

基于自监督深度学习的 NVST 图像去噪

陆县委¹, 刘辉², 尚振宏^{1,3*}

¹昆明理工大学信息工程与自动化学院, 云南 昆明 650500;

²中国科学院云南天文台, 云南 昆明 650216;

³昆明理工大学云南省人工智能重点实验室, 云南 昆明 650500

摘要 新型真空太阳望远镜(NVST)作为研究太阳物理最主要的光学太阳望远镜之一,在采集图像数据过程中会遭受各种噪声干扰,影响对观测数据的研究。一些基于标准监督深度学习的方法在图像去噪领域取得显著成果,但对于干净数据难以获取的天文图像领域该类方法变得不适用。针对此问题,本文将基于自监督深度学习的图像去噪方法应用于 NVST 图像去噪。为定量评价网络模型性能,首先对经过重建的数据添加仿真噪声;其次将含噪数据通过噪声水平估计网络对噪声水平进行估计;接着利用自监督卷积盲点网络对图像特征进行学习,同时使用贝叶斯推理对图像进行恢复;最后通过峰值信噪比和结构相似度评价指标、相关性分析和功率谱分析对实验结果进行定量分析。实验结果表明,不论对于仿真噪声数据还是实际观测数据,相较于实验中其他图像去噪方法,本文方法能有效降低噪声对 NVST 图像的干扰,提高图像信噪比。同时也为干净图像数据难以获取的其他工程领域提供解决思路。

关键词 图像处理; 图像去噪; 新型真空太阳望远镜图像; 自监督学习; 相关性分析; 功率谱分析

中图分类号 P182.4+1

文献标志码 A

doi: 10.3788/LOP202158.0610018

NVST Image Denoising Based on Self-Supervised Deep Learning

Lu Xianwei¹, Liu Hui², Shang Zhenhong^{1,3*}

¹Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming, Yunnan 650500, China;

²Yunnan Observatories, Chinese Academy of Sciences, Kunming, Yunnan 650216, China;

³Yunnan Key Laboratory of Artificial Intelligence, Kunming University of Science and Technology, Kunming, Yunnan 650500, China

Abstract As one of the most important optical solar telescopes for studying solar physics, the new vacuum solar telescope (NVST) suffers from various noise interferences in the process of collecting image data, which affects the study of observation data. Some methods based on standard supervised deep learning have achieved remarkable results in the field of image denoising. However, this type of method becomes inapplicable to the field of astronomical images where clean data is difficult to obtain. To solve this problem, this paper applies the image denoising method based on self-supervised deep learning to NVST image denoising. In order to quantitatively evaluate the performance of the network model, first, add simulation noise to the reconstructed data; second, the noisy data is estimated through the noise level estimation network to estimate the noise level; then, self-supervised convolution blind spot network is used to learn image features, and the image is restored by Bayesian inference; finally, the experimental results are quantitatively analyzed through the peak signal-to-noise ratio (PSNR) and structural similarity evaluation indicators, correlation analysis, and power spectrum analysis. Experimental results

收稿日期: 2020-08-01; 修回日期: 2020-09-05; 录用日期: 2020-09-09

基金项目: 国家自然科学基金(12063002, 11873027, 61462052)

* E-mail: shangzhenhong@126.com

show that, whether for simulated noise data or actual observation data, compared with other image denoising methods in the experiment, the proposed method can effectively reduce the interference of noise on NVST images and improve the image PSNR. At the same time, it also provides solutions for other engineering fields where clean image data is difficult to obtain.

Key words image processing; image denoising; new vacuum solar telescope images; self-supervised learning; correlation analysis; power spectrum analysis

OCIS codes 100.2000; 100.2980; 120.1880; 350.1270

1 引言

在天文图像处理领域,减少噪声干扰最常用的方法是进行长曝光处理,该方法通过增加图像曝光时间来提高图像信噪比^[1]。然而,长曝光方法的缺点显而易见,除了需要很长的观测时间外,对于时间变化非常迅速的活动事件,例如对太阳色球层活动的观测等,该方法可能会丢失部分重要的图像信息从而影响研究结果。由于天文研究对数据有着严谨精密的要求,因此寻求一种更好的天文图像去噪方法十分必要。

在对太阳结构及其活动的研究过程中,为降低观测图像中噪声对研究结果的影响,许多研究学者进行了不同尝试。Livi 等^[2]和 Chae 等^[3]通过整合大熊湖太阳观测站拍摄的多帧太阳磁图,成功研究出太阳宁静区的弱磁场结构。Schrijver 等^[4]通过叠加迈克耳孙多普勒成像仪(MDI)的图像数据,获得一系列太阳高分辨率图像,并且计算出太阳宁静区的极性模式。DeForest^[5]为降低包括太阳图像在内的天文图像中噪声的干扰,提出一种应用性较广泛的局部自适应滤波器算法。这些方法虽然在一定程度上有效减少了噪声,但都有着复杂的计算过程和昂贵的人工成本。随着近些年深度学习技术的迅速发展,利用深度学习进行图像处理有了很大进展。

目前,卷积神经网络^[6](CNN)是图像处理领域主流的深度学习方法之一。CNN 所具有的权值共享、稀疏连接等优点^[7]使得它在多个图像处理领域得到广泛应用。在太阳物理学领域,CNN 也得到了研究学者的广泛关注。Nishizuka 等^[8]通过 CNN 对太阳耀斑进行预测;Illarionov 等^[9]利用 CNN 对日冕孔图像进行分割;Ramos 等^[10]将 CNN 用于光谱极化反转的研究。而基于 CNN 的天文图像去噪中,也有一些效果较佳的方法。例如,Park 等^[11]利用 DCGAN^[12]中生成器和判别器博弈的思想对太阳动力学观测台(SDO)和 HMI(Helioseismic and Magnetic Imager)观测到的太阳磁图进行去噪;Lucas 等^[13]将基于自动编码技术的 U-Net^[14-15]应用于双谱相位恢复,以降低噪声干扰,从而提高重建的

天文图像质量。这些方法的本质是将输入图像转换为低维空间的表现形式,因为在低维空间中不仅可以降低计算量还能更容易地获取图像特征的统计规律;然后将编码后的特征图重新投影至原来的空间,使得原本的噪声图像重建为干净图像。基于这种数据降维的思想^[16],CNN 网络的灵活性和实用性大大提高。同时,因为这种转换过程满足高度复杂的非线性关系,使得网络可以对未知噪声水平甚至空间中更为复杂的噪声图像进行去噪^[17]。

尽管这些基于卷积神经网络的图像去噪方法在实际应用中表现优异,但是仍然存在着一一些问题。首先,大部分方法采用标准监督学习,即需要噪声图像和干净图像作为训练样本对输入网络进行训练,但该条件在现实中很难满足,极大地限制了其应用范围;其次,网络训练以数据为驱动,模型的输出效果很大程度由训练集决定,当干净图像和噪声图像对不够多时,模型性能也会随之下降,而且对于难以获取绝对干净图像的天文观测而言,网络模型难以训练。针对这些问题,Krull 等^[18]提出了 Noise2Void,该网络模型不需要干净图像作为训练目标,只需输入 N 幅单噪声图像即可完成网络训练。该方法是一种自监督学习,因为在没有干净图像的参考下利用含噪像素周围相邻像素的信息即可完成网络训练,但是该模型的不足是没有利用到含噪像素本身的信息,去噪效果有限。Laine 等^[19]针对 Noise2Void 存在的不足进行改进,构建了卷积盲点网络(CBSN),该网络可以同时利用含噪像素及其相邻像素的信息,显著提升去噪效果,并且具有更强的实用性。

本文通过对卷积盲点网络^[19]进行改进,将基于自监督深度学习的图像去噪方法应用于新型真空太阳望远镜(NVST)图像去噪研究中,针对太阳图像特征及设备物理特性对 CBSN 损失函数^[19]进行优化,优化的损失函数不仅对 NVST 观测得到的太阳噪声图像有更好的去噪效果,还在小数据集上有更好表现。在仿真实验中,将经过斑点掩模法^[20]得到的 NVST 重建图像及其添加噪声后的含噪图像作为训练数据,使用峰值信噪比(PSNR)和结构相似

性(SSIM)指标、相关性分析和功率谱分析对去噪结果进行定量评估。最后将该方法应用于 NVST 实际观测的图像数据中,并对去噪结果做出定性分析。

2 NVST 数据

NVST 主要由 1 m 红外太阳望远镜、立式旋转光谱仪和高分辨成像系统等部分组成,是我国太阳物理研究领域对太阳活动观测的主力设备^[21]。NVST 多通道成像系统主要对太阳色球的 H α 波段(656.3 nm)和光球的氧化钛(TiO)波段(705.8 nm)进行高分辨率成像和光谱观测。

2.1 实验数据集介绍

实验使用两套数据对本文方法进行评估。其中一套用于仿真数据去噪,使用的是 NVST 在 2014 年 10 月 3 日 07:26:20 到 09:28:51 时段的太阳 H α 波段观测数据经过斑点掩模法^[20]处理的重建图像;另一套用于真实数据去噪,使用的是 NVST 在 2013 年 3 月 14 日 01:00:40 到 05:24:14 时段含有明显噪声的实际观测图像。

对于仿真数据需要说明的是,由于 NVST 观测系统采用的是 CMOS 图像传感器,所以噪声的主要来源为像素光敏元件的发光二极管和金属-氧化物-半导体(MOS)场效应管^[22]。本文主要针对 MOS 场效应管产生的噪声问题进行研究,而 MOS 场效应管由于其物理特性产生噪声的类型主要为电阻热噪声^[22-23],它是一种服从高斯分布的白噪声,即仿

真噪声使用高斯噪声进行建模。

2.2 实验设置

在仿真数据实验中,对重建图像进行裁剪,获得 2000 幅大小为 512 pixel \times 512 pixel 的局部图像。然后对这些数据添加不同噪声水平的高斯噪声进行降质处理,其中 1500 幅用作训练集,300 幅用作测试集,200 幅用作验证集。在真实数据实验中,从 NVST 实际观测的图像中挑选 600 幅形态较为清楚的含噪图像以避免图像模糊因素对模型训练的影响,将其裁剪为 512 pixel \times 512 pixel 大小的图像,其中 400 幅作为训练集,100 幅作为测试集,100 幅作为验证集,这三个数据集之间不存在交集。在训练过程中使用随机裁剪、图像旋转及翻转等数据扩增方式,一方面可以扩充训练集,另一方面可以提高模型的鲁棒性。

3 网络结构和去噪方法

3.1 卷积盲点网络结构

卷积盲点网络使用 5 层 U-Net^[14]结构,其核心部分是对“盲点”受限感受域的构建,构建过程采用网络分支组合的思想^[19]。如图 1 所示,每个分支的感受域都是不包含中心像素的半平面。在网络末端将具有四个方向的受限感受域经过 3 个 1 \times 1 的卷积进行组合,得到不包含中心像素但具有各个方向像素信息的感受区域^[24]。相比于 Noise2Void,这种方式可以充分利用像素间的潜在关系,使得所有输出的像素都能被损失函数利用。




图 1 具有四个分支网络的卷积盲点网络

Fig. 1 Blind spot convolution network with four branches

在该网络结构中共有四个网络分支,每个分支的感受域被限制在不同方向的半平面内。由于使用的 U-Net 网络通常用于一般图像重建任务,即感受域会获得包括中心像素在内的整个图像区域信息,为了将其转变为受限感受域网络,在每层网络的特征图进行组合之前,对其进行一个像素位置偏移,该操作将分支网络末端的感受域和中心像素分隔开来;然后经过网络末端的 1 \times 1 卷积后输出。不过在

实际情况中,本文与原卷积盲点网络不同,如图 2 所示,将噪声图像分别经过 90 $^\circ$ 、180 $^\circ$ 和 270 $^\circ$ 旋转(R)后(包括原图)输入到其中的一个分支网络。与图 1 原网络结构相比,本文采用的结构虽然与原结构是等效方式,但该结构能在训练过程中共享这个分支网络的卷积核,使得整个模型的权重参数降为原结构的 1/3,大大加快了训练过程,形成一个功能相同但训练更为高效的网络模型体系。




图 2 优化分支后的卷积盲点网络

Fig. 2 Convolution blind spot network after optimizing branch

在网络的卷积层中,为构建图 1 中“盲点”感受域,需要限制零填充卷积层感受域的扩展方向。假定需要该层感受域只向上半平面扩展,那么在进行卷积操作时需将特征图向下进行偏移。例如,一个 $h \times h$ 大小的核,要向上方移动 $n = \text{Floor}(h/2)$ 步长即等效于将特征图向下偏移 n 个像素,以使中心行以下所有权重置零。具体来讲,在特征图顶部填充 n 行零,然后经过卷积操作后获取输出特征图的底部 n 行。在上采样层和下采样层中,感受域在默认情况下也会向各个方向扩展,为避免这种情况,同样应用偏移进行处理。由于下采样层得到的像素内容来源于输入的各个方向的像素信息,而上采样层的输出基于下采样层信息,所以实际操作中只需对下

采样层进行偏移操作。

图 3 展示了对于图 1 网络结构中盲点感受域的构建结果,为了得到不包含中心像素但具有各个方向像素信息的感受区域,使用四个网络分支的输出进行组合。例如在图 3(a)中,中心像素 P 包含在上半平面的受限感受域内,那么 P 的输出来自特征图中相同位置下方的另一像素 A 。在实际操作中,是将输入的特征图向下偏移一个像素,并在其上端填充相应数值。图 3(b)~(d)是其他三个分支网络中的偏移结果,图 3(e)是经过组合后形成的最终“盲点”受限感受域。而对于图 2 网络结构,使用上述等效操作:在输出进行反向旋转之前(R^{-1}),将所有特征图向同一方向进行偏移。




图 3 盲点感受域。(a)上半平面;(b)左半平面;(c)下半平面;(d)右半平面;(e)组合后有盲点的完整感受域

Fig. 3 Blind spot receptive domain. (a)Upper half plane;(b) left half plane; (c)lower half plane;(d) right half plane; (e)complete receptive region with blind spots after combination

使用改进的卷积盲点网络结构提高了含噪数据集的训练效率,减少了网络权重参数;构建的受限感受域使模型在训练过程中避免了恒等映射问题,实现了无参考图像的自监督训练方式。

3.2 卷积盲点网络去噪原理及方法

基于回归思想的图像去噪方法,本质上是对含噪像素 y 潜在的干净像素 x 进行预测^[25]。由于图像中像素不是独立的,所以干净像素 x 由含噪像素 y 以及 y 的各个方向相邻含噪像素 Ω_y 决定。此时的去噪过程可以看是为在已知含噪像素 y 及其相邻含噪像素 Ω_y 的条件下,对于干净像素 x 概率分布 $p(x|y, \Omega_y)$ 的统计推断。对于标准监督学习,通过含噪图像-干净图像训练样本对和 L_2 损失^[12] 来获

取含噪像素 y 及其相邻含噪像素 Ω_y 预测的干净像素均值;而对于自监督学习,由于输入图像和目标图像相同,导致网络训练陷入恒等映射,所以需要考虑输入像素和目标像素的选取。Noise2Void 仅利用 Ω_y 信息构建自监督学习去噪网络忽略了含噪像素 y 的信息^[18],显然这样会对去噪效果造成影响。针对该问题,Laine等^[19]从输出的干净像素均值出发,将含噪像素 y 看成是干净像素 x 的似然 $p(y|x)$,即噪声模型的似然。则根据贝叶斯规则,后验概率正比于先验概率与似然函数之积,即

$$p(x|y, \Omega_y) \propto p(y|x)p(x|\Omega_y), \quad (1)$$

式中: $p(x|y, \Omega_y)$ 表示干净像素的概率分布,即后验分布; $p(y|x)$ 表示噪声模型的似然; $p(x|\Omega_y)$

表示未利用含噪像素 y 时干净像素的概率分布,即先验分布。此时问题转变成求解概率分布 $p(x|\Omega_y)$ 。

由于含噪像素 y 是干净像素 x 的似然 $p(y|x)$,那么含噪训练数据的边缘分布 $p(y|\Omega_y)$ 与未利用含噪像素 y 时干净像素的概率分布 $p(x|\Omega_y)$ 之间满足下式,

$$p(y|\Omega_y) = \int p(y|x)p(x|\Omega_y)dx, \quad (2)$$

式中:含噪训练数据的边缘分布 $p(y|\Omega_y)$ 在高斯噪声模型中可以通过计算封闭解求得^[19],那么作为(1)式中的先验概率 $p(x|\Omega_y)$ 参数模型便可以通过建立噪声模型来学习和预测,即使用高斯分布 $N(u_x, \sigma_x^2)$ 对 $p(x|\Omega_y)$ 进行近似。此时可以训练一个神经网络,利用求解最大似然的方法将 Ω_y 映射为均值 u_x 和方差 σ_x^2 ;最后在测试阶段,由近似 $p(x|\Omega_y)$ 的高斯分布 $N(u_x, \sigma_x^2)$ 通过(1)式的贝叶斯推理计算出后验均值 $E_x[p(x|y, \Omega_y)]$,将后验均值 $E_x[p(x|y, \Omega_y)]$ 作为网络预测结果的原因是它可以使均方误差(MSE)最小化从而提高图像信噪比。

在上述推导过程中,仅通过利用含噪像素本身及其周围相邻的含噪像素信息,不需要参考干净图像即可完成对网络模型的训练,实现了更具实用性的自监督方式图像去噪。

3.3 NVST 噪声模型和训练策略

对 NVST MOS 场效应管产生的噪声进行建模时,由于使用的 NVST H α 波段图像为灰度图,所以不用考虑颜色通道对建模的影响,此时噪声可以建模为

$$u_y = u_x, \sigma_y^2 = \sigma_x^2 + \sigma^2, \quad (3)$$

式中: u_x 和 σ_x 分别表示卷积盲点网络输出的高斯分布的均值与标准差,该高斯分布代表干净像素的概率分布; u_y 和 σ_y 分别表示构建的噪声模型所服从的高斯分布中的均值与标准差; σ 表示高斯噪声的标准差,在网络训练时可以将其作为可训练的未知参数,通过噪声水平估计网络^[26]进行学习和估计,从而预测出输入图像的噪声水平。该网络结构和卷积盲点网络结构^[19]相似,使用 U-Net^[14] 5 层结构。

为将高斯分布 $N(u_y, \sigma_y^2)$ 更好地拟合观测的噪声训练集并提升去噪效果,与原卷积盲点网络不同,本文对负对数似然损失函数^[19]进行了优化,即添加一项正则化常数项,作用是能够更好地校正网

络在训练过程中出现的自身误差,以降低网络训练过程中将含噪像素识别为干净像素的概率

$$\text{Loss}(y, u_y, \sigma_y^2)_{\min} = -\ln f(y; u_y, \sigma_y^2) = \frac{1}{2\sigma_y^2}(y - u_y)^2 + \ln\sigma_y + C, \quad (4)$$

式中: $f(y; u_y, \sigma_y^2)$ 表示高斯分布 $N(u_y, \sigma_y^2)$ 在含噪像素 y 处的概率密度函数; C 表示正则化常数项,在本文中令 $C = -0.2\sigma$ (σ 表示高斯噪声的标准差)。在测试阶段,计算出高斯噪声下干净像素的后验分布均值,

$$p(y|x)p(x|\Omega_y) = f(x; y, \sigma^2)f(x; u_x, \sigma_x^2), \quad (5)$$

利用第一项高斯分布的对称性对 x 和 y 进行交换,同时由于两项乘积结果是一个非归一化的高斯函数,所以其均值和后验均值相同^[27]。计算结果表示为

$$E_x[p(x|y, \Omega_y)] = \frac{u_x\sigma_x^2 + y\sigma_x^2}{\sigma^2 + \sigma_x^2}. \quad (6)$$

除了良好的噪声建模,合适的训练策略也十分重要,它不仅能够让网络更加稳定和高效,同时可以使模型具有更好的泛化能力。其中,在对优化算法进行选择时,考虑到观测环境中的大气抖动具有非稳态性;观测数据本身包含一定噪声;网络训练使用的 NVST H α 波段图像具有丰富的精细结构等问题,确定 Adam^[28] 作为网络训练的优化算法,因为在深度学习领域,大量的实验结果表明,该优化算法适用于非稳态目标并且针对高噪声问题有较好适用性;对于基于神经网络的大规模参数优化问题也有较好效果^[28];同时,网络在训练过程中计算量会不断地增大而占用大量显存,Adam 算法计算的高效性也能缓解这一问题。

实验环境基于 Windows 10 系统,使用英伟达 TITAN X 显卡、Intel(R)E3-1245 V5 处理器,采用 TensorFlow 1.14 深度学习框架。除网络末端最后一个 1×1 卷积使用线性激活函数外,训练中所有卷积层均使用 $\alpha = 0.1$ 的 Leaky ReLU 激活函数。设置初始学习率 $\lambda = 0.0003$,之后在剩余的 30% 的训练集中使用余弦学习率调整策略对学习率进行降低。输入图像为随机裁剪的 $128 \text{ pixel} \times 128 \text{ pixel}$ 图像,批次大小为 4,对于 2000 幅的仿真含噪训练集迭代次数为 10 万次,训练过程耗时约 3 h;600 幅的实际观测训练集迭代次数为 3 万次,训练过程耗时约 1 h。

4 实验结果及分析


4.1 仿真数据去噪结果分析

使用 NVST 在 2013 年 07 月 15 日 01:15:51 到 02:14:35 时段的 50 幅 H α 波段观测图像作为测试数据,这些图像经过斑点掩模法^[20]进行了重建。对每幅图像进行裁剪得到 50 幅大小为 512 pixel \times 512 pixel 的原始图像;对原始图像添加高斯噪声,得到噪声图像;然后分别使用本文方法、Noise2Void、CBSN 及三种传统的图像去噪方法,即 BM3D 算法^[29]、高斯滤波和均值滤波对噪声图像进行处理得到去噪图像,其中 BM3D 算法使用默认参数,高斯滤波和均值滤波的核大小设置为 5;随机选取 20 组实验数据进行分析。在定量分析中,使用 PSNR 和 SSIM 指标分析噪声水平 $\sigma=10$ 、25、40 下的实验结果;而在相关性分析和功率谱分析中,只对低噪声($\sigma=10$)的情况进行分析,原因是高噪声的图像和原图像会产生很大程度的失真现象,实验分析结果参考性较低,并且在实际观测中这类数据很

可能被丢弃。

4.1.1 定性分析

从 20 组实验结果中随机选取一组,在相同噪声水平下,根据视觉效果对本文方法、Noise2Void、CBSN 及三种传统去噪方法的实验结果进行评估。从图 4 可以看出,本文方法处理得到的去噪图像从视觉效果上看,有着更为清晰的特征结构,基本恢复了潜在的暗条纤维等精细结构;CBSN 的去噪结果虽然也有着较好的视觉效果,但由于缺乏网络自身误差的校正,网络恢复出一部分“伪像”即原始图像中不存在的特征结构,且有少部分精细结构丢失;Noise2Void 去噪结果表现出“棋盘伪影”,部分细节结构边缘被模糊化,其原因是未利用到完整的噪声像素信息;而 BM3D 算法的去噪结果出现明显块状现象,同时由于过平滑丢失了大量细节;高斯滤波和均值滤波由于算法特点出现锯齿现象,影响观测效果。所以从视觉效果方面可以证明,本文方法能够对 NVST 太阳图像进行有效去噪。






图 4 各个方法的去噪结果。(a) 原图；(b) 真值；(c) 噪声干扰；(d) 本文算法；(e) CBSN；(f) Noise2Void；(g) BM3D；(h) 高斯滤波；(i) 均值滤波

Fig. 4 Denoising results of each method. (a) Original images; (b) ground truth; (c) noise interference; (d) proposed algorithm; (e) CBSN; (f) Noise2Void; (g) BM3D; (h) Gaussian filter; (i) mean filter

4.1.2 定量分析

1) PSNR 和 SSIM

PSNR 通过计算去噪图像和原始图像之间的 MSE 来衡量去噪图像的复原程度；SSIM 通过计算去噪图像和原始图像之间的亮度、对比度和结构三个属性信息来衡量两者间的相似度。因此可以使用这两种指标对实验结果进行分析。

从表 1 的 20 组结果的 PSNR 和 SSIM 指标平

均值可以看出,在噪声水平相同时,本文方法因采用贝叶斯推理得到的后验均值作为网络输出,真实值与输出值有着更小误差,获得了更高的指标数值,即相较于 Noise2Void、CBSN 及三种传统的图像去噪方法,本文方法得到的去噪图像与原始图像相比失真度较低、结构相似度较高、图像质量较好。结果表明,本文方法得到了与原始图像更相近的去噪图像。

表 1 各方法 20 组测试图像的平均 PSNR 和 SSIM

Table 1 Average PSNR and SSIM of 20 groups of test images for each method

Noise level	Method	Known σ	Average	
			PSNR	SSIM
$\sigma = 10$	BM3D	Yes	37.66	0.9214
	Gaussian filter	Yes	37.39	0.9192
	Mean filter	No	35.16	0.8501
	Noise2Void	No	38.21	0.9389
	CBSN	No	39.30	0.9471
	Proposed	No	40.14	0.9592
$\sigma = 25$	BM3D	Yes	33.51	0.8094
	Gaussian filter	Yes	33.20	0.8034
	Mean filter	No	31.66	0.6633
	Noise2Void	No	33.75	0.8522
	CBSN	No	34.62	0.8856
	Proposed	No	35.45	0.8914
$\sigma = 40$	BM3D	Yes	32.33	0.7485
	Gaussian filter	Yes	30.97	0.6619
	Mean filter	No	29.33	0.4865
	Noise2Void	No	31.77	0.7962
	CBSN	No	33.02	0.8255
	Proposed	No	33.69	0.8370

2) 相关性分析

相关性可以描述原始图像和去噪图像像素之间的相关性强度。图 5 是在噪声水平 $\sigma=10$ 下的相关性图,以斑点掩模法^[18]重建的 NVST H α 波段图像 I_{Original} 归一化后的像素强度值为横坐标,经过降噪处理后的图像 I_{Denoise} 归一化后的像素值强度为纵坐标。则散点分布拟合的表达式为

$$I_{\text{Denoise}} = k \times I_{\text{Original}} \quad (7)$$

如(7)式所示,当 $k=1$ 时, $I_{\text{Denoise}} = I_{\text{Original}}$, 此时说明原始图像与去噪图像对应的像素强度相等;当 $k \neq 1$ 时,说明原始图像与去噪图像之间的亮度差是原始图像灰度级的倍数,结构误差相差不大。而对于图 5 中分布在斜率为 1 的直线附近的点,距离代表着误差,且越靠近直线,去噪所产生的误差越小。因此利用相关性图中的散点分布紧密程度及其所成的直线斜率可以对实验结果进行误差评估。

从图 5 中可以看出,在相同噪声水平下,本文方法产生的散点相较于 Noise2Void、CBSN 和其他三种传统去噪方法产生的散点,能够在斜率为 1 的直线附近分布更加紧密且均匀,说明本文使用的网络能在特征提取阶段学习到潜在的 H α 波段图像精细的结构,在进行特征恢复时仅存在较小的网络误差,能够较完整地保留更多的细节。结果表明,相比 Noise2Void、CBSN 和其他三种传统图像去噪算法,

经过本文方法处理得到的去噪图像与原始图像有着更高的相关系数,即能够在去噪的同时保留与原始图像更为接近的细节结构信息。

3) 功率谱分析

由于图像的噪声信息在频域中多表现为高频区域信息,所以可以通过观察频域中高频信息变化的剧烈程度来对去噪效果进行评估。据此利用功率谱(PSD)对本文方法、Noise2Void、CBSN 和三种传统图像去噪方法的去噪结果进行分析。首先将归一化处理的去噪图像对应的功率谱图像转换到极坐标上,然后对功率谱值取对数得到功率谱图,以频率及其对应的功率谱值分别作为横坐标和纵坐标,最后得到的结果如图 6 所示。

由图 6 可知,原始图像由于经过斑点掩模法^[20]处理,图像信息完整,存在的噪声水平很低,在图中表现为线段平滑连续,且对应的高频区域功率较小;而添加噪声($\sigma=10$)的图像,中频区域和高频区域功率明显增大,说明原图像的基本结构信息及细节信息被添加的噪声所破坏;CBSN 和 Noise2Void 方法在中频区域表现稍好,然而在高频区域依旧存在较大功率,保证了去噪图像的基本结构但是去噪效果不尽人意;其他三种传统方法的去噪图像相较于噪声图像,高频功率虽然得到了一定程度减小,但是图中的中频区域功率也有明显减小,说明在去噪过




图 5 相关性图。(a)本文算法;(b)CBSN;(c)Noise2Void;(d)BM3D;(e)高斯滤波;(f)均值滤波

Fig. 5 Correlation diagrams. (a) Proposed algorithm; (b) CBSN; (c) Noise2Void; (d) BM3D; (e) Gaussian filter; (f) mean filter

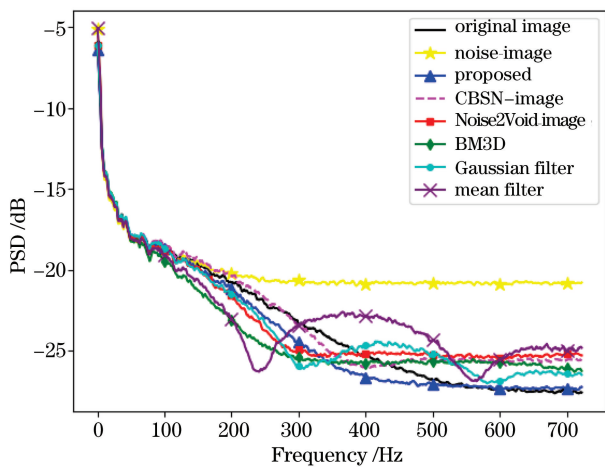


图 6 功率谱图

Fig. 6 Power spectra

程中平滑掉了部分细节结构导致图像信息丢失。而经过本文方法得到的去噪图像,高频区域功率明显减小,说明图像中的噪声得到有效消除,而在中频区域,本文方法由于损失函数中的正则项发挥作用,导

致网络模型以极少的像素信息换取到较高的去噪性能,虽然中频区域功率有所减小,但是相较于 Noise2Void、CBSN 及其他三种传统去噪方法,本文方法最大程度保留了图像中的细节结构信息,在有效去噪的同时提高了图像信噪比。

4.2 真实数据去噪结果分析

为证明本文方法对于真实观测场景的有效性,使用该方法对真实观测数据进行去噪,即采用第 3 节叙述的训练方式和策略,使用实际观测的 NVST $H\alpha$ 波段图像对网络进行训练。

测试数据使用 NVST 在 2014 年 2 月 2 日 01:35:42 到 02:37:26 时段的太阳 $H\alpha$ 波段实际观测图像,随机截取 10 幅 $128 \text{ pixel} \times 128 \text{ pixel}$ 的局部图。分别使用本文方法、Noise2Void、CBSN 和三种传统图像去噪方法对截取的实时观测图像进行去噪,其中使用噪声水平估计网络^[26]的输出结果作为噪声水平,三种传统方法的参数与 4.1 节保持一致。在测试结果中随机选取三组结果进行对比分析,结果如图 7 所示。




图 7 真实太阳图像去噪结果。(a)真实图；(b)本文算法；(c) CBSN；(d) Noise2Void；(e) BM3D；(f)高斯滤波；(g)均值滤波

Fig. 7 Denoising results of real sun image. (a) Real images; (b)proposed algorithm; (c) CBSN; (d) Noise2Void; (e) BM3D; (f) Gaussian filter; (g) mean filter

由图 7 可知,3 组实际观测图像包含了丰富的太阳纹理信息,但由于受到噪声污染,一些细节不够清晰。例如,图 7 第一组中,多条太阳纤维被噪声干扰后无法明确辨别其形态,对观测研究造成影响。经过本文方法处理,噪声得到了一定程度的消除,边缘细节得到恢复,视觉效果也有了明显提升;CBSN 算法的去噪结果基本恢复了边缘结构,视觉效果也有较好提升,但是还能明显看到部分噪声;Noise2Void 算法去噪后的图像,噪声得到抑制,且有一定的视觉效果,但是图像中部分纤维边缘被模糊化;而其他三种传统方法的结果虽然也有一定视觉效果,但由于处理的过平滑,导致部分精细结构丢失。结果表明,相较于 Noise2Void、CBSN 及三种传统图像去噪方法,本文方法在消除噪声的同时有效保留了 H α 波段图像中暗条纤维等精细结构信息。同时,这也表明了使用小数据集训练的本文方法,能够较好地学习到噪声中潜在的细节信息,实现对 NVST 图像的有效去噪。

5 结 论

在太阳物理研究领域,图像噪声严重干扰了天文研究学者对太阳结构和活动的观测,简单的长曝光去噪方式在某些场景下并不适用,非深度学习的去噪方法计算复杂且人工成本高,而基于深度学习标准监督方法对干净数据依赖度较高。针对这些问题,本文将基于自监督深度学习的方法应用于 NVST 图像去噪。通过卷积盲点网络和贝叶斯推理的有效结合,对 NVST 观测的 H α 波段太阳图像进行去噪。仿真数据实验结果表明,相对于 Noise2Void、CBSN 及传统的三种图像去噪方法,本文方法能够有效去除图像噪声,提升图像的视觉效果;定量分析中,PSNR 和 SSIM 评价指标证明了本文方法相对于 Noise2Void、CBSN 及传统的三种去噪方法得到的去噪图像,能够与原始图像之间具有更小的信息误差和更高的结构相似度;相关性分析结果表明,本文方法得到的去噪图像与原始图像之间具有更高的相关系数;功率谱分析证明,本文方法能够在去噪的同时保留图像中较为丰富的精细结构信息。尽管本文方法在客观评价标准中取得较明显的优势,但是不难看出,针对实际观测的噪声图像,本文方法虽然有一定去噪效果但具有局限性,原因是真实噪声的组成和形式都十分复杂,本文所构建的噪声模型不够泛化,因此未来的工作将会在噪声建模上展开,使得本文方法具有更加广泛的实用性。

参 考 文 献

- [1] Birney D S, Gonzalez G, Oesper D. *Observational astronomy* [M]. Cambridge: Cambridge University Press, 2006:1-15.
- [2] Livi S, Wang J, Martin S F. The cancellation of magnetic flux. I. on the quiet Sun [J]. *Australian Journal of Physics*, 1985, 38(6): 855-874.
- [3] Chae J, Martin S F, Yun H S, et al. Small magnetic bipoles emerging in a filament channel [J]. *The Astrophysical Journal*, 2008, 548(1): 497.
- [4] Schrijver J, Title M, et al. Sustaining the quiet photospheric network: the balance of flux emergence, fragmentation, merging, and cancellation [J]. *The Astrophysical Journal*, 2009, 487(1): 424-436.
- [5] DeForest C E. Noise-gating to clean astrophysical image data [J]. *The Astrophysical Journal Letters*, 2017, 838(2): 155.
- [6] LeCun Y, Bengio Y, Hinton G. Deep learning [J]. *Nature*, 2015, 521(7553): 436-444.
- [7] Zhou W J, Zou S, He DK, et al. Spectral convolution neural network is used to realize speckle reduction of holograms [J]. *Acta Optica Sinica*, 2020, 40 (5): 0509001.
周文静, 邹帅, 何登科, 等. 频谱卷积神经网络实现全息图散斑降噪 [J]. *光学学报*, 2020, 40(5): 0509001.
- [8] Nishizuka N, Sugiura K, Kubo Y, et al. Solarflare prediction model with three machine-learning algorithms using ultraviolet brightening and vector magnetograms [J]. *The Astrophysical Journal Letters*, 2017, 835(2): 156.
- [9] Illarionov E A, Tlatov A G. Segmentation of coronal holes in solar disc images with a convolutional neural network [J]. *Monthly Notices of the Royal Astronomical Society*, 2018, 481(4): 5014-5021.
- [10] Ramos A A, Baso C D. Stokes inversion based on convolutional neural networks [J]. *Astronomy & Astrophysics*, 2019, 626: A102.
- [11] Park E, Moon Y J, Lim D, et al. De-noising SDO/HMI solar magnetograms by image translation method based on deep learning [J]. *The Astrophysical Journal Letters*, 2020, 891(1): L4.
- [12] Radford A, Metz L, Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks [EB/OL]. (2016-01-07) [2020-08-01]. <https://arxiv.org/abs/1511.06434>.
- [13] Lucas J, Calef B, Kyono T. Recovering astronomical images with deep neural network supported

- bispectrum processing [C] // The Advanced Maui Optical and Space Surveillance Technologies Conference, 2018.
- [14] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation [C] // Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015, 2015: 234-241.
- [15] Hinge A, Garg P, Goveas N. Image processing for UAV using deep convolutional encoder - decoder networks with symmetric skip connections on a system on chip (SoC) [M]. Singapore: Springer Singapore, 2019: 1009-1015.
- [16] Zhou H H, Yi W N, Du L L, et al. Convolutional neural network-based dimensionality reduction method for image feature descriptors extracted using scale-invariant feature transform [J]. *Laser & Optoelectronics Progress*, 2019, 56(14): 141008.
周宏浩, 易维宁, 杜丽丽, 等. 基于卷积神经网络的 SIFT 特征描述子降维方法 [J]. *激光与光电子学进展*, 2019, 56(14): 141008.
- [17] Ehret T, Davy A, Morel J M, et al. Model-blind video denoising via frame-to-frame training [C] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 11361-11370.
- [18] Krull A, Buchholz T O, Jug F. Noise2Void - learning denoising from single noisy images [C] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 2124-2132.
- [19] Laine S, Karras T, Lehtinen J, et al. Self-supervised deep image denoising [C] // Advances in Neural Information Processing Systems 32 (NIPS 2019), 2019. 6970-6980.
- [20] Liu Z, Qiu Y H, Lou K, et al. Phase recovery methods in speckle masking and image reconstruction experiment [J]. *Acta Optica Sinica*, 1999, 19(7): 935-940.
刘忠, 邱耀辉, 楼柯, 等. 斑点掩模法中的相位复原实施方法和像复原实验 [J]. *光学学报*, 1999, 19(7): 935-940.
- [21] Liu Z, Xu J, Gu B Z, et al. New vacuum solar telescope and observations with high resolution [J]. *Research in Astronomy and Astrophysics*, 2014, 14(6): 705-718.
- [22] He W J. Noise analysis and image processing of CMOS image sensor [D]. Wuhan: Huazhong University of Science and Technology, 2011: 5-7.
和文娟. CMOS 图像传感器的噪声分析及图像处理 [D]. 武汉: 华中科技大学, 2011: 5-7.
- [23] Xu S L, Zou S L, Han Y C, et al. Ionizing radiation response uniformity of solid-state image sensors [J]. *Acta Optica Sinica*, 2019, 39(7): 0728007.
徐守龙, 邹树梁, 韩永超, 等. 固态图像传感器的电离辐射响应均匀性 [J]. *光学学报*, 2019, 39(7): 0728007.
- [24] Oord A V D, Kalchbrenner N, Kavukcuoglu K. Pixel recurrent neural networks [EB/OL]. (2016-08-19) [2020-08-01]. <https://arxiv.org/abs/1601.06759>.
- [25] Papageorgiou G, Bouboulis P, Theodoridis S. Robust nonlinear regression: a greedy approach employing kernels with application to image denoising [J]. *IEEE Transactions on Signal Processing*, 2017, 65(16): 4309-4323.
- [26] Guo S, Yan Z F, Zhang K, et al. Toward convolutional blind denoising of real photographs [C] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 1712-1722.
- [27] Bromiley P A. Products and convolutions of Gaussian distributions [EB/OL]. (2013-09-11) [2020-08-12]. http://129.173.120.78/~kreplak/wordpress/wp-content/uploads/2010/12/gaussians_convolution_lecture3.pdf.
- [28] Kingma D P, Ba J. Adam: a method for stochastic optimization [EB/OL]. (2017-01-30) [2020-08-12]. <https://arxiv.org/abs/1412.6980>.
- [29] Dabov K, Foi A, Katkovnik V, et al. Image denoising by sparse 3D transform-domain collaborative filtering [J]. *IEEE Transactions on Image Processing*, 2007, 16(8): 2080-2095.