

论文引用格式:

两阶段多层感知的随机脉冲噪声比例预测

于海雯, 易昕炜, 徐少平, 张贵珍, 刘婷云

南昌大学信息工程学院, 南昌 330031c

摘要: **目的** 基于卷积神经网络(CNN)在图块级上实现的随机脉冲噪声(RVIN)降噪算法在执行效率方面较经典的逐像素点开关型降噪算法有显著优势, 但其降噪效果受制于对待降噪图像受噪声干扰程度(噪声比例值)的准确估计。为此, 本文提出一种基于多层感知网络的两阶段噪声比例预测算法以自适应地调用CNN预训练降噪模型达到获得最佳去噪效果的目的。**方法** 首先, 对大量无噪声图像添加不同噪声比例的RVIN噪声构成噪声图像集合; 其次, 基于视觉码本(visual codebook)采用软分配(soft-assignment)编码法提取并筛选若干能反映噪声图像受随机脉冲噪声干扰严重程度的特征值构成特征矢量; 再次, 将从噪声图像上提取的特征矢量及其对应的噪声比例分别作为多层感知网络的输入和输出训练噪声比例值预测模型, 实现从特征矢量到噪声比例值的映射(预测); 最后, 采用粗精相结合的两阶段实现策略进一步提高RVIN噪声比例的预测准确性。**结果** 针对不同RVIN噪声比例的失真图像, 本文从预测准确性、实际降噪效果和执行效率三个方面来验证所提出算法的性能和实用性。实验数据表明, 本文算法在大多数噪声比例下的预测误差小于2%, 应用于CNN降噪算法的降噪效果(PSNR指标)较其他主流降噪算法高2~4 dB, 处理一张大小为512×512像素的图像仅需3秒左右。**结论** 本文提出的RVIN噪声比例预测算法在各个噪声比例下具有鲁棒的预测准确性, 依据其所预测的比例值调用预先训练的CNN降噪模型所实现的RVIN降噪算法在降噪效果和执行效率两个方面较经典的开关型RVIN降噪算法有显著提升, 更具实用价值。

关键词: 降噪; 随机脉冲噪声; 噪声比例预测; 噪声比例感知特征; 多层感知网络; 计算效率

Two-Stage Multi-Layer Perceptron Estimation for Random-Valued Impulse Noise Ratio

Yu Haiwen Yi Xinwei Xu Shaoping Zhang Guizhen Liu Tingyun

School of Information Engineering, Nanchang University, Nanchang, 330031

Abstract: Objective The existing switching random-valued impulse noise (RVIN) removal algorithms mainly detect the noisy pixels of an image to be denoised by comparing the local image statistic with predefined thresholds, and then combine a denoising method to restore the detected noisy pixels in a pixel-wise manner, resulting into low execution efficiency. With respect to computational complexity, the convolutional neural network (CNN)-based denoising algorithms that were implemented at patch-level for random-valued impulse noise (RVIN) has a significant advantage over the classical switching denoising algorithms that detect and remove RVIN pixel-by-pixel. However, the restoration performance of the CNN-based denoising algorithms is still limited to the accurate estimation of the distortion level of the given noisy image. In essence, the CNN-based denoising algorithm is still a non-blind method, where the best denoising effect only can be obtained by training a specific denoising model at a fixed noise level, limiting the practical application.

收稿日期: ; 修回日期:

基金项目: 国家自然科学基金项目(61662044, 61163023, 51765042, 81501560); 江西省自然科学基金项目(20171BAB202017) Supported by: National Natural Science Foundation of China (61662044, 61163023, 51765042, 81501560); Project of Jiangxi Natural Science Foundation (20171BAB202017).

第一作者: 于海雯(1972-), 女, 讲师, 主要研究方向图形图像处理技术和机器视觉。E-mail: yuhaiwen@ncu.edu.cn

通信作者: 徐少平, 教授, xushaoping@ncu.edu.cn

For simplicity, the noise ratio can be treated as a measure of the distortion level of a noisy image, by dividing the number of detected noisy pixels by the total number of image pixels. According to the estimated noise ratio, CNN-based denoising methods can remove the RVIN blindly and efficiently with high quality by exploiting the corresponding pre-trained denoisers adaptively. To precisely estimate the noise ratio, a two-stage noise ratio estimation algorithm based on multi-layer perceptron (MLP) was proposed in the paper. **Method** Specifically, a large number of clean images were first corrupted with RVIN at different ratios to form a set of noisy images. Then, based on the visual codebook and soft-assignment coding technology, the features that can reflect the distortion level of a noisy image were extracted and screened to form feature vector for each noisy image. After that, the feature vectors and their corresponding noise ratios extracted from noisy images were used as the input and output of the multi-layer perceptron model respectively to train the noise ratio estimation model that maps a given feature vector to its corresponding noise ratio. Generally, to obtain the ideal approximation function, the more hidden layers are required in MLP architecture. But the construction of MLP-based regression model with multi-hidden layers is difficult in convergence and the training speed. Therefore, a coarse-to-fine two-stage strategy was employed to further improve the estimation accuracy. Concretely, a relatively coarse noise ratio estimation model was trained across the whole range of noise ratio, and then the noise ratio range was divided into a number of sub-ranges, which means the mapping range of the estimation model is reduced. In the same way, several fine noise ratio estimation models were trained in different noise ratio sub-ranges. Note that each subinterval overlaps with its adjacent subinterval to avoid the estimation inaccuracy at the extremities of subinterval. In the prediction phase, a preliminary estimation is first obtained using the coarse estimation model. Based on this, the corresponding fine estimation model is employed to predict the noise ratio more accurately. **Result** The comparison experiments were conducted to test the validity of proposed method from three aspects: estimation accuracy, denoising effect, and execution efficiency. The proposed method was first compared with several classical noise detectors of RVIN denoising methods, such as PSMF, ROLD-EPR, ASVM, and ROR-NLM, to demonstrate the estimation accuracy. The number of detected noisy pixels was converted into noise ratio, since the output result of the noise detectors of those compared switching denoising methods is the number of noisy pixels. Results shows that the estimation error of the proposed method is less than 2% across different noise ratios, showing stronger robustness than others. To verify the availability of the proposed method, the feed-forward denoising convolutional neural network (DnCNN) algorithm that is designed for removing Gaussian noise was improved to deal with the removal of RVIN. In denoising effect comparison, the peak signal-to-noise ratio (PSNR), structural similarity (SSIM), and feature similarity (FSIM) were adopted as image quality assessment index. For the distorted images with different RVIN noise ratios, the PSNR values obtained by the improved DnCNN algorithm utilizing the proposed method increase by 2 dB more than that of others across the range of noise ratio from 10% to 60%. Simultaneously, the FSIM values rank in the top 2 for different noise ratios, while the SSIM values approximate the best results. Regarding qualitative visual evaluation, the improved DnCNN algorithm utilizing the proposed estimation model can generate a clearer restored image with better edge preservation. Compared with switching RVIN removal methods, the improved DnCNN algorithm outperforms them in execution efficiency, which takes only 3.8 seconds to restore an image of size 512×512 px. **Conclusion** Extensive experiments show that, the estimation accuracy of the proposed MLP-based noise ratio estimation algorithm is robust across a wide range of noise ratios. With the proposed noise estimation model, the CNN-based RVIN removal algorithms can achieve the best blind denoising by exploiting the closest matching model. Moreover, compared to the traditional switching RVIN denoising algorithm, the improved DnCNN denoising algorithm with the noise ratio estimation module outperforms them significantly in terms of both denoising effect and execution efficiency, which makes it more practical.

Key words: Image denoising; Random-valued impulse noise (RVIN); Noise ratio estimation; Noise ratio-aware feature; Multi-layer perceptron network; Computational efficiency

0 引言

图像在受到随机脉冲噪声(RVIN)干扰后,部分像素点的亮度值可在其允许的范围内随机发生改变,变化后像素点亮度值在很多时候与其相邻像素点的亮度值相差不大,因此对图像中的RVIN噪声点进行检测并去除的难度较大^[1]。为此,研究者们针对RVIN噪声的随机性和不确定性提出了许多降噪算法^[2-4]。到目前为止,已提出的随机脉冲噪声降噪算法大都属于逐像素点的开关型算法,即首先利用噪声检测器采用逐点方式判断当前窗口内中心像素点是否被破坏,然后根据检测的结果决定是否启动相应的降噪算法来完成噪声点的复原。

早期的开关型RVIN降噪算法^[5-7]主要依据计算中值滤波器(或其衍生滤波器)的输出值和中心像素点亮度值之间的绝对差值与预设阈值的比较结果来判断中心像素点是否为噪声点,然后针对检测出的噪声点调用相应的降噪算法对其复原。这种实现策略在低比例噪声条件下能较为理想地完成降噪任务,但是随着噪声比例的增大,噪声检测正确率快速下降,影响了后续的图像复原效果。为了提高噪声点的检测准确率,研究者们根据自然图像局部相似的规律提出了基于图像局部统计值(LIS)的RVIN检测算法。例如,Garnett等人^[8]引入绝对差值排序(ROAD)统计值进行RVIN噪声点的检测。ROAD统计值是指前 m 个当前局部窗口内中心像素点与其邻域像素点的亮度值之间的绝对差值(已排序)的累积和,将其与预设阈值进行比较来检测判断该中心像素点是否被RVIN噪声污染。ROAD检测器的检测正确率较高,但当噪声比例较高时,检测正确率开始下降。Dong等人^[9]为了放大了噪声和非噪声像素点之间的差异,对ROAD统计值进行对数变换,提出了基于对数差值排序(ROLD)统计值的噪声检测器,在一定程度上提高了噪声检测的正确率。在此基础上,利用边缘保持正则化(EPR)方法实现RVIN噪声的去除。虽然ROAD和ROLD检测器可以检测出图像中的大部分随机脉冲噪声点,但是仅依赖单次的统计值与阈值的判定还是很难获得较高的预测准确率,尤其是对图像边缘噪声点的检测效果非常不理想,这种情况在高比例噪声条件下表现得尤为明显。为此,传统的RVIN降噪算法大多是采用从粗到精依次设置递减阈值的迭代检测策略来提高噪声检测正确率,在迭代过程中的每一步

需要利用某种降噪算法完成对已检出RVIN像素点的降噪,故基于这种策略实现的噪声检测过程并不是一步完成的,执行效率比较低。为提高检测效率,近期Turkmen^[9]提出了一种基于人工神经网络(ANN)的随机脉冲降噪算法。该算法采用ROAD和ROLD这两个统计值作为网络的输入来训练RVIN噪声检测器,一旦噪声检测模型训练完毕,就可以一次性检测出图像中所有的像素点,且无需与某种降噪算法绑定迭代执行即可高效率地执行检测噪声任务。但该算法采用的仍然是逐点检测策略,受预测模型的制约,虽然ANN噪声检测器的执行效率较传统的统计值-阈值方法有所提高,但其检测正确率却不是很高,达不到传统的基于LIS统计值检测方法的水平。总之,现有开关型RVIN降噪算法的性能严重依赖于噪声检测器对图像中噪声像素点的检测正确率和效率,而目前的检测算法在这两个方面尚难获得一个很好的折中平衡点。

近年来,卷积神经网络(CNN)因其局部感知(local connections)及权值共享(shared weights)特性在计算机视觉与图像处理领域^[10-11]获得了比传统方法更加令人满意的结果。此外,基于图像处理单元(GPU)通用并行计算技术可以极大地提高这类算法的执行效率。研究者们已经提出很多利用卷积神经网络解决图像降噪问题的算法^[12-13]。例如,Zhang等人^[12]提出前馈降噪卷积神经网络(DnCNN)去除高斯噪声,该算法表现出了比传统高斯降噪算法(BM3D^[14], MLP^[15], WNNM^[16], TNRD^[17])更好的降噪效果和执行效率。其实,DnCNN算法中利用CNN网络去除高斯噪声的技术路线经过合理改进可以用于去除RVIN噪声,只要将训练数据集中的DnCNN网络模型的输入数据替换成受RVIN噪声干扰的图像即可。但DnCNN算法的框架本质上属于基于训练的降噪框架,这种类型的降噪算法要获得最佳降噪效果的前提是待降噪图像与所调用的降噪模型在训练时所使用的图像受到噪声干扰的程度相似,只有这样才能发挥最大降噪效果。实践中,噪声比例(noise ratio)是衡量噪声图像受RVIN噪声干扰严重程度简单且有效的指标。因此,若要采用训练策略实现性能最佳(包括降噪质量和执行时间)的RVIN噪声的去除,构建噪声比例检测器对图像噪声比例进行检测是必不可少的工作。

自然图像一旦受到RVIN噪声干扰,其图像内在统计特征会发生有规律的变化^[18],度量这些规律性的变化可实现噪声比例的预测。因此,本文试图

提取能够反映图像受 RVIN 噪声干扰程度的噪声比例感知特征(NRAF), 然后基于多层感知(MLP)网络实现从 NRAF 特征到噪声比例值的映射(预测)。为了获得更高的预测正确率, 采用粗精相结合的两阶段策略实现噪声比例的预测。最后, 在不同噪声比例区间内预训练多个 CNN 降噪模型(对 DnCNN 算法做适当的改进使其可用于 RVIN 噪声的去除)。基于此, 对于一张待降噪图像, 根据噪声比例检测器的预测结果(图像中 RVIN 噪声比例)自适应地调用预先训练的相应 DnCNN 降噪模型即可完成 RVIN 降噪任务。所提出的噪声比例预测算法及改进 DnCNN 降噪模型(构成新型 RVIN 降噪算法)一旦训练完成即可直接使用, 整个过程无需人工再设置任何参数, 属于盲降噪算法。大量实验表明, 所提出的新型 RVIN 降噪算法在降噪效果和执行效率两个方面较经典开关型 RVIN 降噪算法有大幅度提高, 具有更好的实用价值。

1 多层感知网络

近年来, 神经网络因其具备强大的学习能力可以完成输入与输出间复杂的非线性映射, 在图像分类^[19]、目标检测^[20]以及人脸识别^[21]等领域得到广泛的应用。其中, 前馈神经网络(FNN)是最简单且使用最广泛的神经网络模型之一, 其基本组成单元是感知器模型^[22]。多层感知器(MLP)通常由输入层、一个或多个隐藏层以及输出层组成, 每一层由简单的神经元或节点构成, 每个节点连接到相邻层中的各个节点, 每一层神经元的输出作为下一层神经元的输入。其中, 节点由权值和输出信号连接, 输出信号是许多简单非线性传输函数或激活函数的加权和, 权值在网络的训练过程中可不断被调整。图 1 展示了输入向量与输出之间的非线性映射关系(每个圆圈代表一个神经元节点, 有“+1”标识的圆圈代表偏置节点)。理论上讲, 只要选择一组合适的连接权值和非线性传输函数, 多层感知器即可逼近输入和输出向量之间的任意光滑可测函数。

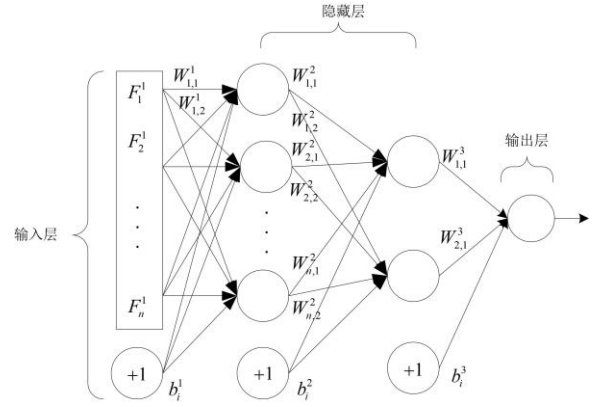


图 1 具有 2 个隐藏层的多层感知器

Fig.1 Multi-layer perceptron with two hidden layers

多层感知器的训练是确定权重的过程, 以便精确地确定输入向量与输出向量之间的关系。MLP 网络的最终训练目标是找到网络中连接权重和偏差的最佳组合使得训练和测试样本的误差最小。具体而言, 假设多层感知神经网络有 n 层, 输入层记为 l_1 , 输出层记为 l_n , 隐藏层记为 l_2, l_3, \dots, l_{n-1} , 则 MLP 网络第 k 层的输出为

$$U_i^k = \sum_{j=1}^n (W_{i,j}^{k-1} F_j^{k-1} + b_j^{k-1}) \quad (1)$$

其中, $W_{i,j}^{k-1}$ 表示第 $k-1$ 层中的第 j 个结点和第 k 层中的第 i 个结点之间的权重。 F_j^{k-1} 表示第 $k-1$ 层第 j 个结点的特征值, b_j^{k-1} 表示对应的偏置值, U_i^k 表示第 k 层第 i 个神经元的输入总和。第 k 层的第 i 个神经元的输出 F_i^k 与输入 U_i^k 之间存在以下关系:

$$X_i^k = f(U_i^k) \quad (2)$$

其中, $f(\cdot)$ 函数表示每个神经元的激活函数, 常见的激活函数 sigmoid 函数的形式一般为

$$f(z) = \frac{1}{1 + \exp(-z)} \quad (3)$$

权重 W 通过训练调整后, 给定一个输入, 网络模型能够给出相对应的输出, 该输出能够最大程度上逼近所期望的结果。

2 随机噪声比例预测

2.1 基本思想

现有的主流 RVIN 降噪算法大都是采用工作在像素点级上的开关型降噪策略,这种降噪方式导致降噪算法的性能严重受制于噪声检测器,而现有的噪声检测器在检测正确率和执行效率两个方面均有待提高(一时还难以有大幅度提高)。近期新提出的基于 CNN 卷积神经网络的 RVIN 降噪算法具有较高的执行效率,但却是通过训练的方式实现的,必须在与待降噪图像受噪声干扰程度近似的图像集合上进行训练 CNN 降噪模型才能获得最佳的降噪效果。对于随机脉冲噪声而言,噪声比例是一种简单而有效的反映图像受 RVIN 噪声干扰严重程度

的指标。为了直观地验证 CNN 降噪模型的降噪效果的确受制于 RVIN 噪声比例的估计准确度,在 3 个噪声比例区间(分别为 30%~40%, 35%~45%, 40%~50%)的噪声图像集合上训练出 3 个专门的 CNN 降噪模型,依次分别命名为 model1、model2、model3,这 3 个模型分别对 35%、40%和 45%的 RVIN 噪声具有最佳的降噪效果。然后用这 3 个模型分别对施加了 40%的随机脉冲噪声的 Lena 图像(大小为 512×512 像素)进行降噪,降噪后的视觉效果如图 2 所示。从图 2 中可以看出利用 model2 模型降噪获得的图 2(d)的 PSNR 值比利用相邻模型 model1、model3 获得的图 2(c)和图 2(e)的 PSNR 值高 1.5 dB 左右,由此说明当且仅当调用与图像噪声比例值最为匹配的 CNN 降噪模型才能获得最佳的降噪效果。



(a)原始图像 (b)噪声图像 (c)model1(PSNR=30.60 dB) (d) model2(PSNR=32.38 dB) (e) mode3(PSNR=30.84 dB)

图 2 不同噪声图像集合上训练的 CNN 降噪模型对 RVIN 噪声比例为 40% 的 Lena 图像降噪的效果对比图

Fig.2 Denoised images obtained by different CNN-based denoising model ((a) original image; (b) 40% RVIN noisy image; (c) model1(PSNR=30.60 dB); (d) model2(PSNR=32.38 dB); (e) mode3(PSNR=30.84 dB))

为此,提出了一种工作在图块级上的基于 MLP 网络的两阶段 RVIN 噪声比例预测算法。该算法适用于基于 CNN 卷积神经网络训练的降噪算法,通过所提出算法检测待降噪图像的噪声比例并以此为依据调用相应预训练的 CNN 降噪模型,即可获得一种降噪效果和执行效率俱佳的 RVIN 降噪算法。具体地,为了构建噪声比例预测算法,首先将大量有代表性的原始无失真图像分解为图块并通过聚类算法获得视觉码本(VC)^[23],码本中的记录反映了无失真图像具有代表性的单词。然后对大量有代表性的原始无失真图像施加各个级别的 RVIN 噪声构成噪声图像集合。对于每一张噪声图像,随机从图像中抽取大量图块(本文使用 10 000 个)并基于所构建的视觉码本利用软分配(soft-assignment)编码法计算这些噪声图块与码本中各个单词的相似度(距离)作为反映图像受 RVIN 干扰的程度,将各

个距离值组合起来可构成反映图像受噪声干扰严重程度特征矢量。为了降低特征矢量中那些对噪声比例不敏感的特征值对模型训练的影响并减少算法的执行时间,从所提取的特征矢量中筛选出与噪声比例相关性较高的若干维特征构成 NRAF 特征矢量作为 MLP 网络的输入以训练噪声比例预测模型,实现 NRAF 特征矢量到噪声比例值的映射。为了进一步提高噪声比例的预测正确率,将整个噪声比例范围划分为更小的子范围(降低 MLP 网络映射模型的构建难度),利用上述相同的训练方法训练精细预测模型,从而获得一种粗细相结合的噪声比例预测模型。

2.2 特征值提取

图像在受到不同比例的 RVIN 噪声干扰后,其统计特征会发生规律性的变化。本文主要通过构建视觉码本^[23]的方法提取图像中蕴含的 NRAF 特征。

具体地, 首先对大量原始无失真图像将其拆分成若干个大小为 $B \times B$ 像素的图块, 其次对图块进行 K-means 聚类分析以构建视觉码本, 视觉码本可表示为矩阵 $D_{d \times K} = (D_1, D_2, \dots, D_K)$, 其中, $d = B \times B$,

$D_{i(i=1,2,\dots,K)}$ 是通过 K-means 聚类方法学习的簇的质心(centroids of clusters)。然后对所学习的码本进行归一化处理使得每一个基都有单位长度(unit length), 归一化处理后的码本可表示为 $D_{d \times K} = (D_1, D_2, \dots, D_K)$ 。对于给定的一张受某一噪声比例干扰的噪声图像 I , 随机从图像 I 中抽取 N 个大小为 $B \times B$ 像素的图块, 对其进行归一化处理并通过零分量分析(ZCA)对这些已归一化处理的图块进行白化处理(whitening), 得到图块局部特征矢量 $\mathbf{X} = (x_1, x_2, \dots, x_k, \dots, x_N)$, 其中 $x_k \in \mathbb{R}^d$ 。利用归一化处理后的码本 D 对这些图块进行软分配编码。具体编码方法是将图块 x_k 与 D 中的视觉码字(visual codewords)进行点积计算得到两者之间的距离 $s_{i,j} = x_i \cdot D_j$, 用其表示局部特征矢量 \mathbf{X} 中的 x_i 与视觉码字 \tilde{D}_j 的相似性度量。那么这样整个图像的编码系数可表示为

$$c_i = (\max(s_{i,1}, 0), \dots, \max(s_{i,d}, 0), \max(-s_{i,1}, 0), \dots, \max(-s_{i,d}, 0))^T \quad (4)$$

文中所使用的软分配函数是文献[24]中软阈值(soft threshold)函数的特例, 将阈值设置为 0。具体实现时, 为了让所获得的特征值具有一般性, 随机从图像中抽取 10 000 个图块, 故基于公式(4)可以从每张图像上提取得到 20 000 维特征矢量, 这是一个高维的特征矢量。

2.3 特征值筛选

通过上述特征值提取方法虽然可以得到 20 000 维特征值, 但是其中绝大多数特征值并不能稳定地反映图像受 RVIN 噪声干扰后发生的规律性变化。

此外, 特征的维数过多不仅会加大后续预测模型的计算量, 而且会在某种程度上降低噪声比例预测模型的精度。因此, 本文并不直接使用所有的 20 000 维特征组成 NRAF 特征, 而是通过计算这些特征值与噪声水平值之间的相关性, 从 20 000 维特征中筛选出与噪声比例相关性较高的若干维特征作为 NRAF 特征值使用(MLP 预测模型的输入)。为了筛选这些特征, 从 BSD500 图像库^[25]中选取 50 张无失真图像作为测试图像集合, 对测试集合中的每一张图像分别施加噪声比例为 5%, 10%, 15%, 20%, 25%, 30%, 35%, 40%, 45%, 50%, 55%, 60% 共 12 个级别的 RVIN 噪声构成 600 张噪声图像, 每张噪声图像的噪声比例值组合后可构成大小为 600×1 的矩阵

$$\mathbf{A} = (\alpha_1, \alpha_2, \dots, \alpha_i, \dots, \alpha_{600})^T \quad (5)$$

其中,

$$\alpha_i = \begin{cases} 0.05 \times i, & i \leq 12 \\ \alpha_{(i-12)}, & i > 12 \end{cases} \quad (6)$$

然后提取每张噪声图像的 20 000 维特征构成大小为 $20\,000 \times 1$ 的特征矢量 β_j , 600 张噪声图像的特征矢量堆叠组合转置后构成大小为 $600 \times 20\,000$ 的矩阵 $\mathbf{B} = (\beta_1, \beta_2, \dots, \beta_i, \dots, \beta_{600})^T$ 。最后计算矩阵 \mathbf{A} 和矩阵 \mathbf{B} 中各个列矢量 β_i 之间的皮尔森线性相关系数(PLCC)值, 获得一个具有 20 000 个值的相关系数矩阵 $\mathbf{P} = (p_1, p_2, \dots, p_i, \dots, p_{20\,000})^T$ 。矩阵 \mathbf{P} 反映各维特征值与噪声水平值之间相关性, 这样通过设置阈值可以筛选出对 RVIN 噪声最为敏感的特征。如表 1 所示, 仅有 13 维特征值满足相关系数值大于 0.95, 表明他们与噪声水平值具有极强的相关性, 故最终只选用这些特征值构成 NRAF 特征矢量 $\mathbf{F} = (f_1, f_2, \dots, f_{13})$ 。特征值的筛选过程不仅降低了相关性不高的特征对模型训练的干扰, 同时也减少了参与运算的数据量, 加快了数据处理速度, 提高了执行效率。

表 1 不同的预设阈值对特征值的筛选情况

Table 1 Features screening results using different thresholds

相关系数值	≥ 0.60	≥ 0.65	≥ 0.70	≥ 0.75	≥ 0.80	≥ 0.85	≥ 0.90	≥ 0.95
满足条件的特征值维数	5 558	4 339	3 379	2 543	1 748	985	403	13

2.4 两阶段预测

在使用 CNN 降噪模型去除图像中 RVIN 噪声之前需要知道待降噪图像的噪声比例才能调用最合适的降噪模型完成理想的降噪任务。为了解决这一问题，将从噪声图像训练集中的每一张噪声图像上提取的 NRAF 特征矢量和相应的噪声比例值构成训练输入输出对(TP),然后基于 TP 数据采用 MLP 网络训练噪声比例预测模型完成 NRAF 特征矢量到噪声比例值的映射。一般地，当噪声比例范围较大时，为获得理想的逼近函数，需要在构建 MLP 预测模型时设置更多的隐含层，但会随之增加模型的拟合难度及训练时间。而预测目标值的范围比较小时，网络模型更容易收敛，预测准确性也更高。因此，笔者采用粗精相结合的两阶段预测策略实现噪声比例值的估计。首先在整个噪声比例范围内训练一个相对来说比较粗粒度的 MLP 预测模型，然后将噪声比例范围划分为多个子区间(即将预测模型映射范围缩小)，采用相同的方法针对各个子区间训练精细 MLP 预测模型。具体地，在噪声比例范围 [0,60%] 内训练一个粗糙的预测模型以确定噪声比例的大致范围，然后将范围 [0,60%] 划分为 11 个子区间，即 0~10%，5%~15%，10%~20%，15%~25%，

20%~30%，25%~35%，30%~40%，35%~45%，40%~50%，45%~55%，55%~65%，在每个子区间内对同一无失真图像集合中的每张图像添加间隔为 2% 的 RVIN 噪声预先训练出相应的专用 CNN 降噪模型。值得注意的是，为了解决处于子区间边缘的噪声比例预测不准的问题，每个子区间都与其相邻子区间重叠了一部分。在预测时，先用粗糙预测模型对图像噪声比例进行初步预测，然后根据初步预测的结果选择相应分段上更为精细的预测模型进行二次预测，以获得更为精确的噪声比例预测值。具体选择时，从第 2 个噪声比例区间开始，如果第一阶段的预测值如果大于等于某个区间范围的中值，则调用该区间相应的预测模型估计图像噪声比例，否则调用前一相邻区间的预测模型对噪声比例进行估计。

表 2 列举了在 10 张常用经典测试图像集上(见下文图 3 所示)计算粗糙模型和精细模型在不同噪声比例下的均方根误差。从表 2 中可以看出，大多数情况下，精细模型得到的均方根误差均比粗糙模型获得的数值更小。即精细模型预测的误差要比粗糙模型的要小，预测值更加接近真实的噪声比例，充分说明了两阶段预测方法的有效性和必要性。

表 2 精细模型与粗糙模型预测结果与真实噪声比例的均方根误差

Table 2 RMSE between the real noise ratio and the estimated ones

噪声比例/%	10	15	20	25	30	35	40	45	50	55
粗糙模型	2.27	2.09	2.37	4.20	4.11	3.47	4.48	3.28	2.77	1.74
精细模型	2.56	1.85	1.37	1.93	1.31	2.51	1.57	2.78	1.83	2.10

2.5 噪声比例检测器伪代码

综上所述，文中所提出的基于多层感知网络的噪声比例检测预测算法的步骤如下：在训练阶段，首先在具有代表性的无失真图像集上施加噪声比例为 0~60%，间隔为 5% 的随机脉冲噪声构成粗糙(精细)训练图像集，从训练集合图像中提取每一张噪声图像的 NRAF 特征矢量和相应的噪声比例值构成训练数据并依据上文介绍的方法训练粗粒度的预测模型。训练精细预测模型的整个过程和粗糙预测模型的训练过程类似，不同之处在于训练的模型更加细化。也就是将 0~60% 分成 11 个细分的区间，在每个区间内对训练图像施加噪声比例间隔 2% 的 RVIN 噪声。根据以上算法流程的描述，对应的伪代码描述如下。

算法 1 两阶段 RVIN 噪声比例预测算法

输入：无失真图像集合、噪声图像 I

输出：噪声比例 δ

训练阶段：

Step1: 将大量无失真图像拆分成图块构建视觉码本

Step2: 在大量无失真图像上施加 0~60%，间隔 5% 的 RVIN 噪声构建噪声图像集合

Step3: 基于视觉码本和软分配编码法提取噪声图像集合中每一张噪声图像的 NRAF 特征矢量(仅利用筛选后的 13 维数据)，并结合相应的噪声比例值构建训练数据集

Step4: 基于训练数据集利用 MLP 网络训练粗粒度预测模型

Step5: 将 0~60% 分成 11 个细分的区间，添加间隔为 2% 的噪声构建噪声图像集合

Step6: 采用与粗粒度预测相同的方法，在各个

细分噪声比例段内训练精细预测模型
预测阶段:

Step7: 提取给定噪声图像 I 的 NRAF 特征矢量

$$F = (f_1, f_2, \dots, f_{13}) \text{ (筛选后的 13 维数据)}$$

Step8: 利用粗糙预测模型对其进行预测, 确定噪声比例的大致范围

Step9: 根据粗糙预测模型的预测结果调用精细模型, 再次预测待降噪图像的噪声比例

3 实验与分析

3.1 测试环境

为了评估所提出的噪声比例检测器的预测能

力, 将其与经典的 PSMF^[26]、ROLD-EPR^[6]、ASWM^[7] 和 ROR-NLM^[27] 共 4 个 RVIN 降噪算法所使用的噪声检测器在如图 3 所示的常用图像集上进行实验对比。为了验证所提出的比例检测器在新型非开关型 RVIN 降噪算法中的作用, 笔者对 DnCNN 算法^[12](可以是任何基于训练的 RVIN 降噪算法, 这里仅以 DnCNN 算法为例)进行了必要改进, 使其可用于去除随机脉冲噪声, 然后将所提出的噪声检测器与之相结合构成新型的非开关型随机脉冲降噪算法(记为 ACNN), 与上述 4 个对比算法在不同噪声比例下比较实际降噪效果。实验的硬件平台为: Inter(R) Core(TM) i7-3517U CPU @ 2.40GHz RAM 8GB, 软件环境为: Windows 10 操作系统, Matlab R2016b 编程环境, 所有实验在相同软硬件环境下完成。



图 3 在各种文献中常用的测试图像集

Fig.3 Commonly used images in the literatures((a) Boat; (b) Lena; (c) House; (d) Cameraman; (e) Couple; (f) Barbara; (g) Peppers; (h) Hill; (i) Man; (j) Monarch)

3.2 预测准确性

为了测试所提出的噪声比例预测算法的预测准确性, 在 10 张常用图像(如图 3 所示)上进行对比实验。分别使用噪声比例预测模型对施加了不同噪声比例的图像进行预测, 并和现有的经典噪声检测算法 (PSMF^[26]、ROLD-EPR^[6]、ASWM^[7]、ROR-NLM^[27])进行对比。由于这四个对比算法都是采用逐点的方式进行噪声检测, 得到的是噪声点的个数。为了便于比较, 将各算法检测出的噪声点个

数除以整张图像总像素点数转化为噪声比例, 对比数据记录于表 3 中(限于篇幅, 表 3 只给出 Peppers 图像在 10%~55%, 间隔 5% 的 RVIN 噪声干扰下的实验数据, 其他图像的实验结果类似)。在各噪声比例下, 预测结果最接近真实噪声比例值的前两个的算法加粗显示。从表 3 中可以看出, 所提出的算法在大多数情况下排名前 2, 表现出了良好的预测准确性。

表 3 各算法在添加了不同级别 RVIN 噪声的 Peppers 图像上的预测结果

Table 3 Estimation results of different methods on Peppers image across different noise ratios

对比算法	噪声比例/%									
	10	15	20	25	30	35	40	45	50	55
ASWM	6.49	11.96	17.45	23.10	28.56	34.26	39.92	45.41	51.62	57.39
PSMF	6.60	8.47	10.03	11.82	13.52	15.27	16.68	18.14	19.51	21.21
ROLD-EPR	7.58	12.25	16.55	20.46	25.11	29.76	33.23	38.63	43.33	47.69
ROR_NLM	12.72	17.06	21.19	25.54	29.49	33.92	37.55	42.16	45.56	49.84
本文算法	10.57	12.90	20.72	24.88	25.28	33.88	40.03	48.33	49.67	54.36

注：排名前 2 的结果加粗显示，最优的结果用下划线标记。

为了进一步测试所提出的 RVIN 噪声比例预测算法的稳定性，对图 3 所示的 10 张图像上添加各个级别(10%~55%，间隔 5%)的 RVIN 噪声，计算各噪声检测器在噪声图像上的预测噪声比例与真实噪声比例的均方根误差来度量噪声比例检测正确率，将

其与上述经典 RVIN 降噪算法中的噪声检测方法进行对比，数据如表 4 所示(排名前 2 的结果加粗显示，最优的结果用下划线标记)。从表 4 中可以看出，所提出的方法在各个噪声比例下均能排名前 2，且大部分情况下都表现出了最佳预测能力。

表 4 各方法在十张图像上的预测结果的均方根误差值

Table 4 RMSE between estimated results and ground truths on ten commonly used images

对比算法	噪声比例/%									
	10	15	20	25	30	35	40	45	50	55
ASWM	5.85	5.37	4.78	4.18	3.58	2.93	2.23	2.23	1.21	1.56
PSMF	1.18	2.78	4.06	5.63	7.18	8.95	10.61	12.57	14.38	16.41
ROLD-EPR	2.58	3.54	4.24	4.86	5.36	5.92	6.28	6.43	6.77	6.67
ROR_NLM	4.65	3.84	3.05	2.40	1.98	2.09	2.58	3.43	4.38	5.29
本文算法	2.55	1.85	1.37	1.93	1.31	2.51	1.57	2.78	1.83	2.10

注：排名前 2 的结果加粗显示，最优的结果用下划线标记。

3.3 实际降噪效果

为了评估所提出噪声比例检测器的实际使用效果，与 4 个经典算法 ASWM、PSMF、ROLD-EPR、ROR_NLM 在常用图像集上进行比较，选用 PSNR, SSIM, FSIM 作为评价指标，比较结果列在表 5~7(排名前 2 的结果加粗显示，最优的结果用下划线标

记)。由表 5~7 可知，所提出的算法在各个噪声比例下的 RSNR 值均表现最优；FSIM 值在各个噪声比例下均排名前 2，绝大部分表现最优；SSIM 值虽然在各个噪声比例下的结果与最优值相差不大。实验数据充分说明了应用了所提出噪声比例检测器后的 CNN 降噪算法的降噪效果是最佳的。

表 5 不同噪声比例下各降噪算法在 PSNR 评价指标上的比较

Table 5 Average PSNR performance on ten commonly used images across different noise ratios

对比算法	噪声比例/%											
	5	10	15	20	25	30	35	40	45	50	55	60
ASWM	31.17	30.61	30.03	29.47	28.87	28.34	27.74	27.05	26.26	25.24	23.97	22.51
PSMF	32.48	30.79	29.40	28.12	26.93	25.71	24.45	23.27	22.08	20.82	19.64	18.52
ROLD-EPR	33.90	31.92	30.62	29.73	28.98	28.30	27.72	27.13	26.65	26.13	25.58	24.95
ROR_NLM	29.06	28.73	28.41	28.00	27.54	27.03	26.48	25.85	25.00	24.08	22.92	21.67
ACNN	<u>35.00</u>	<u>34.42</u>	<u>33.44</u>	<u>32.49</u>	<u>31.78</u>	<u>29.92</u>	<u>29.94</u>	<u>28.89</u>	<u>28.28</u>	<u>27.14</u>	<u>26.30</u>	<u>25.45</u>

注：排名前 2 的结果加粗显示，最优的结果用下划线标记。

表 6 不同噪声比例下各降噪算法在 FSIM 评价指标上的比较

Table 6 Average FSIM performance on ten commonly used images across different noise ratios

对比算法	噪声比例/%											
	5	10	15	20	25	30	35	40	45	50	55	60
ASVM	0.976 5	0.973 6	0.969 9	0.965 7	0.960 7	<u>0.955 1</u>	<u>0.948 1</u>	0.938 4	0.925 8	0.906 0	0.876 6	0.838 1
PSMF	0.984 0	0.975 0	0.964 9	0.952 1	0.936 6	0.917 4	0.892 2	0.864 0	0.829 7	0.789 7	0.747 7	0.706 6
ROLD-EPR	<u>0.987 8</u>	<u>0.980 9</u>	<u>0.973 6</u>	<u>0.967 5</u>	<u>0.961 2</u>	0.954 3	0.947 1	0.939 6	0.931 1	<u>0.921 4</u>	<u>0.908 3</u>	<u>0.891 8</u>
ROR_NLM	0.967 4	0.964 4	0.960 7	0.955 7	0.949 5	0.942 0	0.931 5	0.917 4	0.897 3	0.869 8	0.835 5	0.797 5
ACNN	<u>0.984 8</u>	<u>0.978 9</u>	<u>0.976 2</u>	<u>0.970 1</u>	<u>0.965 6</u>	<u>0.954 4</u>	<u>0.954 2</u>	<u>0.942 5</u>	<u>0.932 9</u>	<u>0.920 6</u>	<u>0.911 8</u>	<u>0.890 8</u>

注：排名前 2 的结果加粗显示，最优的结果用下划线标记。

表 7 不同噪声比例下各降噪算法在 SSIM 评价指标上的比较

Table 7 Average SSIM performance on ten commonly used images across different noise ratios

对比算法	噪声比例/%											
	5	10	15	20	25	30	35	40	45	50	55	60
ASVM	0.941 9	0.933 6	<u>0.924 6</u>	<u>0.914 3</u>	<u>0.902 5</u>	<u>0.889 8</u>	<u>0.874 2</u>	<u>0.854 5</u>	<u>0.828 5</u>	<u>0.788 7</u>	0.734 7	0.666 9
PSMF	0.942 4	0.902 3	0.861 2	0.818 1	0.768 2	0.712 5	0.649 5	0.587 1	0.520 9	0.453 7	0.389 3	0.330 8
ROLD-EPR	<u>0.957 9</u>	<u>0.938 7</u>	<u>0.918 2</u>	<u>0.904 5</u>	<u>0.893 7</u>	<u>0.876 3</u>	<u>0.859 6</u>	<u>0.843 5</u>	<u>0.827 2</u>	<u>0.808 9</u>	<u>0.781 3</u>	<u>0.759 0</u>
ROR_NLM	0.928 0	0.920 7	0.911 8	0.901 0	0.887 3	0.870 0	0.846 6	0.814 6	0.770 5	0.713 7	0.647 5	0.578 1
ACNN	<u>0.942 8</u>	0.922 5	0.908 1	0.901 7	0.890 1	0.839 2	0.864 8	0.833 3	0.818 9	0.781 8	<u>0.751 6</u>	<u>0.724 0</u>

注：排名前 2 的结果加粗显示，最优的结果用下划线标记。

为了更加直观地比较所提出算法的实际应用效果，图 4 给出了各算法对受 40% 随机脉冲噪声干扰的 Lena 图像降噪后的效果图，并将其局部(帽檐部分)放大进行对比。从图 4 可以看出，在相同噪声比例下使用 PSMF 算法恢复的图像上依然存在较多的噪声点，ROLD-EPR 算法、ASWM 算法恢复的

图像仍然存在一些比较明显的没有滤除的噪声点，ROR-NLM 算法处理后的图像轮廓较为模糊。从 Lena 图像帽檐部分可以发现图像轮廓保留较好，且没有明显的噪声点。这说明在检测比例噪声器的引导下，新的 RVIN 降噪算法调用了最匹配的 DnCNN 降噪模型，实现了最佳的降噪效果。

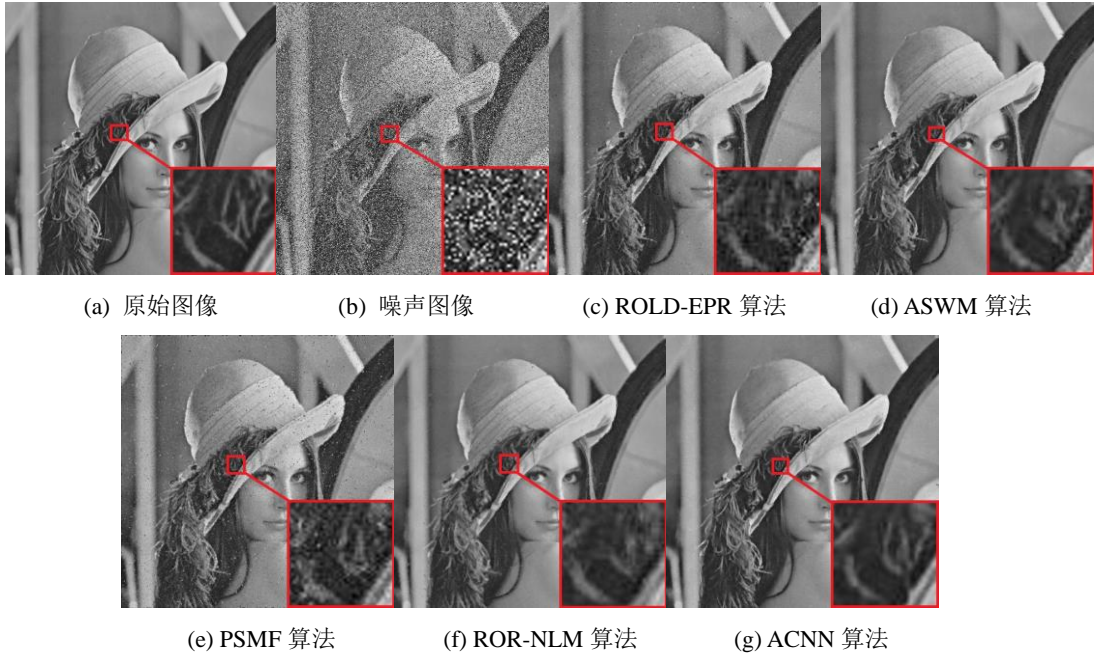


图 4 各算法对 Lena 图像降噪的效果对比

Fig 4 Visual comparison of denoising results with different methods ((a) original image; (b) noisy image; (c) ROLD-EPR; (d) ASWM; (e)PSMF; (f) ROR-NLM; (g) ACNN)

3.4 执行效率

噪声检测器的执行效率也是评价其性能好坏的重要指标之一，关系到整个降噪算法的性能。为了验证所提出噪声检测器的执行效率，将所提出的检测算法结合预先训练的CNN降噪模型对受RVIN脉冲噪声干扰的Lena图像进行复原，并与ASWM、ROLD-EPR、PSMF和ROR_NLM共4种经典随机脉冲噪声降噪算法比较。计算各个参与对比的降噪算法在同一张图像重复执行10次的平均执行时间，数据列在表8中。由表8可知，PSMF算法的执行时间最少，但是从表3~4的实验数据可知其检测正确率也是最差的。而ASWM、ROLD-EPR和ROR_NLM算法中的噪声检测器由于需要与降噪模块配合使用才能获得最终的检测结果，执行时间都非常长。只有本文提出的噪声检测器是基于MLP网络预测模型实现的，与改进DnCNN模型结合使用后能够在降噪效果和执行效率两方面获得最佳的综合性能。

表 8 各噪声检测器结合相应降噪算法的平均执行时间

Table 8 Average execution time of each noise detector combined with corresponding denoising algorithm

Method	ROLD-EPR	ASWM	PSMF	ROR-NLM	ACNN
时间	12.13	172.02	0.51	84.91	3.83

4 结 论

本文提出了一种基于MLP网络粗精相结合的两阶段RVIN随机噪声比例检测器。与现有的大多数噪声检测器需要与某降噪算法串行迭代执行方式不同的是，所提出的噪声比例检测器是基于具有强大映射能力的MLP网络训练的，一旦预测模型训练完成，其进行噪声比例预测的执行时间非常短，且采用粗精相结合的两阶段预测策略能够有效地保证其检测准确性。大量实验数据表明：相较于参与比较的各类经典随机脉冲噪声降噪算法而言，DnCNN降噪算法在结合所提出的噪声比例检测器后，能调用与待降噪图像最为匹配的降噪模型完成降噪，从而实现了盲降噪，并且改进后的RVIN降噪算法在执行效率和降噪后的图像质量两个方面都很获得最佳的性能。未来的研究，可进一步改进噪声比例预测方法，提高其预测精度，为调用DnCNN降噪模型提供更为精准的依据，从而可以进一步提高RVIN降噪算法的降噪效果。

参考文献(References)

[1] Taherkhani F, Jamzad M. Restoring highly corrupted images by impulse noise using radial basis functions

- interpolation[J]. *IET Image Processing*, 2018, 12(1): 20-30. [DOI: 10.1049/iet-ipr.2016.0521]
- [2] Yang H, Chen L T, Qiu H. Denoising algorithm for random-valued impulse noise based on weighted spatial local outlier measure[J]. *Journal of Computer Applications*, 2016, 36(10): 2826-2831. [杨昊, 陈雷霆, 邱航. 基于加权空间离群点度量的随机脉冲噪声降噪算法[J]. *计算机应用*, 2016, 36(10): 2826-2831.] [DOI: 10.11772/j.issn.1001-9081.2016.10.2826]
- [3] Singh N, Thilagavathy T, Lakshmi Priya R T, et al. Some studies on detection and filtering algorithms for the removal of random valued impulse noise[J]. *IET Image Processing*, 2017, 11(11):953-963. [DOI: 10.1049/iet-ipr.2017.0346]
- [4] 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. [DOI: 10.1117/1.jei.27.1.013001]
- [5] Chen T, Wu H R. Adaptive impulse detection using center-weighted median filters[J]. *IEEE Signal Processing Letters*, 2001, 8(1): 1-3. [DOI: 10.1109/97.889633]
- [6] Dong Y Q, Xu S F. A new directional weighted median filter for removal of random-valued impulse noise[J]. *IEEE Signal Processing Letters*, 2007, 14(3): 193-196. [DOI: 10.1109/LSP.2006.884014]
- [7] Akkoul S, Lédée R, Leconge R, et al. A new adaptive switching median filter[J]. *IEEE Signal Process Letters*, 2010, 17(6): 587-590. [DOI: 10.1109/LSP.2010.2048646]
- [8] 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. [DOI: 10.1109/tip.2005.857261]
- [9] Turkmen I. The ANN based detector to remove random-valued impulse noise in images[J]. *Visual Communication and Image Representation*, 2016, 34(January): 28-36. [DOI: 10.1016/j.jvcir.2015.10.011]
- [10] Song Y F, Li J, Wang X G, et al. Single image dehazing using ranking convolutional neural network[J]. *IEEE Transactions on Multimedia*, 2018, 20(6): 1548-1560. [DOI: 10.1109/TMM.2017.2771472]
- [11] Shi Y G, Hao H Y, Liu Z W. Cascaded convolutional neural network based hippocampus subfields segmentation[J]. *Journal of Image and Graphics*, 2018, 23(1): 74-83. [时永刚, 郝华胤, 刘志文. 串行处理卷积神经网络的海马子区分割[J]. *中国图象图形学报*, 2018, 23(1): 74-83.] [DOI: 0.11834/jig.170334]
- [12] 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. [DOI: 10.1109/TIP.2017.2662206]
- [13] Divakar N, Babu R V. Image denoising via CNNs: An adversarial approach[C]//*Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. Honolulu, HI, USA: IEEE, 2017: 1076-1083. [DOI: 10.1109/CVPRW.2017.145]
- [14] 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. [DOI: 10.1117/12.643267]
- [15] Burger H C, Schuler C J, Harmeling S. Image denoising: Can plain neural networks compete with BM3D? [C]//*Proceedings of the 2012 IEEE Conference on Computer Vision and Pattern Recognition*. Providence, RI, USA: IEEE, 2012: 2392-2399. [DOI: 10.1109/CVPR.2012.6247952]
- [16] Gu S H, Zhang L, Zuo W M, et al. Weighted nuclear norm minimization with application to image denoising[C]//*Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition*, Columbus, OH, USA: IEEE, 2014: 2862-2869.[DOI: 0.1109/CVPR.2014.366]
- [17] 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*, 2016, 39(6): 1256-1272. [DOI: 10.13140/RG.2.1.2460.1446]
- [18] Appina B, Khan S, Channappayya S S. No-reference stereoscopic image quality assessment using natural scene statistics[J]. *Signal Processing Image Communication*, 2016, 43(April): 1-14. [DOI: 10.1016/j.image.2016.02.001]
- [19] Weng Y C, Tian Y, Lu D M, et al. Fine-grained bird classification based on deep region networks[J]. *Journal of Image and Graphics*, 2017, 22(11): 1521-1531. [翁雨辰, 田野, 路敦民, 等. 深度区域网络方法的细粒度图像分类[J]. *中国图象图形学报*, 2017, 22(11): 1521-1531.] [DOI: 10.11834/jig.170262]

- [20] Zhu H G, Chen X G, Dai W Q, et al. Orientation robust object detection in aerial images using deep convolutional neural network [C]// Proceedings of the 2015 IEEE International Conference on Image Processing(ICIP). Quebec City, QC, Canada: IEEE, 2015: 3735-3739. [DOI: 10.1109/ICIP.2015.7351502]
- [21] Hu Z P, He W, Wang M, et al. Multi-level deep network fused for face recognition[J]. Pattern Recognition and Artificial Intelligence, 2017, 30(5):448-455. [胡正平, 何薇, 王蒙, 等. 多层次深度网络融合人脸识别算法[J]. 模式识别与人工智能, 2017, 30(5): 448-455.] [DOI: 10.16451/j.cnki.issn1003-6059.201705007]
- [22] Soleimany S, Hamghalam M. A novel random-valued impulse noise detector based on MLP neural network classifier[C]// Proceedings of the 2017 Artificial Intelligence and Robotics (IRANOPEN). Qazvin, Iran: IEEE, 2017: 165-169. [DOI: 10.1109/RIOS. 2017. 7956461]
- [23] Hong Y, Zhu W P. Learning visual codebooks for image classification using spectral clustering[J]. Soft Computing, 2018(18): 6077-6086. [DOI: 10.1007/s00500-017-2937-4]
- [24] Adam Coates and Andrew Y. Ng. The importance of encoding versus training with sparse coding and vector quantization[C]// Proceedings of the International Conference on Machine Learning (2011). Bellevue, Washington, USA: ACM, 2011: 921-928. [DOI: 10.1109/TPEL. 2005. 869755]
- [25] Abdullah S M, Tischer P, Wijewickrema S, et al. Hierarchical mutual nearest neighbour image segmentation[C]// Proceedings of the 2016 International Conference on Digital Image Computing: Techniques and Applications (DICTA). Gold Coast, QLD, Australia: IEEE, 2016:1-8. [DOI: 10.1109/DICTA.2016.7797047]
- [26]Zhang 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 Process. 1999, 46(1): 78-80. [DOI: 10.1109/82.749102]
- [27] Xiong B, Yin Z P. A universal denoising framework with a new impulse detector and nonlocal means[J]. IEEE Transactions on Image Process, 2012, 21(4): 1663-1675. [DOI: 10.1109/TIP. 2011. 2172804]

作者简介



于海雯, 1972年生, 女, 讲师, 主要研究方向为图形图像处理技术和机器视觉。

E-mail: yuhaiwen@ncu.edu.cn



徐少平, 通信作者, 男, 1976年生, 教授, 博士生导师, 主要研究方向包括图形图像处理技术、机器视觉、虚拟手术仿真等。

E-mail: xushaoping@ncu.edu.cn;

易昕炜: 男, 本科生, 主要研究方向为图像处理。

E-mail 6105117013@email.ncu.edu.cn

张贵珍, 女, 硕士研究生, 主要研究方向为图像处理和机器视觉。

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

刘婷云, 女, 硕士研究生, 主要研究方向为图像处理和机器视觉。

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