

## 基于卷积神经网络的高精度分块镜共相检测方法\*

赵伟瑞<sup>1)2)†</sup> 王浩<sup>1)2)</sup> 张璐<sup>1)2)</sup> 赵跃进<sup>1)2)</sup> 褚春艳<sup>1)2)‡</sup>

1) (北京理工大学光电学院, 北京 100081)

2) (精密光电测试仪器及技术北京市重点实验室, 北京 100081)

(2022年3月10日收到; 2022年4月27日收到修改稿)

为获得与单口径望远镜相当的空间分辨率, 使成像系统成像质量达到或接近衍射极限, 拼接主镜式望远镜的分块子镜应确保实现共相位拼接, 本文针对拼接主镜式望远镜高精度平移 (piston) 误差检测问题, 提出了一种基于卷积神经网络的高精度平移误差检测方法. 通过在成像系统的出瞳面上设置具有离散孔的光阑, 构建了对平移误差极为敏感的点扩散函数图像数据集, 根据此数据集的特点搭建了具有高性能的网络模型, 并测试得到网络的最佳检测范围. 仿真结果表明, 在略小于一个波长的捕获范围内, 单个网络能够准确地输出一个或多个分块子镜的平移误差; 应用于六子镜成像系统时, 平移误差检测精度达  $0.0013\lambda$  RMS (root mean square), 并且方法对残余倾斜 (tip-tilt) 误差、波前像差、CCD 噪声、光源带宽具有良好的鲁棒性. 该方法简单快速, 可广泛应用于分块镜系统的平移误差检测.

**关键词:** 分块镜, 平移误差, 卷积神经网络, 点扩散函数

**PACS:** 42.25.Hz, 42.30.Kq, 42.30.Lr, 42.30.-d

**DOI:** 10.7498/aps.71.20220434

## 1 引言

随着太空探索需求的不断增加, 对望远镜分辨率的要求也越来越高, 导致望远镜主镜口径的不断增大. 由于受毛坯制备、加工工艺、镜面检测、运输、发射等多方面因素的限制, 制造 8 m 以上的单口径主镜望远镜非常困难<sup>[1-4]</sup>. 因此, 当前大多数大型望远镜使用分块式拼接主镜来获得高分辨率<sup>[5-8]</sup>. 为获得与单口径望远镜相当的空间分辨率, 使成像系统成像质量达到或接近衍射极限, 在拼接主镜式望远镜的出瞳面处, 与各分块子镜对应的各子波面应实现光学共相位拼接, 平移 (piston) 误差即为子波面偏离共相位位置 (参考波面位置) 的轴向光程差, 要求平移误差小于  $0.025\lambda$  RMS.

国内外针对平移误差检测均展开了深入研究,

并提出了许多有效的检测方法. 平移误差检测方法包括粗测方法和精测方法, 应用较广的平移粗测方法有宽带夏克哈特曼法<sup>[9]</sup>、色散条纹法<sup>[10]</sup>、分类神经网络检测法<sup>[11]</sup>等, 这类方法能够实现较大的检测范围, 但需要借助精测方法进行进一步的检测. 也有很多经典的平移精测方法被提出, 虽然它们能够实现较高的检测精度, 但在方法实现过程中存在一定限制, 例如迈克尔逊干涉法<sup>[12]</sup>对振动、温度及气流扰动非常敏感, 因此对使用环境要求十分严苛; 曲率波前传感器<sup>[13]</sup>和泽尼克相衬共相传感器<sup>[14]</sup>都具有较高的灵敏度, 检测光路简单, 但需切换不同波长的光源或不同带宽的滤光片提高检测范围, 过程繁琐, 测量范围和速度不易同时提高; 金字塔波前传感器<sup>[15-16]</sup>使用灵活、运行效率高、抗噪性能好, 可结合子镜扫描技术或波长扫描技术扩大检测量程, 但对四棱锥镜的锥点角加工精度要求较高;

\* 国家自然科学基金 (批准号: 11874086) 资助的课题.

† 通信作者. E-mail: [zwrei@bit.edu.cn](mailto:zwrei@bit.edu.cn)

‡ 通信作者. E-mail: [xyzccy@163.com](mailto:xyzccy@163.com)

二维色散条纹法<sup>[17]</sup>需要增置阵列色散元件才能实现全口径内的共相位误差检测,且需定期对光谱在 CCD 上的位置进行标定;相位恢复法<sup>[18]</sup>需要增加相应的分光元件及透镜滤轮,来获得算法所需的焦面和离焦面的波前信息,并且探测过程耗时较长;朗奇光栅共相检测法<sup>[19]</sup>能同时实现较大的检测范围和较高的精度,但是该方法只适用于主镜为球面的拼接镜;电容式<sup>[20]</sup>及电感式<sup>[21]</sup>位移传感器系统结构相对简单,但使用中要考虑抗电磁干扰的问题,并且都只能检测相邻子镜间的相对位移,使用前需进行零位标定。

随着深度学习技术的快速发展,卷积神经网络(convolutional neural networks, CNN)在图像识别领域获得极大的成功,基于 CNN 的平移误差检测方法应运而生.早在 2007 年, Yi 等<sup>[22]</sup>就提出了一种基于自组织特征映射网络(self-organizing feature map, SOFM)的位相差异波前传感方法,以人工提取的特征点作为网络的输入,大大缩减了网络训练样本集的规模,该方法最终在三孔径系统中实现了范围为  $\pm 0.4\lambda$ ,精度为  $\lambda/14$  的平移检测;2018 年, Dailos 等<sup>[23]</sup>采用 CNN 实现了点目标场景下对合成孔径的共相误差检测,通过采用多波长和多网络并行的方法突破  $2\pi$  不定性的限制,其检测精度可达  $0.0087\lambda$ ,但方法在采集数据时需切换单波长及多波长光源,且需手动截取图片作为数据集样本,这些增加了数据集收集的难度以及操作的复杂度; Hui 等<sup>[24]</sup>提出了一种基于一对焦点和离焦面图像的平移精测方法,该方法加深了网络层数,训练完成后的 CNN 对于六子镜系统的传感精度约为  $\lambda/20$ ; Ma 等<sup>[25]</sup>选用了网络结构更为复杂的深度卷积神经网络对四子镜系统的平移误差进行检测,检测精度提升为  $\lambda/32$ . 基于 CNN 的方法的硬件结构简单,并且训练完成后的 CNN 工作时无需迭代计算即可快速输出平移误差值,但此类方法的精度仍需进一步提高。

为了配合平移粗测方法使用,并实现更高精度的平移误差检测,以满足共相位要求,本文提出了一种基于 CNN 的平移误差高精度检测方法.通过在光学系统中设置具有离散圆孔的光阑,构建了一个全新的包含丰富平移特征信息的数据集;而后根据此数据集的特点自主搭建了能够准确捕获平移相关特征的 CNN 模型;通过仿真寻找到该方法的最佳检测范围,并在六子镜成像系统中测试了方法的精度以及鲁棒性。

## 2 基本原理

### 2.1 数学模型

基于 CNN 的平移检测方法的本质是利用 CNN 学习输入图像与平移误差之间的映射关系,故图像可作为 CNN 数据集的基本条件是:图像灰度值的变化应与平移误差存在明确的映射关系.图像对于平移变化的灵敏度越高, CNN 能够实现的精度就越高.通过在系统的出瞳面上放置具有离散圆孔的光阑,可以丰富点扩散函数(point spread function, PSF)图像数据集中与平移相关的特征信息,从而为 CNN 更高精度地检测平移误差提供数据基础.为验证 PSF 图像作为 CNN 数据集的理论可行性,本文以两子镜拼接系统为例,建立单色光条件下子镜间平移误差与系统 PSF 关系的数学模型。

将光阑放置在两子镜拼接系统的出瞳面上,光阑上设置两个离散圆孔,分别与两个子镜相对应,无限远的星光经子镜反射后由离散孔采集、经后继成像透镜聚焦在其焦平面处的 CCD 上, CCD 获取的像面强度分布图像即为 PSF 图像.设光阑面坐标系为  $(xoy)$ ,成像透镜像面坐标系为  $(uov)$ .光阑两离散孔的尺寸及其相对位置如图 1 所示。




图 1 光阑子孔径分布

Fig. 1. Sub-pupils distribution of the diaphragm.

设离散孔的直径为  $D$ ,两孔圆心坐标分别为  $(-B/2, 0)$ ,  $(B/2, 0)$ .则系统光瞳函数可表示为

$$G(x, y) = \text{circ}\left(\frac{x - B/2, y}{D/2}\right) \cdot \exp(i\varphi_1) + \text{circ}\left(\frac{x + B/2, y}{D/2}\right) \cdot \exp(i\varphi_2), \quad (1)$$

式中,  $\text{circ}(\cdot)$  为圆域函数,  $\varphi_1$ ,  $\varphi_2$  分别为两离散孔采集波面的初始相位,相位差  $\Delta\varphi$  为

$$\Delta\varphi = \varphi_2 - \varphi_1 = \frac{2\pi}{\lambda} p, \quad (2)$$

式中,  $p$  为两离散孔所采集子波面的轴向光程差,

也即平移误差,  $\lambda$  为系统所用光源的波长, 则:

$$p = \frac{\lambda(\varphi_2 - \varphi_1)}{2\pi}. \quad (3)$$

依据傅里叶光学原理, 由光瞳函数可得系统 PSF:

$$\begin{aligned} \text{PSF}(u, v) &= \frac{1}{\lambda^2 f^2} |\text{FT}[(G(x, y))]|^2 \\ &= \left[ 2 \frac{\left(\frac{D}{2}\right)^2 \cdot \text{J}_1^2\left(\frac{\pi D}{\lambda f} \sqrt{u^2 + v^2}\right)}{u^2 + v^2} \right] \\ &\quad \times \left[ 1 + \cos k \left( p - \frac{B}{f} u \right) \right] \\ &= F_{\text{diffraction}} \cdot F_{\text{interference}}, \end{aligned} \quad (4)$$

式中  $f$  为成像透镜焦距,  $\text{FT}[\cdot]$  为傅里叶变换符号,  $k = 2\pi/\lambda$ ,  $\text{J}_1(\cdot)$  表示一阶贝塞尔函数;  $F_{\text{diffraction}}$  为衍射因子, 是两个单孔衍射的光强的叠加;  $F_{\text{interference}}$  为干涉因子, 为两离散孔子波面的相干叠加. 衍射因子和干涉因子分别表示为

$$F_{\text{diffraction}} = 2 \frac{\left(\frac{D}{2}\right)^2 \cdot \text{J}_1^2\left(\frac{\pi D}{\lambda f} \sqrt{u^2 + v^2}\right)}{u^2 + v^2}, \quad (5)$$

$$F_{\text{interference}} = 1 + \cos k \left( p - \frac{B}{f} u \right). \quad (6)$$

从 (4)–(6) 式可知, PSF 即焦面光强分布为两孔衍射及两孔干涉共同作用的结果, 为受衍射项调制的余弦干涉条纹, 平移误差为干涉项的相位. 因此, 当共相位检测系统设定后, 焦面光强分布由平移误差决定, 当检测范围小于一个波长时, 平移误差与其存在一对一的映射关系, PSF 随子镜间平移的变化而变化, 其变化灵敏度与干涉测量的灵敏度相当.

通过设置不同平移误差值, 可获得相应数量

的 PSF 图像, 将 PSF 图像作为样本, 对应的平移误差值作为标签, 即可构建 CNN 训练和测试所需的数据集. 图 2 为数据集中的两个 PSF 图像样本, 其中图 2(a) 为无平移误差时的 PSF 图像, 图 2(b) 为平移误差为  $0.3\lambda$  时的 PSF 图像, 图中红色虚线为平移为 0 时中央条纹位置, 白色虚线为平移为  $0.3\lambda$  时中央条纹位置. 可以看到, 当平移值发生变化时, PSF 图像中的干涉条纹会发生移动, 强度值也会出现明显变化. 这意味着数据集中的图像样本对平移值变化极为敏感, CNN 可以更轻松、更准确地从图像样本中捕获平移相关信息.

## 2.2 网络模型

CNN 的输入为 PSF 图像的像素矩阵, 输出为平移值. 子镜间存在的平移误差会引起 PSF 图像中干涉条纹的移动, 干涉条纹的移动量与平移值存在明确的函数关系. 因此, 网络需要能够准确学习到干涉条纹移动量这一空间特征与平移值之间的映射关系. CNN 是通过卷积层中的卷积核去过滤提取图片中的局部特征, 感受野越大图像的空间位置特征能够更好地被提取. 此外, 更深层的网络具有更好的非线性表达能力, 可以学习到更复杂的函数关系. 根据上述分析以及多次训练结果的反馈, 确定了如图 3 所示的网络结构.

网络大体可以分为 3 部分:

第 1 部分, 包括 7 个卷积核大小为  $3 \times 3$  的卷积层及两个池化层. 网络输入为  $128 \times 128$  的单通道 PSF 图像, 经过两层堆叠的卷积层后提取到 32 个大小为  $128 \times 128$  的特征图; 而后进入池化层, 池化方式选用最大值池化, 尺寸为  $2 \times 2$  的池化单元, 池化层可以有效地缩小参数矩阵的尺寸, 从而加快计算速度并且能够防止过拟合, 经过池化层后特征图尺寸缩减为  $64 \times 64$ ; 之后经过三层堆叠卷




图 2 不同平移误差对应的 PSF 图像样本 (a)  $p = 0$ ; (b)  $p = 0.3\lambda$

Fig. 2. PSF image samples corresponding to different piston errors: (a)  $p = 0$ ; (b)  $p = 0.3\lambda$ .

积层、最大值池化层以及两层堆叠卷积层后, 可得到 128 个  $32 \times 32$  特征图. 这部分采用堆叠的卷积层和池化层的组合结构, 对 PSF 图像进行初步特征抽象提取. 2 个堆叠的  $3 \times 3$  卷积核的感受野大小等同于一个  $5 \times 5$  卷积核, 3 个堆叠的  $3 \times 3$  卷积核的感受野大小等同于一个  $7 \times 7$  卷积核, 这种架构可以在确保较大的感受野的同时增加网络的深度, 更深层的模型将具有更好的非线性表达能力, 可以学习更复杂的映射关系.

第 2 部分, 采用两个多层感知机卷积 (multi-layer perceptron convolution, Mlpconv) 层对特征进行进一步的融合及提取, 得到 256 个  $16 \times 16$  的特征图. Mlpconv 层的结构如图 4 所示, 包括一次普通的  $3 \times 3$  卷积以及两次  $1 \times 1$  卷积, 其相当于一个由卷积层和多层感知机 (multi-layer perceptron, MLP) 构成的微型网络. 一般的卷积操作只能提取线性特征, 而 Mlpconv 通过在卷积层后加入一个 MLP 使其能够提取非线性特征, 这种结构能够实现跨通道特征融合、增强网络局部模块的抽象表达

能力.

第 3 部分, 包括一个全局平均池化层. 全局平均池化层使用过  $n$  个池化单元对输入特征图进行平均池化操作,  $n$  等于输出值的个数, 也即待测子镜的个数, 池化单元的尺寸等于输入特征图的尺寸, 即  $16 \times 16$ . 全局平均池化层的输出为  $n$  个特征值, 再通过线性函数即可输出  $n$  个待测子镜的平移值. 使用全局平均池化层替换全连接层不仅可以有效地降低参数量, 而且能够整合全局空间信息、增强网络鲁棒性.

网络中所有卷积层的卷积核移动步长均为 1, 池化层的池化单元的移动步长均为 2, 每个卷积层后面都添加了 ReLU(rectified linear unit) 激活函数.

训练过程中应用的损失函数为均方误差 (mean squared error, MSE), 优化函数为 Adam 算法, 网络训练环境为 python3.7, tensorflow-gpu2.1.0 以及 keras-gpu2.3.1, 训练所用计算机处理器为 Intel(R) Core(TM)i7-8750H CPU @2.20 GHz, 显卡型号为 NVIDIA GeForce GTX 1060.

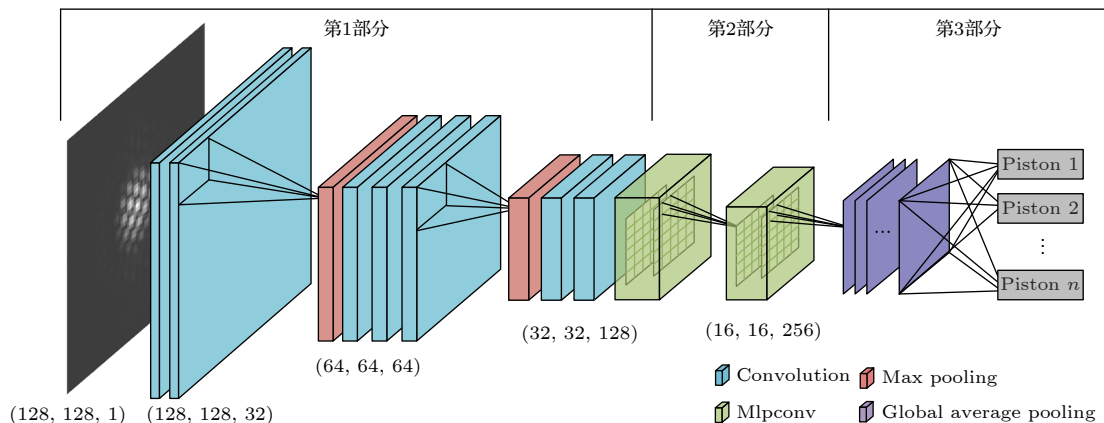


图 3 CNN 网络结构

Fig. 3. The network structure of CNN.




图 4 Mlpconv 结构图

Fig. 4. Structure diagram of Mlpconv.

### 3 仿真与分析

确定了网络训练集及 CNN 架构后, 本文展开了大量仿真实验, 对方法的最佳检测范围、应用于六子镜成像系统时的检测精度以及鲁棒性进行了分析.

#### 3.1 最佳检测范围分析

本文旨在小范围内实现平移的高精度检测, 因此需要测试本文所搭建的 CNN 的最佳检测范围, 也即 CNN 在保证高精度检测情况下能实现的最大检测范围. 由于分块镜系统的子镜个数以及数据集的规模不会对 CNN 的检测范围的测试造成影响, 因此为了方便得出结论, 使用相对少量的数据对双子镜系统进行测试. 仿真系统参数的设置参考 JWST 系统<sup>[26]</sup>: 离散光阑孔的直径  $D = 0.3$  m, 两孔的中心距离  $B = 1.73$  m, 成像透镜的焦距  $f = 131.4$  m, 入射光波长为  $\lambda = 632.8$  nm. 根据 (4) 式可知, 平移误差为 PSF 余弦干涉项的相位, 由于余弦函数存在  $2\pi$  周期性, 因此当系统的输入光源为单波长光源时, 方法理论上能够实现的最大检测范围为  $[-0.5\lambda, 0.5\lambda]$ .

在选定检测范围内随机为测试子镜设置 7000 个平移值, 相应可得到 7000 个 PSF 图像样本, 其中 5000 个样本作为训练集、1000 个作为验证集、1000 个作为测试集. 不同检测范围对应的网络预测精度如表 1 所示, 当检测范围为  $[-0.6\lambda, 0.6\lambda]$  时, 由于余弦函数的周期性, CNN 无法有效检测平

移误差, 当检测范围由  $[-0.5\lambda, 0.5\lambda]$  缩减为  $[-0.48\lambda, 0.48\lambda]$  时, 网络精度明显提升, 而继续缩减检测范围网络的精度只会出现轻微波动, 并不会明显提升.

为了分析这一现象, 图 5 给出了检测范围分别为  $[-0.5\lambda, 0.5\lambda]$ ,  $[-0.49\lambda, 0.49\lambda]$  及  $[-0.48\lambda, 0.48\lambda]$  时设定平移值对应的网络预测误差分布图. 当检测范围为  $[-0.5\lambda, 0.5\lambda]$  时, 区间边缘网络预测结果出现异常大的误差, 这种情况会极大地影响方法的整体精度; 而将检测范围缩减为  $[-0.49\lambda, 0.49\lambda]$ , 区间边缘的异常值仍然存在; 当检测范围为  $[-0.48\lambda, 0.48\lambda]$  时, 边缘异常值全部被消除, 区间内网络预测误差分布较均匀, 因而在  $[-0.48\lambda, 0.48\lambda]$  基础上进一步缩减检测范围时, 网络精度不再有大提升. 为了确定区间边缘的检测出现异常是否由数据集导致, 对不同平移误差对应的 PSF 图像之间的互相关系数进行了测试, 其中, 平移为  $0.49\lambda$  和  $0.48\lambda$  对应的 PSF 图像之间的互相关系数为 0.93, 而平移为  $0.47\lambda$  和  $0.48\lambda$  对应的 PSF 图像之间的互相关系数同样为 0.93, 由此可说明 PSF 图像对于范围为  $[0.48\lambda, 0.5\lambda]$  的平移误差的变化的敏感度和  $[-0.48\lambda, 0.48\lambda]$  相同, 数据集不是导致异常出现的原因. 因此, 出现此现象的原因是文中搭建的 CNN 模型的最大有效检测范围为  $[-0.48\lambda, 0.48\lambda]$ . 实际上, 可以通过加深网络模型实现更大的检测范围, 但其精度远低于图 2 所示的 CNN, 文中所述方法的目的是为了配合大范围的平移粗测方法使用, 实现小量程范围内的极高精度的平移误差检测, 故选择牺牲小部分的检测范围.

表 1 不同检测范围时方法的检测精度

Table 1. Detection precision of the method in different detection ranges.

检测范围/ $\lambda$	$\pm 0.6$	$\pm 0.5$	$\pm 0.49$	$\pm 0.48$	$\pm 0.47$	$\pm 0.46$	$\pm 0.4$	$\pm 0.35$
精度/ $\lambda$ RMS	0.14	0.013	0.0065	0.0014	0.0017	0.0017	0.0014	0.0018




图 5 不同检测范围时设定平移值对应的 CNN 预测误差分布图 (a)  $[-0.5\lambda, 0.5\lambda]$ ; (b)  $[-0.49\lambda, 0.49\lambda]$ ; (c)  $[-0.48\lambda, 0.48\lambda]$

Fig. 5. The distribution of CNN prediction errors corresponding to the piston value in different detection ranges: (a)  $[-0.5\lambda, 0.5\lambda]$ ; (b)  $[-0.49\lambda, 0.49\lambda]$ ; (c)  $[-0.48\lambda, 0.48\lambda]$ .

综上所述, 可以确定方法的最佳检测范围为  $[-0.48\lambda, 0.48\lambda]$ .

### 3.2 六子镜成像系统仿真

六子镜成像系统主镜结构及其对应的 PSF 图像如图 6 所示, 设置子镜 1 为参考子镜, 其余 5 块子镜为测试子镜. 系统参数的设置为: 离散光阑孔的直径为  $D = 0.3 \text{ m}$ , 孔 1—孔 6 的中心的坐标 (单位: m) 为:  $(0, 2.15)$ ,  $(1.45, 1.17)$ ,  $(0.86, -0.98)$ ,  $(0, -2.35)$ ,  $(-1.16, -0.67)$ ,  $(-1.53, 1.30)$ . 则孔 1 和孔 2 的中心距  $B_{12}=1.75 \text{ m}$ , 孔 1 和孔 3 的中心距  $B_{13}=3.25 \text{ m}$ , 孔 1 和孔 4 的中心距  $B_{14}=4.50 \text{ m}$ , 孔 1 和孔 5 的中心距  $B_{15}=3.05 \text{ m}$ , 孔 1 和孔 6 的中心距  $B_{16}=1.75 \text{ m}$ , 成像透镜的焦距为  $f = 131.4 \text{ m}$ , 入射光波长为  $\lambda = 632.8 \text{ nm}$ .

在  $[-0.48\lambda, 0.48\lambda]$  范围内分别为子镜 2 到 6 设置 20000 组随机平移值, 相应得到 20000 张 PSF 图像, 每张 PSF 图像都对应着 5 个测试子镜的平移值. 则六子镜成像系统的数据集共由 20000 个样本和相应的 20000 组标签构成, 每组标签包含 5 个标签, 六子镜系统对应的数据集划分情况见表 2.

表 2 六子镜成像系统数据集划分情况

Table 2. Division of six submirror imaging system data set.

数据集	占比/%	样本形状	标签形状
训练集	80	(16000, 128, 128, 1)	(16000, 5)
验证集	10	(2000, 128, 128, 1)	(2000, 5)
测试集	10	(2000, 128, 128, 1)	(2000, 5)

网络训练完成后, 使用测试集中的 2000 个样本对网络性能进行测试评估, 测试结果为: 子镜 2 的测试精度为  $0.00085\lambda \text{ RMS}$ , 即  $0.58 \text{ nm}$ ; 子镜 3 的为  $0.0013\lambda \text{ RMS}$ , 即  $0.82 \text{ nm}$ ; 子镜 4 为  $0.0022\lambda \text{ RMS}$ ,

即  $1.39 \text{ nm}$ ; 子镜 5 为  $0.0012\lambda \text{ RMS}$ , 即  $0.76 \text{ nm}$ ; 子镜 6 为  $0.00093\lambda \text{ RMS}$ , 即  $0.59 \text{ nm}$ . 图 7 为各测试子镜所有测试结果残余误差的分布直方图, 由图 7 可以发现: 子镜 2 和子镜 6 的结果最为接近, 两个子镜的平移的测试残余误差小于  $1 \text{ nm}$  的比例均在 90% 以上; 子镜 3 和子镜 5 的结果最为接近, 两者的测量精度略差于子镜 2 和 6, 但仍能保证大部分残余误差在  $1 \text{ nm}$  以内; 子镜 4 是 5 块子镜中测量结果最差的, 仅有 45.97% 的残余误差在  $1 \text{ nm}$  以内, 说明当一个子镜和另一个子镜之间的距离越来越远时, 测试误差也将越来越大. 综上所述, 六子镜成像系统中所有测试子镜的平均检测精度可以达到  $0.0013\lambda \text{ RMS}$ , 远超过衍射极限成像的条件, 故本文方法可以实现对六子镜成像系统中平移误差的高精度检测.

### 3.3 方法鲁棒性分析

本文方法是借助 CNN 从图像数据中获取平移误差信息的, 对于 CNN 模型而言, 当数据集中样本存在一定偏差, 尤其是训练样本与测试样本分布不一致时, CNN 预测效果会受到很大的影响. 前文的分析都是基于理想仿真条件下的, 而实际系统中存在的多种干扰因素不可避免地会引起数据集的偏差, 进而降低检测精度, 因此要求方法具有较好的鲁棒性. 为此, 在 3.2 节六子镜成像系统的测试集中分别引入残余倾斜 (tilt/tip) 误差、CCD 噪声、波前像差以及光源带宽, 而训练集仍使用理想条件下获取的 PSF 图像, 以测试评估方法的鲁棒性. 为了表述方便, 下文所述的平移检测精度皆取 5 块测试子镜检测精度的平均值, 以平移检测精度优于  $0.025\lambda \text{ RMS}$  为标准, 测试方法对不同干扰因素的允差.




图 6 六子镜成像系统 (a) 分块镜 (六边形) 和离散光阑孔 (圆形); (b) PSF 图像

Fig. 6. Six submirror imaging system: (a) Segments (hexagons) and sparse subpupils (circles); (b) PSF image.

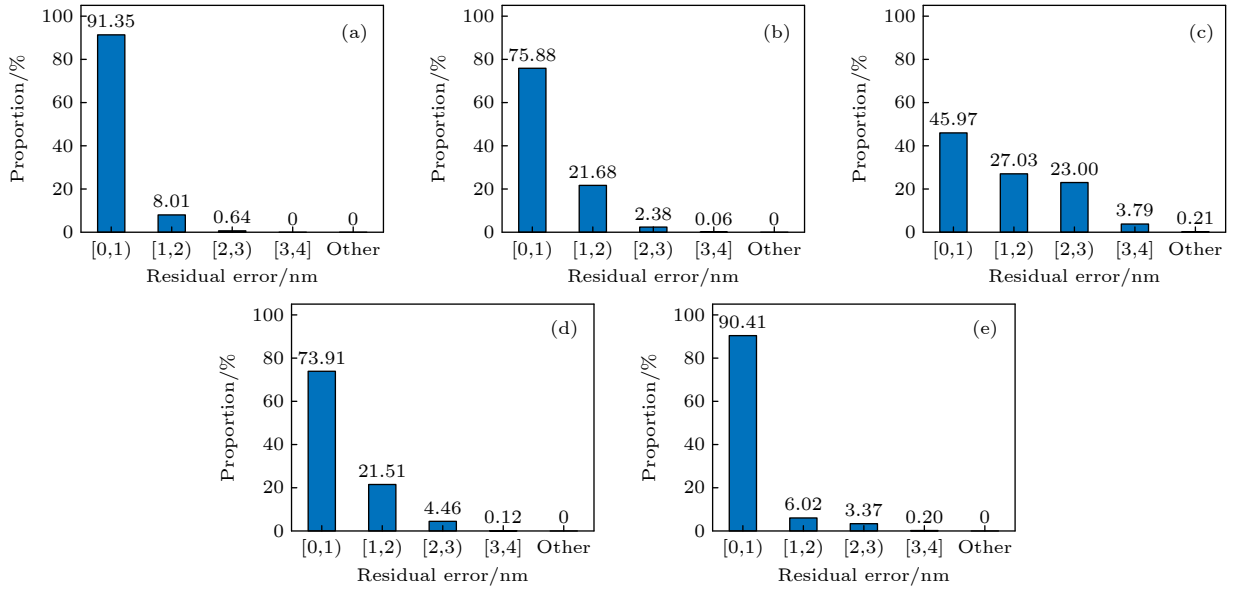


图 7 六子镜成像系统测试结果分布情况 (a) 子镜 2; (b) 子镜 3; (c) 子镜 4; (d) 子镜 5; (e) 子镜 6

Fig. 7. Distributions of errors over all the testing results for six submirror system: (a) Submirror 2; (b) submirror 3; (c) submirror 4; (d) submirror 5; (e) submirror 6.

### 3.3.1 残余倾斜误差

分块镜系统共相位误差包括沿法线方向的平移误差和沿径向/切向的倾斜误差, 其中平移误差的检测在完成倾斜误差校正后进行. 设在图 1 右光阑孔处, 绕  $y$  轴的 tip 误差表示为圆孔光阑边界与

$x$  轴交点处沿光阑法线方向上的最大位移  $a$ , 即倾斜角为  $\arctan \frac{a}{D/2}$ , 绕  $x$  轴的 tilt 误差表示为圆孔光阑边界与  $y$  轴交点处沿光阑法线方向上的最大位移  $b$ , 即倾斜角为  $\arctan \frac{b}{D/2}$ , 倾斜误差存在时, 系统点扩散函数  $\text{PSF}_{\text{TT}}$  可表示为

$$\text{PSF}_{\text{TT}}(u, v) = \left(\frac{D}{2}\right)^2 \left\{ \left[ \frac{J_1\left(\frac{\pi D}{\lambda f} \sqrt{u^2 + v^2}\right)}{\sqrt{u^2 + v^2}} \right]^2 + \left[ \frac{J_1\left(\frac{\pi D}{\lambda f} \sqrt{\left(u - \frac{2a}{\lambda D}\right)^2 + \left(v - \frac{2b}{\lambda D}\right)^2}\right)}{\sqrt{\left(u - \frac{2a}{\lambda D}\right)^2 + \left(v - \frac{2b}{\lambda D}\right)^2}} \right]^2 \right. \\ \left. + 2 \frac{J_1\left(\frac{\pi D}{\lambda f} \sqrt{u^2 + v^2}\right) J_1\left(\frac{\pi D}{\lambda f} \sqrt{\left(u - \frac{2a}{\lambda D}\right)^2 + \left(v - \frac{2b}{\lambda D}\right)^2}\right)}{\sqrt{u^2 + v^2} \sqrt{\left(u - \frac{2a}{\lambda D}\right)^2 + \left(v - \frac{2b}{\lambda D}\right)^2}} \cos k\left(p - \frac{B}{f}u\right) \right\}. \quad (7)$$

从 (7) 式可知, 当倾斜误差存在时, 平移误差仍仅存在于余弦干涉项中, 干涉条纹移动量不会受到残余倾斜误差影响, 故 CNN 能够在残余倾斜误差存在时从 PSF 中捕获平移信息. 但是, 在采集训练集和测试集 PSF 图像样本时, 残余倾斜误差的差异会引起除干涉条纹移动以外的光强分布变化, 这会降低最终平移误差的解算精度.

为验证校正后的残余倾斜误差对平移检测精度的影响程度, 测试了不同残余倾斜误差存在时方法的检测精度, 测试结果如表 3 所示, 方法对倾斜误差的允差为  $0.3\lambda$  (对应倾斜角度约为  $0.26 \text{ as}$ ) RMS. 并且基于斐索干涉仪共相方法<sup>[27-28]</sup>的倾斜校正的残余误差为  $0.004\lambda$  (对应倾斜角度约为  $3.5 \text{ mas}$ ) RMS, 对此倾斜值, 本文方法的平移检测精度几乎

不受影响 (精度仅出现  $10^{-4}$  量级的波动).

表 3 不同倾斜值时方法的检测精度

Table 3. Detection precision of the method in different tip-tilt values.

倾斜值/ $\lambda$ RMS	0.004	0.04	0.1	0.2	0.3	0.4
精度/ $\lambda$ RMS	0.0015	0.0040	0.0095	0.012	0.023	0.041

### 3.3.2 CCD 噪声

光学系统中将 CCD 相机作为探测器, CNN 数据集中的 PSF 图像直接从 CCD 上采集, CCD 噪声会直接影响本文方法的精度, 为此在数据集样本中引入不同程度的高斯噪声, 以测试不同信噪比情况下方法的平移检测精度, 其中图像信噪比  $R_{SN}$  定义为

$$R_{SN} = 10 \lg (P_s/P_n), \quad (8)$$

其中,  $P_s$  为信号功率,  $P_n$  为噪声功率. 测试结果见表 4, 方法对 CCD 噪声的允差为 30 dB, 而目前 CCD 相机信噪比普遍大于 40 dB, 所以方法对于 CCD 噪声的鲁棒性能够满足实际系统的要求.

表 4 不同信噪比值时方法的检测精度

Table 4. Detection precision of the method in different signal-to-noise ratio.

$R_{SN}/\text{dB}$	50	45	40	35	30	25
精度/ $\lambda$ RMS	0.0033	0.0037	0.0058	0.0091	0.019	0.073

### 3.3.3 波前像差

波前像差是点光源发出的球面波经光学系统后形成的波前与理想球面波之间的距离, 上述模拟是在完全消除子镜像差的假设下进行的, 然而, 这些像差在实验中无法被完全消除, 设置的光阑孔采集到的各子镜的反射子波面携带了波前像差信息, 这将降低平移的检测精度, 因此需要测试方法对于波前像差的鲁棒性.

以 Zernike 多项式来表征子镜波前像差, 像差阶数取 4—11 阶, 各阶系数等权分布. 不同像差情况下, 网络的检测精度如表 5 所示, 方法对 4—11 阶像差允差为  $0.05\lambda$  RMS.

表 5 不同像差时方法的检测精度

Table 5. Detection precision of the method in different aberrations.

像差值/ $\lambda$ RMS	0.01	0.02	0.03	0.04	0.05	0.06
精度/ $\lambda$ RMS	0.0047	0.0095	0.014	0.019	0.024	0.032

### 3.3.4 光源带宽

实际应用中不存在理想的单色光源, 因此需要考虑光源带宽对方法检测精度的影响. 对 (4) 式对波长  $\lambda$  求积分可得宽光谱光源条件下像平面上的光强分布  $\text{PSF}_c$  表达式:

$$\text{PSF}_c(u, v, \lambda) = \int_{\lambda_0 - \frac{\Delta\lambda}{2}}^{\lambda_0 + \frac{\Delta\lambda}{2}} \text{PSF}(u, v, \lambda) S(\lambda) d\lambda, \quad (9)$$

式中,  $S(\lambda)$  为各个波长的权重,  $\Delta\lambda$  为光源带宽. 假设  $S(\lambda) = 1$ , 则  $\text{PSF}_c$  表达式可简化为

$$\begin{aligned} \text{PSF}_c(u, v, \lambda) &= \int_{\lambda_0 - \frac{\Delta\lambda}{2}}^{\lambda_0 + \frac{\Delta\lambda}{2}} \text{PSF}(u, v, \lambda) d\lambda \\ &= \int_{\lambda_0 - \frac{\Delta\lambda}{2}}^{\lambda_0 + \frac{\Delta\lambda}{2}} \frac{\left(\frac{D}{2}\right)^2 \cdot J_1^2\left(\frac{\pi D}{\lambda f} \sqrt{u^2 + v^2}\right)}{u^2 + v^2} \\ &\quad \times \left[2 + 2 \cos k \left(p - \frac{B}{f} u\right)\right] d\lambda. \end{aligned} \quad (10)$$

此时, 图像强度分布随着平移误差的变化规律仍然与单光源情况相同. 理论上, CNN 能够从宽光谱光源条件下获取的 PSF 图像中检测平移误差信息. 为测试方法对于光源带宽的鲁棒性, 分别将不同的光源带宽下获取的 PSF 图像作为测试集, 以测试 CNN 的检测精度, 测试结果如表 6 所示.

表 6 不同带宽时方法的检测精度

Table 6. Detection precision of the method with different spectral widths.

带宽 $\Delta\lambda/\text{nm}$	$10^{-6}$	$10^{-4}$	$10^{-2}$	1	5	10
精度/ $\lambda$ RMS	0.0014	0.0015	0.0015	0.0023	0.0025	0.0028

一般而言, 单色光的带宽可以控制在 10 nm 以内, 必要时也可外置干涉滤光片将带宽控制在 10 nm 或更窄的范围内. 从表 6 可知, 光源带宽对方法的检测精度影响极小. 因此方法对于光源带宽的鲁棒性完全可以满足实际系统的要求.

方法对于倾斜误差的允差为  $0.3\lambda$  (0.26 as) RMS, 而实际系统中的残余倾斜误差仅为毫角秒量级; 方法对 CCD 噪声的允差为 30 dB, 而 CCD 相机信噪比普遍大于 40 dB; 对于实验室常用的激光光源的带宽, 方法的精度完全不受影响. 因此, 在实际系统中这些条件是容易满足的. 此外, 方法要求波前像差优于  $0.05\lambda$  RMS, 系统加工装调时需满足此条件. 综上所述, 方法是具备实用性的.

## 4 结 论

本文提出了一种利用 CNN 从 PSF 图像中高精度检测分块镜系统平移误差的方法. 通过测试选择  $[-0.48\lambda, 0.48\lambda]$  为方法的最佳检测范围, 在六子镜成像系统的仿真中, 方法可实现  $0.0013\lambda$  RMS 的检测精度. 此外, 方法还具有良好的鲁棒性: 对残余倾斜误差的允差达到  $0.3\lambda$  RMS、对 CCD 噪声的允差为 30 dB、对 4—11 阶像差的允差为  $0.05\lambda$  RMS.

与传统光学方法相比, 本文方法简单快速且不依赖于特定的传感器, 只需在成像系统的出瞳面上设置具有离散孔的光阑, 通过收集少量的 PSF 图像对 CNN 进行训练, 训练后的网络便能准确地检测分块镜系统中的平移误差. 较之其他基于深度学习的平移检测方法, 本文方法通过构建对平移变化极为敏感的数据集、搭建更高性能的 CNN 模型、并为该 CNN 选取合适的检测范围的方式实现了极高的平移检测精度, 使得方法能够更好地配合粗测方法使用. 目前正在搭建分块镜实验平台, 未来将从实验的角度验证理论研究和仿真结果的正确性.

## 参考文献

- [1] Hege E K, Beckers J M, Strittmatter P A, McCarthy D W 1985 *Appl. Opt.* **24** 2565
- [2] Luo Q, Huang L H, Gu N T, Li F, Rao C H 2012 *Acta Phys. Sin.* **61** 069501 (in Chinese) [罗群, 黄林海, 顾乃庭, 李斐, 饶长辉 2012 物理学报 **61** 069501]
- [3] Yan Z J, Chen X Y, Zheng L X, Ding Y Y, Zhu N H 2016 *Acta Phys. Sin.* **65** 199501 (in Chinese) [颜召军, 陈欣扬, 郑立新, 丁媛媛, 朱能鸿 2016 物理学报 **65** 199501]
- [4] Chang J, Zhang Zh H, Wang R R 2011 *Acta Phys. Sin.* **60** 034218 (in Chinese) [常军, 张正慧, 王蕊瑞 2011 物理学报 **60** 034218]
- [5] Platt B C, Shack R 2001 *J. Refract. Surg.* **17** S573
- [6] Harvey J E, Rockwell R A 1988 *Opt. Eng.* **27** 762
- [7] Baron F, Cassaing F, Blanca A, Laubier D 2003 *Opt. Eng.* **48** 663
- [8] Toni F 2010 *Phys. Today*. **63** 26
- [9] Chanan G, Troy M, Dekens F, Michaels S, Nelson J, Mast T, Kirkman D 1998 *Appl. Opt.* **37** 140
- [10] Shi F, Chanan G, Ohara C, Troy M, David C 2004 *Appl. Opt.* **43** 4474
- [11] Li D, Xu S Y, Wang D, Yan D J 2019 *Opt. Lett.* **44** 1170
- [12] Pizarro C, Arasa J, Laguarda F, Tomàs N 2002 *Appl. Opt.* **41** 4562
- [13] Roddier F 1990 *Appl. Opt.* **29** 1402
- [14] Dohlen K, Langlois M, Lanzoni P, Mazzanti S, Vigan A, Montoya L, Hernandez E, Reyes M, Surdej I, Yaitskova N 2006 *Proc. SPIE* **6267** 626734
- [15] Esposito S, Pinna E, Puglisi A, Tozzi A, Stefanini P 2005 *Opt. Lett.* **30** 2572
- [16] Pinna E, Esposito S, Puglisi A, Pieralli F, Myers R M, Busoni L, Tozzi A, Stefanini P 2006 *Proc. SPIE* **6267** 62672Y
- [17] Wang S S, Zhu Q D, Zhao W R, Li L, Cao G R 2009 *Chin. Opt. Lett.* **07** 1007
- [18] Jiang A M, Wang S, Dong Z C, Xue J W, Wang J Y, Dai Y F 2018 *Appl. Opt.* **57** 2736
- [19] Salinas-Luna J, Luna E, Salas L, Cruz-González I, Cornejo-Rodríguez A 2004 *Opt. Express* **12** 3719
- [20] Vasishta G, Bootha A J, Colavita M M, Johnson R L, Ligona E R, Moore J D, Palmera D L 2003 *Proc. SPIE* **4838** 824
- [21] Booth J A, Adams M T, Ames G H, Fowler J R, Rakoczy J M 2000 *Proc. SPIE* **4003** 176
- [22] Yi H W, Li Y C, Fan C, Wang J 2008 *Acta Photon. Sin.* **37** 1373 (in Chinese) [易红伟, 李英才, 樊超, 王矫 2008 光子学报 **37** 1373]
- [23] Dailos G R, Lara D G, Juan T S, Jose R M 2018 *Opt. Lett.* **43** 4264
- [24] Hui M, Li W Q, Liu M, Dong L Q, Kong L Q, Zhao Y J 2020 *Appl. Opt.* **59** 771
- [25] Ma X F, Xie Z L, Ma H T, Xu Y J, Ren G, Liu Y 2019 *Opt. Express* **27** 16058
- [26] Clampin M 2008 *Proc. SPIE* **41** 254
- [27] Cheetham A C, Tuthill P G, Sivaramakrishnan A, Lloyd J P 2012 *Opt. Express* **20** 29457
- [28] Cheetham A, Cvetojevic N, Norris B, Sivaramakrishnan A, Tuthill P 2014 *Opt. Express* **22** 12924

# High-precision co-phase method for segments based on a convolutional neural network\*

Zhao Wei-Rui<sup>1)2)†</sup> Wang Hao<sup>1)2)</sup> Zhang Lu<sup>1)2)</sup>  
Zhao Yue-Jin<sup>1)2)</sup> Chu Chun-Yan<sup>1)2)‡</sup>

1) (*School of Optics and Photonics, Beijing Institute of Technology, Beijing 100081, China*)

2) (*Beijing Key Laboratory for Precision Optoelectronic Measurement Instrument and Technology, Beijing 100081, China*)

( Received 10 March 2022; revised manuscript received 27 April 2022 )

## Abstract

In order to achieve the resolution comparable to the resolution of a monolithic primary mirror telescope and make the imaging quality of the imaging system reach or approach to the diffraction limit, the submirrors of the segments telescope should ensure co-phase splicing. To solve the problem of phase error detection, a high-precision piston error detection method is proposed based on convolutional neural network (CNN). By setting a mask with a sparse multi-subpupil configuration on the exit pupil of the imaging system, a point spread function (PSF) image dataset that is extremely sensitive to the piston error is constructed. According to the characteristics of this dataset, a high-performance CNN model is built. And the best detection range of CNN is tested. The simulation results show that a single network can accurately output the piston error of one or more submirrors in the capture range slightly less than one wavelength. When the single network is applied to the six-submirror imaging system, the detection precision of the piston error reaches an RMS value of  $0.0013\lambda$  (here, RMS stands for root mean square). And the method has good robustness to residual tip-tilt error, wavefront aberration, and CCD noise, light source bandwidth. The method is simple and fast, and can be widely used to detect the piston error of the segments.

**Keywords:** segmented telescopes, piston, CNN, PSF

**PACS:** 42.25.Hz, 42.30.Kq, 42.30.Lr, 42.30.-d

**DOI:** [10.7498/aps.71.20220434](https://doi.org/10.7498/aps.71.20220434)

---

\* Project supported by the National Natural Science Foundation of China (Grant No. 11874086).

† Corresponding author. E-mail: [zwrei@bit.edu.cn](mailto:zwrei@bit.edu.cn)

‡ Corresponding author. E-mail: [xyzccy@163.com](mailto:xyzccy@163.com)



## 基于卷积神经网络的高精度分块镜共相检测方法

赵伟瑞 王浩 张璐 赵跃进 褚春艳

### High-precision co-phase method for segments based on a convolutional neural network

Zhao Wei-Rui Wang Hao Zhang Lu Zhao Yue-Jin Chu Chun-Yan

引用信息 Citation: *Acta Physica Sinica*, 71, 164202 (2022) DOI: 10.7498/aps.71.20220434

在线阅读 View online: <https://doi.org/10.7498/aps.71.20220434>

当期内容 View table of contents: <http://wulixb.iphy.ac.cn>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 一种基于图像融合和卷积神经网络的相位恢复方法

Phase retrieval wavefront sensing based on image fusion and convolutional neural network

物理学报. 2021, 70(5): 054201 <https://doi.org/10.7498/aps.70.20201362>

#### 基于遗传算法优化卷积长短记忆混合神经网络模型的光伏发电功率预测

A hybrid model for photovoltaic power prediction of both convolutional and long short-term memory neural networks optimized by genetic algorithm

物理学报. 2020, 69(10): 100701 <https://doi.org/10.7498/aps.69.20191935>

#### 基于深度卷积神经网络的大气湍流相位提取

Extracting atmospheric turbulence phase using deep convolutional neural network

物理学报. 2020, 69(1): 014209 <https://doi.org/10.7498/aps.69.20190982>

#### 基于混合神经网络和注意力机制的混沌时间序列预测

Prediction of chaotic time series using hybrid neural network and attention mechanism

物理学报. 2021, 70(1): 010501 <https://doi.org/10.7498/aps.70.20200899>

#### 识别Z玻色子喷注的卷积神经网络方法

Tag Z boson jets via convolutional neural networks

物理学报. 2021, 70(6): 061301 <https://doi.org/10.7498/aps.70.20201557>

#### 基于BP神经网络模型时钟同步误差补偿算法

Clock synchronization error compensation algorithm based on BP neural network model

物理学报. 2021, 70(11): 114203 <https://doi.org/10.7498/aps.70.20201641>