

## 深度学习光学合成孔径共相闭环实验研究

马霞飞<sup>1,2,3</sup>, 杨开元<sup>1,2,3,4</sup>, 马浩统<sup>1,2,3\*</sup>, 杨虎<sup>1,2,3</sup>, 谢宗良<sup>1,2,3\*\*</sup><sup>1</sup>中国科学院光电技术研究所光场调控科学技术全国重点实验室, 四川 成都 610209;<sup>2</sup>中国科学院光束控制重点实验室, 四川 成都 610209;<sup>3</sup>中国科学院大学, 北京 100049;<sup>4</sup>电子科技大学自动化工程学院, 四川 成都 610209

**摘要** 光学合成孔径是研制大口径望远镜的有效技术途径。合成孔径光电望远镜实际分辨率能达到衍射极限的关键在于实时检测并校正各子孔径之间的平移误差。通过构建轻量化 MobileNet 卷积神经网络拟合宽波段点扩展函数和平移误差的非线性映射关系,并基于该网络完成了三孔径共相闭环实验。对三孔径合成孔径系统时序施加平移误差,采集相应宽波段点扩展函数,利用点扩展函数-平移误差数据训练轻量化 MobileNet 网络至收敛。在闭环校正阶段,将训练好的模型部署到嵌入式计算平台中,根据预测输出控制压电反射镜进行误差校正。共相闭环结果表明,该方法每次检测耗时 3 ms,具有较好实时性,且能够在  $\pm 6\lambda_0$  ( $\lambda_0=600$  nm) 的检测范围内,实现 26.2 nm 的检测精度。通过深度学习共相闭环实验,验证了深度学习作为工程级共相解决方案的可行性。

**关键词** 成像系统; 卷积神经网络; 平移误差; 光学合成孔径; 共相闭环

中图分类号 O436 文献标志码 A

DOI: 10.3788/CJL231164

## 1 引言

为了探测更深更远的未知空间,天文观测对望远镜的空间分辨能力提出了越来越高的要求。光学合成孔径望远镜通过多个子孔径组合的形式等效实现大口径系统的分辨率,极大地降低了望远镜主镜的制造难度和加工成本,突破了现有光学加工极限对更高成像分辨率的限制。相比于传统单一大口径望远镜,合成孔径成像技术展现出了广泛的应用前景,对未来空间望远镜设计及发展具有重要意义<sup>[1-5]</sup>。

但系统装调过程中不可避免地会在子孔径之间引入共相误差,导致各子孔径光束无法在像面同相位干涉,影响成像效果,因此对共相误差的检测校正是光学合成孔径系统实现衍射极限分辨能力的重要前提。现有的共相误差检测方法分为瞳面检测和像面检测两种。哈特曼传感器<sup>[6-7]</sup>、色散条纹传感器<sup>[8-10]</sup>和四棱锥传感器<sup>[11-13]</sup>等瞳面检测方法利用特殊设计的光学器件对瞳面信息进行调制来实现共相误差检测,系统复杂度较高;相位差法<sup>[14-18]</sup>、模拟退火法<sup>[19]</sup>等像面检测方法则是通过分析像面强度分布进行共相误差检测,此类方法光路较为简单,但解算过程耗时,难以满足实时性的要求。

随着人工智能时代的到来,深度学习方法成功解决了包括共相检测技术在内的许多光学成像问题<sup>[20-24]</sup>。与传统优化方法不同,深度学习方法基于大数据驱动构建针对特定任务场景的计算模型,经过适当训练的网路能够实现端到端的预测,大大提高了预测效率。2018年,Guerra-Ramos等<sup>[25]</sup>仿真证明了深度学习实现平移误差检测的可行性,通过采用多波长方法解决  $2\pi$  模糊问题,同时结合多网络分阶段实现粗共相和精共相,在  $\pm 11\lambda$  ( $\lambda=700$  nm) 范围内实现了  $\pm 0.0087\lambda$  的高精度平移误差检测。2020年,Hui等<sup>[26]</sup>通过加深网络模型在训练样本较少的情况下完成了平移误差检测仿真研究,在一个波长探测范围内实现了  $0.0622\lambda$  ( $\lambda=700$  nm) 的精共相检测,由于仍采用了多网络分孔径组合检测的形式,该方法检测过程繁琐,实时性较差。2021年,Wang等<sup>[27]</sup>将门控循环单元引入到共相误差检测网络中,有效缓解了深度网络训练中容易出现的梯度消失问题,进一步提高了探测精度,在一个波长探测范围内实现了  $0.0065\lambda$  ( $\lambda=632$  nm) 的探测精度,并实验验证了该方法的检测效果。基于深度学习的共相检测研究通过不断改进网络模型,充分挖掘数据内部的关联性,有效提升共相检测性能。但现有研究大多停留在仿真阶段,相关的实验研究也只进

收稿日期: 2023-09-01; 修回日期: 2023-10-05; 录用日期: 2023-11-06; 网络首发日期: 2023-11-17

基金项目: 国家自然科学基金(62005289, 62175243)、中国科学院青年创新促进会项目(2020372)、国家重点研发计划(2022YFB3901900)

通信作者: \*mahaotong@163.com; \*\*zongliang.xie@yahoo.com

行了误差检测,未实现闭环校正<sup>[28-31]</sup>。

本文建立了光学合成孔径成像实验平台,开展了基于轻量级 MobileNet 卷积神经网络的共相闭环实验,分别针对两孔径系统和三孔径系统实现了平移误差的实时闭环校正。通过宽带光照明扩大检测范围,采集点扩展函数(PSF)实验图像对网络进行线上训练,得到具有大量程高精度共相检测性能的神经网络推理模型。将模型部署到硬件平台上,在系统中加载已知的平移误差,通过对平移误差进行实时计算和闭环控制,验证深度学习算法对实际系统中平移误差的闭环校正性能。

## 2 检测原理

### 2.1 光学合成孔径成像原理

根据成像原理,光学合成孔径系统的成像过程可以描述为

$$I(x, y) = o(x, y) \otimes F_{\text{PSF}}(x, y) + n(x, y), \quad (1)$$

式中: $I(x, y)$ 为成像图像; $o(x, y)$ 为目标理想分布; $F_{\text{PSF}}(x, y)$ 为系统点扩展函数; $n(x, y)$ 为噪声。

在只考虑平移误差的情况下,对于由  $N$  个子孔径组合而成的光学合成孔径成像系统,其广义光瞳函数可以表示为

$$P(u, v) = p(u - u_1, v - v_1) + \sum_{n=2}^N p(u - u_n, v - v_n) \exp\left(\frac{2\pi i}{\lambda} l_{\text{OPD},n}\right), \quad (2)$$

式中: $p(u - u_1, v - v_1)$ 为参考孔径; $(u_n, v_n)$ 表示  $n$  个子孔径的中心坐标; $\lambda$ 表示单色光波长; $l_{\text{OPD},n}$ 表示第  $n$  个子

孔径相对于参考孔径的轴向位移量,即该子孔径的平移误差。两子孔径间的平移误差示意图如图 1(a)所示。

对光瞳函数做傅里叶变换之后取模平方可以得到系统的点扩展函数。若成像内容是点目标,点扩展函数即为系统所成图像:

$$F_{\text{PSF}}(x, y) = \left| \mathcal{F}\{P(u, v)\} \right|^2. \quad (3)$$

当采用波长为  $\lambda_1$  的单色光照明时,平移误差带来的相位差为  $\varphi = 2\pi \frac{l_{\text{OPD}}}{\lambda_1}$ 。若有两个不同的平移误差量

$l_{\text{OPD},1}$  和  $l_{\text{OPD},2}$  存在关系  $l_{\text{OPD},1} = l_{\text{OPD},2} + n\lambda_1$  ( $n$  为整数),此时对应的相位差  $\varphi_1 = \varphi_2$ ,对应的点扩展函数分布相同,无法根据像面信息判断系统中实际存在的平移误差量,此即为  $2\pi$  模糊问题。当引入另一个波长为  $\lambda_2$  的单色光,此时  $l_{\text{OPD},1}$  和  $l_{\text{OPD},2}$  对应的相位差是不同的,能够根据点扩展函数信息进行区分。以一两孔径阵列为例进行详细说明,其中成像透镜焦距为 2 m,子孔径直径为 10 mm。在 600 nm 单波长光源照明下,当  $l_{\text{OPD},1}$  和  $l_{\text{OPD},2}$  存在上述函数关系时,对应产生的焦面 PSF 完全相同,如图 1(b1)和图 1(b2)所示;而在 550~650 nm (中心波长  $\lambda_0 = 600$  nm) 宽波段光源照明下, $l_{\text{OPD},1}$  和  $l_{\text{OPD},2}$  对应的焦面 PSF 存在明显差异,如图 1(c1)和图 1(c2)所示。因此,通过多波长联合求解可以消除  $2\pi$  模糊,扩展共相检测范围。当照明光源为  $\lambda_1 \sim \lambda_M$  谱段的宽带光时,点扩展函数改写为

$$F_{\text{PSF}}(x, y) = \int_{\lambda_1}^{\lambda_M} c(\lambda) F_{\text{PSF}}(x, y, \lambda) d\lambda, \quad (4)$$

式中: $c(\lambda)$ 是每个波长的权重系数。

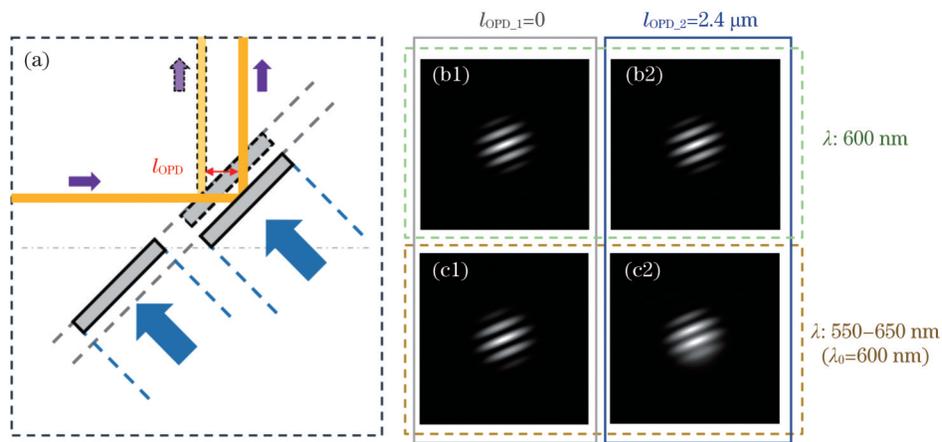


图 1 只考虑平移误差时光学合成孔径成像系统的 PSF。(a) 平移误差示意图;(b1),(b2) 单波长下不同平移误差对应的 PSF;

(c1),(c2) 宽带光下不同平移误差对应的 PSF

Fig. 1 PSF of optical synthetic aperture imaging system when only piston error is considered. (a) Schematic diagram of piston error; (b1), (b2) PSF corresponding to different piston errors at single wavelength; (c1), (c2) PSF corresponding to different piston errors under broadband light illumination

### 2.2 网络结构

卷积神经网络通过多层级的卷积操作对特征进行逐层变换,提取数据更本质的抽象特征,实现对复杂图像处理问题的降维,从而准确构建网络输入与输出之

间的函数映射关系。通常来说,更深层的网络具有更强大的特征提取能力,函数拟合精度更高。但更高的模型复杂度也会带来更高的计算复杂度,导致模型预测耗费大量时间,而且这种复杂的模型往往只能在高

算力的服务器中运行,无法部署到资源非常有限的移动设备中。为了在预测实时性和准确性之间取得良好的平衡,本文搭建了如图 2 所示的轻量级 MobileNet 深度学习模型<sup>[32]</sup>。MobileNet 模型沿用了经典卷积神经网络的基本框架,包括输入层、卷积层、非线性激活层、池化层、全连接层和输出层等。不同点在于 MobileNet 模型将标准卷积转化为由深度卷积和点卷积组成的深度可分离卷积,其中深度卷积以单通道模

式对每一个输入特征图通道进行卷积得到输出特征图,点卷积再对输出特征图进行融合,通过这种组合结构在保证网络整体性能的前提下,有效减少模型参数和计算复杂度。本文采用的是  $3 \times 3$  大小的卷积核,深度可分离卷积的计算量只有标准卷积计算量的  $1/9$  左右,因此,以深度可分离卷积为基础单元的 MobileNet 模型非常适合用于移动设备、嵌入式平台等终端设备,实现快速的深度学习推理。

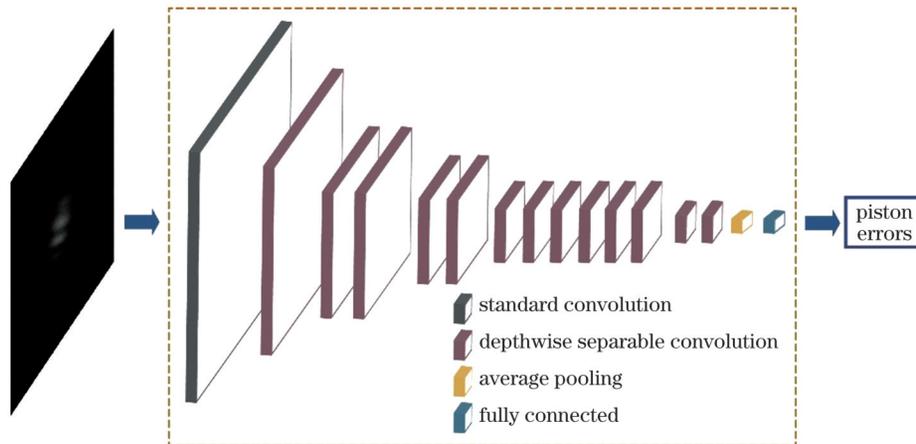


图 2 MobileNet 网络结构

Fig. 2 Structure diagram of MobileNet

实验中采用的 MobileNet 网络包括 1 个标准卷积模块和 13 个深度可分离卷积模块。标准卷积模块包括普通卷积层、BatchNorm (BN) 归一化处理层和 ReLU 激活函数层;深度可分离卷积的结构组成从前往后依次为深度卷积层、BN 层、ReLU 层、点卷积、BN 层和 ReLU 层。其中,BN 层能够在加快训练速度的同时缓解梯度消失和梯度爆炸问题,ReLU 层的作用在于将非线性引入到网络中,使网络可以拟合复杂的非线性函数关系。池化层能够在保留重要特征信息的同时对数据进行降维,提升特征的鲁棒性。最后,全连接层将提取到的抽象特征重新组合并映射到预测空间。在 MobileNet 网络原始结构中,最后一层是 SoftMax 分类器,用于将多分类的结果转换为概率分布。本文构建的 MobileNet 网络以全连接层为最后一层,直接输出预测结果。

对于平移误差检测任务,神经网络的作用是学习不同平移误差情况下合成孔径系统所成图像强度分布的变化规律。采用宽带光照明时,相干长度范围内生成的每一张点扩展函数图像只能匹配到唯一确定的平移误差值。以点扩展函数图像为输入,平移误差数值为输出对网络进行训练,即可实现图像样本空间到平移误差数值空间的映射,得到具有大量程平移误差预测能力的网络模型。

## 3 实验

### 3.1 闭环共相实验系统

本文基于如图 3 所示的光学合成孔径成像实验平

台分别开展了两孔径系统和三孔径系统的闭环共相实验。实验平台搭建在精密光学平台上,发射的光束经平行光管准直扩束成平行光,然后经  $45^\circ$  角放置的压电反射镜反射并通过设计好的孔径阵列,最后子孔径光束经透镜聚焦在相机像面成像。两孔径系统和三孔径系统均由直径为 10 mm 的子孔径构成,结构分别如图 4(a) 和图 4(c) 所示,对应的理想点扩展函数图像分别如图 4(b) 和图 4(d) 所示。

实验采用 NKT Photonics 公司生产的超连续谱激光器作为光源,可输出谱段为 410~2400 nm,平行光管口径为 300 mm,焦距为 3 m,成像透镜焦距为 2 m。压电反射镜由 8 块嵌在固定面板上的压电陶瓷反射镜组成,平行光经 8 块个子镜反射后形成 8 路子光束,特定子镜反射的子光束会通过孔径阵列并在光路后端干涉成像,通过控制该子镜在垂直于固定面板的方向上运动,即可在相应子孔径光路中实现平移误差的加载与补偿,开环状态下子镜在该方向的行程范围为  $28.36 \mu\text{m}$ 。在图 3 所示的两孔径实验光路示意图中,子镜 1 引入的平移误差与子孔径 1 对应,子镜 2 引入的平移误差与子孔径 2 对应。相机采用 Sentech 公司生产的 STC-SPB322PCL 相机,实验中采用 Camera Link Deca 配置,相机最高帧频为 191.56 frame/s,像素尺寸为  $3.45 \mu\text{m} \times 3.45 \mu\text{m}$ ,分辨率为 2048 pixel  $\times$  1536 pixel。嵌入式计算平台采用的现场可编程门阵列 (FPGA) 型号为 XILINX Kintex-XC7K325T,最大收发速率为 200 Gb/s;搭载的图形处理器 (GPU) 型号为 NVIDIA Jetson

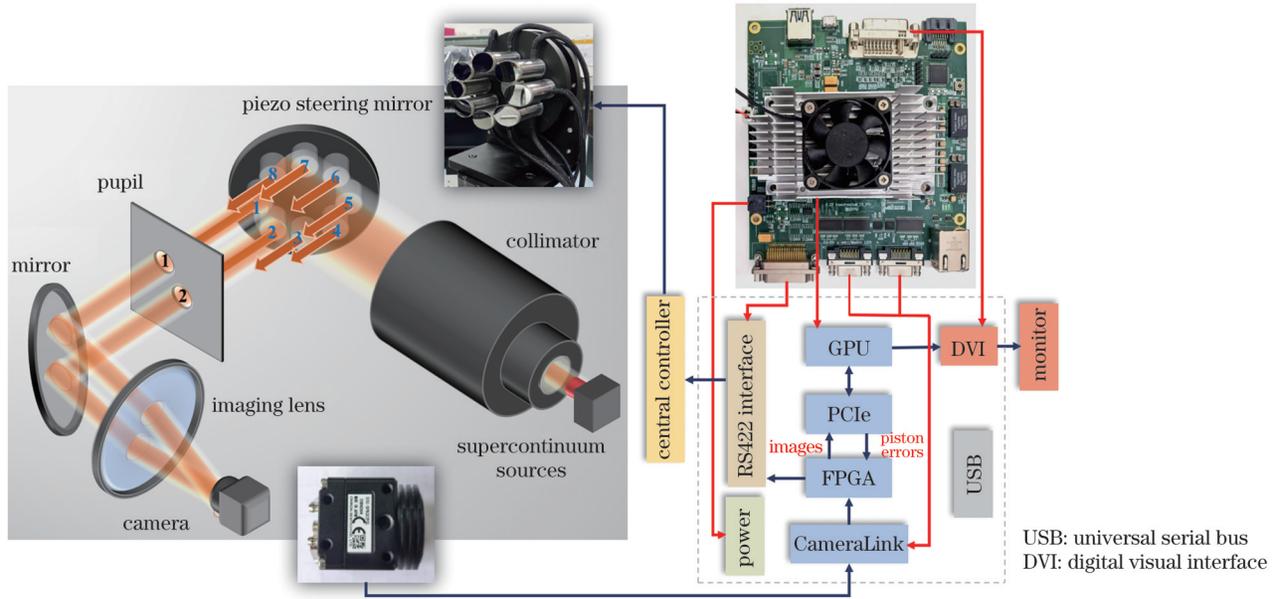


图3 闭环共相实验平台及控制流程

Fig. 3 Experimental platform and control flow chart for closed-loop co-phasing experiment

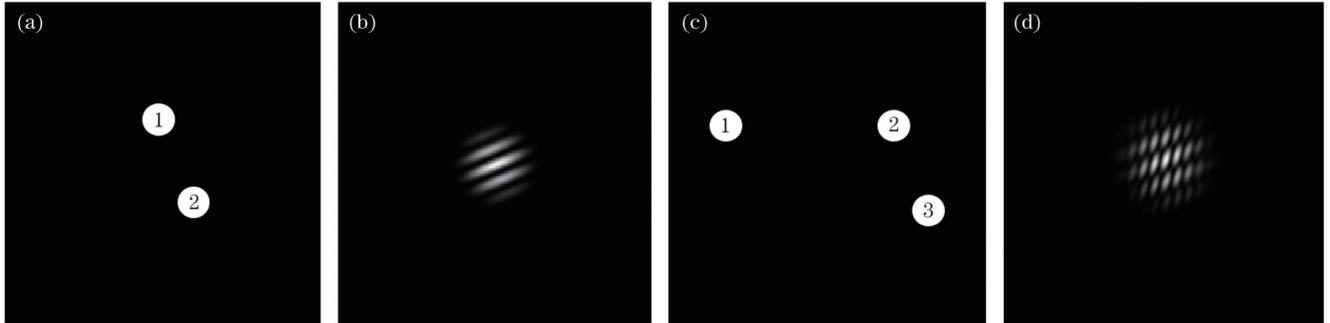


图4 实验研究的光学合成孔径系统及其对应的理想 PSF。(a),(b)两孔径结构和对应的理想 PSF;(c),(d)三孔径结构和对应的理想 PSF

Fig. 4 Experimental optical synthetic aperture imaging systems and corresponding ideal PSFs. (a),(b) Configuration of two-aperture system and corresponding ideal PSF; (c),(d) configuration of three-aperture system and corresponding ideal PSF

TX2,处理频率为 2 GHz,内存为 8 GB 四代低功耗双倍据率同步动态随机存储器(LPDDR4)。相机靶面中的图像通过 CameraLink 传输至 FPGA 中,FPGA 通过高速外围组件互连(PCIe)接口实现与 GPU 之间的数据传输,并通过 RS422 接口实现与控制系统之间的串口通信,控制压电反射镜对误差进行补偿校正。

### 3.2 两孔径系统闭环校正实验

实验采用谱段为 550~650 nm 的宽带光照明,中心波长为 600 nm,计算得到相干长度为 3.6  $\mu\text{m}$ 。以图 4(a)所示的子孔径 1 为参考孔径,其所在平面为零误差的位置,子孔径 2 相对于参考孔径的平移误差存在前后两个方向,因此,理论上深度学习方法可实现的平移误差探测范围为  $[-3.6 \mu\text{m}, 3.6 \mu\text{m}]$ 。在探测范围内,点扩展函数和平移误差数值是一一对应的关系,以点扩展函数图像作为输入,子孔径间的相对平移误差值作为输出,训练得到的神经网络能够从点扩展函数图像中提取出唯一确定的平移误差数值,实现大量

程探测。在  $[-3.6 \mu\text{m}, 3.6 \mu\text{m}]$  范围内采集两孔径系统的实验数据,控制压电反射镜以 10 nm 为步长在垂直于固定面板的方向上运动,由于反射镜运动方向与光束传播方向之间存在  $45^\circ$  夹角,实际引入到子光束的平移误差为  $10\sqrt{2}$  nm。子镜每移动一次采集一张图像,共采集到 500 张点扩展函数图像,选取其中 400 张用于构建训练集,另外 100 张用于构建测试集,测试集不参与网络的训练,图像输入网络之前均进行归一化处理。网络的训练在配置了 NVIDIA GTX 1080 Ti 显卡的台式计算机上进行,显卡内存为 31.3 GB,中央处理器(CPU)型号为 Intel® Core™ i7-6800。点扩展函数图像输入到网络之后,经卷积、池化等操作被逐层提取为抽象的高阶特征,并转换为平移误差预测输出。将网络预测输出与实际数值标签之间的均方根误差(RMSE)定为网络的损失函数,基于误差反向传播原理和 mini-batch 梯度下降算法对模型参数进行迭代更新,其中 mini-batch 大小为 32,即每次迭代参与训练的

样本数量为 32。通过最小化损失函数可以得到全局最优解,使网络输出逼近预期数值,实现平移误差精确预测。初始学习率为 0.01,采用 Adam 优化器动态调整学习率,提高训练效果。

训练完成后,利用测试集检验网络性能。图 5 所示为训练结果和测试结果的 RMSE 分布直方图,可以看到网络在训练集和测试集上的探测性能相对一致,没有出现过拟合问题。测试结果中 50% 以上在 [10 nm, 20 nm] 范围内,最大残差不超过 50 nm。图 6 所示为 100 组测试数据中实际加载的平移误差值与网络预测值的分布,在整个探测范围内,网络预测结果都非常接近实际值,计算得到测试结果残余 RMSE 的平均值约为 18 nm。工程上实现高分辨成像通常需要保证残余误差在  $0.1\lambda_0$  ( $\lambda_0=600$  nm) 范围内,以此为标准对网络预测精度进行评估,其中 RMSE 不超过  $0.1\lambda_0$  的情况为正确预测, RMSE 超过  $0.1\lambda_0$  的情况为错误预测。测试结果表明网络对平移误差的预测精度达到 100%。

将训练好的网络模型转换为与 Jetson TX2 嵌入式计算平台兼容的格式,利用 TensorRT 推理引擎对

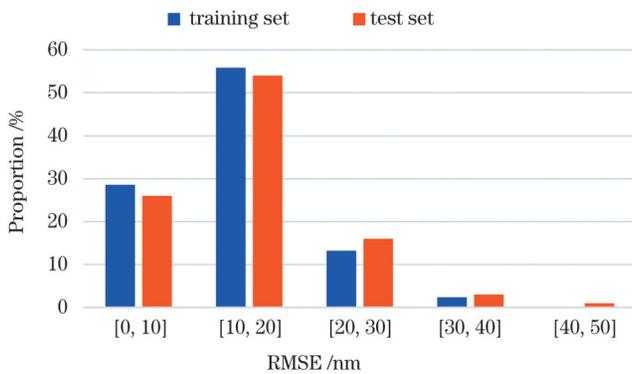


图 5 基于两孔径实验数据得到的训练集与测试集上残余 RMSE 分布直方图

Fig. 5 Histogram of residual RMSE distribution on training set and test set using two-aperture experimental images

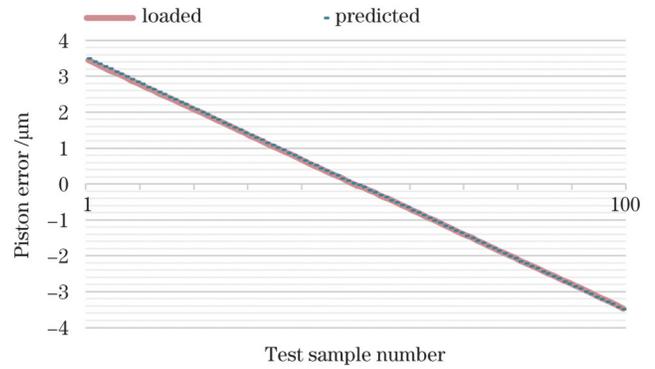


图 6 两孔径系统加载的平移误差与预测的平移误差对比图  
Fig. 6 Comparison between loaded and predicted piston errors in two-aperture system

模型进行优化以实现高性能的前向推理。闭环过程中首先通过 CameraLink 接口将相机靶面接收到的实时图像传输至计算平台中,随后 TensorRT 读取本地模型,基于点扩展函数图像推理出当前状态下系统的平移误差,误差值被转换为电压施加到压电反射镜上,驱动子镜运动对误差进行实时校正,实现闭环共相。两孔径闭环实验过程中的残差曲线如图 7(a) 所示,开环状态下,系统中初始误差约为  $-1.4 \mu\text{m}$ ,从第 50 步迭代开始实现快速收敛,且稳定在零值附近。闭环后的平均残差约为 26 nm,闭环前后的点扩展函数图像分别如图 7(b) 和图 7(c) 所示。从图中可以看到闭环后的图像与图 4(b) 所示的理想点扩展函数基本一致,实现了高精度的平移误差校正。在当前实验条件下, MobileNet 网络每完成一次检测需耗时约 3 ms,文献 [29-30] 采用 VGG-19 网络架构搭建的模型在两孔径实验中实现了 15 nm 的平移误差检测精度,每完成一次检测耗时约 10 ms。从结果对比可知:基于 MobileNet 网络的共相检测方法在损失较少精度的同时大大减少了计算量,在实时性上具有明显优势。

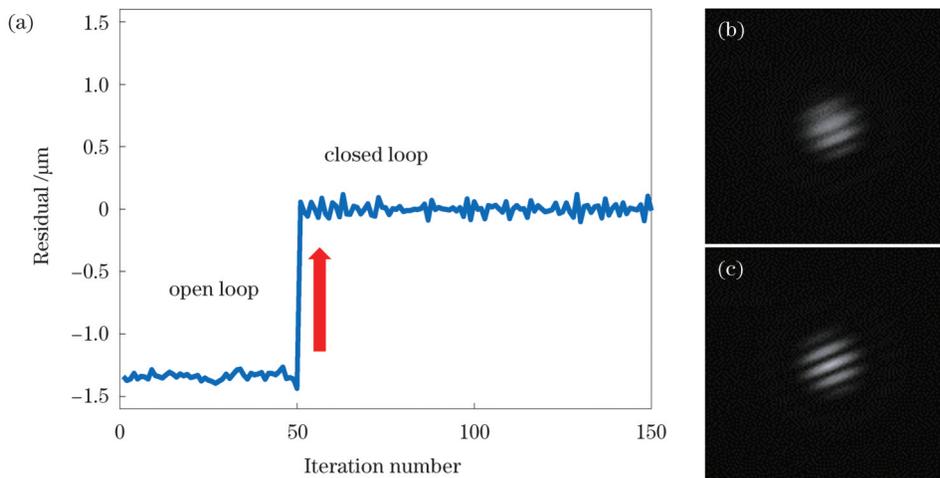


图 7 两孔径系统闭环校正实验结果。(a) 残差收敛曲线; (b) 闭环校正前图像; (c) 闭环校正后图像

Fig. 7 Results of closed-loop correction experiment on two-aperture system. (a) Convergence curve of residual; (b) image without closed-loop correction; (c) image with closed-loop correction

### 3.3 三孔径系统闭环校正实验

三孔径实验仍采用波段为 550~650 nm 的宽带光照明,探测范围 $[-3.6 \mu\text{m}, 3.6 \mu\text{m}]$ 。以图 4(c)所示的子孔径 1 为参考孔径,其所在平面为零误差的位置,在子孔径 2 和子孔径 3 上分别引入相对于参考孔径的平移误差。以点扩展函数图像作为输入,两个相对平移误差值作为输出,训练得到的网络能够实现对三孔径系统的大量程探测。控制压电反射镜以 20 nm 为步长在垂直于固定面板的方向上运动,则实际加载的平移误差步长为  $20\sqrt{2}$  nm。为了减少子镜运动过程中累积误差的影响,将 $[-3.6 \mu\text{m}, 3.6 \mu\text{m}]$ 探测范围分为正量程和负量程,两个待测子孔径上加载平移误差的过程分为四个部分,分别为负量程 $\times$ 负量程、负量程 $\times$ 正量程、正量程 $\times$ 负量程、正量程 $\times$ 正量程,初始位置均为零误差的位置。子镜每运动一次采集一张图像,每个部分采集到 16002 张图像,四个部分共采集 64008 张点扩展函数图像,选取其中 57608 张用于网络的训练,另外 6400 张测试网络性能,同样对图像进行归一化处理后输入网络进行训练和测试。

图 8 为网络在整个三孔径实验数据集上训练和测试结果的 RMSE 分布直方图,以  $0.1\lambda_0$  ( $\lambda_0=600$  nm) 为标准对网络预测精度进行评估,根据图中数据可以得到平移误差的预测精度达到 95%。图 9 所示为两个待测子孔径上实际加载的平移误差值与网络预测值的分

布,可以看到网络预测结果与实际值整体没有出现太大偏差,计算得到测试样本残余 RMSE 平均值约为 30 nm。测试结果表明网络对三孔径系统仍具有高精度平移误差检测能力,但与两孔径系统检测精度相比略有下降,这是因为待测孔径数目越多,点扩展函数和平移误差之间的函数关系越复杂,网络拟合难度越大,三孔径实验要达到与两孔径实验相当的检测精度,需要的训练样本数量至少为两孔径训练样本数量的平方,采集难度非常大,现有实验条件无法满足采图需求。在检测实时性方面,三孔径系统检测所需时间约为 3 ms,与两孔径系统相差不大,说明在共相检测任务中,网络预测输出节点的数量不会显著影响检测实时性。

网络模型根据读取的点扩展函数图像推理出两个待测子孔径的平移误差值,对应的两个反射镜根据预测结果实现实时校正。闭环实验过程中的残差曲线如图 10(a)所示。开环状态下,两个子孔径相对于参考孔径的初始平移误差分别约为  $1.8 \mu\text{m}$  和  $-1.7 \mu\text{m}$ ,从第 100 步迭代开始进入闭环运行。从图 10 可以看到,两个子孔径的残差曲线同时实现快速稳定收敛,计算得到闭环后的三孔径系统的残余 RMSE 平均值约为 38 nm。闭环前后的点扩展函数图像如图 10(b)和图 10(c)所示。闭环校正后的点扩展函数分布非常接近图 4(d)所示的理想点扩展函数分布,验证了该方法在三孔径系统中的实时大量程高精度平移误差闭环校正能力。

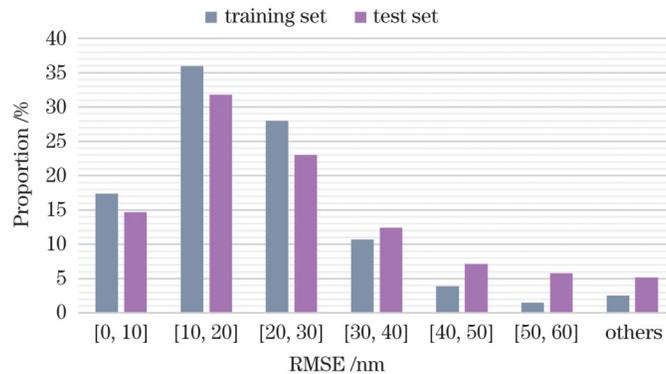


图 8 基于三孔径实验数据得到的训练集与测试集残余 RMSE 分布直方图

Fig. 8 Histogram of residual RMSE distribution on training set and test set using three-aperture experimental images

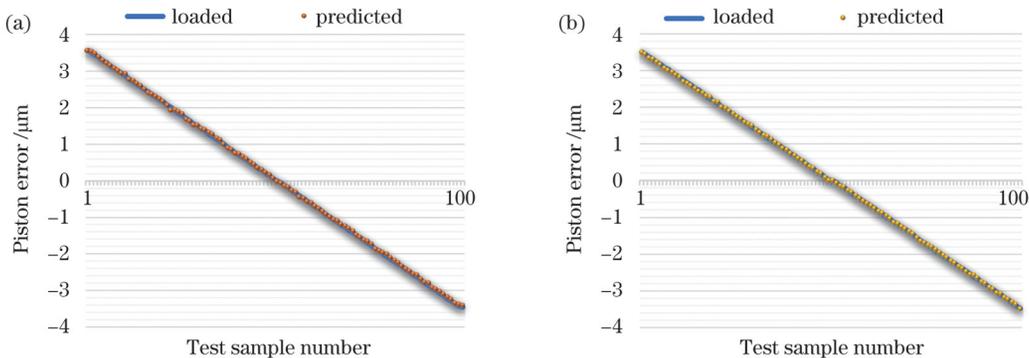


图 9 三孔径系统加载的平移误差与预测的平移误差对比图。(a)待测子孔径 1;(b)待测子孔径 2

Fig. 9 Comparison of loaded and predicted piston errors in three-aperture system. (a) Measured sub-aperture 1; (b) measured sub-aperture 2

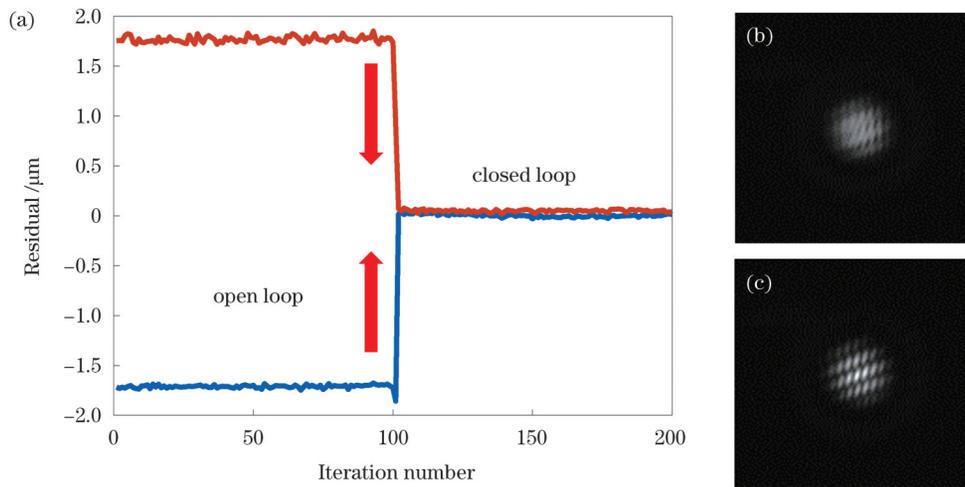


图 10 三孔径系统闭环校正实验结果。(a)残差收敛曲线;(b)闭环校正前图像;(c)闭环校正后图像

Fig. 10 Results of closed-loop correction experiment on three-aperture system. (a) Convergence curve of residual; (b) image without closed-loop correction; (c) image with closed-loop correction

## 4 分析与结论

深度学习共相技术作为一种智能检测手段,在提高探测精度和实时性等方面具有非常大的优势。为进一步推动深度学习共相技术的实用化进程,本文利用嵌入式计算平台实现了以轻量化 MobileNet 深度学习模型为基础的光学合成孔径平移误差闭环校正实验。通过宽带光照明将共相检测范围扩展为  $\pm 6\lambda_0$  ( $\lambda_0 = 600 \text{ nm}$ ),针对两孔径系统和三孔径系统分别采集实验图像对网络模型进行训练,以  $0.1\lambda_0$  ( $\lambda_0 = 600 \text{ nm}$ ) 为标准,测试结果准确率分别达到了 100% 和 95%。将训练好的模型部署到嵌入式平台上,基于实时读取的点扩展函数图像完成平移误差推理,利用压电快反镜对平移误差进行闭环控制。实验结果表明网络在两个系统上均实现了对平移误差的高精度稳定闭环校正,校正后残余 RMSE 平均值分别为 26 nm 和 38 nm。

本文方法基于单个卷积神经网络从焦面点扩展函数中提取平移误差值,极大地降低了系统的光学复杂度,同时端到端的模式也进一步简化了检测流程,可以实现残差曲线的快速稳定收敛。在本文搭建的闭环实验条件下,网络每完成一次检测仅需耗时约 3 ms,具有较好的实时性。综上所述,通过共相闭环实验,初步验证了深度学习共相技术在工程应用中的可靠性和优越性,对该技术的实用化进程具有重要推动作用。

## 参 考 文 献

- [1] Gunturk B K, Miller N J, Watson E A. Camera phasing in multi-aperture coherent imaging[J]. Optics Express, 2012, 20(11): 11796-11805.
- [2] Rabb D, Jameson D, Stokes A, et al. Distributed aperture synthesis[J]. Optics Express, 2010, 18(10): 10334-10342.
- [3] Dente G C, Tilton M L. Segmented mirror phasing using the focal-plane intensity[J]. Applied Optics, 2012, 51(3): 295-301.
- [4] Gibbard S G, MacIntosh B, Gavel D, et al. Titan: high-resolution speckle images from the Keck Telescope[J]. Icarus, 1999, 139(2): 189-201.
- [5] Chu C Y, Liu Z T, Chen M L, et al. Wide-spectrum optical synthetic aperture imaging via spatial intensity interferometry[J]. Opto-Electronic Advances, 2023, 6: 230017.
- [6] Chanan G, Troy M, Dekens F, et al. Phasing the mirror segments of the Keck Telescopes: the broadband phasing algorithm[J]. Applied Optics, 1998, 37(1): 140-155.
- [7] Chanan G, Ohara C, Troy M. Phasing the mirror segments of the Keck Telescopes II: the narrow-band phasing algorithm[J]. Applied Optics, 2000, 39(25): 4706-4714.
- [8] van Dam M A, McLeod B A, Bouchez A H. Dispersed fringe sensor for the Giant Magellan Telescope[J]. Applied Optics, 2016, 55(3): 539-547.
- [9] 张晓芳, 董冰, 黄一帆, 等. 分块式空间望远镜波前传感及控制方法的仿真研究[J]. 光学学报, 2009, 29(1): 7-11.  
Zhang X F, Dong B, Huang Y F, et al. Simulation research on wavefront sensing and correction algorithms for segmented space telescope[J]. Acta Optica Sinica, 2009, 29(1): 7-11.
- [10] 孟玉凤, 徐抒岩, 许博谦. 基于色散条纹传感技术的拼接镜共相方法[J]. 光学学报, 2016, 36(9): 0911006.  
Meng Y H, Xu S Y, Xu B Q. Method of segmented mirror co-phasing based on dispersed fringe sensing technology[J]. Acta Optica Sinica, 2016, 36(9): 0911006.
- [11] Chamot S R, Dainty C, Esposito S. Adaptive optics for ophthalmic applications using a pyramid wavefront sensor[J]. Optics Express, 2006, 14(2): 518-526.
- [12] Esposito S, Pinna E, Puglisi A, et al. Pyramid sensor for segmented mirror alignment[J]. Optics Letters, 2005, 30(19): 2572-2574.
- [13] 颜召军, 郑立新, 王超燕, 等. 四棱锥传感器在空间光干涉望远镜共相中的应用[J]. 光子学报, 2018, 47(11): 1128002.  
Yan Z J, Zheng L X, Wang C Y, et al. Application of pyramid sensor for co-phasing space optical interferometric telescope[J]. Acta Photonica Sinica, 2018, 47(11): 1128002.
- [14] Paxman R G, Fienup J R. Optical misalignment sensing and image reconstruction using phase diversity[J]. Journal of the Optical Society of America A, 1988, 5(6): 914-923.
- [15] Lee D J, Roggemann M C, Welsh B M, et al. Evaluation of least-squares phase-diversity technique for space telescope wave-front sensing[J]. Applied Optics, 1997, 36(35): 9186-9197.
- [16] 杨慧珍, 龚成龙, 李要球. 滤波函数对瞳面相位差波前传感器相位恢复效果的影响[J]. 中国激光, 2011, 38(s1): s114002.  
Yang H Z, Gong C L, Li Y Q. Effects of kind and size of filter function on phase retrieval for the wavefront sensor based on pupil phase diversity[J]. Chinese Journal of Lasers, 2011, 38(s1):

- s114002.
- [17] Gilles L, Vogel C R, Bardsley J M. Computational methods for a large-scale inverse problem arising in atmospheric optics[J]. *Inverse Problems*, 2002, 18(1): 237-252.
- [18] Paxman R G, Schulz T J, Fienup J R. Joint estimation of object and aberrations by using phase diversity[J]. *Journal of the Optical Society of America A*, 1992, 9(7): 1072-1085.
- [19] Paykin I, Yacobi L, Adler J, et al. Phasing a segmented telescope[J]. *Physical Review E*, 2015, 91(2): 023302.
- [20] 浦健, 桂进斌, 张凯. 基于深度学习的多尺度数字全息图重建[J]. *激光与光电子学进展*, 2022, 59(2): 0209001.
- Pu J, Gui J B, Zhang K. Multiscale digital hologram reconstruction based on deep learning[J]. *Laser & Optoelectronics Progress*, 2022, 59(2): 0209001.
- [21] 刘金香, 班伟, 陈宇, 等. 融合多维度 CNN 的高光谱遥感图像分类算法[J]. *中国激光*, 2021, 48(16): 1610003.
- Liu J X, Ban W, Chen Y, et al. Multi-dimensional CNN fused algorithm for hyperspectral remote sensing image classification[J]. *Chinese Journal of Lasers*, 2021, 48(16): 1610003.
- [22] 胡逸雯, 刘鑫, 匡翠方, 等. 基于深度学习的自适应光学技术研究进展及展望[J]. *中国激光*, 2023, 50(11): 1101009.
- Hu Y W, Liu X, Kuang C F, et al. Research progress and prospect of adaptive optics based on deep learning[J]. *Chinese Journal of Lasers*, 2023, 50(11): 1101009.
- [23] Guo Y M, Zhong L B, Min L, et al. Adaptive optics based on machine learning: a review[J]. *Opto-Electronic Advances*, 2022, 5(7): 200082.
- [24] Liu K X, Wu J C, He Z H, et al. 4K-DMDNet: diffraction model-driven network for 4K computer-generated holography[J]. *Opto-Electronic Advances*, 2023, 6(5): 220135.
- [25] Guerra-Ramos D, Díaz-García L, Trujillo-Sevilla J, et al. Piston alignment of segmented optical mirrors via convolutional neural networks[J]. *Optics Letters*, 2018, 43(17): 4264-4267.
- [26] Hui M, Li W Q, Liu M, et al. Object-independent piston diagnosing approach for segmented optical mirrors via deep convolutional neural network[J]. *Applied Optics*, 2020, 59(3): 771-778.
- [27] Wang Y R, Jiang F Y, Ju G H, et al. Deep learning wavefront sensing for fine phasing of segmented mirrors[J]. *Optics Express*, 2021, 29(16): 25960-25978.
- [28] 赵伟瑞, 王浩, 张璐, 等. 基于卷积神经网络的高精度分块镜共相检测方法[J]. *物理学报*, 2022, 71(16): 164202.
- Zhao W R, Wang H, Zhang L, et al. High-precision co-phase method for segments based on a convolutional neural network[J]. *Acta Physica Sinica*, 2022, 71(16): 164202.
- [29] Ma X F, Xie Z L, Ma H T, et al. Piston sensing of sparse aperture systems with a single broadband image via deep learning[J]. *Optics Express*, 2019, 27(11): 16058-16070.
- [30] Ma X F, Xie Z L, Ma H T, et al. Deep learning piston sensing for sparse aperture systems with simulated training data[J]. *IEEE Photonics Journal*, 2022, 14(4): 7444005.
- [31] 李斌, 杨阿坤, 孙赵祥, 等. 基于深度学习的拼接镜共相检测新方法研究[J]. *中国激光*, 2023, 50(22): 2204001.
- Li B, Yang A K, Sun Z X, et al. Research on co-phasing detection new method of segmented mirror based on deep learning[J]. *Chinese Journal of Lasers*, 2023, 50(22): 2204001.
- [32] Howard A G, Zhu M L, Chen B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications [EB/OL]. (2017-04-17) [2023-04-05]. <https://arxiv.org/abs/1704.04861>.

## Research on Co-Phasing Closed-Loop Experiment for Optical Synthetic Aperture Using Deep Learning

Ma Xiafei<sup>1,2,3</sup>, Yang Kaiyuan<sup>1,2,3,4</sup>, Ma Haotong<sup>1,2,3\*</sup>, Yang Hu<sup>1,2,3</sup>, Xie Zongliang<sup>1,2,3\*\*</sup>

<sup>1</sup>National Key Laboratory of Optical Field Manipulation Science and Technology, Institute of Optics and Electronics, Chinese Academy of Sciences, Chengdu 610209, Sichuan, China;

<sup>2</sup>Key Laboratory of Optical Engineering, Chinese Academy of Sciences, Chengdu 610209, Sichuan, China;

<sup>3</sup>University of Chinese Academy of Sciences, Beijing 100049, China;

<sup>4</sup>School of Automation Engineering, University of Electronic Science and Technology of China, Chengdu 610209, Sichuan, China

### Abstract

**Objective** Optical synthetic aperture is an effective technical approach for developing large aperture telescopes. The key to achieving diffraction limit for the actual resolution of synthetic aperture based opto-electronic telescopes lies in the real-time sensing and correction of piston error between sub-apertures. Among the traditional methods, the specific optics-based methods measure piston errors from the pupil information modulated by specially designed hardware, which inevitably increases the system complexity. The image-based methods can measure piston errors directly from the intensity image, which simplifies the system. However, it does need a large amount of iterative optimization calculation, thus failing to realize instant correction. Recently, deep learning method has contributed to many areas with piston sensing included, which is capable of achieving end-to-end piston sensing by fitting the mapping relationship between piston error and intensity image. Although many efforts have been made to improve the piston sensing performance of the deep learning model, most of the studies still stay in the simulation stage. In the few experimental studies, only piston sensing is implemented while co-phasing closed-loop correction has never been worked out. In the present study, we establish an optical synthetic aperture imaging experimental platform and implement co-phasing closed-loop experiment using deep learning approach. We hope that our research could be helpful for promoting the practical process of deep learning based co-phasing technology.

**Methods** Real-time closed-loop piston error correction is achieved for two-aperture system and three-aperture system, respectively. First, the experimental platform is built, where broadband light is utilized to remove  $2\pi$  ambiguity and sequence piston

errors are loaded to the sub-apertures to generate corresponding training images. Then, a lightweight MobileNet convolutional neural network (CNN) is established to learn the nonlinear mapping relationship between broadband point spread function (PSF) and piston error. By converting standard convolution module into depthwise separable convolution module, MobileNet effectively reduces model parameters and computational complexity while ensuring the overall performance of network, thus realizing fast inferring. When the loss function converges to the minimum stably, the training process is completed and the testing dataset is used to evaluate the performance of the network. In the next step, the well-trained model, which is capable of inferring the piston errors directly from the intensity images, is deployed on an embedded computing platform. When implementing the closed-loop correction, the image captured by charge-coupled device (CCD) is transferred to the computing platform and the instant piston error is obtained through forward inference of model in real time. Finally, piston error correction is carried out by controlling the piezo steering mirror based on the predicted output.

**Results and Discussions** The experimental results show that the lightweight MobileNet deep learning model realizes high-precision piston sensing and a large capture range of  $\pm 6\lambda_0$  ( $\lambda_0=600$  nm) is achieved by using 550–650 nm broadband light. For the two-aperture imaging system, the average value of the root mean square error (RMSE) between testing outputs of the network and true piston error values is about 18 nm (Fig. 6). Besides, the predicted values are very close to the true values in the whole capture range. In the process of closed-loop correction, the residual curve converges to the zero line rapidly and stably. The initial piston error is  $2.3\lambda_0$  and the average residual after closed-loop correction is about  $0.043\lambda_0$ . In addition, the PSF image with closed-loop correction is almost the same as the ideal image (Fig. 7). Each piston prediction takes about 3 ms for the lightweight MobileNet, while the time is 10 ms for the VGG-19 model. It is evident that our method has significant advantage in real-time performance. Then another experiment is implemented in the three-aperture system, where the average value of RMSE between testing outputs of the network and true piston values is about 30 nm (Fig. 9). The average residual after closed-loop correction is about  $0.063\lambda_0$ , which shows a reduced accuracy compared with the correction results of two-aperture system. This is because increasing sub-aperture number will complexify the mapping relationship between the PSF and the piston error. Correspondingly, the training data needed and the difficulty in training will greatly increase. Nevertheless, our study shows that there is little difference in the piston sensing time between the two-aperture system and the three-aperture system, which means the increase of sub-apertures to be measured has little effect on the real-time performance.

**Conclusions** In the present study, deep learning based co-phasing closed-loop experiment of optical synthetic aperture is successfully implemented. This technology uses a single lightweight MobileNet CNN to extract piston information from focused PSF image, thus greatly reducing optical complexity of the system. At the same time, the end-to-end mode further simplifies the sensing process and achieves rapid and robust piston error estimation. Under the experimental conditions established in our study, it takes about 3 ms to complete each detection, which means good real-time performance is achieved. Fine co-phasing control with high sensing accuracy is realized for two-aperture system as well as three-aperture system. In summary, the reliability and superiority of deep learning co-phasing technology in engineering application have been preliminarily verified through the co-phasing closed-loop experiments.

**Key words** imaging systems; convolutional neural network; piston error; optical synthetic aperture; co-phasing closed loop