

# 一种非开关型快速随机脉冲噪声降噪算法

徐少平,刘婷云,罗 洁,张贵珍,李崇禧

(南昌大学信息工程学院,江西南昌 330031)

**摘 要:** 为提高现有开关型随机脉冲噪声(Random-Valued Impulse Noise, RVIN)降噪算法的降噪性能,提出了一种基于卷积神经网络的非开关型 RVIN 快速降噪算法(Fast Non-switching RVIN Denoising Algorithm, FNRDA). 首先,利用噪声检测器随机地检测给定噪声图像中少量不同位置处的像素点;然后,将检测为 RVIN 噪声点的个数除以被检像素点总数转化为噪声比例值;最后,根据噪声比例值调用相应预先训练好的非开关型卷积神经网络降噪模型,快速且高质量地完成图像降噪任务. 实验结果表明:所提出的非开关型 FNRDA 算法在各噪声比例下的综合性能(降噪效果和执行效率)优于经典的开关型 RVIN 降噪算法,适用于图像恢复、信号检测、无线通讯等实时系统中.

**关键词:** 降噪; 随机脉冲噪声; 非开关型; 卷积神经网络; 噪声比例值; 执行效率

**中图分类号:** TP391.41      **文献标识码:** A      **文章编号:** 0372-2112 (2019)12-2622-08

**电子学报 URL:** <http://www.ejournal.org.cn>      **DOI:** 10.3969/j.issn.0372-2112.2019.12.023

## A Fast Non-switching Random-Valued Impulse Noise Denoising Algorithm

XU Shao-ping, LIU Ting-yun, LUO Jie, ZHANG Gui-zhen, LI Chong-xi

(School of Information Engineering, Nanchang University, Nanchang, Jiangxi 330031, China)

**Abstract:** To improve denoising effect and execution efficiency of the existing switching random-valued impulse noise (RVIN) removal algorithms, we propose a convolutional neural network (CNN)-based fast non-switching RVIN denoising algorithm (FNRDA), which consists of two serial CNN-based modules, i. e., noise detector and denoiser. Specifically, we first use the noise detector to detect some randomly selected pixels of a given noisy image. Then we divide the number of the detected noisy pixels by the total number of detected pixels to convert it into noise ratio, which can be treated as a measure of the distortion level for the given noisy image. Finally, according to the estimated noise ratio, we exploit the corresponding pre-trained non-switching CNN-based denoising model to remove RVIN efficiently with high quality. Experimental results show that, the proposed non-switching RVIN removal algorithm outperforms the classical switching ones in terms of denoising effect and execution efficiency across various noise ratios. This advantage makes it more attractive and practical in the real-time applications such as image restoration, signal detection, wireless communication, etc.

**Key words:** denoising; random-valued impulse noise; non-switching; convolutional neural network (CNN); noise ratio; computational efficiency

## 1 引言

现有的随机脉冲噪声(Random-Valued Impulse Noise, RVIN)降噪算法大多数都被设计为开关型<sup>[1]</sup>,即先利用内嵌的RVIN噪声检测器先检测图像中所有像素点,再根据检测结果仅对噪声点进行复原.例如,ROAD(Rank-Ordered Absolute Difference)<sup>[2]</sup>,ROLD(Rank-Ordered Logarithmic Difference)<sup>[3]</sup>,ROD-ROAD(Rank-Ordered Difference of ROAD)<sup>[4]</sup>等主流RVIN噪

声检测器先计算图像局部窗口内中心像素点与其邻域像素点亮度值之间的局部图像统计值(local image statistic),再将该值与预设阈值进行比较来判断当前中心像素点是否为RVIN.为提高检测正确率,这类RVIN噪声检测器通常需要多次迭代执行,且在每一次迭代过程中逐步减小阈值并绑定特定降噪算法完成已检出像素点的复原<sup>[3]</sup>.为了提高执行效率,研究者们以若干个局部图像统计值作为机器学习模型的输入,对应的噪声标签作为输出训练噪声检测器<sup>[5,6]</sup>.一旦噪声检测模

型训练完毕,就可以直接判定图像中任意位置的像素点是否为噪声,无需与某种降噪算法绑定迭代执行即可高效率地完成噪声检测任务,但是目前这类检测器的检测正确率尚需提高.简而言之,开关型 RVIN 降噪算法在内置噪声检测器的引导下仅针对被检测为噪声的像素点逐点进行复原,其降噪效果很大程度上依赖于 RVIN 噪声检测器的检测结果,而现有噪声检测器的正确率已无法满足进一步提高 RVIN 降噪算法性能的要求.

卷积神经网络(Convolutional Neural Network, CNN)具有很强的非线性逼近能力且受 GPU(Graphics Processing Unit)硬件支持,近年来被广泛应用于图像处理领域<sup>[7-9]</sup>.例如,已提出的 DnCNN(Denoising Convolutional Neural Network)<sup>[10]</sup>,FFDNet(Fast and Flexible Denoising convolutional neural Network)<sup>[11]</sup>,UDNet(Universal Denoising Network)<sup>[12]</sup>等网络直接在大量数据上训练获得端到端(end to end)的高斯降噪模型,表现出了比传统高斯降噪算法更好的降噪效果.这些算法核心计算代价为卷积操作,没有分支判断的处理过程(非开关型处理模式),也无需迭代执行,具有很高的执行效率.经过拓展后,这类算法可以用于处理 RVIN 降噪问题.然而,当输入噪声图像受 RVIN 噪声干扰的严重程度与训练降噪模型所用图像集合所受到干扰程度差异较大时,这类算法的降噪性能会有不同程度的下降,即存在数据依赖问题,属于非盲降噪算法.

为解决上述基于数据驱动的非盲降噪算法存在的数据依赖问题,以噪声点个数与图像像素点总数的比值(即噪声比例值,noise ratio)作为衡量图像受 RVIN 噪声干扰严重程度的量化指标,提出了一种由噪声检测器和降噪模型两个模块构成的非开关型 RVIN 快速降噪算法(Fast Non-switching RVIN Denoising Algorithm, FNRDA).对于任意给定的噪声图像,首先调用噪声检测器随机检测图像少量不同位置的像素点并将检测结果转换为噪声比例值,然后根据所测定的噪声比例值自适应地调用预先针对特定噪声比例范围训练的专用 DnCNN 降噪模型完成盲降噪任务.

## 2 相关工作

### 2.1 DnCNN 算法

Zhang 等人<sup>[10]</sup>基于深度卷积神经网络和残差学习(Residual Learning, RL)技术实现了一个将噪声信号从图像内容中分离的 DnCNN 降噪算法.如图 1 所示, DnCNN 网络模型主要由卷积层(Convolutional layer, Conv)、修正线性单元(Rectified Linear Unit, ReLU)<sup>[13]</sup>、批归一化(Batch Normalization, BN)<sup>[14]</sup>共 3 种部件构建而成.假设网络深度为  $d$ ,第 1 层(Conv + ReLU)使用 64 个大小

为  $3 \times 3 \times 1$  的滤波器对输入信号执行局部加权组合,然后通过 ReLU 激活函数输出 64 个特征映射图;第 2 ~ ( $d - 1$ )层(Conv + BN + ReLU)在第 1 层的基础上增加了 BN 操作,以缓解训练过程中产生的内部协变量转移(internal covariate shift)现象<sup>[14]</sup>,使用了 64 个大小为  $3 \times 3 \times 64$  的滤波器;最后 1 层(Conv)只用了 1 个大小为  $3 \times 3 \times 64$  的滤波器输出残差图像. ReLU、BN 以及残差学习技术的应用使得训练深度 DnCNN 网络的计算复杂度大大降低,同时也有效地提高了模型的降噪性能.

通过对  $n$  张原始无失真图像  $\{x_1, x_2, \dots, x_i, \dots, x_n\}$  添加不同级别的噪声得到噪声图像  $\{y_1, y_2, \dots, y_i, \dots, y_n\}$ ,以噪声图像集合及其对应的残差图像集  $\{v_1, v_2, \dots, v_i, \dots, v_n\}$ (通过噪声图像减去原始图像获得,即  $v_i = y_i - x_i$ )作为网络的输入输出训练对(Training Pairs, TP),利用残差图像与模型估计残差图像之间的平均均方误差

$$\ell(\Theta) = \frac{1}{2n} \sum_{i=1}^n \|R(y_i; \Theta) - (y_i - x_i)\|_F^2 \quad (1)$$

作为损失函数来调整网络模型的参数  $\Theta$ .对于一张给定的噪声图像  $y$ ,将其减去该降噪模型的输出  $R(y; \Theta) \approx v$  即可得到最终的复原图像  $\hat{x} = y - R(y; \Theta)$ .

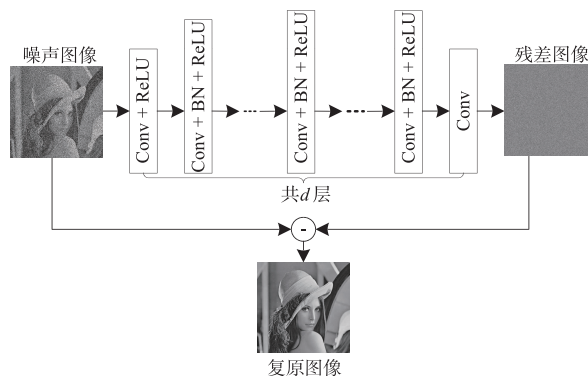


图1 DnCNN降噪模型的组成架构

### 2.2 DnCNN 算法的缺点

基于数据驱动的 DnCNN 高斯降噪算法其降噪效果依赖于模型的训练图像集,只有当待降噪图像和噪声图像训练集受到噪声干扰的严重程度(即图像的高斯噪声水平值  $\sigma$ )相近时,降噪效果才能达到最理想的状态.如图 2 所示,图 2(c)复原质量较好,其 PSNR(Peak Signal to Noise Ratio)值为 29.96dB.而图 2(d)中仍然存在大量的噪声,PSNR 值仅为 24.86dB.上述情况表明:仅当训练 DnCNN 降噪模型的噪声图像与待降噪图像的噪声水平值一致( $\sigma_{\text{train}} = \sigma_{\text{test}}$ )时才能获得最佳的降噪效果,若不匹配则会导致降噪效果严重下降.因此,在使用降噪模型时,准确估计待降噪图像受噪声干扰的严重程度非常重要.



图2 DnCNN降噪模型对数据依赖的示例

### 3 FNRDA 降噪算法

#### 3.1 设计思想与实现步骤

用于去除高斯噪声的 DnCNN 网络结构同样可用于去除 RVIN 噪声,只需调整 TP 训练对中的输入图像(让其受 RVIN 噪声干扰)即可.然而,基于数据驱动的 DnCNN 降噪模型需要在待降噪图像与训练图像受噪声干扰的严重程度近似时才能获得最佳降噪效果.为此,提出以噪声比例作为量化图像受 RVIN 噪声干扰严重程度的指标,并基于浅层卷积神经网络构建一个 RVIN 噪声检测器.利用该噪声检测器快速准确地估计出任意待降噪图像中若干不同位置处的噪声标签(用 0 标记正常像素点,1 标记 RVIN 像素点),并将噪声标签转换为噪声比例值,然后根据该比例值自适应调用预先训练好的专用 DnCNN 降噪模型完成盲降噪任务.具体地,如图 3 所示,算法实现过程分为训练阶段和测试阶段 2 个部分:

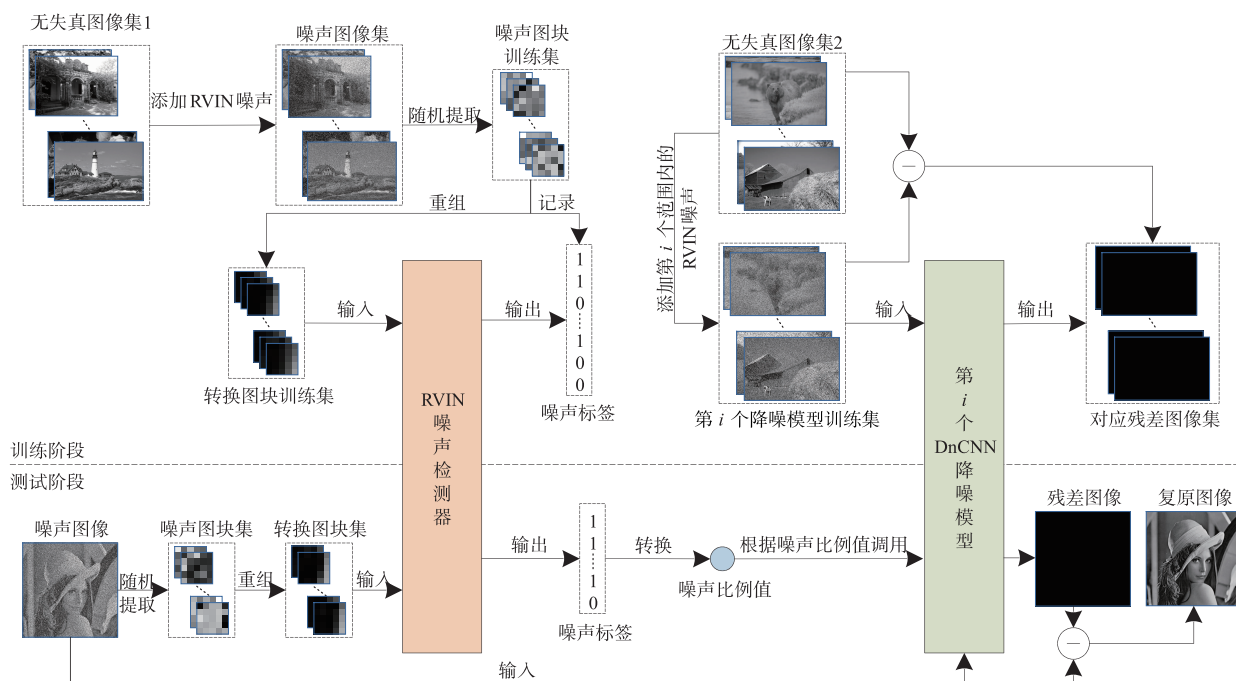


图3 FNRDA算法流程框图

(1) 训练阶段. 首先,对若干原始无失真图像添加各个比例的随机脉冲噪声生成噪声图像集,从噪声图像集中随机抽取大量噪声图块并记录对应的噪声标签.其次,将图块的每个像素点与其中心像素的亮度值做绝对差值,进行升序排序后重新组合成新的图块(称为转换图块),得到转换图块集.然后,分别以转换图块集和相应噪声标签作为浅层卷积神经网络的输入和输出,通过训练即可获得一个噪声检测器.由于转换图块

中像素点的亮度值其实就是构成 ROAD 统计值的基本元素,使用转换后图块作为 CNN 网络输入,有助于简化 CNN 网络结构,提高噪声检测器的检测精度和执行效率.最后,将噪声比例的整个变化区间划分为  $i$  个子范围,在每一个子范围内,对选定的无失真图像集添加噪声比例值属于该段子范围的 RVIN 噪声,生成对应的第  $i$  个模型训练集,将每张噪声图像减去对应的无失真图像得到残差图像集.以噪声图像集和残差图像集作为

DnCNN 网络模型的 TP 训练对,即可训练一个适用于处理该段噪声比例范围的专用 DnCNN 降噪模型。

(2)测试阶段.对于给定的待降噪图像,从中随机提取若干个图块,对噪声图块进行重组之后输入到已训练好的 RVIN 噪声检测器中,得到对应的噪声标签,将检测出的噪声像素点个数除以被检像素点总数转换为噪声比例值,根据该值自适应调用最合适的专用 DnCNN 降噪模型,得到对应的残差图像,将给定的噪声图像减去残差图像即可获得最终的复原图像。

### 3.2 噪声检测器

如图 4 所示,利用 CNN 卷积神经网络各种网络组件(包括卷积层(Conv)、批归一化(BN)、激活函数(ReLU)、全连接层(Fully-Connected layer,FC)和 Softmax 回归层)构成检测分类模型,其输入为固定大小的局部图块,输出为噪声标签.就目前检测一个局部窗口中心像素点是否为噪声的任务来说,采用该浅层 CNN 网络可以满足需要,同时具有很高的执行效率。




图4 基于浅层卷积神经网络的RVIN噪声检测器框架

为训练图 4 所示的 RVIN 噪声检测器,首先从 IL-NIQE (the Integrated Local Nature Image Quality Evaluator) 数据库<sup>[15]</sup>中选择 90 张图像并从 TID (Tampere Image Database) 数据库<sup>[16]</sup>中随机选取 10 张图像,共获得 100 张原始无失真图像,对每张图像施加各个级别(0 ~ 60%, 间隔 10%)的随机脉冲噪声.其次,随机从每张噪声图像不同位置提取大小为  $s \times s$  的 1000 个图块(参照文献[3]中窗口大小的设置, $s = 5$ ),图块及其对应的噪声标签构成 TP 训练对,这样训练数据量达到  $100 \times 1000 \times 7 = 700000$  个.一旦基于卷积神经网络的 RVIN 噪声检测器训练好后,即可用于检测出任意给定图像中的 RVIN 噪声点,无需用户设置任何参数.需要说明的是:在具体实现时,考虑到图像中的噪声像素点一般是均衡分布的,且本文最终的目标是统计图像中噪声像素点所占的比例值,因此无需检测噪声图像所有的像素点,随机在图像中提取少量图块即可.对于 1 张  $512 \times 512$  大小的图像来说,本文随机在图像不同位置处提取像素点总数 0.5% 左右(大约 1300 个)的图块用于估计噪声比例值,这种采样实现方式使得噪声比例检测模块的执行时间非常少。

### 3.3 DnCNN 专用降噪模型

考虑到 DnCNN 算法所存在的数据依赖不足,本文将噪声比例范围(0 ~ 60%)划分为若干个子范围,在每一个子范围内,训练专用于此范围的 DnCNN 降噪模型,配合所提出的噪声检测器即可获得实用性很强的盲降噪算法.噪声比例的划分范围过大则网络模型的拟合难度加大,降噪效果会有所下降;划分范围过小,则需要训练较多的降噪模型,影响其实用性.为此,分别在噪声比例范围(0 ~ 60%)内,间隔 1%,10%,20%,30%,60% 训练专用的降噪模型(间隔 60% 意味着仅训练 1 个 DnCNN 降噪模型).对 BSD (Berkeley Segmentation Dataset) 数据库<sup>[17]</sup>中的 50 张纹理丰富的图像施加 10% ~ 60%、间隔为 10% 的 RVIN 噪声生成噪声图像集合,各模型复原所有噪声图像获得 PSNR 值的均值作为评价指标,对比数据如图 5 所示.从图 5 可知,间隔 10% 训练的模型降噪能力最高,故本文间隔 10% 对全局噪声比例范围进行划分。




图5 噪声比例划分范围对DnCNN模型降噪效果的影响

由于 CNN 卷积神经网络具有权值共享特性,所提出的 DnCNN 模型的训练实际上是在图块级上完成,而图块大小在很大程度上影响着算法的降噪效果和执行效率.为了找到最合适的图块大小,首采用大小不同的训练图块(分别为  $32 \times 32$ 、 $36 \times 36$ 、 $40 \times 40$ 、 $44 \times 44$  和  $48 \times 48$ )训练 5 个降噪模型,用于训练的图块个数超过 250000 个.训练完成后,从 BSD 数据库<sup>[17]</sup>中随机抽取不同于训练集合的 50 张纹理丰富的图像,然后对这些图像分别施加不同噪声比例(0 ~ 60%, 间隔 10%)的 RVIN 噪声构成测试图像集,使用基于不同图块大小训练的多个模型分别对所有测试图像进行降噪,计算每张图像在某一图块大小参数配置下的 PSNR 值,取所有复原图像的 PSNR 均值作为最终的对比数据,如图 6 所示.从图 6 可知,采用大小为  $44 \times 44$  的图块训练出的降噪模型能获得最高降噪效果, $40 \times 40$  次之.虽然  $44 \times 44$  时降噪效果最好,但是要比  $40 \times 40$  时多处理 21% 的像素点,计算代价增加了不少.综合考虑降噪效果和执行效率,将训练与测试所使用的图块大小设置为  $40 \times 40$ 。

此外,通过在多个不同内容的图像数据集上<sup>[15-17]</sup>的交叉测试实验可以发现(限于篇幅,这里不列出具体的数据):训练图像集的选择(图像内容)对降噪模型的性能影响不大,因此本文在 BSD 图像集上完成模型的训练,选用 120 张以上图像构成训练集即可获得令人满意的降噪效果.总之,除去上述提到的参数设置外,本文训练 DnCNN 专用降噪模型其他参数的设置均与文献[10]相同.




图6 不同图块大小训练的DnCNN模型的降噪效果对比

## 4 实验结果与分析

### 4.1 测试环境

为了评估所提出的 FNRDA 算法的 RVIN 噪声检测及降噪能力,将其与主流的 ASWM (Adaptive Switching Median filter)<sup>[18]</sup>、PSMF (Progressive Switching Median Filter)<sup>[19]</sup>、ROLD-EPR (ROLD with Edge-Preserving Regularization)<sup>[3]</sup>、ROR-NLM (the Robust Outlyingness Ratio with Nonlocal Means)<sup>[20]</sup>、ANN-EPR (Artificial Neural Network with EPR)<sup>[5]</sup>和 ALOHA (Annihilating filter-based LOw-rank HAnkel matrix)<sup>[21]</sup>共 6 个 RVIN 降噪算法进行比较.其中,ALOHA 降噪算法没有显式的噪声检测过程,而是直接基于 Hankel 结构矩阵的稀疏低秩分解原理完成图像降噪,故该算法不参与 RVIN 检测正确率的比较,而只参加降噪效果的对比实验.所采用的测试集包括两个:一个是由常见于各文献的 10 张图像(包括 Lena, Peppers, Couple, Barbara, Indor, Man, Cameraman, Monarch, Aerial, Plane)组成的常用图像集,另一个是由从 BSD 数据库<sup>[17]</sup>中随机抽取的 50 张图像(与训练图像不同)构成的纹理图像集.该数据库中的图像纹理丰富,很合适用来测试 RVIN 降噪算法的鲁棒性.所有实验都是在统一环境下(硬件平台为:Inter(R) Core(TM) i7-4770 CPU (NVIDIA Quadro M4000 GPU) @ 3.40GHz 16GB RAM;软件环境为:Windows7.0 操作系统;编程环境为:Matlab R2017)完成的.

### 4.2 噪声比例检测正确性

为了测试 FNRDA 算法的噪声检测准确性,使用噪声比例检测器对施加了不同比例的 RVIN 噪声图像中的

噪声比例值进行预测.由于经典 RVIN 降噪算法的噪声检测都是逐像素点进行的,为了便于比较,将各算法检测出的像素点除以整张图像的像素点总数将其转化为噪声比例,然后计算各算法的噪声比例预测结果与图像上所施加噪声比例真实值之间的均方根误差(Root Mean Square Error, RMSE),实验数据列在表 1 中(排名前 2 的数据加粗表示).由表 1 可知:ANN-EPR 算法和所提出的噪声检测器的检测正确率比较稳定. ANN-EPR 算法虽然在噪声比例检测方面的性能与所提出的噪声比例检测器大致相近,但是由下文表 4 中的数据可知,该算法的执行时间比较长,故 FNRDA 算法中的噪声比例检测器在检测准确性和执行效率方面的综合性能更佳.

表 1 各噪声检测器对 50 张纹理图像在不同噪声比例值下检测结果的均方根误差比较

检测器	噪声比例					
	10%	20%	30%	40%	50%	60%
ASWM	10.14	9.38	8.61	7.85	7.13	6.57
ROR-NLM	8.67	6.41	4.48	<b>3.48</b>	3.85	4.85
PSMF	4.75	4.30	6.47	9.81	13.49	17.34
ROLD-EPR	2.78	4.98	5.61	6.35	6.44	6.45
ANN-EPR	<b>1.89</b>	<b>3.12</b>	<b>3.51</b>	3.82	<b>3.51</b>	<b>3.54</b>
FNRDA	<b>1.97</b>	<b>3.37</b>	<b>3.88</b>	<b>3.42</b>	<b>2.92</b>	<b>2.78</b>

### 4.3 降噪效果

首先,为了验证 FNRDA 算法的降噪效果,在 10 张常用图像上分别施加噪声比例为 10% ~ 60% (间隔 10%)的 RVIN 噪声,并用各个参与比较的 RVIN 降噪算法对这些噪声图像进行降噪,计算降噪后图像的 PSNR 值,实验结果如表 2 所示(实验数据以均值形式给出,最优值加粗显示).由表 2 可知:FNRDA 算法所获得的 PSNR 值是最高的,体现出较大优势,这种优势依赖于所提出的噪声检测器的准确预测以及专用 DnCNN 模型强大的降噪能力.

其次,为了验证 FNRDA 算法降噪能力的鲁棒性,在纹理细节特征丰富的图像集上进行了同样的降噪对比实验.为了说明基于 DnCNN 构建 RVIN 主降噪模型的优势,对 Win5-RB (Wide Inference Networks with 5layers + RL + BN)<sup>[22]</sup>、REDNet30 (very deep Residual Encoder-Decoder Networks)<sup>[23]</sup>和 Auto-Encoder<sup>[24]</sup>三种基于深度学习的高斯降噪模型进行改进使之可以用于去除 RVIN 噪声(只改变网络的 TP 训练对数据,内部网络结构保持不变).这 3 种降噪模型在各个噪声比例下所获得的实验数据列在表 3 中,同时给出了 PSNR 值的标准差(standard deviation)作为反映算法鲁棒性的指标.由表 3 可知,与其他参与对比的 RVIN 降噪算法相比, FNRDA 算法获得的 PSNR 均值最高且标准差变化不

大,降噪效果与稳定性最佳.

最后,为了更直观地比较各算法的降噪效果,图 7 给出了各个算法对施加了 40% 的 RVIN 噪声的 Lena 图像降噪后的图像.为了更好地对比各个算法的降噪效果,将各算法复原的图像右眼部位放大进行细致比较.从图 7 中可以看出:仅 FNRDA 算法复原的图像在睫毛和眼珠部位与原图像相差甚微,表现出了很好的边缘保持能力.

#### 4.4 执行效率

除降噪效果之外,执行效率也是判断一个 RVIN 降噪算法性能好坏的重要标准.为此,在 1 张大小为  $512 \times 512$  的 Lena 图像上进行对比实验,计算 FNRDA 算法与各个对比算法在各个噪声比例下的平均执行时间,结果如表 4 所示.由表 4 可知,在 CPU 环境下运行,FNRDA 算法执行时间不到 2s,较大部分对比算法更有

优势.而在 GPU 环境下运行,FNRDA 算法的平均执行时间为 92ms,执行效率远高于其他对比算法.总体来说,FNRDA 算法的综合性能是最优的,更具实用价值.

表 2 不同噪声比例下各算法在 PSNR 指标上的比较(单位:dB)

算法	噪声比例					
	10%	20%	30%	40%	50%	60%
ASWM	31.25	29.86	28.68	27.11	25.08	22.08
PSMF	30.75	27.97	25.51	22.98	20.42	18.08
ROLD-EPR	31.86	29.83	28.41	27.31	26.22	24.95
ROR-NLM	28.82	27.61	26.36	24.88	22.73	20.20
ANN-EPR	31.11	28.95	27.86	26.73	25.63	24.15
ALOHA	34.94	31.87	29.82	26.45	22.16	20.80
FNRDA	<b>39.69</b>	<b>36.05</b>	<b>35.43</b>	<b>32.63</b>	<b>30.55</b>	<b>28.32</b>

表 3 各算法在纹理图像集的 50 张噪声图像上的降噪效果(PSNR 值均值  $\pm$  标准差)(单位:dB)

算法	噪声比例					
	10%	20%	30%	40%	50%	60%
ASWM	28.79 $\pm$ 4.30	27.83 $\pm$ 3.95	26.85 $\pm$ 3.69	25.68 $\pm$ 3.40	24.00 $\pm$ 3.04	21.50 $\pm$ 2.65
PSMF	26.77 $\pm$ 3.04	25.04 $\pm$ 2.43	22.67 $\pm$ 2.00	20.14 $\pm$ 1.79	17.57 $\pm$ 1.76	15.32 $\pm$ 1.81
ROLD-EPR	30.30 $\pm$ 3.60	28.01 $\pm$ 4.49	27.03 $\pm$ 3.53	26.02 $\pm$ 3.43	25.41 $\pm$ 3.38	24.74 $\pm$ 3.32
ROR-NLM	26.87 $\pm$ 3.89	26.31 $\pm$ 4.45	25.54 $\pm$ 4.12	24.55 $\pm$ 3.68	22.95 $\pm$ 3.24	20.72 $\pm$ 2.76
ANN-EPR	30.42 $\pm$ 3.04	28.09 $\pm$ 3.17	26.72 $\pm$ 3.22	25.60 $\pm$ 3.18	24.57 $\pm$ 3.08	23.40 $\pm$ 2.75
ALOHA	31.45 $\pm$ 4.93	28.93 $\pm$ 4.44	26.53 $\pm$ 3.58	23.95 $\pm$ 2.21	21.71 $\pm$ 2.30	18.64 $\pm$ 2.36
WIN5_RB	33.76 $\pm$ 3.26	30.41 $\pm$ 3.36	28.18 $\pm$ 3.24	26.78 $\pm$ 3.12	25.03 $\pm$ 2.99	22.93 $\pm$ 2.50
REDNet30	28.35 $\pm$ 2.18	26.23 $\pm$ 2.27	24.64 $\pm$ 2.41	23.26 $\pm$ 2.31	22.46 $\pm$ 2.33	21.70 $\pm$ 2.28
Auto-Encoder	27.25 $\pm$ 2.23	26.29 $\pm$ 2.29	25.46 $\pm$ 2.59	24.33 $\pm$ 2.48	23.41 $\pm$ 2.53	21.98 $\pm$ 2.27
FNRDA	<b>37.67 <math>\pm</math> 3.26</b>	<b>33.38 <math>\pm</math> 3.32</b>	<b>28.23 <math>\pm</math> 3.69</b>	<b>27.21 <math>\pm</math> 3.36</b>	<b>25.69 <math>\pm</math> 3.61</b>	<b>24.30 <math>\pm</math> 3.00</b>




图 7 各算法对具有 40% RVIN 噪声的 Lena 图像降噪后的视觉效果对比

表 4 噪声图像在不同算法上的执行时间(单位:s)

算法	ASWM	PSMF	ROLD-EPR	ROR-NLM	ANN-EPR	ALOHA	FNRDA	FNRDA
计算环境	CPU	CPU	CPU	CPU	CPU	GPU	CPU	GPU
执行时间	58.248	0.512	5.688	30.955	3.945	602.295	1.733	0.092

## 5 结论

本文提出了一种非开关型快速随机脉冲噪声降噪算法,该算法以卷积神经网络作为核心技术训练了一个RVIN噪声检测器和多个DnCNN专用降噪模型,快速且高质量地实现了RVIN噪声的去除.与传统开关型RVIN降噪算法采用逐点检测与复原的方式不同,所提出算法基于CNN卷积神经网络技术设计了检测能力强大的噪声检测器,并以噪声比例值作为衡量图像受RVIN噪声干扰严重程度的指标,依据转换得到的噪声比例值调用预先训练好的专用DnCNN模型快速完成高质量的盲降噪任务.这种盲降噪实现方案在计算效率和降噪效果两方面的综合性能超越了现有的主流开关型RVIN降噪算法,实用性更好.

### 参考文献

- [1] XU Q, LI Y H, GUO Y J, et al. Random-valued impulse noise removal using adaptive ranked-ordered impulse detector [J]. *Journal of Electronic Imaging*, 2018, 27(1):013001.
- [2] GARNETT R, HUEGERICH T, CHUI C, et al. A universal noise removal algorithm with an impulse detector[J]. *IEEE Transactions on Image Processing*, 2005, 14(11):1747-1754.
- [3] DONG Y Q, CHAN R H, XU S F. A detection statistic for random-valued impulse noise [J]. *IEEE Transactions on Image Processing*, 2007, 16(4):1112-1120.
- [4] LIU L C, CHEN C L P, ZHOU Y C, et al. A new weighted mean filter with a two-phase detector for removing impulse noise[J]. *Information Sciences*, 2015, 315(September):1-16.
- [5] TURKMEN I. The ANN based detector to remove random-valued impulse noise in images[J]. *Visual Communication and Image Representation*, 2016, 34(October):28-36.
- [6] SOLEIMANY S, BRANCH Q, HAMGHALAM M, et al. A novel random-valued impulse noise detector based on MLP neural network classifier[A]. *Proceedings of the 2017 Artificial Intelligence and Robotics (IRANOPEN)* [C]. Piscataway, NJ:IEEE, 2017. 165-169.
- [7] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. *计算机学报*, 2017, 40(6):1229-1251.  
ZHOU Fei-yan, JIN Lin-peng, DONG Jun. Review of convolutional neural network[J]. *Chinese Journal of Computers*, 2017, 40(6):1229-1251. (in Chinese)
- [8] 李宝奇, 贺昱曜, 何灵蛟, 等. 基于全卷积神经网络的非对称并行语义分割模型[J]. *电子学报*, 2019, 47(5):1058-1064.  
LI Bao-qi, HE Yu-yao, HE Ling-jiao, et al. Asymmetric parallel semantic segmentation model based on full convolutional neural network[J]. *Acta Electronica Sinica*, 2019, 47(5):1058-1064. (in Chinese)
- [9] 李康, 李亚敏, 胡学敏, 等. 基于卷积神经网络的鲁棒高精度目标跟踪算法[J]. *电子学报*, 2018, 46(9):2087-2093.  
LI Kang, LI Ya-min, HU Xue-min, et al. A robust and accurate object tracking algorithm based on convolutional neural network[J]. *Acta Electronica Sinica*, 2018, 46(9):2087-2093. (in Chinese)
- [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*, 2016, 26(7):3142-3155.
- [11] ZHANG K, ZUO W M, ZHANG L. FFDNet: Toward a fast and flexible solution for CNN based image denoising [J]. *IEEE Transactions on Image Processing*, 2018, 27(9):4608-4622.
- [12] LEFKIMMIATIS S. Universal denoising networks: A novel CNN architecture for image denoising[A]. *Proceedings of the 2018 Computer Vision and Pattern Recognition* [C]. Piscataway, NJ:IEEE, 2018. 3204-3213.
- [13] RAWAT W, WANG Z H. Deep convolutional neural networks for image classification: A comprehensive review [J]. *Neural Computation*, 2017, 29(9):2352-2449.
- [14] IOFFE S, SZEGEDY C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift [EB/OL]. <https://arxiv.org/abs/1502.03167>, 2015-03-02/2019-08-10.
- [15] ZHANG L, ZHANG L, BOVIK A C. A feature-enriched completely blind image quality evaluator[J]. *IEEE Transactions on Image Processing*, 2015, 24(8):2579-2591.
- [16] PONOMARENKO N, JIN L, IEREMEIEV O, et al. Image database TID2013: Peculiarities, results and perspectives [J]. *Signal Processing: Image Communication*, 2015, 30(1):57-77.
- [17] ARBELAEZ P, MAIRE M, FOWLKES C, et al. Contour detection and hierarchical image segmentation [J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*,

- 2011,33(5):898-916.
- [18] AKKOUL S, LÉDÉE R, LECONGE R, et al. A new adaptive switching median filter [J]. *IEEE Signal Processing Letters*, 2010, 17(6):587-590.
- [19] WANG Z, ZHANG D. Progressive switching median filter for the removal of impulse noise highly corrupted images [J]. *IEEE Transactions on Circuits System II: Analog Digit Signal Processing*. 1999, 46(1):78-80.
- [20] XIONG B, YIN Z P. A universal denoising framework with a new impulse detector and nonlocal means [J]. *IEEE Transactions on Image Processing*, 2012, 21(4):1663-1675.
- [21] JIN K H, YE J C. Sparse and low-rank decomposition of a Hankel structured matrix for impulse noise removal [J]. *IEEE Transactions on Image Processing*, 2018, 27(3):1448-1461.
- [22] LIU P, FANG R G. Learning Pixel-Distribution Prior with Wider Convolution for Image Denoising [EB/OL]. <https://arxiv.org/abs/1707.09135>, 2017-07-28/2019-08-10.
- [23] MAO X J, SHEN C H, YANG Y B. Image Restoration Using Very Deep Convolutional Encoder-Decoder Networks with Symmetric Skip Connections [EB/OL]. <https://arxiv.org/abs/1603.09056>, 2016-09-01/2019-08-10.
- [24] PARK S, YU S, KIM M, et al. Dual autoencoder network for Retinex-based low-light image enhancement [J]. *IEEE Access*, 2018, 6:22084-22093.

## 作者简介



徐少平 男, 1976年5月出生于江西省九江市. 博士, 南昌大学信息工程学院计算机科学与技术系教授, 博士生导师. 主要研究方向为图形图像处理、机器视觉、虚拟手术仿真等.

E-mail: xushaoping@ncu.edu.cn



罗洁(通信作者) 女, 1978年8月出生于江西省南昌市. 学士. 南昌大学附属传染病医院麻醉科主治医师. 主要研究方向为医学图像处理和机器学习.

E-mail: 110745595@qq.com

刘婷云 女, 1996年10月出生于江西省抚州市. 现为南昌大学硕士研究生, 主要研究方向为图像处理与计算机视觉.

E-mail: 416114517210@email.ncu.edu.cn

张贵珍 女, 1993年5月出生于江西省赣州市. 现为南昌大学硕士研究生, 主要研究方向为图像处理与计算机视觉.

E-mail: 406130917331@email.ncu.edu.cn

李崇禧 男, 1994年8月出生于江西省吉安市. 现为南昌大学硕士研究生, 主要研究方向为图像处理与计算机视觉.

E-mail: 406130917315@email.ncu.edu.cn