

DOI: 10.13382/j.jemi.B2407663

基于注意力机制的双卷积图像去噪网络^{*}

周先春¹ 吕梦楠² 芮 旻¹ 唐彬鑫² 杜志亭² 陈玉泽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:近年来,深度卷积神经网络在图像去噪领域表现出了优越的性能。然而,深度网络结构往往伴随着大量的模型参数,导致训练成本高,推理时间长,限制了其在实际去噪任务中的应用。提出了一种新的基于注意力机制的双卷积图像去噪网络(MA-DFRNet),它由多尺度特征提取网络、双卷积神经网络及动态特征精炼注意力机制组成。多尺度特征提取网络通过不同尺度的卷积获取图像特征,提高灵活性。双卷积神经网络上下分支均采用跳跃连接及扩张卷积来增大感受野。动态特征精炼注意力机制增强特征表示的精度和区分能力。这种结构设计不仅扩大了感受野,还更有效地提取和融合图像特征,显著提升去噪效果。研究结果表明,与最先进的模型相比,提出的MA-DFRNet在所有对比的噪声水平下具有更高的峰值信噪比(PSNR)和结构相似性(SSIM)值,PSNR提高了0.2 dB左右,SSIM提高了1%左右,对于噪声水平较高的图像更具鲁棒性,并且在视觉上更好地保留了图像细节,实现去噪和细节保留之间的平衡。

关键词: 图像去噪; 卷积神经网络; 注意力机制; 跳跃连接; 多尺度特征提取网络

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

Image denoising using dual convolutional neural network with attention mechanism

Zhou Xianchun¹ Lyu Mengnan² Rui Yang¹ Tang Binxin² Du Zhiting² Chen Yuze²

(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: In recent years, deep convolutional neural networks have shown superior performance in image denoising. However, deep network structures often come with a large number of model parameters, leading to high training costs and long inference times, limiting their practical application in denoising tasks. This paper proposes a new dual convolutional denoising network with skip connections (MA-DFRNet), which achieves an ideal balance between denoising effect and network complexity. The paper presents a novel attention-based dual convolutional image denoising network (MA-DFRNet) that achieves an optimal trade-off between denoising performance and network complexity. MA-DFRNet comprises a multi-scale feature extraction network, dual convolutional neural networks, and a dynamic feature refinement attention mechanism. The multi-scale feature extraction network employs convolutions at various scales to enhance flexibility in capturing image features. The dual convolutional neural networks utilize skip connections and dilated convolutions in both upper and lower branches to expand the receptive field. Furthermore, the dynamic feature refinement attention mechanism enhances the accuracy and discriminability of feature representation. This structural design not only enlarges the receptive field but also effectively extracts and integrates image features, leading to significant improvements in denoising performance. The research findings demonstrate that the proposed MA-DFRNet outperforms state-of-the-art models in terms of PSNR and SSIM values across all levels of noise considered in the comparisons. The PSNR has increased by approximately 0.2 dB, while the SSIM has improved by around 1%. Notably, MA-DFRNet demonstrates greater robustness for images with higher noise levels and better preserves image details visually, effectively balancing denoising and detail retention.

Keywords: image denoising; convolutional neural network; attention mechanism; skip connections; multi-scale feature extraction network

收稿日期: 2024-07-09 Received Date: 2024-07-09

^{*} 基金项目: 国家自然科学基金(11202106, 61302188)项目资助

0 引言

图像去噪^[1]是计算机视觉中的一项基础任务,其目的是消除低质量图像中的噪声,恢复图像的空间细节。由于原始图像中的许多关键特征被不确定性噪声严重破坏,图像去噪仍然是一个具有挑战性的问题。在实际应用中,图像去噪不仅可以提高图像的质量和观感,还可以在医学影像、工业检测、安全监控等领域发挥重要作用。因此,研究和改进图像去噪算法对于提高图像处理和分析的效率和准确性具有重要意义。

目前图像去噪领域内的算法主要分为基于模型的算法和基于学习的算法。基于模型的方法对自然图像或噪声分布建模,用建模的分布作为先验,利用优化算法得到清晰图像。常见的先验特征有局部平滑性、稀疏性、非局部自相似和外部统计先验。图像去噪常利用非局部自相似性和稀疏性提升性能。文献[2]介绍了一种非局部均值(non-local means, NLM)算法,此算法以图像块为单位在图像中寻找相似区域,求平均值去除高斯噪声。文献[3]介绍了基于三维块匹配滤波(block-matching and 3D filtering, BM3D)算法,通过相似判定找到相近二维图像块,整合成三维群组,协同滤波后聚合到原图像块位置形成去噪图像。文献[4]介绍了一种加权核范数最小化(weighted nuclear norm minimization, WNNM)算法,对每块进行匹配处理得相似块矩阵,根据奇异值特点收缩处理得到降噪块估计,保留较多纹理细节,减少噪声。此类算法在简单场景和低噪声水平下效果好,但存在信息损失、参数选择困难、计算复杂度高和适应性差等问题。相比之下,深度学习算法通过学习复杂的图像特征和规律,具有更强的处理能力和泛化能力,在处理复杂场景和高噪声水平下通常能取得更好的去噪效果。

由于深度网络框架的灵活连接方式和强大的学习能力,已成为有效解决图像去噪问题的方法。随着深度神经网络的普及,基于学习的去噪方法也迅速发展^[5-8]。例如,2017年Zhang等^[9]提出了一种针对高斯噪声(additive white Gaussian noise, AWGN)的去噪卷积神经网络算法(denoising convolutional neural network, DnCNN),强调残差学习和批量归一化的作用,展现出了卷积神经网络良好的泛化能力,但DnCNN主要只针对一种特定噪声进行去噪,对于其他一些复杂的噪声模型,可能需要更大的网络深度和复杂度才能有效去噪。于是在2018年Zhang等^[10]又提出了一种快速灵活的去噪网络FFDNet(fast flexible denoising network),考虑将高斯噪声泛化为更加复杂的真实噪声,将噪声水平图作为网络输入的一部分,使得网络可以适用于不同噪声水平的图片。但在处理一些特定类型的噪声或者噪声强度较高的

图像时,可能会出现去噪效果不佳的情况。2019年Guo等^[11]提出卷积盲去噪网络(convolutional blind denoising, CBDNet),该网络采用了更真实的噪声模型,结合了合成噪声图像和真实噪声图像进行训练,可以更好地适应真实场景。但此网络需要大量的训练数据,训练过程比较耗时,同时对硬件资源要求比较高。

许多研究工作表明,跳跃连接^[12]、扩张卷积^[13]可以帮助建立深度图像去噪模型。扩张卷积可以扩大卷积层的接受域,跳跃连接可以加速网络训练,并且可以在特征转置过程中提供更好的特征保存。最近提出的一些去噪模型,如文献[14]介绍的用于图像恢复的深度卷积神经网络去噪先验学习(image restoration convolutional neural network, IRCnn)、文献[15]介绍的批重归一化去噪网络(batch renormalization denoising network, BRDNet)和文献[16]介绍的密集残差U型网络(residual dense U-Net, RDUNet),通过使用这些技术都取得了显著的去噪性能。

针对以上问题,本研究提出了一种新的带跳跃连接的双卷积去噪网络(MA-DFRNet),以达到有效的去噪效果。提出的模型包含多尺度特征提取网络、双卷积神经网络和动态特征精炼注意力模块。所提出的MA-DFRNet具有以下优点:

1) 本研究设计了一个多尺度特征提取网络,结合稀疏表示和多尺度接受野的思想,最大化网络的接受野和特征提取范围,为后续操作提供足够的特征信息,避免浅特征提取不足成为模型的瓶颈问题。

2) 本研究提出的双卷积神经网络采用跳跃连接和扩张卷积来扩大感受野,且在每层网络前都添加了一个双注意力机制来强化特征表示的精度和区分能力。同时在后面引入一个动态特征精炼注意力模块融合更多图像特征,从复杂背景中生成噪声图。

3) 实验结果验证了所提出的网络结构在合成噪声图像上比其他对比网络具有更强的鲁棒性和更高效的去噪性能。

1 相关工作

1.1 跳跃连接

深度神经网络中的跳跃连接结构,也称为残差连接结构,是一种架构设计策略,旨在解决深层网络优化和信息传递的问题,当训练层数超过十层且没有跳跃连接结构的深度神经网络时,通常会遇到优化问题^[17-19]。跳跃连接结构最早在残差网络(residual network, ResNet)中得到应用,它引入了残差块,通过跳跃连接实现了信息的直接传递。其他网络架也受到了跳跃连接结构的启发,Transformer模型也采用跳跃连接结构来促进信息传递^[20],缓解深度网络训练中的梯度消失问题。跳跃连接

结构通过直接连接不同层级的神经元,允许信息在网络中以跳跃的方式传递,从而改善了梯度流动,降低了网络优化的难度,提高特征的多样性和表达能力,一定程度上平衡了网络的宽度和深度。

1.2 注意力机制

最早出现在机器翻译领域的注意力机制(attention mechanism, AM),随着神经网络研究的不断深入,现已成为深度学习的重要理论基础^[21]。注意力机制可以用人类视觉系统来描述,因为人类的感知依赖于注意力集中在图像中的相关信息以帮助视觉判断,同时忽略无关信息。

注意力机制的原理是通过生成特征权重矩阵以此识别输入的特征,随后经过神经网络的训练,学习到图像中重点关注的区域。注意力导向去噪卷积神经网络^[22](attention-guided dilated network, ADNet)仅使用一个卷积焦点通道信息来指导 CNN 训练模型。而卷积块注意力模块^[23](convolutional block attention module, CBAM)是赵雅琴等提出的轻量级注意力机制模块,它结合了空间注意力和通道注意力来增强特征表示。受此启发,本研究引入了一个双注意力机制,同时关注空间和通道维度更好地提供图像细节与纹理。

2 网络框架

2.1 整体框架

本研究提出的 MA-DFRNet 由一个多尺度特征提取模块、双卷积神经网络以及动态特征精炼注意力网络组成。

所提出的 MA-DFRNet 架构如图 1 所示。首先,多尺度特征提取模块通过不同扩张因子的扩张卷积来增加感受野,并通过多尺度卷积进一步增强特征。接着经过双卷积神经网络整合全局和局部特征信息,增强模型的去噪能力。最后,动态特征精炼注意力网络融合更多的图像特征并区分通道特征,从而从复杂背景中生成噪声图。这样,整个过程不仅有效地增加了特征提取的广度和深度,还提高了去噪的效果,使得生成的图像更加清晰和准确。

1) 多尺度特征提取模块

在图像去噪研究中,稀疏表示^[24]和多尺度特征分析^[25]已被广泛证实其有效性。为了最大化网络感受野和特征提取,本文设计了多尺度特征提取模块(MFAM)。该模块融合了稀疏表示和多尺度特征分析的理念,利用稀疏表示提取关键信息,同时利用多尺度拓展特征捕捉范围,确保模型在后续处理阶段拥有丰富的特征信息供给,从而有效避免因浅层特征提取不足而形成的性能瓶颈。MFAM 包括 MFAM-B1 和 MFAM-B2 两个子网络,通过扩张卷积和不同卷积核的卷积层提取融合不同尺度的特征。

如图 2 所示, MFAM-B1 利用稀疏表示理念,采用 3 组卷积网络串联而成的结构。每组卷积网络由扩张卷积、批归一化(BN)和 PReLU 激活函数组成。这 3 组扩张卷积网络扩张率分别为 1、2、3,通过叠加这 3 种扩张卷积, MFAM-B1 可以获得最大感受野,更加精确地聚焦于像素点,高效地提取特征。MFAM-B1 的表达式如式(1)所示。

$$O_{MFAM-B1} = D_3(D_2(D_1(N))) \quad (1)$$




图 1 MA-DFRNet 网络框架

Fig. 1 MA-DFRNet network framework

式中: N 为输入噪声图像, D_3 、 D_2 、 D_1 分别为扩张率为 1、2、3 的扩张卷积函数。 $O_{MFAM-B1}$ 表示 MFAM-B1 块的输出。

MFAM-B2 接收 MFAM-B1 处理后的稀疏特征映射作为输入。如图 3 所示, MFAM-B2 将输入的特征映射送入 4 个独立的并行处理分支,这 4 个分支的特征映射均为

64 通道。首先,对每个分支执行 Conv+BN+ReLU 操作,确保各分支在此阶段输出的特征内容一致。随后,针对这 4 个分支的特征映射,分别进行卷积核大小为 1、3、5、7 的卷积操作,以获取不同尺度的特征信息。紧接着,对各分支的特征映射进行 BN+PRReLU 操作,进一步优化其表达能力。值得注意的是,选择使用 PRReLU 激活函数,因为它能根据训练过程自适应地学习参数设定,提升模型精度几乎不会增加额外计算负担。最后,通过 concat 操作将 4 个分支提取的多尺度特征融合,生成更为强大和全面的特征信息输出。MFAM-B2 的表达式如式(2)所示。

$$O_{MFAM-B2} = Concat(O_1, O_2, O_3, O_4) \quad (2)$$

$$O_1 = f_{k=1}(O_{MFAM-B1})$$

$$O_2 = f_{k=3}(O_{MFAM-B1})$$

$$O_3 = f_{k=5}(O_{MFAM-B1})$$

$$O_4 = f_{k=7}(O_{MFAM-B1}) \quad (3)$$

式中: $f_{k=1}$, $f_{k=3}$, $f_{k=5}$ 和 $f_{k=7}$ 分别代表具有不同卷积核大小的卷积函数;Concat 表示多尺度特征融合函数, $O_{MFAM-B2}$ 表示 MFAM-B2 的输出。




图2 MFAM-B1

Fig. 2 MFAM-B1




图3 MFAM-B2

Fig. 3 MFAM-B2

2) 双卷积神经网络

先前的研究已经充分证明,扩展网络宽度可以提高

网络的整体性能^[26]。基于此本研究设计了一种双卷积神经网络结构,通过增加网络宽度来增强模型的去噪效果。此结构包括一个上子网和一个下子网,它们分工合作,共同拓展模型的表达能力。上子网利用卷积、扩张卷积、跳跃连接等操作,捕获全局特征,提供上下文信息。标准卷积与扩张卷积的交替使用,有利于捕捉较大范围信息,且批归一化放置在每个卷积层后,降低计算复杂度。下子网的扩张卷积设计旨在扩大感受野,以捕获更丰富的上下文信息和精细的局部特征。受混合扩张卷积(HDC)启发^[27-28],本文为每个扩张卷积赋予不同的扩张率,并按照 1,2,3,4,3,2,1 的顺序递增与递减,消除可能出现的网格化现象,有力提升网络的去噪性能。上、下两层子网均设置了 7 个卷积层,大小为 $3 \times 3 \times 64$,以实现网络复杂性与去噪性能的平衡。

本研究在上子网引入了 3 组对称跳跃连接,以叠加各层特征,保留关键细节。同样地,下子网也采用了对称跳跃连接操作,确保上下层结构一致性,加快训练速度,增强网络对细节特征的保存能力,并有效避免梯度消失或爆炸问题。

在每层卷积神经网络前,本研究都增加了一个双注意力机制 DAB。通过在信道和空间维度上分配注意力权重,进一步强化特征表示的精度和区分能力。这确保了网络在处理复杂噪声时能够更有效地关注关键特征,过滤掉冗余信息,从而提升整体去噪效果。如图 4 所示,通道注意块^[29](CAB)和空间注意块^[30](SAB)并行处理。CAB 通过计算信道注意力和信息权重生成信道映射(C_M),如式(4)所示。

$$C_M = x_{in} \odot \sigma(f^2 \xi(f^1 P(x_{in}))) \quad (4)$$

其中, x_{in} 是输入特征, $\xi(\cdot)$ 和 $\sigma(\cdot)$ 分别表示 ReLU 和 Sigmoid 激活函数, $\odot$ 表示对应位置元素相乘, $P(\cdot)$ 表示 GAP (global average poolings), $f^i(\cdot)$ 为卷积运算的组合符号。SAB 生成一个空间映射(S_M),如式(5)所示。

$$S_M = x_{in} \odot \sigma(f^1 C(Avg(x_{in}), Max(x_{in}))) \quad (5)$$

其中, $C(\cdot)$ 表示连接操作, $f^i(\cdot)$ 为卷积运算的组合符号, $Avg(\cdot)$ 表示平均池化操作, $Max(\cdot)$ 代表最大池化操作。最后,将 C_M 和 S_M 相加,得到 DAB 的输出。

3) 动态特征精炼注意力模块

本研究在双卷积神经网络后设计了一种动态特征精炼注意力模块 D-FRAB,其采用了类似于 ADNet 的结构,在 ADNet 中,注意力块 (attention block, AB) 被用来引导 CNN 训练去噪模型,并且使用注意力机制来增强噪声分离。为了融合更多的图像特征并区分通道特征,D-FRAB 采用了比 Sigmoid 收敛更快的 Tanh 激活函数,其非线性和高动态范围可以更好地捕捉数据的复杂特征,提高模型的表达能力。模块中第一个 Conv 使用 $2C \times 1 \times 1 \times C$




图 4 双注意力机制

Fig. 4 Dual attention block

的卷积,其中 C 是传入噪声图像的通道数。通过使用卷积获得的权重乘以 $O_{1,2\text{Conv}}$ 来提取更显著的噪声特征,这有助于从复杂背景中生成噪声图。最后,使用残差学习 (residual learning, RL) 技术通过从原始噪声图像中减去纯噪声图像来重建干净图像。D-FRAB 的表达式如式 (6)、(7) 所示。

$$O_{\text{noise}} = O_{1,2\text{Conv}} \times \text{Conv}(\text{Tanh}(O_{1,2\text{Conv}})) \quad (6)$$

$$O_{D\text{-FRAB}} = N - O_{\text{noise}} \quad (7)$$

其中, $O_{1,2\text{Conv}}$ 表示含噪图像经过多尺度特征提取模块和双卷积神经网络后的输出, Conv 和 Tanh 表示各自的函数, O_{noise} 和 $O_{D\text{-FRAB}}$ 分别表示噪声和图像去噪的输出。

2.2 损失函数

为了训练 MA-DFRNet 去除高斯白噪声的网络参数,本文选择均方误差 (MSE) 作为损失函数。假设 x_j 为干净图像, y_j 为噪声图像,对于给定的训练集,然后通过残差学习预测噪声图像的噪声映射 $F(x_j)$,通过 $x = y_j - F(x_j)$,将噪声图像转换成干净图像,通过最小化损失函数获得最优参数,损失函数定义为 $L(\theta)$,如式 (8) 所示。

$$L(\theta) = \frac{1}{2K} \sum_{j=1}^K \|F(y_j; \theta) - x_j\|^2 = \frac{1}{2K} \sum_{j=1}^K \|\hat{x} - x_j\|^2 \quad (8)$$

其中, $x_j, \hat{x}, y_j$ 分别代表干净图像,预测图像和噪声图像, j 为第 j 个图像对, θ 为可训练网络参数, K 为噪声图像块的数量。

3 实验结果与分析

3.1 评价标准

本文定量和定性评估了提出的新模型的去噪性能。为了进行定量分析,对去噪后图像进行评价的客观

指标主要为峰值信噪比 (peak signal to noise ratio, PSNR) 和结构相似性 (structural similarity index measurement, SSIM)。为了定性分析,本文比较了不同方法去噪后图像的视觉效果,参考人眼感官对图像去噪效果的质量判断作为主观评价指标。

3.2 数据集

为去除高斯白噪声,本文在新模型的训练中采用 DIV2K 数据集^[31],包含 800 张高分辨率彩色图像用于训练和 100 张用于测试。训练图像被重新缩放为 512×512 ,并被转换为灰度图像来训练灰度图像去噪模型。同时,为了确保图像块大小大于卷积层的接受域,所有图像均会被随机裁剪为 180×180 的图像块来用于本文的 MA-DFRNet 灰度图像和彩色图像训练,使得模型能够有效捕捉到图像中的重要特征,从而提升图像的去噪效果。这个图像块大小相对较大,但实验结果表明,由于更大的图像块大小,MA-DFRNet 能够捕获更多上下文特征,去噪性能好,特别是对于高噪声水平的图像。对每个干净图像块,添加 AWGN 以获得带噪声的图像块,噪声水平范围为 $[0, 50]$ 。

本研究选用 Set12 和 BSD68 数据集进行灰度图像去噪评估^[32], Kodak24 和 McMaster 数据集^[33] 被选用于彩色图像去噪评估。其中, BSD68 和 Set12 分别包含 68 张和 12 张灰度图像,图像像素分别为 $321 \times 481, 256 \times 256$ 。Kodak24 和 McMaster 分别包含 24 张和 18 张彩色图像,图像像素均为 500×500 。

3.3 实验参数设置

所有实验均在一台配备有 16 核 Intel(R) Core(TM) i7-11700KF CPU @ 2.50 GHz、32 GB RAM 和一块 NVIDIA GeForce RTX 3080Ti GPU 的计算机上实施。本文分别对灰度图像和彩色图像使用了提出的 MA-DFRNet 进行训练,完成 MA-DFRNet 的训练大约需要 48 h。模型参数通过 Adam 优化器进行优化,指数衰减率 $\beta_1 = 0.9$, 指数衰减率 $\beta_2 = 0.999$, 常量 $\epsilon = 1.0 \times 10^{-8}$, 选择均方误差 MSE 为模型损失函数。为了去除高斯白噪声, MA-DFRNet 被训练了 70 次迭代,学习率为 1×10^{-4} , 批量大小设置为 16。

3.4 去噪性能对比试验

在本节中,介绍了灰度图像以及彩色图像的 AWGN 去噪。对于灰度图像和彩色图像,分别将噪声水平为 15、25 和 50 的 AWGN 加入到原始图像中产生噪声图像。虽然灰度图像和彩色图像的去噪任务都旨在提升图像质量,但它们在处理上存在明显区别。灰度图像专注于单一通道的亮度信息,主要针对像素亮度值进行优化。而彩色图像则涉及多个通道,需要综合考虑各通道之间的相互影响,以充分保留图像的色彩信息。此外,为了进一

步验证去噪算法的有效性,本实验还进行了盲去噪实验,以评估不同噪声条件下的去噪性能。

1) 灰度图像去噪评估

对于灰度图像去噪,本研究将 MA-DFRNet 与 DnCNN^[9]、FFDNet^[10]、IRCnn^[13]、BRDNet^[16]、RDUNet^[15]、DudeNet^[34]、DCBDNet^[35]和 DRANet^[36]进行了比较。首先,在 BSD68 和 Set12 两个数据集上,对灰色合成噪声图像进行去噪测试。分别向原始图像中添加了噪声水平为 15、25 和 50 的 AWGN,得到噪声图像,并给出了各自的 PSNR,如表 1 所示。相比其他模型,本文的模型在所有对比的噪声水平下都表现出较高的平均 PSNR。在噪声水平为 15 时,本文提出的 MA-DFRNet 的平均 PSNR 略高于 DRANet 0.09 dB,可能是因为 MA-DFRNet 具有更大的接受野,对低频图像区域的弱噪声不太敏感。但是在噪声水平为 25 和 50 时,分别高于 DRANet 0.12 和 0.21 dB,且对比模型的训练也是在相同的高噪声条件下进行的,这表明本研究的 MA-DFRNet 对于高噪声水平的图像更具有鲁棒性。此外,MA-DFRNet 相较于 DRANet 具有更紧凑的网络结构,减少了卷积层和参数数量,使得计算复

杂度显著降低,提高了训练和推理速度,同时降低了过拟合风险,增强了在不同噪声条件下的鲁棒性。

表 2 为 Set12 数据集上几种去噪方法的平均 SSIM。可以看出,本研究提出的 MA-DFRNet 在噪声水平为 15 时与 DRANet 的平均 SSIM 相等,处于领先的地位。且在更具挑战性的高噪声水平下,本研究的模型明显更优于 DRANet,这再次验证了本研究模型的识别能力。

本研究还使用 BSD68 数据集评估了在噪声水平为 15、25 和 50 时的灰度图像去噪性能。表 3 为各种去噪方法的平均 PSNR 和 SSIM 值。可以看出,本文提出的新模型去噪效果处于领先地位。图 5 展示了 BSD68 数据集中图像 Test027 在噪声水平 50 下不同对比方法的去噪结果。放大了一个区域(绿色框)进行详细比较(红色框),可以看出,IRCnn、DnCNN 和 FFDNet 在一定程度上消除了噪声,但结果稍显模糊。DudeNet、DRANet、DCBDNet 和 RDUNet 丢失了图像的许多纹理和细节。相比之下,MA-DFRNet 获得了更好的视觉效果,能在去噪和保留细节之间取得平衡。结果表明,本文提出的 MA-DFRNet 模型在主观和客观上都取得了较好的效果。

表 1 不同网络在 Set12 上的 PSNR (dB) 结果,最佳 PSNR 的两个结果分别用红色字体和绿色字体显示 ($\sigma=15, 25$ 和 50)

Table 1 The PSNR (dB) results of different networks on Set12, with the two best PSNR results displayed in red and green fonts($\sigma=15, 25$ and 50)														
	图像	C. man	House	Peppers	Starfish	Monarch	Airplane	Parrot	Lena	Barbara	Boats	Man	Couple	Average
$\sigma = 15$	噪声水平													
	DnCNN	32. 61	34. 97	33. 30	32. 20	33. 09	31. 70	31. 83	34. 62	32. 64	32. 42	32. 46	32. 47	32. 86
	FFDNet	32. 43	35. 07	33. 25	31. 99	32. 66	31. 57	31. 81	34. 62	32. 54	32. 38	32. 41	32. 46	32. 77
	IRCnn	32. 55	34. 89	33. 31	32. 02	32. 82	31. 70	31. 84	34. 53	32. 43	32. 34	32. 40	32. 40	32. 77
	ADNet	32. 81	35. 22	33. 49	32. 17	33. 17	31. 86	31. 96	34. 71	32. 80	32. 57	32. 47	32. 58	32. 98
	DudeNet	32. 71	35. 13	33. 38	32. 29	33. 28	31. 78	31. 93	34. 66	32. 73	32. 46	32. 46	32. 49	32. 94
	DCBDNet	32. 14	35. 05	33. 01	32. 06	33. 09	31. 50	31. 66	34. 68	32. 57	32. 41	32. 39	32. 43	32. 75
	DRANet	32. 57	35. 42	33. 32	32. 19	33. 31	31. 78	31. 95	34. 81	32. 91	32. 60	32. 50	32. 65	33. 00
本研究	32. 70	35. 49	33. 45	32. 29	33. 36	31. 84	32. 00	34. 92	33. 20	32. 67	32. 50	32. 70	33. 09	
$\sigma = 25$	噪声水平													
	DnCNN	30. 18	33. 06	30. 87	29. 41	30. 28	29. 13	29. 43	32. 44	30. 00	30. 21	30. 10	30. 12	30. 43
	FFDNet	30. 10	33. 28	30. 93	29. 32	30. 08	29. 04	29. 44	32. 57	30. 01	30. 25	30. 11	30. 20	30. 44
	IRCnn	30. 08	33. 06	30. 88	29. 27	30. 09	29. 12	29. 47	32. 43	29. 92	30. 17	30. 04	30. 08	30. 38
	ADNet	30. 34	33. 41	31. 14	29. 41	30. 39	29. 17	29. 49	32. 61	30. 25	30. 37	30. 08	30. 24	30. 58
	DudeNet	30. 23	33. 24	30. 98	29. 53	30. 44	29. 14	29. 48	32. 52	30. 15	30. 24	30. 08	30. 15	30. 52
	DCBDNet	30. 07	33. 27	30. 74	29. 46	30. 44	29. 05	29. 42	32. 70	30. 29	30. 31	30. 12	30. 21	30. 51
	DRANet	30. 30	33. 62	30. 98	29. 52	30. 61	29. 21	29. 56	32. 83	30. 54	30. 49	30. 19	30. 40	30. 69
本研究	30. 42	33. 74	31. 20	29. 61	30. 73	29. 29	29. 69	32. 95	30. 70	30. 60	30. 29	30. 49	30. 81	
$\sigma = 50$	噪声水平													
	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	27. 18
	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	27. 32
	IRCnn	26. 88	29. 96	27. 33	25. 57	26. 61	25. 89	26. 55	29. 40	26. 24	27. 17	27. 17	26. 88	27. 14
	ADNet	27. 31	30. 59	27. 69	25. 70	26. 90	25. 88	26. 56	29. 59	26. 64	27. 35	27. 17	27. 07	27. 37
	DudeNet	27. 22	30. 27	27. 51	25. 88	26. 93	25. 88	26. 50	29. 45	26. 49	27. 26	27. 19	26. 97	27. 30
	DCBDNet	27. 35	30. 45	27. 50	25. 91	27. 01	25. 94	26. 63	29. 78	27. 10	27. 39	27. 30	27. 14	27. 46
	DRANet	27. 58	30. 89	27. 62	25. 99	27. 13	26. 03	26. 67	29. 95	27. 34	27. 57	27. 34	27. 36	27. 62
本研究	27. 78	31. 17	27. 79	26. 20	27. 35	26. 24	26. 83	30. 21	27. 59	27. 73	27. 53	27. 57	27. 83	

表 2 不同网络在 Set12 上的平均 SSIM 结果($\sigma=15, 25$ 和 50)

Table 2 The averaged SSIM results of different networks on Set12($\sigma=15, 25$ and 50)

方法	DnCnn	FFDNet	IRCnn	ADNet	DCBDNet	DRANet	本研究
$\sigma = 15$	0.903	0.903	0.901	0.905	0.902	0.906	0.909
$\sigma = 25$	0.862	0.864	0.860	0.865	0.865	0.868	0.874
$\sigma = 50$	0.783	0.791	0.780	0.791	0.794	0.800	0.810

表 3 不同网络在 BSD68 数据集上的平均 PSNR 与 SSIM 比较($\sigma=15, 25$ 和 50)

Table 3 The averaged PSNR and SSIM comparisons of different networks on the BSD68 dataset($\sigma=15, 25$ and 50)

方法	$\sigma = 15$	$\sigma = 25$	$\sigma = 50$	
PSNR	DnCNN	31.72	29.23	26.23
	FFDNet	31.63	29.19	26.29
	RDUNet	31.77	29.32	26.51
	IRCnn	31.63	29.15	26.19
	DudeNet	31.78	29.29	26.31
	DCBDNet	31.65	29.24	26.37
	DRANet	31.79	29.36	26.47
	本文	31.81	29.45	26.65
SSIM	DnCNN	0.891	0.828	0.719
	FFDNet	0.890	0.830	0.726
	IRCnn	0.888	0.825	0.717
	RDUNet	0.891	0.832	0.735
	ADNet	0.892	0.829	0.722
	DCBDNet	0.889	0.829	0.727
	DRANet	0.892	0.833	0.732
	本文	0.894	0.835	0.737

2) 彩色图像去噪评估

对于彩色图像去噪,将 MA-DFRNet 与 CBM3D^[3]、CDnCNN-S^[5]、FFDNet^[10]、BRDNet^[15]、ADNet^[21] 和 AIRNet^[37]进行了比较。为了评估本文模型对彩色图像的去噪性能,使用了 Kodak24 和 McMaster 数据集。通过比较方法得到的 PSNR 值如表 4 所示,可以看出本文提出的新模型在噪声水平为 25 和 50 时表现优异,超越了他所有比较方法。特别是在噪声水平为 50 时,在两个数据集上的 PSNR 值分别高出去噪效果排名第 2 的 BRDNet 0.21 和 0.18 dB。然而,在噪声水平为 15 时,本文模型在 McMaster 数据集上的 PSNR 值略低于 BRDNet 0.03 dB,这可能是因为 BRDNet 也采用了双 CNN 结构,在噪声功率较低的情况下,BRDNet 所采用的更深层次的网络结构具有更强的学习能力。平均 SSIM 值如表 5 所示,可以看出本文的模型在不同噪声水平下的 SSIM 值都优于其他方法。尤其是当噪声水平为 50 时,本文模型的 SSIM 值在 Kodak24 上超过了 AIRNet 0.012,在 McMaster 上超过了 ADNet 0.014。噪声水平为 50 的彩色图像噪声去除的视觉结果如图 6 所示,使用来自

McMaster 数据集的图像。可以看到,其他一些比较方法会出现过度平滑的问题,而 MA-DFRNet 细节保留的更好。




图 5 不同网络在 BSD68 里的 test027 图像的去噪结果($\sigma = 50$)

Fig. 5 Denoising results of test027 image in BSD68 with different networks ($\sigma=50$)

3) 图像盲去噪实验

多数实验针对的是特定级别的单一噪声,而在实际生活和生产中常常会面临未知级别的噪声。因此,对图像盲去噪的研究十分重要。目前,大多数图像去噪模型仅能处理单一噪声,盲去噪的效果并不理想。为了进一



图6 不同网络在 McMaster 里图像的去噪结果($\sigma = 50$)

Fig. 6 Denoising results of image in McMaster with different networks ($\sigma = 50$)

步验证本文提出的 MA-DFRNet 在盲去噪方面的能力,将其与在盲去噪效果上表现优异的 DnCNN-B、ADNet-B 和 DudeNet-B 模型进行了比较。

表4 不同网络在 Kodak24 和 McMaster 数据集上的平均 PSNR (dB) 结果 ($\sigma = 15, 25$ 和 50)

Table 4 The averaged PSNR (dB) results of different networks on the Kodak24 and McMaster datasets ($\sigma = 15, 25$ and 50)

数据集	方法	$\sigma = 15$	$\sigma = 25$	$\sigma = 50$
Kodak24	CBM3D	34.28	31.68	28.46
	CDnCNN-S	34.48	32.03	28.85
	FFDNet	34.63	32.13	28.98
	BRDNet	34.88	32.41	29.22
	ADNet	34.76	32.26	29.10
	AirNet	34.68	32.21	29.06
	本研究	34.94	32.50	29.43
McMaster	CBM3D	34.06	31.66	28.51
	CDnCNN-S	33.44	31.51	28.61
	FFDNet	34.66	32.35	29.18
	BRDNet	35.08	32.75	29.52
	ADNet	34.93	32.56	29.36
	AirNet	34.70	32.44	29.26
	本研究	35.05	32.90	29.70

表5 不同网络在 Kodak24 和 McMaster 数据集上的平均 SSIM 结果 ($\sigma = 15, 25$ 和 50)

Table 5 The averaged SSIM results of different networks on the Kodak24 and McMaster datasets ($\sigma = 15, 25$ and 50)

数据集	方法	$\sigma = 15$	$\sigma = 25$	$\sigma = 50$
Kodak24	IRCnn	0.920	0.877	0.793
	FFDNet	0.922	0.878	0.794
	ADNet	0.924	0.882	0.798
	AIRNet	0.924	0.882	0.799
	本文	0.927	0.889	0.811
McMaster	IRCnn	0.920	0.882	0.807
	FFDNet	0.922	0.886	0.815
	ADNet	0.927	0.894	0.825
	AIRNet	0.925	0.891	0.822
	本文	0.927	0.897	0.839

表6列出了在15、25、50的噪声强度下,使用DnCNN-B、ADNet-B和DudeNet-B方法的去噪结果。3种噪声情况下,在Set12测试集上各方法去噪后的平均PSNR和平均SSIM,无论是本文的算法,还是DnCNN-B、ADNet-B和DudeNet-B,当噪声强度逐渐增大时,去噪效果普遍减弱,因为噪声强度与去噪效果之间通常呈反比关系。通过对比可以发现,在任何噪声水平下,MA-DFRNet都能获得比其他方法更高的PSNR和SSIM值,这表明本文的算法在不同噪声强度下仍保持了一定的鲁棒性。

图7展示了更直观的比较结果,本文从Set12测试数据集中选取了“parrot”图像,并与ADNet-B和DudeNet-B在15、25和50噪声水平下进行比较。通过视觉对比可以发现,MA-DFRNet在各种噪声水平下都能取得理想的去噪效果。综上所述,与其他盲去噪模型相比,本文的MA-DFRNet在去噪效果上均展现出明显优势,具备较好的盲去噪能力。

3.5 网络复杂度分析

在本研究实验中,从模型运行时间和网络参数数量的角度评估了网络复杂度。本研究比较了DnCNN^[9]、FFDNet^[10]、IRCnn^[14]、ADNet^[22]、AirNet^[36]和DRANet^[37]这几种去噪模型。所有的去噪模型都是在PyCharm环境下实现的。首先,评估了不同去噪方法的运行时间,并将结果列在表7中。为了评估它们在噪声水平为25时的运行时间,本研究随机选择了3个灰度图像和不同尺寸的彩色图像进行测试。通过计算20次运行的平均时间来确定每个模型对每个图像所需的运行时间。由表7可以发现,虽然本文提出的网络运行时间比DnCNN、FFDNet、IRCnn和ADNet要慢一些,但去噪效果明显要优于这些模型,而具有较优越PSNR性能(如AirNet和DRANet)的模型则需要更长时间进行去噪,特别是对于

较大尺寸图像而言。表 8 为灰度和彩色图像上各种去噪方法的参数数量。观察发现,对比于去噪效果较好的模型,MA-DFRNet 以更简单的模型结构获得了更好的去噪性能。

表 6 不同噪声水平下模型盲去噪的结果 ($\sigma=15, 25$ and 50)

Table 6 Results of model blind denoising results under different noise levels ($\sigma=15, 25$ and 50)		DnCNN-B		ADNet-B		DudeNet-B		本研究	
数据集	σ	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
Set12	15	32. 67	0. 900	32. 77	0. 908	32. 77	0. 901	32. 84	0. 909
	25	30. 35	0. 860	30. 46	0. 862	30. 39	0. 860	30. 65	0. 870
	50	27. 18	0. 781	27. 33	0. 789	27. 22	0. 784	27. 56	0. 795




图 7 噪声水平 $\sigma=\{15, 25, 50\}$ 时 Set12 图像“Parrot”的盲去噪结果

Fig. 7 Results of blind denoising results for image “Parrot” from Set12 at noise levels $\sigma=\{15, 25, 35, 45, 50\}$

3. 6 消融实验

为了验证本研究提出结构的有效性,分别对多尺度特征提取网络、注意力机制的功能性进行了研究,训练 3 种不同网络对于灰度图像去噪的效果。图 8 为在不同的

表 7 所评估的去噪方法在 3 幅不同尺寸的灰度和彩色图像上的运行时间

Table 7 Running time of the evaluated denoising methods on three grayscale and color images with different sizes		(s)					
设备	方法	256×256		512×512		1 024×1 024	
		Gray	Color	Gray	Color	Gray	Color
GPU	DnCNN	0. 034	0. 035	0. 039	0. 039	0. 059	0. 059
	FFDNet	0. 033	0. 032	0. 033	0. 032	0. 034	0. 032
	IRCnn	0. 032	0. 032	0. 032	0. 032	0. 032	0. 032
	ADNet	0. 033	0. 035	0. 037	0. 047	0. 053	0. 095
	AirNet	—	0. 150	—	0. 505	—	2. 515
	DRANet	0. 151	0. 153	0. 345	0. 355	1. 050	1. 059
本文		0. 050	0. 055	0. 076	0. 079	0. 169	0. 173

表 8 不同去噪模型的参数个数

Table 8 The numbers of parameters of different denoising models			($\times 10^3$)
方法	Gray	Color	
DnCNN	666	668	
FFDNet	485	852	
IRCnn	186	188	
ADNet	519	521	
AirNet	—	8 930	
DRANet	1 612	1 617	
本文	1 278	1 326	

迭代过程中,Set12 数据集上 3 种不同网络结构在噪声水平为 25 时的平均 PSNR。其中 MA-DFRNet 不包含多尺度特征提取网络,MA-DFRNet 不包含两个双注意力模块 DAB 以及动态特征精炼注意力模块 D-FARB。由图 8 可以看出,整个 MA-DFRNet 模型的去噪性能明显优于其他两种模型,这说明本文的每个模块都对图像的去噪性能进行了一些提升。表 9 为在 3 种噪声水平($\sigma=15, 25, 50$)下,在 BSD68 数据集上进行消融实验。结果表明,当 $\sigma=15$ 时,完整的 MA-DFRNet 网络比 MA-DFRNet 与 MA-DFRNet 的 PSNR 值分别提升了 0. 36、0. 43;当 $\sigma=25$ 时,分别提升了 0. 2、0. 28;当 $\sigma=50$ 时,分别提升了 0. 09、0. 14,很好地证明了噪声估计网络与多尺度特征提

取网络结合以及双注意力机制对于提升模型的去噪性能是有效的。




图8 Set12数据集上3种不同网络结构在噪声水平为25时的平均PSNR

Fig.8 The average PSNR of various different network architectures on Set12 datasets at noise level of 25

表9 不同网络在BSD68数据集上的PSNR($\sigma=15, 25$ 和 50)

Table 9 The PSNR comparisons of different networks on the BSD68 dataset($\sigma=15, 25$ and 50)

σ	15	25	50
MA-DFRANet	31.45	29.25	26.56
MA-DFRBNet	31.38	29.17	26.51
MA-DFRNet	31.81	29.45	26.65

4 结 论

本文设计并实现了一种新的去噪网络模型——MA-DFRNet,该网络模型集成了多尺度特征提取模块、双卷积神经网络结构与动态特征精炼注意力模块,形成了一个高度协同的去噪体系。通过多尺度特征提取网提供充足的特征信息,增强了模型对多样图像内容的适应性。其次双卷积神经网络的独特架构极大地促进了信息流通与特征复用,使得网络能够更有效地处理和整合来自不同层级的特征信息。此外,动态特征精炼注意力模块的引入融合了更多图像特征,提升了特征表示的精确度,并增强了不同特征之间的区分能力,使得模型能够更准确地识别和处理复杂的图像细节。与其他模型相比,本文的MA-DFRNet在多种去噪任务上都取得了非常有竞争力的去噪结果,特别是在高噪声水平下。不仅体现了模型对强噪声环境的鲁棒性,还确保了去噪后图像的视觉效果,完美平衡了去除噪声与细节保留的需求。实验结

果还表明,本文模型在弱噪声水平下的去噪能力还有待更进一步的研究。此外,尽管所提出的模型具有优异的去噪性能,但模型依旧需要使用原图和噪声图像进行训练,在接下来的研究中,希望可以实现自监督或无监督的图像去噪方法来解决此问题。

参考文献

[1] 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 the method of imaging noise removal for high-speed camera[J]. Chinese Journal of Scientific Instrument, 2023,44(2): 211-220.

[2] 谢巧雪, 马宗庆, 祝连庆, 等. 基于结构相似约束生成对抗网络的视网膜 OCT 图像去噪算法[J]. 电子测量与仪器学报,2023,37(3):11-20.

XIE Q X, MA Z Q, ZHU L Q, et al. Retinal OCT image denoising based on structural similarity constrained generative adversarial network[J]. Journal of Electronic Measurement and Instrumentation, 2023,37(3):11-20.

[3] 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.

[4] GUO X E, LIU F, TIAN X T. Noise modeling and denoising of images collected by on-board track inspection system [J]. Multimedia Tools Applications, 2022, 81(8): 11695-11715.

[5] LIU Y, QIN ZH Y, ANWAR S, et al. Invertible denoising network: A light solution for real noise removal [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13365-13374.

[6] SHARIF S, NAQVI R A, BISWAS M. Beyond joint demosaicking and denoising: An image processing pipeline for a pixel-bin image sensor[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 233-242.

[7] ZAMIR S W, ARORA A, KHAN S, et al. Multi-stage progressive image restoration [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 233-242.

[8] ZHANG K, LI Y W, ZUO W M, et al. Plug-and-play

- image restoration with deep denoiser prior [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(10):6360-6376.
- [9] ZHANG K, ZUO W M, CHEN Y J, et al. Beyond a gaussian denoiser: Residual learning of deep CNN for image denoising[J]. IEEE Trans on Image Processing, 2017, 26(7):3142-3155.
- [10] ZHANG K, ZUO W M, ZHANG L. FFDNet: Toward a fast and flexible solution for cnn-based image denoising [J]. IEEE Trans on Image Processing, 2018, 27(9):4608-4622.
- [11] GUO SH, YAN Z F, ZHANG K, et al. Toward convolutional blind denoising of real photographs [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 1712-1722.
- [12] LAKSHMI P M, HIRTHIK M, SAMPATH K, et al. Despeckling of optical coherence tomography images using encoder-decoder network with skip connections [C]. AIP Conference Proceedings. AIP Publishing, 2023, 2603(1).
- [13] 赵文清, 刘亮, 胡嘉伟, 等. 基于深度可分离空洞卷积金字塔的变压器渗漏油检测[J]. 智能系统学报, 2023, 18(5):966-974.
- ZHAO W Q, LIU L, HU J W, et al. Detection of transformer oil leakage based on deep separable atrous convolution pyramid[J]. CAAI Transactions on Intelligent Systems, 2023, 18(5):966-974.
- [14] ZHANG K, ZUO W M, GU SH H, et al. Learning deep CNN denoiser prior for image restoration [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 3929-3938.
- [15] TIAN CH W, XU Y, ZUO W M. Image denoising using deep CNN with batch renormalization [J]. Neural Networks: The Official Journal of the International Neural Network Society, 2020, 121(6):461-473.
- [16] GURROLA J, DALMAU O, ALRCON T E. A residual dense U-Net neural network for image denoising [J]. IEEE Access, 2021, 9(8):31742-31754.
- [17] WANG H N, CAO P, WANG J Q, et al. UTransNet: Rethinking the skip connections in U-Net from a channel-wise perspective with transformer [C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2022, 36(3):2441-2449.
- [18] OYEDOTUN O K, RAHMAN S A, AOUADA D, et al. Training very deep networks via residual learning with stochastic input shortcut connections [C]. Proceedings of International Conference on Neural Information Processing, 2017.
- [19] OYEDOTUN O K, ISMAEIL K A, AOUADA D. Why is everyone training very deep neural network with skip connections? [J]. IEEE Transactions on Neural Networks and Learning Systems, 2023, 34(9):5961-5975.
- [20] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16×16 words: Transformers for image recognition at scale [C]. Proceedings of International Conference on Learning Representations. Washington D. C., 2021.
- [21] 王冲, 魏子令, 陈曙晖. 基于自注意力机制的无边界应用动作识别方法[J]. 计算机研究与发展, 2022, 59(5):1092-1104.
- WANG CH, WEI Z L, CHEN SH H. Action identification without bounds on applications based on self-attention mechanism [J]. Journal of Computer Research and Development, 2022, 59(5):1092-1104.
- [22] YAN SH, 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.
- [23] 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 Q, 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.
- [24] VISHWAKARMA A. Denoising and inpainting of sonar images using convolutional sparse representation [J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72(2):1-9.
- [25] ZHANG SH, LIU CH Y, ZHANG Y X, et al. Multi-scale feature learning convolutional neural network for image denoising [J]. Sensors, 2023, 23(18):7713.
- [26] SAHU A, RANA K, KUMAR V. An application of deep dual convolutional neural network for enhanced medical image denoising [J]. Medical & Biological Engineering & Computing, 2023, 61(5):991-1004.
- [27] YU J, YANG X K, GAO F, et al. Deep multimodal distance metric learning using click constraints for image ranking [J]. IEEE Transactions on Cybernetics, 2017, 47(12):4014-4024.
- [28] WANG P Q, CHEN P F, YUAN Y, et al. Understanding convolution for semantic segmentation [C]. 2018 IEEE Winter Conference on Applications of Computer Vision (WACV). IEEE, 2018: 1451-1460.
- [29] LIU T L, LUO R H, XU L Q, et al. Spatial channel

attention for deep convolutional neural networks [J]. Mathematics, 2022, 10(10): 1750.

- [30] 陈凯, 王永雄. 结合空间注意力多层特征融合显著性检测 [J]. 中国图象图形学报, 2020, 25(6): 1130-1141.
- CHEN K, WANG Y X. Saliency detection based on multi-level features and spatial attention [J]. Journal of Image and Graphics, 2020, 25(6): 1130-1141.
- [31] EIRIKUR A, RADU T. Ntire 2017 challenge on single image super-resolution: Dataset and study [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2017: 126-135.
- [32] WEI F, ZHU ZH H, ZHOU H, et al. Efficient automatically evolving convolutional neural network for image denoising [J]. Memetic Comp, 2023, 15(2): 219-235.
- [33] KIM J, LEE J K, LEE K M. Accurate image super-resolution using very deep convolutional networks [J]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1646-1654.
- [34] TIAN CH W, XU Y, ZUO W M, et al. Designing and training of a dual CNN for image denoising [J]. Knowledge-Based Systems, 2021, 226(2): 106949.
- [35] WU W C, LIAO SH CH, LYU G N, et al. Image blind denoising using dual convolutional neural network with skip connection [J]. Multimedia Systems, 2024, 263(30): 345.
- [36] WU W C, LIU SH J, XIA Y L, et al. Dual residual attention network for image denoising [J]. Pattern Recognition, 2024, 149(8): 110291.
- [37] LI B Y, LIU X, HU P, et al. All-in-one image restoration for unknown corruption [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2022.

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. 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.



吕梦楠, 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: lylvmn@126.com



Lyu Mengnan 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.

芮阳, 现为南京信息工程大学人工智能学院本科生, 主要研究方向为数字图像处理。
E-mail: 4607928@qq.com



Rui Yang is an undergraduate majoring in the School of Artificial Intelligence of Nanjing University of Information Science and Technology. His main research interest includes digital image processing.

唐彬鑫, 2023年于铜陵学院获得学士学位, 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



Tang Binxin received his B. Sc. from Tongling University in 2023. Now he is a M. Sc. candidate at Nanjing University of Information Science and Technology. His main research interest includes digital image processing.

杜志亭, 2023年于淮阴工学院获得学士学位, 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: 15295514730@163.com

Du Zhiting received his B. Sc. degree from Binjiang College, Nanjing University of Information Science and Technology in 2022. Now he is a M. Sc. candidate at Nanjing University of Information Science and Technology. His main research interest includes digital image processing.



陈玉泽, 2022年于安徽财经大学获得学士学位, 现为南京信息工程大学硕士研究生, 主要研究方向为数字图像处理。
E-mail: 1640983049@qq.com

Chen Yuze received his B. Sc. degree from Anhui University of Finance and Economics in 2023. Now he is a M. Sc. candidate in Nanjing University of Information Science and Technology. His main research interest includes digital image processing.