

一种阶梯型多尺度神经网络条带噪声降噪模型

王 诏*, 王 燕, 苏国辉, 史升凯
(青岛海洋地质研究所, 山东 青岛 266071)

摘要:针对遥感影像上存在的复杂条带噪声问题,提出一种阶梯型多尺度卷积神经网络降噪模型(SmCNN)。该模型采用一种阶梯型网络结构轻量化设计,高度融合高、低层等多层网络特征,对影像上的非均质、高覆盖、多尺度条带噪声具备优秀的识别、去除能力。模型主要通过3*3空洞卷积构建多尺度网络和残差网络融合多尺度特征信息,增强多尺度条带噪声的检测能力、弥补深度网络退化缺点;采用锯齿状混合空洞卷积网络结构解决图像信息不连续问题;设计阶梯型多尺度网络结构、引入1*1卷积以轻量化神经网络模型,降低模型复杂度。实验结果表明,SmCNN降噪性能明显优于传统图像降噪方法,比经典的前馈去噪卷积神经网络(DnCNN)降噪模型在均方误差、峰值信噪比、结构相似性三项图像降噪质量评价指标上,分别提高了61.2%、11.8%和0.7%,且网络结构轻量化效果显著,节约了53.11%的模型训练时间。

关键词:降噪;阶梯型多尺度;混合空洞卷积;卷积神经网络;遥感影像;条带噪声

中图分类号:TP751

文献标识码:A

文章编号:1673-629X(2023)07-0068-07

doi:10.3969/j.issn.1673-629X.2023.07.010

A Staircase Multi-scale Neural Network Model for Stripe Noise Reduction

WANG Zhao*, WANG Yan, SU Guo-hui, SHI Sheng-kai
(Qingdao Institute of Marine Geology, Qingdao 266071, China)

Abstract:In view of the complex stripe noise in remote sensing images, a staircase multi-scale convolutional neural network noise reduction model (SmCNN) is proposed. The model adopts a lightweight design of the staircase network structure, highly integrates multi-layer network features such as high and low layers, and has excellent recognition and removal capabilities for heterogeneous, high coverage, multi-scale stripe noise on images. The model mainly uses 3*3 dilated convolution to construct multi-scale network and residual network to integrate multi-scale feature information, enhance the detection ability of multi-scale stripe noise and make up for the degradation of deep network. The jagged hybrid dilated convolution network is used to solve the problem of image information discontinuity. The multi-scale network structure of staircase type is designed, and the 1*1 convolutional lightweight neural network model is introduced to reduce the complexity of the model. The experimental results show that SmCNN has better denoising performance than traditional image denoising methods. Compared with the classical DnCNN model, the denoising quality evaluation indexes of mean square error, peak signal-to-noise ratio and structural similarity are improved by 61.2%, 11.8% and 0.7% respectively. The lightweight effect of network structure is remarkable, and 53.11% of the model training time is saved.

Key words:denoise; staircase multi-scale; hybrid dilated convolution; convolutional neural network; remote sensing image; stripe noise

0 引言

中国遥感卫星初步具备了全天时、全天候观测能力^[1],形成的遥感影像大数据已深入应用到各行各业,对国民生活 and 经济发展起到重要支撑作用^[2]。但在遥感影像采集系统中,受光线变化及线阵相机硬件影响,成像过程中存在辐射响应非均匀性、不同行或列读出电路不一致等问题^[3],在扫描方向上容易产生条带噪

声。这种噪声会对遥感影像质量及后续分析产生极大影响,因此去除条带噪声是遥感影像预处理的关键一环。目前高分遥感影像分辨率能达到亚米级^[4],每个像素都包含了大量信息,因此对遥感影像进行降噪时需要最大化保留影像细节特征。而传统图像降噪方法如灰度信息统计法、数字滤波法^[5-7],存在噪声去除“不干净”、丢失图像细节信息、图像模糊等问题,对图

收稿日期:2022-07-08

修回日期:2022-11-09

基金项目:国家重点研发计划(2021YFF0704000);青岛海洋科学与技术试点国家实验室山东省专项经费(2022QNLMO5032);中国地质调查局海洋地质调查二级项目(DD20221711)

作者简介:王 诏(1991-),女,硕士,工程师,通讯作者,从事人工智能理论及应用方法研究。

像细节处理表现欠佳。

随着大数据、计算机硬件的快速发展,基于卷积神经网络的机器学习算法在图像降噪^[8]、图像识别^[9-10]、语义分割^[11]等计算机视觉领域展现出了巨大潜力,这为遥感影像大数据降噪提供了参考技术与方法。Jain等^[12]在2008年率先利用CNN处理自然图像的去噪问题,并且得到了与小波变换和马尔可夫随机场相近或更优的去噪结果;Zhang等^[13]提出了一种针对高斯噪声的去噪模型DnCNN,结合残差学习和批量归一化(BN)技术提高了模型的降噪性能;Isogawa等^[14]使用弹性收缩方法作为神经网络模型的激活函数,并提出了一种针对弹性收缩阈值的比例系数优化方法;Han等^[15]提出了一种深度残差学习结合U型网络模型(Unet),用于预测稀疏角度的低剂量CT重建,该方法能较好提取图片中的噪声和条纹伪影特征。但以上降噪模型主要针对点状噪声,仍缺少影响深远的条带噪声降噪模型。

另外,随着卷积神经网络的应用逐渐深入,其结构逐步从单一、多层结构演变为复杂、深层结构,参数量日渐庞大,例如,VGG16模型的参数量达到552 MB^[9]。而参数的训练受限于样本数据的规模,过参数化会导致模型过拟合,降低模型泛化能力。因此,权衡卷积神经网络学习能力与模型过参数化、过拟合问题是研究设计深度卷积神经网络结构的重点内容之一。大量学者^[16]在轻量化网络架构上相继提出了SqueezeNet、MobileNet-v1、GhostNet等,主要是将 $1 * 1$ 卷积替换为 $3 * 3$ 卷积,通过降低通道数来减小计算量和参数量。蒋晓奔针对泊松噪声提出了一种多尺度并行模型CT-ReCNN^[17],通过深度可分离卷积和空洞卷积轻量化模型参数,缩短了模型训练时间。

总结以上问题,针对遥感影像条带噪声的复杂性,该文从条带噪声精准识别与深度网络模型轻量化设计两方面考虑,引用混合空洞卷积、 $1 * 1$ 卷积,提出一种阶梯型多尺度深度卷积神经网络条带降噪模型,通过图像像素级别的降噪处理实现条带噪声影像精细降噪。

1 基本原理

1.1 感受野与卷积核

1962年,Hubel和Wiesel通过对猫视觉皮层细胞的研究,提出了感受野的概念。在卷积神经网络中,感受野是卷积神经网络每一层输出特征图上的像素点在输入图片上映射的区域大小,感受野越大,反映出的图像信息越多、大尺度特征越好。卷积核是对图像做卷积处理的卷积算子,即系数矩阵,通过卷积核图像进行局部加权求和,逐步遍历整张图像,实现对图像的局

部感知到整体感知,卷积核大小一般为奇数,如 $1 * 1$ 、 $3 * 3$ 、 $5 * 5$ 。感受野的大小与卷积核有关,具体地,当前层的感受野大小与卷积核大小和卷积核移动步长有关,同时也与上一层感受野的大小有关,见公式(1)。

$$\begin{cases} F_1 = K_1 * S_1 \\ F_{i+1} = F_i + (K_{i+1} - 1) * S_i \\ S_i = \prod_{j=1}^i S_{stride j} \end{cases} \quad (1)$$

其中, F_i 为第 i 层感受野, K_i 为第 i 层卷积核大小, S_{stride} 为卷积核移动步长。

参数量与卷积核大小、通道数、偏置和批量归一化(BN)^[18]有关,见公式(2)。

$$C_i = K_i * K_i * N_i * M_i + 3M_i \quad (2)$$

其中, C_i 为第 i 层参数量, N_i 、 M_i 分别为第 i 层输入输出通道数,当包含偏置时,偏置数量为 M_i ,当使用BN时,还需学习2个超参数,参数量均为 M_i ,总量为 $2M_i$ 。

由式(1)、(2)可知,当使用大卷积核时,感受野会变大,但参数量也会增大,导致计算量突增,不利于网络结构深度的增加。

1.2 空洞卷积

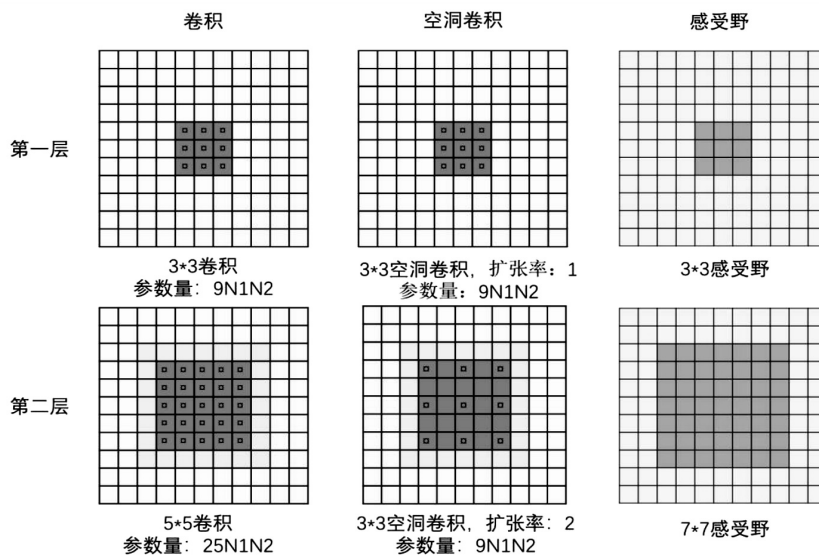
空洞卷积于2016年在ICLR会议上被首次提出,主要用于图像分割领域,解决图像经下采样、上采样后导致的信息丢失问题^[19]。空洞卷积是在常规卷积上引入了一个扩张率(Dilation rate)超参数,该参数定义了卷积核处理数据时各值的间距,当扩张率大于1时,空洞卷积可以在增大感受野的同时,不增加参数量,如图1所示。其中空洞卷积核大小 K_d 计算公式见式(3),其中 R 为扩张率。

$$K_d = K + (K - 1)(R - 1) \quad (3)$$

2 阶梯型多尺度神经网络降噪模型设计

2.1 总体模型设计

在图像降噪领域应用较多的卷积神经网络模型DnCNN、Unet^[20]等,本质上都属于全卷积神经网络(FCN)^[21]。FCN最开始由UC Berkeley提出,主要用于实现图像像素级别处理与分类。与常规卷积神经网络不同的是,FCN去掉了网络末端的全连接层,通过下采样、上采样过程,使网络输入、输出张量大小保持一致。在卷积神经网络中下采样、上采样主要是通过池化和反卷积操作实现。池化是通过压缩特征数据起到降低计算量的作用,但在压缩特征时不可避免丢失图像细节特征信息。由于遥感影像的特殊性,需要最大化保留图像细节信息,因此该文不引入池化和反卷积操作,而是通过引入混合空洞卷积、调整网络结构降低计算量。



在不考虑偏置与 BN 条件下,以 3 * 3 空洞卷积为例,当扩张率为 1 时,其感受野等效于 3 * 3 常规卷积,当扩张率为 2 时,其感受野等效于 5 * 5 常规卷积,但参数数量仍为 9N1N2,远低于 5 * 5 常规卷积的参数数量 25N1N2

图 1 常规卷积核与空洞卷积核

在卷积神经网络中,低层小感受野能获得分辨率更高的特征,其包含更多的细节、位置信息,但信息量少,高层大感受野能获得信息量丰富的大尺度特征,但分辨率低,细节感知能力弱。通过特征融合,使用多尺度网络结构,取长补短,能有效融合多尺度特征,提高多尺度条带噪声识别能力。

随着卷积神经网络结构加深,易导致梯度消失、梯度爆炸、网络退化等问题,目前多在网络中引入 BN、Dropout^[22]操作来解决上述问题,而 He 等^[10]从调整网络结构角度提出一种残差网络来解决这一问题。残差网络是在常规权重层输出外,使用恒等映射直接将输入连接到输出上,该输出和权重层输出做相加运算得到最终的输出。大量实验表明,残差网络能提高网络性能,提高网络的鲁棒性和精确性。

综上,该文设计的遥感影像条带噪声模型,总体思

想上依据 FCN 实现图像像素级别的噪声识别,以均方误差(MSE)为目标函数,通过自适应梯度优化,实现噪声图到“干净”图的端到端映射,从而达到降噪目的,网络结构见图 2。具体地,在传统 FCN 模型基础上,摒弃池化、反卷积层,引用混合空洞卷积,在降低网络计算量的前提下尽量保留图像细节信息;使用多尺度网络结构,提高多尺度、非周期复杂条带噪声的识别、降噪能力;优化网络结构,设计一种阶梯型多尺度网络结构,并且引入空洞卷积和 1 * 1 卷积,轻量化模型参数;在每一层卷积层后,加入 BN 正则化层和 LeakyReLU 激活函数层,缓解梯度爆炸或梯度消失问题,加快收敛速度;在深层网络处引入 Dropout 和残差网络,优化深度网络学习能力,提高降噪模型的鲁棒性和精准性。

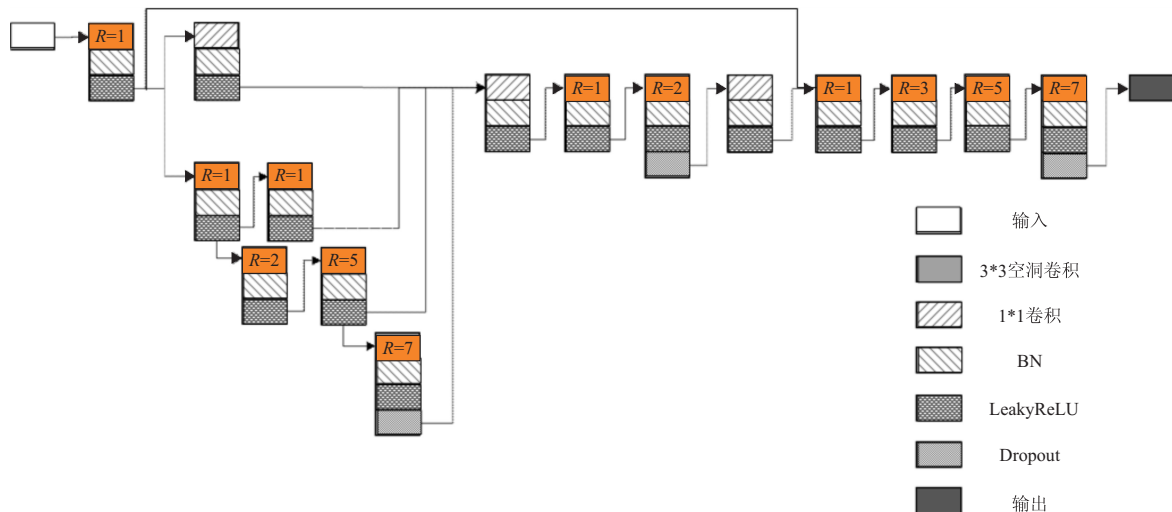


图 2 阶梯型多尺度卷积神经网络降噪模型网络结构

2.2 阶梯型多尺度网络结构设计

该文在传统多尺度网络结构的基础上,提出一种阶梯型多尺度网络结构,其能在不使用大卷积核、不增加卷积核数量的基础上,实现多尺度串、并行结构的轻量化网络结构,网络结构如图 3 所示。由式(2)可知,卷积核越大,网络层参数量以卷积核大小 K 的二次方形式增长,因此设计的网络卷积层仅由 $1 * 1$ 卷积和 $3 * 3$ 空洞卷积构成,通过扩张率超参数 R 灵活调整空洞卷积感受野大小,依据式(1)可知,当前层感受野大小与上一层感受野大小有关,因此以串行连接方式可以逐阶梯增加感受野大小,然后通过并行连接实现多层不同尺度特征融合。与传统多尺度网络结构对比,在保持卷积核数量不变的前提下,阶梯型多尺度网络结构通过改变网络层连接方式,摒弃大卷积核,仅采用 $3 * 3$ 空洞卷积可等效实现多尺度感受野融合。因为阶梯型多尺度网络结构采用小卷积核代替大卷积核,由式(2)知,设置合适的输入层、输出层通道数,可以大大减少参数量。为简化阐述,假设输入输出通道数一致,参数量对比见表 1,当尺度数为 5 时,参数量压缩至 22.4%,随着尺度数量越多,参数量压缩效果越明显。

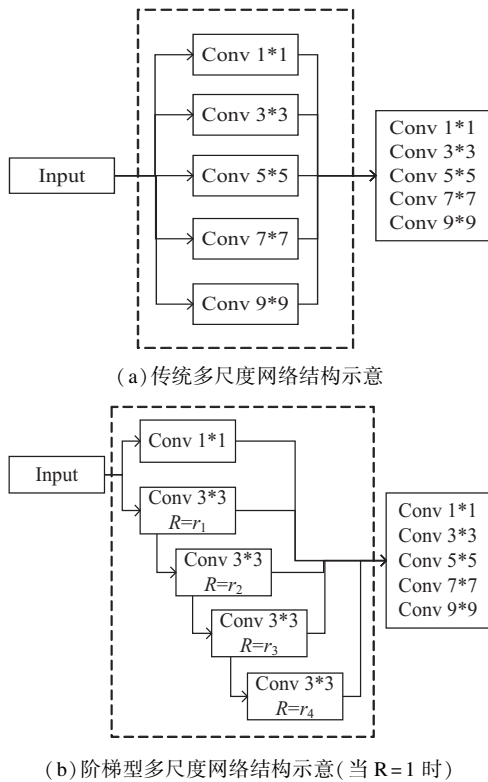


图 3 多尺度网络结构对比

表 1 网络结构参数量对比

多尺度网络结构类型	参数量	实例 ($n = 5$)
传统型	$\frac{1}{3}n(4n^2 - 1)N^2$	$165N^2$
阶梯型	$(9n - 8)N^2$	$37N^2$

为便于参数量对比,简化模型参数,假设尺度以等差数列形式增长, n 为多尺度数量,组合卷积中的 $1 * 1$ 卷积通道数为 $0.25N$,其余卷积层输入输出通道数均为 N 。

2.3 混合空洞卷积设计

卷积神经网络结构越深、卷积核越大,其感受野越广阔,能获得基于简单特征合成的越复杂的特征,但训练模型需要的计算资源、时间成本越多。受硬件环境限制,为尽可能获得高性能模型,同时降低模型训练的计算资源和时间成本,主要采用 $3 * 3$ 空洞卷积,设置扩张率超参数来增加感受野。但多个空洞卷积叠加使用时,虽然会增大感受野,但会损失图像信息的连续性。因此,有人提出混合空洞卷积^[23]的概念以解决图像信息不连续问题,其主要有如下两个特征:①叠加的空洞卷积的扩张率不能有大于 1 的公约数(例如 $[2,4,6]$),不然会产生栅格效应。②设计锯齿状空洞卷积网络结构,例如 $[1,2,5,1,2,5]$ 的循环结构。该文借鉴混合空洞卷积思想,设置混合空洞卷积扩张率组合主要有 $[1,2] [1,2,5] [1,2,5,7] [1,3,5,7]$ 。

2.4 $1 * 1$ 卷积网络结构设计

$1 * 1$ 卷积最早在 network in network 网络结构中被提出,是卷积核大小为 1 的特殊卷积。使用 $1 * 1$ 卷积可以在保证感受野大小不变的条件下,通过降低通道数的方式压缩参数量。如图 4 所示,如果在输入层与输出层之间增加一个 $1 * 1$ 卷积操作,参数量由式(4)变为式(5),当中间层通道数 N_2 满足式(6)条件时,达到压缩参数量的目的。因此,该文设计主干网络、阶梯型多尺度网络时,在通道数大的两个卷积层间适当引入 $1 * 1$ 卷积,能在不降低网络识别性能的前提下,进一步压缩卷积神经网络模型参数量。

$$C_1 = N_1 N_2 + K^2 N_2 N_3 \quad (4)$$

$$C_2 = K^2 N_1 N_3 \quad (5)$$

$$\begin{cases} N_2 < \frac{K^2 N_1 N_3}{K^2 N_3 + N_1} \\ K = 2k - 1, k = 1, 2, 3 \dots \end{cases} \quad (6)$$

3 实验

3.1 遥感影像数据处理

遥感图像条带噪声可能呈周期性分布,可能呈非周期性均匀分布,也可能是非均匀分布;条带噪声的宽度或宽或窄,呈多尺度分布;条带噪声带有一定方向性,但方向不定,可能垂直、水平或倾斜分布。对于一幅含噪声遥感图像,其加性噪声方程式为:

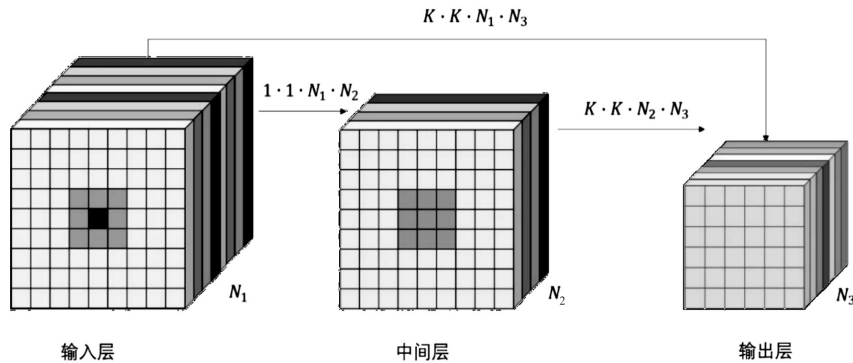
$$X' = X + N \quad (7)$$

其中, X' 为含噪图像, X 为纯净图像, N 为噪声矩阵。

根据式(7)对公开数据集 CCF-BDCI2020 的纯净

遥感图像进行加噪处理,生成覆盖率分别为 0.2、0.5、0.8 的均质多尺度非周期条带噪声图和覆盖率为 0.5 的非均质多尺度非周期条带噪声图,并对图像像素值

进行归一化处理,生成便于进行图像降噪实验的遥感条带噪声影像。



例如,在不考虑偏置与 BN 条件下,输入层通道数为 $N_1=8$,输出层通道数 $N_3=7$,采用 3×3 卷积,参数量为 $3 \times 3 \times 8 \times 9=648$;引入 1×1 卷积降低通道数 $N_2=4$,则参数量为 $1 \times 1 \times 8 \times 4 + 3 \times 3 \times 4 \times 7=284$,参数量压缩 1 倍有余

图 4 1×1 卷积降通道数压缩参数量示意

3.2 降噪实验

实验数据为纯净的遥感影像和加噪遥感影像,噪声为非均质多尺度非周期条带噪声,图像大小为 256×256 (像素),共计 11 000 幅,以 $8:2:1$ 的比例分为训练集、测试集和验证集。以加噪遥感影像数据作为网络输入层、纯净遥感影像数据作为网络输出层,迭代训练出降噪模型。实验在一台高性能计算工作站中进行,显卡为 NVIDIA Tesla P100-PCI-E-12GB(2 片),处理器为 Intel(R) Xeon(R) CPU E5-2650 v4@ 2.20 GHz(2 处理器),内存为 128 G。

根据图 2 网络结构训练获得 SmCNN 模型,其大小为 5.40 MB。量化评价阶梯型多尺度卷积神经网络模型降噪性能,用训练好的 SmCNN 模型对不同条带噪声进行降噪处理,选择均方误差 (MSE)、峰值信噪比 (PSNR)、结构相似性 (SSIM)^[24] 三项图像降噪

质量评价指标评定降噪效果。由表 2 可知,对于均质、非均质多尺度条带噪声都表现出较好的降噪性能,SmCNN 模型具备较好的泛化能力。与纯净原始影像对比,降噪图像均方误差达到 $e-04$ 数量级、峰值信噪比均大于 30、结构相似性均达到 0.97 以上,但随着噪声覆盖率的提高,模型降噪性能有所降低,在噪声覆盖率相同的情况下,对均质噪声降噪性能更好。定性观察降噪性能(见图 5),肉眼几乎很难察觉到降噪图与原始影像的差异,对原始影像的细节信息保留较好。

表 2 不同条带噪声图降噪定量对比

噪声类别	噪声覆盖率	MSE	PSNR	SSIM
均质噪声	0.2	1.300 2e-05	39.859 9	0.994 0
	0.5	7.052 8e-05	39.516 4	0.978 6
	0.8	8.769 6e-04	30.570 2	0.976 6
非均质噪声	0.5	1.257 4e-04	39.005 2	0.994 1

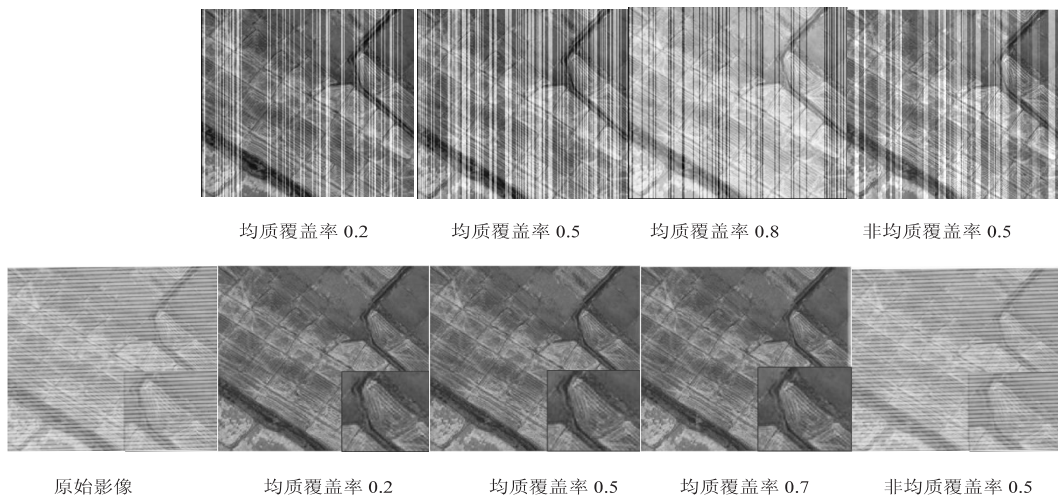


图 5 不同条带噪声图降噪定性对比

将 SmCNN 模型与现在主流的 FCN 模型和传统的图像去噪方法进行降噪效果对比。为保证实验公平

性,对 DnCNN、Unet 及 SmCNN 这类 FCN 模型,采用相同的非均质非周期多尺度噪声图作为训练集、测试

集和验证集,并设置相同的自适应优化器 Adam 与训练参数。各模型降噪性能见表 3、图 6。分析结果可知,傅里叶变换、小波变换这类传统降噪方法降噪性能明显弱于 FCN 模型,其中使用傅里叶变换滤噪能获得结构相似性较高的降噪图,但在图像有效信息保留上不如 FCN 模型;其中,使用 Unet 模型降噪,图像细节会模糊,且均方误差较大;而对于 DnCNN 和 SmCNN 模型,肉眼几乎看不出降噪后的图像与原图的差别,且 SmCNN 相对于 DnCNN,在三项图像降噪质量评价指

标上分别提高了 61.2%、11.8% 和 0.7%。

表 3 不同方法降噪定量对比

方法	MSE	PSNR	SSIM
Wavelet	0.016 9	17.713 1	0.821 0
FT	0.014 6	18.358 0	0.966 2
Unet	0.001 5	28.296 1	0.844 6
DnCNN	3.242 1e-04	34.891 7	0.987 2
SmCNN	1.257 4e-04	39.005 2	0.994 1

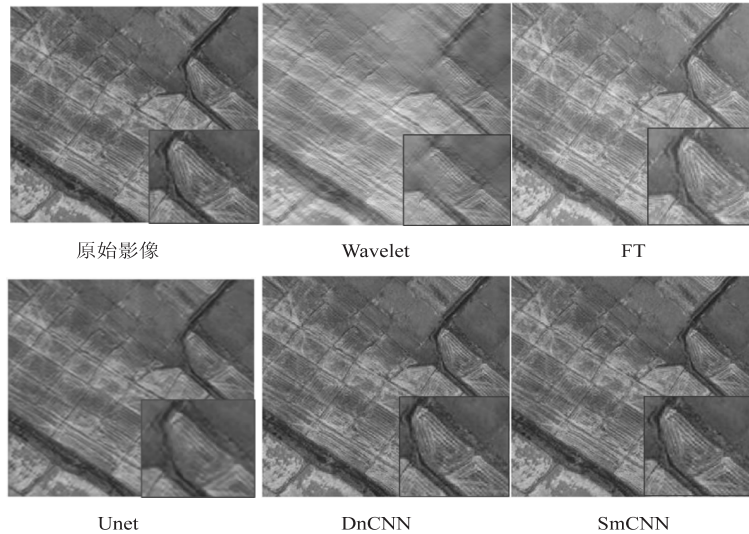


图 6 不同方法对非均质非周期多尺度噪声降噪性能定性比较

由实验可知,DnCNN 与 SmCNN 均具备较好的降噪性能,对比两种模型训练时间,见表 4 中的结构 1、3,文中模型由于引入了阶梯型多尺度网络结构,参数量、网络层数增加了 1 倍左右,模型训练时间也翻倍。

表 4 模型参数量和训练时间对比

序号	模型	参数量	层数	时间/s
1	DnCNN	222 785	24	12 271
2	SmCNN(无轻量化)	1 369 969	122	56 053
3	SmCNN	443 377	53	26 283

模型训练数据集 10 000 幅,epoch 为 100。参数、模型训练时间压缩程度均以上一种模型为基准。

为验证文中卷积神经网络模型轻量化效果,对比 SmCNN 与未作轻量化处理的 SmCNN 的模型参数量、神经网络层数与训练时间,具体结果见表 4 中的模型 2、3。由于 SmCNN 使用阶梯型多尺度网络结构,采用混合空洞卷积等效代替常规卷积,并适当引入了 1 * 1 卷积,其参数量、网络层数相对于模型 2 分别压缩了 66.19% 和 56.56%,节约了 53.11% 的模型训练时间,但仍比模型 1 多了一倍有余的模型训练时间。

4 结束语

针对遥感影像复杂条带噪声,设计了一种阶梯型

多尺度卷积神经网络降噪模型,高度融合高、低层网络的特征信息,以提高非均质、高覆盖、多尺度条带噪声识别、去除能力。实验证明,该多尺度降噪模型对不同覆盖率、非均质的多尺度非周期条带噪声,都具备优秀的降噪能力。与其他降噪方法相比,其降噪性能明显优于传统傅里叶滤波降噪和小波系数阈值降噪方法,与经典的 DnCNN、Unet 降噪模型相比,由于 SmCNN 提高了对多尺度条带噪声的检测能力,且引用混合空洞卷积,弥补了深度空洞卷积层特征提取不连续问题,使其在均方误差、峰值信噪比、结构相似性三个图像降噪质量评价指标上有明显提高。同时,通过设计阶梯型网络结构、引入特殊卷积以轻量化卷积神经网络模型,大幅度降低了模型复杂度,提高了模型训练速度。

受硬件环境制约,更深、更宽、更灵活多变的阶梯型多尺度网络结构对复杂条带噪声有效识别仍需进一步验证。下一步将模块化引入阶梯型多尺度网络结构,加强网络结构、超参数的科学性研究,提高模型的准确度与泛化能力。

参考文献:

[1] 薛毅,李博,张广科. 浅谈我国卫星遥感应用现状与发展[J]. 中国航天,2020(4):51-53.
 [2] 胡杰,张莹,谢仕义. 国产遥感影像分类技术应用研究

- 进展综述[J]. 计算机工程与应用,2021,57(3):1-13.
- [3] 刘则洵,全先荣,任建伟,等. CCD 相机输出非均匀性线性校正系数的定标[J]. 红外与激光工程,2012,41(8):2211-2215.
- [4] 杨诗瑞. 高分系列卫星:太空中的中国“慧眼”[J]. 太空探索,2021(3):6-10.
- [5] 张杨洋. 滤波算法在数字图像降噪中的应用[J]. 自动化应用,2020(12):49-51.
- [6] LIU J G, MORGAN G L K. FFT selective and adaptive filtering for removal of systematic noise in ETM+ imageodesy images[J]. IEEE Transactions on Geoscience and Remote Sensing,2006,44(12):3716-3724.
- [7] MÜNCH B, TRTIK P, MARONE F, et al. Stripe and ring artifact removal with combined wavelet—Fourier filtering[J]. Optics Express,2009,17(10):8567-8591.
- [8] JAVAID U, SOURIS K, HUANG S, et al. OC-0214: comparison of deep convolutional neural networks to denoise Monte Carlo proton dose distributions[J]. Radiotherapy and Oncology,2020,152(S1):107-108.
- [9] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv:1409.1556,2014.
- [10] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the 2016 IEEE conference on computer vision and pattern recognition. Las Vegas; IEEE,2016:770-778.
- [11] PHAM D L, XU C, PRINCE J L. Current methods in medical image segmentation [J]. Annual Review of Biomedical Engineering,2000,2(1):315-337.
- [12] JAIN V, SEUNG H S. Natural image denoising with convolutional networks [C]//Advances in neural information processing systems. New York: Curran Associates Inc.,2008:769-776.
- [13] 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.
- [14] ISOGAWA K, IDA T, SHIODERA T, et al. Deep shrinkage convolutional neural network for adaptive noise reduction [J]. IEEE Signal Processing Letters,2018,25(2):224-228.
- [15] HAN Y S, YOO J, YE J C. Deep residual learning for compressed sensing CT reconstruction via persistent homology analysis[J]. arXiv. 1611.06391,2016.
- [16] 王 军,冯孙铖,程 勇. 深度学习的轻量化神经网络结构研究综述[J]. 计算机工程,2021,47(8):1-13.
- [17] 蒋晓奔. 基于深度卷积神经网络的医学图像去噪方法 [D]. 杭州:浙江工业大学,2020.
- [18] LU Li, ZHANG Ganchun, NIE Ying, et al. Application of improved CNN in SAR image noise reduction [J]. Journal of Physics: Conference Series,2021,1792(1):1-9.
- [19] WANG P, CHEN P, YUAN Y, et al. Understanding convolution for semantic segmentation[C]//2018 IEEE winter conference on applications of computer vision (WACV). Lake Tahoe; IEEE,2018:1451-1460.
- [20] 陈钧荣,林涵阳,陈羽中. 基于 U-Net 融合的保留纹理的图像去噪方法[J]. 小型微型计算机系统,2021,42(4):791-797.
- [21] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2017,39(4):640-651.
- [22] 覃 晓,黄呈铖,施 宇,等. 基于卷积神经网络的图像分类研究进展[J]. 广西科学,2020,27(6):587-599.
- [23] 李海燕,吴自莹,郭 磊,等. 基于混合空洞卷积网络的多鉴别器图像修复[J]. 华中科技大学学报:自然科学版,2021,49(3):40-45.
- [24] 惠婉玉,吴玉秀. 图像去噪滤波方法的对比研究[J]. 洛阳理工学院学报:自然科学版,2021,31(1):71-76.
-
- (上接第 60 页)
- IEEE conference on computer vision and pattern recognition. Athens; IEEE,2018:2472-2481.
- [15] 梁柱彬. 基于多尺度特征融合的目标检测算法研究[D]. 北京:北京交通大学,2021.
- [16] 王 林,王超凡. 差分信息熵在拼接图像质量评估中的应用[J]. 计算机仿真,2020,37(4):265-268.
- [17] 张 建,贾媛媛,贺向前,等. 面向各向异性 3D-MRI 图像超分辨率重建的 ESRGAN 网络[J]. 重庆大学学报,2022,45(5):114-124.
- [18] WANG Y D, ARMSTRONG R T, MOSTAGHIMI P. Enhancing resolution of digital rock images with super resolution convolutional neural networks[J]. Journal of Petroleum Science and Engineering,2019,182:106261.
- [19] TONG T, LI G, LIU X J, et al. Image super-resolution using dense skip connections [C]//IEEE international conference on computer vision. Venice; IEEE,2017:4809-4817.
- [20] 任海涛. 基于深度学习的单幅图像超分辨率技术研究 [D]. 成都:电子科技大学,2022.
- [21] 徐伟夫. 基于深度学习的图像超分辨率重建方法研究与实现[D]. 兰州:兰州交通大学,2019.
- [22] 李英民. 图像双三次插值算法的研究 [D]. 兰州:兰州大学,2020.
- [23] WANG X T, YU K, DONG C, et al. Recovering realistic texture in image super-resolution by deep spatial feature transform [C]//IEEE/CVF conference on computer vision and pattern recognition. Salt Lake City; IEEE,2018:606-615.