

DOI: 10.7652/xjtuxb201906016

深立井井壁图像的卷积神经网络去噪方法

贾晓芬, 郭永存, 柴华荣, 赵佰亭, 黄友锐

(安徽理工大学省部共建深部煤矿采动响应与灾害防控国家重点实验室, 232001, 安徽淮南)

摘要: 为了实现井壁缺陷的自动检测,提出去除井壁图像噪声的卷积神经网络(CNN)模型(ELU-CNN)。该模型为深28层的全卷积网络模型,由5个特征提取模块(FEM)和跳跃连接组成;跳跃连接将第一卷积层的输出特征与每一个FEM的输出特征串联融合,保证图像特征的充分提取;使用残差学习来缓解梯度消失并提高收敛速度,保证训练后的去噪模型学习到的非线性映射是图像噪声;选用ELU作为激活函数,它具有软饱和性且输出均值接近于零,能增强模型对输入噪声的鲁棒性并加速模型收敛。在标准测试集BSD68、set12及实际井壁图像上,验证ELU-CNN模型的去噪性能并和先进方法作比较,实验结果表明:与FFDNet模型相比,ELU-CNN模型的平均峰值信噪比,在含噪声浓度 σ 为(15,25,35,50,75)的BSD68、set12测试集上分别提高了(0.17,0.11,0.08,0.05,0.03)dB,(0.18,0.16,0.08,0.06,0.07)dB。在去除井壁图像盲噪声时,ELU-CNN模型能更好地保留缺陷的纹理信息。

关键词: 图像去噪;卷积神经网络;井壁图像;深立井

中图分类号: TP391 **文献标志码:** A **文章编号:** 0253-987X(2019)06-0117-08

Denoising Method for Deep Shaft Lining Images Based on Convolution Neural Network

JIA Xiaofen, GUO Yongcun, CHAI Huarong, ZHAO Baiting, HUANG Yourui

(State Key Laboratory of Mining Response and Disaster Prevention and Control in Deep Coal Mines,
Anhui University of Science and Technology, Huainan, Anhui 232001, China)

Abstract: An ELU-CNN image denoising model based on convolution neural network (CNN) is proposed to realize automatic detection of the defects on the shaft lining. It is a 28-layer full-convolution denoising network model and consists of five feature extraction modules (FEMs) and skip connections. The skip connections combine the output features of the first convolution layer with the output features of each FEM to ensure the full extraction of image features. The residual learning is used in the ELU-CNN model to relieve the gradient disappearance problem, to improve the convergence speed, and to ensure that the learned nonlinear mapping from a noisy image by the denoising model after training is a noise image. ELU is used as an activation function. It has soft saturation performance, and the average of its outputs is close to zero. These properties can accelerate the convergence of the model and enhance the robustness of the model to the input noises. The denoising effect of ELU-CNN is verified on the standard test sets BSD68 and set12 as

收稿日期: 2018-12-28。 作者简介: 贾晓芬(1978—),女,副教授,在职博士生;郭永存(通信作者),男,教授,博士生导师。
基金项目: 国家自然科学基金资助项目(61501006);安徽省高校自然科学研究重大资助项目(KJ2018ZD008);国家重点研发计划专项资助项目(2016YFC0600908)。

网络出版时间: 2019-03-22

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1069.T.20190320.1309.002.html>

well as actual shaft wall images, and is compared with those of some advanced methods. The experimental results on BSD68 and set12 with noise concentration $\sigma=(15, 25, 35, 50, 75)$ and comparisons with FFDNet model show that the average of peak signal to noise ratios of ELU-CNN increases (0.17, 0.11, 0.08, 0.05, 0.03) dB and (0.18, 0.16, 0.08, 0.06, 0.07) dB, respectively. ELU-CNN can better preserve the texture information of fractures when removing blind noise from shaft wall images.

Keywords: image denoising; convolution neural network; shaft lining image; deep vertical shaft

我国约有 2.95 万亿吨煤炭资源深埋在 1 km 以下,占煤炭资源总量的 53%^[1]。随着社会经济的不断发展,在 21 世纪的煤炭开采中,我国将有大批矿井转入深部开采^[2]。深井的高温高湿环境加上盐碱水的侵蚀,井筒井壁砟会被慢慢地腐蚀。井壁承受的井筒周围岩浆、泥浆膨胀引起的环压会引起井壁上出现炸裂、鼓包等破损。必须及时检测、修复破损才能有效保证井筒安全,防止井壁破裂的发生。

图像是人类获取、表达和传递信息的重要手段,人类获取的外界信息中,约 75% 来自视觉^[3]。美国哈佛商学院的最新研究数据表明,人的大脑接受的外部信息中约 83% 来自视觉。图像含有丰富的信息,已经成为人类获取知识和数据的重要来源,井壁图像能很好地传递井壁上出现的缺陷信息。图像在采集、形成与传输的过程中,会引入噪声导致图像质量的下降^[4]。复杂的深井环境必然导致获取的井壁图像中含有噪声,要想利用井壁图像实现缺陷的分类、预测,必须先去噪。本文结合井壁图像特点提出一种卷积神经网络(CNN)去噪模型(ELU-CNN)。

1 井壁图像去噪

立井多为钢筋混凝土井壁,井壁图像背景简单,主要包括法兰盘和砟,井壁检测的主要目的是检测砟上出现的裂缝,它是导致井壁破裂的主要因素。井壁裂缝一般有横向、纵向、块状和网状裂缝,表现为连续的线条型,由线段组成,具有一定的方向性。井壁裂缝颜色相对于背景的颜色较深,呈暗色特征,对应的图像像素值较小。深井环境复杂,井壁上的灰尘、腐蚀、高温高湿引起的水雾等因素都会降低图像质量且增加去噪的难度。

利用图像处理检测井壁缺陷的研究较少,没有专门针对井壁图像去噪的方法,但是图像去噪的思路相通、目的一致,只是不同应用领域的图像具备不同特征。好的去噪方法应该具有通用性,可以处理不同背景、不同类型的含噪图像。现有文献中的去噪方法多利用标准图像测试去噪效果,实际图像中

含有的噪声并不单一,难以评估噪声水平和类型,其去噪的难度远高于去除标准图像上加入的已知噪声。因此,结合实际应用设计出具有普适性的去噪方法才是研究的根本。

高斯噪声和椒盐噪声是两种最常见的图像噪声,前者服从高斯分布,严重影响图像质量,受到学者们关注。经典且被广泛认可的去除高斯噪声的方法,例如 BM3D^[5]、WNNM^[6]、CSF^[7] 和 TRND^[8] 等方法均取得了很好的去噪效果,但需要手动修改参数。为了解决上述问题,研究者开始利用 CNN 方法进行图像去噪。例如,Zhang 等提出了 DnCNN 去噪模型,将深层次的网络体系结构、残差学习算法和批量归一化应用到图像去噪中^[9],在此基础上 Zhang 又提出 FFDNet 模型实现盲高斯去噪^[10]; Isogawa 等将软收缩与 deep-CNN 结合,提出了 SC-NN 高斯去噪模型^[11]。

CNN 去噪方法^[9-11]能够有效地利用图像的全局特征,使去噪效果得到明显提高,但随着网络深度的加深,CNN 方法提取的特征越来越高级,会逐层丢失大量的低级特征。CNN 的层越低提取的低级特征越原始,例如颜色和边缘线条等;高层提取的则是纹理细节等高级特征。为了更好地提取井壁图像中组成裂缝的线条及呈现裂缝开裂程度的纹理特征,本文利用跳跃连接将低级特征传递到高层与高级特征合并,提出了 ELU-CNN 井壁图像去噪模型。

2 ELU-CNN 去噪模型

2.1 模型结构

为了有效去除井壁图像含有的噪声,使用 5 个特征提取模块(FEM)、跳跃连接和残差学习,设计了图 1 所示的 ELU-CNN 去噪模型。图 1 中 $\mathbf{X}$ 、 $\mathbf{I}$ 和 $\hat{\mathbf{Y}}$ 分别表示输入的含噪图像、估计的噪声图像和估计的干净图像。 $\mathbf{L}_j$ 为第 j 个卷积层的输出, $j=1,2,\dots,28$; $\mathbf{F}_{kl}$ 、 $\mathbf{F}_{k0}$ 为第 k 个特征提取模块的输入和输出, $k=1,2,\dots,5$ 。ELU-CNN 模型的深度为 28 层,最后一个卷积层仅用一个大小为 3×3 的滤




图 1 ELU-CNN 去噪模型

波器且不连接激活层,其余卷积层均使用 64 个大小为 3×3 的滤波器且连接激活层。在每个卷积层之前均执行零填充,以确保输出图像的大小与输入一致。在网络模型中,引入跳跃连接,将第一个卷积层的输出连接到每一个特征提取模块的输出,使第一层提取的低级特征不断与高层提取的高级特征串联融合,保证图像特征的充分提取。引入残差学习思想,使得去噪模型通过端到端的学习获得含噪图像中的噪声信息 Γ 。

2.2 特征提取模块

井壁图像中的噪声无法准确衡量,应用 ELU-CNN 模型实现去噪的关键是充分提取井壁图像中的各种特征信息并传递到模型的输出端。受稠密连接^[12]的启发,设计了特征提取模块,它能充分利用网络的不同卷积层提取的不同特征信息。FEM 模块中包含 5 个卷积层和 4 个激活层,激活层的激活函数为 ELU。每个 FEM 的输出由其第 1、3、5 共 3 个卷积层的输出及 ELU-CNN 模型的第 1 个卷积层的输出串联融合而成。

常用的激活函数有 sigmoid^[13]、tanh^[14] 和 ReLU^[15] 等,其中 ReLU 函数的应用最广泛。ELU^[16] 是改进型的 ReLU 函数,如图 2 所示,超参数 α 取 0.5,ELU 融合了 sigmoid 和 ReLU 函数的特性,右

侧线性部分能够缓解梯度消失,左侧软饱和和性能使其对输入噪声更具鲁棒性。ELU 的输出均值接近于零,收敛速度会更快。

2.3 数学模型

假设图像中的噪声模型为 $X=Y+n$,其中 X,Y 分别是含噪图像和干净图像, n 是标准方差为 σ 的高斯噪声。使用训练集 $\{X_i,Y_i\}_{i=1}^N$ 训练 ELU-CNN 去噪模型的目的是建立 X 和 Y 之间的非线性映射,学习去噪模型的输入端输入的含噪图像中的噪声特征。以最小化实际干净图像和理想干净图像的差值为目标,定义损失函数为

$$L(\omega,b) = \arg \min_{\omega,b} \frac{1}{2N} \sum_{i=1}^N \|Y_i - \hat{Y}_i\|^2 \quad (1)$$

式中: ω 和 b 分别是权重矩阵和偏置; X_i,Y_i 和 $\hat{Y}_i$ 分别是噪声图像、其对应的理想干净图像和估计的干净图像。

图 1 所示 ELU-CNN 的数学模型如下,其中第 1 个卷积层的输出为

$$L_1 = \sum_{d=1}^{64} \omega_{3 \times 3}^1 * X + b^1 \quad (2)$$

式中: $\omega_{3 \times 3}^1$ 表示第 1 个卷积层的 ω 的大小为 3×3 ,即 ω 的上、下标分别表示其所在的层及所在层的滤波器大小, b^1 的上标表示其所在的层; d 表示输入通道的个数,即滤波器的个数。第 1 个特征提取模块的输入为

$$F_{11} = \text{ELU}(L_1) = \begin{cases} L_1, & \sum_{j=1}^9 \omega_j x_j > 0 \\ \alpha(e^{L_1} - 1), & \sum_{j=1}^9 \omega_j x_j \leq 0 \end{cases} \quad (3)$$

式中:ELU()是激活函数,超参数 $\alpha > 0$; x_j 和 ω_j 分




图 2 ReLU 与 ELU 函数

别表示式(2)中计算 L_1 时局部感受野(3×3 滤波窗口)内的图像像素值和对应的权重系数。第2个特征提取模块的输入为

$$F_{21} = \text{ELU}(F_{10}) \quad (4)$$

$$L_7 = \sum_{d=1}^{64} \omega_{3 \times 3}^7 * F_{21} + b^7 \quad (5)$$

$$L_9 = \sum_{d=1}^{64} \omega_{3 \times 3}^9 * \text{ELU}\left(\sum_{d=1}^{64} \omega_{3 \times 3}^8 * \text{ELU}(L_7) + b^8\right) + b^9 \quad (6)$$

$$L_{11} = \sum_{d=1}^{64} \omega_{3 \times 3}^{11} * \text{ELU}\left(\sum_{d=1}^{64} \omega_{3 \times 3}^{10} * \text{ELU}(L_9) + b^{10}\right) + b^{11} \quad (7)$$

$$F_{20} = \text{concat}[L_7, L_9, L_{11}, L_1] \quad (8)$$

式中:concat[]表示串联融合。第3个特征提取模块的输入为

$$F_{31} = \text{ELU}(F_{20}) \quad (9)$$

$$L_{27} = \sum_{d=1}^{64} \omega_{3 \times 3}^{27} * \text{ELU}(F_{30}) + b^{27} \quad (10)$$

$$\Gamma = L_{28} = \omega_{3 \times 3}^{28} * \text{ELU}(L_{27}) + b^{28} \quad (11)$$

ELU-CNN 模型获得式(11)的噪声信息 Γ 后,

即可得到估计的干净图像 $\hat{Y} = X - \Gamma$ 。

3 仿真实验

3.1 数据集和模型训练

为了验证模型的去噪效果,训练 ELU-CNN 和 ELU-CNNB 两个模型,分别实现在标准图像上去除已知浓度的高斯噪声和对实际图像的盲去噪。选用 400 幅 180×180 像素的灰度图像构造训练集。通过对 400 幅图像进行随机翻转、任意角度旋转后按照步长 10 裁剪成 40×40 像素的图像,形成 ELU-CNN 模型的训练集。以相同的方法将旋转后的图像裁剪成 50×50 像素的图像块,形成 ELU-CNNB 模型的训练集。实验环境是 Keras,在 CPU Intel (R) Core(TM) i5-8300H CPU 2.30 GHz 的 PC 上进行,利用 Nvidia 1050 Ti GPU 加速。

标准图像测试选用的测试集为 Berkeley 的 68 幅图像的 BSD68 图像集^[9-10]及如图 3 所示被广泛使用的 12 幅图像的 set12 图像集,其中图 3a~图 3g 分辨率均为 256×256 像素,图 3h~图 3l 分辨率均为 512×512 像素。在实际图像上测试时选用深立井的井壁图像。



图3 set12 图像集中的 12 幅图像

3.2 标准图像的高斯去噪比较及分析

训练 ELU-CNN 模型时的参数设置为:每 64 个样本更新一次模型参数,迭代次数 $e=50$,超参数 $\alpha=0.1$,Adam 作为优化器,初始学习效率是 0.01,每 10 个 e 后学习效率降低一半,每个 e 训练 2 000 步。在标准图像中加入浓度 $\sigma=(15, 25, 35, 50, 75)$ 的高斯噪声后,利用 ELU-CNN 模型与 BM3D^[5]、WNNM^[6]、CSF^[7]、TRND^[8]、DnCNN-S^[9]、FFDNet^[10] 和 SCNN^[11] 7 种被高度认可的方法比较去噪效果。

表 1 给出了在 BSD68 上的测试结果,粗体表示

最高的峰值信噪比(设为 r_{PSNR})。显然,4 种 CNN 去噪方法的 r_{PSNR} 远高于 BM3D、WNNM、CSF 和 TRND 方法,在各种噪声浓度下,ELU-CNN 模型均获得了最高的 r_{PSNR} 。 $\sigma=(15, 25)$ 时,DnCNN-S 方法的 r_{PSNR} 高于 FFDNet 方法,在高浓度 $\sigma=(35, 50, 75)$ 时,FFDNet 方法的去噪性能超越了 DnCNN-S 方法。

表 2 给出了 ELU-CNN 模型及各种去噪方法对图 3 的 12 幅图像的测试结果,可以看出,不同噪声水平下,ELU-CNN 模型在大多数图像上都获得

表 1 BSD68 图像集上不同方法的平均峰值信噪比对比

σ	$\bar{r}_{\text{PSNR}}/\text{dB}$							
	BM3D	WNNM	CSF	TNRD	DnCNN-S	FFDNet	SCNN	ELU-CNN
15	31.07	31.37	31.24	31.42	31.73	31.63	31.48	31.80
25	28.57	28.83	28.74	28.92	29.23	29.19	29.03	29.30
35	27.08	27.30			27.69	27.73		27.81
50	25.62	25.87		25.97	26.23	26.29	26.08	26.34
75	24.21	24.40			24.64	24.79		24.82

表 2 set12 图像集上每幅图像的峰值信噪比

σ	方法	$r_{\text{PSNR}}/\text{dB}$												$\bar{r}_{\text{PSNR}}/\text{dB}$
		C. man	House	Peppers	Starfish	Monarch	Airplane	Parrot	Lena	Barbara	Boat	Man	Couple	
15	BM3D	31.92	34.94	32.70	31.15	31.86	31.08	31.38	34.27	33.11	32.14	31.93	32.11	32.38
	WNNM	32.18	35.15	32.97	31.83	32.72	31.40	31.61	34.38	33.61	32.28	32.12	32.18	32.70
	CSF	31.79	34.45	32.81	31.57	32.42	31.31	31.36	34.06	31.92	32.00	32.06	31.97	32.31
	TNRD	32.19	34.55	33.03	31.76	32.57	31.47	31.63	34.25	32.14	32.15	32.24	32.12	32.51
	DnCNN-S	32.61	34.97	33.30	32.20	33.09	31.70	31.83	34.62	32.64	32.42	32.46	32.47	32.86
	FFDNet	32.42	35.01	33.10	32.02	32.77	31.58	31.77	34.63	32.50	32.35	32.40	32.45	32.75
	ELU-CNN	32.63	35.11	33.30	32.27	33.28	31.77	31.93	34.68	32.74	32.49	32.49	32.51	32.93
25	BM3D	29.45	32.86	30.16	28.56	29.25	28.43	28.94	32.08	30.72	29.91	29.62	29.72	29.98
	WNNM	29.64	33.23	30.40	29.03	29.85	28.69	29.12	32.25	31.24	30.03	29.77	29.82	30.26
	CSF	29.35	32.40	30.17	28.80	29.59	28.67	28.88	31.83	29.03	29.71	29.66	29.46	29.80
	TNRD	29.71	32.54	30.55	29.02	29.86	28.89	29.18	32.01	29.41	29.92	29.88	29.71	30.06
	DnCNN-S	30.18	33.06	30.87	29.41	30.28	29.13	29.43	32.44	30.00	30.21	30.10	30.12	30.43
	FFDNet	30.06	33.27	30.79	29.33	30.14	29.05	29.43	32.59	29.98	30.23	30.10	30.18	30.43
	ELU-CNN	30.30	33.32	31.14	29.49	30.57	29.20	29.55	32.65	30.24	30.25	30.12	30.25	30.59
35	BM3D	27.93	31.38	28.52	26.87	27.58	26.84	27.41	30.56	28.98	28.43	28.22	28.15	28.41
	WNNM	28.07	31.93	28.73	27.27	28.13	27.10	27.66	30.74	29.48	28.54	28.33	28.24	28.69
	CSF													
	TNRD													
	DnCNN-S	28.61	31.61	29.14	27.53	28.51	27.52	27.94	30.91	28.09	28.72	28.66	28.52	28.82
	FFDNet	28.54	31.99	29.18	27.58	28.54	27.47	28.02	31.20	28.29	28.82	28.70	28.68	28.92
	ELU-CNN	28.83	32.02	29.21	27.75	28.71	27.54	28.02	31.18	28.48	28.86	28.72	28.72	29.00
50	BM3D	26.13	29.69	26.68	25.04	25.82	25.10	25.90	29.05	27.23	26.78	26.81	26.46	26.72
	WNNM	26.45	30.33	26.91	25.43	26.32	25.42	26.09	29.25	27.79	26.97	26.94	26.64	27.05
	CSF													
	TNRD	26.61	29.49	27.08	25.42	26.32	25.59	26.16	28.94	25.70	26.94	26.99	26.50	26.81
	DnCNN-S	27.03	30.00	27.32	25.70	26.78	25.87	26.48	29.39	26.22	27.20	27.24	26.90	27.18
	FFDNet	27.03	30.43	27.43	25.77	26.88	25.90	26.58	29.68	26.48	27.32	27.30	27.07	27.32
	ELU-CNN	27.14	30.50	27.49	25.80	27.00	26.11	26.53	29.63	26.60	27.35	27.32	27.10	27.38
75	BM3D	24.32	27.51	24.73	23.27	23.91	23.48	24.18	27.25	25.12	25.12	25.32	24.70	24.91
	WNNM	24.60	28.24	24.96	23.49	24.31	23.74	24.43	27.54	25.81	25.29	25.42	24.86	25.23
	CSF													
	TNRD													
	DnCNN-S	25.07	27.85	25.17	23.64	24.71	24.03	24.71	27.54	23.63	25.47	25.64	24.97	25.20
	FFDNet	25.29	28.43	25.39	23.82	24.99	24.18	24.94	27.97	24.24	25.64	25.75	25.29	25.49
	ELU-CNN	25.62	28.47	25.55	23.85	25.04	24.22	24.91	27.85	24.41	25.66	25.79	25.29	25.56

最高的 r_{PSNR} , 且均获得了最高的平均 r_{PSNR} 。DnC-NN-S 和 FFDNet 两种网络去噪模型获得了较好的去噪结果, $\sigma=(15, 25)$ 时, 前者表现优秀, $\sigma=(35, 50, 75)$ 时后者获胜, 尤其对 Parrot 和 Lena 两幅含有弧形特征的图像表现优异, 均略胜 ELU-CNN 模型。对 House 和 Barbara 两幅由规则和重复性结构组成的图像, ELU-CNN 模型并不能总是获得最高的 r_{PSNR} , 而 WNNM 是一种非局部相似性去噪方法, 它针对具有规则和重复纹理的图像去噪具有优势。基于非局部相似性的方法通常在具有规则和重复结构的图像上去噪效果更好, 而基于学习的方法通常在具有平滑区域或不规则纹理的图像上产生更好的结果^[17]。表 2 的结果与文献[16]的理论相符。综合表 1、2 的客观指标可知, ELU-CNN 模型具有较好的去噪效果。

图 4 给出了在 set12 图像集的 Couple 图像上随机加入 $\sigma=25$ 的高斯噪声后, 不同方法对其去噪





图 4 不同方法对 $\sigma=25$ 的 Couple 图像去噪的局部放大结果对比

后的局部放大结果。由图 4 可知:CSF 和 TNRD 方法的视觉效果最差, 门框的左侧竖直边缘和墙面上的横向纹理均模糊不清;BM3D、WNNM 和 DnC-NN-S 方法的纹理细节有所改善, 对边缘保护能力有所提高, 但并不理想;FFDNet 方法呈现出了边缘的轮廓, 视觉效果较好;ELU-CNN 模型获得了最好的去噪效果, 能清晰地体现线条纹理, 对线条特征的保护能力较强, 并能很好地呈现出图像的轮廓特征。

3.3 井壁图像盲去噪

ELU-CNNB 模型的超参数 $\alpha=0.05$, 其他的参数设置与 ELU-CNN 模型相同。图像获取、传输时有多种噪声来源, 无法准确估计实际噪声图像的噪声水平, 且真实噪声图像对应的干净图像也是未知的, 无法衡量去噪后的客观指标。为了验证去噪效果, 在井壁图像上加入高斯噪声, 通过去噪后的视觉图像衡量 ELU-CNNB 模型的盲去噪效果。

图 5 给出了 ELU-CNNB 模型对含不同浓度高斯噪声的井壁图像去噪的结果, 可以看出, 各幅图像在去除噪声的同时, 均很好地保留了井壁上的裂缝、腐蚀、破损及法兰盘等特征信息。ELU-CNNB 模型在保护图像纹理特征的同时, 能很好地保留图像中的线条特征, 是一种有效的盲去噪模型, 可以用于实际井壁图像去噪, 为井壁裂缝检测、定位等工作做好铺垫。



(a) 噪声图 (b) 去噪结果
图 5 ELU-CNNB 方法对含高斯噪声井壁图像的去噪结果

大雾伴有小雨的实际天气, 接近井下高温高湿的自然环境, 此环境下拍摄混凝土路面的图像来模

拟含水雾的井壁图像,加入 $\sigma=(15,25,50)$ 的高斯噪声后,使用 ELU-CNNB 模型和 DnCNN-B^[9] 方法去噪,结果如图 6 所示,其中 $\sigma=50$ 时噪声图里的方框内显示的是原图的放大结果。由图 6 可以看出,低噪声时两者的去噪效果相当,在高噪声浓度 $\sigma=50$ 时,圆圈内的裂缝在原图中往上延伸,ELU-CNNB 模型很好地保留了此特性,DnCNN-B 方法丢失了这条向上延伸的线条特征。可见,在深立井的井壁图像上,ELU-CNNB 模型的去噪效果较好,能有效去除井壁图像中含有的各种浓度的高斯噪声,同时很好地保留井壁的破损特征,从而为缺陷检测奠定了基础。

3.4 运行效率

CPU 运行时间是衡量去噪方法优劣的重要方面。表 3 给出了不同方法对加入 $\sigma=25$ 的高斯噪声的图像去噪需要的 CPU 运行时间。分辨率为 321×481 像素(BSD68)、 256×256 像素(set12)和 512

$\times 512$ 像素(set12)的图像是 3 幅标准图像, 640×480 像素的图像是井壁图像,对应盲去噪的运行时间。显然,3 种 CNN 去噪方法的运行速度高于 BM3D、WNNM、CSF 和 TRND 方法。与 DnCNN-S 和 ELU-CNN 模型相比,FFDNet 方法的网络深度最浅,运行时间最短,但盲去噪时对纹理的保护能力稍弱。ELU-CNN 模型没有获得最好的去噪效率,但是能够满足井壁图像去噪的需要,也可以使用高性能的 GPU 来提高去噪效率。

4 结 论

井壁是深立井的咽喉,井壁图像去噪是对井壁缺陷实现自动检测的关键步骤。本文提出的 ELU-CNN 模型是一种全卷积网络模型,除最后一个卷积层外的每个卷积层均用 64 个大小为 3×3 的滤波器提取不同类型、不同层次的特征。模型中的 5 个特征提取模块 FEM 与跳跃连接的结合能够将浅层提




图 6 ELU-CNNB 和 DnCNN-B 方法对加入高斯噪声的含水雾井壁图像的去噪结果

表 3 对 $\sigma=25$ 的图像去噪的 CPU 运行时间

分辨率/像素	CPU 运行时间/s						
	BM3D	WNNM	CSF	TNRD	DnCNN-S	FFDNet	ELU-CNN
321×481	1.82	265.36	2.47	1.65	0.42	0.22	0.51
256×256	0.67	124.13	2.10	1.21	0.23	0.13	0.27
512×512	3.20	519.77	4.61	2.57	0.69	0.26	0.75
640×480	4.23	608.16	5.31	3.21	0.73	0.41	0.82

取的低级图像特征传递到高层,保证充分提取输入图像中的噪声特征,确保模型通过端到端的训练后有效建立输入和输出之间的非线性映射。含噪图像中的噪声包含的信息量远小于信号的信息量,残差学习的引入使得训练后的模型学习到的是噪声,能够降低模型的学习困难。激活函数 ELU 的软饱和特性及输出均值接近于零的特性,能够提高模型的鲁棒性、加速模型收敛。

与 DnCNN 和 FFDNet 等方法相比,ELU-CNN 模型在标准测试集及井壁图像上去噪的主客观指标均有所提高,尤其在去除井壁图像的盲噪声时,能很好地保留井壁的特征信息。ELU-CNN 模型具有较强的线条保护能力,能很好地呈现出图像的轮廓特征,保护井壁裂缝的线条信息。

参考文献:

- [1] 何满潮,袁和生,靖洪文. 中国煤矿锚杆支护理论与实践 [M]. 北京: 科学出版社, 2004: 5-32.
- [2] DIERING D H. Ultra-deep level mining: future requirements [J]. Journal of South African Institute of Mining and Metallurgy, 1997, 97(6): 249-255.
- [3] 阮秋琦. 数字图像处理学 [M]. 北京: 电子工业出版社, 2013: 1-30.
- [4] CHATTERJEE P, MILANFAR P. Is denoising dead? [J]. IEEE Transactions on Image Processing, 2010, 19(4): 895-911.
- [5] 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.
- [6] GU Shuhang, ZHANG Lei, ZUO Wangmeng, et al. Weighted nuclear norm minimization with application to image denoising [C] // Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2014: 2862-2869.
- [7] SCHMIDT U, ROTH S. Shrinkage fields for effective image restoration [C] // Proceedings of the 27th IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2014: 2774-2781.
- [8] 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.
- [9] ZHANG Kai, ZUO Wangmeng, CHEN Yunjin, 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.
- [10] ZHANG Kai, ZUO Wangmeng, ZHANG Lei. FFDNet: toward a fast and flexible solution for CNN-based image denoising [J]. IEEE Transactions on Image Processing, 2018, 27(9): 4608-4622.
- [11] ISOGAWA K, IDA T, SHIODERA T, et al. Deep shrinkage convolutional neural network for adaptive noise reduction [J]. IEEE Signal Processing Letters, 2017, 25(2): 224-228.
- [12] HUANG Gao, LIU Zhuang, LAURENS V D M. Densely connected convolutional networks [C] // Proceedings of the 30th IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2018: 2261-2269.
- [13] JAIN V, SEUNG S. Natural image denoising with convolutional networks [C] // Proceedings of the Neural Information Processing Systems. New York, USA: Curran Associates Inc., 2009: 769-776.
- [14] BURGER H C, SCHULER C J, HARMELING S. Image denoising: can plain neural networks compete with BM3D? [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2012: 2392-2399.
- [15] NAIR V, HINTON G E. Rectified linear units improve restricted Boltzmann machines [C] // Proceedings of the 27th International Conference on Machine Learning. New York, USA: ICML, 2010: 807-814.
- [16] CLEVERT D A, UNTERTHINER T, HOCHREITER S. Fast and accurate deep network learning by exponential linear units (ELUs) [EB/OL]. (2016-02-22) [2018-11-17]. <https://arxiv.org/abs/1511.07289v5>.
- [17] BURGER H C, SCHULER C, HARMELING S. Learning how to combine internal and external denoising methods [C] // Proceedings of the 35th German Conference on Pattern Recognition. Berlin, Germany: Springer Verlag, 2013: 121-130.

(编辑 武红江)