

DOI: 10.13382/j.jemi.B2306973

基于纹理先验的扩张残差注意力相似性去噪网络^{*}

周先春¹ 史振婷² 王子威² 李 婷² 张 影²
(1. 南京信息工程大学人工智能学院 南京 210044; 2. 南京信息工程大学电子与信息工程学院 南京 210044)

摘 要: 目前,大多数基于卷积神经网络的图像去噪模型不能充分利用图像数据的冗余性,这限制了模型的表达能力。而且,为了有效去噪,往往将边缘信息用作先验知识,而纹理信息通常被忽略。针对这些问题,提出一种新的图像去噪网络,该网络首先使用注意力相似性模块提取图像的全局相似性特征,通过平均池化来平滑和抑制注意力相似性模块中的噪声,以进一步提高网络性能;其次使用扩张残差模块来提取图像的局部和全局特征;最后使用全局残差学习增强网络从浅层到深层的去噪效果。此外,还设计一种纹理提取网络从噪声图像中提取局部二值模式以获取纹理信息,利用纹理信息作为先验知识,可在去噪过程中保留演化图像中的细节。实验结果表明,与一些先进的去噪网络相比,新提出的去噪网络在图像视觉上有很大改善、效率更高且峰值信噪比提高了 2 dB 左右,结构相似性提高了 3% 左右,更有利于实际应用。

关键词: 图像去噪;卷积神经网络;纹理信息;注意力相似性模块;扩张残差模块

中图分类号: TP751.1;TN911.73 **文献标识码:** A **国家标准学科分类代码:** 510.40

Expanded residual attention similarity denoising network based on texture prior

Zhou Xianchun¹ Shi Zhenting² Wang Ziwei² Li Ting² Zhang Ying²
(1. School of Artificial Intelligence, Nanjing University of Information Science and Technology, Nanjing 210044, China;
2. School of Electronic and Information Engineering, Nanjing University of Information
Science and Technology, Nanjing 210044, China)

Abstract: Currently, most image denoising models based on convolutional neural networks cannot fully utilize the redundancy of image data, which limits the expressive power of the models. Moreover, edge information is often used as a priori knowledge for effective denoising, while texture information is usually ignored. To address these issues, a new image denoising network is proposed, which firstly uses the attentional similarity module to extract global similarity features of the image, and smooths and suppresses the noise in the attentional similarity module through average pooling to further improve the network performance; secondly, the dilated residual module is used to extract both local and global features of the image; finally, a global residual learning is utilized to enhance the denoising performance from shallow to deep layers. In addition, a texture extraction network is designed to extract local binary patterns from noisy images to obtain texture information, which can be utilized as a priori knowledge to preserve the details in the evolved images during the denoising process. The experimental results show that compared with some advanced denoising networks, the newly proposed denoising network has a great improvement in image vision, higher efficiency and peak signal-to-noise ratio by about 2 dB, and structural similarity by about 3%, which is more conducive to practical applications.

Keywords: image denoising; convolutional neural network; texture information; attention similarity module; dilated residual module

0 引言

由于光照、污渍等环境因素的影响,数字图像总是包含噪声。为了从噪声中恢复图像,减少由噪声引起的图像退化,同时尽可能地保留图像的结构和纹理信息^[1],去噪是图像处理的一项基本任务。一般来说,图像去噪方法可以分为两类:基于模型的去噪方法和基于学习的去噪方法。基于模型的去噪方法包括空间滤波器^[2-3]、变换域方法^[4]和基于稀疏度的方法^[5]等。这些算法依赖于原始图像包含某些特征的基本假设^[6]。基于三维块匹配滤波(block matching and 3D filtering, BM3D)算法^[7]利用块匹配和三维滤波来增强图像的去噪效果和稀疏性。尽管这些传统去噪方法在去噪方面取得了相应的成功,但是在处理复杂噪声和保留图像细节方面可能存在挑战。

近年来,基于深度学习的方法,尤其是卷积神经网络(convolutional neural network, CNN),已经成为其中最受欢迎的技术。其试图通过学习有噪声和干净图像之间的映射函数来找到无噪声图像^[8]。Zhang等^[9]通过堆叠多个卷积层,残差学习和批量归一化(batch normalization, BN)提出了去噪卷积神经网络(denoising convolutional neural network, DnCNN),以提高训练效率和去噪性能。然而,DnCNN必须针对特定噪声水平训练多个模型,对盲噪声效果不理想。为解决这一问题,王洪雁等^[10]设计了一种快速灵活的去噪网络(fast flexible denoising network, FFDNet),将含噪图像和可训练的噪声水平图作为输入,单个模型可以处理不同噪声水平。为了充分地利用各层的丰富特征来提高模型性能,Zhang等^[11]提出了用于图像超分辨率的深度残差密集网络(residual dense network, RDN)。通过级联残差密集块形成连续的记忆机制。此外,为了降低计算成本,Tian等^[12]提出了批量重整化去噪网络(batch renormalization denoising network, BRDNet),该网络使用批量重整化来加速网络训练的收敛。此外,用扩张卷积(dilated convolution, DConv)代替普通卷积也可以减少模型的参数。例如,Yan等^[13]设计了一种有效的注意引导CNN(attention-guided dilated network, ADNet),该网络通过扩张卷积和普通卷积组成的稀疏块来提高去噪性能。Latifi等^[14]提出了一种基于CNN的去噪网络,通过叠加多个扩张卷积和普通卷积层来去除噪声。Wu等^[15]提出了一种灵活有效的U形网络(flexible and effective Ushaped network, FEUNet),通过叠加多个卷积层来去除噪声。然而,这两种去噪方法只是叠加了大量的卷积层,易造成图像细节损失,对现实世界复杂的噪声图像处理不足。Thakur等^[16]提出了AGSDNet,该方法结合了注意机制和梯度去噪。但在获得较好的去噪效果的同时,该模型本身权重

较大,需要大量数据集作为支持,导致网络收敛速度一般。在网络的鲁棒性方面,Zhang等^[17]提出一种变形卷积神经网络(deformed convolutional neural network, DCN)相较于传统CNN网络,在鲁棒性和图像去噪方面性能均有明显提升。总之,CNN因其在图像去噪任务中表现出色而备受关注。但是基于CNN模型仍然有可能进一步提高性能。针对这一问题,新提出了一种图像去噪网络,主要贡献如下:

1) 为了在去噪过程中更好地保留图像的细节信息,考虑到局部二进制模式(local binary pattern, LBP)纹理特征简单、易于计算且具有一定的鲁棒性,提出了一种基于CNN的LBP纹理提取网络(texture extraction network, TENet)。并通过消融实验验证了纹理提取网络的有效性。

2) 为了在去噪过程中充分利用图像数据的冗余性,在新提出的去噪网络中加入注意力相似性模块(attention similarity module, ASM)。ASM是通过扩张卷积来充分关注图像的全局相似性信息,利用平均池化来平滑和抑制ASM中的噪声,以进一步提高网络性能。最后通过消融实验验证了ASM的有效性。

3) 为了进一步提高网络的性能,在新提出的去噪网络中加入由普通卷积和扩张卷积相结合的扩张残差模块(CDC-RM)。实验结果表明,与其他残差模块相比,本文提出的CDC-RM不仅扩大了网络的感受野,使网络更好地关注图像的局部和全局特征,而且解决了扩张卷积带来的网格效应和不连续核带来的连续性损失,进一步提高了网络的去噪性能。

1 相关工作

1.1 多尺度特征提取

图像的多尺度信息对CNN的表达能力至关重要。在CNN中,通常使用 3×3 核、 5×5 核和 7×7 核来提取不同尺度的特征。不同尺度的信息也可以通过使用下采样或池化操作来获得,但会丢失一些图像细节。此外,SGN^[18]开发了一种自顶向下的自引导架构来提取多尺度信息,并直接采用shuffle操作来生成多尺度输入。为了进一步提高网络性能,本文也通过使用shuffle操作来提取多尺度信息。

1.2 注意力机制及其相似性

图像中存在冗余信息,即图像细节具有全局相似性。注意力机制可以对重要的图像细节给予更多的关注。因此,在复杂的环境中,这对于获取图像的关键信息非常有用。赵雅琴等^[19]提出了即插即用的卷积块注意模块(convolutional block attention module, CBAM),该模块通

过最大池化和平均池化分别在通道和空间维度上提取图像的全局特征。受此启发,本文提出的注意力机制也包括两个维度,通道维度和空间维度。此外,经典的BM3D^[7]充分利用了图像的局部相似性。但很少关注图像的全局相似性。受此启发,本文使用注意力机制来关注图像细节的全局相似性。

1.3 扩张卷积

在CNN中,通常使用3种主要方法来扩大感受野:池化操作、增加网络深度和扩张卷积。池化操作可能会导致部分信息丢失,并且对于图像恢复任务是不可逆的。网络深度的增加不可避免地导致网络训练变得更加困难。因此,扩张卷积是扩大感受野的最佳选择。然而,扩张卷积具有网格效应^[20]。为了减轻网格效应,Wang等^[21]提出了一种混合扩张卷积(hybrid dilated convolution, HDC)架构。基于此研究,本文提出了一种

由普通卷积和扩张卷积相结合的扩张残差模块,可解决扩张卷积带来的网格效应、扩大感受野和提高网络的去噪性能。

2 新提出的图像去噪网络

新提出的网络体系结构如图1所示。首先利用纹理提取网络得到纹理图像,然后通过级联操作将LBP图像和噪声图像合并作为去噪网络的输入;其次使用多尺度特征提取块(multi-scale feature extraction block, MFEB)和带有LReLU激活函数的卷积层提取浅层特征;接着使用扩张残差注意力相似性模块(CDC-RASM)提取图像的深层特征;然后使用级联操作和 1×1 卷积实现全局特征融合;最后使用两个卷积来重构图像。此外,使用全局残差学习来增强网络从浅层到深层的效果。




图1 新提出的纹理提取网络(上)和去噪网络(下)

Fig. 1 Newly proposed texture extraction network (top) and denoising network (bottom)

在模型中没有特别的要求,为了方便实验,所有情况下都使用 3×3 卷积核。同时使用零填充策略来保持图像的大小不变。此外,去噪网络中有10个CDC-RASM组成,每个CDC-RASM使用局部残差学习将当前层的特征向后传递。

2.1 网络结构

如图1所示,假设 I_{noise} 和 $I_{denoising}$ 分别表示加噪的输入图像和去噪后的输出图像。具体来说,在TENet中,首先使用单卷积层提取第1个特征,其次使用4个双卷积模块(dual convolution module, DCM)用于高效的LBP特征提取,然后再使用一个单卷积层获取LBP图像(I_{LBP}),最后通过级联将LBP图像和噪声图像合并作为去噪网络的输入 I_0 , I_0 可表示为:

$$I_0 = C_{at}(I_{LBP}, I_{noise}) \quad (1)$$

其中, C_{at} 表示级联操作。

接着通过MFEB和带有LReLU函数的卷积层提取浅层特征 F_0 , F_0 可表示为:

$$F_0 = C_{LR}(H_{MFEB}(I_0)) \quad (2)$$

其中, H_{MFEB} 表示多尺度特征提取模块, C_{LR} 表示Conv+LReLU层, F_0 表示经过多尺度特征提取模块和卷积层提取的浅层特征。

然后将 F_0 输入到CDC-RASM中,得到输出特征 F_D , F_D 可表示为:

$$F_D = H_D(\cdots H_d(\cdots H_1(F_0)\cdots)\cdots) \quad (3)$$

其中, $H_d \{d = 1, 2, 3, \cdots, D\}$ 为第 d 次CDC-RASM的运算, H_d 为非线性变换;它是一系列的操作,例如卷积和

LReLU (关于 CDC-RASM, 详见 2.3 节 2) 中。

然后对所有 CDC-RASM 的输出特征进行融合, 得到输出特征 F_{DS}, F_{DS} 可表示为:

$$F_{DS} = C_1(C_{at}(F_1, \dots, F_d, \dots, F_D)) \quad (4)$$

其中, C_1 表示 1×1 卷积层。

然后使用两个单卷积层来重建输出图像 F_{out} , 并使用全局残差学习增强从浅层到深层的效果。其中 F_{out} 可表示为:

$$F_{out} = C_3(C_3(F_{DS}) + F_{-1}) + I_0 \quad (5)$$

其中, C_3 是 3×3 卷积, 前一个 3×3 卷积层可以进一步融合多尺度局部特征, 后一个 3×3 卷积层用来重建输出图像 F_{out} 。

假设训练集有 N 对图像 $I_{noise}^i, I_{GT}^i (i = 1, 2, \dots, N)$, 本文目标是使经过网络后的去噪图像 $F_{CDC-RASNet}(I_{noise}^i)$ 与原始干净图像更为接近。但由于 ℓ_2 损失函数容易陷入局部最优^[22], 而 ℓ_1 损失函数不同于 ℓ_2 损失函数受大误差的影响, 使得模型对离群值具有鲁棒性并且更加关注特征的重要性^[23]。所以本文采用 ℓ_1 损失函数, 则 CDC-RASNet 的 ℓ_1 损失函数为:

$$L = \frac{1}{N} \sum_{i=1}^N |F_{CDC-RASNet}(I_{noise}^i) - I_{GT}^i| \quad (6)$$

其中, $F_{CDC-RASNet}(I_{noise}^i)$ 为模型的预测输出, I_{GT}^i 为干净图像。

2.2 纹理提取网络

在网络中选择了一种简单、计算量低但有效的纹理提取方法—LBP^[24]方法从噪声图像中提取 LBP 图像。

该纹理提取网络首先使用单个卷积层提取第一个特征, 然后将此特征输入到后面的 4 个 DCM 中, 如图 2 所示, 进行高效的 LBP 特征提取。在 DCM 中, Dconv、Conv、BN 和 ReLU 分别为扩张率为 2 的 3×3 卷积、 3×3 卷积、批归一化和 ReLU 激活函数。提取不同的特征 2 次后, 通过 Concat 级联将这些特征组合在一起, 再通过单卷积获取共同特征, 接着通过跳跃连接传输携带大量图像细节的低级特征。最后为了提取共同特征, 添加一个单独的 Conv+BN+ReLU。此外, 除了最后一个用于获取 LBP 图像卷积层的核大小为 $1 \times 3 \times 3$, 其余每个卷积层的核大小为 $64 \times 3 \times 3$ 。为了给出 DCM 的数学描述, 使用 C_{BR} 表示 Conv+BN+ReLU, D_{BR} 表示 Dconv+BN+ReLU, C_{at} 表示级联操作, C_3 表示 3×3 卷积。则 DCM 的输出特征可表示为:

$$f_{o1} = C_{at}(C_{BR}(D_{BR}(f_{in})), D_{BR}(C_{BR}(f_{in}))) \quad (7)$$

$$f_{o2} = C_3(C_{at}(C_{BR}(D_{BR}(f_{o1})), D_{BR}(C_{BR}(f_{o1})))) \quad (8)$$

$$f_{DCM} = C_{BR}(C_{at}(f_{o2}, f_{in})) \quad (9)$$

其中, f_{in} 表示 DCM 的输入特征, f_{o1} 和 f_{o2} 表示 DCM 的中间输出特征, f_{DCM} 表示 DCM 的输出特征。




图 2 双卷积模块

Fig. 2 Dual convolution module

2.3 去噪网络 (CDC-RASNet)

新提出的去噪网络的主要模块由 MFEB 和 CDC-RASM 构成。

1) 多尺度特征提取模块 (MFEB)

本文提出的 MFEB 是一种可以充分利用不同尺度特征信息的多尺度特征提取模块, 如图 3 所示。对于图像

去噪任务, 输出图像应该与输入图像具有相同的大小。因此, 使用 shuffle/2 操作作为下采样, 使用 shuffle $\times 2$ 操作作为恢复图像大小。由此可得到 3 种尺度的特征图: 原始图像特征图、shuffle/2 个操作特征图和 shuffle/4 个操作特征图, 它们对应的特征图数量分别为 $C, 4C, 16C$, 其中 C 为图像通道。灰度图像 $C=1$, 彩色图像 $C=3$ 。为了

使 MFEB 输出的特征图个数为 64, 3 个尺度的卷积操作的卷积核数分别为 22、84、336。由于采用了零填充, 卷积运算不会改变特征图的大小。最后, 采用恒等映射、shuffle×2 操作和 shuffle×4 操作分别得到 22、21 和 21 个特征图, 将这些特征图连接起来, 形成 64 个特征图作为 MFEB 的输出。考虑到计算机资源的消耗, 本文仅在去噪网络的第 1 层使用一个 MFEB。由于 MFEB 可以提取图像的多尺度信息, 增加网络的宽度, 因此, MFEB 的使用可以提高网络的去噪性能。




图3 多尺度特征提取模块

Fig. 3 Multi-scale feature extraction module

2) 扩张残差注意力相似性模块 (CDC-RASM)

新提出的去噪网络的核心模块 CDC-RASM, 它包括




图4 扩张残差注意力相似性模块 (CDC-RASM)

Fig. 4 Extended residual attention similarity module (CDC-RASM)

(1) 扩张残差模块 (CDC-RM)

如图 5 所示, CDC-RM 由 Conv+BN+ReLU、CDC-残差块和一个 ReLU 激活函数组成。其中, CDC-残差块按顺序排列: Conv, DConv, Conv, 这种组合可以从图像中提取更丰富的信息, 还可以解决由于扩张卷积核得不连续而造成的信息连续性损失和网格效应等缺点。因此 CDC-

CDC-RM 和 ASM, 如图 4 所示。CDC-RM 通过结合普通卷积和扩张卷积提取图像的局部和全局特征。ASM 通过注意力机制获取复杂背景下图像的全局相似性特征, 包括通道注意相似性和空间注意相似性。通道注意力相似性模块 (channel attention similarity module, CASM) 侧重于从通道维度获取全局相似性特征, 而空间注意力相似性模块 (spatial attention similarity module, SASM) 侧重于从空间维度获取全局相似性特征。

在图 4 中, ASM 可表示为:

$$F_c = M_c \otimes F_{d-1} \quad (10)$$

$$F_s = M_s \otimes F_c \quad (11)$$

其中, $M_c \in R^{C \times 1 \times 1}$ 为通道注意相似性特征图, F_{d-1} 为第 d 个 CDC-RASM 的输入特征图, $M_s \in R^{1 \times H \times W}$ 为空间注意相似性特征图, F_c 和 F_s 分别为 CASM 和 ASM 的输出特征图, $\otimes$ 表示元素级的乘法。然后, F_s 和 CDC-RM 的串行输出 $F_{d,i} \ (i=1, 2, 3, 4, 5)$ 通过级联和 1×1 卷积后的输出特征图 F_d' 为:

$$F_d' = C_1(C_{at}(F_{d,1}, F_{d,2}, \dots, F_{d,5}, F_s)) \quad (12)$$

其中, C_{at} 表示 $(F_{d,1}, F_{d,2}, \dots, F_{d,5}, F_s)$ 进行级联, 1×1 卷积层来控制输出通道的数量。因此, 第 $d+1$ 个 CDC-RASM 的输入特征图可以表示为:

$$F_d = F_{d-1} + F_d' \quad (13)$$

其中, F_d 表示第 $d+1$ 个 CDC-RASM 的输入特征图, 当前层的特征图通过局部残差学习向后传递。

残差块比其他类型的残差块性能更好 (详见 3.4 节 3) 中, 消融实验)。

此外, CDC-残差块可以解决梯度消失问题。它有一个跳跃式连接, 通过输入 x 和中间结果 $F(x, w)$ 相加得到剩余输出, 因此第 k 层的输出 $y(x_k)$ 可以表示为:

$$y(x_k) = x_k + F(x_k, w_k) \quad (14)$$




图5 扩张残差模块(CDC-RM)

Fig. 5 Extended residual module (CDC-RM)

两部分连接的线性特性保证了信息可以直接传回浅层。即CDC-残差块可以处理网络中梯度消失问题。

(2) 通道注意力相似性模块(CASM)

如图6所示,使用 $F_{d-1} \in R^{C \times H \times W}$ 来表示CASM的输入特征图,CASM在每个通道上使用全局平均池化将特征图从 $C \times H \times W$ 压缩到 $C \times 1 \times 1$,以便1个像素代表1个通道,从而实现全局信息嵌入。此外,通过全局平均池化可将全局空间信息压缩成一个通道描述符 $Z \in R^{C \times 1 \times 1}$ 。则第 c 个通道的 Z_c 计算公式为:

$$Z_c = H_{GAP}(f_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W f_c(i, j) \quad (15)$$

其中, H_{GAP} 表示全局平均池, $f_c(i, j)$ 表示特征图

F_{d-1} 位置 (i, j) 的值。

然后,通过DConv+LReLU+DConv,使用具有Sigmoid激活的门控机制来学习通道之间的相互关系,得到通道注意相似性特征图 $M_c \in R^{C \times 1 \times 1}$ 。则 M_c 可表示为:

$$M_c = \sigma_2(H_{DConv2}(\sigma_1(H_{DConv1}(Z_c)))) \quad (16)$$

其中, σ_1 表示第1个扩张卷积层后的LReLU激活函数, σ_2 为Sigmoid激活函数。 $H_{DConv1} \in R^{\frac{C}{r} \times C}$ 和 $H_{DConv2} \in R^{\frac{C}{r} \times \frac{C}{r}}$ 分别表示两层扩张卷积,扩张率为2, r 为缩减比,将参数的个数缩减为16^[25]。此外,由图6中的通道注意相似性特征图 M_c 可知,其中两个通道具有相似的权重 $w1$,而且CASM对关键通道特征给予了较大的权重。

(3) 空间注意力相似性模块(SASM)

如图7所示,使用 $F_c \in R^{C \times H \times W}$ 表示SASM的输入特征图,SASM也使用全局平均池化将空间维度上的通道从 $C \times H \times W$ 压缩为 $1 \times H \times W$ 。使用全局平均池化将其压缩为 $R^{1 \times H \times W}$ 。接着通过一组非线性变换得到空间注意相似性特征图 $M_s \in R^{1 \times H \times W}$ 。则 M_s 可表示为:

$$M_s = \sigma_2(H_{DConv}(H_{GAP}(F_c))) \quad (17)$$

其中, H_{DConv} 为扩张卷积,核大小为 3×3 ,扩张率为2。 σ_2 表示Sigmoid激活函数。




图6 通道注意力相似性模块(CASM)

Fig. 6 Channel attention similarity module (CASM)




图7 空间注意力相似性模块(SASM)

Fig. 7 Spatial attention similarity module (SASM)

3 实验结果与分析

在本章中,介绍了模型的数据集、实验设置、实验结果以及相应的消融实验。

3.1 数据集

1) 合成噪声数据集

(1) 训练数据集

对于灰度图像和彩色图像的高斯去噪,本文分别在

训练图像中加入 $\sigma = 15, 25$ 和 50 的高斯噪声。在训练纹理提取网络和去噪网络时,为了消除过拟合现象,选择两个不同的数据库进行纹理提取和噪声去除。即使用 BSD500^[26] 进行纹理提取,使用包含 $4\,744$ 张高分辨率图像的 Waterloo Exploration 数据集^[27] 进行图像去噪。为了训练纹理提取网络,从 BSD500 中提取 50×50 的图像块;而为了训练去噪网络,从 Waterloo Exploration 数据集中提取 44×44 的图像块进行灰度和彩色图像去噪。此外,使用以下 8 种策略来增加训练样本的多样性:不操作(原始图像),旋转 90° ,旋转 180° ,旋转 270° ,水平翻转,旋转 90° 后水平翻转,旋转 180° 后水平翻转,旋转 270° 后水平翻转。为了提高训练方法的鲁棒性,为每个图像块随机选择其中一种策略。

(2) 测试数据集

灰度图像数据集包括 Set12 和 BSD68。Set12 有 12 张大小为 256×256 的灰度图,BSD68 有 68 张大小为 481×321 或 321×481 的灰度图。彩色图像数据集包括 McMaster^[28] 和 Kodak24^[29]。McMaster 和 Kodak24 分别包含 18 和 24 张 500×500 干净的彩色图像,并且它们对应的合成噪声图像是通过添加高斯噪声而生成的。其中噪声水平由标准差 σ 决定,选择 $\sigma = 15, 25$ 和 50 的 3 种噪声水平来测试 CDC-RASNet。

2) 真实噪声数据集

真实噪声图像是直接的自然环境中获得的。本文使用智能手机图像去噪数据(SIDD)训练集^[30]来训练 CDC-RASNet。它包含 160 个场景实例,由 5 个智能手机摄像头在不同的照明条件和相机设置下拍摄。每个场景实例有两对高分辨率图像,每对图像包含一幅噪声图像和对应的干净图像。总共使用了 320 对图像进行训练。为了进行测试,本文使用了 SIDD 数据集自带的验证集和 Darmstadt 噪声数据集(DND)^[31]进行网络模型验证。DND 不提供任何培训数据,它包含了 50 组由 4 种不同的消费级的相机拍摄的图像。然后将去噪图像提交到 DND 官方网站,可以得到 PSNR 和 SSIM 结果。

3) 盲噪声数据集

对于灰度图像和彩色图像的盲去噪,本文从 Waterloo Exploration 数据集中提取 44×44 的干净图像块来训练去噪网络,通过不操作(原始图像),旋转 90° ,旋转 180° ,旋转 270° ,水平翻转,旋转 90° 后水平翻转,旋转 180° 后水平翻转,旋转 270° 后水平翻转来增加训练样本的多样性,为了提高训练方法的鲁棒性,为每个图像块随机选择其中一种策略。

测试数据集包括 68 张 BSD68 灰度图像和 24 张 Kodak24^[29]彩色图像,且它们对应的噪声图像都是通过随机噪声生成器而生成的。

3.2 实验设置

实验参数如表 1 所示,本文采用 $\beta_1 = 0.9$ 、 $\beta_2 = 0.999$ 的 ADAM^[32] 优化器对模型进行优化。纹理提取网络用 60 个 epochs 进行训练,初始学习速率为 1×10^{-3} ,每 10 个 epochs 除以 5 ;去噪网络用 80 个 epochs 进行训练,初始学习速率为 1×10^{-3} ,在训练过程中采用余弦退火策略^[33]将学习率从 10^{-3} 稳步降低到 10^{-6} 。此外,Batch size 设置为 64 ,所有实验都是在操作系统 Windows 11、Python 3.10、CUDA 11.2 和 cuDNN 8.1 环境中实现的,并在一台配备 Intel Core i9-11900K @ 3.50 GHz、16GB RAM 和 NVIDIA GeForce RTX 3090 电脑上运行。

表 1 超参数列表

Table 1 List of hyperparameters

网络	实验参数	$\sigma = 15$
纹理提取网络	损失函数	ℓ_1 损失函数
	优化器	Adam
	批大小	64
	迭代次数	60
	初始学习率	1×10^{-3}
去噪网络	损失函数	ℓ_1 损失函数
	优化器	Adam
	批大小	64
	迭代次数	80
	初始学习率	1×10^{-3}

3.3 实验结果

在本节中,介绍了实验的评价指标、图像纹理特征提取、AWGN 去噪、真实噪声去噪以及盲去噪。

1) 评价指标

利用峰值信噪比(peak signal-to-noise ratio, PSNR)和结构相似性(structural similarity index measurement, SSIM)对重建结果进行定量分析。

2) 图像纹理特征提取

为了验证本文提出的纹理提取网络能够有效地提取图像中的纹理特征,使得去噪后的图像的纹理结构更加清晰可见。从 Set12、BSD68、McMaster 和 Kodak24 这 4 种数据集中分别选取一张图片并添加不同强度的高斯噪声,即使用 4 种类型的加噪图像来验证纹理提取网络的有效性,并进行纹理可视化呈现。

由图 8 可知,通过纹理提取网络能够有效地提取到图像的纹理特征,这些纹理信息具有与原始图像相似的特征,由此可以验证本文提出的纹理提取网络的有效性。

3) AWGN 去噪

(1) 灰度图像

对于灰度图像去噪,本文将 CDC-RASNet 与 BM3D、DnCNN、ADNet、RDN、AGSDNet 和 FEUNet 进行了比较。由图 9 可知,CDC-RASNet 经过了良好的训练,训练集为




图 8 纹理提取结果

Fig. 8 Texture extraction result images




图 9 CDC-RASNet 中的 PSNR 曲线($\sigma=25$)

Fig. 9 PSNR curve of CDC-RASNet($\sigma=25$)

Waterloo Exploration 数据集,在 Set12 的测试数据集上获得了良好的去噪结果。

表 2 显示了 Set12 和 BSD68 上不同网络的合成灰度噪声图像得去噪结果。由表 2 可知,在 Set12 和 BSD68 的不同噪声水平($\sigma=15$ 、25 和 50)下,CDC-RASNet 都优于其他网络。具体来说,在 $\sigma=15$ 时,与第 2 好网络,

CDC-RASNet 在 PSNR 上平均提高了 1.46 dB;在 $\sigma=25$ 时,PSNR 平均提高了 1.43 dB;在 $\sigma=50$ 时,PSNR 平均提高了 1.73 dB。此外,如图 10 和 11 所示,CDC-RASNet 在对 Set12 里的蝴蝶图像进行去噪时和对 BSD68 里的 test006 图像都表现出最佳的视觉效果。

表 2 不同网络在 Set12 和 BSD68 上的 PSNR (dB) 和 SSIM 结果

Table 2 PSNR (dB) and SSIM results for different networks on Set12 and BSD68

数据集	去噪方法	$\sigma=15$	$\sigma=25$	$\sigma=50$
Set12	BM3D	31.92/0.899 4	28.45/0.791 3	26.23/0.643 5
	DnCNN	33.68/0.929 0	31.23/0.883 1	28.06/0.789 6
	ADNet	33.83/0.932 5	31.32/0.887 9	28.04/0.771 3
	RDN	34.06/0.941 3	31.43/0.890 6	28.38/0.811 6
	AGSDNet	34.48/0.947 3	<u>31.69/0.893 7</u>	<u>28.73/0.823 8</u>
	FEUNet	<u>34.89/0.953 6</u>	31.56/0.894 0	28.67/0.824 3
	CDC-RASNet	36.17/0.985 4	32.53/0.939 5	29.49/0.857 5
BSD68	BM3D	33.06/0.912 3	31.36/0.884 3	27.73/0.758 3
	DnCNN	35.23/0.933 7	32.43/0.892 1	28.34/0.765 9
	ADNet	35.53/0.935 6	32.77/0.889 9	28.73/0.773 6
	RDN	35.64/0.938 5	32.73/0.896 1	28.32/0.770 1
	AGSDNet	35.83/0.939 2	33.24/0.899 7	28.87/0.783 7
	FEUNet	<u>36.32/0.942 7</u>	<u>33.91/0.903 5</u>	<u>29.34/0.792 4</u>
	CDC-RASNet	37.96/0.963 1	35.92/0.919 8	32.04/0.829 4

注:最佳 PSNR 的两个结果分别用加粗字体和下划线字体显示($\sigma=15$ 、25 和 50)

(2) 彩色图像

对于彩色图像去噪,将 CDC-RASNet 与 BM3D、DnCNN、ADNet、RDN、AGSDNet 和 FEUNet 进行了比较。表 3 显示了使用 Kodak24 和 McMaster 数据集的 PSNR 和 SSIM 结果。从定量结果可以推断,在低噪声水平下,新提出的 CDC-RASNet 在彩色图像上的去噪效果优于其他所有的图像去噪方法;在高噪声水平($\sigma=50$)下,CDC-RASNet 具有竞争性。此外,由图 12 和 13 可知,与其他去噪网络相比,经过 CDC-RASNet 去噪后的两幅图像的视觉效果更好。

4) 真实噪声去噪

AWGN 去噪虽然能够体现本文去噪方法的有效性,

但它仍然存在明显的局限性。由于真实噪声更加复杂和不可预测,因此评估真实噪声图像的去噪方法更有意义。为了评估 CDC-RASNet 在真实噪声图像的去噪性能,使用了 SIDD 验证集和 DND 噪声数据集。表 4 列出了不同网络的去噪结果,其中 CDC-RASNet 在 SIDD 验证集和 DND 数据集上获得了最佳的 PSNR 和 SSIM 结果。图 14 显示了在 SIDD 数据集上 CDC-RASNet 去噪图像。由图 14 可知,CDC-RASNet 对真实噪声图像去噪也具有较好的去噪效果,具有实际应用价值。

5) 盲去噪

对于盲去噪,将 CDC-RASNet 与 RDN、AGSDNet 和 FEUNet 进行比较。




图 10 不同网络在 Set12 里的蝴蝶图像的去噪结果 ($\sigma=25$)
Fig. 10 Denoising results of butterfly images from different networks in Set12 ($\sigma=25$)




图 11 不同网络在 BSD68 里的 test006 图像的去噪结果 ($\sigma=50$)
Fig. 11 Denoising results of test006 image in BSD68 with different networks ($\sigma=50$)

表 5 显示了使用 DSB68 和 Kodak24 数据集的 PSNR 和 SSIM 结果。从定量结果可以推断,新提出的 CDC-RASNet 在灰度和彩色图像上的去噪效果优于其他的图像去噪方法;此外,由图 15 和 16 可知,与其他去噪网络




图 12 不同网络在 Kodak24 里的 kodim 图像的去噪结果 ($\sigma=25$)
Fig. 12 Denoising results of kodim images of different networks in Kodak24 ($\sigma=25$)



图 13 不同网络在 McMaster 里的一幅图像的去噪结果 ($\sigma=15$)
Fig. 13 Denoising results of an image with different networks in McMaster ($\sigma=15$)

相比,经过 CDC-RASNet 去噪后的两幅图像的视觉效果更好。

表 3 不同网络在 Kodak24 和 McMaster 上的 PSNR (dB) 和 SSIM 结果

Table 3 PSNR (dB) and SSIM results for different networks on Kodak24 and McMaster

数据集	去噪方法	$\sigma = 15$	$\sigma = 25$	$\sigma = 50$
Kodak24	BM3D	30.34/0.883 4	29.45/0.794 3	28.13/0.691 5
	DnCNN	34.01/0.929 1	32.32/0.883 1	29.01/0.789 3
	ADNet	34.94/0.942 5	32.31/0.886 8	29.04/0.791 3
	RDN	35.06/0.944 2	32.63/0.890 7	31.38/0.851 6
	AGSDNet	35.36/0.946 3	32.77/0.891 9	29.23/0.823 6
	FEUNet	<u>35.69/0.948 7</u>	<u>32.93/0.893 7</u>	29.26/0.834 7
	CDC-RASNet	37.17/0.985 4	34.73/0.948 5	<u>29.31/0.845 5</u>
McMaster	BM3D	29.06/0.781 3	27.66/0.664 3	27.73/0.643 6
	DnCNN	33.80/0.854 5	31.47/0.821 3	27.34/0.764 5
	ADNet	33.93/0.865 6	31.56/0.823 9	27.53/0.763 8
	RDN	34.04/0.882 4	31.74/0.826 1	27.82/0.780 1
	AGSDNet	34.23/0.891 2	<u>32.37/0.838 4</u>	27.95/0.789 6
	FEUNet	<u>34.62/0.899 3</u>	31.92/0.830 2	<u>28.34/0.798 3</u>
	CDC-RASNet	36.21/0.936 1	34.91/0.867 4	30.14/0.828 4

注:最佳 PSNR 的两个结果分别用加粗字体和下划线字体显示 ($\sigma = 15, 25$ 和 50)

表 4 不同网络在真实噪声数据集 (SIDD 验证集和 DND) 上的去噪结果

数据集	SIDD 验证集						
去噪方法	BM3D	DnCNN	RDN	ADNet	AGSDNet	FEUNet	CDC-RASNet
PSNR	26.65	27.64	27.35	27.75	28.03	<u>28.34</u>	29.14
SSIM	0.7852	0.799 3	0.798 4	0.804 7	0.813 5	0.822 7	0.867 1
数据集	DND						
PSNR	33.51	36.67	38.26	38.52	38.69	<u>38.83</u>	39.34
SSIM	0.861 2	0.915 6	0.957 3	0.961 4	0.962 1	0.963 3	0.963 7

注:最佳 PSNR 的两个结果分别用加粗字体和下划线字体显示




图 14 CDC-RASNet 在 SIDD 上的去噪图像, 去噪结果来自 SIDD 官方网站

Fig. 14 CDC-RASNet denoised image on SIDD, denoising results from SIDD official website

表 5 不同网络在和 Kodak24 上的 PSNR (dB) 和 SSIM 结果

方法	RDN	AGSDNet	FEUNet	CDC-RASNet
数据集	BSD68			
PSNR	25.49	26.58	26.42	28.32
SSIM	0.814	0.886	0.873	0.931
数据集	Kodak24			
PSNR	23.34	25.03	25.46	26.73
SSIM	0.732	0.814	0.827	0.895

3.4 消融实验

本文提出的去噪网络的有效性依赖于纹理提取网络




图 15 不同网络在 BSD68 里的一幅图像的去噪结果

Fig. 15 Denoising results of an image with different networks in BSD68

的设计,注意力相似性模块的设计和扩张残差块的设计。因此,下面对这些组件进行详细研究,并证明它们在改善去噪结果方面的有效性。

1) 纹理提取网络

纹理信息作为先验知识对于网络的去噪性能至关重要,有必要确定该网络是否提高了去噪性能。首先将其从训练模型中移除,即不使用先验纹理知识进行训练的网络。为此,只给出一幅噪声图像作为图像去噪网络的输入。在 Set12 和 BSD68 数据集上对 $\sigma = \{15, 25, 50\}$




图 16 不同网络在 Kodak24 里的 kodim 图像的去噪结果

Fig. 16 Denoising results of kodim images of different networks in Kodak24

水平进行了测试。为了节省时间,模型只训练了 50 个 epoch,平均 PSNR 随迭代次数变化的曲线如图 17 所示。测试集的 PSNR 结果如表 6 所示,其中,×表示没有使用该纹理提取网络,√表示使用了该纹理提取网络。

表 6 {CDC-RASNet with TENet} 和 {CDC-RASNet without TENet} 在 Set12 和 BSD68 数据集上的 PSNR (dB) 结果 ($\sigma=15, 25$ 和 50)

Table 6 PSNR (dB) results for {CDC-RASNet with TENet} and {CDC-RASNet without TENet} on Set12 and BSD68 datasets ($\sigma=15, 25$ and 50)

数据集	TENet	CDC-RASNet	$\sigma=15$	$\sigma=25$	$\sigma=50$
Set12	×	√	32.87	30.63	27.49
	√	√	33.16	30.75	27.56
BSD68	×	√	31.23	28.24	26.31
	√	√	31.72	28.63	26.52

由图 17 可知,没有纹理信息作为先验知识的去噪网络的去噪效果不如使用纹理信息作为先验知识的去噪网络去噪效果好。从表 6 中也可以看出,没有使用纹信息作为先验知识的去噪网络去噪效果差,即当 $\sigma=\{15, 25, 50\}$ 时,Set12 数据集的值降低了 $\{0.29, 0.12, 0.07\}$ dB,而 BSD68 数据集的值降低了 $\{0.49, 0.39, 0.21\}$ dB,因此使用纹理作为先验知识可以提高网络的去噪性能。

2) 注意力相似性模块

本文提出的注意力相似性模块 (ASM) 有几个新颖之处:(1)使用注意机制来挖掘图像的全局相似性信息;(2)使用扩张卷积扩大感受野,从而更好地聚焦图像的全局相似性信息;(3)使用平均池化操作平滑和抑制噪声。

为了验证 ASM 的有效性,设计了一组对比实验,比较扩张残差模块 (CDC-RM) 和扩张残差注意力相似性模块 (CDC-RASM) 在 Set12 和 BSD68 数据集上的图像去噪




图 17 不同网络下平均 PSNR 随迭代次数变化的曲线

Fig. 17 Average PSNR curve with the number of iterations under different networks

效果。为了节省时间,模型只训练了 50 个 epoch,平均 PSNR 随迭代次数变化的曲线如图 18 所示。测试集的 PSNR 结果如表 7 所示。其中,CDC-RM 没有使用 ASM, CDC-RASM 使用了 ASM。




图 18 不同模块下平均 PSNR 随迭代次数变化的曲线

Fig. 18 Average PSNR curve with the number of iterations under different modules

表 7 CDC-RASM 和 CDC-RM 在 Set12 和 BSD68 上的 PSNR (dB) 结果 ($\sigma=15, 25$ 和 50)

Table 7 PSNR (dB) results of CDC-RASM and CDC-RM on Set12 and BSD68 ($\sigma=15, 25$ and 50)

数据集	模块	$\sigma=15$	$\sigma=25$	$\sigma=50$
Set12	CDC-RM	32.87	30.56	27.38
	CDC-RASM	32.91	30.78	27.54
BSD68	CDC-RM	31.34	29.06	26.12
	CDC-RASM	31.46	29.19	26.26

由图 18 可知,CDC-RASM 去噪效果比 CDC-RM 好。由表 7 可知,所提出的 CDC-RASM 在图像去噪方面有较好的效果,证明了 ASM 的有效性。

3) 扩张残差模块

残差模块在图像去噪网络中起着关键的作用,其设计可以很复杂。通常,一个残差模块包含了多个卷积层、批量归一化层和激活函数。通过叠加多个残差模块,可

以构建出深层的卷积神经网络,实现高效的特征学习和表达能力。为此,对残差模块进行了消融实验,测试结果如表 8 所示,残差模块图如图 19 所示。B 表示批量归一化,C 表示普通卷积,D 表示扩张卷积,R 表示 ReLU。




图 19 不同的残差模块
Fig. 19 Different residual modules

(1) 根据图 19(a)、(f) 和(h) 的比较,在第 1 层和第 2 层 C 或 D 之间添加 B 会使结果更差。由于 B 类似于图像的一种对比度拉伸,一幅图像通过 B 后,其分布被归一化,破坏了图像原有的对比度信息,因此 B 的加入会影响网络输出的质量。

(2) 根据图 19(a)、(b) 和(c) 的比较,在 ResBlock 的末尾,加入 B、R 或 BR 对网络的输出几乎无影响。

(3) 根据图 19(b) 和(e)、(f) 和(g) 以及图 19(c) 和(d) 的比较,在最后一层用 D 代替 C 不能提高网络的输出效果。

(4) 根据图 19(i),可得出使用 C 和 D 且没有 B 或 R 的组合获得较好性能。此外,与图 19(j) 相比,一个区块中的 3 个卷积层是合适的。

从表 8 可以看出,与其他残差模块相比,CRC-ResBlock、CCR-ResBlock、CRD-ResBlock 和 CDC-ResBlock 相对较好。为了进一步区分,使用不同类型的噪声在 BSD68 上测试这 4 个残差模块。结果如表 9 所示,由表 9 可知 CDC-Resblock 是最好的。

3.5 复杂性分析

模型的测试速度也是一个重要的评价指标。因此,使用噪声水平为 $\sigma = 50$ 且像素为 256×256 和 512×512 的两种灰度图像进行测试,并将 CDC-RASNet 模型与 BM3D、DnCNN、RDN、ADNet、AGSDNet 和 FEUNet 比较,

表 8 不同的 ResBlocks 在 Set12 上的 PSNR (dB) 和 SSIM 结果

Table 8 PSNR (dB) and SSIM results of different ResBlocks on Set12

残差模块	PSNR	SSIM
CBRCR-残差块	31.46	0.864 2
CBRCB-残差块	31.47	0.864 4
CBRCBR-残差块	31.47	0.864 3
CBRDBR-残差块	31.47	0.864 5
CBRDB-残差块	31.48	0.864 8
CRC-残差块	<u>31.52</u>	0.865 7
CRD-残差块	<u>31.54</u>	0.865 4
CCR-残差块	<u>31.54</u>	0.865 4
CDC-残差块	31.61	0.867 6
CDCC-残差块	31.48	0.864 6

注:最佳 PSNR 的 4 个结果分别用加粗字体和下划线字体显示 ($\sigma = 25$)

其运行时间结果如表 10 所示。由表 10 可知,与 RDN、AGSDNet 和 FEUNet 相比,新提出的 CDC-RASNet 模型的速度更快。

此外,ADNet 是为解决资源约束情况而提出的轻量级模型,其参数更小。将 CDC-RASNet 模型与 AGSDNet 和 FEUNet 相比,CDC-RASNet 模型参数相对较少,因此该模型性能更好。

表 9 不同的 ResBlocks 在 BSD68 上的 PSNR(dB) 和 SSIM 结果

Table 9 PSNR (dB) and SSIM results of different ResBlocks on BSD68

残差模块	$\sigma = 15$	$\sigma = 25$	$\sigma = 50$
CRC-残差块	32.76/0.892 3	30.21/0.833 4	27.31/0.724 6
CCR-残差块	32.75/0.891 7	30.31/0.833 9	<u>27.41/0.725 6</u>
CRD-残差块	<u>32.77/0.892 1</u>	<u>30.32/0.833 5</u>	27.36/0.725 1
CDC-残差块	32.81/0.898 5	30.35/0.836 3	27.49/0.728 3

注:最佳 PSNR 的两个结果分别使用加粗字体和下划线字体显示 ($\sigma = 15, 25$ 和 50)

表 10 不同网络在 McMaster 上的参数和运行时间的结果比较 ($\sigma = 50$)

Table 10 Comparison of parameters and running time of different networks on McMaster ($\sigma = 50$)

去噪方法	设备	PSNR/256×256	PSNR/512×512	参数
BM3D	CPU	26.05/0.60	28.06/2.54	-
DnCNN	GPU	26.71/0.007 2	28.40/0.018 9	534 K
ADNet	GPU	26.71/0.009 7	28.59/0.0219	539 K
RDN	GPU	26.66/0.021 4	28.76/0.077 5	20.24 M
AGSDNet	GPU	26.54/0.031 9	28.69/0.064 6	22.39 M
FEUNet	GPU	26.68/0.030 8	28.77/0.078 3	21.41 M
CDC-RASNet	GPU	26.95/0.019 5	28.81/0.032 0	20.31 M

4 结 论

本文提出了一种用于图像去噪的扩张残差注意力相似性去噪网络 (CDC-RASNet)。CDC-RASNet 先使用多尺度特征提取模块提取图像的浅层特征,然后使用扩张残差注意力相似性模块 (CDC-RASM) 进一步挖掘图像的深层特征,其中,CDC-RASM 中的扩张残差模块用来提取图像的局部和全局特征,注意力相似性模块用来提取图像的全局相似性特征,从而充分利用图像的冗余信息。此外,相似的特征具有相似的权重,关键特征会被赋予更多的权重,使模型更适合复杂噪声。另外,CDC-RASNet 还采用全局残差学习的方法增强从浅层到深层的学习效果。与此同时,还提出了纹理提取网络 (TENet) 来提取从噪声图像中包含纹理知识的 LBP 图像。然后将 LBP 图像与噪声图像一起输入到 CDC-RASNet 中,作为去噪过程的指导。通过 LBP 图像,在去噪的同时保留了原始图像的结构。实验结果表明,CDC-RASNet 不仅在灰度和彩色图像上去噪效果较好,也适合于真实噪声图像和盲噪声的去噪。对于 BSD68 灰度图像集和 McMaster 彩色图像集,当噪声水平 $\sigma = \{15, 25, 50\}$ 时,CDC-RASNet 得到的 $PSNR = \{37.96, 35.92, 32.04\}$, $SSIM = \{0.963 1, 0.919 8, 0.829 4\}$, $PSNR = \{36.21, 34.91, 30.14\}$,

$SSIM = \{0.936 1, 0.867 4, 0.828 4\}$ 。在接下来的研究中,希望使用深度可分离卷积代替传统卷积或者双线性卷积代替扩张卷积来减少模型参数的数量。此外,还可以进行压缩来设计轻量级的 CDC-RASNet。

参考文献

[1] 许学彬,陈博桓,赵楠楠,等. 基于 GA-BP 的改进高斯均值区域去噪技术[J]. 电子测量与仪器学报, 2022, 36(2): 107-113.

XU X B, CHEN B H, ZHAO N N, et al. Improved Gaussian mean region denoising based on GA-BP [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(2): 107-113.

[2] 陈怀安,卢小银,单奕萌,等. 高速摄影仪成像噪声去除方法研究[J]. 仪器仪表学报, 2023, 44(2): 211-220.

CHEN H AN, LU X Y, SHAN Y M, et al. Research on imaging noise removal method of high-speed photogrammetry [J]. Chinese Journal of Scientific Instrument, 2023, 44(2): 211-220.

[3] 盖杉,鲍中运. 基于深度学习的高噪声图像去噪算法[J]. 自动化学报, 2020, 46(12): 2672-2680.

GAI SH, BAO ZH Y. Deep learning based denoising algorithm for highly noisy images [J]. Journal of Automation, 2020, 46(12): 2672-2680.

[4] LI S C, LIU K, JIANG J F, et al. An ameliorated denoising scheme based on deep learning for Φ -OTDR system with 41-km detection range [J]. IEEE Sensors Journal, 2022, 22(20): 19666-19674.

[5] LIU H, LI L, LU J, et al. Group sparsity mixture model and its application on image denoising [J]. IEEE Transactions on Image Processing, 2022, 31(9): 5677-5690.

[6] SHAO L, YAN R, LI X, et al. From heuristic optimization to dictionary learning: A review and comprehensive comparison of image denoising algorithms [J]. IEEE Transactions on Cybernetics, 2014, 44(7): 1001-1013.

[7] 程德强,陈杰,寇旗旗,等. 融合层次特征和注意力机制的轻量化矿井图像超分辨率重建方法[J]. 仪器仪表学报, 2022, 43(8): 73-84.

CHENG D Q, CHEN J, KOU Q Q, et al. A super-resolution reconstruction method for lightweight mine images by fusing hierarchical features and attention mechanism[J]. Chinese Journal of Scientific Instrument, 2022, 43(8): 73-84.

[8] 刘一畅,马伟,徐士彪,等. 基于卷积神经网络的边缘保真图像去噪算法[J]. 计算机辅助设计与图形学

- 学报, 2020, 32(11): 1822-1831.
- LIU Y CH, MA W, XU SH M, et al. An edge-fidelity image denoising algorithm based on convolutional neural network [J]. Journal of Computer-Aided Design and Graphics, 2020, 32(11): 1822-1831.
- [9] 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.
- [10] 王洪雁, 王拓, 潘勉, 等. 基于伽马范数最小化的图像去噪算法[J]. 通信学报, 2020, 41(10): 222-230.
- WANG H Y, WANG T, PAN M, et al. Image denoising algorithm based on gamma-paradigm minimization [J]. Communications Letters, 2020, 41(10): 222-230.
- [11] ZHANG Y, TIAN Y, KONG Y, et al. Residual dense network for image restoration [J]. IEEE Transactions on Image Processing, 2020, 43(9): 2480-2495.
- [12] TIAN C, XU Y, ZUO W. Image denoising using deep CNN with batch renormalization [J]. Neural Networks, 2020, 121(5): 461-473.
- [13] YAN S, LONG Y, FU R H, et al. A method for denoising seismic signals with a CNN based on an attention mechanism [J], IEEE Transactions on Geoscience and Remote Sensing, 2022, 60(1): 1-15.
- [14] LATIFI B, RAIE A. Image denoising using convolutional neural network [C]. 2022 30th International Conference on Electrical Engineering (ICEE). IEEE, 2022: 185-190.
- [15] WU W, LV G, LIAO S, et al. FEUNet: A flexible and effective U-shaped network for image denoising [J]. Signal, Image and Video Processing, 2023, 17(5): 2545-2553.
- [16] THAKUR R K, MAJI S K. Agsdnet: Attention and gradient-based sar denoising network [J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19(1): 1-5.
- [17] ZHANG Q, XIAO J, TIAN C, et al. A robust deformed convolutional neural network (CNN) for image denoising [J]. CAAI Transactions on Intelligence Technology, 2023, 8(2): 331-342.
- [18] ZHU S, YU Z. Self-guided filter for image denoising [J]. IET Image Processing, 2020, 14(11): 2561-2566.
- [19] 赵雅琴, 宋雨晴, 吴晗, 等. 基于 DenseNet 和卷积注意力模块的高精度手势识别 [J]. 电子与信息学报, 2023, 6(1): 1-10.
- ZHOU Y X, SONG Y Q, WU H, et al. Highly accurate gesture recognition based on DenseNet and convolutional attention module [J]. Journal of Electronics and Information, 2023, 6(1): 1-10.
- [20] YU F, KOLTUN V, FUNKHOUSER T. Dilated residual networks [C]. IEEE Computer Society. IEEE Computer Society, 2017.
- [21] WANG P, CHEN P, YUAN Y, et al. Understanding convolution for semantic segmentation [C]. 2018 IEEE Winter Conference on Applications of Computer Vision (WACV). IEEE, 2018.
- [22] CHEN S, YANG J, WEI Y, et al. δ -norm-based robust regression with applications to image analysis [J]. IEEE Transactions on Cybernetics, 2021, 51(6): 3371-3383.
- [23] LU B, GAI S, XIONG B S, et al. Single image deraining with dual U-Net generative adversarial network [J]. Multidim Syst Sign Process, 2022, 33(2): 485-499.
- [24] ZEEBAREE D Q, ABDULAZEEZ A M, ZEBARI D A, et al. Multi-level fusion in ultrasound for cancer detection based on uniform LBP features [J]. Computers, Materials & Continua, 2021, 66(3): 3363-3382.
- [25] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2018.
- [26] WEI F, ZHU Z H, ZHOU H, et al. Efficient automatically evolving convolutional neural network for image denoising [J]. Memetic Comp, 2023, 15(2): 219-235.
- [27] MA K, DUAN Z, WU Q, et al. Waterloo exploration database: new challenges for image quality assessment models [J]. IEEE Transactions on Image Processing, 2017, 26(2): 1004-1016.
- [28] ROTH S, BLACK M J. Fields of experts: A framework for learning image priors [C]. IEEE Computer Society Conference on Computer Vision & Pattern Recognition. IEEE, 2005.
- [29] KIM J, LEE J K, LEE K M. Accurate image super-resolution using very deep convolutional networks [J]. IEEE, 2016, 34(6): 1646-1654.
- [30] ZHANG D, ZHOU F. Self-supervised image denoising for real-world images with context-aware transformer [J]. IEEE Access, 2023, 22(9): 14340-14349.
- [31] SONG Y D, ZHU Y F, DU X. Grouped multi-scale network for real-world image denoising [J]. IEEE Signal Processing Letters, 2020, 27(4): 2124-2128.
- [32] KINGMA D, BA J. Adam: A method for stochastic optimization [J]. Computer Science, 2014, 35(4): 1-9.

55-67.

[33] 李弟文, 潘伟. 改进的残差网络和混合注意力的人脸表情识别[J]. 智能计算机与应用, 2023, 13(5): 9-17.

LI D W, PAN W. Improved face expression recognition with residual networks and mixed attention [J]. Intelligent Computer and Applications, 2023, 13(5): 9-17.

作者简介



周先春(通信作者), 2011 年于南京信息工程大学获得博士学位, 现为南京信息工程大学硕士生导师, 教授, 中国电子学会高级会员, 主要研究方向为信号与信息处理。
E-mail: zhouxc2008@163.com

Zhou Xianchun (Corresponding author)

received Ph. D. degree from Nanjing University of Information Science and Technology in 2011. Now he is a professor and M.Sc. supervisor at Nanjing University of Information Science and Technology, is also a senior member of China Electronics Society. His main research interests include signal and information processing.



史振婷, 2022 年于金陵科技学院获得学士学位, 现为南京信息工程大学硕士研究生, 主要研究方向为数字图像处理。
E-mail: szt19981026@163.com

Shi Zhengting received her B. Sc. degree

from Jinling University of Science and Technology in 2022. Now she is a M. Sc. candidate at Nanjing University of Information Science and Technology. Her main research interest includes digital image processing.



王子威, 2022 年于南京信息工程大学获得学士学位, 现为南京信息工程大学硕士研究生, 主要研究方向为无线网络优化、AI 在通信系统中应用、图神经网络等。
E-mail: 1151821037@qq.com

Wang Ziwei received a B. Sc. degree

from Nanjing University of Information Science and Technology in 2022. Now he is a M. Sc. candidate in Nanjing University of Information Science and Technology. His main research interests include wireless network optimization, AI application in communication systems and graph neural networks.



李婷, 2021 年于南京工程学院获得学士学位, 现为南京信息工程大学硕士研究生, 主要研究方向为数字图像处理。
E-mail: 12574831840@163.com

Li Ting received her B. Sc. degree from

Nanjing Institute of Technology in 2021. Now she is a M. Sc. candidate at Nanjing University of Information Science and Technology. Her main research interest includes digital image processing.



张影, 2022 年于南京信息工程大学滨江学院获得学士学位, 现为南京信息工程大学硕士研究生, 主要研究方向为数字图像处理。
E-mail: is_zy4091@163.com

Zhang Ying received her B. Sc. degree

from Binjiang College, Nanjing University of Information Science and Technology in 2022. Now she is a M. Sc. candidate at Nanjing University of Information Science and Technology. Her main research interest includes digital image processing.