

DOI:10.19651/j.cnki.emt.2212298

# 基于深度神经网络的单幅图像盲去噪算法<sup>\*</sup>

李晨 许雪 郭业才

(无锡学院 无锡 210044)

**摘要:**针对大多去噪网络仅在合成噪声去噪任务上表现良好,且只从单一尺度上提取特征,不能够更好的重构出干净的图像等问题,本文提出了一种多尺度特征融合的真实噪声图像盲去噪算法。该算法的横向网络结构利用自适应密集残差块提取同一尺度的丰富特征,并且有选择性的增强信息量大的特征,纵向网络结构利用金字塔层与编一解码器进一步获得不同的感受野,实现多尺度特征提取,横向同一尺度的特征与纵向不同尺度的特征充分融合更有利于噪声去除,保留图像的边缘细节。在真实噪声测试集(DND和SIDD)上对提出的网络进行评估,峰值信噪比(PSNR)分别为39.62和39.49,结构相似性(SSIM)分别为0.956和0.954。实验结果表明,本文提出的网络取得了更加优越的性能表现。

**关键词:**卷积神经网络;真实噪声图像去噪;自适应密集连接残差;多尺度特征融合

**中图分类号:**TP391.41    **文献标识码:**A    **国家标准学科分类代码:**510.4050

## Blind denoising algorithm for single image based on deep neural network

Li Chen Xu Xue Guo Yecai

(Wuxi University, Wuxi 210044, China)

**Abstract:** Most denoising networks only perform well in the task of synthetic noise denoising, and only extract features from a single scale, which can not better reconstruct a clean image. To solve the above problems, this paper proposes a blind denoising algorithm for real noisy images based on multi-scale feature fusion. The horizontal network structure of the algorithm uses adaptive dense residual blocks to extract rich features of the same scale, and selectively enhance features with large amount of information. The vertical network structure uses pyramid layer and encode-decode to further obtain different receptive fields to realize multi-scale feature extraction. The full fusion of the features of the same horizontal scale and the features of different vertical scales is more conducive to noise removal and retain the edge details of the image. The proposed network is evaluated on the real noise test set (DND and SIDD). The peak signal-to-noise ratio (PSNR) is 39.62 and 39.49 respectively, and the structural similarity (SSIM) is 0.956 and 0.954 respectively. The experimental results show that the network proposed in this paper has achieved better performance.

**Keywords:** convolutional neural network; real noise image denoising; adaptive dense connection residual; multiscale feature fusion

## 0 引言

随着计算机科学和图像技术的迅速发展,图像在医学成像、卫星遥感图像、模式识别、目标追踪与图像分类方面取得了广泛的应用。但是,图像在形成与传输过程中,不可避免会受到噪声的干扰。图像中的噪声往往和信号交织在一起,会使图像本身的细节如边界轮廓、线条等变得模糊不清。被噪声污染的图像会降低图像的质量,导致视觉上的不清晰,严重影响了人们对于图像中有用信息的识别与获

取。同时,噪声图像也妨碍了人们获取图像后进一步的处理任务。现有的图像去噪方法主要有:1)利用自然图像的先验信息进行图像去噪<sup>[1-2]</sup>,比如均值滤波<sup>[3-5]</sup>、中值滤波<sup>[6-8]</sup>、小波变换<sup>[9]</sup>等传统去噪算法。图像的先验知识就是图像数据本身的特性,若能很好的利用自然图像的先验知识,就能从噪声图像上恢复原始图像,但这些算法计算量大,耗时长,不能直接抑制空间变化的复杂噪声。2)运用深度卷积神经网络<sup>[10]</sup>进行图像去噪,比如去噪卷积神经网络(denoising convolutional neural network,DnCNN)<sup>[11]</sup>、快速

收稿日期:2022-12-06

\*基金项目:无锡学院人才启动费(2021r028)、国家自然科学基金(61673222)项目资助

灵活去噪网络 (fast and flexible denoising network, FFDNet)<sup>[12]</sup>、迭代残差卷积神经网络 (iterative residual convolutional neural network, IRCNN)<sup>[13]</sup> 等算法。Xu 等<sup>[14]</sup>提出的一种外部先验引导内部先验学习的方法,该网络对真实噪声进行去噪任务后,得到的图像中仍有大量噪声残留;Zhou 等<sup>[15]</sup>提出的像素重组下采样 (pixel-shuffle down-sampling, PD) 去噪网络,仅使用与合成像素无关的加性高斯白噪声 (additive white gaussian noise, AWGN) 数据进行训练,训练出的模型可以适应真实噪声,但去噪后的图像模糊且会出现色彩失真问题;Guo 等<sup>[16]</sup>根据图像信号处理器 (image signal processor, ISP) 的工作原理和异方差高斯噪声提出了一种去噪模型,可以对真实噪声图像进行去噪,但去噪后的图像过于平滑,细节丢失严重,依旧得不到较好的视觉效果。Anwar 等<sup>[17]</sup>提出了一种基于特征注意的单级去噪网络,但缺乏对图像内容的自适应性。上述方法多用于合成噪声图像。Wei 等<sup>[18]</sup>提出在低光环境下使用异方差高斯模型合成数据集训练,达到去除真实噪声的目的。Wang 等<sup>[19]</sup>提出将噪声分布建模为高斯泊松分布,然后使用线性回归方式预测分布参数,拟合真实噪声。Zamir 等<sup>[20]</sup>提出了一个多阶段渐进训练网络架构,用于在不同阶段之间进行信息交换,在真实图像去噪方面取得了优越的成果。

根据噪声产生的原因可将噪声分为内部噪声和外部噪声两类。按照统计观点可将噪声分为平稳噪声和非平稳噪声。根据幅度分布统计特性可将噪声分为高斯噪声和瑞丽噪声。此外,噪声还可以按照其他方式进行分类,如加性噪声、乘性噪声、量化噪声和“椒盐”噪声。大多数研究者们致力于如何更好地去除加性高斯白噪声对图像的干扰<sup>[11-13,21]</sup>,虽然随着噪声源数量的上升,真实环境中的噪声可以近似看成高斯分布,但是,真实环境中的噪声往往不是由单一源头造成的,而是很多不同噪声源的复合体,所以对于 AWGN 去噪性能较好的网络,处理真实噪声图像的效果不太理想。

针对上述现有图像去噪方法仅在合成噪声方面表现优异,真实噪声无法完全去除问题,本文提出了一种多尺度特征融合的真实噪声图像盲去噪算法 (multi-scale feature fusion image denoising network, MEIDNet),以下简称 MFIDNet,提出算法不同于以往算法,而是致力于去除真实噪声。该算法以自适应密集残差块为网络横向结构,可以从先前和当前局部特征中学习更丰富的特征,让网络有选择性的增强信息量大的特征,但特征尺度太过单一,为了增加不同的感受野,本文设计多尺度特征提取模块为网络纵向结构,金字塔池化可以得到不同尺度的分层,其次,在每个金字塔分层后搭建具有跳跃连接的 U-Net<sup>[22]</sup>,有助于从先前网络提取的特征中去除噪声,在 U-Net 最小尺度中间加入扩张卷积,更好的保留了图像细节。将纵向结构穿插在横向结构的不同位置处,实现横向结构与纵向结构互

相弥补,最后将横向结构与纵向结构提取的特征进行融合,利用全局残差学习构建去噪后的干净图像。本文提出的算法可以实现对真实噪声图像进行去噪处理,具有较好的去噪效果和实际作用。

## 1 本文提出方法

### 1.1 噪声模型

在数字图像中,噪声主要来源于图像的获取和传输过程。在图像的获取过程中,感光器会受到光照亮度与环境温度的不同而影响图像的成像效果,并产生噪声<sup>[23]</sup>;在图像传输过程中,由于发送与接收设备的不完善及传输信道的不佳等而产生噪声,一般噪声产生的过程如图 1 所示。

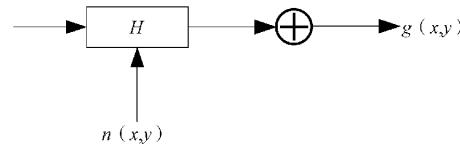


图 1 噪声产生模型

$$g(x,y) = H \times f(x,y) + n(x,y) \quad (1)$$

$f(x,y)$  代表干净的图像信号,  $*$  表示卷积,  $H$  表示获取过程对图像的退化,  $n(x,y)$  表示传输过程中的干扰而产生的噪声,  $g(x,y)$  表示噪声图像。简单的给图像添加高斯噪声无法真正的体现出现实噪声的复杂度和真实度,并且深度学习算法非常依赖于训练数据,用合成噪声数据集训练出来的去噪模型,对真实噪声图像进行去噪并不能得到较好的效果。

### 1.2 MFIDNet 算法设计

通过对文献[22]、[24]和[25]的学习,本文提出的 MFIDNet 的网络横向结构主要由自适应密集连接残差块 (self-adaptive dense connection residual blocks, SDCR) 组成, MFIDNet 的网络纵向结构 PU-Net 是由金字塔模块 (pyramid-block, PB) 和具有跳跃连接和空洞卷积的 U-Net 组成。MFIDNet 结构如图 2 所示。

由图 2 可知,  $x_i$  和  $y_i$  作为网络的输入和输出,  $x_i$  为噪声图像,  $y_i$  为去噪后的干净图像。未进行特别标注的卷积核大小均为  $3 \times 3$ , 使用两层卷积层来提取浅层特征,  $F_1$  用于全局残差学习,此过程可以描述为:

$$F_0 = Conv_2(Conv_1(x_i)) \quad (2)$$

其中,  $F_0$  作为第 2 个卷积操作得到的特征,亦是后续网络的输入。

考虑到 SDCR 块提取的尺度特征太过单一,为了增加不同的感受野,在 SDCR 块后面添加多尺度特征提取模块 PU-Net。假设整个网络有  $I$  个自适应密集连接残差块,3 个网络纵向结构 PU-Net 分别插入在 SDCR 块的  $I/3, 2I/3$  和  $I-1$  后面,多尺度特征和单一尺度特征的进行交替互补得到局部特征  $F_i$ ,综合考虑训练时间长短与参数量大小, MFIDNet 的网络横向结构由 15 个 SDCR 块组成,因此纵

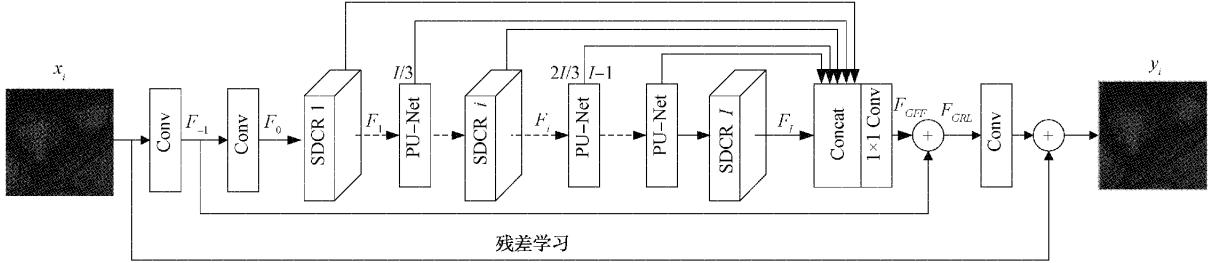


图 2 MFIDNet 网络结构图

向结构 PU-Net 分别插入在第 5 个 SDCR 块、第 10 个 SDCR 块和第 14 个 SDCR 块后面, 将 3 个 PU-Net 分别插入网络的不同位置, 更有利于全局特征的融合和利用。 $\mathbf{F}_i$  可以表示为

$$\mathbf{F}_i = H_{SDCR,i}(\mathbf{F}_{i-1}) = H_{SDCR,i}\{H_{I-1}\{H_{DCR,I-2}\{\cdots H_{2I/3}\{\cdots H_{I/3}[H_{SDCR,1}(\mathbf{F}_0)]\}\}\}\}\} \quad (3)$$

其中,  $H_{SDCR,i}$  可以看作为一个复合函数的操作, 表示第  $i$  个 SDCR 块。

$H_{I-1}$  是第  $I-1$  个 SDCR 块与 MFIDNet 网络中第 3 个 PU-Net 的结合,  $H_{2I/3}$  表示第 3 个 PU-Net 模块, 以此类推  $H_{2I/3}$  和  $H_{I/3}$ 。 $H_{I-1}$ 、 $H_{2I/3}$  和  $H_{I/3}$  的表述如下:

$$(F_1, \dots, F_i, \dots, F_I) \quad (4)$$

通过式(3)提取各个局部特征( $F_1, \dots, F_i, \dots, F_I$ )后, 进一步将局部特征与网络初始阶段提取的浅层特征  $\mathbf{F}_{-1}$  与  $\mathbf{F}_0$  进行密集特征融合, 得到全局融合特征  $\mathbf{F}_{GFF}$  为:

$$\mathbf{F}_{GFF} = Conv[Concat(\mathbf{F}_{-1}, \mathbf{F}_0, \mathbf{F}_1, \dots, \mathbf{F}_i, \dots, \mathbf{F}_I)] \quad (5)$$

其中,  $1 \times 1$  卷积层融合不同层次的特征,  $Concat(\mathbf{F}_{-1}, \mathbf{F}_0, \mathbf{F}_1, \dots, \mathbf{F}_i, \dots, \mathbf{F}_I)$  将局部的特征图进行通道连接, 能够进一步增强全局信息, 再将全局融合特征  $\mathbf{F}_{GFF}$  和  $\mathbf{F}_{-1}$  进行全局残差学习得到特征  $\mathbf{F}_{GRL}$  为:

$$\mathbf{F}_{GRL} = \mathbf{F}_{-1} + \mathbf{F}_{GFF} \quad (6)$$

1) 自适应密集连接残差块 SDCR

自适应密集连接残差块 SDCR 是由密集连接残差块 (dense connection residual blocks, DCR) 模块和压缩激励 (squeeze-and-excitation residual network, SEResNet) 残差模块<sup>[26]</sup>组成。每两个卷积层组成一个 DCR 块, 可充分提取层次空间特征, 每一个特征图之间密集连接起来, 在特征融合之后经过 SEResNet 模块, 此模块加强了对特征图信息的提取, 减弱无用信息对网络的影响, 自适应的调整各通道的特征响应值。SEResNet 模块只会增加很小的计算量, 但却可以极大地提升网络性能, SDCR 详细结构如图 3 所示。

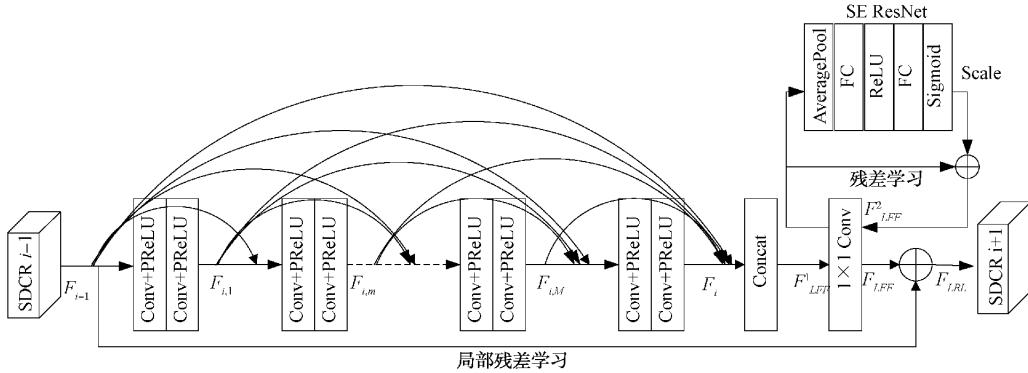


图 3 SDCR 内部结构图

$\mathbf{F}_{i-1}$  和  $\mathbf{F}$  作为第  $i$  个 SDCR 模块的输入和输出, 其中第  $i$  个 SDCR 模块的第  $m$  个卷积层的输出可以表示为

$$\mathbf{F}_{i,m} = \sigma[\mathbf{W}_{i,m}(\mathbf{F}_{i-1}, \mathbf{F}_{i,1}, \dots, \mathbf{F}_{i,m-1})] \quad (7)$$

其中,  $\sigma$  表示激活函数,  $\mathbf{W}_{i,m}$  表示第  $m$  个卷积层的权重。

无需归一化和池化, 每两个卷积层组成一个块, 再将前面各块的输出和当前块的输出连接起来一起作为下一个块的输入, 其中每个卷积层后面只有一个参数整流线性单元 (parametric rectified linear unit, PReLU) 激活函数,

更有利于特征的保留, 将第  $i-1$  个 SDCR 的输出特征与当前各个卷积层的输出特征进行融合, 得到局部融合特征  $\mathbf{F}_{LFF}^1$ , 描述为

$$\mathbf{F}_{LFF}^1 = Concat(\mathbf{F}_{i-1}, \mathbf{F}_{i,1}, \dots, \mathbf{F}_{i,m}, \dots, \mathbf{F}_{i,M}) \quad (8)$$

其中,  $M=6$ ,  $Concat$  表示特征拼接层。

为了能够自适应学习每个通道的权重, 根据该权重去提升有用的特征并抑制用处不大的特征, 所以在局部特征融合后加入 SEResNet 模块, 该模块中的 ReLU 表示修正线性单元 (rectified linear unit, ReLU), AveragePool 表示

平均池化层, FC 表示全连接层(fully connected, FC), Sigmoid 表示激活函数, Scale 表示重标层, Residual 表示残差学习, 该模块的输出用  $\mathbf{F}_{LFF}^2$  表示。

$$\mathbf{F}_{LFF}^2 = F_{\text{Scale}} \{ F_{\text{ex}} [F_{\text{sq}} (\mathbf{F}_{LFF}^1, \mathbf{W})] + \mathbf{F}_{LFF}^1 \} \quad (9)$$

$F_{\text{sq}}(\cdot)$  为压缩函数,  $F_{\text{ex}}(\cdot, \mathbf{w})$  为激励函数,  $F_{\text{Scale}}(\cdot)$  为逐通道加权函数, 平均池化层将特征通道信息压缩成一个实数, 第 1 个特征层可以将特征通道数降到输入的  $1/r$ , 其中  $r=16$  为缩小因子。上一层输出的特征图经 ReLU 函数激活后, 被第 2 个特征层变回到原来的通道数。经第 2 个特征层处理过的特征图通过 Sigmoid 函数的门机制获得  $0 \sim 1$  之间的特征权重, 最后 Scale 层将归一化的权重加权到  $\mathbf{F}_{LFF}^1$  上, 得到 SEResNet 模块的输出  $\mathbf{F}_{LFF}^2$ 。

卷积层最后的总输出为  $\mathbf{F}_{LFF}$ , 再利用局部残差学习提高网络性能以增加和改善信息的流动, 从而精确地去除噪声并

避免梯度消失问题, 第  $i$  个 SDCR 的输出可以有下式获得:

$$\mathbf{F}_{LRL} = \mathbf{F}_{i-1} + \mathbf{F}_{LFF} \quad (10)$$

## 2) 纵向结构 PU-Net

本文算法的纵向结构(PyramidU-Net, PU-Net)是由金字塔池化层和具有跳跃连接的 U-Net 组成, 上一个 SDCR 块的输出作为 PU-Net 输入, 通过池化层得到不同尺度的特征图, 弥补了网络横向结构的尺度单一缺点, 实现了网络并行处理和多尺度特征提取, 并且将 PU-Net 插入在 SDCR 块的不同位置, 更能实现多尺度特征提取与单一尺度特征提取的互相弥补, 充分提取全局信息, 在编码器和解码器之间的最小尺度中引入空洞卷积(dilated convolution, DC)<sup>[27]</sup>, 扩大感受野, 且不增加额外的参数, 减少了图像细节的丢失和不必要的计算成本。PU-Net 的内部结构如图 4 所示。

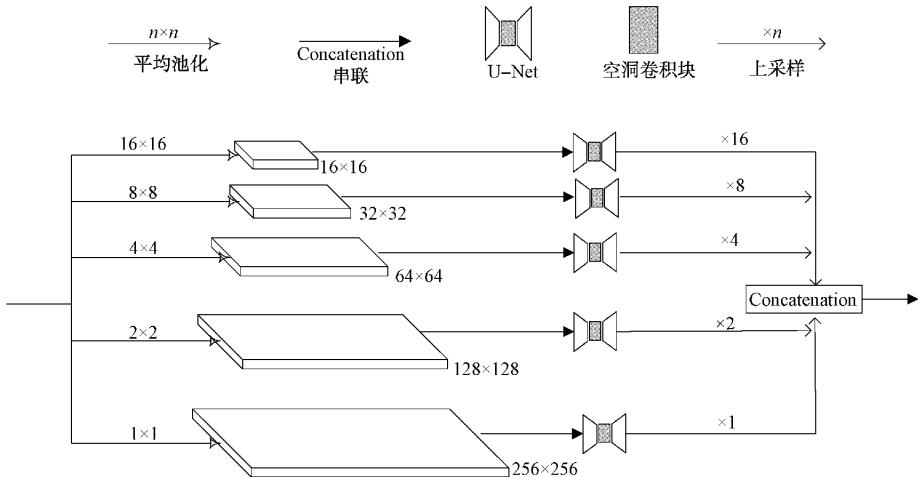


图 4 PU-Net 内部结构图

网络中上一个 SDCR 块的输出作为 PU-Net 的输入, 经过内核分别为  $1 \times 1$ 、 $2 \times 2$ 、 $4 \times 4$ 、 $8 \times 8$  和  $16 \times 16$  的平均池化后, 得到不同尺度的特征图。以训练图像大小  $256 \times 256$  为例, 得到特征图大小如图 4 所示, 因此纵向结构的 5 层分支就可以得到大小不同的感受野, 同时捕获局部与全局信息。然后分别在每一个金字塔层后面搭建 U-Net 网络, 金字塔模块得到不同尺度的特征图则作为 U-Net 网络的输入, 对各个特征图进行编一解码处理, 较好的保留了图像的高频信息与低频信息, 对图像去噪任务有很大的帮助, U-Net 的内部结构如表 1 所示。

由表 1 可以看出, U-Net 具有 5 层编码结构、5 层解码结构和一个  $1 \times 1$  卷积层来计算最后的输出。编码层有 4 个卷积核大小为  $3 \times 3$  的卷积层, 每个编码层经过  $2 \times 2$  的池化层后, 卷积核的个数相应扩大 2 倍。解码层具有 4 个卷积层, 其中 3 个与编码器的卷积层一样, 是卷积核  $3 \times 3$  的卷积层。另外 1 个为上采样因子为 2 的卷积层, 同时与对应特征图大小一样的编码层相连接, 每次上采样之后卷

积核的个数相应缩小 2 倍。最后通过  $1 \times 1$  层卷积得到 U-Net 最后的输出, 除了该层卷积之外, 其他卷积层的激活函数均为带泄露随机线性整流函数(leaky rectified linear unit, LReLU)。

多尺度信息对于图像去噪任务非常重要, 但是空间分辨率太小会导致图像结构破坏, 信息丢失, 不利于特征的重建。为了在不进一步降低空间分辨率的情况下增加感受野并捕获多尺度信息, 本文设置在编码器和解码器之间的最小尺度中引入空洞卷积块, 其使用具有不同扩张率的 4 个膨胀卷积。如图 5 所示, 它可以在不增加参数数量且不损坏结构的情况下扩大感受野。然后将不同感受野提取的特征进行融合, 四个扩张率分别设置为 1、2、3 和 4。为了进一步简化操作并减少运行时间, 首先使用  $1 \times 1$  卷积来压缩特征通道。压缩比设置为 4。在融合设置中, 采用  $1 \times 1$  卷积使输出通道数与原始输入特征的通道数大小相等, 并在输入和输出特征之间采用局部残差连接以防止信息阻塞。

表1 U-Net的内部结构

Layers	Num_conv	Kernel_size	Num_outputs	Sampling	Concat	Activation
Encode_1	4	$3 \times 3$	32	—	—	LReLU
Encode_2	4	$3 \times 3$	64	Max	Encode_4	LReLU
Encode_3	4	$3 \times 3$	128	_pool2d	Encode_3	LReLU
Encode_4	4	$3 \times 3$	256	$2 \times 2$	Encode_2	LReLU
Encode_5	4	$3 \times 3$	512	—	Encode_1	LReLU
(Decode_5)	3	$3 \times 3$	256	—	—	LReLU
Decode_6	3	$3 \times 3$	128	Upsample	—	LReLU
Decode_7	3	$3 \times 3$	64	(2↑)	—	LReLU
Decode_8	3	$3 \times 3$	32	—	—	LReLU
Decode_9	—	—	—	—	—	—
Conv_10	1	$1 \times 1$	1	—	—	None

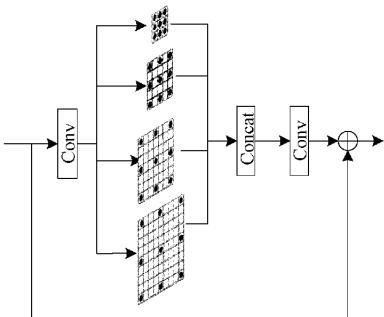


图5 Dilated Conv 内部结构图

每一个分层的 U-Net 输出经过不同尺度的上采样之后,得到尺寸一样的特征图,将分层得到的特征图进行融合连接,此时特征图的大小与 PU-Net 前面的 SDCR 块输出大小相同,所以 PU-Net 的输出可以作为下一个 SDCR 块的输入,网络完成纵向结构的任务进入到横向结构继续进行学习。

本文采用  $l_1$  损失函数,给定一批数量为  $N$  的训练图像对,即  $\{x_i, y_i\}_{i=1}^N$ ,目标是使经过 MFIDNet 后的去噪图像与原始干净图像更为接近,  $l_1$  损失函数表示为:

$$l(\mathbf{W}) = \frac{1}{N} \sum_{i=1}^N \| \text{MFIDNet}(x_i) - y_i \|_1 \quad (11)$$

其中,  $x_i$  是输入的噪声图像,  $y_i$  是原始干净图像, MFIDNet()是本文提出的网络,  $\mathbf{W}$  表示所有参数的集合。

## 2 实验结果及分析

### 2.1 数据集与评估指标

使用智能手机降噪数据集(smart image denoising dataset, SIDD)数据集<sup>[28]</sup>进行去噪模型训练,该数据集的训练集包含 200 对干净图像和噪声图像,将其随意分割成  $256 \times 256$  的图像块,得到 48 000 对图像用于网络训练,用 SIDD 数据集自带的验证集进行网络模型验证。总共进行 4 000 次迭代,学习速率最初设置为  $10^{-4}$ ,2 000 次迭代之

后,每过 500 次迭代将学习速率减半进行微调。采用  $\beta_1 = 0.9$ ,  $\beta_2 = 0.999$  的 Adam 优化器对模型进行优化。在真实噪声图像数据集 SIDD、DND<sup>[29]</sup> 和 NC12<sup>[30]</sup> 进行测试。NC12 包括 12 幅噪声图像,真实干净的图像无法获取,本文只提供其去噪结果图进行定性评估。

该网络在 Pytorch<sup>[31]</sup> 1.7.1 框架中实现,并用英伟达 GeForce GTX 1080 Ti 进行训练。本文采用峰值信噪比(peak signal to noise ratio, PSNR)和结构相似性(structural similarity, SSIM)<sup>[32]</sup>对提出算法的去噪结果进行分析。

### 2.2 图像去噪结果对比

为了验证 MFIDNet 算法在真实噪声图像上的去噪效果,将其与 FFDNet<sup>[12]</sup>、NC<sup>[30]</sup>、GID<sup>[14]</sup>、CBDNet<sup>[16]</sup>、PD<sup>[15]</sup>、RIDNet<sup>[17]</sup>、AINDNet<sup>[33]</sup>、InvDN<sup>[34]</sup> 卷积神经网络去噪算法进行对比实验,本文在 SIDD、DND 和 NC12 3 个真实数据集上进行可视化结果对比,图 6、7 和 8 分别为以上对比算法与本文提出算法的去噪结果图。

在 DND 数据集上的实验结果对比如图 6 所示,FFDNet 可以去除以物体为背景的噪声,但是物体中间的黑色区域上的噪声无法去除,去噪后的该区域被噪声腐蚀严重。NC 与 PD 对去噪后的图像有伪影和瑕疵产生,且有噪声残留。GID 和 CBDNet 同样是无法去除更多的噪声,CBDNet 破坏图像纹理,导致视觉效果较差。RIDNet、AINDNet 和 InvDN 处理噪声图像后细节模糊,物体边缘处有部分缺损且产生伪影;在 SIDD 数据集上的实验对比结果如图 7 所示,与本文提出的算法相比,AINDNet 和 InvDN 还有少量噪声残留,RIDNet 去噪后的图像会朦胧视觉。其他对比算法的表现与图 6 相同;在 NC12 数据集上的实验对比结果如图 8 所示,FFDNet 去噪后的图像过于平滑,细节丢失严重,NC 的去噪效果要好于前两个数据集上的实验效果,其他对比算法的表现如上所述。从以上实验结果可以看出,本文提出的 MFIDNet 在尽可能去除噪声的情况下,保持清晰的边缘细节,不会破坏纹理结

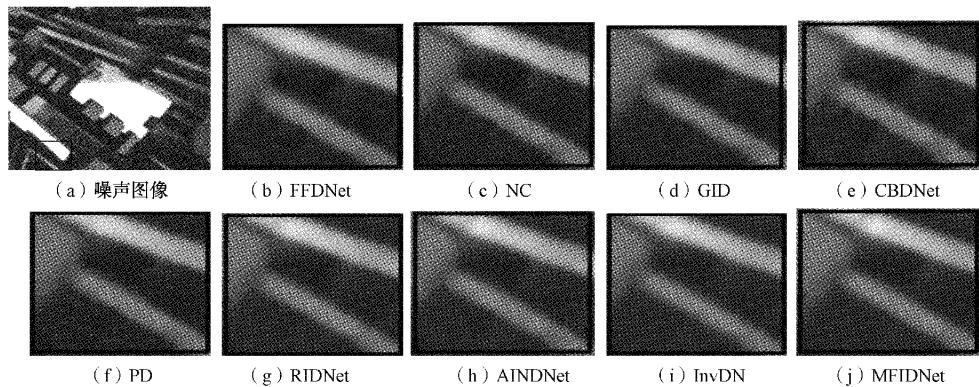


图 6 在数据集 DND 上的去噪结果对比

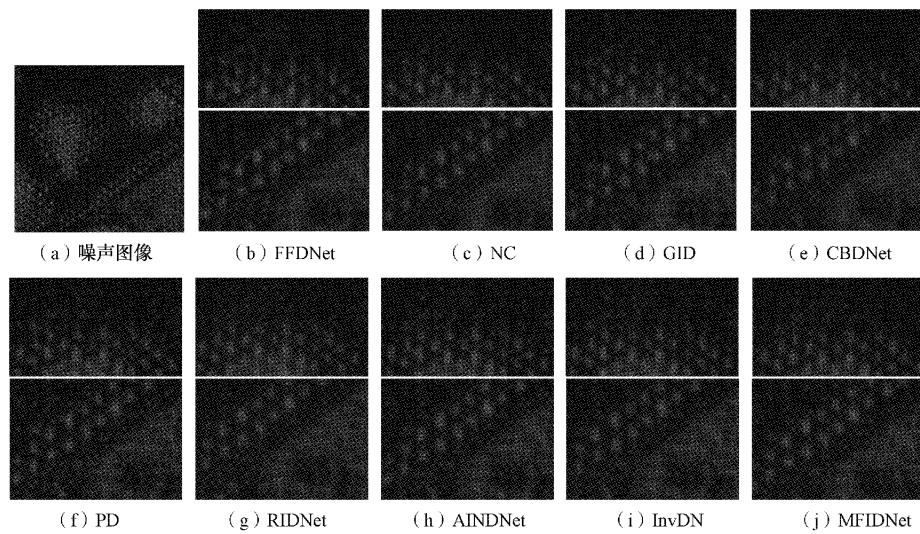


图 7 在数据集 SIDD 上的去噪结果对比

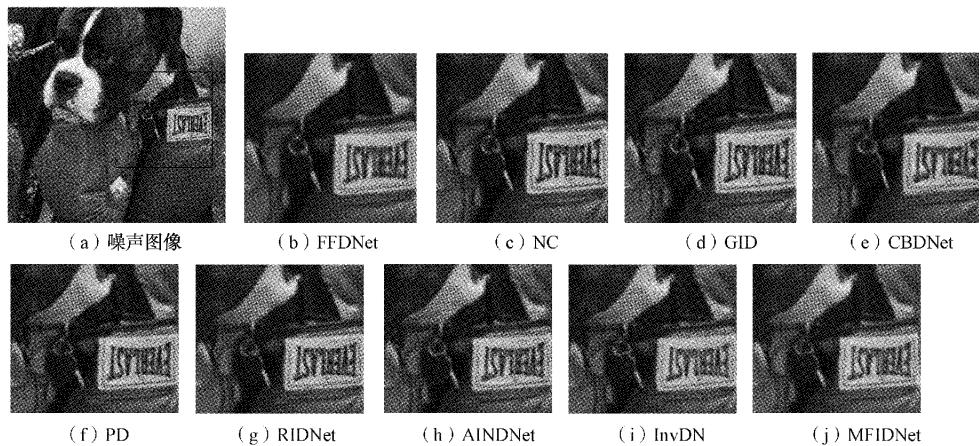


图 8 在数据集 NC12 上的去噪结果对比

构,没有过度平滑和产生伪影,能达到较好的去噪效果。

图 9 为手机后置摄像头随意拍摄的真实场景的 RGB 照片,智能手机相比专业相机来说,在成像时会产生更多的噪声,从图中可以看出,MFIDNet 可以去除较多的噪声,较好的保留墙体的竖形条纹和边缘处的斑驳破损,验证了

以上对比实验所得到的结论,也为本文提出的算法增加了说服力。

由于 NC12 数据集的干净图像无法获得,本文只提供在数据集 DND 和 SIDD 上的 PSNR 和 SSIM 值。如表 2 所示,选取的对比算法既有传统去噪算法,又有近几年基

于深度学习的优秀算法,所有对比算法的 PSNR 和 SSIM 值都从数据集的官方网站上获得,字体加粗突出表示最高

数值,从评价指标值可以看出,本文算法在真实噪声图像去噪方面是具有竞争性和有效性的。

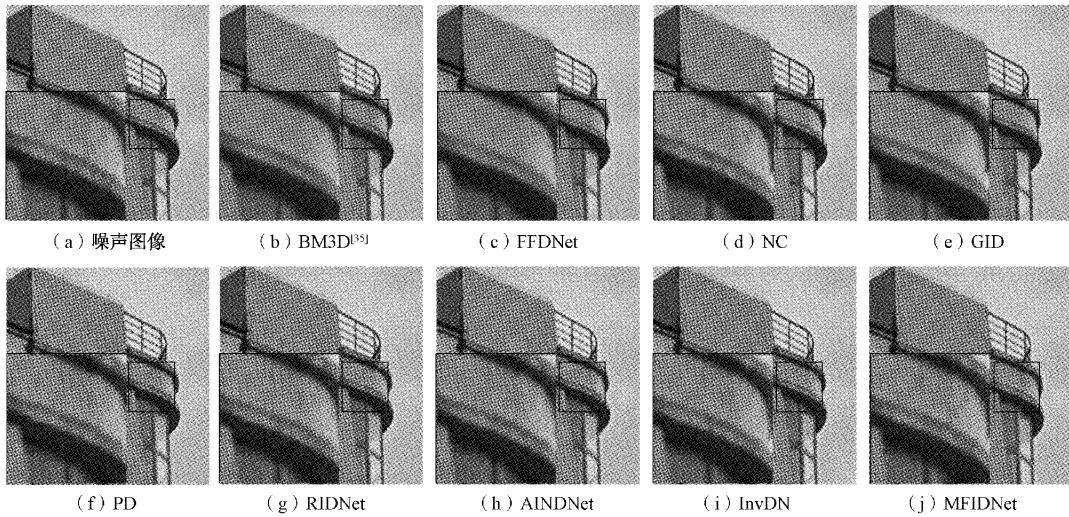


图 9 普通手机拍摄的图像

表 2 各种算法在 DND、SIDD 数据集上的 PSNR 和 SSIM 值

Method	DND		SIDD		SSIM
	PSNR/dB	SSIM	Method	PSNR/dB	
BM3D	34.51	0.851	BM3D	26.65	0.685
NC	35.43	0.884	MLP <sup>[36]</sup>	24.71	0.641
FFDNet+	37.61	0.942	WNNM <sup>[37]</sup>	25.78	0.809
CBDNet	38.06	0.942	CBDNet	33.28	0.868
PD	38.40	0.945	PD	32.94	0.865
RIDNet	39.26	0.953	RIDNet	38.71	0.953
AINDNet	39.37	0.951	AINDNet	38.95	0.952
VDN <sup>[38]</sup>	39.38	0.952	VDN <sup>[38]</sup>	39.26	0.955
InvDN	39.57	0.952	InvDN	39.28	0.955
本文算法	39.62	0.956	本文算法	39.49	0.954

### 2.3 消融实验

为了验证 MFIDNet 的每个模块在去噪任务中的作用,对 SDCR 数量和 PU-Net 在网络中的位置进行消融实验。如表 3 所示,首先研究横向结构 SDCR 数量  $n$  对网络性能的影响,即  $n=15$  和  $n=20$  这两种情况,由 PSNR 值可以看出,相比  $n=15$ ,当  $n=20$  时,PSNR 值增益较小,证明仅增加网络深度无法进一步取得较好的去噪效果,综合训练时间和参数量考虑,本文的网络采用 15 个 SDCR 块作为网络横向结构。

在本文的 1.2 节已经提到,本文使用 3 个 PU-Net 用于提取多尺度特征,作为网络的纵向结构,3 个 PU-Net 被分别放置在第 5 个 SDCR、第 10 个 SDCR 和第 14 个 SDCR 的后面,在表 3 中,(n) 表示将 PU-Net 放在第  $n$  个 SDCR 块的后面。从 PSNR 值的对比中可以看出,单个 PU-Net 插入在网络的靠后位置,更有利于图像去噪,SDCR( $n=$

表 3 MFIDNet 消融实验

模块 模型	SDCR		PU-Net			DND
	$n=15$	$n=20$	(5)	(10)	(14)	PSNR
1	✓					38.79
2		✓				38.83
3	✓		✓			39.17
4	✓			✓		39.26
5	✓				✓	39.38
MFIDNet	✓		✓	✓	✓	39.62

15) + PU-Net(14) 的 PSNR 值比 SDCR( $n=15$ ) 高出 0.59 dB,证明了本文提出的纵向结构 PU-Net 在图像去噪中的作用。而将 3 个 PU-Net 都插入网络后,PSNR 值达到了 39.62 dB,这也是本文在图 2 中所给出的网络结构。

对以上模型在 DND 数据集上进行实验测试,直观的

视觉对比结果如图 10 所示。从图 10(a)中可以看出,和噪声图片相比,模型 1 已经能够去除图像中的绝大部分噪声,证明了 SDCR 模块的有效性,但放大区域比较模糊;模型 2 采用 20 个 SDCR 块,虽然比模型 1 的网络更深,但去噪后的图像仍然模糊,视觉效果没有明显提升;模型 3 的去噪图像如图 10(c)所示,相比于模型 2,模型 3 在去除伪影上有明显改进,证明了 PU-Net 模块的有效性;模型 4 和模型 5 将 PU-Net 插入在网络的靠后位置,去噪后图像的细节更加清晰完整,在模糊程度上有明显改进;图 10(f)是本文提出的网络结构,将以上模型的优点进行结合,在去除更多噪声的情况下,很好的解决了伪影问题和细节模糊问题。

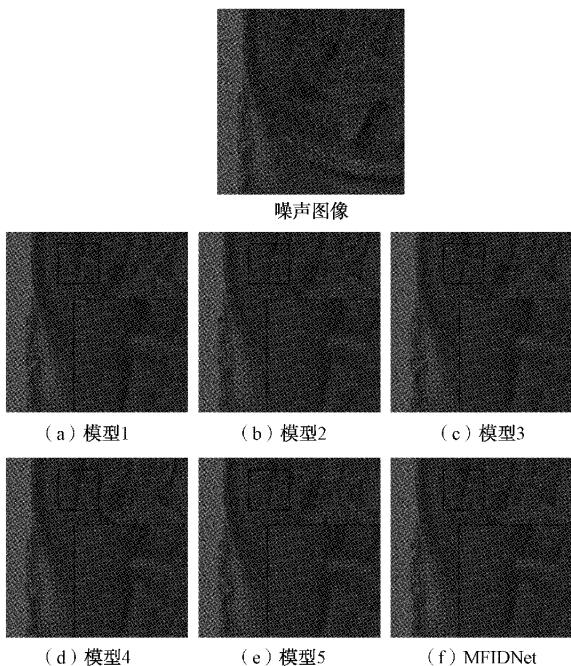


图 10 不同模型的结果对比

### 3 结 论

本文针对真实噪声图像提出了 MFIDNet 去噪网络,该网络主要由以自适应密集残差块 SDCR 为横向结构,以 PU-Net 为纵向结构搭建而成。横向结构充分的提取同一尺度的特征,自适应的调整各通道的权重,使网络能够利用先前的特征图信息,PU-Net 的纵向结构由金字塔模块和具有跳跃连接和空洞卷积块的 U-Net 组成,弥补了网络横向结构的尺度单一缺点,实现了网络的多尺度特征提取,在编码器和解码器之间的最小尺度中引入空洞卷积块,扩大感受野的同时不损坏图像的细节。并且将 PU-Net 插入在 SDCR 块的不同位置,更能实现多尺度特征提取与单一尺度特征提取的互相弥补。在真实噪声数据集上的实验结果表明,MFIDNet 在确保去除噪声的情况下,能够保留更多的纹理细节。接下来的研究工作重心将放

在注意力与模拟真实噪声上,以优化 MFIDNet 网络性能。

### 参 考 文 献

- [1] 汤一彬,徐宁,姚澄,等. 基于旋转不变稀疏表示和流形学习的图像降噪[J]. 仪器仪表学报, 2014, 35(5): 1101-1108.
- [2] 崔程程,周先春,昝明远,等. 基于自适应滤波的 BM3D 降噪算法[J]. 电子测量技术, 2021, 44(12): 97-101.
- [3] 高欣欣,倪念勇,孙波. 数字图像迭代均值滤波降噪算法[J]. 湖南文理学院学报(自然科学版), 2017, 29(2): 54-57.
- [4] 彭妹妹. 基于均值滤波和小波变换的图像去噪[J]. 现代计算机, 2019,(12): 62-67.
- [5] 梁利利,高楠,李建军. 基于小波变换和均值滤波的图像去噪方法[J]. 计算机与数字工程, 2019, 47(5): 1229-1232.
- [6] MAKOTO S, KUMAR P R, YOSHIKI K, et al. Improved iterative reconstruction method for compton imaging using median filter[J]. PloS ONE, 2020, 15(3): 22-36.
- [7] 届正庚,牛少清. 一种改进的自适应加权中值滤波算法研究[J]. 计算机技术与发展, 2018, 28(12): 86-90.
- [8] 聂真真. 基于脉冲噪声点检测的中值滤波改进算法[J]. 武汉理工大学学报(信息与管理工程版), 2012, 34(3): 278-280.
- [9] 江巨浪,辛倩,朱柱. 一种改进的方向加权中值滤波算法[J]. 安庆师范大学学报(自然科学版), 2019, 25(1): 60-63.
- [10] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA, IEEE, 2016: 770-778.
- [11] 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.
- [12] 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.
- [13] ZHANG K, ZUO W M, GU S H, et al. Learning deep CNN denoiser prior for image restoration [C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA, IEEE, 2017: 2808-2817.
- [14] XU J, ZHANG L, ZHANG D. External prior guided internal prior learning for real-world noisy image denoising [J]. IEEE Transactions on Image

- Processing, 2018, 27(6): 2996-3010.
- [15] ZHOU Y Q, JIAO J B, HUANG H B, et al. When AWGN-based Denoiser Meets Real Noises[J]. ArXiv Preprint, 2016, ArXiv: 1904.03485.
- [16] GUO S, YAN Z, ZHANG K, et al. Toward convolutional blind denoising of real photographs [C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Long Beach, CA, USA, IEEE, 2019: 1712-1722.
- [17] ANAWR S, BARNES N. Real image denoising with feature attention [C]. 2019 IEEE/CVF International Conference on Computer Vision, Seoul, Korea(South), IEEE, 2019: 3155-3164.
- [18] WEI K, FU Y, YANG J, et al. A physics-based noise formation model for extreme low-light raw denoising[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, IEEE, 2020: 2758-2767.
- [19] WANG Y, HUANG H, XU Q, et al. Practical deep raw image denoising on mobile devices[C]. Computer Vision-ECCV 2020: 16th European Conference, Glasgow, UK, Springer International Publishing, Springer. 2020: 1-16.
- [20] ZAMIR S W, ARORA A, KHAN S, et al. Multi-stage progressive image restoration[C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Nashville, TN, USA, IEEE, 2021: 14816-14826.
- [21] 王延年, 李雄飞. 基于深度密连网络的自然图像去噪算法[J]. 国外电子测量技术, 2021, 316(3):23-27.
- [22] GURROLA-RAMOS J, DALMAU O, ALARCON T E. A residual dense U-Net neural network for image denoising [J]. IEEE Access, 2021, 9 ( 6 ): 31742-31754.
- [23] 杨国亮. 基于卷积神经网络图像去噪方法研究[D]. 南昌: 南昌大学, 2020: 4-7.
- [24] ZHANG Y, TIAN Y, KNOG Y, et al. Residual dense network for image restoration [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(7): 2480-2495.
- [25] SOH J W, CHO N I. Lightweight single image super-resolution with multi-scale spatial attention networks[J]. in IEEE Access, 2020, 8(3): 35383-35391.
- [26] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.
- [27] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions [J]. ArXiv Preprint, 2016, ArXiv: 1511.07122.
- [28] ABDELHAMED A, LIN S, BROWN M S. A high-quality denoising dataset for smartphone cameras[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA, IEEE. 2018: 1692-1700.
- [29] PLOTZ T, ROTH S. Benchmarking denoising algorithms with real photographs [C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA, IEEE, 2017: 2750-2759.
- [30] LEBRUN M, COLOM M, MOREL J M. The noise clinic: A blind image denoising algorithm[J]. Image Processing On Line(IPOL), 2015, 8(5): 1-54.
- [31] PASZKE A, GROSS S, CHINTALA S, et al. Automatic differentiation in pytorch [C]. Neural Information Processing Systems, Long Beach, CA, USA, IEEE, 2017: 1-4.
- [32] TONG Y B, ZHANG Q S, QI Y P. Image qualityassessing by combining PSNR with SSIM[J]. Journalof Image and Graphics, 2006, 11 ( 12 ): 1758-1763.
- [33] KIM Y, SOH J W, PARK G Y, et al. Transfer learning from synthetic to real-noise denoising with adaptive instance normalization[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Seattle, WA, USA, IEEE. 2020: 3479-3489.
- [34] LIU Y, QIN Z Y, ANWAR S, et al. Invertible denoising network: A light solution for real noise removal [C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Nashville, TN, USA, IEEE, 2021: 13360-13369.
- [35] DABOV K, FOI A, KATKOVNIK V, et al. Color image denoising via sparse 3D collaborative filtering with grouping constraint in luminance-chrominance space[C]. 2007 IEEE International Conference on Image Processing, San Antonio, TX, USA, IEEE. 2007: 313-316.
- [36] BURGER H C, SCHULER C J, HARMRLING S. Image denoising: Can plain neural networks compete with BM3D[C]. 2012 IEEE Conference on Computer Vision and Pattern Recognition, Providence, RI, USA, IEEE, 2012: 2392-2399.
- [37] GU S, ZHANG L, ZUO W, et al. Weighted nuclear norm minimization with application to image denoising[C]. 2014 IEEE Conference on Computer Vision and Pattern Recognition, Columbus, OH, USA, IEEE. 2014: 2862-2869.

- [38] YUE Z S, YONG H W, ZHAO Q, et al. Variational denoising network: Toward blind noise modeling and removal [C]. In Advances in Neural Information Processing Systems, Vancouver, Canada, IEEE. 2019: 1690-1701.

#### 作者简介

李晨,讲师,研究生导师,主要研究方向为图像复原、深

度学习。

E-mail:papertg2018@163.com

许雪,助理实验师,主要研究方向为图像处理、深度学习。

E-mail:1492306962@qq.com

郭业才,教授,博士生导师,主要研究方向为通信信号处理、气象信息技术与安全、水声信号处理等方面。

E-mail:guo-yecai@163.com