

## 基于深度学习的拼接镜共相检测新方法研究

李斌\*, 杨阿坤, 孙赵祥, 陈楠

华东交通大学智能机电装备创新研究院, 江西 南昌 330013

**摘要** 基于互相关算法的双波长共相检测方法在大量程共相误差检测中,存在检测速度慢、精度低的问题。针对该问题,利用卷积神经网络的方法建立拼接镜的平移(piston)误差预测模型,以实现双波长共相检测方法在大量程共相误差下的快速、准确检测。首先,将两波长下的圆孔衍射图像拼接作为卷积神经网络的训练数据。训练结束后,将包含 piston 误差信息的圆孔衍射拼接图像输入到训练好的模型中,可直接检测出 piston 误差值。仿真结果表明:基于卷积神经网络的共相方法具有高的检测精度、快的检测速度及较好的抗噪性和泛化能力。该方法为平移误差的测量提供了一种可行且易于实现的方案。

**关键词** 测量; 卷积神经网络; piston 误差; 拼接镜; 圆孔衍射

**中图分类号** O436 **文献标志码** A

**DOI:** 10.3788/CJL221357

## 1 引言

为了探索宇宙奥秘,观测的图像须尽可能清晰,并且图像具有尽可能高的对比度,以研究昏暗天体的特征。更大的望远镜直径意味着更高的分辨率和更强的集光能力,也意味着能获得更清晰的天体图像。但由于成本和加工技术等原因,目前单块镜口径极限仅为 8 m 级。拼接镜技术使更大口径望远镜成为了可能。采用分段主镜的地基望远镜包括等效口径为 10 m 的凯克望远镜<sup>[1]</sup>、郭守敬望远镜(LAOMST)<sup>[2]</sup>、直径达 39.9 m 的欧洲极大望远镜(E-ELT)<sup>[3]</sup>。空间分段望远镜项目的任务是天文或地球观测,例如 2022 年发射的由 18 个部分组成的詹姆斯·韦伯空间望远镜(JWST)<sup>[4]</sup>的任务是研究宇宙的下一代空间天体。然而,拼接镜的应用也带来了新的难题,其中拼接镜各子镜的相对位置的误差严重影响望远镜最终的成像质量。为了获得与口径相当的单口径分辨率,必须使拼接镜精共相。

为了获得高质量的图像,拼接镜的平移(piston)误差须小于 100 nm<sup>[5]</sup>。目前常见的检测 piston 误差的方法主要包括依赖于特定硬件传感器的宽窄带相位算法<sup>[6-8]</sup>、四棱锥传感器法<sup>[9-10]</sup>、曲率传感器法<sup>[11]</sup>、色散条纹传感器法<sup>[12-13]</sup>、基于图像的相位恢复法<sup>[14]</sup>、相位差法<sup>[15]</sup>等,但这些方法都无法同时实现大量程、高精度、高能量利用率、较快速度的检测。目前双波长算法虽然能够有效削弱  $2\pi$  模糊效应,但其在检测量程较大时,运算速度较慢,不能达到拼接镜的快速共

相检测的要求。

卷积神经网络(CNN)在图像处理领域中得到了广泛的应用<sup>[16-19]</sup>。为了解决传统 piston 误差方法存在的问题,近年来许多学者将深度学习与 piston 误差检测结合,提出了基于深度学习的 piston 误差检测新方法。1990 年,Angel 等<sup>[20]</sup>提出利用反向传播(BP)神经网络实现相位误差检测。2019 年,Nishizaki 等<sup>[21]</sup>证明利用卷积神经网络可以从单幅白光强度图像中直接估计出波前信息。同年,Li 等<sup>[22]</sup>将 PD 算法和神经网络相结合,首先将 piston 误差校正到 PD 算法的检测范围内,然后进行精细的同相校正。Ma 等<sup>[23-24]</sup>证明,神经网络经过适当的训练后,可以直接从宽带扩展图像中提取 piston 误差,同时讨论了孔的数目和大小对 piston 误差预测精度的影响。2021 年,Wang 等<sup>[25]</sup>利用 Bi-GRU 神经网络有效地解决了其他神经网络在训练过程中的梯度消失问题,该网络在拟合精度和训练速度上均优于其他网络。目前,基于深度学习的共相检测大都是利用整个拼接镜的强度图像,而拼接子镜个数多,造成目前基于深度学习的共相模型复杂、鲁棒性差。

本文没有利用传统互相关(CC)算法,而是提出了一种基于卷积神经网络的双波长共相检测方法。利用圆孔衍射原理,通过软件仿真得到圆孔衍射图案,将两个波长下包含 piston 误差的圆孔衍射图案进行拼接,得到训练网络的数据集。同时,构建卷积神经网络,利用建立的数据集训练圆孔衍射图案与 piston 误差的卷积神经网络模型。卷积神经网络构建完成后,通过在

收稿日期: 2022-10-24; 修回日期: 2022-11-30; 录用日期: 2023-01-09; 网络首发日期: 2023-02-07

基金项目: 国家自然科学基金(12103019)

通信作者: \*libingioe@126.com

拼接镜系统子镜间放置圆孔掩模,采集对应波长下的圆孔衍射图案,并将其作为神经网络的输入。利用训练好的卷积神经网络模型,直接输出子镜的 piston 误差。最后,通过仿真验证了该方法的有效性和准确性,确保了该方法能够成功应用于拼接镜的 piston 误差检测。该方法基于两子镜间圆孔衍射信息进行建模,而目前其他基于深度学习的共相检测方法是基于所有拼接子镜的信息进行建模,因此该方法较传统共相检测方法具有更高检测精度和效率,比目前基于深度学习的共相方法具有更好的鲁棒性。

## 2 基本原理

该方法基于圆孔的夫琅禾费衍射原理,在拼接子镜之间放置圆孔掩模,利用该圆孔的夫琅禾费衍射信息随 piston 的变化,计算得到子镜的 piston 误差。

圆孔检测原理如图 1 所示,圆孔半径为  $r$ ,上下半圆孔的距离为  $\delta$ ,则波前的光程差为  $2\delta$ 。当光源为单色光时,单个拼接子镜间的圆孔衍射图案的光强分布<sup>[26-27]</sup>为

$$I(\boldsymbol{\omega}, k\delta) = f^2(\boldsymbol{\omega}, k\delta) = \left[ f(\boldsymbol{\rho}, 0) \cos(k\delta) + f(\boldsymbol{\rho}, \pi/2) \sin(k\delta) \right]^2, \quad (1)$$

式中:  $\delta$  为拼接镜的 piston 误差;  $k=2\pi/\lambda$ , 其中  $\lambda$  为波长;  $\boldsymbol{\omega}$  为理想单色光在孔径像平面上的位置向量;  $\boldsymbol{\rho}$  为理想单色光在孔径平面上的位置向量。




图 1 圆孔检测原理示意图。(a)主视图;(b)左视图  
Fig. 1 Schematics of round hole detection principle. (a) Front view; (b) left view

$\delta$  从  $-\lambda/4$  变化到  $\lambda/4$  时的理论衍射图案如图 2 所示。可以看出,衍射图案随着  $\delta$  的变化而变化。当两个半圆孔间的  $\delta$  为  $-\lambda/4$  时,衍射图案是两个完全对称的衍射光斑,随着两个半圆孔间的  $\delta$  的减小,下半部分




图 2 不同  $\delta$  下半径为  $r$  的两个圆孔的理论衍射图(单色光)  
Fig. 2 Theoretical diffraction patterns of two circular holes with radius  $r$  under different  $\delta$  (monochromatic light)

的衍射光斑慢慢消失,上半部分的衍射光斑缓慢向下移动;当两个半圆孔间的  $\delta$  为零时,衍射图案为一个常见的圆形图案(理想艾里斑),然后随着两个半圆孔间的  $\delta$  的增加,衍射光斑继续缓慢向下移动,衍射图上半部分慢慢出现光斑且逐渐变亮;直到  $\delta$  为  $\lambda/4$  时,又形成了两个完全对称的衍射光斑,此时的图案与起始光斑的亮度和形状相同,即表明圆孔衍射图案的周期为  $\lambda/2$ 。

对于任何使用单色光或窄带光的干涉测距方法,在测量的光路长度中都存在  $2\pi$  模糊效应,这是由所涉及的波前或条纹的重复性质引起的。如果



图 3 两个波长的检测范围的示例。(a)  $\lambda_1$ ; (b)  $\lambda_2$

Fig. 3 Example of detection ranges for two wavelengths. (a)  $\lambda_1$ ; (b)  $\lambda_2$

假设波长  $\lambda_1 < \lambda_2$ , 当  $\lambda_1/(\lambda_2 - \lambda_1)$  的值为整数时, 双波长检测的实际周期<sup>[29]</sup>为

$$P = \frac{n+1}{2} \lambda_1 = \frac{n}{2} \lambda_2, \quad (2)$$

式中:  $n$  取整数, 取值范围为

$$\frac{\lambda_1}{\lambda_2 - \lambda_1} \leq n < \frac{\lambda_2}{\lambda_2 - \lambda_1}. \quad (3)$$

当  $\lambda_1/(\lambda_2 - \lambda_1)$  的值不为整数时, 双波长检测的实际周期为

$$P = \frac{n-1}{2} \lambda_2. \quad (4)$$

实际检测范围与模板间隔的关系为

$$P = \begin{cases} \frac{n-1}{2} \lambda_2, & \frac{n\lambda_1}{2} - \frac{(n-1)\lambda_2}{2} < \Delta < \frac{\lambda_2 - \lambda_1}{2} \\ \frac{n+1}{2} \lambda_1, & \Delta < \frac{n\lambda_1}{2} - \frac{(n-1)\lambda_2}{2} \end{cases}, \quad (5)$$

式中:  $\Delta$  为模板间隔, 即检测精度。

### 3 基于 CNN 模型的 piston 误差检测方法

#### 3.1 训练数据集的构建

根据双波长检测原理选取合适的两个波长, 选取  $\lambda_1 = 628 \text{ nm}$ ,  $\lambda_2 = 650 \text{ nm}$ 。由式(3)得  $n = 29$ , 实际检测周期为  $P = 9.1 \text{ } \mu\text{m}$ , 即实际检测范围为  $-4.55 \text{ } \mu\text{m} \leq P \leq 4.55 \text{ } \mu\text{m}$ 。由式(5)可得, 模板间隔的范围为  $6 \text{ nm} < \Delta < 11 \text{ nm}$ , 此时模板个数的选取范围为  $827 < n < 1516$ , 本文取  $n = 1500$ 。在网络的训练阶段, 通过 MATLAB 生成足够多的数量样本, 即圆孔衍射图案, 并具有正确的标签。为了更好地模拟拼接镜共相过程中拼接子镜的状态, 生成数据集时引入子镜间的间隙误差。间隙误差的定义为

在几个波长中进行测量, 这种不确定性就可以得到解决<sup>[28]</sup>。双波长检测方法与单波检测方法类似, 圆孔衍射图案都会随着子镜 piston 误差的增加而出现周期性变化。图 3 给出了利用双波长算法检测 piston 误差的一个简单示例, 仅显示了较小的捕获范围, 其中  $m_1, m_2$  均为正整数。可以看出: 同一 piston 误差在不同波长下有不同圆孔衍射图案, 而实际单个波长在单一 piston 误差下只能对应一个圆孔衍射图案, 通过同时匹配两波长在 piston 误差下的圆孔衍射图案, 即可消除  $2\pi$  模糊效应, 从而扩大检测量程。

$$R_1 = \frac{\Delta_{\text{gap}}}{r}, \quad (6)$$

式中:  $\Delta_{\text{gap}}$  为相邻子镜之间的距离。

本文将两个子镜间的间隙误差  $R_1$  设置在由 MATLAB 随机生成的  $[0, 0.3]$  范围内。数据集包含 360000 张训练样本、45000 张验证样本、45000 张测试样本, 测试样本不参与网络的训练。输入到网络中的图像为圆孔衍射图案的拼接图案, 其含有两波长下的 piston 误差, 如表 1 所示, 其图案的尺寸为  $256 \text{ pixel} \times 512 \text{ pixel}$ 。

#### 3.2 卷积神经网络结构

卷积神经网络经过长足的发展, 其结构有很多变体, 但都基本包括输入层 (Input Layer)、卷积层 (Convolution Layer)、池化层 (Pooling Layer)、全连接层 (Full Connected Layer) 以及输出层 (Output Layer)。训练数据集准备完成后, 利用 TensorFlow 开源机器学习软件库构建卷积神经网络的框架。由于网络训练用的数据集较大, 分类数较多 (1500 类), 当选择比较大、比较深的网络结构时, 网络训练时间过长, 对设备的要求也会成倍增加。因此我们选择轻量级的卷积神经网络结构 MobileNetV3<sup>[30]</sup> 作为网络的基础结构。本文基于 MobileNetV3 进行了多次搭建尝试, 根据训练效果的差异, 对网络结构及参数进行调整, 最终确定了图 4 所示的网络结构。其中与瓶颈结构相连的 Global Average pooling (GAP2d) 层代替全连接层, Global Average pooling 层能够有效减少全连接层中的大量参数, 减少过拟合。最后再添加一层全连接层, 网络最后的输入节点数为 1500 个。

#### 3.3 MobileNetV3 简介

MobileNetV3 是由 Google 团队在 2019 年提出的, 该团队在 MobileNetV2<sup>[31]</sup> 网络的基础上, 重新设计了

表 1 数据集示例  
Table 1 Examples of data sets

$R_1$	Category label is 4	Category label is 2	Category label is 0	Category label is -2.5	Category label is -4
$R_1=0$					
$R_1=0.2$					

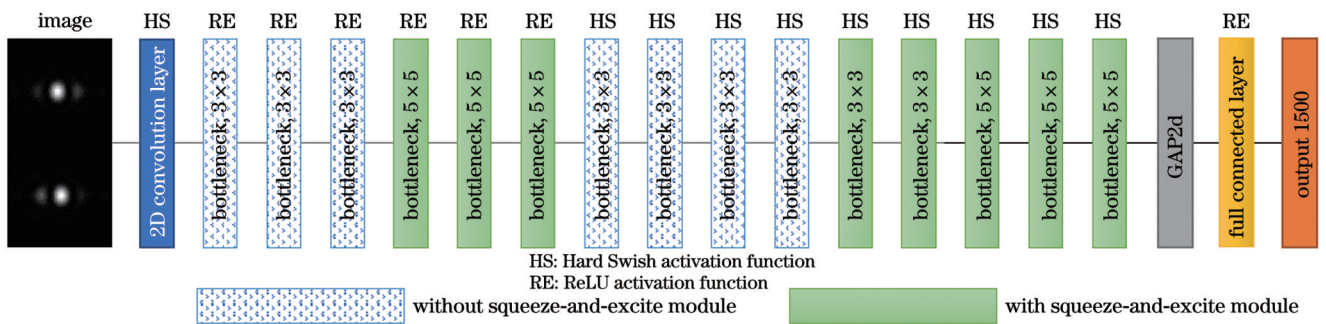


图 4 MobileNetV3 网络的结构示意图

Fig. 4 Schematic of MobileNetV3 network

网络的开头和结尾,同时引入了新的非线性 Hard Swish 激活函数:

$$H(x) = x \cdot \frac{R[6(x+3)]}{6} = \begin{cases} x, & x \geq 3 \\ \frac{x^2}{6} + \frac{x}{2}, & -3 < x < 3, \\ 0, & x \leq -3 \end{cases} \quad (7)$$

式中: $H(x)$ 为 Hard Swish 激活函数; $R(\cdot)$ 为 ReLU 函数; $x$ 为输入值。

图 5 绘制了 Hard Swish 激活函数图像以及它的导函数图像。可以看出,在网络训练时,Hard Swish 激活函数会将所有正向输入值小于 3 的值变为 0,而将所有正向输入值大于 3 的值原封不动地传给下一步。这种单向拟制作用使得神经网络中的神经元具有稀疏激活性,从而减少参数之间的依赖性,防止过拟合。

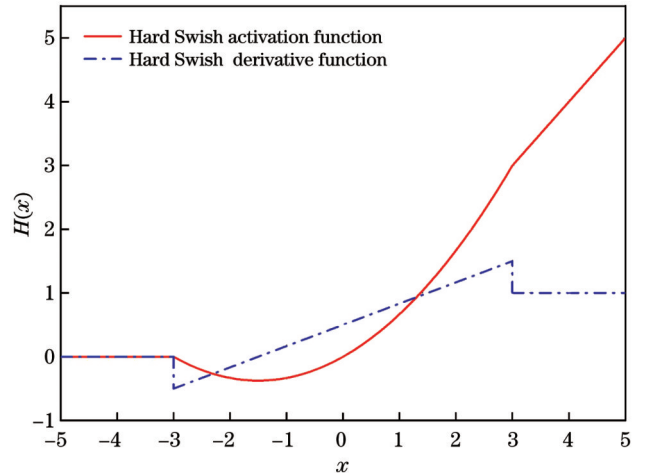


图 5 Hard Swish 激活函数及其导函数

Fig. 5 Hard Swish activation function and its derivative function

同时 MobileNetV3 还引入了注意力机制 (SE), 在正常的卷积操作后分出一个旁路分支,利用全局

信息嵌入操作和自适应重新校正操作得到特征通道的权重,再将该权重应用到原来的每个特征通道中,基于特定的网络学习任务,学习不同通道的重要性。

### 3.4 网络的训练

网络参数对训练效果有很大的影响。其中,批大小为 32,学习率为 0.001,训练 30 代,网络权值使用小批量梯度下降算法和 Adam 优化器<sup>[32]</sup>更新。网络训练所使用的中央处理器(CPU)为 Intel(R) Core(TM) i5-10400 F,频率为 2.90 GHz,使用的图形处理单元(GPU)是 NVIDIA GeForce RTX 3050。Python 的软件版本为

3.9.7, TensorFlow 的软件版本为 tensorflow\_gpu-2.8.0。

图 6(a)绘制了验证集在训练过程中的准确率变化曲线,最高精度达到 99.85%。最后利用测试集对网络进行评估,每张图片的评估时间约为 4.3 ms,测试集的评估准确率为 99.9%,在 45000 张图片中仅有 34 张图片预测出错,残余均方根误差(RMSE)为 36.7 nm。图 6(b)所示为测试集的预测结果,可以看出,预测出错的图片的预测结果与实际 piston 误差完全相反,例如实际 piston 误差为 2.8684  $\mu\text{m}$ ,预测结果为 -2.8806  $\mu\text{m}$ ,两个 piston 误差对应的圆孔衍射模板相似,神经网络并不能准确区分。




图 6 神经网络的性能指标。(a)网络训练过程中验证集的准确率;(b)测试集的预测结果

Fig. 6 Performance indexes of neural network. (a) Accuracy of validation set during network training; (b) prediction result of test set

## 4 基于数值模拟的性能演示

当拼接镜工作时,两拼接子镜须预留一定的间隙,这样温度变化时拼接子镜不会相互挤压,但这会导致间隙误差;圆孔掩模中心与两拼接子镜重叠区域中心在对准时会存在一定偏差,在实际拼接镜工作时,就会产生偏心误差;拼接镜工作时探测光强会因相机产生的噪声而发生变化。这些误差都会对成像造成影响。制作数据集时只考虑了间隙误差,因此还需考虑所设

计的网络对偏心误差和相机噪声的鲁棒性。

### 4.1 圆孔偏心误差下神经网络的鲁棒性分析

定义偏心误差为

$$R_2 = \frac{\Delta_{ecc}}{r}, \quad (8)$$

式中: $\Delta_{ecc}$ 为圆孔理论位置与实际位置之差。

测试用的数据集与训练用的数据集的制作方法相同,仅仅是增加了偏心误差,同时考虑了数据样本数对检测误差的影响。图 7 为不同偏心误差下多种测试样

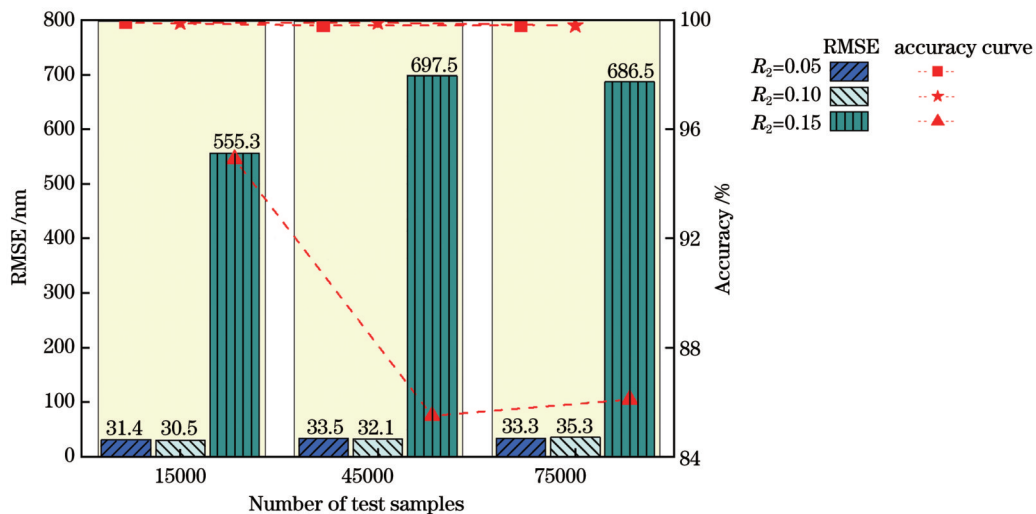


图 7 不同  $R_2$  下测试样本数与残余 RMSE 的关系以及测试的准确率

Fig. 7 Relationship between number of test samples and residual RMSE and test accuracies under different  $R_2$

本数量对应的残余 RMSE 值和测试的准确率。当偏心误差  $R_2=0.05$  或  $0.10$  时,测试样本的准确率均达到了 99.8% 以上,均方根误差小于 40 nm。当偏心误差  $R_2=0.15$  时,预测效果变差,测试样本的准确率低于 95%。可以看出:预测数据样本的数量对卷积神经网络模型的预测结果无明显影响。

#### 4.2 相机噪声下神经网络的鲁棒性分析

假设信号光强峰值为  $I_{max}$ ,噪声均值为  $I_{avg}$ ,标准差

为  $\delta_1$ ,现定义信噪比( $S_{SNR}$ )为

$$S_{SNR} = \frac{I_{max} - I_{avg}}{\delta_1} \quad (9)$$

图 8 为不同噪声误差下多种测试样本数量对应的残余 RMSE 值和测试的准确率。 $S_{SNR}=40$  或  $45$  时,检测样本的准确率均达到了 99.8% 以上,均方根误差均在 35 nm 左右。当  $S_{SNR}=35$  时,检测效果变差,检测样本的准确率低于 96%。可以看出:预测数据样本的数量对卷积神经网络模型的预测结果无明显影响。

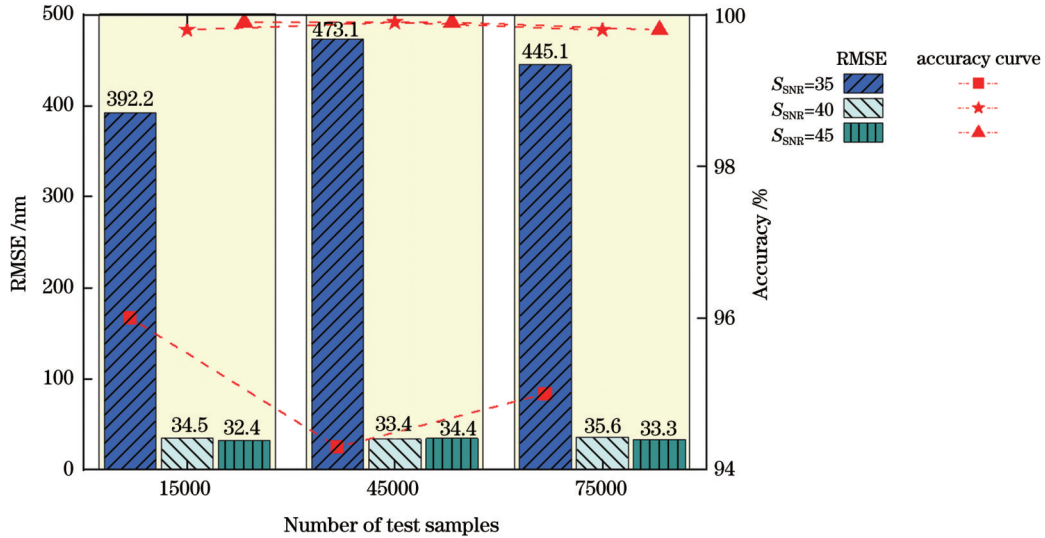


图 8 不同测试样本信噪比下测试样本数与残余 RMSE 的关系以及测试的准确率

Fig. 8 Relationship between number of test samples and residual RMSE and test accuracies under different signal-to-noise ratios

#### 4.3 多种误差同时存在时神经网络的鲁棒性分析

在获取实际含有 piston 误差的衍射图片时,由于电荷耦合器件(CCD)相机造成的相机噪声,子镜未完全校准而产生的偏心误差、间隙误差往往同时存在,因此,需分析多种误差同时存在时卷积神经网络模型对检测精度的影响。图 9 为不同  $R_2$  和  $S_{SNR}$  下的残余

RMSE 值及测试的准确率。当  $S_{SNR}=40, R_2=0.05$  或  $S_{SNR}=45, R_2=0.05$  时,测试样本的准确率均达到了 99.8% 以上,均方根误差小于 40 nm。当  $S_{SNR}=40, R_2=0.10$  时,检测效果变差,检测样本的准确率低于 99.4%。可以看出:预测数据样本的数量对卷积神经网络模型的预测结果无明显影响。

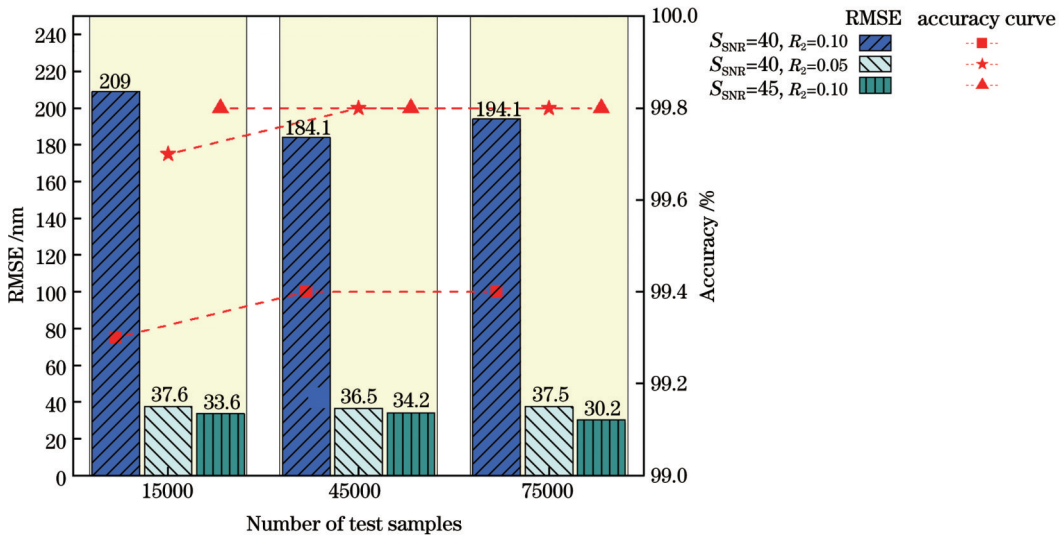


图 9 不同  $R_2$  和  $S_{SNR}$  下的残余 RMSE 值及测试的准确率

Fig. 9 Residual RMSEs and test accuracies under different  $R_2$  and  $S_{SNR}$

根据以上分析可得,本文提出的利用卷积神经网络的双波长检测方法,不仅实现了 piston 误差的大规模、高精度测量,而且具有较强的抗噪能力。

#### 4.4 与基于互相关算法的双波长共相检测方法的比较

为了说明本文提出的方法相较于传统互相关算法的优势,利用 3.1 节生成的数据集,用两种共相检测方法检测 1500 组 piston 误差图像,图像含有随机生成的 0~0.3 的间隙误差,得到的结果如图 10 所示。可以看出,利用 CNN 检测 piston 误差的准确率为 99.87%,仅有 2 张图片预测出错。利用互相关算法检测 piston 误差的准确率为 44%,其中误差在一个波长范围内的准确率为 98.4%。同时表 2 给出了两种检测方法的各项参数,其中  $\lambda=650\text{ nm}$ 。由表 2 可以看出,本文提出的基于卷积神经网络的 piston 误差检测方法能同时实现实时和高精度的检测。

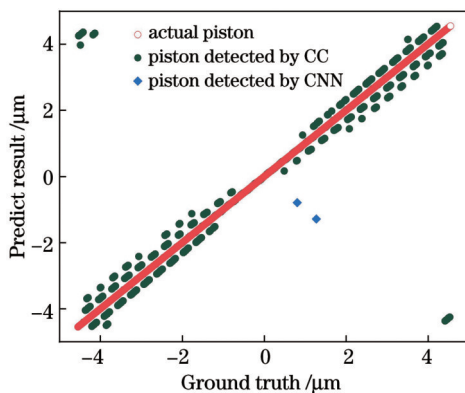


图 10 不同检测方法下 piston 误差值的检测结果

Fig.10 Detection results for piston errors under different detection methods

表 2 两种共相误差检测方法的技术指标

Table 2 Technical indexes of two co-phasing error detection methods

Detection method	Detection range	$\Delta/\text{nm}$	Response time /s	Accuracy / %
CC	$(-7\lambda, 7\lambda)$	6.1	268.22	98.4
CNN	$(-7\lambda, 7\lambda)$	6.1	15.08	99.87

## 5 结 论

基于圆孔衍射原理,提出了利用卷积神经网络的共相检测方法,实现了拼接镜更快速、更准确的共相检测。首先通过仿真分析了波长为 650 nm 和 628 nm 时 piston 检测范围为  $-4.55\sim 4.55\ \mu\text{m}$  的共相检测数据集,并基于该数据集验证了所提方法的快速性和准确性,其中验证集的准确率超过了 99.8%,测试集的准确率超过了 99.9%,残余 RMSE 为 36.7 nm,单次检测时间为 45 ms。同时验证了多种误差情况下卷积神经网络的鲁棒性,结果表明:基于卷积神经网络的共相

检测方法具有较好的泛化能力,当信噪比  $>40$ ,偏心误差  $R_2 < 0.1$  时,残余 RMSE 小于 40 nm。仿真分析结果表明:基于卷积神经网络的双波长检测方法能够达到量程大、精度高、检测速度快的共相检测要求。该研究为共相检测方法在工程实验中的应用提供了参考。

## 参 考 文 献

- [1] Jerry E N, Peter R G. Overview of the performance of the W.M. Keck observatory[J]. Proceedings of SPIE, 1994, 2199: 82-93.
- [2] 李珊珊,樊东卫,崔辰州,等. LAMOST 天体光谱数据开放共享的回顾与展望[J]. 中国科技资源导刊, 2022, 54(1): 47-55, 82. Li S S, Fan D W, Cui C Z, et al. Review of LAMOST open data access and future prospect[J]. China Science & Technology Resources Review, 2022, 54(1): 47-55, 82.
- [3] Janson M, Henning T, Quanz S P, et al. Occulter to earth: prospects for studying earth-like planets with the E-ELT and a space-based occulter[J]. Experimental Astronomy, 2021: 1-14.
- [4] Life, the universe and JWST[J]. Nature Astronomy, 2022, 6(2): 169.
- [5] 苏定强,崔向群. 主动光学: 新一代大望远镜的关键技术[J]. 天文学进展, 1999, 17(1): 1-14. Su D Q, Cui X Q. Active optics: key technology of the new generation telescopes[J]. Progress in Astronomy, 1999, 17(1): 1-14.
- [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] 郑彬,陆培芬,陈永和,等. 拼接式反射镜共相误差检测[J]. 光学学报, 2017, 37(11): 1112002. Zheng B, Lu P F, Chen Y H, et al. Co-phase error detection of segmented mirrors[J]. Acta Optica Sinica, 2017, 37(11): 1112002.
- [9] Huang L S, Wang J L, Chen L, et al. Visible pyramid wavefront sensing approach for daylight adaptive optics[J]. Optics Express, 2022, 30(7): 10833-10849.
- [10] 马舒凡,鲜浩,王胜千. 合成孔径系统平移误差的四棱锥传感器检测方法[J]. 激光与光电子学进展, 2023, 60(15): 1528001. Ma F S, Xian H, Wang S Q. Detection method of piston error of synthetic aperture system by pyramid sensor[J]. Laser & Optoelectronics Progress, 2023, 60(15): 1528001.
- [11] An Q C, Wu X X, Lin X D, et al. Large segmented sparse aperture collimation by curvature sensing[J]. Optics Express, 2020, 28(26): 40176-40187.
- [12] Hedglen A D, Close L M, Haffert S Y, et al. Lab tests of segment/petal phasing with a pyramid wavefront sensor and a holographic dispersed fringe sensor in turbulence with the Giant Magellan Telescope high contrast adaptive optics phasing testbed [J]. Journal of Astronomical Telescopes, Instruments, and Systems, 2022, 8(2): 021515.
- [13] 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.
- [14] Robert A G, Robert C. Wavefront sensing by phase retrieval[J]. Proceedings of SPIE, 1979, 0207: 32-39.
- [15] Zhang L, Zhao H, Yi H W, et al. Modified phase diversity technique to eliminate Poisson noise for reconstructing high-resolution images[J]. Proceedings of SPIE, 2019, 10838: 108380R.
- [16] 孔繁镛,周永波,沈秋,等. 基于卷积神经网络的端到端多光谱

- 图像压缩方法[J]. 中国激光, 2019, 46(10): 1009001.
- Kong F Q, Zhou Y B, Shen Q, et al. End-to-end multispectral image compression using convolutional neural network[J]. Chinese Journal of Lasers, 2019, 46(10): 1009001.
- [17] 孙正, 王树雁. 深度学习在血管内光学相干层析成像中的应用现状[J]. 激光与光电子学进展, 2022, 59(22): 2200002.
- Sun Z, Wang S Y. Application of deep learning in intravascular optical coherence tomography[J]. Laser & Optoelectronics Progress, 2022, 59(22): 2200002.
- [18] 袁坤, 霍力. 用于视网膜 OCT 图像分层的多尺度补全卷积神经网络[J]. 中国激光, 2021, 48(15): 1507004.
- Yuan K, Huo L. Multiple-scale inpainting convolutional neural network for retinal OCT image segmentation[J]. Chinese Journal of Lasers, 2021, 48(15): 1507004.
- [19] 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.
- [20] 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.
- [21] Nishizaki Y, Valdivia M, Horisaki R, et al. Deep learning wavefront sensing[J]. Optics Express, 2019, 27(1): 240-251.
- [22] Li D Q, Xu S Y, Wang D, et al. Large-scale piston error detection technology for segmented optical mirrors via convolutional neural networks[J]. Optics Letters, 2019, 44(5): 1170-1173.
- [23] 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.
- [24] Ma X F, Xie Z L, Ma H T, et al. Piston sensing for sparse aperture systems with broadband extended objects via a single convolutional neural network[J]. Optics and Lasers in Engineering, 2020, 128: 106005.
- [25] 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.
- [26] 李斌, 吴建, 刘燕德, 等. 拼接镜主动共相实验研究[J]. 光子学报, 2018, 47(2): 0212003.
- Li B, Wu J, Liu Y D, et al. Co-phasing experiment of active optics for segmented mirror[J]. Acta Photonica Sinica, 2018, 47(2): 0212003.
- [27] 李斌, 刘燕德, 谢锋云. 拼接镜新型粗共相检测方法[J]. 光学精密工程, 2018, 26(11): 2647-2653.
- Li B, Liu Y D, Xie F Y. Coarse co-phasing detection of segmented mirrors[J]. Optics and Precision Engineering, 2018, 26(11): 2647-2653.
- [28] Lofdahl M G, Eriksson H. Algorithm for resolving  $2\pi$  ambiguities in interferometric measurements by use of multiple wavelengths[J]. Optical Engineering, 2001, 40(6): 984-990.
- [29] Li B, Yu W H, Tang J L, et al. Theory and experiment of phasing detection by use of two wavelengths[J]. Applied Optics, 2016, 56(1): 1-7.
- [30] Howard A, Sandler M, Chen B, et al. Searching for MobileNetV3 [C] // 2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27-November 2, 2019, Seoul, Republic of Korea. New York: IEEE Press, 2020: 1314-1324.
- [31] Sandler M, Howard A, Zhu M L, et al. MobileNetV2: inverted residuals and linear bottlenecks[C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 4510-4520.
- [32] Kingma D P, Ba J. Adam: a method for stochastic optimization [EB/OL]. (2014-12-22) [2022-10-06]. <https://arxiv.org/abs/1412.6980>.

## Research on New Co-phasing Detection Method of Segmented Mirror Based on Deep Learning

Li Bin\*, Yang Akun, Sun Zhaoxiang, Chen Nan

*Intelligent Electromechanical Equipment Innovation Research Institute, East China Jiaotong University,  
Nanchang 330013, Jiangxi, China*

### Abstract

**Objective** A large aperture telescope is needed to achieve long distance observations. The size of a single aperture telescope is limited by processing costs and other factors, and the segmented mirror technology is expected to break through the single aperture telescope limit. The key to the realization of segmented mirror technology is fine co-phasing. Currently, the most widely used technique for co-phasing detection is the broadband and narrowband Shack-Hartmann (S-H) method. The broadband S-H detection range is large, but the accuracy is low (30 nm), whereas the narrowband S-H method has a high detection accuracy of 6 nm; however, there is  $2\pi$  ambiguity effect and its detection range is  $\lambda/2$ . The conventional cross-correlation algorithm uses two wavelengths to detect the co-phasing error, which effectively solves the  $2\pi$  ambiguity effect in single wavelength detection and simultaneously improves the detection range. In this study, to address the slow detection speed and low accuracy of the current two-wavelength co-phasing detection method using the cross-correlation algorithm in the detection of large-range co-phasing errors, a two-wavelength co-phasing algorithm based on convolutional neural networks is proposed to achieve fast and accurate co-phasing detection in large-range co-phasing errors. First, the circular diffraction image splicing at the two wavelengths is used as the training data for the convolutional neural network. After training, the circular diffraction splicing image containing the piston error information is input into the trained model, and the piston error value is detected directly. The robustness of the convolutional network based on convolutional networks under different error situations is also analyzed.

**Methods** Based on the principle of circular diffraction, the circular diffraction pattern with the piston error information is first obtained through software simulation, and the circular diffraction patterns corresponding to the piston error at the two wavelengths are



used to splice and obtain the data set for training the network. The convolutional neural network is then constructed, and the model of the circular aperture diffraction pattern and piston error is trained using the established data set. Finally, after the convolutional neural network is trained, the circular diffraction pattern at the corresponding wavelength is collected by inserting a circular aperture mask between the sub-mirrors of the segmented mirror system, and the obtained circular diffraction pattern is used as the input of the neural network. The piston error between the two sub-mirrors is directly obtained using the trained convolutional neural network model. The robustness of the convolutional neural network is also analyzed for different error situations.

**Results and Discussions** The convolutional neural network model is trained with 99.85% accuracy in the validation set and 99.9% accuracy in the test set, with a residual root-mean-square error (RMSE) of 36.7 nm (Fig. 6). The robustness of the convolutional neural network model under multiple error cases is discussed. When only the eccentricity error ( $R_2$ ) is present, the residual RMSE of the convolutional neural network is less than 40 nm at  $R_2 \leq 0.1$  (Fig. 7). When only the noisy signal-noise-ratio ( $S_{\text{SNR}}$ ) is present, the residual RMSE of the convolutional neural network is less than 40 nm for  $S_{\text{SNR}} \geq 40$  (Fig. 8). When both errors are present, the residual RMSE of the convolutional neural network is less than 40 nm for  $S_{\text{SNR}} > 40$  and the eccentricity error  $R_2 < 0.1$  (Fig. 9). It is also demonstrated that the number of prediction data samples has no significant effect on the prediction results of the convolutional neural network model. Finally, comparing the convolutional neural network-based detection method with the traditional cross-correlation algorithm (Fig. 10 and Table 2), the convolutional neural network takes 15.88 s to predict 1500 sets of piston error images successively under the same conditions. Only two images are predicted incorrectly, compared with the lower performance of the traditional cross-correlation algorithm.

**Conclusions** Based on the principle of circular diffraction, this study proposes the use of a convolutional neural network for the co-phasing detection method to solve the problem of slow operation speed based on the cross-correlation algorithm in the current two-wavelength detection co-phase error method and to achieve faster and more accurate co-phasing detection of the segmented mirror. The robustness of the convolutional neural network under several error situations is also demonstrated. The detection method based on the convolutional neural network is compared with the traditional cross-correlation algorithm. The simulation analysis shows that the two-wavelength detection method based on the convolutional neural network can achieve the requirements of co-phasing detection with a large range, high accuracy, and fast detection speed. The study provides an experimental reference for the future application of the co-phasing detection method in engineering experiments.

**Key words** measurement; convolutional neural network; piston error; segmented mirror; circular diffraction