

# 基于神经网络的全天时天文导航图像去噪方法

刘宇宸\*, 赵春晖, 徐卿

中国空间技术研究院北京控制工程研究所, 北京 100190

**摘要** 全天时天文导航图像是在大气层内白天的条件下拍摄,因此图像具有强背景,低信噪比等特点,传统星点提取算法对图像星点的提取效果较差。为提高星点识别率,提出一种较准确的全天时天文导航图像模拟方法,并基于模拟星图训练了一种可加入图像降采样结构的卷积神经网络,有效抑制了星图噪声,并提高了星点信噪比。实验结果表明:本文方法得到的峰值信噪比平均提高了 11.28 dB;在效果相同的条件下,本文方法的平均处理时间仅为 0.2 s,远少于传统神经网络方法的处理时间。利用真实星图对网络进行测试,发现本文方法对星点信噪比的提升效果较常用算法提升了 88.9 倍。

**关键词** 图像处理;卷积神经网络;全天时星敏传感器;残差网络;降采样层;星图模拟;噪声抑制

中图分类号 TP183; TN215

文献标识码 A

doi: 10.3788/AOS201939.0610003

## Neural Network-Based Noise Suppression Algorithm for Star Images Captured During Daylight Hours

Liu Yuchen\*, Zhao Chunhui, Xu Qing

Beijing Institute of Control Engineering, China Academy of Space Technology, Beijing 100190, China

**Abstract** Typically, star images captured in the atmosphere during daylight hours have a strong background and low signal-to-noise ratio (SNR), which makes it difficult for traditional algorithms to extract the star from the images. To improve the recognition rate, we propose an accurate method for simulating star images and train a deep convolutional neural network with a downsampling layer using the simulated images. The trained network can denoise and enhance the star images. Experimental results demonstrate that the proposed method improves the peak SNR by 11.28 dB within an average runtime of 0.2 s, which is significantly less than that of a traditional neural network. In addition, we test the proposed method on the trained network using real star images and find that the improved SNR is 88.9 times greater than that of the existing methods.

**Key words** image processing; convolutional neural network; star sensor used during daylight hours; residual network; down-sampling layer; star-image simulation; noise suppression

**OCIS codes** 100.2000; 100.2980; 100.4996

## 1 引 言

星敏传感器是目前自主定姿定位精度最高的星载姿态敏感器,目前国内星敏传感器的研究已比较完备,已经能够提供角秒级甚至亚角秒级的姿态测量精度,远远高于惯性导航等姿态敏感器。随着控制技术的提高,飞机、导弹甚至舰船平台对于姿态测量的精度需求也大幅提升,研究人员开始进行全天时星敏传感器的研发<sup>[1]</sup>,基于天文惯性组合导航<sup>[2]</sup>的方式实现大气内高精度全天时自主导

航。目前,图像噪声抑制技术是全天时星敏传感器研发的关键技术。

白天观星图像的主要特点是背景强、目标能量弱、噪声方差大且种类多,此类噪声主要包括光子散粒噪声、像元响应不一致噪声<sup>[3]</sup>、条纹噪声及单点噪声。受此影响,白天观星图像的信噪比明显低于传统星图,因此噪声抑制算法的引入必不可少。国内外很多学者提出了多种抑制星图噪声强度的方法,主要包括调整电荷积累占空比<sup>[4]</sup>、多帧叠加法<sup>[5-6]</sup>、单点及条纹噪声补偿法<sup>[7-8]</sup>、偏振成

收稿日期: 2019-01-18; 修回日期: 2019-02-25; 录用日期: 2019-03-12

基金项目: 国家重大仪器设备开发专项(2013YQ310799)

\* E-mail: lyc133@163.com

像<sup>[9]</sup>等。但上述方法存在的问题主要包括:应用条件过于理想化,如假设相机在连续多帧曝光过程中姿态保持不变,实际中无法避免震动;仅补偿了其中部分种类噪声,且在去噪的同时抑制了星点能量,导致信噪比提升效果不明显。

近年来,基于卷积神经网络图像重建类方法的研究受到广泛关注。卷积神经网络因为共享权值及卷积计算的特点,适用于图像去噪,能够兼顾噪声抑制和图像细节保护。深度学习方法与传统方法的区别在于深度学习方法无需人为确定特征提取方法,只需提供已知结果的数据集,神经网络就能够自动拟合输入到输出的非线性映射。目前常见的基于卷积神经网络的算法如 DnCNN<sup>[10]</sup>及 TRND<sup>[11]</sup>等网络的数据集都仅添加了高斯噪声及椒盐噪声,不能直接应用于星图去噪,需要基于特定的数据集进行噪声分布特点拟合。同时,利用 ModTran 软件及星点能量计算公式可仿真生成理想星图。通过对主要噪声的建模,可对理想星图进行退化处理,得到模拟星图。因此,本文通过星图模拟技术建立数据集,利用改进的卷积神经网络对全天时天文导航图像去噪进行研究。

表 1 ModTran 软件的输入参数样例

Table 1 Example of input parameters for ModTran software

Latitude season	Mid-latitude summer	Latitude season	Mid-latitude summer
Terrain	Forest	Altitude angle of observation $\mu_1 / (^\circ)$	70
Weather	Sunny	Solar azimuth $\mu_2 / (^\circ)$	90
Altitude $H / \text{km}$	8	Solar elevation $\theta / (^\circ)$	70

根据 ModTran 软件的仿真结果及全天时星敏感器探测器参数,天空背景辐射在探测器单个像元上产生的电荷数为

$$N_b = \frac{\pi D^2}{4} \cdot \frac{S_{\text{pix}}^2}{f^2} \cdot \frac{1}{hc} \cdot \xi \cdot t \cdot \tau \int_{\lambda_{\min}}^{\lambda_{\max}} \psi(H, \lambda_{\min}, \lambda_{\max}, \mu_1, \mu_2, \theta) \cdot Q \cdot \lambda d\lambda, \quad (1)$$

式中: $D$ 为星敏感器光学系统有效孔径; $f$ 为焦距; $\tau$ 为光学系统透过率; $S_{\text{pix}}$ 为探测器像元尺寸; $\xi$ 为像元填充因子; $Q$ 为探测器平均量子效率; $t$ 为积分时间; $h$ 为普朗克常数; $c$ 为光速; $\lambda_{\max}$ 和 $\lambda_{\min}$ 为探测器工作光谱上、下限; $\psi$ 为 ModTran 软件的仿真结果,表示单位波长、单位面积、单位时间的辐射能量,对应的单位是  $\text{W}/\text{m}^3$ 。模拟星图使用的探测器光学系统参数见表 2,其中  $F$  为敏感器视场大小, $N_x$ 、 $N_y$  为敏感器图像分辨率, $d_w$  为满阱电荷量,单位为电子电荷量  $e$ , $n$  为弥散因子, $\sigma_{\text{PRNU}}$  为像元

## 2 全天时星敏感器噪声建模及星图模拟技术

利用已知的全天时星敏感器噪声模型、ModTran 软件仿真生成的大气辐照度模型、星点能量计算公式及全天时星敏感器参数等仿真生成模拟星图。

### 2.1 噪声模型

探测器工作谱段为  $800 \sim 1100 \text{ nm}$ ,通过对探测器的分析可知,星图中的主要噪声有两种:天空背景辐射产生的散粒噪声及探测器响应不一致引起的噪声。光子噪声符合泊松分布,其参数  $\lambda_b = \sqrt{N_b}$ ,  $N_b$  为探测器像元产生的理论背景辐射电荷数。像元响应不一致所引起的噪声是乘性噪声,系数符合高斯分布,均值为 0,标准差与探测器参数相关。

### 2.2 背景辐照度仿真

利用 ModTran 软件能够计算对应输入条件的大气辐照度,由于神经网络训练需要的样本数量大,且涵盖各类情况,因此基于多组输入参数生成了多组数据,其中输入变量包括季节、观测高度  $H$ 、太阳方位角  $\mu_1$ 、观测高度角  $\mu_2$  以及太阳高度角  $\theta$  等。表 1 是一组模拟的输入参数。

响应不一致参数,  $I_{\min}$  和  $I_{\max}$  为灰度转换上、下限。利用(1)式计算出电荷数,对应相面坐标为  $(i, j)$  的灰度值  $I(i, j)$  为

$$I(i, j) = N_b(i, j) / d_w \cdot (I_{\max} - I_{\min}) + I_{\min}. \quad (2)$$

表 2 探测器光学系统参数

Table 2 Optical-system parameters of detector

Parameter	Value	Parameter	Value
$F / (^\circ)$	2	$N_x \times N_y / (\text{pixel} \times \text{pixel})$	$512 \times 512$
$S_{\text{pix}} / \mu\text{m}$	11	$f / \text{mm}$	161.1
$D / \text{mm}$	41	$\tau$	0.80
$\zeta$	0.75	$Q$	0.40
$d_w$	$120000e$	$\sigma_{\text{PRNU}}^2$	0.0001
$t / \text{ms}$	10	$n$	3
$\lambda_{\min} / \text{nm}$	800	$I_{\min}$	400
$\lambda_{\max} / \text{nm}$	1100	$I_{\max}$	3600

### 2.3 背景灰度渐变现象

通过对多幅观星图像的研究可知,星图的背景存在灰度渐变现象,产生这一现象的因素可能是观测方向与太阳照射方向的夹角或观测高度角的渐变。根

据表 3 中的不同输入参数,利用 ModTran 软件进行多次仿真,结果如图 1。实验证明星图背景灰度渐变现象只与太阳方位角  $\mu_1$  有关,并基于该曲线生成不同太阳方位角下的模拟星图背景且模拟灰度渐变现象。

表 3 ModTran 软件的输入参数

Table 3 Input parameters of ModTran software

Latitude season	Mid-latitude summer	Latitude season	Mid-latitude summer
Terrain	Forest	Altitude angle of observation $\mu_1 / (^\circ)$	50-90
Weather	Sunny	Solar azimuth $\mu_2 / (^\circ)$	55-150
Altitude $H / \text{km}$	8	Solar elevation $\theta / (^\circ)$	70

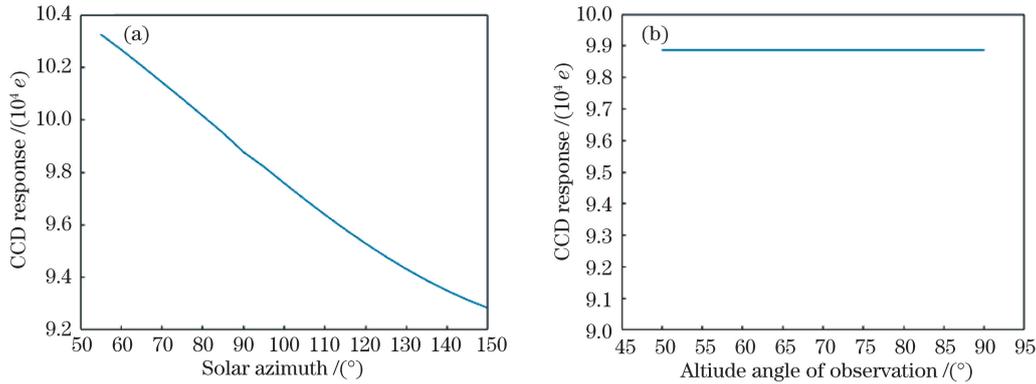


图 1 像元响应与不同输入变量的关系。(a)与太阳方位角关系;(b)与观测高度角关系

Fig. 1 Relationship between pixel response and different input parameters. (a) Solar azimuth; (b) altitude angle of observation

### 2.4 星点能量计算公式

基于标定系数法,根据恒星星等  $m_v$  及色温  $T$  计算星点能量。恒星的光谱辐射分布可采用普朗克黑体辐射定律描述。当恒星星温为  $T$  时,波长  $\lambda$  处的辐射能量计算公式为

$$E_s(\lambda, T) = \frac{2\pi hc^2}{\lambda^5 [\exp(hc/\lambda k_B T) - 1]}, \quad (3)$$

式中: $k_B$  为玻尔兹曼常数。(3)式计算出的结果为单位面积、单位时间、单位波长变化的恒星辐射能量 ( $\text{W}/\text{m}^3$ )。

黑体辐射定律描述恒星辐射的相对光谱分布,其绝对光谱与相对光谱及恒星星温相关。其计算公式为

$$\varphi(m_v, T) = k(m_v, T) \cdot E_s(\lambda, T), \quad (4)$$

式中: $k(m_v, T)$  为标定系数,与星等及色温相关。

标定系数的计算方法如下:相同视星等、不同色温的恒星在可见光谱段内的辐射光子通量相同, $m_v$  等星在可见光谱段的辐射光子通量为

$$E_{m_v} = \int_{0.38 \times 10^{-6}}^{0.78 \times 10^{-6}} k(m_v, T) \cdot \frac{2\pi hc^2}{\lambda^5 [\exp(hc/\lambda k_B T) - 1]} d\lambda. \quad (5)$$

不同视星等的光子通量满足

$$E_m = E_n \cdot 2.512^{-(m-n)}, \quad (6)$$

式中: $m, n$  分别为两颗恒星的视星等。根据(5)式,标定系数可表示为

$$k(m_v, T) = \frac{E_0 \cdot 2.512^{-m_v}}{\int_{0.38 \times 10^{-6}}^{0.78 \times 10^{-6}} k(m_v, T) \cdot \frac{2\pi hc^2}{\lambda^5 [\exp(hc/\lambda k_B T) - 1]} d\lambda}, \quad (7)$$

式中: $E_0$  为大气层外零等星可见光谱范围内的辐射出射度。根据可见光范围内太阳常数  $687 \text{ W}/\text{m}^2$ , 及太阳的视星等  $-26.74$  计算出  $E_0 = 1.38 \times 10^{-8} \text{ W}/\text{m}^2$ 。利用(3)式的结果,得到星点在对应像元上的响应电荷量  $N_s$  为

$$N_s = \frac{\pi D^2}{4} \cdot \frac{S_{\text{pix}}^2}{f^2} \cdot \frac{1}{hc} \cdot \xi \cdot t \cdot \tau \int_{\lambda_{\text{min}}}^{\lambda_{\text{max}}} E_s(\lambda, T) \cdot Q \cdot \lambda d\lambda. \quad (8)$$

根据光学系统弥散因子将星点弥散到多个像元中。

## 3 降采样卷积神经网络结构设计

### 3.1 网络结构

网络结构设计如图 2 所示,其中 Conv 是卷积

层, BN 为批归一化层<sup>[12]</sup>, RELU 为线性整流单元, 其中输入层和输出层不添加批归一化层。在具体结构及映射关系中,  $i$  表示网络的对应层数,  $j$  表示中间层中对应的子层数,  $W_i, b_i$  分别为对应层的权重及偏置 ( $i=1$  或  $i=5$ ),  $*$  为卷积运算,  $W_{i,j}, b_{i,j}$  为对应中间层的对应子层权重和偏置 ( $2 \leq i \leq 4, 1 \leq j \leq 2$ ), 网络卷积核尺寸均为  $3 \times 3$ , 特征图数量

为 32,  $f_d, f_u$  分别为降采样及升采样运算符, 每层可表示为

$$F_1(x) = \max[0, W_1 * f_d(x) + b_1], \quad (9)$$

$$F_i(x) = F_{i-1}(x) + \max\{0, W_{i,2} * \max[0, W_{i,1} * F_{i-1}(x) + b_{i,1}] + b_{i,2}\}, \quad (10)$$

$$F_5(x) = f_u[W_5 * F_4(x) + b_5]. \quad (11)$$

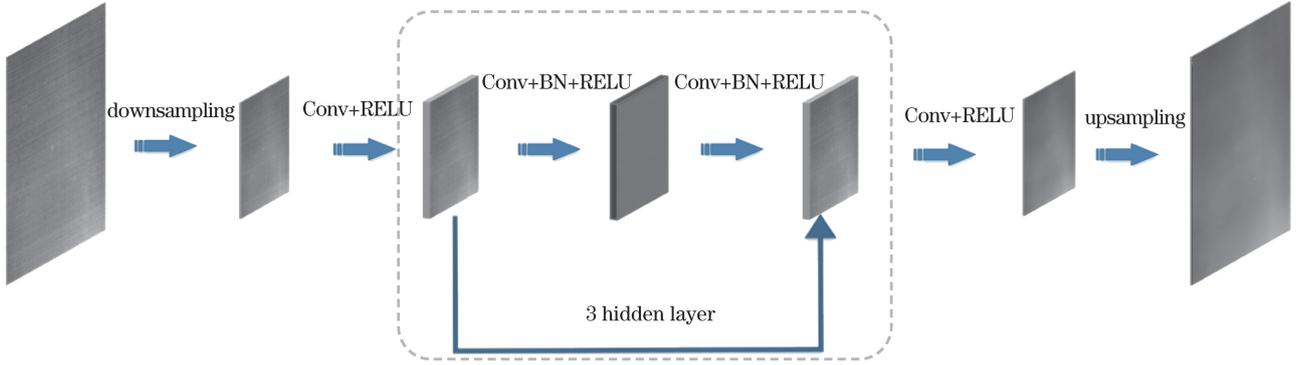


图 2 网络结构示意图

Fig. 2 Schematic of network structure

### 3.2 残差网络结构设计

当神经网络最终拟合的映射为零时, 可以避免网络出现退化, 且能够提高网络收敛速度及拟合精度<sup>[13]</sup>。该方法的思想同样被应用到去噪神经网络中, 噪声图像可被认为是原始图像及噪声分量的叠加

$$F(x) = x - H(x), \quad (12)$$

式中:  $H(x)$  为图像噪声;  $x$  为加噪图像;  $F(x)$  为目标图像。

图 3 显示了目前常见的两种残差网络的结构: 全局跳线结构及局部跳线结构。

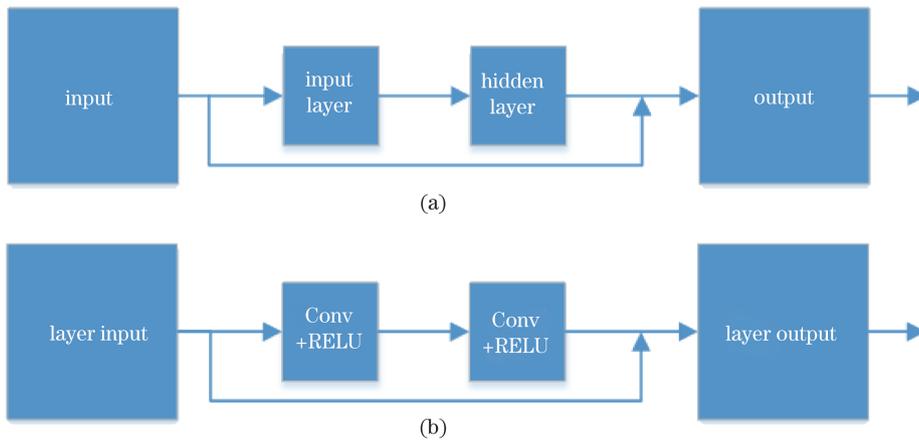


图 3 不同网络跳线结构简图。(a) 全局跳线网络结构; (b) 局部跳线的结构

Fig. 3 Structural diagrams of different network shortcut connections.

(a) Overall shortcut; (b) local shortcut

图 4 所示为不同跳线结构的网络收敛曲线。由图 4 可知, 在其他网络参数相同的条件下, 局部跳线网络的精度略高于全局跳线网络, 且训练过程中网络误差振荡幅度相对较小。

### 3.3 降采样及升采样层

去噪算法的核心思想是基于对应像素的邻域像

元进行噪声综合分析, 并预测当前像元噪声分量强度。算法感知域是重要参数之一, 综合各经典算法的参数分析, 算法的感知域在 35 到 61 之间最佳, 而一个正常的  $3 \times 3$  像元尺寸, 卷积核的标准卷积神经网络的感知域要达到最佳感知域至少需要 17 层。星图中细节较少, 网络深度的需求量小, 由于图像受

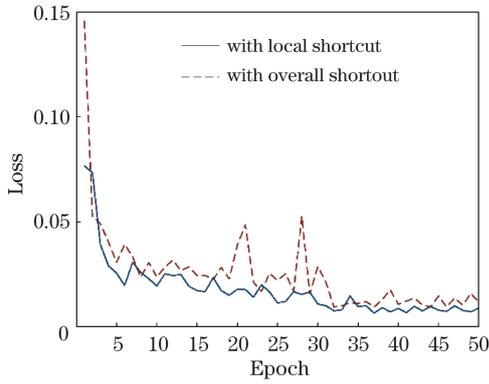


图 4 不同跳线结构的网络收敛曲线

Fig. 4 Convergence curves of network with different types of shortcut connection

到云层干扰,对感知域的需求无法降低。

受到图像金字塔处理思想的启发,引入了降采样层和升采样层,在感知域不变的条件下,降低网络层数,同时将降采样后的图像堆叠,保留图像的全部信息。降采样运算可表示为

$$f_d(I_o)(i, j, k) =$$

$$I_o[2i - 1 + k/2, 2j - 1 + (k \bmod 2)]. \quad (13)$$

式中:mod 为取余数计算; $k$  为对应的堆叠厚度( $1 \leq k \leq 4$ ); $I_o$  为原始图像。升采样运算为降采样的逆运算。根据 Shi 等<sup>[14]</sup>的研究,降采样层的引入能够提升卷积神经网络的效率,且能提取更深层次图像的特征信息。对比加入降采样层或加入空洞卷积<sup>[15]</sup>(dilated convolution)的卷积神经网络与传统卷积神经网络在相同深度条件下的训练效果,结果如图 5 所示。由于感受域较大,前两者最终训练误差显著小于传统卷积神经网络的训练误差。

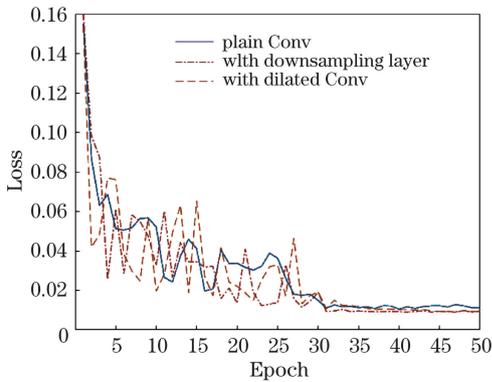


图 5 具有不同功能结构的网络收敛曲线

Fig. 5 Convergence curves of network with different functional structures

表 4 是各网络处理  $512 \text{ pixel} \times 512 \text{ pixel}$  分辨率图像的处理时间统计结果,其中  $t_{\text{GPU}}$  和  $t_{\text{CPU}}$  分别表示算法在 GPU 和 CPU 中的计算时间。由表 4

可知:各网络在 GPU 中的运算时间近似,原因是在网络层数、网络参数量相同及显存足够的情况下,网络处理不同分辨率的图像的时间相近;但在 CPU 中引入了降采样层的网络的运算时间是其他两种算法的 25%左右,分析原理可知,加入降采样层后,图像分辨率降低为  $256 \text{ pixel} \times 256 \text{ pixel}$ ,因此计算量相对于其他两种网络降低了 75%。

表 4 不同网络结构的网络计算时间

Table 4 Running time of network with different functional structures

Types of convolutional network	Dilated Conv	Downsampling Conv	Plain Conv
$t_{\text{GPU}}/\text{ms}$	16.21	16.11	16.84
$t_{\text{CPU}}/\text{s}$	0.87	0.22	0.86

## 4 仿真结果与分析

### 4.1 网络训练

考虑去噪算法需要兼顾星点信噪比提升及噪声抑制,样本分为星点局部样本及仿真星图样本两类。考虑到网络训练过程中加入批归一化处理,样本生成以批为单位,每一批中包括 32 个样本。星点局部样本中每一个样本的中心区域都存在星点,其色温固定为 5240 K,星等为 0~3 的随机数,星点位于样本中心  $20 \times 20$  像元的区域内的随机亚像素坐标上,星点进行弥散处理,弥散基于高斯分布,使用 ModTran 软件的仿真结果生成背景,ModTran 软件的输入参数如表 3 所示,共生成  $8000 \times 32$  张训练样本及  $80 \times 32$  张测试样本;仿真星图样本是利用 ModTran 软件仿真结果生成的大尺寸星图,加入了灰度渐变现象,并从中间隔 20 像元提取一个  $40 \times 40$  的局部图像作为样本。本研究共选取  $8000 \times 32$  个训练样本和  $80 \times 32$  个测试样本。

采用均方误差(MSE)表征损失函数,采用小批随机梯度下降法(mini-batch SGD)进行样本训练,学习率初始值为 0.001,在第 31 次迭代降低到 0.0001,在第 49 次迭代降低到 0.000001。训练周期设置为 50 次。

### 4.2 实验结果分析

利用训练好的网络对测试集进行效果测试,对比三维块匹配(BM3D<sup>[16]</sup>)、字典学习法(K-SVD<sup>[17]</sup>)及 DnCNN 网络等去噪算法的效果。其中 K-SVD 是基于稀疏表达的去噪方法;BM3D 通过提取去噪区域邻域小块进行匹配,并将相似区域组合进行类似叠加去噪的操作,最终获得降噪图像;DnCNN 是

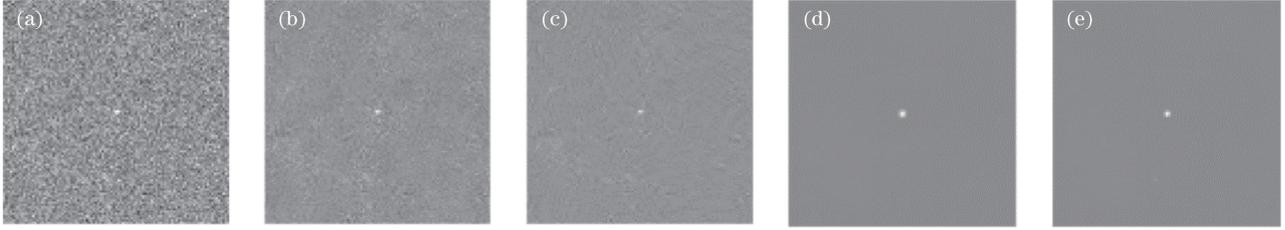


图 6 各方法的处理效果。(a) 原始星图; (b) K-SVD; (c) BM3D; (d) DnCNN; (e) 本文方法

Fig. 6 Processing results of different algorithms. (a) Original star image; (b) K-SVD;

(c) BM3D; (d) DnCNN; (e) proposed method

基于深度卷积神经网络的去噪算法,基于训练集对该网络进行再训练。图 6 是各算法对模拟星图进行去噪处理的结果。

综合图 6 和表 5 可知, BM3D 及 K-SVD 算法能够在一定程度上抑制噪声,但是图像中噪声仍然明显,从 PSNR(峰值信噪比)值也能看出,两者的去噪能力明显弱于神经网络去噪方法。原因在于: K-SVD 算法的效果受到其字典大小及迭代次数的影响,而星图噪声强度随背景强度发生变化,星点强度随机分布,导致没有固定的最佳参数; BM3D 算法提取图像中相似度较高的区域进行噪声强度估计,而星图中纹理细节少,导致相似区域的提取难度较大,去噪效果较差。两种神经网络方法都能够有效抑制噪声,其中 DnCNN 网络为 17 层卷积神经网络,其参数量是加入降采样结构网络的 8 倍,去噪效果提升较少。原因在于星图背景复杂度低,对细节的辨识能力要求低, 8 层的网络已经能够得到接近最优的拟合结果,网络参数的增加无法再显著提升对当前问题的处理能力。

表 5 不同算法的 PSNR 值

Table 5 PSNR of different algorithms

Algorithm	PSNR /dB
Original star image	22.36
K-SVD	25.43
BM3D	26.15
DnCNN	37.42
Proposed algorithm	37.43

在 Intel i7-4770K CPU@3.5 GHz, 24 GB 内存和 Nvidia GTX1070 GPU 平台比较上述算法的处理时间,使用的软件平台为 MATLAB 2017a,测试使用图片的分辨率为 512 pixel×512 pixel,所有算法的平均运行时间见表 6。K-SVD 及 BM3D 算法无法在 GPU 中运行,因此表 6 中不包括上述两种算法的  $t_{GPU}$ 。由表 6 可知, BM3D 及 K-SVD 算法的

处理时间较长,无法实际应用; DnCNN 网络在 GPU 上的运行时间为 45 ms,但是在 CPU 中的处理时间超过 10 s,实际工程中无法提供大容量并行计算能力,因此该方法的实用性较差; 本文方法无论在 GPU 还是 CPU 上的运行速度都显著优于 DnCNN 网络,在 CPU 中的计算能够控制在 0.2 s 左右,有较高的实用价值。

表 6 不同算法处理时间

Table 6 Running time of different algorithms

Algorithm	K-SVD	BM3D	DnCNN	Proposed
$t_{GPU}$ /ms	-	-	45.43	16.84
$t_{CPU}$ /s	1.64	1.84	12.12	0.21

为了检测去噪算法对真实噪声的抑制能力,利用训练完的网络对 1000 张含星点的真实观星图像进行了降噪处理,并选取文献[7]和文献[8]使用的算法进行比较。由于真实星图无法计算 PSNR,利用星点信噪比( $R_{SN}$ )衡量算法的效果。为了方便计算,对降噪后的图像使用 Top-Hat 算法减除背景,结果如表 7 所示。由分析结果可知,文献[7]和文献[8]所用的算法分别采用不同方法对单点噪声及条纹噪声进行补偿,但忽略了背景随机噪声,因此虽然提升了图像质量,但对星点信噪比的提升有限; 本文方法考虑了多种主要噪声,能够显著提升星点信噪比,与文献[8]所用算法相比,提升率高达 88.9 倍。图 7 为含有薄云情况下各方法的处理结果,其中图

表 7 各算法去噪后星点信噪比统计表

Table 7 Statistical  $R_{SN}$  of star points after denoising by different algorithms

Algorithm	$R_{SN}$ /dB
Original image	5.82
Algorithm in Ref. [8]	7.95
Algorithm in Ref. [7]	7.56
Proposed algorithm	195

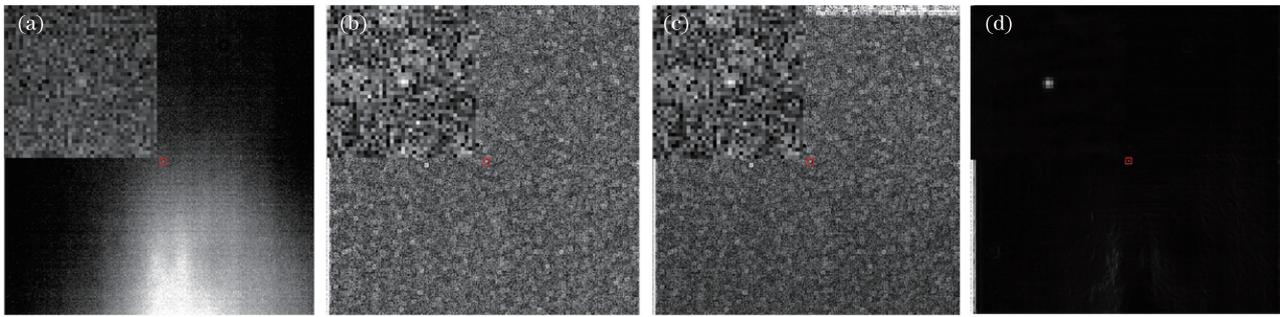


图 7 各算法真实星图的去噪并减除背景后的效果图。(a)原始图像;(b)文献[7]的算法;(c)文献[8]的算法;(d)本文方法

Fig. 7 Renderings of real star image after denoising and subtracting background by different algorithms.

(a) Original image; (b) algorithm in Ref. [7]; (c) algorithm in Ref. [8]; (d) proposed algorithm

像左上角为矩形区域的放大图像。由图 7 可知,仅本文方法可提取图中星点,其他方法受到高亮云区域影响,降噪效果不明显。主要原因在于邻域卷积计算能够充分提取邻域灰度分布特征,区分噪声及细节;列补偿算法基于全局信息,对小区域灰度变化不敏感。

## 5 结 论

利用 ModTran 软件、星点能量计算公式及星图噪声模型,提出一种全天时天文导航图像模拟方法;受到金字塔图像处理方法的启发,基于模拟星图,提出一种降采样卷积神经网络去噪方法,并与传统去噪算法进行对比实验。结果表明:利用模拟星图训练的神经网络,能够快速、有效地抑制星图噪声,提升星点信噪比;与星图去噪领域其他算法相比较,本文方法能够有效抑制云等高亮异物的影响。

## 参 考 文 献

- [1] Fan Q Y, Li X J. Selection of optical-system parameters for an all-day used star sensor[J]. Acta Optica Sinica, 2011, 31(11): 1122001.  
樊巧云, 李小娟. 全天时星敏感器光学系统设计参数选择[J]. 光学学报, 2011, 31(11): 1122001.
- [2] Liu Y, Dai D K, Ma L H, *et al.* A star sensor calibration method based on attitude correlated frame [J]. Acta Optica Sinica, 2017, 37(11): 1128003.  
刘宇, 戴东凯, 马丽衡, 等. 一种基于姿态关联帧的星敏感器标定方法[J]. 光学学报, 2017, 37(11): 1128003.
- [3] Xu Q, Zhao C H, Li X. Stellar radiation modeling and image simulation for airborne daytime star sensor[C]//2016 IEEE International Conference on Signal and Image Processing (ICSIP), August 13-15, 2016, Beijing, China. New York: IEEE, 2016: 630-635.
- [4] Duncan T M. A daylight stellar sensor using a charge-coupled device[J]. Proceedings of SPIE, 1989, 1111: 2-14.
- [5] Jiang P, Sun T F. Infrared star target detection based on maximum energy in daytime[J]. Infrared, 2013, 34(6): 34-38.  
姜鹏, 孙腾飞. 基于最大能量法的白天红外星目标检测[J]. 红外, 2013, 34(6): 34-38.
- [6] Hu X D, Hu Q, Lei X, *et al.* Method of star centroid extraction used in daytime star sensors[J]. Journal of Chinese Inertial Technology, 2014, 22(4): 481-485.  
胡晓东, 胡强, 雷兴, 等. 一种用于白天星敏感器的星点质心提取方法[J]. 中国惯性技术学报, 2014, 22(4): 481-485.
- [7] Wei W, Liu E H. Preprocessing of infrared star map and position accuracy analysis of star point[J]. Infrared and Laser Engineering, 2014, 43(3): 991-996.  
魏伟, 刘恩海. 红外星图预处理及星点定位精度分析[J]. 红外与激光工程, 2014, 43(3): 991-996.
- [8] Wang W J, Wei X G, Li J, *et al.* Noise suppression algorithm of short-wave infrared star image for daytime star sensor[J]. Infrared Physics & Technology, 2017, 85: 382-394.
- [9] Han L, Cai H. Analysis of stargazing capability of star sensors from the atmosphere in daytime[J]. Journal of Spacecraft TT & C Technology, 2015, 34(3): 291-297.  
韩礼, 蔡洪. 白天大气层内星敏感器观星能力分析[J]. 飞行器测控学报, 2015, 34(3): 291-297.
- [10] Zhang K, Zuo W M, Chen Y J, *et al.* Beyond a Gaussian denoiser: residual learning of deep CNN for image denoising [J]. IEEE Transactions on Image Processing, 2017, 26(7): 3142-3155.
- [11] Chen Y J, Pock T. Trainable nonlinear reaction diffusion: a flexible framework for fast and effective image restoration[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6):

- 1256-1272.
- [12] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C]//Proceedings of the 32nd International Conference on International Conference on Machine Learning, July 6-11, 2015, Lille France. Cambridge: JMLR. org, 2015, 37: 448-456.
- [13] He K M, Zhang X Y, Ren S Q, *et al.* Identity mappings in deep residual networks[M] // Leibe B, Matas J, Sebe N, *et al.* Computer Vision-ECCV 2016. Cham: Springer, 2016, 9908: 630-645.
- [14] Shi W Z, Caballero J, Huszár F, *et al.* Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 1874-1883.
- [15] Zhang Y M, Chen T. Efficient inference for fully-connected CRFs with stationarity[C]//2012 IEEE Conference on Computer Vision and Pattern Recognition, June 16-21, 2012, Providence, RI, USA. New York: IEEE, 2012: 582-589.
- [16] Dabov K, Foi A, Katkovnik V, *et al.* Image denoising by sparse 3-D transform-domain collaborative filtering[J]. IEEE Transactions on Image Processing, 2007, 16(8): 2080-2095.
- [17] Aharon M, Elad M, Bruckstein A. K-SVD: an algorithm for designing overcomplete dictionaries for sparse representation[J]. IEEE Transactions on Signal Processing, 2006, 54(11): 4311-4322.