-7]。经典的自适应光学系统一般包括波前传感、波前控制、波前校正三个基本部分,这三部分组成了一个实时的控制系统:利用波前传感器测量波前动态误差;用快速的电子系统进行计算和控制;通过能动器件进行实时的波前校正^[8]。其中波前传感为波前控制和波前校正提供了畸变波前的相位信息,因此不仅决定了系统的校正精度,很大程度上还影响着系统的稳定性。波前传感器按照工作原理可以大致划分为三

* 收稿日期:2021-04-22; 修订日期:2021-07-08

基金项目:国家自然科学基金项目(62005286)

作者简介:李自强(1994—),男,博士,博士后,从事自适应光学波前传感及智能控制的研究。

通信作者:李新阳(1971—),男,博士,研究员,博士生导师,从事自适应光学、激光技术等多方面的研究工作。

类: 基于强度测量的结果进行相位反演的波前传感器、直接测量波前斜率或曲率的波前传感器和基于干涉原理的波前传感器。这三类传感器的结构和原理迥然不同, 其中前两种波前传感器因为对硬件要求较低而在自适应光学中最为广泛使用。与此同时, 人工智能特别是深度学习技术在近年来受到了从学界到工业界的广泛关注。所谓“深度学习”(Deep Learning), 脱胎于机器学习中的“人工神经网络”(ANN), 建立了一种类似人脑神经网络的结构, 在数学本质上是基于误差反向传播和梯度下降算法的一种参数的迭代和优化^[9-10]。得益于网络结构的不断进化、互联网时代的大数据量以及计算机算力的不断增长, 深度学习技术彰显出强大的非线性问题拟合能力, 其与自适应光学波前传感技术的结合也在近年来成为研究的热点。本文归纳了该领域最新的研究成果, 并重点介绍深度学习在相位反演波前传感器和哈特曼波前传感器中的应用。

1 深度学习简述

1.1 深度学习的发展历程

“深度学习”起源于“人工神经网络”, 它的基本特点是试图模仿大脑的神经元之间传递以及处理信息的模式。ANN的历史可以追溯到20世纪40年代, 这一时期虽然还没有出现机器学习的概念, 但是基于对心理学、脑科学和神经科学的研究, 已经发展出计算机科学中神经元模型的雏形。一般认为, 神经网络技术迄今为止已经经历了3次发展浪潮(如图1所示): 20世纪40年代到60年代, 神经网络的雏形出现在控制论中, 心理学家 W. S. McCulloch 和数理逻辑学家 W. Pitts 建立了神经元的数学模型, 称为 MP 模型^[11]; 1949 年心理学家 D. O. Hebb 提出了 Hebb 学习率, 启发计算机科学家们用调整权值的方法来让机器自主学习^[12]。1958 年 F. Rosenblatt 提出了一个基于单层神经网络的线性分类器, 命名为“感知机”(Perceptron), 从而推动了研究神经网络的第一次浪潮^[13]。1969 年 M. Minsky 用详细的数学推理证明了感知机的弱点, 尤其是对异或这样的简单分类任务都无法解决^[14], 而多层神经网络计算量过大没有有效的学习算法, 有关神经网络的研究陷入了冰河期, 被称为“AI Winter”。后来 G. Hinton 等人又提出了反向传播(BP)算法^[15], 加上 Hopfield 网络的良好表现, 带动了业界使用两层神经网络进行研究的第二次浪潮。20世纪90年代中期, 由 V. Vapnik 等人发明的支持向量机(SVM)打败了神经网络, 神经网络的研究再次进入低潮。直到2006年, 深度神经网络的出现才真正冠以深度学习之名, 掀起第三次浪潮。

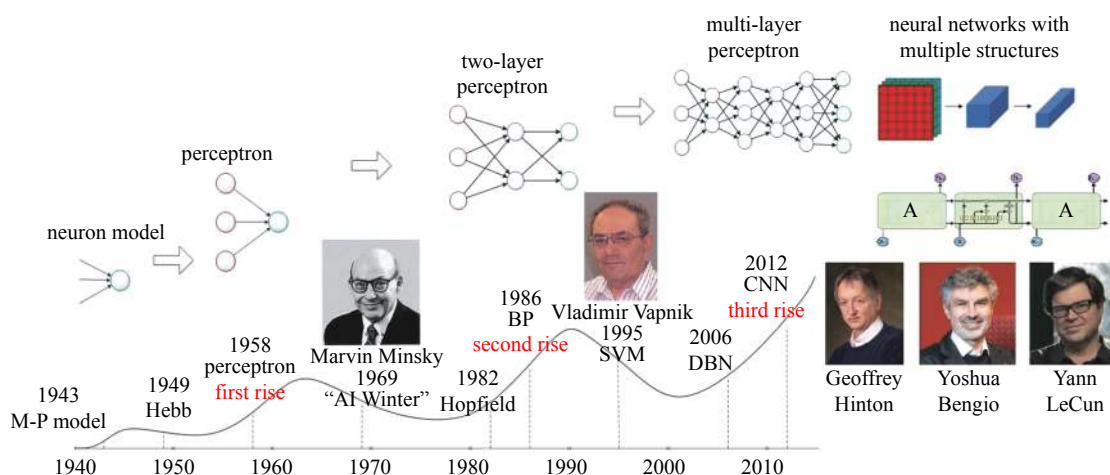


Fig. 1 Development of Deep Learning

图1 深度学习发展历程

1.2 人工神经网络的基本原理

人工神经网络的基本运算单元叫做“神经元”或者称为“结点”, 这种抽象的神经元模型参考了生物神经元的结构, 称为 MP 模型。在此模型中, 每个神经元包含有多个输入, 1 个输出, 以及 2 种计算功能, 分别为求和以及施加激活函数。神经元与神经元之间可能会存在连接, 每个连接上都有一个“权值”或者叫“权重”。因此这种神经元可以看作是一个计算与存储单元, 也就是神经元对输入的数据进行计算、暂存计算结果, 并传递到下一个神经元。把许多个这样的神经元按一定的层次结构连接起来, 就得到了人工神经网络, 它使用连续多层神经元的计算来近似实现输入空间到输出空间的最佳对应关系, 如图 2(a) 所示。神经网络中的每一个神经元都计算前一层输出的加权和, 然后有选择的施加一个激活函数, 如图 2(b), 并可以被表达为式(1)所示的数学表达式。

$$Y = g\left(\sum x_j w_j + b\right) \quad (1)$$

式中： Y 是神经元的输出， x 为输入， w 是连接上的权值， b 是偏置， g 是激活函数。

公式(1)表示了已知权值的情况下从输入得到输出的计算过程，这一过程被称为“前向传播”。在神经元的MP模型刚提出的时候，其各个连接上的权值都是固定的。1949年心理学家Hebb提出了Hebb学习率，认为人脑神经细胞的突触(也就是连接)上的强度是可以变化的，启发了人们开展调整人工神经网络权值的研究。1986年，Rumelhar和Hinton等人提出了反向传播(BP)算法，解决了两层神经网络调整权值所需要的复杂计算量问题。BP算法的核心是数学求导的链式法则，先通过损失函数计算出输出和标签之间的误差，并逐级往输入层传递该误差，计算出每层中权重的梯度后，就能利用梯度下降算法不断迭代来优化各个权重的值，这种通过调整权值使神经网络的输出不断逼近标签值的过程就叫做神经网络的训练。ANN的网络结构、损失函数的构造、激活函数的选取以及训练算法的选择都是影响人工神经网络性能的关键参数，需要根据不同的任务需求进行具体的分析。

2 基于测量光强分布的相位反演

从测量得到的光强分布信息求解对应的相位信息，叫做相位反演技术。所谓相位反演，或称为相位恢复(PR)，按照Gonsalves的定义，广义上可以指一切从光强信息恢复出相位信息的技术，但有时也特指只使用一幅光强图恢复相位信息^[16-17]。当使用两幅光强图进行相位恢复时，通常其中一幅图为焦平面上的光强图，另一幅为离焦面光强图，这种方法就被称为相位差反演(PD)。由于仅仅需要光强图，与其他波前传感器相比，相位反演具有对光学硬件要求低的优点。

最早将深度学习技术应用到自适应光学领域的是20世纪90年代初期美国亚利桑那大学的J. R. P. Angel、P. Wizinowich、M. Lloyd-Hart和Thermo Electron Corp.公司的D. Sandler等人^[18]。1990年，为了解决地基多镜面望远镜(MMT)由于受到湍流以及多个镜面间倾斜像差带来的影响，Angel等人在Nature杂志上刊文，使用人工神经网络来校正活塞(piston)和倾斜(tip/tilt)像差。最初的MMT是亚利桑那大学史都华天文台(Steward Observatory)的一台多镜面望远镜，由6块直径1.8 m的独立镜面组成，每一块镜面都有自己独立的次镜。但是多个独立的镜面会带来各自的倾斜像差，加上大气湍流扰动，采集到的图像并不能达到衍射极限，需要AO系统进行校正。然而MMT镜面的不连续导致了波前的不连续，使得剪切干涉仪、哈特曼波前传感器、曲率传感器等常用的波前检测手段在该望远镜中难以使用。为了解决MMT中的波前探测难题，一个基于人工神经网络的波前传感器被提出。与经验丰富的科学家能从点扩散函数(PSF)的形状和特征中辨认出特定的像差类型相似，这个神经网络使用一对同时采集的焦面图像和离焦面图像作为输入，然后输出对独立子镜的控制信号。该网络一共有三层，其中输入层338个结点，输入了两幅13×13分辨率的图像(焦面图像和离焦面图像)，隐藏层有150个结点。因为MMT有6个镜面，每个镜面有独立的 x 方向倾斜、 y 方向倾斜和活塞像差，所以输出层有18个结点，输出为每个镜面的控制信号。使用该方法去除倾斜和活塞像差后，在长曝光条件下使MMT获得了接近衍射极限的观测图像。Lloyd-Hart等人在1992年的实验中对该网络进行了改进^[19]，改进后的神经网络有300个输入结点，输入两幅15×10的图像。有36个隐藏层结点和6个输出结点。利用该网络进行波前倾斜和活塞像差的在线测量，使用MMT的两个独立子镜在2.2 μm波长下对恒星进行实时成像。具体的光路如示意**图3**所示。

上面的方法是直接输出对变形镜的控制信号，能够校正的像差类型十分有限。1991年，Sandler等人在Nature杂志上报道了使用神经网络波前探测器在美国空军菲利普斯实验室1.5 m单镜面望远镜上的实验结果^[20]，并且在1993年这一技术也被应用到哈勃太空望远镜中来估计静态像差^[21]。由于是单镜面望远镜，为了获得更多的像差信息，神经网络不再直接输出控制信号，而是输出波前的第4~11阶Zernike系数，这样就不再是只能校正倾斜和活塞像差。具体的网络结构如**图4**所示。

以上这种输入光强图，经过神经网络的运算，然后输出Zernike系数的方式，成为了使用深度学习技术进行相位差反演的基本架构，后续的研究基本都是按照这种框架进行，最大的改进是光电探测器件的不断优化、网络结构的更新以及计算机算力的不断增强。




Fig. 2 ANN and the basic operation of a neuron

图2 神经网络及神经元的运算




Fig. 3 Optical path of using wavefront sensor based on ANN to correct the aberration of two independent mirrors of MMT

图 3 使用神经网络波前传感器校正 MMT 两块独立镜面的像差的光路图^[19]

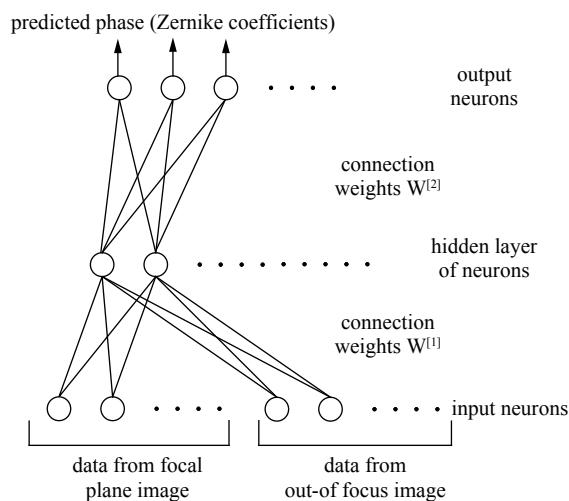


Fig. 4 Architecture of wavefront sensor based on ANN

图 4 一种神经网络波前传感器的网络架构^[20]

在 Angel 和 Sandler 等人首次将人工神经网络技术引入 AO 的 20 世纪 90 年代, 受限于当时的光电探测器发展水平, 采集得到的焦面和离焦面图像分辨率都很低, 这显然会对 Zernike 系数的估计带来一定误差。因此基于人工神经网络的波前传感器需要输入更高分辨率的图像, 这意味着输入层的结点数会急剧增加。同时为了估计更高阶数的 Zernike 系数, 输出层的结点数也需要增加。这导致原来的三层网络结构异常庞大, 需要优化的参数爆炸性增长, 不仅需要更长的训练时间、更多的训练数据, 还有可能因为过拟合而导致神经网络训练失败。为了解决这个问题, 越来越多的研究者把目光投向了卷积神经网络(CNN)。在 Angel 等人的论文中, 输入层是将两幅图像的所有像素展开组成一个向量, 每两层之间的所有结点都是有边相连的, 这种网络结构称为全连接神经网络, 也叫多层感知机(MLP)。全连接神经网络处理图像的最大问题在于参数太多, 而在卷积神经网络中, 两幅图像在深度上进行连接组成一个三维的张量, 输入的图像块在深度方向上由很多通道组成, 每一个通道都对应多个结点, 相邻两层之间只有部分结点相连, 结点的权重表现为卷积核的形式, 即一个方形的滤波器, 这个滤波器按照设定好的步长对前一层进行卷积操作, 实现了参数共享。在卷积层后面一般还会有池化层, 池化层不会改变三维张量的深度, 但是它可以缩小张量的尺寸。池化层进行下采样进一步减少结点数, 从而减小参数规模、降低计算复杂度, 也可以防止过拟合。卷积神经网络诞生后在图像分类、检测、跟踪、语义分割等领域大放异彩, 通过调整和组合卷积层、池化层的参数以及连接方式, 先后出现了多种不同的网络结构, 并且也被应用在了波前传感当中。例如 2018 年安徽农业大学的马慧敏等对 AlexNet^[22] 进行改造, 仿真生成了不同大气湍流参数下的焦面与离焦面图像, 将这些图像作为输入, 训练输出前 35 阶 Zernike 系数^[23]。与之类似, 2020 年中国科学院光电技术研究所的吴玉和郭友明等对 LeNet-5^[24] 进行改造并将改造后的网络命名为 PD-CNN, 也是输入焦面与离焦面图像, 输出 13 阶 Zernike 系数^[25]。值得注意的是, 吴玉和郭友明的研究与马慧敏的工作有所不同, 其训练所用的数据集并不是通过仿真得来, 而是使用一个液晶空间光调制器(SLM)生成的真实相位, 并通过实验采集焦面与离焦面的真实图像, 这样做的好处是避免了仿真和真实世界之间的差异性问题。在进行实验验证时, 使用训练完成的神经网络对一个峰谷值(PV)为 1.188λ , 均方根值(RMS)为 0.226λ 的波前进行测量, 最终复原后的波前残差如图 5(a) 所示, 其残差的 PV 为 0.078λ , RMS 为 0.012λ , 如图 5(b) 所示是该神经网络输出的 Zernike 系数与波前的真实 Zernike 系数的对比。

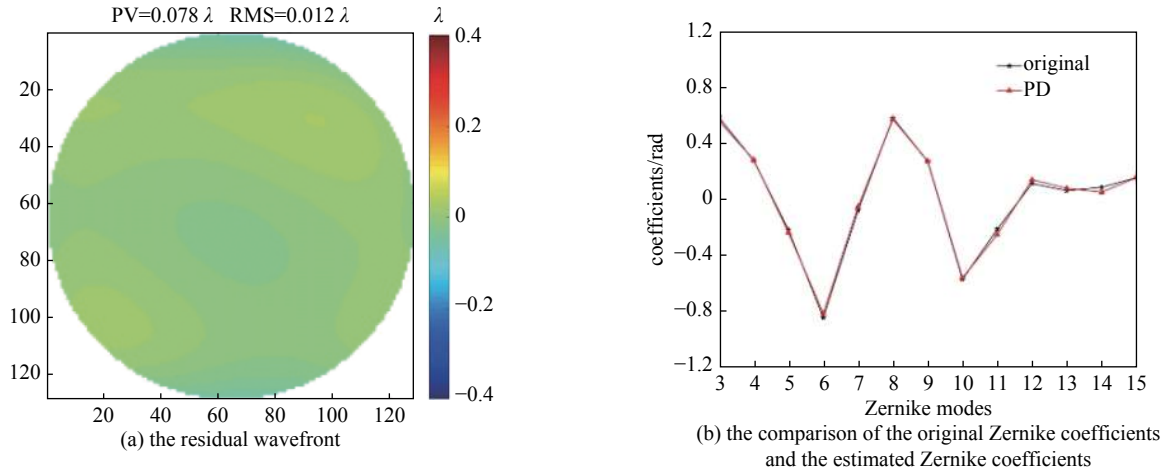


Fig. 5 Result of the PD model of PD-CNN

图 5 PD-CNN 同时输入焦面图像和离焦图像的测试结果

一般认为, 深度学习的成功离不开三个要素: 一是数据; 二是算法; 三是算力。其中大量的多样化的数据可以说是深度学习获得成功的首要支撑, 然而深度学习技术在消费互联网以外的工业领域中应用的时候, 并没有现成的通用数据集, 因此深度学习技术在 AO 中应用面临的最大的困难是数据的问题。首先是数据量小的问题, 大数据量在目标检测、图像语义分割等计算机视觉领域的研究中很常见, 并且有公开的通用数据集。但在 AO 系统的研究中其数据基本上不能通用, 只能由研究者针对不同的系统自行采集数据。然而在实际系统中能获得真实数据的量通常又比较小, 这就导致了难以使用真实数据训练较大规模的神经网络。第二个问题, 是即便使用真实数据也很难对真实数据进行真值的标注。目前在波前传感领域使用的深度学习技术都还属于监督学习的范畴, 因此数据集都必须进行真实标签的标注。如果使用真实数据制作训练集, 以使用 SLM 生成待测相位为例, 数据集的质量就完全取决于 SLM 的精度, 如果实验中使用的 SLM 存在一个恒定的系统误差, 那么训练好的网络也会存在一个恒定的误差。使用仿真数据训练网络是解决数据量小以及真值标注困难较为可行的方法之一, 由于是仿真生成的, 数据的量可以没有上限, 同时真值也是完全可知的, 但是仿真数据集就面临着仿真和真实世界之间的差异问题。在应用深度学习技术的时候, 测试集与训练集应该是独立同分布的 (i.i.d.), 也就是训练数据要与真实的待测数据尽可能地“像”, 这就对训练集提出三个要求: 一是训练数据要符合真实的物理模型; 二是数据最好能有较为明显的特征; 三是数据集要足够大并且足够多样化, 比如有多种不同噪声水平下的数据, 从而提高网络的泛化能力。

为了降低神经网络对输入图像的质量和数量的要求, 2018 年中国科学院长春光学精密机械研究所鞠国浩等则不再直接输入原始的光强分布图像, 而是输入焦面和离焦面图像的几何特征, 这种特征提取可以看作是对原始图像的一种压缩和概括, 可以有效降低训练所需的数据量^[26]。具体来说, 就是先计算焦面和离焦面图像的切比雪夫矩, 然后输入的就是切比雪夫矩这样的一维特征向量而不是二维的原始强度图像, 不仅能大大减小输入层的大小从而压缩网络规模, 也减轻了神经网络面临的任务复杂度, 因此在该文中使用的是全连接神经网络而不是卷积神经网络。通过仿真生成训练集, 以 Zernike 系数作为标签对网络进行训练。网络训练完成后, 使用图 6 所示的实验平台进行验证, 其中的干涉仪有两个作用: 一是测量待测相位作为对比真值; 二是作为一个标准光源, 通过移动平移平台, 可以分别得到一幅焦面光强图和离焦面光强图, 从而通过神经网络计算相位。

除了使用深度学习技术进行相位差反演, 近年来也出现了仅使用焦面图像进行相位反演的研究。如 2016 年吉林大学李兆坤等人提出在无线光通信领域使用一幅焦平面图像





Fig. 6 Sketch (a) and physical map (b) of the optical system used in the experiment

图 6 (a) 是实验验证概念图, (b) 是实验实物图^[26]

进行无波前校正^[27],该方法将焦平面图像分为16个子区域,将前18阶Zernike系数划分为1536个子空间,构造单隐层神经网络估计前18阶Zernike系数。2018年美国罗切斯特大学的S. W. Paine和J. R. Fienup等人使用Inception v3网络架构^[28],仅通过一幅焦面光强图来估计波前相位,结果显示这种结构能够对波前像差进行一个有效的初始预测^[29]。2019年日本大阪大学的Y. Nishizaki等人使用基于CNN的神经网络,同样实现了仅使用一幅光强图计算前32阶Zernike系数^[30]。为了校正自由空间光通信中的大气湍流相位,2021年华南理工大学元秀华等对预训练好的网络架构EfficientNet^[31]使用仿真大气湍流相位屏进行微调,也是使用一张光强图输出66个Zernike系数^[32]。可以看出这些相位反演的研究与相位差反演的研究在方法上是类似的,都是输入光强图,输出Zernike系数,只不过以上相位反演的研究期望仅从一幅光强图恢复波前相位。值得注意的是,仅有一张焦平面的光强图进行相位恢复在原理上就是存在相位模糊的,即便在相位连续的假设下也无法完全解决这一多解问题^[33-34],因此这类方法通常精度不高而且对应用场景有一定的限制,在没有从理论上证明单帧焦平面光强图在哪些应用场景中恢复出的相位是唯一的情况下,直接使用神经网络进行Zernike系数的预测具有一定的过拟合风险。同时,由于这些方法大多数都是端到端(end-to-end)的,即直接对一个神经网络输入焦平面图像然后输出Zernike系数,网络的不可解释性、可移植性和鲁棒性都不强,离高精度波前探测的应用要求还有一定的距离。

3 针对哈特曼波前传感器的改进

虽然波前探测有多种手段,德国海德堡大学C. A. Diez等人也曾研究过将神经网络应用于金字塔波前传感器^[35],中国科学院光电技术研究所的李自强、李新阳和美国亚利桑那大学的R. Liang也研究过将深度学习技术用于基于干涉的波前传感器^[36],但是AO系统中最为常见和实用的还是哈特曼波前传感器(SHWFS)。哈特曼波前传感器由微透镜阵列和光电探测器组成,微透镜阵列作为波前分割元件,对入射波前进行子孔径分割,并将每个子孔径内的波前聚焦在光电探测器上,通过探测每个子孔径光斑的质心位置能够计算出该子孔径波前的斜率,进而通过一定的波前重构算法恢复出整个波前。

3.1 哈特曼波前传感器的质心计算

子孔径质心位置的计算是哈特曼波前传感器复原相位的首要步骤,传统的质心检测算法是重心法(CoG),该方法在有噪声的情况下精度不高,更为严重的是,当光斑靠近子孔径边缘,质心的估计误差会迅速增大,这种由截断误差引起的非线性效应会大大限制哈特曼传感器的动态范围。为了解决这一问题,美国怀特-帕特森空军基地空军技术学院的D. A. Montera等人,于1996年第一次将人工智能技术应用到哈特曼波前传感器质心检测中^[37]。他们设计了一个单隐层全连接神经网络来检测质心位置,该神经网络输入层有16个结点,因为其使用的哈特曼传感器每个子孔径对应的CCD中包含4×4个像素,隐藏层有20个结点,使用双曲正切函数(Tanh)作为激活函数,输出层有两个结点,输出层不使用激活函数而是直接将隐藏层的输出进行线性叠加。也就是说,该神经网络将质心探测问题直接看作回归问题,输出分别是质心的x和y方向的坐标。Montera等人在仿真实验中生成了不同大气参数和信噪比条件下的一共两万张子孔径图像作为输入,使用相应图像的真实质心位置坐标作为标签,对网络进行训练,训练完成后独立生成两万张图像对该神经网络方法和传统CoG算法进行对比测试。仿真结果显示,神经网络方法要明显优于传统的CoG算法,尤其是在大动态范围的情况下。

2014年,来自巴西和智利的科学家A. T. Mello和D. Guzmán等人使用神经网络方法对产生了拉长效应的子孔径光斑进行质心检测^[38],并于2016年进行了实验验证^[39]。子孔径光斑的拉长效应是在激发信标光的过程中由于大气中间钠层有一定的厚度而导致的。在传统的AO系统中,入射光在经过变形镜的校正后会分为两部分,其中一部分用作成像,另一部分进入哈特曼传感器用于波前探测。但在天文观测领域,如果观测的星体并不十分明亮,这样的分光操作不仅会使成像的亮度不够,更有可能因光强不足而导致哈特曼传感器部分子孔径缺光,从而无法探测波前。通常的做法是寻找一颗与被测星体相邻而且亮度足够的自然星体作为信标,哈特曼传感器探测自然信标的波前,被测星体的光只用作成像。这种信标必须与被测星体十分邻近以保证两颗星体发出的光到达望远镜所经过的大气湍流是一致的。但并不是所有的情况下都能找到合适的自然信标,激光导引星技术的发展可以解决这一问题。使用波长为589 nm的激光聚焦在高度大约为90 km的大气中间钠层,能使其中的钠原子产生共振散射形成导星。但是大气中间钠层有一定的厚度,被激发的钠原子大约呈现出一个圆柱形。如图7所示,使用哈特曼传感器探测波前时,这个圆柱形的导星在中间子孔径形成一个圆形光斑,但是边缘子孔径上光斑被拉长,特别是在口径很大的望远镜比如极大望远镜(ELT)中,直接使用CoG算法检测光斑质心会带来较大误差。

一些学者提出使用匹配滤波^[40]或者相关跟踪^[41]的算法来探测拉长光斑的质心。但是匹配滤波算法需要光斑形状的参考图像,相关跟踪算法需要钠层密度分布作为参考。Mello 等人提出一种不需要其他信息的神经网络方法来检测拉长光斑的质心,该神经网络使用均方误差作为损失函数,因为每个子孔径中包含 16×16 个像素,因此输入层有 256 个结点,其隐藏层有 16 个结点,输出层有两个结点分别代表质心 x 和 y 方向的坐标。实验结果显示,在存在湍流的情况下,基于神经网络的方法对拉长光斑质心探测的精度远高于其他方法。但是由于实验过程中的训练数据量不大,加之该网络结构的规模较小导致其表征能力不足,对不同朝向的拉长光斑进行质心检测需要训练不同的神经网络。

以上的研究都是将质心检测看作回归问题,使用神经网络直接输出质心的坐标,但是回归问题神经网络要比分类问题神经网络更加难以收敛,训练所需的数据量也更大。2018 年,中国科学院光电技术研究所李自强和李新阳构造了一个名为夏克-哈特曼波前传感器质心探测神经网络 (SHNN) 的网络结构实现了在强光干扰以及极低信噪比情况下的哈特曼传感器质心探测^[42]。该神经网络同样使用单隐层全连接网络,每个子孔径包含 25×25 个像素点,因此输入层有 625 个结点。隐藏层根据干扰强度、信噪比大小以及运算时间的需求可选择 50 或者 900 个结点,隐藏层结点数越多,网络表征能力越强,但在训练时需要的数据量就越大,训练时间以及训练完成后的运算时间也越长。与 Montera 和 Mello 的方法不同,该神经网络输出层有 625 个结点,与输入层结点数一致。这是因为 Montera 和 Mello 的神经网络都是直接将质心探测问题看作回归问题,端到端地输出质心的坐标,因此使用均方误差作为损失函数。这种损失函数会使神经网络较难训练,尤其是在有强光干扰和极低信噪比的情况下,回归得到的质心位置会有比较大的误差。因此可以将质心探测的回归问题转换为 Softmax 多分类问题,不再直接回归质心坐标而是先找到质心所在的像素点,然后用加窗的重心法计算质心从而实现亚像素级精度的质心坐标计算。这种方法使用交叉熵作为损失函数,极大降低了训练的难度。Softmax 能够输出多个类别的相对概率,其公式如下:

$$Y_{\text{predicted}_i} = g(Z) = \frac{e^{z_i}}{\sum_{j=1}^n e^{z_j}} \quad (2)$$

式中: Z 是输出层在进入 Softmax 前的输出, $Y_{\text{predicted}}$ 是经过 Softmax 分类后输出的每个类别的概率。

在分类问题中,使用交叉熵而非均方误差作为损失函数能使训练过程更快收敛,该神经网络的损失函数如下:

$$J = - \sum Y \log Y_{\text{predicted}} + \lambda \sum \|w\|^2 \quad (3)$$

损失函数 J 由交叉熵和正则化项组成,其中 Y 是真实的标签,由独热码 (one-hot code) 表示,即质心所在的像素点为 1,其余的像素点为 0; $Y_{\text{predicted}}$ 是神经网络的预测输出, λ 是正则化系数, w 是网络的权值。

仿真和实验结果表明,该神经网络方法在有强光干扰的极端环境中探测精度明显优于 CoG 以及其他改进的 CoG 算法,如图 8(a) 的第一幅图所示是在暗室中使用哈特曼波前传感器对一个稳定的 532 nm 激光光源的波前测量,此时没有任何环境干扰光,并且信噪比很高,因此可以将第一幅图的 CoG 结果作为真实值 (Ground truth)。随后将暗室中的窗帘一点点拉开,将室外的白天天光引入哈特曼波前传感器。随着窗帘被逐渐拉开,干扰光的功率也越来越大,最终子孔径中干扰光的最大光强甚至可能超过信号光斑的峰值光强。此时分别使用隐藏层有 50 个结点的 SHNN-50 和 TCoG 算法计算子孔径中的质心坐标,如图 8(b) 所示,对比可以发现 SHNN 在强光干扰下依然能准确找到真实光斑的质心。随后使用 Zernike 模式法重构圆域内的波前,然后以没有环境光干扰时重构的波前为基准进行对比。表 1 给出了不同算法对所有子孔径进行光斑探测后的平均质心估计误差 (CEE) 和错误率 (False Rate),以及重构波前与原始波前相减后的残差的 PV 和 RMS。可以看出,在强干扰环境下 SHNN 的结果要比 TCoG




Fig. 7 Elongation of spots in the SHWFS. Here, r is the distance of the subaperture in the SHWFS from the center (as projected on to the primary mirror), h_0 is the average altitude of the sodium layer, σ_{NA} is the thickness of the sodium layer and z is the zenith angle

图 7 哈特曼波前传感器中的拉长效应。其中 r 是子孔径到中心的距离, h_0 是钠层的平均高度, σ_{NA} 是钠层的厚度, z 是天顶角^[33]

的结果好接近一个数量级。

3.2 波前重构及多传感器数据融合

上述的研究能够有效提高哈特曼传感器质心探测的精度,探测到质心后就能够计算出每个子孔径中的波前斜率从而进行波前重构。所谓波前重构,就是对探测到的斜率信息进行计算,进而得到波前相位信息或者能够表征相位信息的特征量(如各阶 Zernike 多项式的系数)。常用的波前重构方法有区域法和基于 Zernike 多项式的模式法,但是无论是区域法还是模式法,都难以对多个哈特曼传感器采集到的斜率信息进行融合。现代的大型光学系统如果要对大视场或者扩展目标进行波前校正,通常会使用多目标自适应光学技术(MOAO)。这是因为有限高度的人造信标只能对其高度以下到望远镜接收口径之间的圆锥体内的湍流进行采样,而圆锥体外的湍流未被采样,当望远镜增大到一定程度,钠导星的锥体效应会非常明显,需要采用多个导星对整个视场内的湍流进行采样,同时需要多个波前传感器,如图 9 所示。为了将这多个传感器的数据进行融合从而实现大气层析重建,一些学者提出了 LS(least squares matrix vector multiplication)^[43-44]以及 L+A(learn and apply)^[45]等算法。

早在 2006 年,德国海德堡大学的 H. Guo 等人就指出使用 ANN 构建的波前重构器比基于最小二乘拟合(LSF)以及奇异值分解(SVD)的波前重构方法更有优势^[46]。该波前重构器使用哈特曼传感器探测到的质心位置作为输入,输出波前的 Zernike 系数。但是上述研究仅使用一个哈特曼传感器的数据,并未进行多传感器融合。2012 年,以 J. Osborn、D. Guzmán 等为代表的由来自智利、西班牙、英国和法国的科学家组成的联合团队用神经网络的方法构建了一个大气层析重构器,并命名为卡门(Complex Atmospheric Reconstructor based on Machine lEarning, CARMEN)。最初的卡门是一个单隐层的神经网络^[47-48],隐藏层使用 Sigmoid 激活函数,网络结构示意图如图 10。

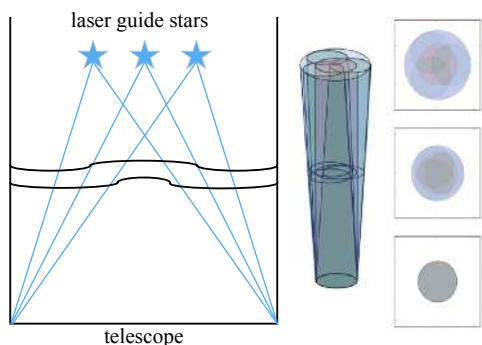


Fig. 9 Wavefront sensing by using multiple laser guide stars
图 9 使用多个激光导引星的波前探测

该网络输入的是三个哈特曼传感器的斜率,输入层共 222 个结点,隐藏层也有 222 个结点以保证有足够的特征映射能力,输出层有 27 个输出结点,输出不包含活塞像差在内的前 6 阶径向频率数的 Zernike 系数。仿真结果表明,训练完成后的卡门能融合三个哈特曼传感器的数据进行大气层析重建,并且在模拟校正中,其校正效果明显优于传统的 LS 和 L+A 算法,同时能有更好的噪声容忍度。该团队在后续的报道中在实验室验证了该方法^[49],并于 2014 年在 4.2 m William Herschel Telescope 天文望远镜的 CANARY 自适应光学系统中进行了实际实验^[50]。为了解决卡门运行时间较长的问题,该团队于 2017 年分别比较了不同深度学习框架(Caffe、Torch、Theano 以及 C/CUDA)下卡门的运行速度^[51-52],尝试使用图形处理器(GPU)进行加速,显著改进了卡门的训练和执行时间^[53]。2018 年,该团队继续使用多块 GPU 进行运算加速,并对算法并行化进行研究^[54]。

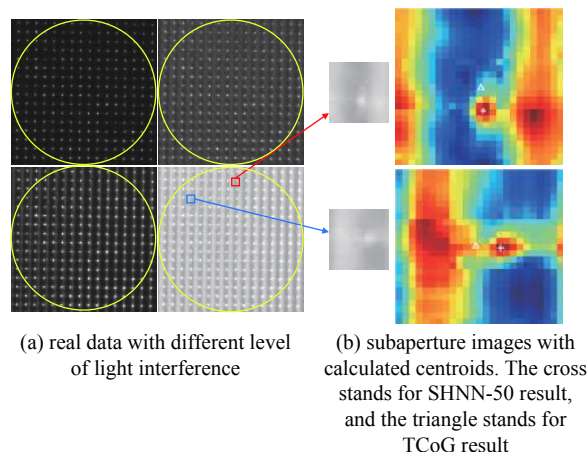


Fig. 8 Experimental result of centroid computation for Shack-Hartmann wavefront sensor in extreme situations based on the SHNN

图 8 基于神经网络 SHNN 对哈特曼传感器在强光干扰下进行质心探测的实验结果^[42]

表 1 实验结果

Table 1 Results of experiments

Methods	Performances			
	CEE/pixel	False Rate	PV/um	RMS/um
TCoG	4.5958	95.31%	2.6593	0.5349
SHNN-50	0.5250	1.17%	0.3107	0.0651




Fig. 10 CARMEN with MLP
图 10 全连接卡门示意图^[47]

上述全连接网络结构的卡门,其输入是对子孔径探测质心后计算的斜率,由于使用的是传统的改进 CoG 算法计算质心,这一提取质心并计算斜率的过程可能会带来较大的误差和信息丢失。2018 年, G3mez 和 Osborn 等人也成功将全连接卡门改进为卷积卡门(CARMEN as Convolutional Neural Network)^[55]。卷积卡门使用哈特曼传感器的整幅图像作为输入,既避免了质心提取和斜率计算过程中可能带来的信息丢失,也使得从哈特曼传感器的光斑阵列图到 Zernike 系数之间的整个计算过程全部由神经网络完成,实现了端到端的应用。该卷积卡门将 3 个哈特曼传感器的图像重叠为 3 通道的张量作为输入,经过 4 个卷积层、4 个池化层以及 1 个全连接层后输出,输出层有 72 个结点。仿真结果显示,卷积卡门的准确度优于全连接卡门。卷积卡门的网络拓扑结构示意图如图 11 所示。

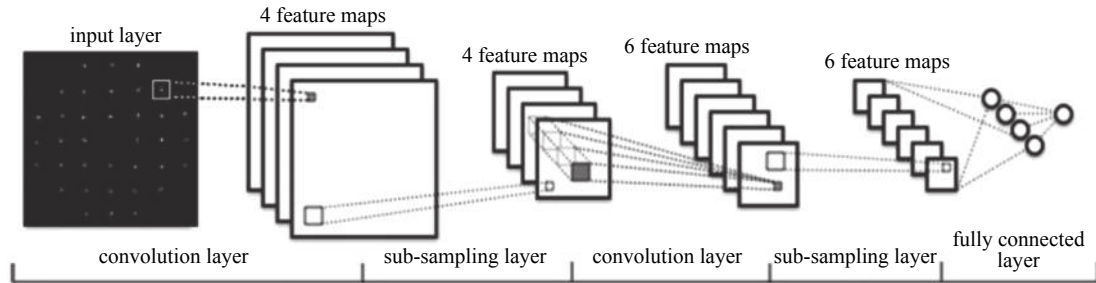


Fig. 11 Example of the topology of CARMEN with CNN

图 11 卷积卡门的网络拓扑结构示意图^[55]

除了进行多个传感器的数据融合, H. Guo 等人的研究也预示了使用深度学习技术替换传统波前重构算法从而提升相位预测精度的潜力。2019 年, 浙江大学胡乐佳和斯科等人为了克服生物组织成像过程中的折射率不均匀性带来的像差影响, 引入了自适应光学对像差进行校正, 并使用深度学习技术对哈特曼传感器进行算法上的改进^[56]。该改进方法被命名为 Learning-based Shack-Hartmann wavefront sensor (LSHWS), 与上述卷积卡门比较类似, LSHWS 也是构造一个卷积神经网络直接输入哈特曼传感器的光斑阵列图, 然后输出预测的 Zernike 系数, 不同之处在于该方法的输入只是一个哈特曼传感器的单张光斑阵列图, 而卷积卡门的输入是三个不同位置处的哈特曼传感器光斑阵列图。

上述使用深度学习技术的波前重构方法无论是使用哈特曼传感器的斜率还是原始的哈特曼传感器光斑阵列图作为输入, 其输出都是 Zernike 系数, 这一点和传统的模式法是类似的。加拿大多伦多大学的 R. Swanson 等人于 2018 年首次改变了这一研究思路^[57], 在该研究中, 输入依然是哈特曼传感器的斜率, 但是使用了 U-Net 的网络结构, 因此不再输出 Zernike 系数而是直接输出待测波前的相位图。U-Net 是一种全卷积神经网络, 最初是用于图像语义分割的^[58], 由于其具有下采样和上采样两个部分, 整个网络看起来像英文字母 U 因此被称为 U-Net。其中下采样部分负责进行图像的特征提取, 上采样部分负责图像的扩充复原。为了更好地保留低维度信息, 每一步下采样后的结果会直接连接到对应的上采样层。U-Net 结构的神经网络通常没有全连接层, 因此被广泛应用于图像到图像的映射任务。受此启发, 美国海军研究实验室的 T. B. DuBose 等人也提出了一个 U-Net 结构的神经网络并命名为 intensity/slopes network (ISNet), 用以解决大气湍流闪烁、非均匀后向散射等引起的波前探测困难^[59]。ISNet 与 Swanson 等人的工作的区别在于其输入层不仅有哈特曼传感器 x 方向和 y 方向的斜率, 还有哈特曼传感器每个子孔径中的光斑总强度, 具体结构如图 12 所示。

受到 Swanson 所做工作以及 ISNet 的启发, 2020 年浙江大学胡乐佳和斯科等人将该团队之前的工作 LSHWS 进行了改进, 基于 U-Net 和 ResNet 构造神经网络并命名为 SH-Net^[60]。该网络输入哈特曼传感器的光斑阵列图, 直接输出待测波前的相位图, 实现了从哈特曼传感器图像到相位图之间端到端的映射。在数值仿真中, 通过 Zernike 多项式法和高斯滤波器乘上一个随机矩阵的方法分别生成不同模式的相位屏, 然后使用五种算法进行对比测试(如图 13 所示), 在测试的统计结果中 SH-Net 不仅在与传统模式法、区域法的对比中表现出了优异的性能, 也大幅领先该团队之前的工作 LSHWS。例如在同时有 Zernike 多项式法和随机法生成相位屏的“Hybrid”测试组中, SH-Net 复原的波前残差 RMS 仅有 0.0168λ , 比 LSHWS 的残差低了 81.19% (0.0893λ), 比 Swanson 的网络低了 87.70% (0.1336λ), 比模式法低了 89.60% (0.1616λ), 比区域法低了 90.61% (0.1790λ)。不仅如此, 该神经网络的运算速度也较为可观, 训练完成后的 SH-Net 在实际使用时的平均运算时间为 40.2 ms, 比 LSHWS 快 67.18% (0.1225 s), 比模式法快 68.93% (0.1294 s), 虽然比区域法的 26.3 ms 慢, 但是同为 U-net 网络结构的 Swanson 网络仅用了 22.6 ms, 这

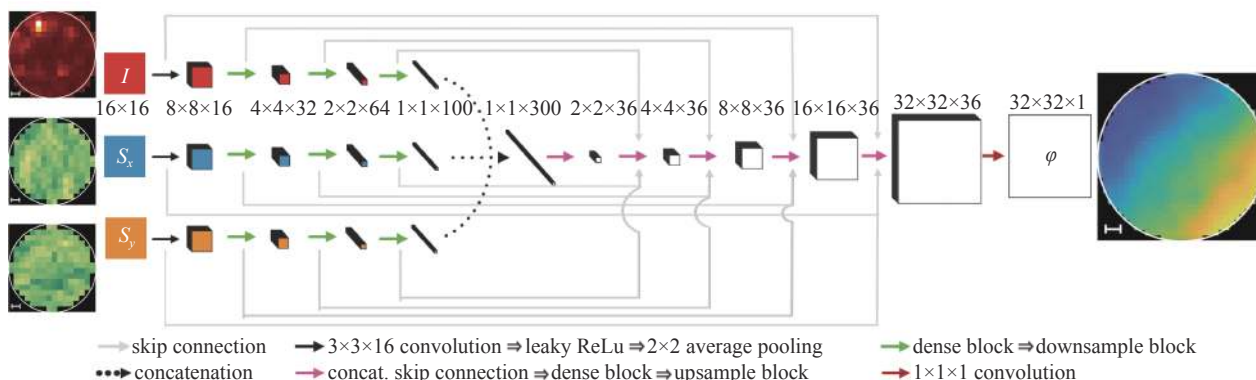


Fig. 12 ISNet architecture

图 12 ISNet 的网络结构图^[59]

一结果显示出了 U-Net 网络结构以及直接输出待测波前相位图这一思路的巨大潜力。

此外还有一些与 H. Guo 等人的工作相类似的报道,但是在具体的应用环境上有所区别:例如针对哈特曼传感器子孔径数目不足情况下的波前复原研究。理论上哈特曼传感器的子孔径数目越多,其空间分辨率就越高,但是同时也意味着计算量的增加(即实时性的下降)和子孔径中光通量的下降(即子孔径中的信噪比降低),因此在很多情况下子孔径的数目并不能太多。但在大气湍流较强的环境中,如果哈特曼传感器子孔径数目不够多,子孔径中的波前就不能被近似看作平面波,子孔径内高阶像差引起的光斑形状的不规则性将导致质心位置的计算产生较大误差,而传统的波前重构方法难以应对这种情况。2020年中国科学院光电技术研究所的徐志强和杨平等

人构建了一个单隐层神经网络用来拟合欠采样情况下的质心位置与待测波前相位的 Zernike 系数之间的非线性关系^[61]。经过训练,该网络输入哈特曼传感器得到的斜率,能够输出比模式法更准确的 Zernike 系数,说明了深度学习技术对欠采样哈特曼传感器进行波前重构的可行性。2021年,太原理工大学的贾鹏等人提出一种基于深度学习的压缩哈特曼传感器波前重构方法^[62]。所谓“压缩”是来源于“压缩感知”的概念,就是在大气湍流较强或信噪比较低时,选取少数信噪比较高的子孔径斜率信息恢复出完整的相位信息,这一过程被称为 compressive Shack-Hartmann wavefront sensing (CS-WFS)。CS-WFS 的物理过程和计算流程图如图 14 所示。CS-WFS 分为两个部分:首先,对原始的光斑阵列图以每个子孔径中的信噪比为标准进行有效光斑的筛选得到稀疏光斑阵列图,该稀疏光斑阵列图计算出稀疏斜率图后会经过一个卷积神经网络得到完整斜率图;第二步,上一步得到的完整斜率图将经过一个 U-Net 输出波前相位图。可以发现,CS-WFS 与 SH-Net 较为类似,都是输入哈特曼传感器的光斑阵列图,然后直接得到相位图,但是区别有二:首先,CS-WFS 的输入不是完整的光斑阵列图,而是随机缺失了部分子孔径光斑的光斑阵列图,因此有从所谓“压缩”信号恢复完整信号的过程;也正是由于 CS-WFS 有明显的两个步骤,CS-WFS 使用了分步骤的两个网络,这两个网络可以分开训练,也可以连接起来之后一起训练,与 SH-Net 只有一个不可分割的网络有所区别,虽然两者都是输入光斑阵列图后直接得到相位图,但是 SH-Net 是端到端的应用而 CS-WFS 更应该被看作是全部使用了神经网络的分步骤算法。

4 结 论

本文中,我们着重介绍了深度学习技术在相位反演波前传感器和哈特曼波前传感器中的应用现状。通过以上论述可以看出,深度学习技术在自适应光学波前传感中的应用日趋成熟,从应用场景上看,既有天文观测也有生物组织成像;从解决的问题上看,既有相位反演和相位差反演,也有在哈特曼传感器各个环节中的应用,比如在各种极端环境下的质心检测、强湍流或欠采样环境下的波前重构以及多传感器数据融合;从网络结构上看,有从简单

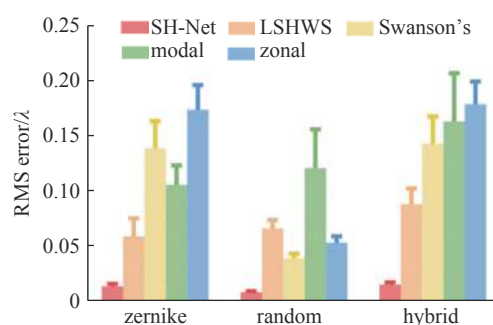


Fig. 13 Statistical results of the RMS wavefront error of five methods in wavefront detection. Each kind of phase screen contains 100 datasets

图 13 SH-Net、LSHWS、Swanson 的网络、模式法以及区域法的仿真测试统计结果,每种不同的相位屏都包含 100 个数据^[60]

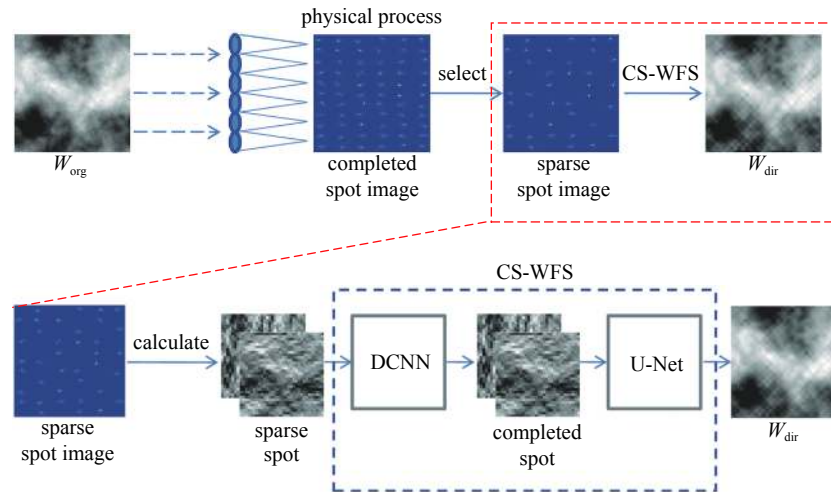


Fig. 14 Physical process and flow chart of the CS-WFS method

图 14 CS-WFS 的物理过程和计算流程图^[62]

到复杂、从解决单一问题到实现端到端应用的发展趋势；从研究方法上看，有一直都广泛使用的 Zernike 系数预测方案，也有最近出现的直接预测相位图的方案。以上这些研究在各自的应用环境和假设前提下都具有优异的性能，但是在某些方面仍然有待改进并且缺乏广泛推广的一般性。

首先在理论上，真实实验采集得到的数据量少、数据多样性不足，仿真得到的数据量大但与真实世界存在一定的差别，如何在两者之间进行平衡并进行算法的设计从而提取到真正的特征将会是研究的重点。另外，网络结构的优化、分步骤网络和端到端网络的优劣也有待进一步的研究。例如在 Gómez 和 Osborn 的报道中，虽然卷积卡门的准确度优于全连接卡门，但是该文并未和使用全连接网络计算质心然后使用全连接卡门重构波前的分步骤网络进行对比，因此卷积卡门的性能提升可能有相当一部分来源于使用神经网络后质心探测精度的提升，故该文中卷积神经网络优于全连接神经网络的结果并不能作为一种一般的结论，也不能断定所有端到端的网络就比分步骤的网络更准确。有关如何根据各个任务的不同需求和复杂度设计合适的网络结构还需要更多更深入的研究，从而实现精度、计算速度和鲁棒性之间的平衡。

其次在工程上，现有的部分算法对实际的应用环境考虑不足，例如 ISNet 以及 CS-WFS 的输出是大小为 32×32 的相位图，进行原理验证没有问题，但是在很多实际的工程应用中这样的尺寸就太小了。另外还有运算速度的问题，早期在天文领域的研究由于输入图像本身尺寸有限因而比较容易进行工程实现，但近期的有关工作除了 Osborn 和 Guzmán 对全连接卡门做了算法和硬件的结合，大多数是理论研究和实验室验证，因此各类算法在实时 AO 系统中应用时与硬件之间的协调和优化还有很大的研究空间。

参考文献：

- [1] 姜文汉. 自适应光学发展综述[J]. 光电工程, 2018, 45: 170489. (Jiang Wenhan. Overview of adaptive optics development[J]. Opto-Electronic Engineering, 2018, 45: 170489)
- [2] Pomohaci R, Oudmaijer R D, Goodwin S P. A pilot survey of the binarity of Massive Young Stellar Objects with K-band adaptive optics[J]. *Monthly Notices of the Royal Astronomical Society*, 2019, 484(1): 226-238.
- [3] Salter P S, Booth M J. Adaptive optics in laser processing[J]. *Light: Science & Applications*, 2019, 8: 110.
- [4] Sun Licheng, Guo Yading, Shao Chongfeng, et al. 10.8 kW, 2.6 times diffraction limited laser based on a continuous wave Nd: YAG oscillator and an extra-cavity adaptive optics system[J]. *Optics Letters*, 2018, 43(17): 4160-4163.
- [5] 李恩德, 杨泽平, 官春林, 等. 我国惯性约束聚变领域中的波前控制技术[J]. 光电工程, 2020, 47: 200344. (Li Ende, Yang Zeping, Guan Chunlin, et al. Wavefront control technology for ICF facility in China[J]. Opto-Electronic Engineering, 2020, 47: 200344)
- [6] Toselli I, Gladysz S. Improving system performance by using adaptive optics and aperture averaging for laser communications in oceanic turbulence[J]. *Optics Express*, 2020, 28(12): 17347-17361.
- [7] Azimipour M, Migacz J V, Zawadzki R J, et al. Functional retinal imaging using adaptive optics swept-source OCT at 1.6 MHz[J]. *Optica*, 2019, 6(3): 300-303.
- [8] 张雨东, 饶长辉, 李新阳. 自适应光学及激光操控[M]. 北京: 国防工业出版社, 2016. (Zhang Yudong, Rao Changhui, Li Xinyang. Adaptive optics and laser control[M]. Beijing: National Defense Industry Press, 2016)
- [9] 张钲, 朱军, 苏航. 迈向第三代人工智能[J]. *中国科学: 信息科学*, 2020, 50(9): 1281-1302. (Zhang Bo, Zhu Jun, Su Hang. Toward the third generation of

- artificial intelligence[J]. *Scientia Sinica (Informationis)*, 2020, 50(9): 1281-1302)
- [10] 伊恩·古德费洛, 约书亚·本吉奥, 亚伦·库维尔. 深度学习[M]. 赵申剑, 黎戎君, 符天凡, 等, 译. 北京: 人民邮电出版社, 2017. (Goodfellow I, Bengio Y, Courville A, et al. Deep learning[M]. Zhao Shenjian, Li Yujun, Fu Tianfan, et al, trans. Beijing: Posts & Telecom Press, 2017).)
- [11] McCulloch W S, Pitts W. A logical calculus of the ideas immanent in nervous activity[J]. *The Bulletin of Mathematical Biophysics*, 1943, 5(4): 115-133.
- [12] Hebb D O. The organization of behavior: a neuropsychological theory[M]. New York: Wiley, 1949.
- [13] Rosenblatt F. The perceptron: a probabilistic model for information storage and organization in the brain[J]. *Psychological Review*, 1958, 65(6): 386-408.
- [14] Minsky M, Papert S A. Perceptrons: an introduction to computational geometry[M]. Cambridge: MIT Press, 2017.
- [15] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagating errors[J]. *Nature*, 1986, 323(6088): 533-536.
- [16] Gonsalves R A. Phase retrieval and diversity in adaptive optics[J]. *Optical Engineering*, 1982, 21: 215829.
- [17] Carrano C J, Olivier S S, Brase J M, et al. Phase retrieval techniques for adaptive optics[C]//Proceedings Volume 3353, Adaptive Optical System Technologies. Kona, 1998: 658-667.
- [18] 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.
- [19] Lloyd-Hart M, Wizinowich P, McLeod B, et al. First results of an on-line adaptive optics system with atmospheric wavefront sensing by an artificial neural network[J]. *The Astrophysical Journal*, 1992, 390: L41-L44.
- [20] 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.
- [21] 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.
- [22] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[J]. *Communications of the ACM*, 2017, 60(6): 84-90.
- [23] 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.
- [24] 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.
- [25] Wu Yu, Guo Youming, Bao Hua, et al. Sub-millisecond phase retrieval for phase-diversity wavefront sensor[J]. *Sensors*, 2020, 20: 4877.
- [26] Ju Guohao, Qi Xin, Ma Hongcai, et al. Feature-based phase retrieval wavefront sensing approach using machine learning[J]. *Optics Express*, 2018, 26(24): 31767-31783.
- [27] Li Zhaokun, Zhao Xiaohui. BP artificial neural network based wave front correction for sensor-less free space optics communication[J]. *Optics Communications*, 2017, 385: 219-228.
- [28] Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the inception architecture for computer vision[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016: 2818-2826.
- [29] Paine S W, Fienup J R. Machine learning for improved image-based wavefront sensing[J]. *Optics Letters*, 2018, 43(6): 1235-1238.
- [30] Nishizaki Y, Valdivia M, Horisaki R, et al. Deep learning wavefront sensing[J]. *Optics Express*, 2019, 27(1): 240-251.
- [31] Tan Mingxing, Le Q V. Efficientnet: rethinking model scaling for convolutional neural networks[C]//Proceedings of the International Conference on Machine Learning, ICML 2019. Long Beach, 2019: 6105-6114.
- [32] Wang Minghao, Guo Wen, Yuan Xiuhua. Single-shot wavefront sensing with deep neural networks for free-space optical communications[J]. *Optics Express*, 2021, 29(3): 3465-3478.
- [33] Hoenders B J. On the solution of the phase retrieval problem[J]. *Journal of Mathematical Physics*, 1975, 16(9): 1719-1725.
- [34] Kim W, Hayes M H. Phase retrieval using two Fourier-transform intensities[J]. *Journal of the Optical Society of America A*, 1990, 7(3): 441-449.
- [35] Diez C A, 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.
- [36] Li Ziqiang, Li Xinyang, Liang Rongguang. Random two-frame interferometry based on deep learning[J]. *Optics Express*, 2020, 28(17): 24747-24760.
- [37] 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.
- [38] Mello A T, Kanaan A, Guzman D, et al. Artificial neural networks for centroiding elongated spots in Shack-Hartmann wavefront sensors[J]. *Monthly Notices of the Royal Astronomical Society*, 2014, 440(3): 2781-2790.
- [39] Berdja A, Santibañez E G, Guzman C D. Experimental results on using artificial neural networks for accurate centroiding in Shack-Hartmann wavefront sensors with elongated spots[C]//Proceedings Volume 9909, Adaptive Optics Systems V. Edinburgh: SPIE, 2016: 99093Y.
- [40] Gilles L, Ellerbroek B L. Constrained matched filtering for extended dynamic range and improved noise rejection for Shack-Hartmann wavefront sensing[J]. *Optics Letters*, 2008, 33(10): 1159-1161.
- [41] Michau V, Conan J M, Fusco T, et al. Shack-Hartmann wavefront sensing with extended sources[C]//Proceedings Volume 6303, Atmospheric Optical Modeling, Measurement, and Simulation II. San Diego: SPIE, 2006: 63030B.
- [42] Li Ziqiang, Li Xinyang. Centroid computation for Shack-Hartmann wavefront sensor in extreme situations based on artificial neural networks[J]. *Optics Express*, 2018, 26(24): 31675-31692.

- [43] Ellerbroek B L. First-order performance evaluation of adaptive-optics systems for atmospheric-turbulence compensation in extended-field-of-view astronomical telescopes[J]. *Journal of the Optical Society of America A*, 1994, 11(2): 783-805.
- [44] Fusco T, Conan J M, Rousset G, et al. Optimal wave-front reconstruction strategies for multiconjugate adaptive optics[J]. *Journal of the Optical Society of America A*, 2001, 18(10): 2527-2538.
- [45] Vidal F, Gendron E, Rousset G. Tomography approach for multi-object adaptive optics[J]. *Journal of the Optical Society of America A*, 2010, 27(11): A253-A264.
- [46] Guo Hong, Korablinova N, Ren Qiushi, et al. Wavefront reconstruction with artificial neural networks[J]. *Optics Express*, 2006, 14(14): 6456-6462.
- [47] Osborn J, De Cos Juez F J, Guzman D, et al. Using artificial neural networks for open-loop tomography[J]. *Optics Express*, 2012, 20(3): 2420-2434.
- [48] de Cos Juez F J, Lasheras F S, Roqueñi N, et al. An ANN-based smart tomographic reconstructor in a dynamic environment[J]. *Sensors*, 2012, 12(7): 8895-8911.
- [49] Guzman D, Mello A T, Osborn J, et al. Tomographic reconstructor for multi-object adaptive optics using artificial neural networks[C]//Proceedings Volume 8447, Adaptive Optics Systems III. Amsterdam: SPIE, 2012: 844740.
- [50] Osborn J, Guzman D, de Cos Juez F J, et al. Open-loop tomography with artificial neural networks on CANARY: on-sky results[J]. *Monthly Notices of the Royal Astronomical Society*, 2014, 441(3): 2508-2514.
- [51] Gonzalez-Gutiérrez C, Santos J D, Martínez-Zarzuela M, et al. Comparative study of neural network frameworks for the next generation of adaptive optics systems[J]. *Sensors*, 2017, 17: 1263.
- [52] Gómez S L S, Gutiérrez C G, Rodríguez J D S, et al. Analysing the performance of a tomographic reconstructor with different neural networks frameworks[C]//Proceedings of the 16th International Conference on Intelligent Systems Design and Applications (ISDA 2016). Porto: Springer, 2016: 1051-1060.
- [53] Gonzalez-Gutiérrez C, Santos-Rodríguez J D, Díaz R Á F, et al. Using GPUs to speed up a tomographic reconstructor based on machine learning[C]//Proceedings of the International Joint Conference SOCO'16-CISIS'16-ICEUTE'16. San Sebastián: Springer, 2016: 279-289.
- [54] González-Gutiérrez C, Sánchez-Rodríguez M L, Calvo-Rolle J L, et al. Multi-GPU development of a neural networks based reconstructor for adaptive optics[J]. *Complexity*, 2018, 2018: 5348265.
- [55] Gómez S L S, González-Gutiérrez C, Alonso E D, et al. Improving adaptive optics reconstructions with a deep learning approach[C]//Proceedings of the 13th International Conference, HAIS 2018. Oviedo: Springer, 2018: 74-83.
- [56] Hu Leijia, Hu Shuwen, Gong Wei, et al. Learning-based Shack-Hartmann wavefront sensor for high-order aberration detection[J]. *Optics Express*, 2019, 27(23): 33504-33517.
- [57] Swanson R, Lamb M, Correia C, et al. Wavefront reconstruction and prediction with convolutional neural networks[C]//Proceedings Volume 10703, Adaptive Optics Systems VI. Austin, 2018: 107031F.
- [58] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[C]//Proceedings of the 18th International Conference. Munich, 2015: 234-241.
- [59] 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.
- [60] Hu Leijia, Hu Shuwen, Gong Wei, et al. Deep learning assisted Shack-Hartmann wavefront sensor for direct wavefront detection[J]. *Optics Letters*, 2020, 45(13): 3741-3744.
- [61] Xu Zhiqiang, Wang Shuai, Zhao Mengmeng, 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.
- [62] Jia Peng, Ma Mingyang, Cai Dongmei, et al. Compressive Shack-Hartmann wavefront sensor based on deep neural networks[J]. *Monthly Notices of the Royal Astronomical Society*, 2021, 503(3): 3194-3203.