

基于多方向梯度网络的自适应边缘 信息图像去噪模型

王梓桐¹, 赵 晶², 乔 双³, 朱 芮⁴

(1. 吉林大学 计算机科学与技术学院, 长春 130012; 2. 北京理工大学 光电学院, 北京 100081; 3. 东北师范大学 物理学院, 长春 130024; 4. 吉林大学 通信工程学院, 长春 130012)

摘 要: 针对现有的基于学习的图像去噪算法不能很好地保留图像边缘和纹理信息的不足, 本文提出了一种基于多方向梯度网络的自适应边缘信息图像去噪模型, 能够分别捕获不同类别的图像信息。首先, 采用多方向梯度算子过滤干净目标图像以获取无噪声梯度图, 引导多方向梯度网络学习无噪声梯度图。其次, 提出自适应梯度融合模块, 自适应地融合梯度信息与噪声图像, 提高去噪网络对边缘和纹理信息的关注度。实验结果表明, 本文模型在 PSNR 和 SSIM 指标方面具有良好性能。此外, 去噪后的图像始终具有更好的视觉质量, 从而展示了其在图像去噪中的应用潜力。

关键词: 深度神经网络; 图像去噪; 梯度算子; 自适应融合

中图分类号: TP391.4 **文献标志码:** A **文章编号:** 1671-5497(2025)10-3319-10

DOI: 10.13229/j.cnki.jdxbgxb.20231453

Adaptive edge information image denoising model based on multi-directional gradient network

WANG Zi-tong¹, ZHAO Jing², QIAO Shuang³, ZHU Rui⁴

(1. College of Computer Science and Technology, Jilin University, Changchun 130012, China; 2. School of Optics and Photonics, Beijing Institute of Technology, Beijing 100081, China; 3. College of Physics, Northeast Normal University, Changchun 130024, China; 4. College of Communication Engineering, Jilin University, Changchun 130012, China)

Abstract: To address the limitation that existing learning-based image denoising algorithms struggle to preserve edges and textures, we propose an adaptive edge-aware denoising model built upon a multi-directional gradient network that can capture distinct image information separately. First, multi-directional gradient operators are applied to the clean target image to generate noise-free gradient maps, which then guide the network in learning gradient representations free from corruption. Second, an adaptive gradient-fusion module is introduced to fuse gradient cues with the noisy image adaptively, increasing the network's attention to edge and texture details. Experimental results demonstrate that the proposed model achieves competitive PSNR and SSIM values. Moreover, the denoised images consistently exhibit superior visual

收稿日期: 2023-12-28.

基金项目: 吉林省科技厅青年成长科技项目(20230508164RC).

作者简介: 王梓桐(2000-), 女, 博士研究生. 研究方向: 深度学习及图像去噪. E-mail: softlikeyou@163.com

通信作者: 朱芮(1993-), 女, 讲师, 博士. 研究方向: 图像处理. E-mail: zhurui@jlu.edu.cn

quality, underscoring the model's potential for practical image-denoising applications.

Key words: deep neural network; image denoising; gradient operator; adaptive fusion

0 引言

图像去噪是指通过数学模型和算法,抑制和去除图像中的噪声,进而恢复得到高质量图像的任务过程。去噪任务可以表示为 $y=x+n$,其中 y 为观察到的退化图像, x 为潜在的干净图像, n 为噪声。由于图像项 x 和噪声项 n 都是未知的,因此求解 y 的问题是不可逆的退化过程,其要求在减弱噪声的同时尽可能地保留图像的边缘、纹理等高频信息,因此设计理想的图像去噪算法是必要且困难的。

传统的基于非学习的图像去噪算法分为基于滤波和基于模型先验知识两类。基于滤波图像去噪算法主要包含中值滤波^[1]、均值滤波^[2]、非局部均值滤波^[3]、三维块匹配协同滤波(Block-matching 3D collaborative filtering, BM3D)^[4,5]等。基于模型先验知识图像去噪算法分为总变分^[6-8]、稀疏表示^[9-13]、低秩矩阵^[14-18]等。这些方法通常将图像分成多个小区块进行分块去噪,再合并为一个完整的图像。虽然这些方法简单易行,且在多种噪声场景下均具有一定去噪效果,但存在分块操作导致图像边缘模糊、图像整体过度平滑等问题。

随着卷积神经网络技术的不断发展,深度学习方法被引入图像去噪任务中^[19-22]。通常假设噪声 n 为均值且等于0,方差为固定的加性高斯白噪声。Zhou等^[23]首次引入卷积神经网络完成图像去噪任务,提出可以通过神经网络恢复干净图像。Jain等^[24]通过设计多层卷积网络,获取了更优的去噪效果,证明多层卷积可以提取更有效的特征。Chen等^[25]采用梯度下降法训练非线性反应扩散(Trainable nonlinear reaction diffusion, TNRD)网络结构,使其能够更好地保留噪声图像的基本信息。Zhang等^[26]结合残差学习、批归一化(Batch normalization, BN)结构、线性整流函数及激活函数,提出了去噪卷积神经网络(Denoising convolution neural network, DnCNN),该网络在高斯噪声去噪任务中表现出出色的去噪性能和模型运算速度。Mao等^[27]提出了具有对称跳连接的深度全卷积编码解码网络。Tai等^[28]提出了深层持久记忆网络(Memory network, MemNet),通过自适应学习使神经网络保持对浅层特征的持久记

忆。为了提高网络处理噪声的灵活性并使其能够适应不同程度的噪声,Zhang等^[29]通过预估噪声水平并将其与噪声图像一起输入网络,提出了FFDNet。随着研究的深入,受传统算法的启发,部分基于深度学习的算法引入了图像非局部相似性。例如,NLRN^[30]和N³Net^[31]将图像的非局部特性嵌入深度神经网络中,虽然在利用传统算法的同时也发挥了深度学习的优势,但是在图像边缘、纹理等信息上缺乏一定关注度,导致去噪结果不理想。

为解决上述问题,本文利用多方向梯度网络和去噪网络分别学习不同目标图像,有针对性地获取不同信息以提高去噪图像质量。首先,采用多方向梯度网络学习多方向干净梯度图像,利用不同方向梯度图更好地反映图像的边缘和结构信息特点,有效弥补网络获取高频信息(如边缘信息)的缺失。其次,提出纹理结构融合模块,促进梯度图像自适应融合到噪声图像中,助力网络提高对边缘和纹理信息的关注程度。最后,进行了实验验证,结果表明本文模型具有良好的性能。

1 网络模型设计

本章首先说明网络整体架构,然后详细阐述架构中的各个组成部分。

1.1 整体架构

如图1所示,本文提出的网络由多方向梯度网络和去噪网络并行组成。多方向梯度网络的输入图像与分层输入梯度网络(Layered Input GradientNet, LIGN)相似:将输入的噪声图像按比特分层后并行送入该网络,最终学习得到4通道或12通道梯度图像。为了更好地利用梯度图像的信息,原始的噪声图像和梯度图像共同送入去噪网络,以获取最终的去噪图像。此外,在去噪网络前端设置自适应梯度融合模块,用于高效融合噪声图像和梯度图像。

1.2 多方向梯度网络

(1)网络架构:如图2所示,多方向梯度网络(Multi-directional gradient network, MGradNet)主干由编码器模块([Conv+BN+ReLU]×2+




图 1 网络整体架构

Fig. 1 Network overall architecture




图 2 多方向梯度网络和去噪网络的网络架构

Fig. 2 Network architecture of multi-directional gradient network and denoising network

[Conv+stride=2+BN+ReLU)、中间模块([Conv+BN+ReLU)、解码器模块([Transpose Conv+BN+ReLU]+[Conv+BN+ELU]×2)及

(2)约束函数:本文采用多方向边缘算子过滤训练目标图像(无噪声图像),并将过滤得到的干净梯度图作为多方向梯度网络的目标图像。通过损失函数约束多方向梯度网络获取干净梯度图,具体可以表示为:

$$\mathcal{L}_1 = \mathcal{L}_{\text{char}} \| \text{MGradNet}(\text{layer}), F_{\text{gradient}}(Y) \| \quad (1)$$

式中: Y 和 layer 分别为干净图像和按比特分层后的噪声图像; $\text{MGradNet}(\cdot)$ 为多方向梯度网络; $\mathcal{L}_{\text{char}}$ 为损失函数 Charbonnier loss^[32]; F_{gradient} 为4个方向的梯度算子,具体可以表示为:

尺度间的对称跳跃连接组成,最后一层使用128个3×3过滤器进行图像重建。

$$F_{s1} = \begin{bmatrix} 5 & 5 & -3 \\ 5 & 0 & -3 \\ -3 & -3 & -3 \end{bmatrix}, F_{s2} = \begin{bmatrix} -3 & 5 & 5 \\ -3 & 0 & 5 \\ -3 & -3 & -3 \end{bmatrix}$$

$$F_{s3} = \begin{bmatrix} -3 & -3 & 5 \\ -3 & 0 & 5 \\ -3 & -3 & 5 \end{bmatrix}, F_{s4} = \begin{bmatrix} -3 & -3 & -3 \\ -3 & 0 & 5 \\ -3 & 5 & 5 \end{bmatrix} \quad (2)$$

式中: $F_{sj}(\cdot)$ 为梯度算子,其中 j 代表4个不同方向梯度算子($j=1,2,3,4$)。相比于单一梯度图存在信息受限问题,多方向梯度图可以更好地展现图像在不同方向上的梯度,进而提高网络对细节和纹理的关注度。由于目标图像被设置为无噪声梯度图像,因此多方向梯度网络的输出图像近乎无

噪声,具体内容见 3.1 节。此外,由于采用 4 个方向的梯度算子,因此对梯度信息的描述也更为多元。

1.3 去噪网络

(1) 网络架构:如图 2 所示,去噪网络(Denoised network)将多方向梯度网络的 128 个 3×3 滤波器替换为自适应梯度融合模块,其他网络架构均相同。

(2) 自适应梯度融合模块:多方向梯度网络




图 3 自适应梯度融合模块

Fig. 3 Architecture of AGFM

首先,通过 {Concat+Conv 3×3 +ReLU} 操作有效地融合输入图像,获取特征 x_1 。

其次,将特征 x_1 分别输入自适应融合模块 (Adaptive fusion module, AFM)、结构融合模块 (Structure fusion module, SFM) 和细节融合模块 (Detail fusion module, DFM)。在自适应融合模块中,首先平均池化 x_1 特征通道并转换至二维空间,以获取全局特征;其次采用 1 组 {Linear+ReLU+Linear} 操作校准全局特征;最后采用 softmax 激活函数输出预测权重。自适应融合模块可以表示为 $\{\alpha, \beta\} = \text{AFM}(x_1)$, 其中 α, β 为不同特征权重。在细节融合模块中,随着卷积层数增加,提取特征的视野不断扩大,网络对纹理的关注度逐渐增高。通过 3 组 {Conv 3×3 +ReLU} 操作逐步提取特征 x_1 , 以获取细节信息,最后经 1 层 Conv 3×3 操作获取最终特征 x_d 。细节融合模块可以表示为 $x_d = \text{DFM}(x_1)$ 。结构融合模块旨在处理全局特征,因此引入空间注意力机制以获取最终输出特征 x_s 。为了更好地获取结构权重信息,采用 {Conv 3×3 +GELU} 激活层增强输入特征 x_1 的信息表达,最终输入注意力机制模块。结构融合模块可以表示为 $x_s = \text{SFM}(x_1)$ 。

最后,梯度融合网络的输出可以表示为:

$$y = (\alpha \otimes x_s) \oplus (\beta \otimes x_d) \quad (3)$$

式中: $\otimes$ 代表对应矩阵元素相乘; $\oplus$ 代表对应矩

阵元素相加; y 为最终输出特征。其通过线性层捕获全局信息,得到系数 α 和 β 表示相对权重,其中 $\alpha + \beta = 1$ 。

如图 3 所示,原始噪声图像和梯度图像并行输入梯度融合网络,通过融合—分离—融合的操作,提取得到包含大量边缘结构信息的特征。

阵元素相加; y 为最终输出特征。其通过线性层捕获全局信息,得到系数 α 和 β 表示相对权重,其中 $\alpha + \beta = 1$ 。

(3) 损失函数:去噪网络的输入为梯度图像和噪声图像,目标图像设置为原始目标图像。具体可以表示为:

$$\mathcal{L}_2 = \mathcal{L}_{\text{char}} \|\text{DenoisedNet}(x, x_{\text{grad}}), Y\| \quad (4)$$

式中: x 和 x_{grad} 分别为噪声图像和梯度图像; $\text{DenoisedNet}(\cdot)$ 为去噪网络。通过式(4)约束去噪网络学习干净图像 Y 。

2 实验结果及分析

2.1 训练细节

训练使用的 GPU 型号为 RTX3090, 处理器为 AMD3900X, 系统内存为 16 GB。采用 Adam^[33] 优化器, 初始学习率为 0.001, 第一次衰减率设为 0.9, 第二次衰减率设为 0.999, 批次大小为 30。选择 PSNR 和 SSIM^[34] 作为评价指标评估去噪效果。

2.2 数据集说明

假设噪声为零均值且噪声水平为 σ_n 的高斯噪声 (Additive white gaussian noise, AWGN)。采用 BSD400^[35] 和 DIV2K^[36] 作为训练集, 将训练数据随机裁剪为 128×128 的图像块, 并进行旋转和水平翻转以增强训练样本。此外, 采用

Set12^[37]、BSD68^[38]及Urban100^[39]数据集进行验证。

2.3 不同算法性能比较

为评估本文算法的有效性,选取7种去噪算法作为对比算法。这些算法包括4个经典深度学习算法(DnCNN^[26]、MemNet^[28]、FFDNet^[29]和N³Net^[31])和3个近期主流深度学习算法(LIGN^[40]、MWDCNN^[41]和DRANet^[42])。上述算法均通过本文的训练细节获得最终去噪结果。表1~3分别列出不同算法在3种高斯噪声水平下的表现情况。以噪声等级 $\sigma_n=50$ 的结果为例(数据集为Set12、BSD68和Urban100),与经典深度学习算法相比,本文算法在PSNR和SSIM指标上有较大的提升。例如,相较于经典算法DnCNN,其PSNR提升约0.33~1.81 dB,SSIM提升约0.020 3~0.049。与基于非局部相似性(NSS)建模的N³Net相比,本文算法同样有明显的提升,尤其在Urban100数据集上,PSNR、SSIM增益分别为1.27 dB、0.022 3。相较于近3年的去噪模型,本文算法在包含较多边缘结构信息的Urban100数据集上展现出一定优势。以高等级噪声($\sigma_n=50$)为例,相较于最新模型DRANet,本文算法的PSNR、SSIM分别提升0.19 dB、0.007;相较于LIGN的增益分别为0.41 dB、0.010 3;与MWDCNN相比,PSNR、SSIM增益分别达到0.97 dB、0.030 1。此外,本文算法在Set12和BSD68数据集上始终保持最优结果。以上结果均表明,本文设计的网络结构具有有效性和良好

表1 不同去噪算法在3个标准库上的平均

PSNR(dB)/SSIM对比($\sigma_n=15$)

Table 1 Comparison of average PSNR(dB)/SSIM of different denoising algorithms on three standard libraries($\sigma_n=15$)

数据库	Set12		BSD68		Urban100	
指标	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
DnCNN	32.86	0.903 1	31.73	0.890 7	32.68	0.925 5
FFDNet	32.75	0.902 7	31.63	0.890 2	32.43	0.927 3
MemNet	32.84	0.904 4	31.70	0.892 7	32.84	0.926 1
N ³ Net	—	—	—	—	—	—
MWDCNN	32.87	0.907 2	31.87	0.897 6	33.15	0.931 3
LIGN	33.03	0.909 9	31.77	0.896 4	33.46	0.935 6
DRANet	33.00	0.905 6	31.79	0.892 1	33.55	0.932 8
本文算法	33.19	0.911 8	31.93	0.900 6	33.86	0.938 9

注:“—”代表源代码未提供该数据。

表3 不同去噪算法在3个标准库上的平均

PSNR(dB)/SSIM对比($\sigma_n=50$)

Table 3 Comparison of average PSNR(dB)/SSIM of different denoising algorithms on three standard libraries($\sigma_n=50$)

数据库	Set12		BSD68		Urban100	
指标	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
DnCNN	27.18	0.782 9	26.23	0.718 9	26.28	0.787 4
FFDNet	27.32	0.790 3	26.29	0.724 5	26.52	0.805 7
MemNet	27.38	0.793 3	26.35	0.729 7	26.64	0.802 9
N ³ Net	27.43	0.795 0	26.40	0.730 2	26.82	0.814 1
MWDCNN	27.36	0.790 4	26.40	0.729 7	27.12	0.806 3
LIGN	27.61	0.793 3	26.53	0.736 2	27.68	0.826 1
DRANet	27.62	0.800 3	26.47	0.731 6	27.90	0.829 4
本文算法	27.76	0.803 9	26.56	0.739 2	28.09	0.836 4

表2 不同去噪算法在3个标准库上的平均

PSNR(dB)/SSIM对比($\sigma_n=25$)

Table 2 Comparison of average PSNR(dB)/SSIM of different denoising algorithms on three standard libraries($\sigma_n=25$)

数据库	Set12		BSD68		Urban100	
指标	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
DnCNN	30.44	0.862 2	29.23	0.828 7	29.97	0.879 7
FFDNet	30.43	0.863 4	29.19	0.828 9	29.92	0.888 6
MemNet	30.43	0.860 2	29.20	0.826 2	30.45	0.882 9
N ³ Net	30.50	0.865 1	29.30	0.832 9	30.19	0.891 0
MWDCNN	30.52	0.867 0	29.34	0.837 6	30.64	0.892 9
LIGN	30.72	0.871 1	29.25	0.833 4	31.04	0.901 3
DRANet	30.69	0.868 1	29.36	0.832 6	31.18	0.899 9
本文算法	30.83	0.873 0	29.48	0.842 4	31.39	0.906 3

的建模能力。表4列出了在噪声等级 $\sigma_n=50$ 时,不同去噪算法在Set12数据集上单张图像的PSNR值。由表4可以看出,本文算法的PSNR值远远高于经典算法,其中,本文算法相比N³Net平均高出0.3 dB。本文算法相较于MWDCNN和LIGN始终保持去噪最佳性能,并且基本优于最新算法DRANet。

为进一步验证本文算法的有效性,采用单张图像的视觉效果进行验证。由图4中名为“star”的图像可见,经典算法DnCNN和FFDNet出现伪影,且边缘部分识别度较低,不能完全恢复图像的有效信息。与原图相比,LIGN虽然恢复出清晰的结构,但边缘过度平滑;MWDCNN部分纹理信息模糊。与上述算法研究结果相比,本文算法

表 4 不同去噪算法在 Set12 数据集上的单张图像 PSNR(dB) 对比 ($\sigma_n=50$)

Table 4 Comparison of single image PSNR(dB) of different denoising algorithms on the Set12 dataset ($\sigma_n=50$)

算法	C.man	House	Peppers	Starfish	Monarch	Airplane	Parrot	Lena	Barbara	Boat	Man	Couple
DnCNN	27.03	30.00	27.32	25.70	26.78	25.87	26.48	29.39	26.22	27.20	27.24	26.90
FFDNet	27.05	30.37	27.54	25.75	26.81	25.89	26.57	29.66	26.45	27.33	27.29	27.08
MemNet	27.17	30.52	27.47	25.81	26.98	25.95	26.52	29.68	26.67	27.34	27.30	27.14
N ³ Net	27.18	30.60	27.63	26.13	27.02	25.94	26.47	29.65	26.92	27.33	27.26	27.03
MWDCNN	27.15	30.56	27.44	25.82	27.00	25.83	26.53	29.64	26.67	27.32	27.22	27.08
LIGN	27.30	30.86	27.67	26.39	27.13	26.03	26.67	29.87	27.34	27.49	27.30	27.26
DRANet	27.58	30.89	27.62	25.99	27.13	26.03	26.67	29.59	27.34	27.57	27.34	27.36
本文算法	27.42	31.09	27.81	26.69	27.22	26.04	26.67	29.96	27.82	27.58	27.37	27.38

引入多方向的干净梯度图像,使图像边缘信息及主要轮廓部分保留得更加清晰且完整,从而提升了图像的整体视觉效果。图 5 和图 6 进一步展示了当噪声等级为 50 和 25 时,不同数据集中单张图片在不同算法中的表现。分析表明,对比算法获取的去噪图像均出现不同程度的缺陷:恢复的纹理和边缘或过于平滑,或发生畸变,或丢失部分细节。相比之下,本文算法在精细细节恢复方面表现更优,视觉效果更佳,取得了令人满意的结果。例如,在图 5 建筑窗户和墙体处,DnCNN、FFDNet 和 MemNet 在边缘处产生畸变;N³Net 和 LIGN 恢复的纹理存在一定程度的失真,并伴有




图 4 当噪声等级为 50 时,不同算法在 Set12 数据集上图片“star”上的去噪结果

Fig.4 Denoising results on image “star” from Set12 dataset by different algorithms when noise level of 50




图 5 当噪声等级为 50 时,不同算法在 BSD68 数据集中图片“test011”上的去噪结果

Fig.5 Denoising results on image “test011” from BSD68 dataset by different algorithms when noise level of 50




图 6 当噪声等级为 25 时,不同算法在 Urban100 数据集中图片“img055”上的去噪结果

Fig.6 Denoising results on image “img055” from the Urban100 dataset by different algorithms when noise level of 25

明显的伪影;本文算法能有效去除噪声,且恢复的细节信息与原始图像较为接近,去噪质量也有较大提升。

综上所述,无论从客观指标还是主观视觉效果,本文算法都能有效去除不同程度的噪声,并且在恢复图像的纹理、边缘和结构等细节信息方面

具有一定优势。

2.4 推理时间和模型参数量

表5总结了各模型参数量及噪声等级为50时不同尺寸噪声图像的推理时间。需要注意的是,所有实验都使用Nvidia3090对Urban100数据集进行测试。

表5 不同去噪网络模型参数量及在尺寸为 256×256 、 512×512 和 $1\,024 \times 1\,024$ 且噪声等级为50的噪声图像上的运行时间比较

Table 5 Comparison of different denoising network model parameter quantities and running time on noisy images of size 256×256 , 512×512 and $1\,024 \times 1\,024$ and noise level 50

尺寸/资源消耗	DnCNN	MemNet	FFDNet	N ³ Net	DRANet	MWDCNN	LIGN	MDGAENet
Size 256×256	0.01	0.88	0.01	0.17	0.08	0.06	0.02	0.01
Size 512×512	0.05	3.61	0.03	0.74	0.38	0.22	0.06	0.12
Size $1\,024 \times 1\,024$	0.16	14.69	0.11	3.25	1.24	3.89	2.10	1.33
Memory cost/M	0.554	0.667	0.490	0.706	1.211	0.525	3.749	3.845

本文算法相较于经典算法(DnCNN^[26]、MemNet^[28]、FFDNet^[29]、N³Net^[31]),在处理 $1\,024 \times 1\,024$ 尺寸图像时运行时间较慢,模型参数量也较大,但是图像去噪性能有极大的提升。与近3年的最新算法相比,DRANet^[42]和MWDCNN^[41]模型参数量较低,但整体运行时间较慢。特别是在尺寸增大时,MWDCNN的运行时间较本文算法慢2.56 s。由于本文算法基于LIGN^[40]改进而来,因此在模型参数量及运行时间上与LIGN没有明显差距。综上,本文算法在降噪效果、推理速度和模型复杂度之间实现了良好的平衡,能够在保证去噪质量的前提下,具有较快的推理速度和较低的计算资源消耗。

3 消融实验

为了验证多方向梯度网络及梯度融合网络的有效性,本文在噪声等级 σ 为15、25、50的高斯噪声上分别进行消融实验(见表6)。其中:案例1代表本文提出的MDGAENet;案例2代表移除多方向梯度网络后的去噪性能;案例3代表移除梯度融合网络后的去噪性能。

3.1 多方向梯度网络的有效性

多方向梯度网络提供了足够的边缘和结构信息,助力MDGAENet提取有效信息。为了验证多方向梯度网络的有效性,本文在测试阶段输出多方向梯度网络的图像。如图7所示,第一列为多方向梯度网络输出的梯度图像,第二列为输入

表6 消融实验

Table 6 Ablation study

评估指标	$\sigma=50$		$\sigma=25$		$\sigma=15$	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
案例1	27.76	0.802 4	30.82	0.873 6	33.19	0.911 8
案例2	27.31	0.785 0	30.52	0.867 2	32.82	0.906 7
案例3	27.60	0.800 0	30.71	0.869 4	33.06	0.909 9

噪声图像的梯度图像。通过对比可见,多方向梯度网络输出的梯度图像过滤了大量噪声,且基本完整保留图像的结构和边缘信息;而包含噪声的梯度图像则由于噪声干扰导致眼部轮廓及发丝边缘不再清晰。此外,移除多方向梯度网络后,网络整体去噪性能下降。当噪声等级为50时,PSNR、SSIM分别下降0.37 dB、0.005 1;当噪声等级为25时,去噪性能分别下降0.3 dB、0.006 4。由此可见,干净梯度信息可以潜在地引导网络获取更多有效信息,提高网络整体去噪性能。

3.2 梯度融合网络的有效性

梯度融合网络能有效融合图像中潜在的边缘和结构信息,促进MDGAENet更好地学习高频区域特征。如表6所示,在移除梯度融合网络条件下,噪声等级为15时,网络整体的PSNR、SSIM分别下降0.16 dB、0.0024;噪声等级为50时,MDGAENet的去噪性能分别下降0.13 dB、0.001 9。综上,无论在低噪声还是高噪声情况下,梯度融合网络都能较好地梯度信息与输入原始噪声图像信息融合,促进网络提取有效信息。




图 7 多方向梯度网络输出梯度图像与噪声梯度图像

Fig. 7 Gradient images of MGradNet outputs and noise gradient image

4 结束语

本文提出一种基于多方向梯度网络的自适应边缘信息图像去噪模型,有效解决了固定算子在提取噪声图像边缘信息时的局限性。通过函数约束多方向梯度网络学习干净的梯度图像,引导去噪网络关注更多有效的高频信息。此外,提出的自适应梯度融合模块能促进梯度图像与噪声图像融合,助力网络提取有效信息。实验表明,本文算法在图像去噪性能、推理时间和模型参数量之间实现了良好的平衡。可视化结果也表明,去噪后的图像具有清晰的纹理、突出的边缘和良好的视觉效果。

参考文献:

- [1] Chen T, Ma K K, Chen L H. Tri-state median filter for image denoising[J]. IEEE Transactions on Image Processing, 1999, 8(12): 1834-1838.
- [2] Zhang X B, Zhang S L. Diffusion scheme using mean filter and wavelet coefficient magnitude for image denoising[J]. AEU-International Journal of Electronics and Communications, 2016, 70(7): 944-952.
- [3] Buades A, Coll B, Morel J M. A non-local algorithm for image denoising[C]//IEEE Conference on Computer Vision and Pattern Recognition, Piscataway, LISA, 2005: 60-65.
- [4] 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.
- [5] Dabov K, Foi A, Katkovnik V, et al. Color image denoising via sparse 3D collaborative filtering with grouping constraint in luminance-chrominance space [C]//IEEE International Conference on Image Processing, Piscataway, LISA, 2007: 313-I-6.
- [6] Rudin L I, Osher S, Fatemi E. Nonlinear total variation based noise removal algorithms[J]. Physica D: nonlinear Phenomena, 1992, 60(1-4): 259-268.
- [7] Weiss Y, Freeman W T. What makes a good model of natural images[C]//IEEE Conference on Computer Vision and Pattern Recognition, Piscataway, USA, 2007: 1-8.
- [8] 张红英, 彭启琮. 全变分自适应图像去噪模型[J]. 光电工程, 2006, 33(3): 50-53.
Zhang Hong-ying, Peng Qi-cong. Adaptive total variation image denoising model[J]. Opto-Electronic Engineering, 2006, 33(3): 50-53.
- [9] Elad M, Aharon M. Image denoising via sparse and redundant representations over learned dictionaries [J]. IEEE Transactions on Image Processing, 2006, 15(12): 3736-3745.
- [10] Mairal J, Elad M, Sapiro G. Sparse representation for color image restoration[J]. IEEE Transactions on Image Processing, 2007, 17(1): 53-69.
- [11] Xie Q, Zhao Q, Meng D Y, et al. Multispectral images denoising by intrinsic tensor sparsity regularization[C]. IEEE Conference on Computer Vision and Pattern Recognition, Piscataway, USA, 2016: 1692-1700.
- [12] 郑毅贤. 基于稀疏表示理论的图像去噪方法研究

- [D]. 上海:上海交通大学电子信息与电气工程学院, 2013.
- Zheng Yi-xian. Research on image denoising methods based on sparse representation theory[D]. Shanghai: School of Electronic Information and Electrical Engineering, Shanghai Jiao Tong University, 2013.
- [13] 银壮辰. 基于稀疏表示和字典学习的图像去噪研究[D]. 武汉: 武汉理工大学电子信息学院, 2014.
- Yin Zhuang-chen. Research on image denoising based on sparse representation and dictionary learning [D]. Wuhan: School of Electronic Information Wuhan University of Technology, 2014.
- [14] Gu S H, Zhang L, Zuo W M, et al. Weighted nuclear norm minimization with application to image denoising[C]//IEEE Conference on Computer Vision and Pattern Recognition, Piscataway, USA, 2014: 2862-2869.
- [15] Xu J, Zhang L, Zhang D, et al. Multi-channel weighted nuclear norm minimization for real color image denoising[C]//IEEE International Conference on Computer Vision, Piscataway, USA, 2017: 1096-104.
- [16] Xie T, Li S T, Sun B. Hyperspectral images denoising via nonconvex regularized low-rank and sparse matrix decomposition[J]. IEEE Transactions on Image Processing, 2019, 29: 44-56.
- [17] Jia X X, Feng X C, Wang W W. Adaptive regularizer learning for low rank approximation with application to image denoising[C]//IEEE International Conference on Image Processing, Piscataway, USA, 2016: 3096-3100.
- [18] 王圳萍. 基于低秩矩阵恢复的图像去噪算法研究[D]. 成都: 西南交通大学信息科学与技术学院, 2015.
- Wang Zhen-ping. Research on image denoising algorithms based on low-rank matrix recovery[D]. Chengdu: School of Information Science and Technology, Southwest Jiaotong University, 2015.
- [19] Xie J Y, Xu L L, Chen E H. Image denoising and inpainting with deep neural networks[C]//Advances in Neural Information Processing Systems. Red Hook, NY: Curran Associates, Inc., 2012: 341-349.
- [20] Agostinelli F, Anderson M R, Lee H. Adaptive multi-column deep neural networks with application to robust image denoising[C]//Advances in Neural Information Processing Systems, Red Hook, NY: Curran Associates, Inc., 2013: 1493-1501.
- [21] Sivakumar K, Desai U B. Image restoration using a multilayer perceptron with a multilevel sigmoidal function[J]. IEEE Transactions on Signal Processing, 1993, 41(5): 2018-2022.
- [22] Burger H C, Schuler C J, Harmeling S. Image denoising: Can plain neural networks compete with BM3D[C]//IEEE Conference on Computer Vision and Pattern Recognition, Piscataway, USA, 2012: 2392-2399.
- [23] Zhou Y T, Chellappa R, Vaid A, et al. Image restoration using a neural network[J]. IEEE Transactions on Acoustics, Speech, and Signal Processing, 1988, 36(7): 1141-1151.
- [24] Jain V, Seung H S. Natural image denoising with convolutional networks[C]//Advances in Neural Information Processing Systems. Red Hook, NY: Curran Associates, Inc., 2008, 21.
- [25] 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.
- [26] 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.
- [27] Mao X J, Shen C, Yang Y B. Image restoration using very deep convolutional encoder-decoder networks with symmetric skip connections[C]//Advances in Neural Information Processing Systems, Piscataway, USA, 2016: 379-387.
- [28] Tai Y, Yang J, Liu X M, et al. MemNet: A persistent memory network for image restoration[C]//IEEE International Conference on Computer Vision, Piscataway, USA, 2017: 4539-4547.
- [29] 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.
- [30] Liu D, Wen B H, Fan Y C, et al. Non-local recurrent network for image restoration[C]//Advances in Neural Information Processing Systems, Red Hook, NY: Curran Associates, Inc., 2018: 1673-1682.
- [31] Plötz T, Roth S. Neural nearest neighbors networks [C]//Advances in Neural Information Processing Sys-

- tems, Red Hook, NY: Curran Associates, Inc., 2018: 1095–1106.
- [32] Charbonnier P, Blanc-Feraud L, Aubert G, et al. Two deterministic half-quadratic regularization algorithms for computed imaging[C]//Proceedings of 1st International Conference on Image Processing, Piscataway, USA, 1994, 2: 168–172.
- [33] Kingma D P, Ba J. Adam: a method for stochastic optimization[J]. Computer Science, 2014: 1–15.
- [34] Wang Z, Bovik A C, Sheikh H R, et al. Image quality assessment: from error visibility to structural similarity[J]. IEEE Transactions on Image Processing, 2004, 13(4): 600–612.
- [35] Martin D, Fowlkes C, Tal D, et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics[C]//Proceedings Eighth IEEE International Conference on Computer Vision, Piscataway, USA, 2001: 416–423.
- [36] Timofte R, Agustsson E, Van Gool L, et al. Ntire 2017 challenge on single image super-resolution: Methods and results[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, Piscataway, USA, 2017: 114–125.
- [37] 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.
- [38] Roth S, Black M J. Fields of experts[J]. International Journal of Computer Vision, 2009, 82: 205–229.
- [39] Huang J B, Singh A, Ahuja N. Single image super-resolution from transformed self-exemplars[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Piscataway, USA, 2015: 5197–5206.
- [40] Qiao S, Yang J R, Zhang T, et al. Layered input GradiNet for image denoising[J]. Knowledge-Based Systems, 2022, 254: No. 109587.
- [41] Tian C W, Zheng M H, Zuo W M, et al. Multi-stage image denoising with the wavelet transform[J]. Pattern Recognition, 2023, 134(1): No. 109050.
- [42] Wu W C, Liu S J, Xia Y, et al. Dual residual attention network for image denoising[J]. Pattern Recognition, 2024, 149: No. 110291.