

DOI: 10.19650/j.cnki.cjsi.J2312120

基于多 CNN 的分块镜 piston 和 tip-tilt 误差 同步检测方法研究*

李 响, 赵伟瑞

(北京理工大学光电学院 北京 100081)

摘 要:绝大多数大型望远镜采用分块镜的设计方案,为了获得优质的成像效果,需要控制分块望远镜系统的 piston 和 tip-tilt 误差。神经网络误差检测方法相较于传统的检测方法具有一定优势,但存在仅检测单一类型误差的局限性。本文提出一种基于卷积神经网络的 piston 和 tip-tilt 误差同步检测方法,通过在出瞳面设置具有离散孔的光阑,引发分段镜反射的子波发生干涉-衍射现象,构建包含丰富 piston 和 tip-tilt 误差信息的数据集。通过粗测网络和精测网络级联,满足大范围和高精度同步检测的需求。结果表明,该方法实现了对输入光源相干长度内纳米级的 piston 误差检测,并对 $10\ \mu\text{rad}$ 范围内的 tip-tilt 误差实现了亚微弧度检测;对 40 dB 的 CCD 噪声表现出良好的抗干扰性,对面形误差的允差为 $0.05\lambda_0\text{RMS}$ ($\lambda_0 = 600\ \text{nm}$),同时对六子镜系统具有可扩展性。本文方法光路简单,操作便利,具有实际意义。

关键词: piston 误差; tip-tilt 误差; 分块镜; 卷积神经网络

中图分类号: TH743 文献标识码: A 国家标准学科分类代码: 460.40

Research on the method for simultaneously detecting piston and tip-tilt errors of segmented telescopes based on multiple CNNs

Li Xiang, Zhao Weirui

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

Abstract: Most large telescopes adopt the design scheme of segmented mirror. In order to obtain high-quality imaging effect, it is necessary to control the piston and tip-tilt errors of segmented telescope system. Compared with traditional detection methods, the error detection method based on neural networks has some advantages, but it is limited to detecting only a single type of error. This paper proposes a method for synchronous detection of piston and tip-tilt errors based on a multi-convolutional neural network. By setting a mask with a sparse sub-pupils configuration at the exit pupil, the sub-waves reflected by the segmented mirrors generate interference-diffraction phenomena, thereby constructing a dataset containing rich piston and tip-tilt errors information. The design includes coarse measurement and fine measurement networks to meet the requirements of large-range and high-precision synchronous detection. Results demonstrate that the method achieves nanometer-level detection of piston errors within the coherent length of the input light source and sub-milliarcsecond detection of tip-tilt errors within a range of $10\ \mu\text{rad}$. The method exhibits robust resistance to 40 dB CCD noise, a tolerance of $0.05\ \lambda\ \text{RMS}$ ($\lambda_0 = 600\ \text{nm}$) for surface shape errors, and portability to six-mirror systems. Additionally, the method has simple optical path, convenient operation and practical significance.

Keywords: piston error; tip-tilt error; segmented telescope; neural networks

0 引 言

目前大口径地基和空间望远镜大都采用分块式主镜^[1]。为确保分块望远镜系统获得优质的成像效果,共

相位误差(包括 piston、tip-tilt 误差等)应控制在 $\lambda/40\ \text{RMS}$ 内。人们研究了许多方法,比如 KECK 望远镜中使用宽/窄带夏克-哈特曼法^[2-3]实现 piston 误差检测,但此法需切换两种波长的光源,还需在出瞳面设置微透镜。詹姆斯·韦伯空间望远镜(James Webb space telescope,

JWST) 使用分散条纹传感器 (dispersed fringe sensor, DFS) 技术^[4]对 piston 误差进行粗略定相,需要配合使用相位恢复法 (phase retrieval, PR)^[5]进行精确定相。加那利群岛大望远镜 (gran telescopio canarias, GTC) 中使用迈克逊干涉检测法^[6-7],但其仅适于地面应用 piston 误差检测。光斑质心探测法是经典的 tip-tilt 误差探测方法^[8],但需对图像进行多次叠加,时间成本大。2018 年法国宇航局提出 PISTIL 干涉仪法^[9],此方法可以同时提取 piston 和 tip-tilt 误差信息,但其中衍射元件的设计和制造是关键和难点。

深度学习在检测共相位误差时具有硬件要求简单,检测效率高的优势。目前已广泛应用到光学成像问题^[10-14]。2018 年, Dailo 等人采用卷积神经网络 (convolutional neural networks, CNN) 实现 piston 误差检测^[15],捕获范围为 $\pm 11\lambda$ ($\lambda = 700 \text{ nm}$),在仿真中检测精度可达 $\pm \lambda/115 \text{ RMS}$,但需切换单波长和多波长光源,并手动截取图片作为数据集样本。2019 年,长春光机所的李德全等人研究了采用卷积神经网络对扩展目标的 piston 误差检测^[16],探测范围为 $\pm 10 \lambda$,但该网络只能实现 piston 误差的粗略检测。2020 年,北京理工大学的惠梅等人加深了卷积神经网络层数^[17],用较少的训练样本实现 piston 误差检测,但探测范围仅为 $\pm \lambda$,精度约为 $\lambda/20 \text{ RMS}$ 。2022 年,中国科学院大学的马霞飞等人利用卷积神经网络实现 piston 误差检测^[18],借助 2 个分类网络实现 $\pm 3.5 \lambda$ 内亚波长精度的 piston 误差检测。2023 年,华东交通大学的李斌等人利用 2 个分类网络实现两孔径系统 piston 误差检测^[19],实现了 $\pm 10.5 \mu\text{m}$ 内误差的模糊检测和 $0.375 \mu\text{m}$ 范围内 piston 误差检测。以上方法仅关注检测 piston 误差。2021 年,西北工业大学的唐菊等人利用深度卷积神经网络实现 tip-tilt 误差的检测^[20],检测范围为 $\pm 2 \lambda$,精度仅为 $\lambda/10 \text{ RMS}$ 。综上,当前基于深度学习的共相位误差检测方法存在仅关注单一误差类型的局限性。在实现系统的高精度调相过程中,不可避免地需要借助传统方法。这削弱了神经网络在高效性和多输出方面的优势。因此,有必要探索更综合的深度学习方法,实现全面、高效的共相位误差检测。

本文提出一种基于多 CNN 的 piston 误差和 tip-tilt 误差同步检测方法,旨在满足对 2 种误差的同时检测需求,并确保动态范围的广泛覆盖和共相位误差的高精度检测,为实现衍射受限成像提供保障。通过在成像系统的出瞳面设置具有离散孔结构的光阑,引发各分镜反射的子波发生干涉-衍射现象。干涉条纹信息可以追溯到每对子镜的共相位误差。将干涉图作为数据集,可在包含丰富的 piston 和 tip-tilt 误差特征的同时,减小其他噪声的干扰。整体神经网络的设计采用粗测网络 (coarse measurement network, CMN) 和精测网络 (fine measure-

ment network, FMN) 级联的策略。其中,CMN 对 piston 误差进行类别检测,扩大 piston 误差的检测范围。通过循环校正流程,保证分类检测的准确率。随后,将大范围的 piston 误差带入具有 2 个输出节点的 FMN 的有效范围内,实现 piston 和 tip-tilt 误差的高精度同步检测。此外,通过 CCD 噪声和面形误差的测试,表明方法具备出色的抗干扰性能。将方法迁移到六子镜系统中,仍具有良好表现。

1 原理分析

以两子镜系统为例,建立光学系统成像模型,并对其原理进行说明。如图 1(a) 将 2 个子镜编号 1、2,设子镜 1 为参考子镜,子镜 2 为被测子镜。在两子镜系统出瞳面设置具有离散孔结构的光阑,无限远的星光经子镜反射后,通过非冗余排布的光阑孔,发生干涉-衍射现象,成像于焦平面,得到所需要的点扩散函数 (point spread function, PSF)。光阑结构如图 1(b) 所示,在出瞳面建立坐标系 (x_0, y_0),光阑孔的直径为 D ,光阑孔中心距离为 B 。




图1 两子镜系统及离散光阑孔结构

Fig. 1 The structure of the two-mirror system and the discrete sub-apertures

此系统光瞳函数可以表示为:

$$P(x_0, y_0) = \text{circ}\left(\frac{\sqrt{\left(x_0 + \frac{B}{2}\right)^2 + y_0^2}}{\frac{D}{2}}\right) + \text{circ}\left(\frac{\sqrt{\left(x_0 - \frac{B}{2}\right)^2 + y_0^2}}{\frac{D}{2}}\right) \cdot e^{\frac{j2\pi}{\lambda}\left(p + \frac{a}{2}x_0 + \frac{b}{2}y_0\right)} \quad (1)$$

式中: $\text{circ}(\cdot)$ 为圆域函数, λ 为输入光源波长, p 为被测子镜 2 的 piston 误差; a 为被测子镜 2 绕 y 轴旋转的 tip 误差, b 为绕 x 轴旋转的 tilt 误差。

基于傅里叶光学原理, PSF 在像平面 (x, y) 中定义为:

$$PSF(x, y) = |FT[P(x_0, y_0)]|^2 = \left(\frac{D}{2}\right)^2 \left\{ \left[\frac{J_1\left(\pi D \sqrt{\left(\frac{x}{\lambda f}\right)^2 + \left(\frac{y}{\lambda f}\right)^2}\right)}{\sqrt{\left(\frac{x}{\lambda f}\right)^2 + \left(\frac{y}{\lambda f}\right)^2}} \right]^2 + \left[\frac{J_1\left(\pi D \sqrt{\left(\frac{x}{\lambda f} - \frac{2a}{\lambda D}\right)^2 + \left(\frac{y}{\lambda f} - \frac{2b}{\lambda D}\right)^2}\right)}{\sqrt{\left(\frac{x}{\lambda f} - \frac{2a}{\lambda D}\right)^2 + \left(\frac{y}{\lambda f} - \frac{2b}{\lambda D}\right)^2}} \right]^2 + \frac{J_1\left(\pi D \sqrt{\left(\frac{x}{\lambda f} - \frac{2a}{\lambda D}\right)^2 + \left(\frac{y}{\lambda f} - \frac{2b}{\lambda D}\right)^2}\right)}{\sqrt{\left(\frac{x}{\lambda f} - \frac{2a}{\lambda D}\right)^2 + \left(\frac{y}{\lambda f} - \frac{2b}{\lambda D}\right)^2}} \cdot 2\cos\left[2\pi\left(\frac{x}{\lambda f}B - \frac{p}{\lambda}\right)\right] \right\} \quad (2)$$

式中: $FT(\cdot)$ 是傅里叶变换运算, $J_1(\cdot)$ 是一阶贝塞尔函数, f 是成像镜头的焦距, $\frac{J_1(\pi D \sqrt{(x/\lambda f)^2 + (y/\lambda f)^2})}{\sqrt{(x/\lambda f)^2 + (y/\lambda f)^2}}$ 和 $\frac{J_1(\pi D \sqrt{(x/\lambda f - 2a/\lambda D)^2 + (y/\lambda f - 2b/\lambda D)^2})}{\sqrt{(x/\lambda f - 2a/\lambda D)^2 + (y/\lambda f - 2b/\lambda D)^2}}$ 是 PSF 的两个衍射因子, 携带 tip-tilt 误差信息。 $\cos[2\pi(xB/\lambda f - p/\lambda)]$ 是干涉因子, 携带 piston 误差信息。式(2)表明, piston 和 tip-tilt 对 PSF 的影响可分离。采用宽光谱光源可解决 piston 误差受余弦函数周期性限制产生的 2π 不定性问题。由于干涉原理可知, 当 piston 误差小于输入光源的相干长度时会存在干涉现象, 相干长度计算为:

$$L_c = \frac{\lambda_0^2}{\Delta\lambda} \quad (3)$$

式中: λ_0 是中心波长, $\Delta\lambda$ 是光谱带宽。

在宽光谱下, 系统的点扩散函数 PSF_c 为:

$$PSF_c(x, y, \lambda) = \int_{\lambda_0 - \frac{\Delta\lambda}{2}}^{\lambda_0 + \frac{\Delta\lambda}{2}} PSF(x, y, \lambda) S(\lambda) d\lambda \quad (4)$$

式中: $S(\lambda)$ 是权重, 取 $S(\lambda) = 1$, 通过微分求和法对此积分进行近似, 将带宽 $\Delta\lambda$ 均分成 n 段, 每一小段中心波长分别为 λ_i , PSF_c 可以表示为:

$$PSF_c(x, y, \lambda) = \frac{\Delta\lambda}{n} \sum_{i=1}^n PSF(x, y, \lambda_i) \quad (5)$$

对于 N 子镜系统, 在出瞳面设置一个带有 N 个直径为 D 的离散孔光阑, 每个离散孔与一个分块子镜对应, 并采集其反射的光波。多子镜拼接系统的光瞳函数 P_N 为:

$$P_N(x_0, y_0) = \sum_{m=1}^N \text{circ}\left(\frac{\sqrt{x_0^2 + y_0^2}}{D/2}\right) * \delta(x_0 - x_m, y_0 - y_m) \cdot e^{j\varphi_m} \quad (6)$$

式中: (x_m, y_m) 为子镜 m 对应光阑孔的中心坐标, φ_m 为对应光阑孔采集的波面相位, $*$ 为卷积运算符号。

宽光谱光源下 N 子镜系统的点扩散函数 PSF_{Nc} 可表

示为:

$$PSF_{Nc}(x, y, \lambda) = \sum_{i=1}^n \left(\frac{\pi D^2}{2\lambda f}\right)^2 \cdot \left[\frac{J_1\left(\frac{\pi \rho D}{\lambda f}\right)}{\frac{\pi \rho D}{\lambda f}} \right]^2 \cdot \left\{ N + \sum_{m=1}^{N(N-1)/2} \left[e^{-j\frac{2\pi}{\lambda f}(x \cdot x_m + y \cdot y_m)} + e^{j\frac{2\pi}{\lambda f}\left(p_m + \frac{a_m x}{D/2} + \frac{b_m y}{D/2}\right)} \right] \right\} \quad (7)$$

式中: $\rho = \sqrt{x^2 + y^2}$ 。根据式(7)可以得出, N 子镜系统的点扩散函数 PSF_{Nc} 图像是 N 个子孔径的单孔衍射相叠加和 $\frac{N(N-1)}{2}$ 对子孔径的干涉叠加而成。

在共相位状态时, PSF 图像的干涉条纹具有高对比度, 如图 2(a), (d) 所示。在引入 piston 误差后, 条纹移动并且宽带图像对比度下降, 如图 2(b), (e)。在引入 tip-tilt 误差后, 每个孔径的艾里斑质心发生移动, 但条纹中心位置保持不变, 如图 2(c), (f) 所示。将 PSF 作为数据集, 可以确保神经网络能够精准、独立地学习输入图像与 piston 以及 tip-tilt 误差之间的映射关系。




图2 两光阑孔生成的 PSF

Fig. 2 PSF generated from two-pupils mask

设计 FMN 并对其进行仿真,图 3(a)显示精度随着 piston 误差范围的增大而减小。图 3(b)显示当 piston 误差范围设置为 $[-0.4\lambda_0, 0.4\lambda_0]$ 时,网络的预测偏差不再有超过 10 nm 的值,故选定 $[-0.4\lambda_0, 0.4\lambda_0]$ 为 FMN 的检测范围。




图 3 FMN 预测偏差分布
Fig. 3 FMN prediction bias distribution

设计 CMN 扩大 piston 误差检测范围,实现对 piston 误差区间类别(K)的检测。CMN 以 $[-0.4\lambda_0, 0.4\lambda_0]$ 为

中心区间($K=0$),以 $0.8\lambda_0$ 为步长,向两侧划分区间,每个区间对应一个类别,划分规则如表 1 所示。

表 1 piston 误差分类情况
Table 1 Categories of piston error intervals

piston 误差区间	区间类别 K
...	...
$[-2\lambda_0, -1.2\lambda_0)$	-2
$[-1.2\lambda_0, -0.4\lambda_0)$	-1
$[-0.4\lambda_0, 0.4\lambda_0]$	0
$(0.4\lambda_0, 1.2\lambda_0]$	1
$(1.2\lambda_0, 2.0\lambda_0]$	2
...	...

2 网络结构和级联

本文构造了 2 个卷积神经网络,CMN 来实现分类的功能,FMN 实现回归功能,2 种网络的配合使用来满足 piston 和 tip-tilt 误差的大范围和高精度同步检测。

2.1 网络结构

CMN 的结构如图 4 所示,CMN 通过较大卷积核的设计,能够有效捕获 PSF 图像的特征,输出大捕获范围的 piston 误差区间类别。3 个卷积层分别使用了尺寸为 (11,11)、(5,5)、(3,3) 的卷积核,前两层使用较大的卷积核增大 PSF 图像对于 piston 误差变化的感受野,使得网络在处理这种特定数据集时表现出色。最大池化层被用于压缩特征空间,随后通过完全连接层整合特征,并通过 softmax 函数输出离散类别值。由于 CMN 只能输出单个子镜的 piston 类别,因此为了检测相应数量的测试子镜,需要使用多个完全相同结构的 CMN。值得注意的是,不同 CMN 之间的数据集图像样本是相同的,只需调整对应子镜的类别标签,因此增加 CMN 的数量并不会增加数据负担。




图 4 CMN 结构
Fig. 4 Architecture of CMN

FMN 的结构如图 5 所示。在卷积层中,选择了堆叠的 (3,3) 卷积核替代大卷积核,有助于更好地捕捉 PSF 图像中的局部特征,确保在保持相同感受野的同时增加网络深度。同时,引入 (1,1) 卷积核提高模型对于数据集中复杂干涉条纹特征的表达能力。为了减少参数数量、防止过拟合,并学习更高级的特征表

示,FMN 采用了全局平均池化层替代全连接层,有助于提取整体图像的抽象特征,使得网络更具泛化能力。最终,通过 2 个输出节点,将学到的高级特征映射到 piston 和 tip-tilt 误差值的预测上,实现了对输入图像与共相位误差之间复杂映射关系的精确独立学习。




图 5 FMN 结构

Fig. 5 Architecture of FMN

2.2 CMN 和 FMN 的级联

CMN 和 FMN 之间的级联如图 6 所示。首先,CMN 根据输入的 PSF 图像对大范围的 piston 误差进行分类判断,将其归类为特定的误差类别 K 。若 K 不为零,即 piston 误差不在 FMN 的有效检测范围 $[-0.4\lambda_0, 0.4\lambda_0]$ 内,系统将进入循环结构:调整被测子镜的 piston 值为 $-0.8\lambda_0$,随后更新 PSF 图像并再次经过 CMN。该过

程循环进行,直至 K 等于零,然后退出循环,进入 FMN。这种循环检测结构确保了误差分类的准确性,并将大范围的 piston 误差带入 FMN 的有效范围内。随后,FMN 根据输入的 PSF 图像直接输出两种误差值。CMN 和 FMN 有效协同工作,既保障高检测精度,又扩大了检测范围,最终实现了系统的 piston 和 tip-tilt 误差的检测与校准。




图 6 网络间的级联

Fig. 6 Networks cascading

3 方 法

3.1 数据集的生成

搭建多子镜光学成像系统,用于生成数据集。系统参数如下:光阑孔直径 $D=0.24\text{ m}$,中心波长 $\lambda_0=600\text{ nm}$,

带宽 $\Delta\lambda=100\text{ nm}$ 。由式(3)确定 CMN 捕获 piston 误差的动态范围为 $[-6\lambda_0, 6\lambda_0]$, K 值为 15。FMN 捕获 piston 误差的动态范围为 $[-0.4\lambda_0, 0.4\lambda_0]$,推导过程详见第 1 节。JWST 系统的拼接主镜在实现分块镜合像之后,单块分块镜 tip-tilt 误差小于 $9.7\text{ }\mu\text{rad}$ ^[8]。因此,该方法的 tip-tilt 误差捕获范围被设定为 $10\text{ }\mu\text{rad}$,即 $[-2\lambda_0, 2\lambda_0]$ 。以

下仅展示存在 tip 误差的情况,tilt 误差的处理方式与其类似。

在被测子镜上加载动态范围为 $[-6\lambda_0, 6\lambda_0]$ 的随机 piston 误差和 $[-2\lambda_0, 2\lambda_0]$ 的随机 tip 误差,共生成 54 000 张 PSF 图像,构建用于 CMN 的数据集,其中数据集标签表示 piston 误差的类别。同样地,在被测子镜上加载动态范围为 $[-0.4\lambda_0, 0.4\lambda_0]$ 的随机 piston 误差和 $[-2\lambda_0, 2\lambda_0]$ 的随机 tip 误差,生成 54 000 张 PSF 图像,数据集标签包括(piston 误差值, tip 误差值),构建用于 FMN 的数据集。数据集划分为 50 000 张训练集图像,2 000 张验证集图像和 2 000 张测试集图像。

3.2 网络训练及测试

网络训练及测试过程在配置有 Intel(R) Xeon(R) Platinum 8255C CPU 和 NVIDIA RTX 3080Ti GPU 的服务器上,采用 TensorFlow 2.9.0 深度学习框架。

在粗测阶段,建立 CMN1 和 CMN2 分别对被测子镜 1、2 上的 piston 误差进行分类。CMN1 在训练的几十个批次内,分类准确率即可提升至 90% 以上;CMN2 情况与

之类似。这表明网络能够迅速而准确地学习到图像特征与 piston 误差类别之间的映射关系。

完成训练后,使用包含 2 000 个样本的测试集分别对 CMN1、CMN2 进行测试。引入统计学中常用的重抽样方法—Bootstrap 法对 CMN1 和 CMN2 进行更全面的性能和不确定性的评估。Bootstrap 法从原始测试集中进行有放回地抽样,生成 1 000 个样本集,从而进行 1 000 次测试。结果显示,CMN1 平均分类准确率达到 95.2% (95% 置信区间(CI): $[94.1\%, 96.1\%]$)。CMN2 平均分类准确率为 95.1% (95% CI: $[94.1\%, 96.1\%]$)。

随机选取一组 CMN1、CMN2 的测试结果展示其混淆矩阵。如图 7(a) 为 CMN1 测试结果的混淆矩阵,图 7(b) 为 CMN2 测试结果的混淆矩阵,其中对角线上的元素值在 93%~98.7% 之间,表明 CMN 在每个类别上都能够实现高精度的识别。这验证了网络对图像特征和 piston 误差类别之间映射关系的快速而准确的掌握。结合循环校正流程,可以避免网络在粗测阶段的分类错误。




图7 测试结果的混淆矩阵
Fig. 7 Confusion matrices for test results

在精测阶段,建立 FMN1 和 FMN2 分别对被测子镜 1、2 上的 piston 和 tip-tilt 误差进行同步检测。损失函数为均方误差(mean square error, MSE),经过约 50 个批次的训练,损失降至较低水平;FMN2 的情况与之类似。这体现了网络在处理复杂任务时的有效性和高效性。

完成训练后,使用包含 2 000 个样本的测试集分别

对 FMN1、FMN2 进行测试。同样引入 Bootstrap 法进行 1 000 次测试。结果显示,FMN1 预测 piston 误差的平均精度(RMSE)为 $0.002\,99\lambda_0$ (95% CI: $[0.002\,87\lambda_0, 0.003\,12\lambda_0]$),即 $1.79\,\text{nm}$ (95% CI: $[1.62\,\text{nm}, 1.87\,\text{nm}]$),预测 tip 误差的平均精度(RMSE)为 $0.005\,19\lambda_0$ (95% CI: $[0.005\,01\lambda_0, 0.005\,32\lambda_0]$),即 $0.026\,\mu\text{rad}$ (95% CI: $[0.025\,\mu\text{rad}, 0.027\,\mu\text{rad}]$)。FMN2 预测 piston 误差的

平均精度 (RMSE) 为 $0.002\ 73\ \lambda_0$ (95% CI: $[0.002\ 62\ \lambda_0, 0.002\ 85\ \lambda_0]$), 即 $1.64\ \text{nm}$ (95% CI: $[1.57\ \text{nm}, 1.71\ \text{nm}]$), 预测 tip 误差的平均精度为 (RMSE) 为 $0.004\ 74\ \lambda_0$ (95% CI: $[0.004\ 63\ \lambda_0, 0.004\ 86\ \lambda_0]$), 即 $0.024\ \mu\text{rad}$ (95% CI: $[0.023\ \mu\text{rad}, 0.024\ \mu\text{rad}]$)。

此外,随机选取一组 FMN1、FMN2 的测试结果展示

其预测残余误差统计图。图 8 展示了 FMN1 的预测结果,直方图(a)表明残余 piston 误差有 99.15% 都在 5 nm 之内;散点图(b)显示残余 piston 误差集中分布在 0~3 nm 之间;直方图(c)表明残余 tip 误差有 99.8% 都在 0.05 μrad 以内;散点图(d)显示残余 tip 误差集中分布在 0~0.04 μrad 之间。




图 8 FMN1 预测残余误差统计图

Fig. 8 Statistical diagrams of the residual error of FMN1

图 9 展示了 FMN2 的预测结果,直方图(a)表明残余 piston 误差有 99.4% 都在 5 nm 之内;散点图(b)显示残余 piston 误差集中分布在 0 到 3 nm 之间;直方图(c)表明残余 tip 误差有 99.85% 都在 0.05 μrad 以内;散点图(d)显示残余 tip 误差集中分布在 0~0.04 μrad 之间。这表明 FMN 能够实现 piston 和 tip 误差的高精度检测。

3.3 抗干扰性和扩展性评估

在实际应用场景中,CCD 噪声是典型的干扰因素,目前普通商用 CCD 相机信噪比均大于 40 dB,图 10 中展示了 40 dB 噪声对 PSF 图像的影响。为方便表述,取两个网络测试结果的平均值来说明。当加入了 40 dB 的 CCD

噪声后,CMN 检测的准确率为 94.99 %,FMN 对于 piston 误差和 tip-tilt 误差的精度分别为 $0.005\ 18\ \lambda_0\text{RMS}$ 和 $0.009\ 13\ \lambda_0\text{RMS}$ 。因此,方法对 CCD 噪声的抗干扰性能满足系统的要求。

因为所采用的光学系统为反射式光路,所以反射镜面的面形误差是影响成像质量的一个重要因素。用 Zernike 多项式除去前 3 项 (piston 误差、tip 和 tilt 误差) 外的前 36 项像差来模拟子镜面形误差,各项系数等权分布。通过向测试集中分别引入 RMS 值为 $0.03\ \lambda_0$ 、 $0.04\ \lambda_0$ 、 $0.05\ \lambda_0$ 、 $0.06\ \lambda_0$ 的面形误差,以评估面形误差对网络性能的影响。




图 9 FMN2 预测残余误差统计图

Fig. 9 Statistical diagrams of the residual error of FMN2




图 10 不同 CCD 噪声的 PSF 图

Fig. 10 PSF of different CCD noise

下表 2 展示了 CMN 和 FMN 在不同面形误差情况下的检测结果。该方法对于面形误差的允差为 $0.05 \lambda_0 \text{RMS}$,在实际镜面加工过程中,这一条件是可以满足的。因此,方法对系统面形误差的抗干扰性能够满足实际系统的要求。

为进一步评估网络的可扩展性,将系统从三子镜扩展为六子镜。对 CMN 进行性能评估。如表 3,5 个被测

表 2 不同面形误差对应的网络检测结果			
Table 2 Networks detection results corresponding to different face shape errors			
面形误差 $/\lambda_0 \text{ RMS}$	CMN 准确率 $\text{\%}$	FMN 精度 Piston/ $\lambda_0 \text{ RMS}$	FMN 精度 Tip/ $\lambda_0 \text{ RMS}$
0.03	96.01	0.009 20	0.010 98
0.04	95.85	0.014 53	0.018 57
0.05	94.90	0.019 26	0.024 31
0.06	92.42	0.028 30	0.029 80

子镜的检测准确率仍保持在 90 % 以上,表明 CMN 在六子镜系统仍保持较高准确率。

表 3 CMN 准确率					
Table 3 CMN accuracy					
被测子镜	1	2	3	4	5
准确率/ $\text{\%}$	93.70	93.50	92.30	92.05	92.90

对 FMN 进行性能评估。5 个被测子镜 piston 误差和 tip 误差的精度如表 4 所示。被测子镜 1 和 2 上的 piston 误差和 tip 误差的检测精度较高;被测子镜 3、4、5 的精度略有下降。对于六子镜系统内 $[-6\lambda_0, 6\lambda_0]$ 范围内的 piston 误差和 $[-2\lambda_0, 2\lambda_0]$ 范围内的 tip 误差,所提出的方法符合 $\lambda_0/40\text{RMS}$ 同相误差检测的精度要求。

表 4 FMN 精度
Table 4 FMN precision

被测子镜 r	Piston	Tip
	$/\lambda_0$ RMS	$/\lambda_0$ RMS
1	0.004 74	0.005 36
2	0.003 76	0.005 12
3	0.006 36	0.011 26
4	0.012 05	0.020 76
5	0.008 80	0.018 20

4 结 论

本文提出了一种基于多 CNN 的同步检测 piston、tip-tilt 误差的方法,满足对两种误差同时检测的需求,并确保动态范围的广泛覆盖和共相位误差的高精度检测。通过设置具有离散孔结构的光阑,构建了高质量的数据集。采用 CMN 和 FMN 级联的方法,解决了扩大检测范围时精度下降的问题,实现 $[-6\lambda_0, 6\lambda_0]$ 范围内 piston 误差和 $[-2\lambda_0, 2\lambda_0]$ 范围内的 tip-tilt 误差的检测($\lambda_0 = 600\text{ nm}$), 平均精度分别达到 $0.002\ 86\ \lambda_0\text{RMS}$ 和 $0.004\ 50\ \lambda_0\text{RMS}$,即 1.72 nm 和 $0.025\ \mu\text{rad}$ 。该方法对 40 dB 的 CCD 噪声表现出良好的抗干扰性,对面形误差的允差为 $0.05\ \lambda_0\text{RMS}$ 。此外,将该方法扩展到六子镜系统中,依然展现良好的性能。该方法光路简单,不依赖特定的硬件传感器,检测效率高,具备适用性和抗干扰性。该方法可在高分辨望远镜设计中发挥作用,并与其他类似任务提供借鉴。

参考文献

[1] NELSON J, GILLINGHAM P. Overview of the performance of the W. M. Keck observatory[J]. 1994 Symposium on Astronomical Telescopes and Instrumentation for the 21st Century, 1994, 2199.

[2] 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.

[3] 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.

[4] SHI F, OHARA C, CHANAN G, et al. Experimental verification of dispersed fringe sensing as a segment-phasing technique using the keck telescope[J]. SPIE Astronomical Telescopes + Instrumentation, 2004, 5489.

[5] DEAN B, ARONSTEIN D, SMITH J, et al. Phase retrieval algorithm for JWST flight and testbed telescope[J]. Proc SPIE, 2006, 6265.

[6] PINTÓ A, LAGUARTA F, ARTIGAS R, et al. New interferometric technique for piston measurement in segmented mirrors[J]. Journal of Optics A: Pure and Applied Optics, 2002, 4(6): S369.

[7] PIZARRO C, ARASA J, LAGUARTA F, et al. Design of an interferometric system for the measurement of phasing errors in segmented mirrors[J]. Applied Optics, 2002, 41(22): 4562-4570.

[8] NELLA J, ATCHESON P, ATKINSON C, et al. James webb space telescope (JWST) observatory architecture and performance[M]. 2004.

[9] DEPRez M, WATTELLIER B, BELLANGER C, et al. Phase measurement of a segmented wave front using PISton and TILt interferometry (PISTIL)[J]. Optics Express, 2018, 26: 5212.

[10] CHENG Y F, STRACHAN M, WEISS Z, et al. Illumination pattern design with deep learning for single-shot fourier ptychographic microscopy [J]. Optics Express, 2018, 27 2: 644-656.

[11] MANIFOLD B, THOMAS E, FRANCIS A T, et al. Denoising of stimulated raman scattering microscopy images via deep learning [J]. Biomed Opt Express, 2019, 10(8): 3860-3874.

[12] HIGHAM C F, MURRAY-SMITH R, PADGETT M J, et al. Deep learning for real-time single-pixel video[J]. Scientific Reports, 2018, 8(1): 2369.

[13] FENG S, CHEN Q, GU G, et al. Fringe pattern analysis using deep learning [J]. Advanced Photonics, 2019, 1: 1.

[14] NISHIZAKI Y, HORISAKI R, KITAGUCHI K, et al. Analysis of non-iterative phase retrieval based on machine

- learning[J]. Optical Review, 2020, 27(1): 136-141.
- [15] GUERRA-RAMOS D, DIAZ-GARCIA L, TRUJILLO-SEVILLA J, et al. Piston alignment of segmented optics mirrors via convolutional neural networks [J]. Optics Letters, 2018, 43(17): 4264-4267.
- [16] 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.
- [17] 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.
- [18] MA X, XIE Z, MA H, et al. Piston Sensing for Sparse Aperture Systems Via All-Optical Diffractive Neural Network[M]. 2022.
- [19] LI B, YANG A, LI Y, et al. Research on co-phasing detection of segmented mirror based on convolutioned neural networks[J]. Optics & Laser Technology, 2023, 167: 109737.
- [20] TANG J, REN Z B, WU X Y, et al. Object-independent tilt detection for optical sparse aperture system with large-scale piston error via deep convolution neural network[J]. Optics Express, 2021, 29(25): 41670-41684.

作者简介



李响, 2021 年于燕山大学获得学士学位, 现为北京理工大学硕士研究生, 主要研究方向为拼接式主镜望远镜共相位误差检测技术。

E-mail: 3220210531@bit.edu.cn

Li Xiang received her B. Sc. degree in 2021 from Yanshan University, now she is master's student in Beijing Institute of Technology. Her main research interests include co-phase error detection technology of segmented primary mirror telescopes.



赵伟瑞 (通信作者), 1989 年于首都师范大学获得学士学位, 1992 年于天津大学获得硕士学位, 2000 年于北京理工大学获得博士学位, 现为北京理工大学副研究员, 主要研究合成孔径成像等方面。

E-mail: zwrei@bit.edu.cn

Zhao Weirui (Corresponding author) received her B. Sc. degree in 1989 from Capital Normal University, received her M. Sc. degree in 1992 from Tianjin University, received her Ph. D. degree in 2000 from Beijing Institute of Technology, now she is an associate researcher in Beijing Institute of Technology. Her main research interests include synthetic aperture imaging, etc.