

基于多特征融合的神经网络波前重构方法*

李文龙^{1,2,3} 赵刚^{1,2†} 窦江培^{1,2} 朱永田^{1,2,3} 张熙^{1,2} 王钢^{1,2}

(1 中国科学院南京天文光学技术研究所 南京 210042)

(2 中国科学院天文光学技术重点实验室(南京天文光学技术研究所) 南京 210042)

(3 中国科学院大学 北京 100049)

摘要 SH-WFS (Shack-Hartmann Wavefront Sensor)在自适应光学系统中被广泛使用. 为了充分利用SH-WFS图像中所包含的信息, 一种基于多特征融合的神经网络波前重构方法Moment-U-Net被提出. 该方法在传统波前重构方法使用的质心偏移量的基础上, 额外引入了像斑强度和二阶矩特征, 用来表征像斑的形状信息, 可以对波前进行高精度重建. Moment-U-Net采用U-Net作为主干构架, 通过引入密集连接模块DenseBlock (Dense Convolutional Block)与通道注意力机制SEBlock (Squeeze-and-Excitation Block), 使模型能够在训练过程中有效提取高阶像差特征. 该模型利用仿真生成大规模的大气相位和波前图像数据进行训练, 具有良好的收敛性. 利用仿真生成的不同强度的大气湍流进行验证, Moment-U-Net波前重构均方根误差可达到0.010-0.025 μm . 另外该方法对于暗星也具有较高的重构精度, 在8 mag时重构误差低于0.070 μm . 验证结果表明, Moment-U-Net不仅具有极高的波前重构精度, 还对不同的湍流强度和星等表现出较高的泛化能力, 具备在实际观测中提升自适应光学系统校正能力的潜力.

关键词 大气: 大气湍流, 波: 波前传感器, 自适应光学

中图分类号: P111; **文献标识码**: A

1 引言

自适应光学(Adaptive Optics, AO)系统广泛应用于太阳、星系、系外行星以及星周盘等天文观测中. 通过实时校正大气湍流引起的波前扰动, 该系统可以获得接近衍射极限的观测图像, 从而提升地面望远镜的分辨能力. 系外行星直接成像领域^[1], 由于需要探测到距离恒星小于1"的暗弱行星, 对自适应光学性能提出更高的要求. 当前国际上用于系外行星成像仪的, 如GPI (Gemini Planet

Imager)/Gemini South、SPHERE (Spectro-Polarimetric High-contrast Exoplanet REsearch)/VLT (Very Large Telescope), 都配备超级自适应光学系统(Extreme AO System)^[2], 可获得斯特列尔比 (Strehl Ratio)大于0.9的校正效果. SH-WFS (Shack-Hartmann Wavefront Sensor)是自适应光学系统中最常用的波前探测仪器类型. SH-WFS通过微透镜阵列将入射光束汇聚到二维相机上, 形成像斑阵列^[3]. 利用像斑的质心位置偏移与其通过

2025-03-06收到原稿, 2025-04-14收到修改稿

*国家自然科学基金项目(U2031210), 国家重大科研仪器研制项目(11827804), 中国载人航天工程巡天空间望远镜专项科学研究项目(CMS-CSST-2021-A11、CMS-CSST-2021-B04、CMS-CSST-2025-A17、CMS-CSST-2025-A18、CMS-CSST-2025-A19)资助

† gzhao@niaot.ac.cn

透镜子孔径的波前斜率成正比特性,可以重构获取波前相位信息,并后续控制可变形镜实现波前相位的校正.波前探测的精度直接决定了自适应光学的校正能力.通过增加子孔径数目可以提高波前探测精度,然而这样会使得每个子孔径接收到的光强减少,导致极限星等下降.因此如何优化波前重构算法提高SH-WFS波前重构精度成为了被广泛关注的研究课题.

在传统的SH-WFS波前重构算法(例如模式法、局部法)中,仅使用像斑质心的偏移信息,而忽略了像斑强度、形状、结构等信息.如何充分利用像斑的信息是提高波前重构精度的关键. DuBose等^[4]讨论了在波前重构中引入像斑强度信息的方法,提出了基于光强增强的深度网络ISNet(Intensity/Slopes Network).该方法在大气折射率结构常数 $C_n^2 = 5.0 \times 10^{-14} \text{ m}^{-2/3}$ 的条件下,将波前重构的均方根误差降低至 0.071λ ,显著提升了波前探测性能. Vieggers等^[5]在2017年提出了一种基于样条的像差重建方法(Spline-based Aberration Reconstruction through Moment measurements, SABRE-M),利用SH-WFS焦点光斑的一阶和二阶矩信息,使用B-样条基函数进行波前重建.数值实验表明,SABRE-M在处理高阶像差时远好于传统的波前重构算法.丰帆等^[6]设计了离焦型SH-WFS,通过将相机偏离微透镜阵列焦点的方式放大了像斑的尺寸,并结合像斑的二阶矩得到的波前曲率信息,提高了波前重构的精度. Jia等^[7]于2021年提出了一种基于压缩感知的SH-WFS方法.该方法通过信噪比信息对像斑进行筛选,仅使用高信噪比的像斑数据进行波前重构,避免了低信噪比像斑对波前重构结果的影响.结合深度学习网络加速重构速度,并引入Dropout层模拟压缩感知过程,该方法可以在仅利用60%子孔径数据、低相干长度($r_0 = 6 \text{ cm}$ 、 12 cm 、 18 cm)、高噪声条件下,使波前重构的RMSE(Root Mean Square Error)降低至 1 rad 左右.使用RNN(Recurrent Neural Network)、Transformer等深度学习网络,直接利用整张SH-WFS图像进行波前重构的方法也被广泛研究.这些方法避免了像斑质心计算等过程造成的信息损失,可以提高波前重构的精度. Gu等^[8]

于2021年提出了一种基于深度卷积神经网络ResNet50+(Residual Network 50+)的高精度波前重构方法.该方法通过建立像斑图案与Zernike系数之间的非线性映射,避免了传统的斜率计算过程,显著提高了重构精度.在 9 mag 的低信噪比环境下波前重构的RMSE达到了 0.083λ .冯佳濠等^[9]于2023年提出了基于Transformer的波前重构方法,构建了直接从像斑图像到波前像差之间的神经网络模型,残余波前RMSE稳定在 $0.010\text{--}0.024 \mu\text{m}$ 之间.

在本文中,我们构建了基于深度学习的波前重构神经网络模型Moment-U-Net.该模型结合了以往深度学习模型的优点,使用像斑的偏移量、强度、二阶矩(即像斑的形状)共6个维度的信息进行波前重构,充分提取像斑信息,减少了使用完整图片作为输入时模型训练和推理时的资源消耗. Moment-U-Net网络模型参照DuBose等^[4]和Jia等^[7]的工作,基于U-Net^[10]作为主结构构建. U-Net已在图像分类、图像分割以及图像恢复等领域展示了卓越的性能^[11-16].模型通过引入DenseBlock^[17]和SEBlock^[18](Squeeze and Excitation Block)进一步提升了网络的表达能力和性能.通过数值模拟,我们验证该方法可以在 $C_n^2 = 4.0 \times 10^{-13} \text{ m}^{-2/3}$ 的湍流环境下得到 $0.028 \pm 0.0022\lambda$ 的重构精度.且在不同湍流环境下均优于不包含二阶矩的神经网络重构方法和基于最小二乘法拟合的Zernike模式法.

2 波前数据和Moment-U-Net模型

2.1 波前数据模拟

我们使用Hcipy^[19]程序包构建了大气湍流模型和波前传感器模型,使用蒙特卡洛数值模拟的方法生成大气相位屏和对应的波前图像用于模型训练和验证.大气湍流相位屏使用基于Assémat等^[20]2006年给出的算法生成.我们仿真了Fired参数 $r_0 = 20.2 \text{ cm}$ 、 14.4 cm 、 10.1 cm 共3种不同的湍流强度.望远镜口径设置为 2 m ,SH-WFS子孔径阵列为 16×16 ,每个子孔径投影尺寸为 12.5 cm 和模拟设置的大气 r_0 匹配.波前焦面图像利用菲涅尔衍射光学传播模型生成.对应的大气相位屏和

波前传感器图像如图1所示. 我们共生成了 $r_0 = 14.4$ cm 条件下的40000组大气相位和对应的波前图像对模型进行训练. 并且生成3种湍流强度下

1800张不同星等的观测仿真图像, 用来对模型的实测性能和泛化能力进行评估.




图 1 不同湍流强度的大气相位屏与SH-WFS焦面图像. 上方3幅子图分别为仿真生成的 $r_0 = 20.2$ cm、14.4 cm、10.1 cm 时的大气相位屏, 下方3幅子图为对应的波前传感器图像.

Fig. 1 Atmospheric phase screens and SH-WFS focal plane images under different turbulence intensities. The top three subplots show the atmospheric phase screens simulated for $r_0 = 20.2$ cm, 14.4 cm, 10.1 cm, while the bottom three subplots show the corresponding wavefront sensor images.

2.2 像斑信息提取

对于每个子孔径对应的像斑, 我们提取了其强度、质心偏移以及二阶矩信息. 光强 I_{total} 可以表示为区域内所有像素点 (x, y) 的光强 $I(x, y)$ 之和:

$$I_{\text{total}} = \sum_{(x,y) \in R} I(x, y), \quad (1)$$

其中, R 表示子孔径对应的图像区域, (x, y) 是区域 R 内的像素点坐标, $I(x, y)$ 是像素点 (x, y) 的光强值.

在Shack-Hartmann波前传感器中, 像斑的偏移量 Δx 和 Δy 分别表示为:

$$\Delta x = (x_{\text{ref}} - x_{\text{centroid}}), \quad \Delta y = (y_{\text{ref}} - y_{\text{centroid}}), \quad (2)$$

其中, Δx 和 Δy 分别表示像斑在 x 和 y 方向的质心偏移量, 单位为像素数; x_{centroid} 与 y_{centroid} 为实测质心坐标, x_{ref} 与 y_{ref} 为参考图像的质心坐标.

像斑的形状信息通过计算像斑二阶矩进行提

取, 计算公式如下:

$$M_{xx} = \frac{\sum_R I(x, y)(x - x_{\text{centroid}})^2}{\sum_R I(x, y)}, \quad (3)$$

$$M_{yy} = \frac{\sum_R I(x, y)(y - y_{\text{centroid}})^2}{\sum_R I(x, y)}, \quad (4)$$

$$M_{xy} = \frac{\sum_R I(x, y)(x - x_{\text{centroid}})(y - y_{\text{centroid}})}{\sum_R I(x, y)}. \quad (5)$$

其中 M_{xx} 和 M_{yy} 分别表示像斑在 x 和 y 方向的二阶矩, 反映像斑在 x 和 y 方向的弥散度; M_{xy} 是像斑的混合二阶矩, 表示像斑强度分布的倾斜度. 如图2所示, 每张波前图像提取6组特征组成 $16 \times 16 \times 6$ 的矩阵, 作为后续深度模型训练的输入.




图 2 波前传感器像斑特征提取结果, 上方3幅子图为对应光斑强度、 x 方向质心偏移以及 y 方向质心偏移. 下方3幅子图为像斑的3个二阶矩特征分量.

Fig. 2 Wavefront sensor spot feature extraction results. The top three subfigures show the corresponding light spot intensity, x -direction centroid offset, and y -direction centroid offset. The bottom three subfigures show the three second-order moment components of the spot.

2.3 Moment-U-Net模型设计

我们基于ISNet^[4]模型进行改进, 提出了Moment-U-Net模型. ISNet是以波前传感器像斑强度和偏移量为输入特征, 通过神经网络进行波前重构. 在ISNet的基础上, Moment-U-Net引入了密集连接模块和注意力机制, 以增强特征提取能力和网络表达能力. 同时, 通过优化整体架构, 使模型的输入层能够接受6个特征分量(二阶矩3个分量、偏移量2个分量、像斑强度1个分量), 从而更好地适应波前重构任务的需求. 在Moment-U-Net模型中, 波前重构通过像斑强度、斜率及二阶矩作为神经网络输入, 以大气相位屏作为神经网络输出, 模型结构如图3所示. 该模型以U-Net为主框架, 在U-Net基础上引入了DenseBlock机制, 提供了强大的特征空间信息保留能力. U-Net的编码器-解码器结构能够有效捕捉多尺度特征, 同时通过跳跃连接(Skip Connection)将低层特征与高层特征融合, 确保在重构过程中保留细节信息. 这种结构特别适合处理波前重构任务, 因为波前畸变通常包含丰富的空间频率信息. 为了进一步增强网络的表达能力, DenseBlock和SEBlock被引入到编码器和解码器中. DenseBlock结构通过密集连接机制, 使

得每一层的输入都来自前面所有层的输出, 从而促进了特征的重用和信息流动. 这种设计不仅提高了特征的利用率, 还缓解了梯度消失问题, 使网络在训练过程中更加稳定. SEBlock通过引入注意力机制, 动态调整通道之间的权重, 使网络能够自动学习每个通道的重要性, 提高特征表达能力, 增强模型对关键特征的关注. 在神经网络的卷积操作中, 采用了双卷积的方法, 即分两次卷积操作, 逐步增加通道数. 完成卷积操作后, 为防止过拟合, 需要进行归一化操作, 我们使用组归一化(Group Normalization), 将通道分为若干组, 并在每组内进行归一化. 相比批量归一化(Batch Normalization), 组归一化对于分布多样性较高的数据更加适配, 尤其适合处理高维数据. 在网络的下采样过程中, 特征图尺寸从输入的 16×16 逐步缩小为 8×8 、 4×4 、 2×2 、 1×1 , 同时通道数从6 (对应6个输入特征)逐步增加至128、256、512、1024, 逐步提取高层次的特征表示. 在上采样过程中, 虽然通过反卷积操作将特征图尺寸从 1×1 逐步恢复为 2×2 、 4×4 、 8×8 、 16×16 、 32×32 , 同时通道数从1024逐步减少至512、256、128、64、32, 最终输出通道调整为1, 表示重构的目标大气相位屏.

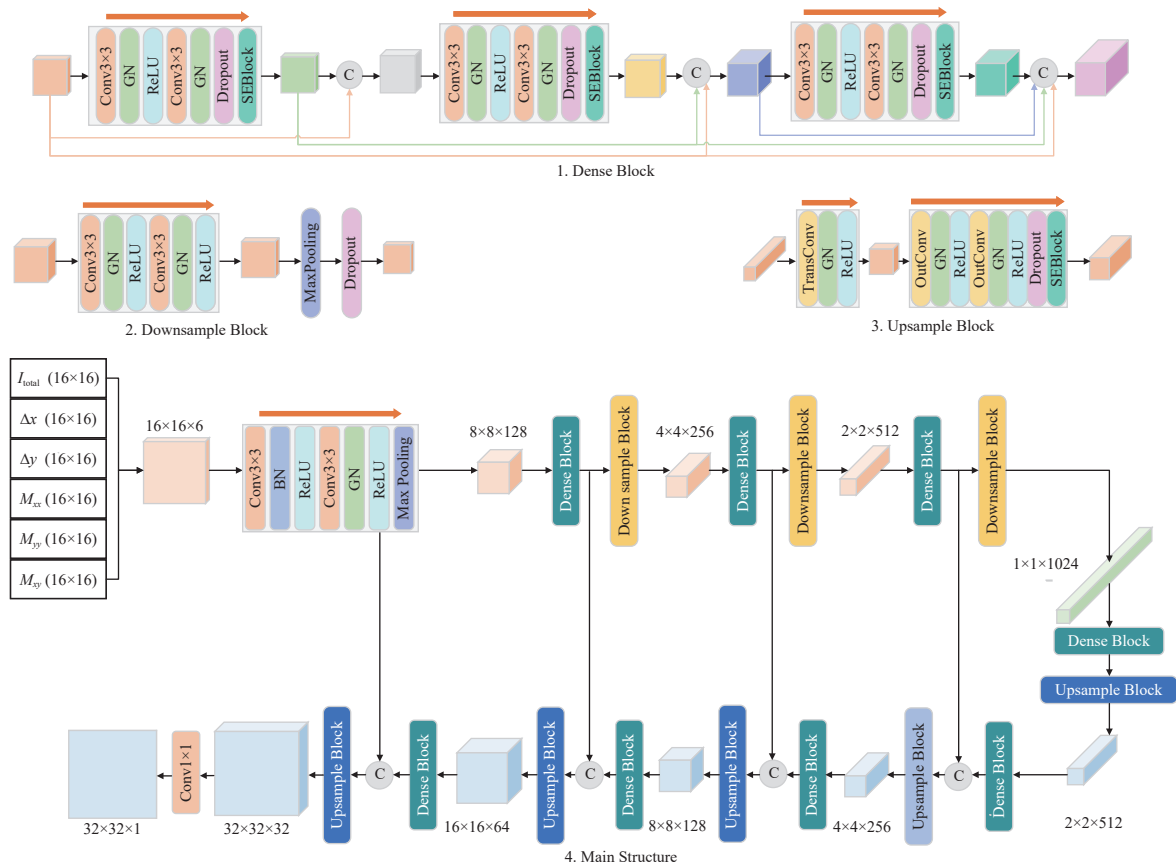


图 3 Moment-U-Net网络的结构, 包括4个部分: (1) DenseBlock结构, 通过密集连接增强特征复用; (2) 下采样模块, 通过卷积和池化降低分辨率并提取高层次特征; (3) 上采样模块, 通过转置卷积(TransConv)恢复分辨率; (4) Moment-U-Net主框架, 整合了DenseBlock, 下采样和上采样模块, 并包含卷积层(Conv)、激活函数(ReLU)、组归一化层(GN)、通道堆叠层(C)和丢弃层(Dropout)。

输入特征为 I_{total} 、 Δx 、 Δy 、 M_{xx} 、 M_{yy} 、 M_{xy} 。

Fig. 3 The structure of the Moment-U-Net network consists of four components: (1) DenseBlock structure, which enhances feature reuse through dense connectivity; (2) downsampling module, which reduces spatial resolution and extracts high-level features using convolutional and pooling operations; (3) upsampling module, which restores spatial resolution via transposed convolution (TransConv); (4) main framework of Moment-U-Net, which integrates DenseBlock, downsampling and upsampling modules, and also includes convolutional layers (Conv), activation functions (ReLU), group normalization layers (GN), channel concatenation layers (C), and dropout layers (Dropout). The input features are: I_{total} , Δx , Δy , M_{xx} , M_{yy} , M_{xy} .

由于上采样过程中特征图的通道数逐步减少, 导致部分重要特征被压缩, 为减少细节信息的丢失, 我们还在DenseBlock和上采样过程中引入如图4所示的SEBlock结构, 该结构被用于自适应调整特征通道的权重. 在波前重构任务中通过全局平均池化提取每个通道的全局信息, 捕捉波前畸变的整体特征, 避免局部噪声干扰. 随后通过全连接层和Sigmoid激活函数学习通道间的依赖关系, 生成每个通道的权重值, 自适应地增强关键特征(如高阶像差)并抑制无关特征. 最后通过通道加权

将权重值与输入特征图逐通道相乘, 提升特征表达能力. 这种设计能够有效增强波前重构任务中的关键信息, 抑制噪声干扰, 同时提升模型的泛化能力和收敛速度, 使其在复杂湍流环境下表现出色, 为高精度波前校正提供可靠支持.

2.4 Moment-U-Net模型训练

在Moment-U-Net的训练中, 首先将包含40000对像斑特征及其对应的大气相位屏数据进行归一化处理, 之后将其划分为训练集(32000组)、测试

集(4000组)和验证集(4000组). 训练参数设置如下: Epoch为100, 每批次数据量(Batch size)为256. 初始学习率为 1×10^{-3} 并根据每个迭代轮次损失函数进行自适应调整.

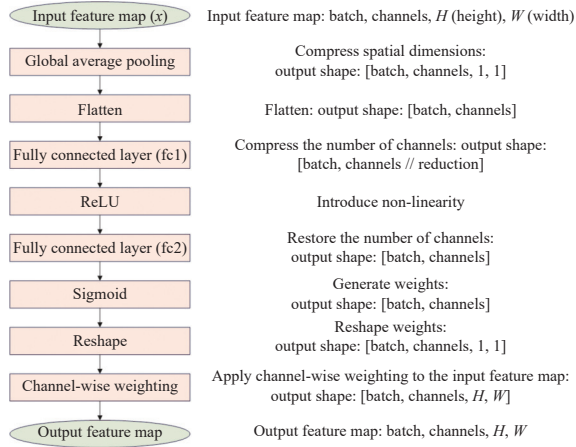


图 4 SEBlock结构图. 通过全连接层和激活函数(ReLU和Sigmoid)生成通道权重, 用于重新校准每个通道的重要性.

Fig. 4 SEBlock architecture. Generates channel weights through fully connected layers and activation functions (ReLU and Sigmoid) to recalibrate the importance of each channel.

对于优化器以及损失函数, 我们采用了AdamW (Adam Weight Decay Optimizer)与RMSE的组合来训练神经网络. AdamW的优势在于其将权重衰减与梯度更新解耦, 有效控制模型复杂度并提升泛化能力, 同时继承了Adam (Adaptive Moment Estimation)的自适应学习率特性, 能够快速收敛并避免局部最优. 对于损失函数RMSE, 其平方误差特性能够更强烈地惩罚较大误差, 显著提升复杂波前畸变的重构精度. 通过对Moment-U-Net模型在AdamW优化器和RMSE损失函数下的测试, 结果如图5所示, 模型在60个迭代轮次快速收敛, 获得了RMSE=0.013的最低验证集损失函数值.

3 结果

3.1 不同湍流强度下的基准测试

为了验证Moment-U-Net模型性能, 我们模拟生成了3种不同湍流强度下的基准测试集, 对应的 r_0 分别为20.2 cm、14.4 cm、10.1 cm. 我们还训练

了不包含二阶矩信息, 仅利用像斑强度和偏移量信息重构波前的模型, 该模型和ISNet模型非常类似, 仅额外增加一层SEBlock. 另外我们还和传统的基于OLS (Optimization of the Least Squares)的Zernike模式法进行对比. 图6为3个波前重构模型在3种湍流强度下的一组重构结果, 可以看到基于深度学习的Moment-U-Net模型和ISNet模型在不同湍流强度下重构后的波前图像均具有更精细的细节结构, 而Moment-U-Net具有最小均方根误差, 具体结果对比如表1所示. 在 $r_0 = 20.2$ cm条件下, 包含二阶矩的神经网络重构误差为 $0.020 \lambda \pm 0.003 \lambda$, 优于模式法的 0.030λ . 在 $r_0 = 14.4$ cm条件下, 包含二阶矩的神经网络重构误差为 $0.028 \lambda \pm 0.0022 \lambda$, 相较模式法的 0.060λ 展现出明显的提升. 在 $r_0 = 10.1$ cm强湍流条件下, 包含二阶矩的神经网络重构误差为 $0.050 \lambda \pm 0.014 \lambda$, 相较模式法的 0.124λ 提升显著. 在图7中我们画出了3种方法200组重构数据对应的RMSE值, 可以看到Moment-U-Net模型和ISNet模型相比传统模式法具有更高的稳定性, 而Moment-U-Net模型具有更高的重构精度.

3.2 Moment-U-Net在自然导星下的性能测试

为了评估Moment-U-Net在实际观测中的性能, 我们仿真了导星星等在3-8 mag时波前的图像. 我们设SH-WFS综合光电效率为0.8, 等效观测波段为200 nm、中心波长500 nm、仿真单帧曝光时间为1 ms. 对于使用EMCCD (Electron-Multiplying Charge-Coupled Device)的波前传感器, 等效读出噪声小于 $1 e^-$, 且由于曝光时间极短, 暗电流可以忽略. 因此在仿真中, 我们仅考虑了光子噪声的影响. 我们对比了Moment-U-Net在3种湍流强度下的表现, 其中 r_0 分别为20.2 cm、14.4 cm、10.1 cm, 结果如图8所示. 结果表明在高信噪比条件下重构精度可达10 nm左右, 展现了其强大的波前重构能力; 而在8 mag低信噪比条件下, 重构精度仍能保持在70 nm左右. 这表明Moment-U-Net对湍流强度以及星等变化具有较高的稳定性, 尤其在极端观测条件下仍能保持较高的重构精度, 展现了其在实际应用中的潜力.




图 5 验证集的收敛曲线。横轴为训练步数, 纵轴为损失函数值。验证集损失函数在60次迭代内达到收敛, 最终损失函数值为0.013。

Fig. 5 The convergence curve of the validation set. The horizontal axis represents the training steps, and the vertical axis represents the loss function value. The validation loss converges within 60 iterations, with a final loss value of 0.013.

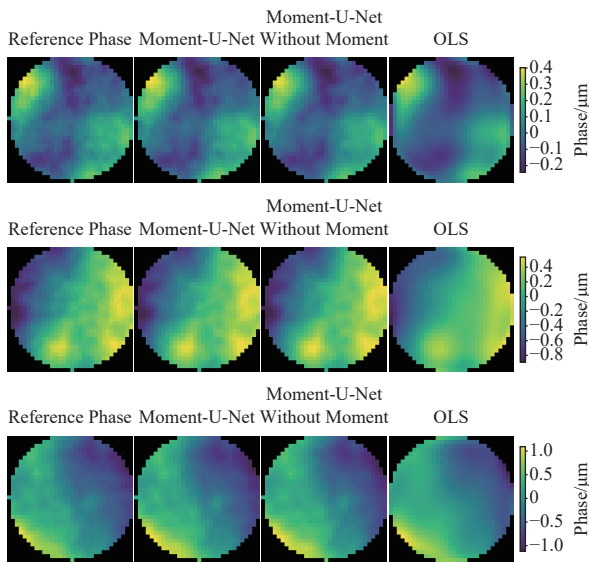


图 6 不同湍流强度下的波前重构对比图。从上到下3张子图分别对应3种大气相干长度 $r_0 = 20.2$ cm, 14.4 cm, 10.1 cm。每张子图中, 从左到右分别为: 参考相位屏和Moment-U-Net、不含二阶矩的Moment-U-Net、Zernike模式法的重构相位屏。

Fig. 6 Comparison of wavefront reconstruction under different turbulence intensities. The three subplots from top to bottom correspond to three atmospheric coherence lengths $r_0 = 20.2$ cm, 14.4 cm, 10.1 cm, respectively. In each subplot, from left to right, the phase screens are: the reference phase screen and the reconstructed phase screens obtained using Moment-U-Net, Moment-U-Net without 2nd-order moments, and the Zernike Mode Method.

表 1 不同湍流强度波前重构对比
Table 1 Comparison of wavefront reconstruction under different turbulence strengths

Models	Parameters			
	r_0 /cm	C_n^2 /m ^{-2/3}	RMSE /μm	RMSE /λ
Moment-U-Net	20.2	2×10^{-13}	0.010	0.020
	14.4	4×10^{-13}	0.014	0.028
	10.1	7×10^{-13}	0.025	0.050
Moment-U-Net without 2nd-order Moment	20.2	2×10^{-13}	0.011	0.022
	14.4	4×10^{-13}	0.018	0.036
	10.1	7×10^{-13}	0.029	0.058
Zernike	20.2	2×10^{-13}	0.015	0.030
	14.4	4×10^{-13}	0.030	0.060
	10.1	7×10^{-13}	0.062	0.124

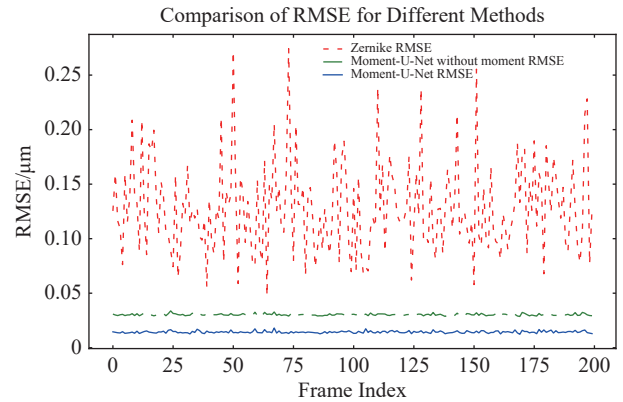


图 7 200组数据3种方法的波前重构RMSE对比图。图中红色点表示Zernike模式法的RMSE, 绿色点线表示不含二阶矩的Moment-U-Net的RMSE, 蓝色实线表示Moment-U-Net的RMSE。

Fig. 7 The comparison of wavefront reconstruction RMSE for 200 datasets using three methods. The red dots represent the RMSE of the Zernike Mode Method, the green dotted line represents the RMSE of Moment-U-Net without 2nd-order moments, and the blue solid line represents the RMSE of Moment-U-Net.




图 8 Moment-U-Net模型在不同星等下的RMSE变化及误差. 图中蓝色、绿色、红色线分别对应3种大气相干长度: $r_0 = 20.2$ cm、14.4 cm、10.1 cm.

Fig. 8 The RMSE variation and error of the Moment-U-Net model under different magnitudes. The blue, green, and red lines in the figure correspond to three atmospheric coherence lengths: $r_0 = 20.2$ cm, 14.4 cm, 10.1 cm.

4 讨论

4.1 Moment-U-Net波前重构原理分析

本文构建的神经网络模型融合使用了像斑的6个特征, 有效地提高了波前重建的精度. 处理类似的多特征、多维度任务是神经网络的擅长领域. 由于神经网络模型的黑盒特性, 我们无法得知其内部运算原理, 这里我们试图从数据层面分析特征中的隐含信息, 推测神经网络进行波前重构获得高精度的原因.

- 二阶矩信息描述了像斑在 x 、 y 方向的弥散程度和弥散的方向, 对应了波前的曲率信息, 结合质心偏移给出的波前斜率信息, 可以有效提高波前重构的精度.

- 光强和二阶矩信息还反映了像斑的信噪比信息, 强度低或更弥散的像斑往往具有较低的信噪比. 通过训练, 神经网络有能力自适应地识别这些像斑, 避免低精度像斑对波前重构的影响.

- 波前传感器边缘的像斑往往具有非规则的点扩散函数, 其质心偏移量和波前倾斜也不满足线性关系, 因此传统方法对于边缘区域的校正效果普遍较差. 而基于神经网络的算法, 可以实现边缘子孔径的有效利用.

- 在质心提取过程中, 如果使用固定区域进行

质心计算, 当质心偏离计算区域中心越远, 计算质心和实际质心差别越大, 更精确的方法需要应用高斯拟合或者更复杂的方法(例Li等^[21]提出的基于人工神经网络的质心提取方法, 该方法在低信噪比条件下显著提高了质心计算的精度), 这无疑增大了计算的复杂度. 而使用深度学习重构波前, 可以在学习过程中自适应地标定质心计算位置 and 实际位置之间的非线性关系, 提高重建精度.

在文中介绍的Moment-U-Net模型中, 输入的子孔径数目为 16×16 , 而输出的波前相位为 32×32 . 目前自适应光学系统中, 波前子孔径和可变形镜促动器基本上为一一对应的关系. 如果Moment-U-Net可应用在实际自适应光学系统中, 可以通过较少的波前子孔径实现更多数目促动器的控制, 有效提升大望远镜极限星等. 另外传统自适应光学中需要子孔径和可变形镜在几何上交错对齐, 否则可变形镜的促动器变化无法有效反馈到波前偏移上. Moment-U-Net由于可以探测波前曲率信息, 预计可以降低WFS和可变形镜的配准要求. 在后续的工作中, 我们计划通过数值仿真和仪器搭建的方法, 探索和验证Moment-U-Net网络在自适应光学系统的应用.

4.2 波前华夫模式重构

大气湍流是影响自适应光学系统性能的主要因素之一, 其引起的波前畸变会显著降低成像质量. 其中, 华夫饼状波前畸变(waffle mode)是一种特殊的波前误差模式, 其特点是相邻区域相位相反, 呈现出类似棋盘格的分布特性. 这种模式在高分辨率成像和天文观测中尤为常见, 但由于其特殊的相位分布特性, 传统基于斜率测量的方法存在固有的局限性: 相邻子透镜区域的正负斜率会相互抵消, 导致无法准确检测和重构此类波前畸变.

在自适应光学系统中, 如果波前传感算法设计不当, 可能会进一步放大这一缺陷, 使得华夫饼模式难以被有效抑制. 这不仅会影响系统的校正能力, 还可能导致成像质量恶化, 尤其在高精度应用场景中, 这种缺陷的影响尤为显著.

本文提出的神经网络模型, 引入了像斑的形状信息, 为解决华夫饼模式重构提供了新的可能

性. 与传统的斜率测量方法不同, 二阶矩特征能够从光斑的整体分布中提取关键信息, 避免了局部斜率相互抵消的问题. 实验结果如图9所示, 该方法能够有效应对华夫饼状波前畸变, 显著提升了波前重构的精度和稳定性.




图9 不同方法华夫饼状波前畸变重构图像质量对比图, 包含3个子图, 从左到右依次为参考华夫饼波前(即基准相位屏)、Moment-U-Net重构相位屏结果以及模式法重构相位屏结果. 颜色条单位为微米(μm).

Fig. 9 Comparison of image quality for waffle mode reconstruction using different methods. The figure contains three subplots, showing from left to right: the reference waffle wavefront (i.e., the baseline phase screen), the reconstructed phase screen result by Moment-U-Net, and the reconstructed phase screen result using the modal method.

The color bar is in units of micrometer (μm).

4.3 包含像斑三阶矩的波前重构模型

由于引入二阶矩信息显著提升了波前重构精度, 这表明高阶统计特征对波前重构任务的重要性. 因此, 我们进一步探索了像斑的三阶矩特征, 以挖掘更高维度的像斑信息来提升模型性能. 三阶矩作为描述像斑分布高阶不对称性的关键指标, 能够捕捉像斑形态中更为复杂和精细的变化. 三阶矩特征具有4个分量, 其计算方法如(6)–(9)式所示:

$$M_{x^3} = \frac{\sum_R (x - x_{\text{centroid}})^3 \cdot I(x, y)}{\sum_R I(x, y)}, \quad (6)$$

$$M_{y^3} = \frac{\sum_R (y - y_{\text{centroid}})^3 \cdot I(x, y)}{\sum_R I(x, y)}, \quad (7)$$

$$M_{x^2y} = \frac{\sum_R (x - x_{\text{centroid}})^2 (y - y_{\text{centroid}}) \cdot I(x, y)}{\sum_R I(x, y)}, \quad (8)$$

$$M_{xy^2} = \frac{\sum_R (x - x_{\text{centroid}}) (y - y_{\text{centroid}})^2 \cdot I(x, y)}{\sum_R I(x, y)}. \quad (9)$$

其中, M_{x^3} 、 M_{y^3} 、 M_{x^2y} 和 M_{xy^2} 分别表征了像斑在不同维度的高阶不对称特性: M_{x^3} 和 M_{y^3} 反映光斑在 x 和 y 方向的偏斜度(与彗差相关), 而 M_{x^2y} 和 M_{xy^2} 则揭示了光斑形态的耦合不对称性(类似三叶草像差), 可视化结果如图10所示.




图10 波前传感器的像斑三阶矩可视化, 共包含4个分量, 按子图顺序分别为 M_{x^3} 、 M_{y^3} 、 M_{x^2y} 和 M_{xy^2} , 分别表示沿 x 方向和 y 方向的三阶矩以及它们的混合项.

Fig. 10 The wavefront sensor's spot third-order moment visualization includes four components, in the order of subplots: M_{x^3} , M_{y^3} , M_{x^2y} and M_{xy^2} . These represent the third-order moments along the x and y directions, as well as their mixed terms.

通过将像斑三阶矩特征(4个分量)与二阶矩(3个分量)、偏移量(2个分量)以及强度进行特征融合, 我们对Moment-U-Net架构的输入层进行了调整, 使其能够容纳10个特征分量, 并成功训练出新的神经网络模型. 为验证该模型的性能提升效果, 我们选取了100组典型数据样本进行重构实验, 并与原始Moment-U-Net方法进行了对比分析. 实验结果如图11所示, 新模型的RMSE由 $(0.0144 \pm 0.0024) \mu\text{m}$ 降至 $(0.0131 \pm 0.0017) \mu\text{m}$, 精度提升约9.2%. 然而, 由于特征维度的增加, 新模型的单帧处理时间从 $(8.82 \pm 1.23) \text{ms}$ 上升至 $(12.85 \pm 2.63) \text{ms}$, 耗时增幅达45.6%. 这一结果表明, 在实时性

要求相对宽松的应用场景中,通过引入更高阶特征信息可以进一步提升重构精度.后续研究将重点探索如何在引入高阶信息的同时,通过模型结构优化、特征选择等方法,有效控制计算复杂度的增长,以兼顾精度与效率的平衡.

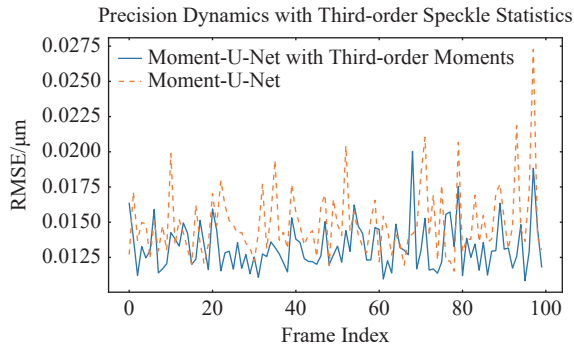


图 11 增加三阶矩重构效果对比图. 图中的蓝色实线表示引入三阶矩的重构结果, 橙色虚线表示Moment-U-Net的重构结果.

Fig. 11 Comparison of reconstruction results with third-order moments. The blue solid line in the figure represents the reconstruction results using the method that incorporates third-order moments, while the orange dashed line represents the reconstruction results using Moment-U-Net.

5 结论

本文提出了一种基于多特征融合的神经网络波前重构方法Moment-U-Net,旨在充分利用夏克-哈特曼波前传感器(SH-WFS)图像中的信息,显著提升波前重构的精度和稳定性.通过在传统质心偏移量的基础上引入像斑强度和二阶矩特征, Moment-U-Net能够更全面地描述像斑的形状、信噪比以及波前的曲率信息,从而实现波前的高精度重建. Moment-U-Net采用U-Net作为主干网络,并结合密集连接模块(DenseBlock)与通道注意力机制(SEBlock),有效增强了模型对高阶像差特征的提取能力.通过大规模仿真生成的大气相位和波前图像数据进行训练,模型表现出良好的收敛性和稳定性.实验结果表明, Moment-U-Net在不同湍流强度下的波前重构均方根误差(RMSE)可达到 $0.010\text{--}0.025\ \mu\text{m}$,显著优于传统方法和其他基于深度学习的波前重构算法.此外,该方法对

暗弱目标(8 mag)同样表现出较高的重构精度,重构误差低于 $0.070\ \mu\text{m}$,展现了其在低信噪比条件下的强大适应能力.验证结果进一步表明, Moment-U-Net不仅具有极高的波前重构精度,还表现出较强的泛化能力,能够适应不同湍流强度和星等条件下的波前重构任务.因此, Moment-U-Net在实际天文观测中具有广泛的应用潜力,能够有效提升自适应光学系统的校正性能,为高分辨率天文成像提供可靠的技术支持.

参考文献

- [1] Jovanovic N, Martinache F, Guyon O, et al. *PASP*, 2015, 127: 890
- [2] Macintosh B, Graham J R, Ingraham P, et al. *PNAS*, 2014, 111: 12661
- [3] Platt B C, Shack R. *Journal of Refractive Surgery*, 2001, 17: S573
- [4] DuBose T B, Gardner D F, Watnik A T. *OptL*, 2020, 45: 1699
- [5] Vieggers M, Brunner E, Soloviev O, et al. *OExpr*, 2017, 25: 11514
- [6] 丰帆, 李常伟, 张思炯. *光学学报*, 2018, 38: 0628001
- [7] Jia P, Ma M, Cai D, et al. *MNRAS*, 2021, 503: 3194
- [8] Gu H, Zhao Z, Zhang Z, et al. *MeScT*, 2021, 32: 085101
- [9] 冯佳濛, 胡启立, 姜律, 等. *液晶与显示*, 2023, 38: 798
- [10] Ronneberger O, Fischer P, Brox T. *Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015: 18th International Conference*. Cham: Springer International Publishing, 2015, 9351: 234-241
- [11] Wang C, Zhou P, Zhu J. *OExpr*, 2023, 31: 33287
- [12] Zhang Y, Wu P, Chen S, et al. *OExpr*, 2022, 13: 3521
- [13] Gavrilov D A. *CoOpt*, 2021, 45: 575
- [14] Aragon-Calvo M A. *MNRAS*, 2019, 484: 5771
- [15] Mackovjak Š, Harman M, Maslej-Krešňáková V, et al. *MNRAS*, 2021, 508: 3111
- [16] Kennedy J, Carr J C, Gagnon-Hartman S, et al. *MNRAS*, 2024, 529: 3684
- [17] Huang G, Liu Z, Van Der Maaten L, et al. *2017 IEEE Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE, 2017: 4700
- [18] Hu J, Shen L, Sun G. *Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE, 2018: 7132
- [19] Por E H, Hafert S Y, Radhakrishnan V M, et al. *Proceedings of Adaptive Optics Systems VI*. Bellingham: SPIE, 2018, 10703: 1070342
- [20] Assémat F, Wilson R W, Gendron E. *OExpr*, 2006, 14: 988
- [21] Li Z, Li X. *OExpr*, 2018, 26: 31675

