

一种基于 Uniformer Transformer 与 UNet 的 图像降噪模型

鲁正威, 张笃振

(江苏师范大学计算机科学与技术学院, 江苏 徐州 221116)

[摘要] 卷积神经网络(CNNs)在图像降噪任务中取得了较大的成功. 基于 Vision Transformer 模型表现出较好的效果. 计算机视觉领域利用 Transformer 方法其性能超过了卷积神经网络方法. 提出了一种名为 UUNet (Uniformer Transformer-UNet)的图像降噪模型,该模型使用 Uniformer Transformer 作为骨干网络,并融入 UNet 网络来提取图像的深层特征,使用 PSNR、SSIM 等指标对图像降噪效果进行评估. 实验结果表明,使用 UUNet 网络对图像降噪的整体性最优.

[关键词] 卷积神经网络(CNNs), Uniformer Transformer, 图像降噪, UNet

[中图分类号] TP391.41 **[文献标志码]** A **[文章编号]** 1672-1292(2023)01-0039-07

An Image Denoising Model Based on Uniformer Transformer and UNet

Lu Zhengwei, Zhang Duzhen

(School of Computer Science and Technology, Jiangsu Normal University, Xuzhou 221116, China)

Abstract: Convolutional Neural Networks (CNNs) have achieved a great success in image denoising task. The Vision Transformer-based model has also demonstrated superior results. In previous experimental results, the performance of using the Transformer methods in the field of computer vision outperformed that of the CNNs-based methods. A UUNet (Uniformer Transformer-UNet) image denoising model is proposed in this paper which uses the Uniformer Transformer as the backbone network and integrates the UNet network structure to extract the deep feature information of the images. PSNR and SSIM are used in this study to evaluate the image denoising effects. The experimental results show that the UUNet network has a better performance than other five models.

Key words: Convolutional Neural Networks (CNNs), Uniformer Transformer, image denoising, UNet

在计算机视觉领域中,图像降噪是一个基础的且具有挑战性的问题,它在其他图像任务的预处理阶段也发挥着极其重要的作用. 图像降噪方法大致分为两种,一种是基于传统算法的图像降噪方法,另一种是基于深度学习算法的图像降噪方法.

基于传统图像降噪的方法,例如基于块匹配和滤波(block matching and 3D-filtering, BM3D)^[1]、非局部均值(NLM)^[2]等降噪算法,一般都是基于图像的原有信息,充分利用图像中的非局部自相似性和稀疏性进行处理. 有些在降噪效果方面的性能较好,有些在执行效率方面的性能较好. 虽然这些传统的算法可以处理大部分的降噪任务并且能获得可接受的性能,但是传统的方法需要先对不同的噪声进行分析,然后针对噪声的不同种类进行处理,这大大增加了图像降噪的难度、降低了图像降噪的效率.

深度学习技术发展迅速并取得较大的成功,因为它具有强大的非线性映射、特征学习与表达能力等特点. 在计算机视觉中,基于卷积神经网络(CNN)的方法取得了优异的效果与性能^[3-8],但仅使用单调的卷积神经网络处理视觉任务还存在着一些问题. 首先,卷积核与图像所表示的内容无关,使用某一尺寸的卷

收稿日期:2022-09-15.

基金项目:江苏省高校自然科学基金项目(19KJB520032)、江苏师范大学博士学位教师科研支持项目(20XSRS018)、江苏师范大学研究生科研与实践创新计划项目(2022XKT1535).

通讯作者:张笃振,博士,副教授,研究方向:目标检测、机器学习. E-mail:zhduzhen@jsnu.edu.cn

积核,并以输出与原图像相同尺寸为目标方案对于图像降噪可能不是最佳的解决方案^[9-10]。其次,由于卷积核可以看作一个序列块,它获取的特征是局部信息,当使用 CNN 模型进行大范围依赖建模时,图像的全局信息将会丢失。尽管后来提出了一些防止全局图像信息丢失的模型算法,例如:自适应卷积^[11-12]、非局部卷积^[13]和全局平均池^[14]等,通过权衡图像全局信息的权重与度量远距离像素间的相似性,使得算法处理图像局部信息的同时能够获取图像远距离的全局信息。用该方式来防止处理图像时全局信息的丢失只是获取到部分远距离的信息,不能将图像的局部信息与全局信息很好地融合,没有从根本上解决图像处理时全局信息丢失的问题。近期,解决视觉任务的方法有了新的突破,借鉴自然语言处理中的 Transformer 模型,该模型的输入输出都是序列,可以有效地获取上下文信息。随即出现了 Vision Transformer 模型,简称 ViT^[9]。该模型将 Transformer 模型引入到视觉任务中,有效地解决了图像全局信息丢失的问题。然后,出现了 Swin Transformer 模型算法,此算法在 ViT 算法的基础上增加了滑窗操作与层级设计思想,可方便地融合其他网络模型解决多种视觉任务。Swin Transformer 模型会存在参数的冗余与信息的依赖问题。文献[15]是继 Swin Transformer 模型后又提出的一种新型的基于 Vision Transformer 的主干网络模型,称为 Uniformer Transformer 模型,该网络模型能够将卷积与自注意力的优点无缝集成,Uniformer 的相关性聚合在浅层与深层分别配备了局部与全局的 token,能够同时解决 Swin Transformer 模型算法的冗余与依赖问题,实现了高效的特征学习,且该模型具有很强的拓展性,可以很好地融合目前大多数模型并完成不同的图像任务。目前该模型应用在越来越多的视觉任务中,例如图像分类、目标检测、姿势估计、图像分割、视频理解等领域,并取得了较好的效果。

本文利用 Uniformer Transformer^[15]模型作为图像降噪的主干网络,将 UNet^[3]网络模型的思想融入其中,提出了一种 Uniformer Transformer-UNet(UUNet)网络模型,将该网络模型应用于图像降噪。UUNet 网络模型中应用 Dual up-sample^[16-17]模块进行上采样,该上采样模块为双线性上采样技术,可有效防止棋盘效应。通过上采样模块使 Uniformer Transformer 网络与 UNet 网络的思想有效结合,并完成图像降噪的任务。实验结果表明,使用 Uniformer Transformer 模型已超越了基于 CNN 的模型算法,获得较优的结果与性能。本文将该网络模型应用到图像降噪领域,通过对比实验与降噪后的图像效果进行主客观评价,使用 UUNet 网络模型对图像进行降噪整体上要优于 SRMNet^[16]和 SUNet^[17]等 5 种其他的图像降噪算法。

1 相关研究

随着人工智能的迅速发展,基于深度学习技术解决视觉任务的方法越来越普遍。同时硬件技术的快速发展使计算机在执行速度和性能上有了大幅度提升,这使得深度学习方法应用到视觉任务上成为了现实。对图像降噪而言,深度学习方法与传统的图像降噪方法相比有了较大的优势。

1.1 图像降噪

一般来说,图像受到干扰后的噪声图像的退化过程可以建模为:

$$Y=D(X)+n. \quad (1)$$

式中, X 表示原图像, $D(\cdot)$ 表示退化函数, n 通常表示为满足零均值正态分布 $N(0, \sigma^2)$,即加性高斯噪声函数。

传统的图像降噪方法通常基于人工提取特征降噪,例如自相似性^[18-19]、稀疏编码^[20-21]和全变差^[22]。这些方法一般使用滤波器,计算图像中相邻区域间的相似相关性处理图像降噪的问题。目前,基于 CNN 模型的图像降噪方法已经有了很好的效果^[23-24]。此外,文献[22-25]的降噪模型也有较高的竞争力。

1.2 UNet

目前,UNet 在图像处理的许多应用中成为常选的网络模型。因为该网络模型的结构具有层次化特征映射,可以获得多尺度上下文特征信息。此外,使用编码器和解码器之间的跳跃连接来增强图像的重建过程。UNet 被广泛应用于计算机视觉任务中,如图像分割、图像恢复等。此外,该网络模型算法还有各种改进的算法,如 Res-UNet^[26]、Densite-UNet^[27]、Attention-UNet^[28]、Non-local-UNet^[29]和 Swin-UNet^[16]。UNet 是强大的自适应主干网络,可方便地被应用到不同的网络中提取特征,以提高性能和丰富图像信息。UNet 网络模型结构如图 1 所示。

1.3 Uniformer Transformer

Uniformer Transformer 模型可解决大量的局部冗余和视频帧之间复杂的全局依赖性,从高维的视频中学习丰富的多尺度时空语义信息. 该网络结构由三维卷积神经网络和 Vision Transformer 模型构成. Vision Transformer 模型可通过自注意力机制有效地捕获远程依赖性. Uniformer Transformer 模型则集成了三维卷积和时空自注意力的优点. 在静态图像中,三维卷积则转变为二维卷积. Uniformer Transformer 模型被广泛应用于图像分类、目标检测、视频理解等计算机视觉任务中,其网络结构如图 2 所示.




图 1 UNet 网络结构

Fig. 1 UNet network structure

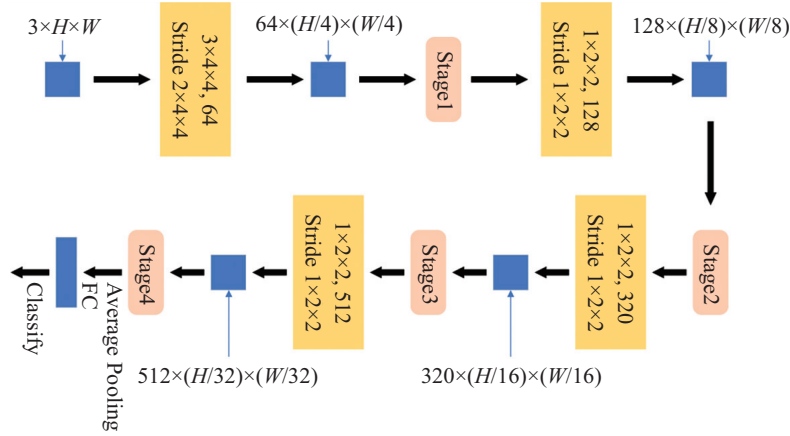


图 2 Uniformer Transformer 网络结构

Fig. 2 Uniformer Transformer network structure

1.4 融合思想

Uniformer Transformer 模型可用于多种图像处理任务,该模型可作为主干网络进行下采样提取特征并完成大部分图像任务. UNet 模型结构具有层次化特征可以获得多尺度的上下文特征,并且可以通过跳连的方式来增强图像的重建过程. 对 Uniformer Transformer^[15] 模型下采样的每个阶段进行层次划分增加上采样模块并通过跳连结构连接. 原模型的不同阶段可以获取图像深层与浅层的特征. 并且新增加的跳连结构可以得到与 UNet 模型相似的功能结构用以获取多尺度特征和增强图像的重建.

2 研究方法

2.1 UUNet

Uniformer Transformer-UNet (UUNet) 作为主干网络,利用 3×3 的卷积核提取图像的颜色、纹理等浅层特征信息,将提取出的特征信息输入到 Uniformer Transformer 网络中,该网络通过图像序列块与自注意力机制将图像进行下采样来获取图像的深层特征信息,然后结合 UNet 网络模型的思想将多尺度的上下文特征信息融合,使用 3×3 的卷积核将融合的特征信息转变为与输入图像相同的尺寸作为网络的输出,输出结果即为降噪后的图像. 通过损失函数利用梯度下降法对 UUNet 模型进行训练,利用训练后的模型参数对噪声图像进行降噪处理. UUNet 网络结构如图 3 所示.

UUNet 可看作由 3 个功能模块组成:浅层特征提取模块,基于 UNet 网络模型方式的特征融合模块,重建图像模块. 功能模块结构如图 4 所示. 浅层特征提取模块中,有噪声的输入图像 $Y \in \mathbf{R}^{3 \times 3}$,其中 H, W 分别是噪声图像的高和宽. UUNet 对输入图像首先使用单个 3×3 的卷积层 $\text{Conv_in}(\cdot)$,获取输入图像的颜色、纹理等浅层信息. 浅层特征是 $\text{Conv_in} \in \mathbf{R}^{C \times H \times W}$,可表示为:

$$Y_1 = \text{Conv_in}(Y). \quad (2)$$

式中,图像通道数为 C ,在本文实验中将 C 设置为 3,方便利用 Uniformer Transformer 进行特征提取.

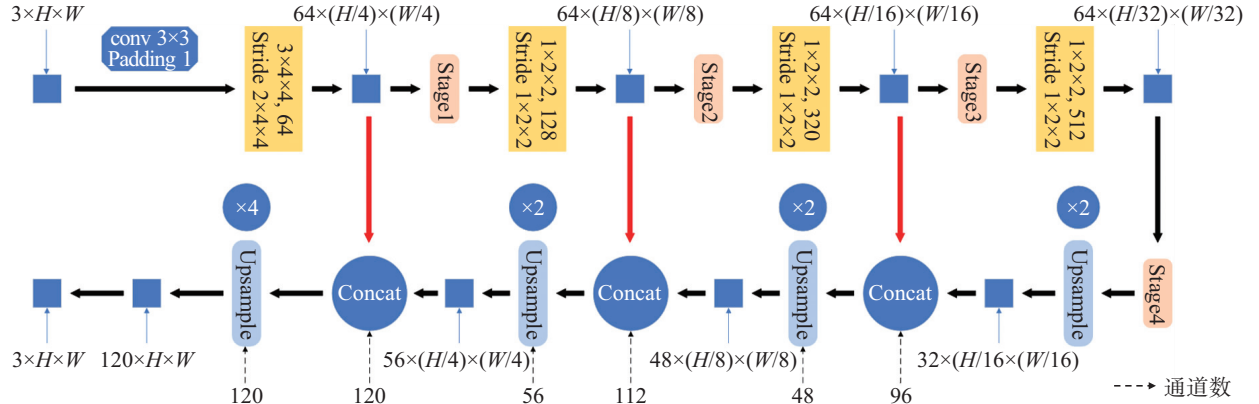


图 3 UUNet 网络结构

Fig. 3 UUNet network structure




图 4 Uniformer Transformer-UNet 功能模块结构

Fig. 4 Uniformer Transformer-UNet function module

基于 UNet 网络模型的多尺度上下文特征融合模块,浅层特征 Y_1 将被输入到类似 UNet 网络模型中提取特征 $U(\cdot)$. 提取的深层、多尺度特征图是 $U(\cdot) \in \mathbf{R}^{120 \times H \times W}$,其中 120 的通道数中融合了 4 个尺度的特征图. 公式可表示为:

$$Y_2 = U(Y_1). \quad (3)$$

式中, $U(\cdot)$ 是带有 UNet 思想的 Uniformer Transformer 的主干网,该模块通过自上而下的特征提取,获取输入图像的 4 个不同层的特征信息.

重建模块中,使用 3×3 的卷积层生成降噪后的图像,

$$X' = \text{Conv_out}(Y_2). \quad (4)$$

式中, X' 是输入图像 Y_2 通过 UUNet 网络模型输出的降噪图像.

损失函数中,本文使用常规的 L_1 损失来优化端到端的 UUNet 图像降噪模型,

$$L_{\text{denoise}} = \|X - X'\|_1. \quad (5)$$

式中, X 是式(1)中噪声图像 Y 的原图像.

2.2 模块尺寸调整

UUNet 模型可以获取多尺度的上下文特征信息,该网络中具有不同尺寸的特征图. 因此需要通过另外的子模块来调整特征图尺寸,例如:下采样模块和上采样模块. UUNet 模型中,利用 Uniformer Transformer 作为主干网络进行下采样,获取特征

图尺寸分别为 $\frac{H}{4} \times \frac{W}{4}$ 、 $\frac{H}{8} \times \frac{W}{8}$ 、 $\frac{H}{16} \times \frac{W}{16}$ 、 $\frac{H}{32} \times \frac{W}{32}$,然后

使用 Dual up-sample 网络结构^[16-17]作为 UUNet 模型的上采样模块来融合深层和浅层的特征信息,以防止在上采样时出现的棋盘效应. Dual up-sample 结构包含 bilinear (双线性层)和 PixelShuffle^[30]两条采样支路将两部分特征图的通道进行合并以实现上采样,其结构如图 5 所示.

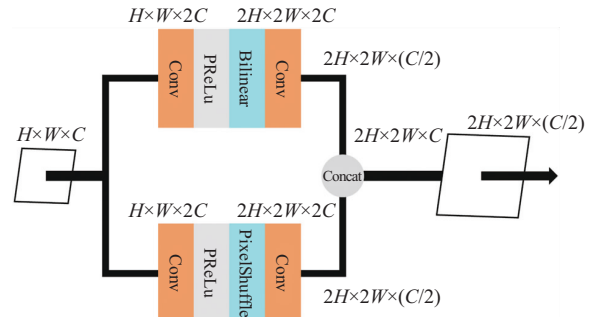


图 5 双上采样网络结构

Fig. 5 Dual up-sample network structure

3 实验分析

3.1 实验环境

UUNet 网络模型是一种可训练的端到端模型,不需要设置预训练模型参数,实验在 PyTorch 1.8.0 和 NVIDIA GTX 1060 GPU 环境下进行. 实验中训练 UUNet 模型时设置的初始学习率为 2×10^{-4} ,为避免迭代时出现震荡的情况,在训练进行时使学习率递减,最终学习率的值为 1×10^{-6} .

3.2 数据集

训练集:在超分辨率图像的 DIV2K^[10]数据集上训练 UUNet 网络模型,该数据集有 800 幅和 100 幅高质量(平均分辨率约为 $1\,920 \times 1\,080$)图像,分别用于模型的训练和验证阶段. 将 DIV2K^[10]数据集中的每幅图像随机裁剪为 100 个分辨率为 256×256 的裁剪图像,并为 800 幅训练图像随机添加高斯噪声等级为 $\sigma = 5 \sim 50$ 的噪声,最终生成 80 000 幅图像作为训练集. 实验中使用包含 100 幅高质量的图像,给其添加 $\sigma = 10$ 、 $\sigma = 30$ 和 $\sigma = 50$ 的 3 种等级的高斯噪声,最终生成 10 000 幅图像数据集作为验证集.

测试集:实验在 CBSD68^[31]数据集(包含 68 幅彩色图像,分辨率为 768×512)以及 Kodak24 数据集(包含 24 幅图像,分辨率为 321×481)分别在等级为 $\sigma = 10$ 、 $\sigma = 30$ 和 $\sigma = 50$ 的高斯噪声图像上进行测试.

3.3 实验结果

3.3.1 定量结果

实验使用常用的峰值信噪比(*PSNR*)和结构相似性(*SSIM*)指标. *PSNR* 和 *SSIM* 都是值越高越好, *PSNR* 的单位是分贝, dB. 其它的指标有网络模型的参数值(*Params*)和 *FLOPs* 值.

下面的实验将 UUNet 网络模型与基于 CNN 模型的方法 DnCNN^[4]、IrCNN^[8]、FFDNet^[5] 和基于 UNet 的方法 SRMNet^[16]、SUNet^[17] 进行了比较.

表 1 显示了 UUNet 网络模型与其它模型在 CBSD68^[31]数据集和 Kodak24 数据集中,高斯噪声等级为 $\sigma = 10$ 、 $\sigma = 30$ 和 $\sigma = 50$ 的实验结果,其中 *PSNR* 值与 *SSIM* 值为该测试数据集所测试数值的均值并保留相应位数的小数, *Params* 值与 *FLOPs* 值为两个测试数据集建模的平均参数.

从表 1 中可以看出 UUNet 模型的 *PSNR* 与 *SSIM* 指标整体高于别的模型, UUNet 模型的参数更少并且 *FLOPs* 值也更小. 与 SRMNet 网络模型和 SUNet 网络模型相比, UUNet 网络模型拥有更少的网络模型参数,其参数值约为占 SUNet 和 SRMNet 网络模型参数值的 1.34% 和 3.54%, UUNet 网络模型也有更小的 *FLOPs* 值,其 *FLOPs* 值约占 SUNet 和 SRMNet 网络模型 *FLOPs* 值的 84.5% 和 8.9%. 从以上数据对比可知, UUNet 模型在运行时所占计算机内存更小,与此同时模型在训练速度与推断速度上也有所提升.

表 1 CBSD68 数据集和 Kodak24 数据集上的高斯噪声图像降噪实验结果

Table 1 Gaussian noise image denoising results on CBSD68 dataset and Kodak24 dataset

Approachs	CBSD68						Kodak24						Parms	FLOPs
	$\sigma = 10$		$\sigma = 30$		$\sigma = 50$		$\sigma = 10$		$\sigma = 30$		$\sigma = 50$			
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM		
Noisy	24.87	0.711	20.57	0.535	15.03	0.307	28.27	0.796	18.97	0.412	14.91	0.256	—	—
DnCNN	36.14	0.951	30.32	0.861	27.92	0.788	36.58	0.945	31.28	0.858	28.94	0.792	558K	36G
IrCNN	36.06	0.953	30.22	0.861	27.86	0.789	36.70	0.945	31.24	0.858	28.92	0.794	420K	27G
FFDNet	36.14	0.954	30.31	0.860	27.96	0.788	36.80	0.946	31.39	0.860	29.10	0.795	854K	18G
SRMNet	36.46	0.961	30.72	0.878	28.38	0.814	37.29	0.957	31.97	0.882	29.72	0.826	37.59M	285G
SUNet	35.94	0.958	30.28	0.870	27.85	0.799	36.79	0.953	31.82	0.899	29.54	0.810	99M	30G
UUNet	40.76	0.993	37.20	0.985	34.40	0.973	41.35	0.994	37.57	0.986	34.81	0.974	1.33M	25.36G

3.3.2 消融实验

UUNet 模型使用如图 3 所示的 Stage1、Stage2、Stage3、Stage4 共 4 个阶段进行不同程度的图像编码与特征提取,这 4 个阶段分别利用 CBlock1、CBlock2、SABlock1、SABlock2 模块进行特征提取,现将这 4 阶段中的模块依次删减,观察模型的降噪效果,实验结果如表 2 所示. 总体上当 CBlock1、CBlock2、SABlock1、SABlock2 模块都存在时降噪指标最高. 这些模块可以在不同阶段提取特征.

表 2 CBSD68 数据集和 Kodak24 数据集上的高斯噪声图像降噪消融实验结果

Table 2 Gaussian noise image denoising ablation results on CBSD68 dataset and Kodak24 dataset

CBlock1	CBlock2	SABlock1	SABlock2	σ	CBSD68		Kodak24	
					PSNR	SSIM	PSNR	SSIM
✓	✓	✓	✓	10	40.76	0.993	41.35	0.994
			✓	10	35.28	0.980	36.21	0.983
			✓	10	34.73	0.979	35.43	0.981
			✓	10	35.09	0.978	36.17	0.980
			✓	10	34.80	0.977	35.89	0.982
✓	✓	✓	✓	30	37.20	0.985	37.57	0.986
			✓	30	32.65	0.962	33.06	0.962
			✓	30	32.13	0.954	32.44	0.952
			✓	30	31.91	0.951	32.54	0.950
			✓	30	31.94	0.952	32.46	0.951
✓	✓	✓	✓	50	34.40	0.973	34.81	0.974
			✓	50	30.11	0.933	30.71	0.933
			✓	50	29.75	0.922	30.17	0.917
			✓	50	29.47	0.917	30.10	0.913
			✓	50	29.60	0.921	30.07	0.914

注:表中“✓”表示 UUNet 模型中 4 个阶段相应的阶段存在.

3.3.3 视觉比较

图 6 给出了 DnCNN、IrCNN、FFDNet、SRMNet、SUNet、UUNet 网络模型在噪声等级为 $\sigma = 50$ 时图像降噪的效果对比例图. 从图中可以看出,对高斯噪声为 $\sigma = 50$ 的图像(如图 6(a)所示),各个模型的图像降噪视觉效果图中,UUNet 网络模型的降噪效果(如图 6(g)所示)更佳、图像更清晰.

通过上述实验可知,UUNet 网络模型在峰值信噪比(PSNR)评估指标与结构相似性(SSIM)指标上更优. 说明 UUNet 网络模型可以更有效地处理大量的局部冗余和多维复杂的全局依赖性问题. UUNet 网络模型的降噪效果更佳、图像处理后变得更清晰.




图 6 图像降噪视觉效果对比

Fig. 6 Denoising visual effect comparison

4 结论

提出一种新的 UUNet 网络模型,将 Uniformer Transformer 网络模型与 UNet 网络模型进行融合,形成主干网络. 在 CBSD68 数据集和 Kodak24 数据集上的实验结果显示 UUNet 网络模型的图像降噪效果整体优于其他模型.

在深度学习的计算机视觉领域中,应用 Transformer 模型对图像处理的方法越来越常见. 但 Transformer 模型在模型参数上可能会急剧增多,在模型训练阶段有时会出现收敛比较缓慢或很难收敛的情况,需要使用配置更好的实验设备通过较高的迭代次数以满足其模型参数和模型收敛的条件.

[参考文献](References)

[1] DABOV K,FOI A,KATKOVNIK V,et al. Image denoising with block-matching and 3D filtering[C]//International Society for Optics and Photonics.Washington,USA,2006:6064–6078.

[2] GU S,ZHANG L,ZUO W,et al. Weighted nuclear norm minimization with application to image denoising[C]//Proceedings

- of the IEEE Conference on Computer Vision and Pattern Recognition. Columbus, Ohio, USA, 2014:2862–2869.
- [3] RONNEBERGER O, FISCHER P, BROX T. U-Net; Convolutional networks for biomedical image segmentation [C]//Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Switzerland: Springer. 2015:234–241.
 - [4] 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.
 - [5] 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.
 - [6] PARK B, YU S, JEONG J. Densely connected hierarchical network for image denoising[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Long Beach, CA, USA, 2019.
 - [7] GURROLA-RAMOS J, DALMAU O, ALARCÓN T E. A residual dense U-Net neural network for image denoising[J]. IEEE Access, 2021, 9:31742–31754.
 - [8] AGUSTSSON E, TIMOFTE R. Ntire 2017 challenge on single image super-resolution; Dataset and study[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. Honolulu, Hawaii, USA, 2017:126–135.
 - [9] LIU Z, LIN Y, CAO Y, et al. Swin transformer; Hierarchical vision transformer using shifted windows[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. USA: IEEE, 2021:10012–10022.
 - [10] LIANG J Y, CAO J Z, SUN G L, et al. SwinIR; Image restoration using swin transformer[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. USA: IEEE, 2021:1833–1844.
 - [11] NIKLAUS S, MAI L, LIU F. Video frame interpolation via adaptive convolution[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, Hawaii, USA, 2017:670–679.
 - [12] WU H, QU Y, LIN S, et al. Contrastive learning for compact single image dehazing[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. USA: IEEE, 2021:10551–10560.
 - [13] WANG X, GIRSHICK R, GUPTA A, et al. Non-local neural net-works [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City, Utah, USA, 2018:7794–7803.
 - [14] ZHANG Y, LI K, LI K, et al. Image super-resolution using very deep residual channel attention networks[C]//Proceedings of the European Conference on Computer Vision. Berlin: Springer Science, 2018:286–301.
 - [15] LI K, WANG Y, ZHANG J, et al. Uniformer: Unifying convolution and self-attention for visual recognition[J]. arXiv Preprint arXiv:2201.09450, 2022.
 - [16] FAN C M, LIU T J, LIU K H. Selective residual M-Net for real image denoising[J]. arXiv Preprint arXiv:2203.01645, 2022.
 - [17] FAN C M, LIU T J, LIU K H. SUNet; Swin transformer UNet for image denoising[J]. arXiv Preprint arXiv:2202.14009, 2022.
 - [18] CHEN B X, LIU T J, LIU K H, et al. Image super-resolution using complex dense block on generative adversarial networks [C]//2019 IEEE International Conference on Image Processing. Taipei, China, 2019:2866–2870.
 - [19] BUADES A, COLL B, MOREL J M. A non-local algorithm for image denoising[C]//2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. San Diego, CA, USA, 2005, 2:60–65.
 - [20] DONG W S, LI X, ZHANG L, et al. Sparsity-based image denoising via dictionary learning and structural clustering[C]//CVPR 2011. Colorado Springs, CO, USA, 2011.
 - [21] XU L, ZHENG S, JIA J. Unnatural L_0 sparse representation for natural image deblurring[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Oregon, Portland, 2013.
 - [22] CHAN T F, WONG C K. Total variation blind deconvolution[J]. IEEE Transactions on Image Processing, 1998, 7(3):370–375.
 - [23] KRAHMER F, LIN Y Z, MCADOO B Z, et al. Blind image deconvolution; motion blur estimation [J/OL]. University of Minnesota, 2006, 9[2022-05-15]. <http://purl.umn.edu/3685>.
 - [24] WEN K Y, LIU T J, LIU K H, et al. Identifying poultry farms from satellite images with residual dense U-Net[C]//2020 IEEE International Conference on Systems, Man, and Cybernetics. Toronto, ON, Canada, 2020.
 - [25] SHI M Z, XU T F, FENG L, et al. Single image deblurring using novel image prior constraints[J]. Optik, 2013, 124(20):4429–4434.
 - [26] XIAO X, LIAN S, LUO Z, et al. Weighted res-unet for high-quality retina vessel segmentation[C]//2018 9th International Conference on Information Technology in Medicine and Education. Hangzhou, China, 2018.
 - [27] GUAN S, KHAN A A, SIKDAR S, et al. Fully dense UNet for 2-D sparse photoacoustic tomography artifact removal[J]. IEEE Journal of Biomedical and Health Informatics, 2019, 24(2):568–576.
 - [28] JIN Q, MENG Z, SUN C, et al. RA-UNet; A hybrid deep attention-aware network to extract liver and tumor in CT scans[J]. Frontiers in Bioengineering and Biotechnology, 2020, 8:1471.

-
- [8] 李鸿培,于畅,忽朝俭,等. 2013 工业控制系统及其安全性研究报告[R]. 北京:绿盟科技,2013.
- [9] SU C, JU S G, LIU Y G, et al. Improving random forest and rotation forest for highly imbalanced datasets[J]. *Intelligent Data Analysis*, 2015, 19(6):1409–1432.
- [10] CAO X H, LI R J, GE Y M, et al. Densely connected deep random forest for hyperspectral imagery classification[J]. *International Journal of Remote Sensing*, 2019, 40(9):3606–3622.
- [11] SHAKIBA R, NAJAFIPOUR M R, SELEHI M E. An improved PSO-based path planning algorithm for humanoid soccer playing robots[C]//*Proceedings of the 2013 3rd Joint Conference of AI & Robotics and 5th RoboCup Iran Open International Symposium*. Tehran, Iran:IEEE, 2013.
- [12] QIAN W Y, LI M. Convergence analysis of standard particle swarm optimization algorithm and its improvement[J]. *Soft Computing*, 2018, 22(12):4047–4070.
- [13] HOU G Y, XU Z D, LIU X, et al. Improved particle swarm optimization for selection of shield tunneling parameter values[J]. *Computer Modeling in Engineering and Sciences*, 2019, 118(2):317–337.
- [14] CHANG W D. An improved PSO algorithm for solving nonlinear programming problems with constrained conditions[J]. *International Journal of Modeling, Simulation, and Scientific Computing*, 2021, 12(1):2150001.
- [15] 王志华,刘绍廷,罗齐.基于改进 K-modes 聚类的 KNN 分类算法[J]. *计算机工程与设计*, 2019, 40(8):2228–2234.
- [16] SUN J, LANG J, FUJITA H, et al. Imbalanced enterprise credit evaluation with DTE-SBD: Decision tree ensemble based on SMOTE and bagging with differentiated sampling rates[J]. *Information Sciences*, 2018, 425:76–91.
- [17] ZHANG D H, QIAN L Y, MAO B J, et al. A data-driven design for fault detection of wind turbines using random forests and XGBoost[J]. *IEEE Access*, 2018, 6:21020–21031.
- [18] TAHMASSEBI A, WENGERT G J, HELBICH T H, et al. Impact of machine learning with multiparametric magnetic resonance imaging of the breast for early prediction of response to neoadjuvant chemotherapy and survival outcomes in breast cancer patients[J]. *Investigative Radiology*, 2019, 54(2):110–117.
- [19] ZHU M, WU K, ZHOU Y Z, et al. Prediction of cooling moisture content after cut tobacco drying process based on a particle swarm optimization-extreme learning machine algorithm[J]. *Mathematical Biosciences and Engineering*, 2021, 18(3):2496–2507.
- [20] 国家市场监督管理总局, 国家标准化管理委员会. 综合能耗计算通则:GB/T 2589–2020[S]. 北京:中国标准出版社, 2020.
- [21] 简毅文, 江亿. 住宅供暖空调能耗计算模式的研究[J]. *暖通空调*, 2005, 35(2):11–14.
- [22] XU L, HOU L, ZHU Z Y, et al. Midterm prediction of electrical energy consumption for crude oil pipelines using a hybrid algorithm of support vector machine and genetic algorithm[J]. *Energy*, 2021, 222(1):119955.
- [23] BESROUR A, KSANTINI R. Incremental subclass support vector machine[J]. *International Journal on Artificial Intelligence Tools*, 2019, 28(7):1950020.
- [24] ALKUBAISI G. The role of ensemble learning in stock market classification model accuracy enhancement based on Naive Bayes Classifiers[J]. *International Journal of Statistics and Probability*, 2020, 9(1):1–36.

[责任编辑:严海琳]

(上接第 45 页)

- [29] YAN Q, ZHANG L, LIU Y, et al. Deep HDR imaging via a non-local network[J]. *IEEE Transactions on Image Processing*, 2020, 29:4308–4322.
- [30] SHI W, CABALLERO J, HUSZÁR F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. USA: IEEE, 2016:1874–1883.
- [31] 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 of the Eighth IEEE International Conference on Computer Vision*. ICCV 2001. USA:IEEE, 2002:416–423.

[责任编辑:陈 庆]