

## 自适应深度残差椒盐噪声滤除算法

邓森<sup>1,2,3)</sup>, 徐进轩<sup>1,2,3)</sup>, 梁鹿鸣<sup>4)</sup>, 杨珉<sup>5)</sup>, 谢浩然<sup>6)</sup>, 王富利<sup>7)</sup>, 汪俊<sup>1)</sup>, 魏明强<sup>1,2,3)\*</sup>, 郭延文<sup>3)</sup>

<sup>1)</sup>(南京航空航天大学计算机科学与技术学院 南京 210016)

<sup>2)</sup>(模式分析与机器智能工业和信息化部重点实验室 南京 210016)

<sup>3)</sup>(南京大学计算机软件新技术国家重点实验室 南京 210023)

<sup>4)</sup>(Microsoft Research Seattle 90876)

<sup>5)</sup>(吉林大学软件学院 长春 130012)

<sup>6)</sup>(香港岭南大学电脑及决策科学学系 香港 999077)

<sup>7)</sup>(香港公开大学科技学院 香港 999077)

(mqwei@nuaa.edu.com)

**摘要:** 为了在去除图像中椒盐噪声的同时最大程度地避免产生色彩失真与边缘模糊等瑕疵, 提出基于深度残差网络的椒盐噪声自适应滤除算法. 将图像去噪分解为 2 步. 首先, 为了让网络模型能够处理不同尺度密度的椒盐噪声, 提高网络模型的鲁棒性, 先对图像进行自适应预处理以去除高频信息; 其次, 构建深度残差网络模型, 训练出能将预处理后的图像映射到干净图像的函数. 大量实验结果表明, 文中算法不仅在保留图像边缘细节和去除高密度椒盐噪声方面均优于传统和基于机器学习的椒盐噪声去除技术, 可有效地避免出现色彩失真和条纹等瑕疵. 同时, 其在 BSD300 数据集上去噪效果优于其他算法.

**关键词:** 椒盐噪声; 残差网络; 图像去噪

**中图分类号:** TP391.41 **DOI:** 10.3724/SP.J.1089.2020.17941

## Adaptive Salt-and-Pepper Denoising Based on Deep Residual Network

Deng Sen<sup>1,2,3)</sup>, Xu Jinxuan<sup>1,2,3)</sup>, Liang Luming<sup>4)</sup>, Yang Min<sup>5)</sup>, Xie Haoran<sup>6)</sup>, Wang Fuli<sup>7)</sup>, Wang Jun<sup>1)</sup>, Wei Mingqiang<sup>1,2,3)\*</sup>, and Guo Yanwen<sup>3)</sup>

<sup>1)</sup>(College of Computer Science & Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 210016)

<sup>2)</sup>(MIT Key Laboratory of Pattern Analysis and Machine Intelligence, Nanjing 210016)

<sup>3)</sup>(State Key Laboratory for Novel Software Technology, Nanjing University, Nanjing 210023)

<sup>4)</sup>(Microsoft Research, Seattle 90876)

<sup>5)</sup>(College of Software, Jilin University, Changchun 130012)

<sup>6)</sup>(Department of Computing and Decision Sciences, Lingnan University, Hong Kong 999077)

<sup>7)</sup>(College of Science and Technology, The Open University of Hong Kong, Hong Kong 999077)

**Abstract:** To remove salt-and-pepper noise with minimal degradation (e.g., edge blurring, color deviation, and stripe) of image intrinsic properties, we present an adaptive salt-and-pepper denoising method based on a deep residual network. The main idea of this paper is to simplify image denoising into two steps. Firstly, in order to enable the network model to handle different-densities salt-and-pepper noises and improve the ro-

收稿日期: 2019-06-24; 修回日期: 2020-03-31. 基金项目: 国家自然科学基金(61502137); 中央高校基本科研业务费(NJ2019010); 南京大学计算机软件新技术国家重点实验室开放课题(KFKT2018B20); 香港岭南大学香港商学研究所 2019-20 种子研究基金(190-009); 香港岭南大学种子研究基金(102367); 香港岭南大学陈斌博士数据科学机构项目(LEO Dr David P. Chan Institute of Data Science); 南京航空航天大学研究生创新基地(实验室)开放基金(Kfjj20191601). 邓森(1997—), 男, 硕士研究生, 主要研究方向为图像处理; 徐进轩(1994—), 男, 硕士研究生, 主要研究方向为计算机视觉; 梁鹿鸣(1985—), 男, 博士, 高级研究员, 主要研究方向为深度学习; 杨珉(1997—), 男, 硕士研究生, 主要研究方向为图形学; 谢浩然(1985—), 男, 博士, 副教授, 博士生导师, 主要研究方向为机器学习; 王富利(1973—), 男, 博士, 博士生导师, 主要研究方向为信息检索; 汪俊(1981—), 男, 博士, 教授, 主要研究方向为数字几何处理; 魏明强(1985—), 男, 博士, 副教授, 硕士生导师, 论文通讯作者, 主要研究方向为计算机图形学; 郭延文(1980—), 男, 博士, 教授, CCF 会员, 主要研究方向为计算机图形学.

business of the network model, we remove the high frequency information using adaptive windows as the first step. Secondly, we construct an effective deep residual network model to train a function which can map the pre-processed images to their corresponding ground truths. Qualitative and quantitative experiments show that not only can our method avoid problems such as color distortions and streaks, but also our method outperforms the state-of-the-art learning-based and traditional approaches, in terms of both handling inputs with different levels of noises and revealing high-fidelity image edges. Meanwhile, the performance on BSD300 evaluated in PSNR shows superiority over the competitors.

**Key words:** salt-and-pepper noise; residual network; image denoising

图像信号在采集、传输和接收的过程中,易受到外界因素干扰而产生椒盐噪声<sup>[1]</sup>.在进一步对图像进行分析分割和目标识别等工作之前,需要去除图像中的椒盐噪声,以减小椒盐噪声对后续图像分析处理工作的影响.

椒盐噪声是一种典型的脉冲噪声,被扰动的像素值通常为极端值(极大或极小值).对于特定噪声密度  $p$  (范围为 0~1)的椒盐噪声,其数学公式为

$$I(i, j) = \begin{cases} I(i, j), & r_1 \geq p \\ 0, & r_1 < p \text{ 且 } r_2 \geq 0.5 \\ 255, & r_1 < p \text{ 且 } r_2 < 0.5 \end{cases}$$

其中,  $I(i, j)$  为含噪声图像在  $(i, j)$  处的像素值;  $r_1$  和  $r_2$  是范围为 0~1 的随机数.

由于椒盐噪声点位于极端值附近,去除椒盐噪声的同时通常会产生条纹、色彩失真和边缘模糊等问题;因此,在去除椒盐噪声的同时,如何最大限度地避免上述问题的发生是去除椒盐噪声所面临的难题与挑战.

目前去除椒盐噪声的方法主要分为以下几类.一类是基于改进中值滤波去噪声方法<sup>[2-6]</sup>,其利用图像局部相似性来去除椒盐噪声,但由于对噪声点和非噪声点采取相同的操作,此类算法在去噪时不可避免地会模糊图像边缘细节.

另一类方法是基于分步策略的去噪算法<sup>[7-10]</sup>,它首先检测出图像中的椒盐噪声点,然后采用特定的去噪策略将噪声点替换掉,而非噪声点则不做处理.此类算法能有效地去除图像中的噪声,但基于策略的不同会带来条纹、色彩失真等问题.

随着机器学习理论知识的发展和计算机计算能力的进步,基于深度学习的图像去噪方法,如 DNCNN<sup>[11]</sup>, Deep Image Prior<sup>[12]</sup>和 FFDNet<sup>[13]</sup>等,都取得了较为优异的去噪结果.但上述算法旨在消除图像中的高斯白噪声,均无法有效地处理椒盐噪声,尤其是高密度椒盐噪声.

综上所述,如何有效地去除图像中的椒盐噪声是一个经过充分研究但尚未完全解决的棘手问题.基于椒盐噪声的先验性知识并借鉴传统方法的思路,同时将其与深度学习相结合,本文提出了基于深度残差网络的椒盐噪声自适应滤除算法.本文算法在去噪的同时,既能保留图像细节,又能避免出现条纹和色彩失真等问题,极大地提高了图像质量.

## 1 相关工作

作为一种典型的脉冲图像噪声,椒盐噪声会使被扰动的像素值处于极端值附近.针对此特性,中值滤波器(median filter, MF)通过将待处理点的像素值替换为滤波窗口中值的方式,可有效地去除图像中的椒盐噪声.但其去噪效果随着噪声密度的增大而下降,同时滤波的过程也会使图像中原本的细节失真,产生图像边界模糊的问题. Brownrigg<sup>[2]</sup>提出基于权值的加权滤波器(weight median filter, WMF),在传统 MF 的基础上引入了权重,使得图像去噪过程有更强的适应性.这在一定程度上解决了图像边缘模糊等问题,但无法从高密度椒盐噪声中恢复图像.在此基础上, Zhang 等<sup>[6]</sup>提出了自适应加权平均滤波器(adaptive weight median filter, AWMF),通过改变滤波窗口的大小增强加权滤波器在不同密度噪声下的鲁棒性;这样的改进使得原有算法能够在高密度噪声下有效地恢复图像.

为了改善去除高密度椒盐噪声后图像质量下降等问题, Srinivasan 等<sup>[7]</sup>提出了基于决策(decision-based algorithm, DBA)的 MF,该方法将去噪分为 2 步: (1) 首先利用椒盐噪声的先验性知识(噪声点的像素值位于 0 或 255 极值点附近)来检测出图像中的噪声点; (2) 对于检测出的噪声点,使用其邻域内的非噪声点的值来替换噪声点的值.该算法能够大幅度提升图像恢复后的质量,但在某

些特殊情况下会产生条纹和色彩失真等问题. 基于 DBA, Nair 等<sup>[8]</sup>提出了基于改进决策(improved decision based algorithm, IDBA)的 MF, Balasubramanian 等<sup>[14]</sup>提出了基于概率决策的滤波器(probabilistic decision based filter, PDBF). 与 DBA 的 MF 思路类似, 该类算法是 DBA 的改良版本. 虽然该类改良版的算法相较于 DBA 有更优异的去噪效果, 但仍旧无法避免出现类似色彩偏移和条纹等问题.

近些年, 一些针对椒盐噪声的去噪方法被相继提出, 并取得了不错的去噪效果. Aiswarya 等<sup>[9]</sup>提出了非对称修剪中值滤波器(unsymmetrical trimmed median, UTMF), Esakkirajan 等<sup>[10]</sup>提出了基于决策的非对称修剪中值滤波器(modified decision based UTMF, MDBUTMF). Veerakumar 等<sup>[15]</sup>提出了基于全局决策的非对称修剪中值滤波器(modified decision based UTMF global, MDBUTMF\_GM). 该类算法与 DBA 相似, 同样是将去噪分为检测噪声和替换噪声点 2 步. 不同之处在于, 该类算法在替换噪声点时可以适应性地选择滤波窗口中的均值或是近似中位数, 因此它在处理高密度噪声时取得比前者更好的效果. 但在某些特殊情况下, 如黑白相间或交替的情况下, 该算法仍旧会出现色彩偏移和条纹等问题. Erkan 等<sup>[16]</sup>提出了对椒盐噪声采用不同的中值滤波(different applied median filter, DAMF)的方法, 并取得了良好的去除椒盐噪声的效果.

随着深度学习理论的发展和计算机计算能力的提升, 深度学习被广泛应用于图像处理中, 各种基于深度学习的网络模型被提出并用于图像去噪.

Jain 等<sup>[17]</sup>首次将卷积神经网络(convolutional neural networks, CNN)模型应用于图像去噪. 该方法不仅获得比传统的小波和隐马尔可夫模型更好的去噪效果和更高的效率, 而且还表明特定形式

下的 CNN 模型可以视为马尔可夫模型推理的近似形式. Xie 等<sup>[18]</sup>将深度学习理论与图像去噪结合起来, 提出了基于栈式的深度自编码模型进行图像去噪和恢复. Zhang 等<sup>[11]</sup>提出了更深层的 CNN 模型(denoising convolutional neural networks, DNCNN)用于图像去噪, 首次尝试训练一个从被噪声污染的图像中得到残差噪声图的模型, 最终通过将含噪声的原图像减去噪声残差图的方式得到最终的去噪图像. 上述算法旨在消除高斯白噪声, 并不能较好地处理椒盐噪声. Fu 等<sup>[19]</sup>提出了将 non-local switching filter(NLSF)与 CNN 模型相结合的方法来去除椒盐噪声.

去除椒盐噪声是个典型但尚未完全解决的病态问题. 随着计算机视觉的不断发展, 对于原始图像数据的质量需求也越来越高, 图像质量的高低甚至能影响后续图像分析处理结果. 作为典型图像噪声之一的椒盐噪声也是降低图像质量的一大因素. 为了在去除椒盐噪声同时解决上述算法所存在的问题, 本文提出了基于残差网络的椒盐噪声自适应滤波算法, 在滤除椒盐噪声的同时能够保留和恢复图像细节, 并避免出现条纹与色彩失真等问题的发生.

## 2 基于残差网络的自适应去噪

针对椒盐噪声去除和图像细节保留问题, 本文进行了相关研究, 提出了基于深度残差网络的自适应去噪算法, 将自适应的预处理算法和深度残差去噪神经网络相结合, 在完成对不同密度椒盐噪声去除的同时, 最大限度地保留图像中的细节. 主要思路分为 2 步: (1) 采用自适应窗口预处理算法去除图像中部分噪声和低频信息; (2) 采用深度残差网络将深度学习与图像去噪相结合, 去除剩余部分噪声并修复图像细节, 避免产生条纹、色彩失真和图像模糊等问题; 具体流程如图 1 所示.




图 1 去除椒盐噪声流程图

## 2.1 自适应窗口预处理

通常, 滤波器中滤波窗口的大小直接关联着去噪效果的好坏. 滤波窗口越小, 越有利于保留图像边缘细节, 但随着椒盐噪声密度的增大, 其去噪效果越差. 滤波窗口越大, 越有利于处理高密度的椒盐噪声, 但会造成图像边缘细节丢失, 使图像变模糊.

因此, 本文提出随着椒盐噪声密度增大而自适应变化窗口的预处理算法: (1) 先将各个滤波窗口中最大与最小值的像素点检测为噪声点; (2) 如滤波窗口中心为噪声点, 剔除其滤波窗口中所有的噪声点, 如滤波窗口还剩余像素点则返回非噪声中值来代替原噪声点; 否则扩大滤波窗口的大小再重复上述操作; (3) 假设窗口扩大 3 次后仍旧无法得到有效中值, 则保留原像素点的值不变; 通过上述过程, 就能达到让滤波窗口随着椒盐噪声密度的提升而自适应增大的目的.

自适应窗口预处理步骤如下:

输入. 含椒盐噪声图像  $I$ .

输出. 自适应窗口预处理后的图像  $O$ .

Step1. 提取图像  $I$  中  $3 \times 3$  大小窗口的像素点.

Step2. 剔除各个窗口中的最大/最小值, 若还剩余像素点, 返回剩余像素点的中值; 否则扩大窗口大小继续剔除最值.

Step3. 若窗口大小扩大到  $7 \times 7$  且剔除最值后窗口仍未剩余像素点, 停止扩大窗口大小并返回窗口中心点处原值.

在本文算法中, 滤波窗口大小的初始值被设置为  $3 \times 3$ . 当剔除该滤波窗口的噪声点后没有剩余像素点时(即滤波窗口全为椒盐噪声), 就代表噪声密度较大; 此时提升窗口大小至  $5 \times 5$ , 并重复上述过程. 基于统计概率学的知识, 即使图像被 90%密度的椒盐噪声所污染, 其在  $7 \times 7$  的滤波窗口中全为噪声点的概率是极小的. 假设出现  $7 \times 7$  的滤波窗口中全为噪声点的情况, 则极有可能在原图像中本就含有值为 0 或 255 的像素点(原背景图像为黑色或白色), 故不对该噪声点进行替换修改.

## 2.2 深度残差网络模型

He 等<sup>[20]</sup>提出了深度残差网络, 其认为基于深度残差网络的模型比基于 DCNN 的模型能更好、更快地收敛. 受此启发, 本文构建了深度残差网络去噪模型, 以此来去除在自适应预处理后仍未被去除的噪声点, 并修复图像细节. 本文的网络模型如图 2 所示.

如图 2a 所示, 每个残差块由输入层和 2 个 CNN 层组成, 每个 CNN 层都拥有 64 个滤波器, 最终残差块的输出为最后的 CNN 层与输入相加的结果. 如图 2b 所示, 本文提出的深度残差网络模型由 32 个残差块组成, 同时本文模型所有的卷积层后都紧接着批正则化层和 ReLU 激活函数层.




图 2 深度网络残差模型结构

由于含高密度椒盐噪声图像的高复杂性, 直接将噪声图像作为输入数据加入到网络模型中并不能取得良好的去噪效果; 但将图像进行预处理后再输入网络中却能达到去除噪声的目的. 本文认为主要原因有以下几点:

(1) 对于受到高密度椒盐噪声污染的图片, 其

大部分像素点都被噪声所污染. 这就导致输入的图像数据中缺少足够的有效信息, 卷积操作很难将仅含少量有效信息的噪声图像恢复回原图像.

(2) 被椒盐噪声所污染的像素值通常位于极值点 0 或 255 附近, 故而受到噪声污染的图像与原图像相对差异较大, 而采用本文自适应预处理后

能有效地减小噪声图像与原图像的相对差异, 客观上降低了噪声图恢复为原图像的难度.

图 3 展示了一维模拟噪声信号、相应窗口 MF 后的结果及本文自适应预处理后的结果, 以此证明本文提出的自适应预处理算法相比 MF 能够降低相对误差, 提高图像有效信息比例.

图 3 所示为一维模拟噪声信号  $y = \sin x$ 、相应窗口 MF 后的结果及本文自适应预处理后的结果. 可以看出, 对于被高密度污染的信号, 经过单纯的  $3 \times 3$  或  $5 \times 5$  窗口大小的 MF 后并不能较好地恢复回原信号, 而经过本文的自适应预处理算法后即可取得较好的去噪效果.

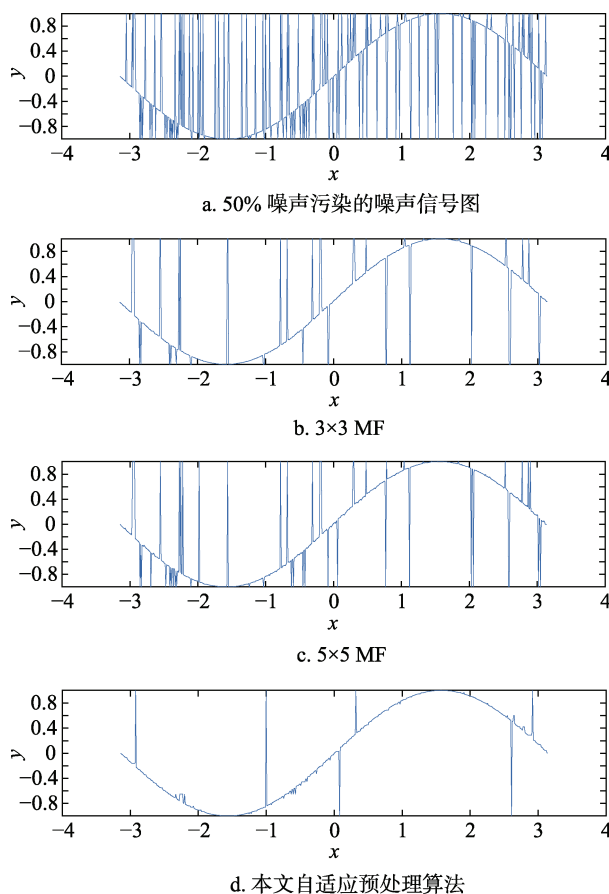


图 3 传统 MF 与本文自适应预处理算法对比

### 2.3 损失函数优化

为了训练出将预处理后的图像映射到干净图像的函数, 需要优化网络的目标损失函数. 通常可采用  $L_2$  损失函数, 即

$$L = \arg \min_{p_i \in I} \|\Phi(p_i) - \hat{p}_i\|^2.$$

其中,  $p_i$  是输入网络中图像的各个点;  $\hat{p}_i$  是原始图

像中对应的点;  $\Phi(\cdot)$  是训练的目标函数.

经过多次实验并受 Lehtinen 等<sup>[21]</sup>工作的启发, 本文采用基于模拟退火算法的  $L_0$  损失函数

$$L = \arg \min_{p_i \in I} (\Phi(p_i) - \hat{p}_i + \varepsilon)^\gamma.$$

其中, 为了避免出现损失函数为零的情况,  $\varepsilon$  被设置为一个极小的数值  $10^{-8}$ ; 初始化退火因子  $\gamma = 2$ , 并随着训练次数的增大而线性减少到 0, 其衰减公式为

$$\gamma = 2 \times \frac{\text{epoch}_a - \text{epoch}_n}{\text{epoch}_a}.$$

其中,  $\text{epoch}_a$  是训练的总批次,  $\text{epoch}_n$  是当前训练批次. 实验证明, 采用  $L_0$  损失函数比采用  $L_2$  损失函数能够让模型更好、更快收敛. 图 4 展示了在每次训练过程中采用不同损失函数时训练集与含噪声密度 70% 的测试集的峰值信噪比 (peak signal to noise ratio, PSNR).

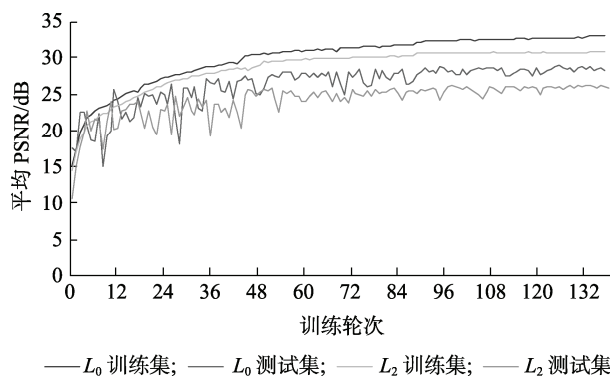


图 4  $L_0$  与  $L_2$  在 BSD300 数据集实验结果对比

### 2.4 深度网络模型对比

本文算法的网络部分借鉴了 Resnet 的残差块架构. 为验证本文所提出网络模型的有效性, 采用相同的数据集将噪声图像经过自适应预处理后分别加入 Resnet50, Resnet101 网络架构中训练.

Resnet50 和 Resnet101 最初设计用于分类任务, 为了使它们更好地适用于图像去噪, 本文去除该网络中的 pooling 层 (用于保持图像维度大小不变) 和最后的 Softmax 分类器; 同时基于公平起见, 所有卷积层的卷积通道数目统一设置为 64.

在图 5 中, 本文算法能够清晰地保留框中人物姿态和细节, 而其他算法在去除椒盐噪声的同时使图像细节模糊. 在图 6 中, 其他算法均不同程度地模糊了棕熊的毛发纹理细节; 而本文算法能够保留一定的毛发纹理细节.




图 5 不同算法在悬崖图像上的去噪结果对比

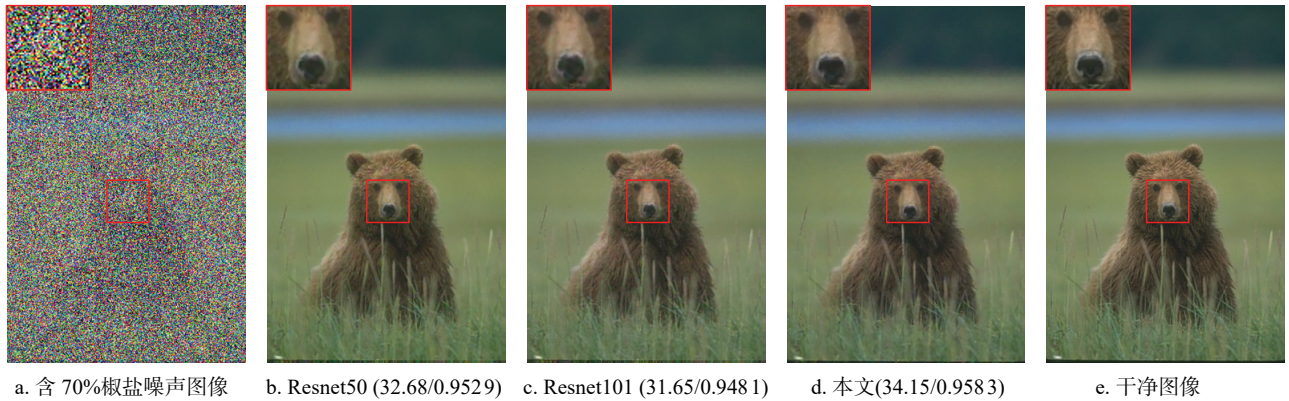




图 6 不同算法在棕熊图像上的去噪结果对比

如表 1 所示, 无论是在低强度椒盐噪声或是高强度椒盐噪声的情况下, 本文所采用的深度网络模型在 PSNR 和结构相似性(structural similarity index, SSIM)的评价指标上均优于其他网络模型. Resnet50 也取得了较好的去噪效果, 但随着网络的层数的加深, Resnet101 的去噪效果反而降低了. 这意味着采用更深层的网络模型并不一定能有效地提高图像去噪的性能.

表 1 不同网络模型 PSNR/SSIM 结果对比

图像	噪声级别/%	Resnet50	Resnet101	本文
	30	<b>32.41/0.972 6</b>	31.74/0.967 5	32.40/0.972 0
	50	32.19/0.967 4	31.52/0.960 8	<b>32.24/0.968 9</b>
	70	31.37/0.942 9	30.86/0.918 1	<b>33.75/0.959 9</b>
	30	37.53/0.989 5	36.38/0.987 2	<b>39.57/0.990 6</b>
	50	36.26/0.985 2	35.41/0.982 9	<b>38.20/0.986 7</b>
	70	32.68/0.952 9	31.65/0.948 1	<b>34.15/0.958 3</b>
BSD300 平均	30	31.23/0.967 7	30.48/0.960 7	<b>32.46/0.977 8</b>
	50	30.11/0.955 9	29.49/0.948 7	<b>31.34/0.966 6</b>
	70	28.12/0.924 1	26.01/0.916 7	<b>28.81/0.933 0</b>

注: 粗体为最好结果.

### 3 实验与分析

#### 3.1 实验图像数据

本文算法与目前主流的去椒盐噪声的算法(包括传统滤波算法和基于深度学习的算法)进行了对比. 为了保证实验的公平有效性, 本文的训练集采

用了与 Fu 等<sup>[19]</sup>提出的 NLSF-CNN 相同的 91 幅图像, 每幅图像被随机引入 10%~90%的椒盐噪声. 在实验过程中, 含噪声的图像先经过自适应预处理后再加入到深度残差网络中, 最终得到去噪后的图像. 为客观地评价去噪效果, 本文采用 PSNR 和 SSIM 作为量化评价标准.

#### 3.2 实验结果对比

本文算法与多个主流的去椒盐噪声的算法在几幅经典图像上和 BSD300 数据集上进行对比, 结果如表 2 所示.




在属于传统滤波器的对比算法中有 AMF<sup>[5]</sup>, AWMF<sup>[6]</sup>, DBA<sup>[7]</sup>, MDBUTMF<sup>[10]</sup>, DAMF<sup>[16]</sup> 和 BPDF<sup>[22]</sup>; 属于深度学习的算法有 DNCNN<sup>[11]</sup>和 NLSF-CNN<sup>[19]</sup>. 所有算法都分别用含 30%, 50%, 70% 噪声的图像进行测试, 它们均采用原作者的代码或严格按照原文进行复现, NLSF-CNN 则直接采其原文所给出的结果. 不同噪声密度的图像中表现最好的结果用加粗表示.

如表 2 所示, 本文算法去噪效果相比传统的椒盐去噪算法有较高的提升幅度, 同时优于基于深度学习的 DNCNN 和 NLSF-CNN 算法.

在高密度椒盐噪声情况下, 本文算法能够有效地保留图像细节. 图 7~图 10 展示了 2 幅属于 BSD300 数据集的图像去噪结果对比图.

在图 7 中, 其他算法在去噪的同时均模糊了蓝色方框中树的纹理, 而本文算法能够清晰地保留树的纹理结构, 且能够较好地保留考拉眼睛部位

表 2 不同算法的 PSNR/SSIM 结果对比

图像	噪声级别/%	AMF <sup>[5]</sup>	AWMF <sup>[6]</sup>	DBA <sup>[7]</sup>	MDBU-TMF <sup>[10]</sup>	BPDF <sup>[22]</sup>	DAMF <sup>[16]</sup>	DNCNN <sup>[11]</sup>	NLSF-CNN <sup>[9]</sup>	本文
	30	23.93/0.935 1	34.88/0.992 0	34.42/0.991 6	32.85/0.987 7	32.31/0.987 0	35.18/0.992 5	<b>36.75/0.994 5</b>	35.38/	35.53/0.993 1
	50	23.63/0.930 1	32.33/0.985 8	30.11/0.988 7	30.40/0.978 9	28.38/0.971 4	31.93/0.984 7	32.62/0.989 0	32.55/	<b>32.93/0.991 4</b>
	70	20.65/0.969 6	29.62/0.974 3	25.84/0.972 9	28.67/0.966 9	23.68/0.933 7	29.30/0.972 8	24.18/0.935 1	30.18/	<b>30.81/0.977 3</b>
	30	24.11/0.784 4	32.10/0.968 0	31.29/0.939 9	28.55/0.940 4	30.34/0.948 0	32.48/0.961 6	34.81/0.977 2		<b>35.60/0.982 6</b>
	50	23.76/0.769 0	30.77/0.949 6	29.54/0.920 1	28.38/0.914 2	26.81/0.876 6	30.61/0.945 4	32.84/0.935 5		<b>33.84/0.951 5</b>
	70	20.28/0.636 6	28.57/0.906 1	26.78/0.868 5	27.79/0.881 6	22.42/0.711 0	28.42/0.902 3	21.98/0.697 2		<b>31.54/0.932 0</b>
	30	20.36/0.775 0	27.94/0.960 8	27.32/0.958 6	24.19/0.942 9	26.84/0.946 8	28.23/0.962 9	31.76/0.979 3		<b>32.78/0.979 6</b>
	50	20.19/0.769 3	26.29/0.933 7	25.82/0.927 6	22.53/0.909 3	23.78/0.891 7	26.11/0.930 7	29.88/0.956 7		<b>31.10/0.970 1</b>
	70	18.35/0.661 9	24.27/0.888 7	23.83/0.870 8	19.76/0.828 0	20.13/0.787 7	24.02/0.883 9	22.62/0.801 2		<b>28.56/0.946 5</b>
BSD300 平均	30	21.54/0.727 6	30.70/0.952 8	29.92/0.943 7	27.30/0.922 6	28.65/0.935 5	30.65/0.954 6	<b>32.58/0.972 8</b>	30.87/	32.46/0.977 8
	50	21.27/0.716 9	28.50/0.922 4	26.32/0.899 5	25.73/0.880 5	24.88/0.860 2	27.79/0.915 6	30.71/0.941 1	27.84/	<b>31.34/0.966 6</b>
	70	18.90/0.628 2	26.01/0.870 3	22.81/0.913 5	23.85/0.828 1	20.82/0.724 3	25.31/0.857 8	22.37/0.781 9	25.35/	<b>28.82/0.933 0</b>

注. 粗体为最好结果, PSNR/dB.

轮廓细节, 其他算法则不能较好地恢复出眼睛的椭圆形轮廓, 甚至还会出现条纹和色彩失真等问题. 如图 8 所示, 由于原图像中纹理结构和背景的复杂性, 其他算法都无法较好地恢复蓝框中窗户的结构, 而本文算法能够较好地从噪声图像中复原出蓝框中窗户的轮廓结构. 在去噪过程中,

MDBUTMF 在去噪的过程中引入了新的绿色噪点; 其他算法都产生了一定程度的条纹, 红框中的塔尖都出现不同程度的色彩失真问题, 原本为偏黑的塔尖被恢复为颜色为红、绿或蓝的塔尖; 而本文算法则较为真实地将塔尖的颜色复原. 更多去除椒盐噪声的例子如图 9 和图 10 所示.

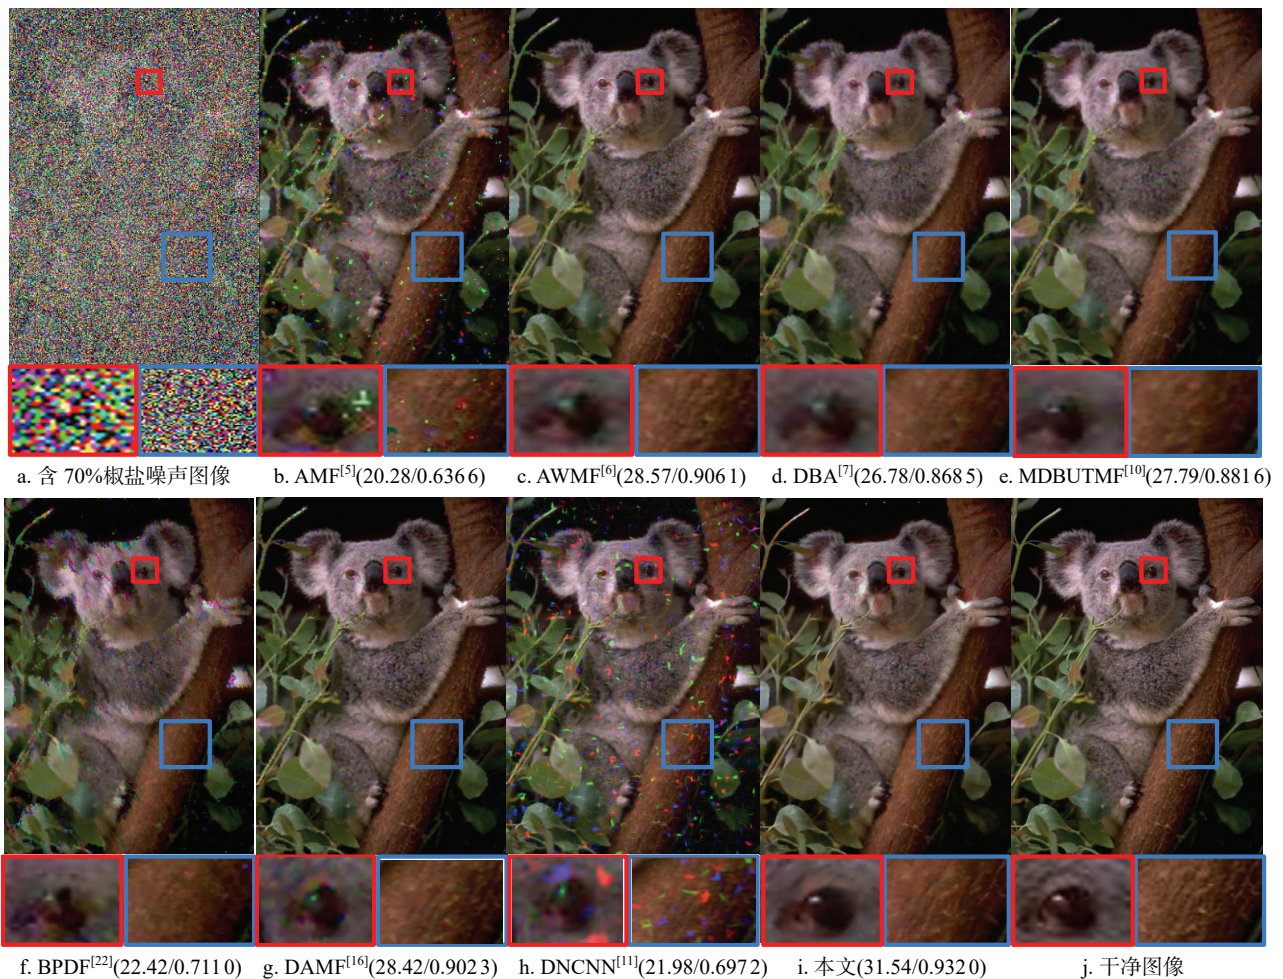


图 7 不同算法在考拉图像上的去噪结果对比

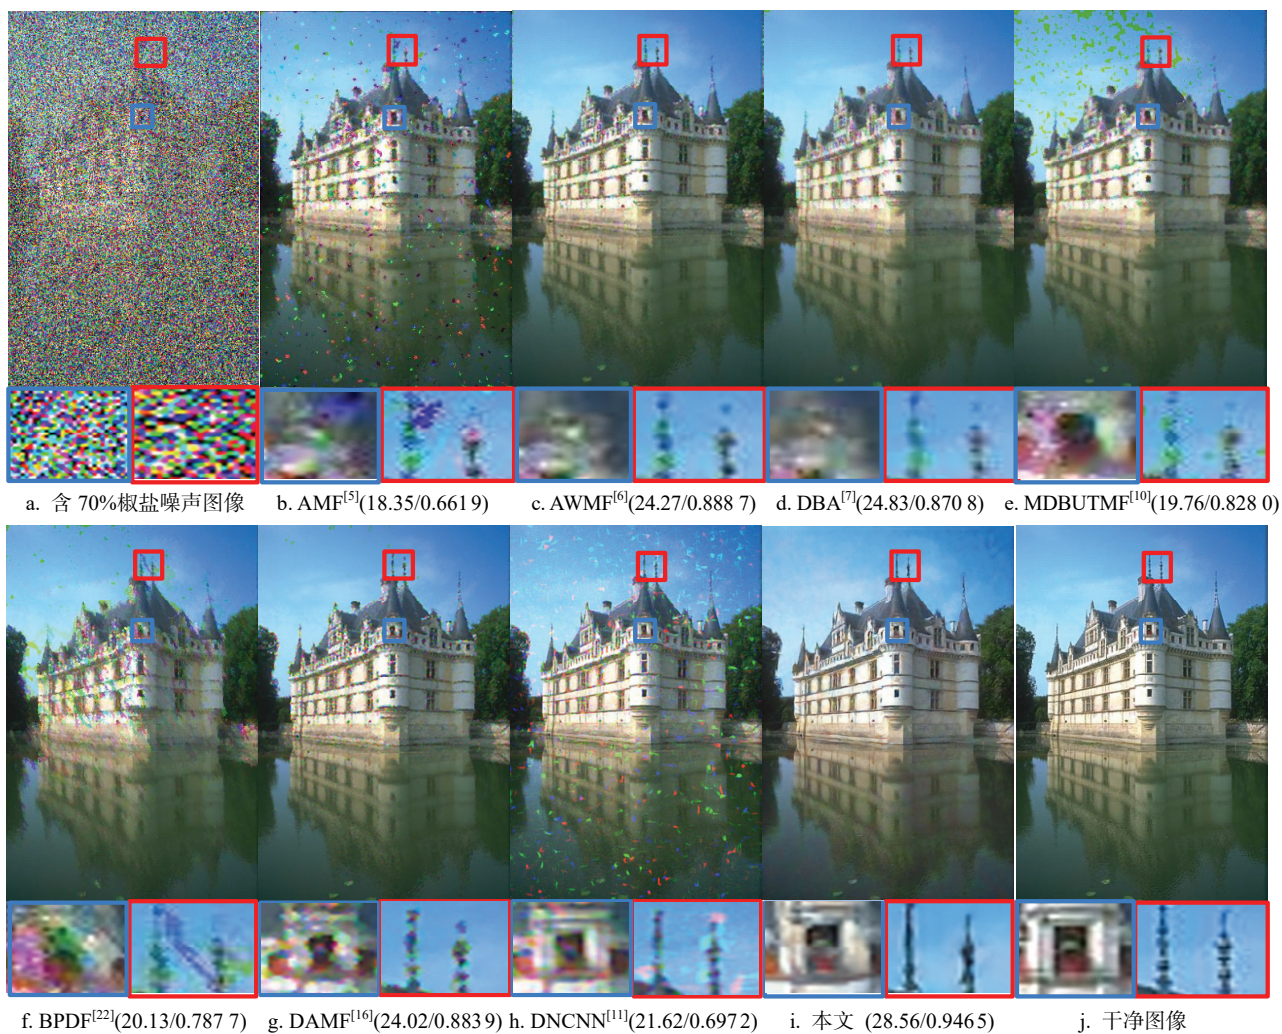


图 8 不同算法在城堡图像上的去噪结果对比

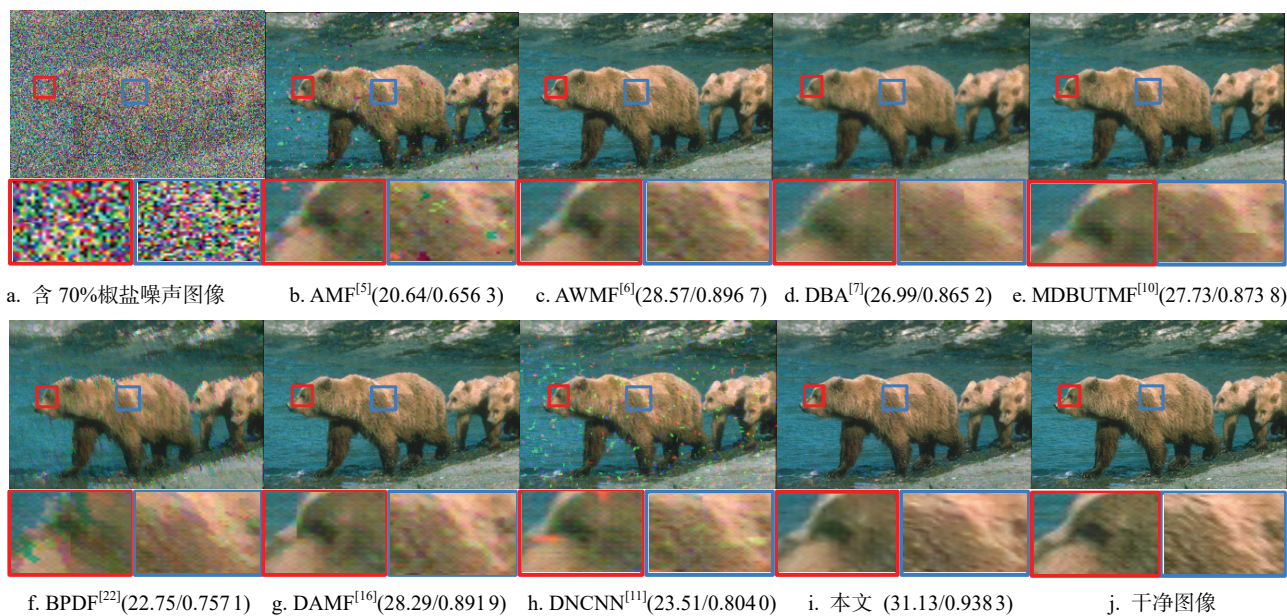


图 9 不同算法在熊群图像上的去噪结果对比



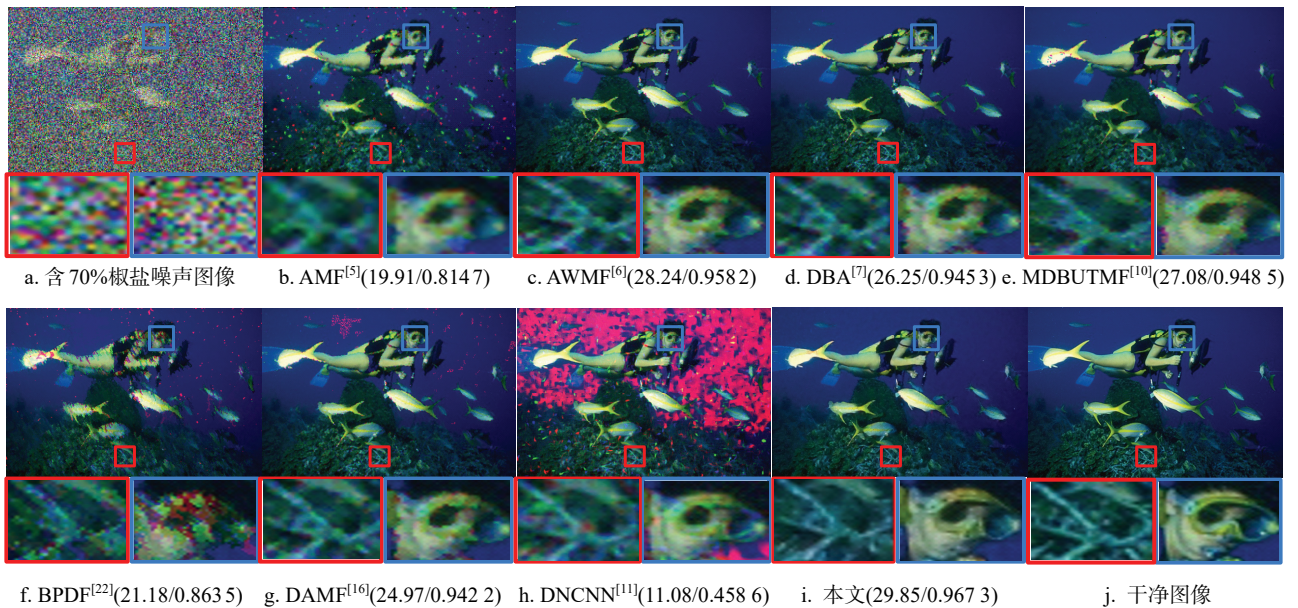


图 10 不同算法在鱼群图像上的去噪结果对比

### 3.3 本文算法限制与讨论

实验证明,即使在高密度噪声的情况下,本文算法仍然表现出较强的鲁棒性,能够在去除噪声的同时有效地避免条纹、色彩失真和边缘模糊等问题.但本文算法仍存在一定的改进空间,例如,先自适应预处理后加入深度残差网络的去除椒盐噪声的算法虽取得不错的去噪效果,但由于没有实现端对端去噪,因此自适应预处理所需要的时间开销也较大.在处理低密度椒盐噪声时,本文算法能够快速地完成去噪工作,随着噪声密度的增大,自适应预处理所需的时间也越多.因此,将来的改进思路集中于如何将本文算法自适应预处理融合进深度神经网络中,以此提高椒盐噪声去噪效果与效率.

## 4 结 语

针对椒盐噪声,提出了基于深度残差网络的自适应去噪算法.根据椒盐噪声的随机性,将算法分成 2 步:(1)先采用自适应预处理方法将部分噪声去除,让受到高密度噪声污染的图像尽可能恢复一部分有效信息;(2)基于深度残差网络,设计训练出能够去除剩余噪声并恢复图像细节的网络模型.大量实验证明,本文算法能够有效地处理不同类型和不同噪声密度图像,即使在高密度噪声的情况下也能够有效地保留图像细节,并避免出现条纹和色彩失真等问题.

### 参考文献(References):

- [1] Long Jingwen, Pu Yifei. Inverse distance weighting method based on BPANN noise detection to remove salt and pepper noise[J]. *Journal of Computer Applications*, 2018: 35(4): 1266-1269(in Chinese)  
(龙敬文, 蒲亦非. 基于 BPANN 噪声检测的反距离加权法滤除椒盐噪声[J]. *计算机应用研究*, 2018: 35(4): 1266-1269)
- [2] Brownrigg D R K. The weighted median filter[J]. *Communications of the ACM*, 1984, 27(8): 807-818
- [3] Ko S J, Lee Y H. Center weighted median filters and their applications to image enhancement[J]. *IEEE Transactions on Circuits & Systems*, 1991, 38(9): 984-993
- [4] Abreu E, Lightstone M, Mitra S K, *et al.* A new efficient approach for the removal of impulse noise from highly corrupted images[J]. *IEEE Transactions on Image Processing*, 1996: 5(6): 1012-1025
- [5] Chan R H, Ho C W, Nikolova M, *et al.* Salt-and-pepper noise removal by median-type noise detectors and detail-preserving regularization[J]. *IEEE Transactions on Signal Processing*. 2005, 14(10): 1479-1485
- [6] Zhang P, Li F. A new adaptive weighted mean filter for removing salt-and-pepper noise[J]. *IEEE Signal Processing Letters*, 2014, 21(10): 1280-1283
- [7] Srinivasan K S, Ebenezer D. A new fast and efficient decision-based algorithm for removal of high-density impulse noises[J]. *IEEE Signal Processing Letters*, 2007, 14(3): 189-192
- [8] Nair M S, Revathy K, Tatabarti R. An improved decision-based algorithm for impulse noise removal[C] // *Proceedings of the Congress on Image and Signal Processing*. Los Alamitos: IEEE Computer Society Press, 2008: 426-431
- [9] Aiswarya K, Jayaraj V, Ebenezer D. A new and efficient algorithm for the removal of high density salt and pepper noise in images and videos[C] // *Proceedings of the 2nd International*

- Conference on Computer Modeling and Simulation. Los Alamitos: IEEE Computer Society Press, 2010: 409-413
- [10] Esakkirajan S, Veerakumar T, Subramanyam A N, *et al.* Removal of high density salt and pepper noise through modified decision based unsymmetrical trimmed median filter[J]. IEEE Signal Processing Letters, 2011, 18(5): 287-290
- [11] Zhang K, Zuo W, Chen Y, *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
- [12] Ulyanov D, Vedaldi A, Lempitsky V. Deep image prior[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2018: 9446-9454
- [13] Zhang K, Zuo W, 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
- [14] Balasubramanian G, Chilambuchelvan A, Vijayan S, *et al.* Probabilistic decision based filter to remove impulse noise using patch else trimmed median[J]. AEU-International Journal of Electronics and Communications, 2016, 70(4): 471-481
- [15] Veerakumar T, Esakkirajan S, Vennila I. An approach to minimize very high density salt and pepper noise through trimmed global mean[J]. International Journal of Computer Applications, 2012, 39(12): 29-33
- [16] Erkan U, Gökrem L, Enginoğlu S. Different applied median filter in salt and pepper noise[J]. Computers & Electrical Engineering, 2018, 70: 789-798
- [17] Jain V, Sebastian Seung H. Natural image denoising with convolutional networks[C] // Proceedings of the 21st International Conference on Neural Information Processing Systems. Cambridge: MIT Press, 2009: 769-776
- [18] Xie J Y, Xu L L, Chen E H. Image denoising and inpainting with deep neural networks[C] // Proceedings of the 25th International Conference on Neural Information Processing Systems. New York: ACM Press, 2012: 341-349
- [19] Fu B, Zhao X Y, Li Y, *et al.* A convolutional neural networks denoising approach for salt and pepper noise[J]. Multimedia Tools and Applications, 2018, 78: 30707-30721
- [20] He K M, Zhang X Y, Ren S Q, *et al.* Deep residual learning for image recognition[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2016: 770-778
- [21] Lehtinen J, Munkberg J, Hasselgren J, *et al.* Noise2noise: learning image restoration without clean data[OL]. [2019-06-24]. <https://arxiv.org/abs/1803.04189>
- [22] Erkan U, Gökrem L. A new method based on pixel density in salt and pepper noise removal[J]. Turkish Journal of Electrical Engineering & Computer Sciences, 2018, 26(1): 162-171