

DOI: 10.19650/j.cnki.cjsi.J2312095

基于多图超分辨率重建的精细导星仪 星点质心定位精度提升方法*

王雯蕊^{1,2,3}, 张泉^{1,2}, 高源蓬^{1,2,3}, 房陈岩^{1,2}, 尹达一^{1,2,3}

(1. 中国科学院上海技术物理研究所 上海 200083; 2. 中国科学院红外探测与成像技术重点实验室
上海 200083; 3. 中国科学院大学 北京 100049)

摘要:精细导星仪的星点质心定位精度决定了空间天文望远镜的视轴姿态解算精度,为了提升精细导星仪的星点质心定位精度,提出了一种基于深度小波循环神经网络的星图超分辨率重建方法。首先,借助微扫描技术获取亚像素错位低分辨率星图序列,采用小波编码器提取低分辨率星图的小波域特征,通过小波系数约束低分辨率星图的噪声,并将亚像素错位星图序列配准过程融入到网络学习中。其次,利用卷积门循环神经单元对所提取的多星图序列特征进行融合。最后,使用逆小波解码器对多特征融合模块输出的小波域特征进行解码,从而实现基于低分辨率星图序列的去噪与超分辨率重建。实验结果表明,分别采用平方加权质心法求取原始星图和超分辨率重建后星图中的各星点的质心位置,相比于前者,后者的各星点平均质心定位精度和稳定度在 X 方向分别提升了64.76%和19.15%,在 Y 方向分别提升了75.35%和26.14%。

关键词:精细导星仪;星点质心定位;超分辨率重建;小波信号处理;卷积门循环神经网络

中图分类号: TH124 TP391 **文献标识码:** A **国家标准学科分类代码:** 42020

Precision improvement method of star centroid positioning based on multi-image super-resolution reconstruction for fine guide sensor

Wang Wenrui^{1,2,3}, Zhang Quan^{1,2}, Gao Yuanpeng^{1,2,3}, Fang Chenyan^{1,2,3}, Yin Dayi^{1,2,3}

(1. Shanghai Institute of Technical Physics, Chinese Academy of Sciences, Shanghai 200083, China; 2. Key Labray Infrared
System Detection and Imaging Technology, Chinese Academy of Sciences, Shanghai 200083, China;
3. University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: The accuracy of the fine guide sensor's star centroid positioning determines the accuracy of the visual axis attitude calculation of the space telescope. To improve the positioning accuracy of the star centroid of the fine guide sensor, a star image super-resolution reconstruction method based on the deep wavelet recurrent neural network is proposed. Firstly, the micro-scanning technology is used to obtain the sub-pixel misalignment low-resolution star image sequence, and the wavelet domain features of the low-resolution star image are extracted by using the wavelet encoder while the noise of the low-resolution star image is constrained by the wavelet coefficients. The registration process of the input star image sequence is integrated into the network learning. Secondly, the convolutional gate recurrent neural unit is used to fuse the features of the extracted star image sequence. Finally, the inverse wavelet decoder is utilized to decode the wavelet domain features output by the multi-feature fusion module. In this way, the de-noising and super-resolution reconstruction based on low-resolution star image sequences are realized. The experimental results show that the square-weighted centroid method is used to obtain the centroid positions of each star point in the original star image and the reconstructed star image with super-resolution. Compared with the former, the average centroid positioning accuracy and stability of each star point in the X direction are improved by 64.76% and 19.15%, respectively. In the Y direction, the accuracy and stability are improved by 75.35% and 26.14%, respectively.

Keywords: fine guide sensor; star point centroid positioning; super-resolution reconstruction; wavelet signal processing; convolutional gate recurrent neural networks

0 引言

精细导星仪(fine guide sensor, FGS)作为空间天文望远镜精密稳像系统的检测模块,位于主视场边缘,与主焦面共用主光学系统,其先进行高帧频的星点目标质心定位,然后通过解算输出姿态信息,姿态解算的精度主要由星点质心定位的精度决定^[1],而星点质心定位精度的提升又受到星图空间分辨率的制约^[2]。在实际空间天文观测环境中,受限于望远镜研制成本,包括望远镜口径、成像终端规模、重量、体积、功耗等,和成像能力的技术瓶颈,获取足够高分辨率的星图具有很大挑战^[3]。超分辨率成像技术的目的是恢复光学系统衍射极限以外已丢失的高频分量,能够花费较小成本突破原有低分辨率系统的分辨率限制,获得接近衍射极限的高分辨率成像效果^[4]。因此,研究星图超分辨率重建算法以实现星点质心定位精度的提升具有十分重要的现实意义。

空间天文望远镜通常采用基于快摆镜机构的精密稳像技术对视轴扰动进行补偿^[5],因此,可以通过快摆镜机构的微扫描对同一场景进行多次采样,生成系列相互之间有亚像素信息差异的低分辨率图像,从而可将多幅低分辨率图像合成高分辨率图像^[6]。多图超分辨率重建方法将同一场景的多幅图像互补非冗余信息融合,结合成像模型与先验知识重构出一幅高分辨率图像^[7]。多图超分辨率重建算法分为插值法、基于先验信息的重建方法和深度学习方法3类。插值法假设低分辨率图像是由高分辨率图像下采样得到的,故直接对低分辨率图像上采样来得到超分辨率图像,该方法实现过程简单且运算速度快,但是受低分辨率图像噪声影响,鲁棒性较差且容易出现伪影^[8-9]。基于先验信息的重建方法通过估计相关场景的模型,用正则化^[10-11]等方法迭代求解得到超分辨率图像,詹姆斯·韦布空间望远镜采用微扫描测量方法获取周期性的多张图像,用互相关估计多幅图像之间的相对运动并使用贝叶斯解卷积重建中波红外探测器的超分辨率PSF图像^[12]。文献[13]将图像的子像素配准与稀疏编码相结合,通过双稀疏表示的方法构建稀疏字典,进行多幅图像的超分辨率重建,该方法对多个位置的传感器得到了多个观测值的增强。上述方法对于多图超分辨率还需要将图像进行配准等操作,流程较为复杂。深度学习超分辨率重建近年来取得了较为突出的效果,其通过已有的数据结合先验信息实现超分辨率重建同时将配准过程融入模型训练中^[14-15],文献[4]提出了一种新的残差注意力模块,在提取和融合多幅低分辨率图像特征的过程中引入了视觉注意力机制,利用多幅图像的时间和空间相关性进行超分辨率重建并在欧洲航天局对地植被观测卫星PROBA-V采集的数据集上进行验证。

本文提出了一种基于小波变换与深度循环神经网络相结合的方法,实现亚像素错位低分辨率星图序列的超分辨率重建。首先,借助微扫描技术获取亚像素错位低分辨率星图序列,采用小波编码器提取出低分辨率星图的小波域特征,并通过小波系数约束低分辨率星图的噪声,并将输入星图序列配准过程融入到网络学习中,从而降低传统配准算法的复杂度,提升超分辨率重建的准确性。其次,借助卷积门循环神经网络(convolution gate recurrent unit, ConvGRU)对所提取的序列特征进行融合。最后,使用逆小波解码器对小波域特征进行解码,最终实现对低分辨率星图序列的去噪与超分辨率重建。本文借鉴了ESA的Proba-V数据集^[16]构建多图序列进行超分辨率重建的方法,结合高速微扫技术,模拟精细导星仪观测场景,构建了数据集用于多星图超分辨率重建模型训练与评估。

1 精细导星仪星点质心定位算法

作为空间天文望远镜精密稳像系统的检测模块,精细导星仪先进行高帧频的星点质心定位,然后根据星点质心进行望远镜的姿态解算,输出两类信息:1)任意时刻的目标星点质心位置与参考位置的偏差,即望远镜指向误差;2)根据多星点质心位置,通过星图匹配和姿态确定算法得到望远镜的三轴绝对姿态。

星点质心定位是精细导星仪姿态解算的基础,为了获取目标星点中的质心位置,精细导星仪对高速CMOS探测器实时获取的导航星点图像进行预处理,包括中值滤波和阈值分割^[17]。中值滤波是一种非线性滤波算法,其可以在减小散粒噪声以及坏元影响的同时,改善星点形状,如式(1)所示。

$$g(x, y) = \text{median}\{P(i, j)\}, (i, j) \in W \quad (1)$$

式中: $P(i, j)$ 表示原始图像像素的灰度值; $g(x, y)$ 表示中值滤波后像素的灰度值; W 表示 3×3 滑动窗口。

采用阈值分割将星点目标和背景分离开,通过找最大DN值进行目标星点质心粗定位,然后以最大DN值所处像素位置为中心,利用平方加权质心法进行星点质心细分定位。设包含目标的图像表示为 $f(x, y)$,其中 $x=1, \dots, m, y=1, \dots, n$,阈值分割过程如下:

$$F(x, y) = \begin{cases} f(x, y), & f(x, y) \geq T \\ 0, & f(x, y) < T \end{cases} \quad (2)$$

其中, T 为背景阈值。

平方加权质心法计算过程^[18]如下:

$$X_c = \frac{\sum_{x=1}^M \sum_{y=1}^N x F^2(x, y)}{\sum_{x=1}^M \sum_{y=1}^N F^2(x, y)}, Y_c = \frac{\sum_{x=1}^M \sum_{y=1}^N y F^2(x, y)}{\sum_{x=1}^M \sum_{y=1}^N F^2(x, y)} \quad (3)$$

式中: $F(i, j)$ 为开窗内第 i 行和第 j 列像素的 DN 值; x_j 为 X 轴坐标; y_i 为 Y 轴坐标; X_c 和 Y_c 是质心 X 方向和 Y 方向坐标。

2 所提模型

2.1 模型整体架构

通过微扫描获得亚像素错位低分辨率星图序列, 这些序列具有时间和空间相关性, 且含有噪声干扰。通过约束离散小波变换系数, 可以去除图像噪声, 同时保留图像特征的细节信息, 循环神经网络对于时间或者空间相关的图像序列, 具有较强的建模能力, 且消耗资源较少。所以本文采用小波变换与循环神经网络相结合的方式, 融合多张低分辨率星图序列之间的互补信息, 并学习低分辨率星图序列与高分辨率星图的离散小波变换系数映射关系, 实现去除噪声保留星斑细节信息, 从而实现星图的超分辨率重建。所提模型结构如图 1 所示, 由小波编码器、多特征融合模块、逆小波解码器等模块组成。




图 1 所提模型结构

Fig. 1 Structure diagram of the proposed model

模型输入为 4 张亚像素错位的低分辨率星图集合 $\{S_1, S_2, S_3, S_4\}$, 采用深度循环神经网络融合多张亚像素错位星图序列的特征, 输出为超分辨率重建后的星图, 如式(4)所示。

$$SR = H(S_1, S_2, \dots, S_K) \quad (4)$$

式中: H 表示整个超分辨率重建网络。

2.2 亚像素错位星图超分辨率重建原理

空间天文望远镜的大口径快摆镜机构在进行精密稳像光轴稳定补偿的同时, 也为微扫描获取亚像素错位低分辨率天文图像序列创造了条件, 微扫描原理如图 2 所示。

由大口径快摆镜机构通过摆动控制生成的亚像素错位低分辨率星图序列, 如图 3 所示。其中, 图 3(a) 为原始的图像, 图 3(b) 相对于图 3(a) 向上偏移 0.5 个像素, 图 3(c) 相对于图 3(b) 向左偏移 0.5 个像素, 图 3(d) 相对于图 3(c) 向下偏移 0.5 个像素。通过以上方法得到亚像素错位的低分辨率星图序列, 图 3(a) ~ (d) 可以重建为一张高分辨率图像。分别将图 3(a) 和 (c)、




图 2 微扫描原理

Fig. 2 Micro-scanning principle

(b) 和 (d) 隔行内插, 得到两张图像, 再将其隔列内插, 最后得到图 3 中高分辨率图像。该方法较为简单, 其重建结果在实验不同方法对比中展示。




图 3 微扫描超分辨率重建过程

Fig. 3 Super-resolution reconstruction process through micro-scanning

2.3 模型架构

1) 小波编码器

文献[19]证明了离散小波变换 (discrete wavelet transform, DWT) 在提取图像垂直、水平和对角方向高频信息的同时, 保留完整的边缘信息的能力。由光电探测器得到的星图含有高斯背景噪声, 离散小波变换将噪声星图从空间域转换到频率域, 转换为高频成分和低频成分, 通过约束离散小波变换低频系数实现高斯噪声去除。

小波编码器用来提取每张星图在小波域的特征, 其具有两个输入端, 第 1 个输入端依次输入每张低分辨率星图; 第 2 个输入端口输入由低分辨率图像序列得到的中值图像。低分辨率星图序列未配准会导致超分辨率重建后的星图相对于真实星图产生像素偏移, 因此, 子像素配准是星图序列超分辨率重建的必要处理步骤。本文借鉴文献[20]的思想, 计算星图序列的中值图像, 将其图像特征与每张低分辨率星图特征进行连接, 在网络训练中隐式地计算出参考图像相关的共配准。本文使用 ShiftNet 预测高分辨率图像与超分辨率输出之间的像素偏移, 通过 lanczos 滤波器对图像卷积, 实现子像素对齐。从而极大简化配准过程, 使得网络在训练过程中更加专注于困难的超分辨率重建。小波编码器的结构组成如图 4 所示。




图4 小波编码器

Fig. 4 Wavelet encoder

首先,对两个输入分别进行特征提取,使用离散小波变换将输入图像变换到小波域得到4个分量LL、LH、HH和HL,再把4个分量合并后输入残差卷积网络,其结构组成依次为卷积层、PReLU、残差块,残差块包含两个卷积层和两个PReLU,激活函数PReLU如下所示:

$$\text{PReLU}(x_i) = \begin{cases} x_i, & x_i > 0 \\ a_i x_i, & x_i \leq 0 \end{cases} \quad (5)$$

式中:\$i\$表示不同的通道。

将两个输入提取到的特征进行合并连接输入到卷积神经网络中,得到亚像素错位低分辨率图像在小波域的相关特征。小波编码的过程如下所示:

$$F'_i = [\phi_1(S_i), \phi_1(\text{median}(S_i))] \quad i = 1, \dots, k \quad (6)$$

$$F_i = \phi_2(F'_i) \quad i = 1, \dots, k \quad (7)$$

式中:\$\text{median}(S_i)\$表示由低分辨率星图序列得到的参考图像;\$F'_i\$表示第\$i\$张原始星图和参考星图经过小波变换和残差卷积网络后合并的特征;\$F_i\$表示小波编码器输出的第\$i\$张星图的特征值。

2) 多特征融合模块

GRU(gated recurrent unit)^[21]网络是性能优异的循环神经网络,其层与层之间采用全连接层连接,但会引入大量的参数,导致计算资源的浪费。为了充分利用卷积映射强空间相关性的优势并减少计算参数,引入ConvGRU^[22]网络进行多特征融合,多特征融合模块输入通道大小为64,有2个隐藏层,卷积核大小为3×3。ConvGRU结构如图5所示。

多特征融合模块使用ConvGRU网络将小波编码器所获取的特征进行融合,提取星图中更精细的特征信息,通过上一个隐藏状态表示和当前的特征计算出激活门和复位门,复位门和当前特征计算出当前隐藏状态的估计值,激活门、当前隐藏状态预估值和上一个隐藏状态真实值计算出当前隐藏状态真实的函数值,如式(8)~(11)所示。

$$z_t = \text{sigmoid}(W_i * (F_t, a_{t-1}) + b_i) \quad (8)$$

$$r_t = \text{sigmoid}(W_j * (F_t, a_{t-1}) + b_j) \quad (9)$$

$$a'_t = \tanh(W_h * (F_t, r_t \times a_{t-1}) + b_h) \quad (10)$$




图5 ConvGRU 结构

Fig. 5 ConvGRU structure diagram

$$a_t = (1 - Z_t) \times a_{t-1} + Z_t \times a'_t \quad (11)$$

式中:\$*\$是卷积操作;\$W_i\$、\$W_j\$和\$W_h\$是卷积核;\$b_i\$、\$b_j\$和\$b_h\$是偏差;\$Z_t\$和\$r_t\$分别代表激活门和复位门;\$a'_t\$和\$a_t\$分别代表当前隐藏状态估计值和当前隐藏状态真实值。

在多特征融合模块中,网络将输入的4个小波域特征表示转换为隐藏表示\$\{a_1, a_2, a_3, a_4\}\$,最后将所有隐藏状态特征做全局平均池化(global average pooling, GAP)得到一个固定大小的表示,即将不同通道GRU的输出加权取平均以将多个特征进行融合:

$$a_{mean} = \text{GAP}(\text{MF}(F_1, \dots, F_i)) \quad (12)$$

式中:\$\text{MF}\$代表多特征融合模块;\$a_{mean}\$为星图集合在多特征融合模块输出的全局平均值。

3) 逆小波解码器

逆小波解码器包含解卷积网络和离散逆小波变换层,解卷积网络由逆卷积层和卷积层组成,逆卷积层的激活函数为PReLU。首先将融合模块得到的全局平均值输入到解码器的逆卷积层进行上采样,通过卷积层进行特征维度转换得到4个分量,再将4个分量拼接成一个向量输入到离散小波逆变换,最终得到超分辨率重建后的星图:

$$SR = \psi(a_{mean}), \quad a \in \mathbf{R}^{c \times h \times w} \quad (13)$$

式中:\$SR\$是超分辨率重建后星图;\$\psi\$是逆小波解码器。

2.4 损失函数

在超分辨率重建网络中,通常采用最小均方误差(MSE)函数作为网络的损失函数,如式(14)和(15)所示:

$$L_{multi-image} = \|SR - H\|^2 \quad (14)$$

式中:\$H\$为高分辨率标签图像。

本文针对改进模型,引入了小波域预测损失函数^[23]。通过离散小波变换得到低分辨率星图和高分辨率参考图像的方向系数,即水平系数\$y_1\$和\$y'_1\$,垂直系数\$y_2\$和\$y'_2\$,对角系数\$y_3\$和\$y'_3\$,近似系数\$y_4\$和\$y'_4\$。

$$L_{\text{wavelet}}(y, y') = \lambda_i \sum_{i=1}^4 \|y_i - y'_i\|^2 \quad (15)$$

式中: y 和 y' 分别表示方向系数真实值与预测值; λ_i 表示方向系数的权重; $L_{\text{wavelet}}(y, y')$ 为小波域损失函数。参考文献[23], 通过经验调节系数权重 λ_i , 保留星图纹理特征信息。

故星图超分辨率重建网络的总损失函数如下所示:

$$L_{\text{total}} = \mu L_{\text{wavelet}}(y, y') + L_{\text{multi-image}} \quad (16)$$

式中: μ 为控制方向权重损失的平衡参数。

3 实验结果与分析

3.1 实验数据集及评价指标

本文采用的数据集根据精细导星仪实际工作场景获取的星图构建, 共计 2 000 张星图, 分为 400 组, 每组包含 4 张亚像素错位低分辨率星图和 1 张参考星图, 其中 300 组为训练集和验证集, 100 组为测试集。数据集中低分辨率星图尺寸为 128×128 , 星斑大小为 5×5 , 参考星图尺寸为 256×256 。参考图像为理想场景下探测器获得的高分辨率星图。

在图像超分辨率重建研究中, 峰值信噪比 (peak signal to noise ratio, PSNR) 与结构相似性 (structural similarity, SSIM) 是评价超分辨率重建方法的主要指标。PSNR 通过两幅图像的均方根误差评价超分辨率重建后图像质量得到:

$$\text{PSNR} = 10 \log \left(\frac{\text{Max}^2}{\text{MSE}} \right) \quad (17)$$

式中: Max 为超分重建后图像的最大值; MSE 为超分图像与参考图像的差值均方根。

SSIM 从亮度、结构和对比度 3 个方面衡量两幅图像的相似性:

$$\text{SSIM} = \frac{(2\mu_x \mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (18)$$

式中: μ_x, μ_y 分别为超分辨率重建的星图和参考星图的平均值; $\sigma_x^2, \sigma_y^2, \sigma_{xy}$ 分别为超分辨率重建的星图、参考星图方差及两者的协方差。为了保证本文方法的可靠性, 文中超分辨率重建效果的定量评价指标为测试集得到的 100 组星图测试集的平均 PSNR 值。

3.2 实验环境及参数设置

文中模型实现基于 Pytorch 框架, 实验设备使用 AMD Ryzen 5600 6-Core 处理器, 32 GB DDR 内存, 配备 16 GB 显存的 NVIDIA GeForce RTX 3060 显卡的图形工作站。所提网络模型在训练过程中使用 Adam 优化器^[24]进行参数优化, 训练迭代次数为 100 个 epoch, 批量大小为 4, 原始学习率为 7×10^{-5} , 学习率随步长衰减, 步长为

2, 衰减速率为 0.97, 损失函数参数设置为 $\lambda_1 = 0.01, \lambda_2 = \lambda_3 = \lambda_4 = 1, \mu = 0.5$ 。为了解决数据未进行归一化在模型训练中出现的梯度消失问题, 文中将数据集集中的星图先进行批量归一化处理再输入网络。

3.3 实验结果展示

原始星图及对应三维星图 (128×128 pixels) 与超分辨率重建后的星图 (256×256 pixels) 分别如图 6(a)、(b) 和图 7(a)、(b) 所示。为了验证不同结构对模型的影响, 本文探究了残差块数量对所提模型性能的影响。通过改变残差块数量 0、1 和 2, 比较模型的梯度曲线。通过模型的梯度曲线得出, 加入残差块可以有效地防止模型梯度消失, 而加入 2 个残差块会出现过拟合的情况, 所以, 本文模型残差块数量为 1。




图 6 原始星图及对应三维星图

Fig. 6 Original star map and corresponding 3-D star map




图 7 超分辨率重建后的星图及对应三维星图

Fig. 7 Star map and corresponding 3D star map after super-resolution reconstruction

同时, 本文对比了改进模型与原始模型, 对于星图序列超分辨率重建的性能。将所提改进的超分辨率重建模型与传统内插法、双三次上采样法、残差注意力网络^[4]以及卷积门循环神经单元的性能在测试集上进行对比, 如表 1 所示。

从表 1 可以看出, 相比于传统的内插法, 双三次上采样、卷积门循环单元以及残差注意力网络, 所提出的改进 MISR-GRU 超分辨率重建网络的 PSNR 分别提高了 42.72%、23.5%、7.5% 和 5.5%, SSIM 分别提高了

表 1 测试集验证不同多图超分辨率重建方法的平均 PSNR/SSIM 结果

Table 1 Average PSNR/SSIM results on test set for different Multi-image super-resolution reconstruction methods

方法	PSNR	SSIM
本文	48.610	0.999
残差注意力网络	46.069	0.992
卷积门循环单元	45.231	0.791
双三次上采样	39.371	0.510
内插法	34.059	0.404

147.28%、95.88%、26.23% 和 0.7%，性能更优。残差注意力网络在学习过程中只考虑输入序列的时域和频域信息，并且只学习时空域的高频信息，而将低频信息直接输

出到模型输出端。卷积门循环神经单元只考虑了序列在时域与空间域的关系，未考虑噪声因素，会影响后续配准精度。双三次上采样通过映射加权邻域内的像素值得到超分图像中的像素值，但是无法自动实现多张星图序列配准过程，且没有考虑星图序列之间的互补信息。传统内插法只是机械地将 4 张序列像素值融合，没有考虑序列之间的配准，以及像素之间的映射关系。相比于以上模型，所提模型能够对具有空间和时间相关性的连续序列进行建模，利用小波变换系数提供的多尺度信息去除噪声恢复图像细节，考虑星图序列的全局和局部纹理特征，同时将配准过程融入模型中，简化配准过程，实现星图的超分辨率重建。

原始星图中星点三维图像和超分辨重建后的星点三维图像如图 8(a)、(b) 所示。




图 8 原始星图中及超分辨重建后的星点三维图像

Fig. 8 3D images of star points in the original star map and star points after super-resolution reconstruction

通过多连通域算法和星点细分定位算法对固定连续观测 100 帧的原始星图和超分辨率后的星图中的星点进

行质心提取，探测器像元尺寸为 $5.5\text{ }\mu\text{m}$ ，这里抽取 star-1 的质心位置和其真实位置曲线如图 9(a)、(b) 所示。




图 9 X 方向与 Y 方向求解质心位置及其真实位置

Fig. 9 The solved centroid position and the true centroid position in the X-direction and Y-direction

求解的星点质心位置标准差如表 2 所示，求解星点质心位置与真实质心位置偏差均方根值如表 3 所示。超

分辨率重建后星图的分辨率得到提升，星点质心粗定位确定的星点质心位置与星点真实质心位置的偏差更小，

从而提升了星点质心定位精度。以星点最大 DN 值所处像素位置为中心,通过质心细分定位求解出质心位置的波动更小,从而进一步提升了星点质心定位的精度,也提升了稳定度。通过表 2 和 3 可以看出,相比于原始星图,采用改进 MISR-GRU 超分辨率重建后的星图中各星点平均质心定位精度和稳定度在 X 方向分别提升了 64.76% 和 19.15%,在 Y 方向分别提升了 75.35% 和 26.14%。

表 2 求解的星点质心位置标准差
Table 2 Standard deviation of centroid position

μm			
星点	坐标指向	原始星图	超分辨率重建星图
star-1	X -方向	0.087	0.070
	Y -方向	0.088	0.062
star-2	X -方向	0.121	0.097
	Y -方向	0.052	0.035
star-3	X -方向	0.106	0.084
	Y -方向	0.115	0.069
star-4	X -方向	0.340	0.271
	Y -方向	0.382	0.307
star-5	X -方向	0.163	0.138
	Y -方向	0.170	0.155

表 3 求解星点质心位置与真实质心位置偏差均方根值
Table 3 RMS between the solved centroid position and the true centroid position

μm			
星点	坐标指向	原始星图	超分辨率重建星图
star-1	X -方向	8.266	2.743
	Y -方向	7.973	1.902
star-2	X -方向	8.234	3.230
	Y -方向	8.245	1.902
star-3	X -方向	7.881	2.690
	Y -方向	8.283	1.999
star-4	X -方向	7.317	2.614
	Y -方向	7.548	2.053
star-5	X -方向	7.867	2.668
	Y -方向	8.443	2.109

本文所提出的超分辨率重建模型的推理时间为 0.029 s。精细导星仪可以通过开窗成像保证星点图像读出帧频,本文的精细导星仪探测器读出 4 张低分辨率图像的时间为 0.04 s,质心定位采用边读边算模式,故精细导星仪生成高分辨率星图并完成质心定位的时间为 0.069 s,帧频为 14.5 Hz。

4 结 论

本文针对精细导星仪质心定位精度提升问题,提出了一种小波变换与卷积循环神经网络相结合的亚像素错位多图超分辨率重建方法。将微扫描技术得到的亚像素错位低分辨率星图序列及其中值图像作为小波编码器的输入,得到相应的小波域特征并通过小波系数约束低分辨率星图的噪声,再输入到门卷积循环神经网络将其与先验信息融合得到更准确的网络映射,最后通过训练学习得到的网络映射函数获取超分辨率重建后的星图。文中所提出的方法在超分辨率重建的同时可以去除高斯及散粒噪声,同时通过输入低分辨率星图的中值图像在网络中隐式地对亚像素错位低分辨率星图序列进行配准,降低了传统配准算法的复杂度,并提升了超分辨率重建的准确性。

超分辨率重建后星图的分辨率得到提升,星点质心粗定位确定的星点质心位置与星点真实质心位置的偏差更小,从而提升了星点质心定位精度。以星点最大 DN 值所处像素位置为中心,通过质心细分定位求解出质心位置的波动更小,从而进一步提升了星点质心定位的精度,也提升了稳定度。分别采用平方加权质心法求取原始星图和超分辨率重建后星图中的各星点的质心位置,相比于前者,后者的各星点平均质心定位精度和稳定度在 X 方向分别提升了 64.76% 和 19.15%,在 Y 方向分别提升了 75.35% 和 26.14%。

实验结果表明,本文所提的将小波变换与深度循环神经网络相结合的方法能有效地实现亚像素错位低分辨率星图序列的超分辨率重建,从而提升精细导星仪的星点质心定位精度与稳定度。

参考文献

[1] KAZEMI L, ENRIGHT J, DZAMBA T. Improving star tracker centroiding performance in dynamic imaging conditions [C]. 2015 IEEE Aerospace Conference. IEEE, 2015: 1-8.

[2] 朱红,谢俊峰,吴向前,等. 超分辨率重建在卫星平台颤振探测中的可行性[J]. 激光与光电子学进展, 2021,58(3):221-227.

ZHU H, XIE J F, WU X Q, et al. Feasibility of super-resolution reconstruction in satellite platform jitter detection[J]. Laser & Optoelectronics Progress, 2021, 58 (3): 221-227.

[3] 程德强,陈杰,寇旗旗,等. 融合层次特征和注意力机制的轻量化矿井图像 超分辨率重建方法[J]. 仪器仪表学报,2022,43(8):73-84.

CHENG D Q, CHEN J, KOU Q Q, et al. Lightweight

- super-resolution reconstruction method based on hierarchical features fusion and attention mechanism for mi-ne image [J]. Chinese Journal of Scientific Instrument, 2022, 43(8): 73-84.
- [4] SALVETTI F, MAZZIA V, KHALIQ A, et al. Multi-image super resolution of remotely sensed images using residual attention deep neural networks [J]. Remote Sensing, 2020, 12(14): 2207.
- [5] 高源蓬, 张泉, 李清灵, 等. 压电陶瓷执行器迟滞非线性补偿与最优控制[J]. 仪器仪表学报, 2022, 43(8): 163-172.
- GAO Y P, ZHANG Q, LI Q L, et al. Hysteresis nonlinear compensation and optimal control of piezoelectric actuators[J]. Chinese Journal of Scientific Instrument, 2022, 43(8): 163-172.
- [6] 赵浩光, 曲涵石, 王鑫, 等. 高速微扫描图像超分辨重建[J]. 光学精密工程, 2021, 29(10): 2456-2464.
- ZHAO H G, QU H SH, WANG X, et al. Super-resolution reconstruction of micro-scanning images[J]. Optics and Precision Engineering, 2021, 29(10): 2456-2464.
- [7] WRONSKI B, GARCIA-DORADO I, ERNST M, et al. Handheld multi-frame super-resolution [J]. ACM Transactions on Graphics (ToG), 2019, 38(4): 1-18.
- [8] KHALEDYAN D, AMIRANY A, JAFARI K, et al. Low-cost implementation of bilinear and bicubic image interpolation for real-time image super-resolution [C]. 2020 IEEE Global Humanitarian Technology Conference (GHTC). IEEE, 2020: 1-5.
- [9] KIM S Y, OH J, KIM M. Fsr: Deep joint frame interpolation and super-resolution with a multi-scale temporal loss [C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 11278-11286.
- [10] JI X, CAO Y, TAI Y, et al. Real-world super-resolution via kernel estimation and noise injection [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, 2020: 466-467.
- [11] JIANG J, SUN H, LIU X, et al. Learning spatial-spectral prior for super-resolution of hyperspectral imagery[J]. IEEE Transactions on Computational Imaging, 2020, 6: 1082-1096.
- [12] GUILLARD P, RODET T, RONAYETTE S, et al. Optical performance of the JWST/MIRI flight model: Characterization of the point spread function at high resolution [C]. Space Telescopes and Instrumentation 2010: Optical, Infrared, and Millimeter Wave. SPIE, 2010: 166-178.
- [13] KATO T, HINO H, MURATA N. Double sparsity for multi-frame super resolution [J]. Neurocomputing, 2017, 240: 115-126.
- [14] NGUYEN N L, ANGER J, DAVY A, et al. Self-supervised multi-image super-resolution for push-frame satellite images [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 1121-1131.
- [15] BHAT G, DANELLIAN M, YU F, et al. Deep reparametrization of multi-frame super-resolution and denoising [C]. Proceedings of the IEEE/CVF International Co-nference on Computer Vision, 2021: 2460-2470.
- [16] MARTENS M, IZZO D, KRZIC A, et al. Super-resolution of PROBA-V images using convolutional neural networks[J]. Astrodynamics, 2019, 3: 387-402.
- [17] 杨蕴, 李玉, 赵泉华. 高分辨率全色遥感图像多级阈值分割[J]. 光学精密工程, 2020, 28(10): 2370-2383.
- YANG Y, LI Y, ZHAO Q H. Multi-level threshold segmentation of high-resolution panchromatic remote sensing imagery[J]. Optics and Precision Engineering, 2020, 28(10): 2370-2383.
- [18] 王星星, 唐新明, 祝小勇, 等. 高分七号卫星足印光斑质心提取方法与稳定性监测[J]. 光学学报, 2021, 41(24): 274-282.
- WANG X X, TANG X M, ZHU X Y, et al. Centroid extraction method of Gaofen-7 satellite footprint spots and stability monitoring [J]. Acta Optica Sinica, 2021, 41(24): 274-282.
- [19] LAI B L, CHANG L W. Adaptive data hiding for images based on harr discrete wavelet transform [C]. Advances in Image and Video Technology: First Pacific Rim Symposium. Springer, 2006: 1085-1093.
- [20] ZIAJA M, NALEPA J, KAWULOK M. Data augmentation for multi-image super-resolution [C]. IGARSS 2022-2022 IEEE International Geoscience and Remote Sensing Symposium. IEEE, 2022: 119-122.
- [21] WEERAKODY P B, WONG K W, WANG G, et al. A review of irregular time series data handling with gated recurrent neural networks [J]. Neurocomputing, 2021, 441: 161-178.
- [22] BALLAS N, YAO L, PAL C, et al. Delving deeper into convolutional networks for learning video representations[J]. International Conference on Learning Representations, 2016.
- [23] HUANG H, HE R, SUN Z, et al. Wavelet-SRNet: A wavelet-based CNN for multi-scale face super resolution [C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 1689-1697.

- [24] KINGMA D P, BA J. Adam: A method for stochastic optimization [J]. Proceedings of 3rd International Conference on Learning Representations, 2015.

作者简介



王雯蕊, 2019 年于兰州大学获得学士学位, 现为中国科学院上海技术物理研究所博士研究生, 主要研究方向为精密稳像系统微扫超分技术。

E-mail: wangwenrui@mail.sitp.ac.cn

Wang Wenrui received her B. Sc. degree from Lanzhou University in 2019. She is currently a Ph. D. candidate at Shanghai Institute of Technical Physics of the Chinese Academy of Science. Her main research interests include micro-scanning super-resolution control technology of star target in precise image stabilization system.



张泉(通信作者), 2014 年于武汉大学获得学士学位, 2019 年于中国科学院上海技术物理研究所获得博士学位, 现为中国科学院上海技术物理研究所博士后, 主要研究方向为空间望远镜精密稳像系统集成控制技术。

E-mail: zhangquan@mail.sitp.ac.cn

Zhang Quan (Corresponding author) received his B. Sc. degree from Wuhan University in 2014, and Ph. D. degree from Shanghai Institute of Technical Physics of the Chinese Academy of Science in 2019. He is currently a postdoc at Shanghai Institute of Technical Physics of the Chinese Academy of Science. His main research interests include precise image stabilization control technology of space telescope.



高源蓬, 2019 年于西北工业大学获得学士学位, 现为中国科学院上海技术物理研究所博士研究生, 主要研究方向为精密稳像系统星点目标微扫超分控制技术。

E-mail: gaoyuanpeng@mail.sitp.ac.cn

Gao Yuanpeng received his B. Sc. degree

from Northwestern Polytechnical University in 2019. He is currently a Ph. D. candidate at Shanghai Institute of Technical Physics of the Chinese Academy of Science. His main research interests include micro-scanning super-resolution control technology of star target in precise image stabilization system.



房陈岩, 2011 年于上海交通大学获得学士学位, 2016 年于中国科学院上海技术物理研究所获得博士学位, 现为中国科学院上海技术物理研究所副研究员, 主要研究方向为星上信号实时处理技术。

E-mail: fangcy@mail.sitp.ac.cn

Fang Chenyan received his B. Sc. degree from Shanghai Jiao Tong University in 2011, and Ph. D. degree from Shanghai Institute of Technical Physics of the Chinese Academy of Science in 2016. He is currently an associate researcher at Shanghai Institute of Technical Physics of the Chinese Academy of Science. His main research interests include on-board signal real-time processing technology.



尹达一, 1999 年于兰州大学获得学士学位, 2009 年于中国科学院上海技术物理研究所获得博士学位, 现为中国科学院上海技术物理研究所研究员, 主要研究方向为空间紫外成像和光谱技术以及空间高精度稳像控制技术。

E-mail: yindayi@mail.sitp.ac.cn

Yin Dayi received his B. Sc. degree from Lanzhou University in 1999, and Ph. D. degree from Shanghai Institute of Technical Physics of the Chinese Academy of Science in 2009. He is currently a professor at Shanghai Institute of Technical Physics of the Chinese Academy of Science. His main research interests include space ultraviolet imaging, spectroscopy technology and space high precision image stabilization control technology.