

基于残差递归网络的毫米波辐射图像去模糊

徐国豪, 刘媛媛*, 朱路

华东交通大学信息工程学院, 江西 南昌 330013

摘要 为降低真实毫米波辐射图像的模糊现象, 提出了一种基于残差尺度递归网络(RSRN)的毫米波辐射图像盲去模糊方法。RSRN采用多级残差递归结构, 在编码器-解码器网络结构中添加级联残差连接和多尺度循环连接。充分利用毫米波辐射图像多尺度特征信息可以提升模型性能, 同时使网络的训练更加稳定。最后, 通过端到端的方式对毫米波辐射图像进行去模糊。实验结果表明, 与现有的图像去模糊方法相比, 所提方法消除模糊的同时更好地保留了细节信息, 并且呈现出较好的定性和定量结果。

关键词 图像处理; 图像去模糊; 编解码器; 多尺度; 深度学习

中图分类号 TP391.4 文献标志码 A

DOI: 10.3788/LOP202259.1810011

Millimeter-Wave Radiation Image Deblurring Based on Residual Recursive Network

Xu Guohao, Liu Yuanyuan*, Zhu Lu

School of Information Engineering, East China Jiaotong University, Nanchang 330013, Jiangxi, China

Abstract To reduce the blur phenomenon in real millimeter-wave radiation images, a blind deblurring method of millimeter-wave radiation images based on residual scale recursive network (RSEN) is proposed. RSRN adopted a multi-level residual recursive structure and added cascading residual connections and multi-scale recurrent connections to the encoder-decoder network structure. It completely utilized the multi-scale feature information of millimeter-wave radiation images while improving model performance, thus making the networks training more stable. Finally, the millimeter-wave radiation image was deblurred in an end-to-end manner. The results demonstrate that, when compared with the existing image deblurring methods, this method eliminates the blur better while retaining the detailed information, and provides better qualitative and quantitative results.

Key words image processing; image deblurring; encoder-decoder; multi-scale; deep learning

1 引言

毫米波辐射成像技术因其隐蔽性好、适应范围广、探测识别率高, 在精确制导、海关安检、地质勘探、军事等领域具有广泛的应用前景。随着毫米波辐射图像向精细化和结构化方向发展, 成像系统需要再增加天线孔径尺寸或阵列的直径以满足高分辨率的需求。然而, 毫米波辐射测量系统通常存在天线孔径尺寸受限的问题且会受到噪声的影响, 这将导致毫米波辐射图像出现模糊。模糊图像必将影响毫米波辐射图像操作及后续目标检测性能。因此, 在天线孔径尺寸受限条

件下, 对毫米波辐射测量系统所采集到的图像进行去模糊有着重要的意义。

目前, 已有众多国内外学者针对图像去模糊问题展开了研究。传统的图像去模糊将去模糊过程转化为模糊核估计问题, 利用先验对图像模糊核进行建模^[1-4], 然后通过反卷积操作去除图像模糊核和加性噪声来得到清晰图像。盲去模糊方法给定一个未知模糊核的模糊图像, 通过消除图像中不希望存在的模糊来得到清晰图像。由于盲去模糊是一个不适定的逆问题, 估计最佳模糊核是一项困难的任务, 并且这些先验中的大多数只在一般的自然图像上表现良好, 不能推广到特定的图像领

收稿日期: 2021-06-09; 修回日期: 2021-07-13; 录用日期: 2021-07-28

基金项目: 国防科技重点实验室基金(6142113180101)、国家自然科学基金(61967007, 61963016)、教育部人文社会科学研究规划基金(18YJAZH150)、江西省教育厅科学技术研究重点项目(GJJ170360)、江西省重点研发计划重点项目(20201BBF61012)

通信作者: *lyy.78@163.com

域^[5-7],如毫米波图像、人脸^[6]和低照度图像^[7]。为了解决该不适定的问题,相关人员研究了各种自然图像和模糊核先验来正则化潜在在清晰图像的解空间,包括暗通道先验^[1]、 L_0 梯度先验^[2]、重尾梯度先验^[8]、稀疏核先验^[9]和归一化稀疏先验^[10]。然而,这些先验估计都是从有限的观察中得到的,不适合应用于真实图像去模糊任务。

近年来,随着深度学习的发展,越来越多的学者将深度学习应用于图像盲去模糊领域^[11-21]。Nah等^[12]提出了一种从“粗”到“精”的多尺度去模糊处理方法,该方法使用循环神经网络处理每个尺度的图像。Tao等^[13]和Gao等^[14]在不同的尺度之间使用共享网络权重的策略来提升网络性能。Park等^[15]提出了一种多时相(MT)的方法,该方法将严重模糊建模为一系列小模糊,然后在原始空间尺度上渐进地去除少量模糊。然而这些方法通常只在公开的通用数据集上表现良好,难以学习所有模糊类型的变体,因此不能很好地推广到真实图像和特定的图像领域。

根据现有的图像去模糊方法存在的问题,本文基于从“粗”到“精”的策略,提出了一种基于残差尺度递归网络(RSRN)的毫米波辐射图像盲去模糊方法。针对毫米波辐射图像的复杂模糊因素,该方法将编码器-解码器网络与改进的残差块结合,对图像逐级进行去模糊,有效捕获了毫米波辐射图像的多尺度特征,也增强了图像去模糊的性能和鲁棒性。然后,在毫米波图

像数据集上对所提方法进行了评估。实验结果表明,所提方法展现出了良好的去模糊性能。

2 基于RSRN模型的毫米波辐射图像去模糊方法

图像的模糊是由各种各样因素造成的,通常图像模糊的过程在数学上可建模为

$$I_{\text{Blur}} = K * I_{\text{Sharp}} + N, \quad (1)$$

式中: I_{Blur} 和 I_{Sharp} 分别为模糊图像和清晰图像; K 为未知(盲)的或已知(非盲)的模糊核; N 为加性噪声;*表示二维空间卷积运算。

传统的去模糊方法通常从模糊图像 I_{Blur} 中估计模糊核 K ,再通过反卷积移除模糊核得到清晰图像 I_{Sharp} 。由于天线孔径尺寸受限和噪声的影响,且毫米波辐射图像去模糊是一个高度不适定的问题,传统盲去模糊方法难以适用。

针对毫米波辐射图像盲去模糊的高度不适定问题,本实验组设计了基于RSRN的毫米波辐射图像盲去模糊方法。RSRN的网络结构如图1所示,主要包括尺度变换模块(ST)、非线性映射模块(NL)、多尺度模糊提取模块(MSEB)、上采样模块(UB)。UB采用双三次插值的方法对输入特征进行上采样操作,该方法可以避免在改变图像尺寸时产生的锯齿现象,使图像具备平滑的边缘和高质量的细节。

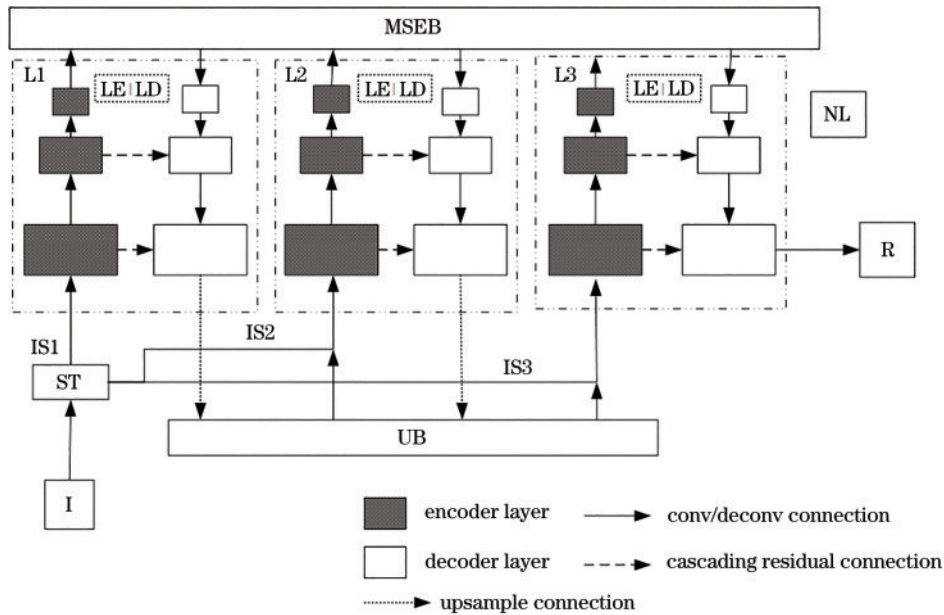


图1 RSRN结构
Fig. 1 RSRN structure

2.1 尺度变换模块

由于毫米波辐射图像普遍存在分辨率低、图像质量差的问题,传统的去模糊方法不能得到很好的结果。因此,为了在保留图像高级信息的同时利用低级信息,本实验组通过ST从输入图像中下采样一组不同尺度

的模糊图像作为网络的输入,利用小尺度图像去模糊过程中获取的特征信息来提升更大尺度图像的去模糊性能。ST是一个浅层图像尺度处理层,主要功能是从输入图像中下采样一组不同尺度的模糊图像(I_{Si}),并将其作为不同尺度的层次模糊提取模块(L)的输入。

下采样的过程可以表示为

$$\begin{cases} I_{\downarrow 1}, I_{\downarrow 2}, \dots, I_{\downarrow i} = f_{ST}(I) \\ S_{\downarrow 1}, S_{\downarrow 2}, \dots, S_{\downarrow i} = f_{ST}(S) \end{cases} \quad (2)$$

式中: f_{ST} 表示尺度变换模块; I, S 分别为输入的模糊图像和对应的清晰图像; $I_{\downarrow 1}, I_{\downarrow 2}, \dots, I_{\downarrow i}, S_{\downarrow 1}, S_{\downarrow 2}, \dots, S_{\downarrow i}$ 分别为对应下采样的不同尺度图像, 并且第 i 个尺度是第 $i-1$ 个尺度的两倍。

2.2 非线性映射模块

由于RSRN采用从“粗”到“精”的策略对图像进行逐级去模糊, 如果各个尺度都使用独立参数会使网络的参数量过于庞大, 从而增加训练难度。受DMPHN^[21]的启发, 在NL中利用权值共享的方法提高网络训练速度、减少网络参数量。NL是L的多次递归, 作用是进一步提取不同尺度图像的深层特征, 其架构如图2所示。每个L的输出经过上采样后与ST的输出在RGB通道上进行叠加(concatenation)并传递到下一个L, 第1个L的输入仅为ST的输出, 之后递归的每一次, L的输入都包含两个部分: 1) 上一个L输出上采样后的结果; 2) ST下采样得到的模糊图像 I_{Si} 。然后, 最后一个L输出最终的神经网络去模糊结果。因为在许多视觉任务中, 编码器-解码器结构已被证明是有效的^[22-26], 所以RSRN的L采用对称的编码器-解码器结构。L包括编码器LE和解码器LD两部分: LE部分负责对输入的图像进行特征提取, 并传递给MSEB进一步捕获该尺度下图像结构和模糊核信息; LD部分负责接收MSEB传递的特征信息, 并进行有效的重建。L的重要特性就是每个L的输入来源不同。由于信息在流动过程中会不断损耗, 为了有效地进行特征重用, 同时考虑参数量的问题, 最终搭建了级联残差(CR)连接, 如图2所示。CR连接结构上类似于级联连接, 但本质上仍为残差连接, 并通过参数控制信息的流动。由于级联残差连接, LD的输入除了MSEB传递的信息, 还包括来自于LE对应部位CR连接的输入。

在第 i 个L中, 第1部分的输入(即第 $i-1$ 个L的输出), 先经过UB进行上采样, 并与第2部分的输入(即ST下采样得到的模糊图像 I_{Si})相连接, 再输入LE中进行高频信息的定位与提取。第 i 个L的表达式为

$$R_d^i = f_L(I_{Si}, R_d^{i-1}), \quad (3)$$

式中: f_L 表示L; R_d^i, R_d^{i-1} 分别为第 i 个和第 $i-1$ 个L的输出; I_{Si} 为第 i 个L的第2部分输入。

编码器LE包含了三个通道数不同的特征提取模块, 模块通道数分别为[32, 64, 128], 每个特征提取块都由一个卷积层与两个残差块构成。将输入数据逐步转换成空间尺寸更小、通道更多的特征图, 然后再在解码器中将其转换回输入的形状。并且, 在编码器LE和解码器LD中对应模块之间的级联残差连接可以用于组合不同层次的特征信息, 有利于梯度传播和加速收敛。

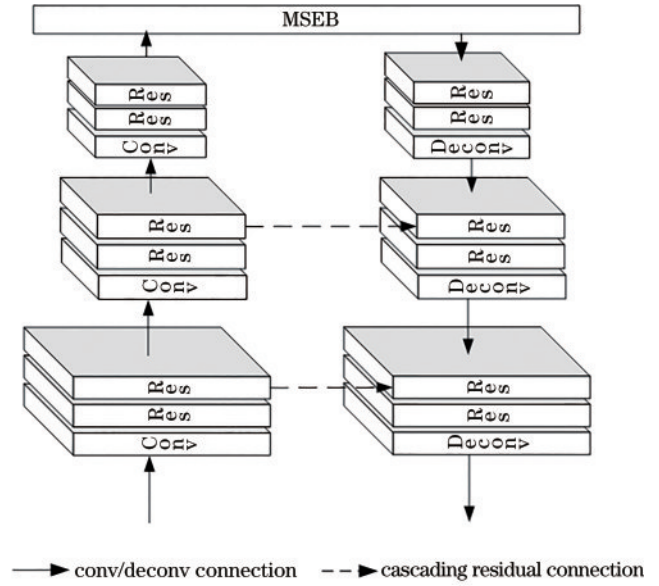


图2 层次模糊提取模块结构

Fig. 2 Hierarchical blur extraction module structure




图3 编码器LE的结构组成

Fig. 3 Structure of encoder LE

典型的编码器包含几个阶梯形的卷积层, 而译码模块是使用一系列的反卷积层^[22-23, 25]或调整大小来实现的, 并在其后面插入卷积层以进一步增加深度。本实验组为了初步选择信息更丰富的特征, 达到好的网络性能, 引入了残差块^[12]与卷积层来构成特征提取块, 并且随着网络的深入, 特征提取块的卷积核数量翻倍, 将特征图的样本大小缩小一半, 从而达到快速处理的目的。残差块由两个卷积层、一个激活函数层和一个跳跃连接组成, 可以实现更深的体系结构, 可以有效地对模糊与清晰图像之间的差异进行学习, 提高训练时的收敛速度, 如图4所示。并且, 网络中的所有卷积核尺寸都为 5×5 。




图4 残差块(Res)的内部结构

Fig. 4 Internal structure of residual block (Res)

在 RSRN 中, L 采用的是一种对称的卷积神经网络结构, 所以解码器 LD 和编码器 LE 具有相同的层结构, 不同的是两个卷积层被反卷积层替换以重建图像。解码器中的特征重建块与编码器中的特征提取块类似, 包含两个残差块和一个反卷积块, 反卷积块用来增大特征图尺寸和减少通道数量。解码器类似于编码器的结构, 通过三个不同大小的特征重建块逐步将接收的信息进行恢复重建, 最终重建出移除了模糊因素的清晰图像。




图 5 解码器 LD 的结构

Fig. 5 Structure of decoder LD

2.3 多尺度模糊提取模块

虽然编码器-解码器结构在许多视觉任务中表现出了很好的性能, 但是去模糊任务需要很大的感受野来处理剧烈的运动, 因此网络需要堆叠更多的编码/解码模块, 直接使用这种结构会导致参数数量快速增加, 并不是去模糊任务的最佳选择。本实验组在编码器和解码器之间添加多尺度模糊提取模块, 用于提取各个尺度图像的特征图并循环传递跨尺度去模糊的信息, 有利于图像跨尺度去模糊的重构。

循环神经网络(RNN)因其在序列信息处理中的优势, 是一种常用的去模糊工具^[13, 27]。由于图像数据有着丰富的空间信息并且每一个点和周围有很强的相关性, 在编码过程中保留其空间信息有助于图像重构; 而在各种类型的循环神经网络中, ConvLSTM 可以保留图像数据的空间信息, 有利于图像的特征提取, 所以本实验组基于 ConvLSTM 设计了一种用于多尺度重建网络的 MSEB, 如图 6 所示




图 6 MSEB 的内部结构

Fig. 6 Internal structure of MSEB module

该模块可以充分利用 NL 提取到的图像特征, 捕获各个尺度下图像结构和模糊核信息; 可以在保留图像高级信息的同时利用网络中的低级信息, 对各个尺度下提取的特征映射进行堆叠连接, 增大网络的感受野, 大幅提高了网络性能。同时, MSEB 捕获的信息有助于解码器 LD 对图像的模糊特征进行移除, 恢复出高质量的清晰图像。

$$O_{LD_i} = \text{ConvLSTM}(O_{LE_i}; \theta_{LSTM}), \quad (4)$$

式中: O_{LE_i} 为第 i 个 L 的编码器输出; O_{LD_i} 为第 i 个 ConvLSTM 的输出; ConvLSTM(\cdot) 是参数为 θ_{LSTM} 的 RNN。

2.4 网络损失函数

L2 范数对异常值更加敏感, 能够有效避免网络在训练时出现过拟合现象, 并且可以提升网络的泛化能力, 为了优化 RSRN 模型, 本实验组使用 L2 范数作为损失函数。损失函数的表达式为

$$L = \sum_{i=1}^n (1/N^i) \|I_{\text{sharp}}^i - R_{\text{out}}^i\|_2^2, \quad (5)$$

式中: R_{out}^i 和 I_{sharp}^i 分别为网络第 i 个 L 的输出与对应的真实锐利图像; N^i 是第 i 个 L 中进行标准化的元素个数。

3 结果分析与讨论

3.1 实验数据集及预处理

为了创建一个大型的训练数据集, 早期基于学习的方法^[28-29]将清晰图像与真实的或生成的模糊核进行卷积来合成模糊图像。由于毫米波辐射图像采集过程的复杂性, 本实验组利用 Open CV 并基于 Python 语言对已有毫米波辐射图像数据集 UGR-PM2WI Dataset^[30]添加模糊, 主要使用 Open CV 中的 cv2.filter2D() 函数来处理 UGR-PM2WI Dataset 数据集内的毫米波辐射图像, 生成实验需要的模糊/清晰图像对^[31], 并将新生成的具有配对数据的数据集命名为 PM2WI Dataset。这些生成的图像近似于受到一定干扰后采集的有损毫米波辐射图像, 因此可以很好模拟复杂环境干扰给毫米波辐射图像采集带来的影响。

为了在网络结构方面进行公平比较, 使用生成的 PM2WI Dataset 来训练网络, 该数据集包含 3309 对模糊/清晰图像, 大部分都是不同人(肤色和身高不同)在 10 个身体部位佩戴 12 个不同物体的照片: 前臂、胸部、腹部、大腿、脚踝(前)、腰部、腋窝、手臂、脚踝(侧)、大腿及 2 张没有任何物体的图像, 还拍摄了人们在不同位置同时佩戴两件物品的照片。总之, 数据集由 463 张没有佩戴任何物品、2144 张佩戴一个物品、702 张佩戴两个物品的人物图像组成。图 7 展示了 PM2WI Dataset 的部分图像样本, 网络的训练集和测试集划分如表 1 所示。

模糊距离为 40 pixel、模糊角度为 45° 时的模糊效果如图 8 所示, 其中左侧为清晰图像, 右侧为生成的模




图 7 数据集中部分毫米波辐射图像样本

Fig. 7 Some millimeter wave radiation image samples in dataset

表 1 训练集与测试集图像数量

Table 1 Number of images in training set and test set

Dataset	Original dataset	Preprocessed dataset
Number of images in training set	2979	5958
Number of images in test set	330	660
Total number of images	3309	6618




图 8 模糊效果展示

Fig. 8 Blur effect display

糊图像。

此外,为防止网络模型对训练集的过拟合,在训练过程中随机对图像进行镜像和几何翻转处理。

3.2 实验环境及训练参数设置

所有的实验均在 PyTorch 框架中实施,并在单个 NVIDIA GeForce RTX 2080 Ti GPU 上进行了评估。为了训练 RSRN,首先将图像随机裁剪为 256×256 大小。随后,从裁剪的图像中提取补丁并将其转发到每个尺度网络的输入端。在训练期间,批次大小设置为 16,使用 Adam 求解器对模型迭代 3000 次。初始学习率设置为 1×10^{-4} ,衰减率设置为 0.1。

3.3 评估与结果

首先将原始图像输入 RSRN 进行性能分析,并选择目前在图像去模糊领域表现良好的文献[13]、文献[15]、文献[32]和文献[33]的几种图像盲去模糊方法进行对比,对应的峰值信噪比(PSNR)、结构相似性(SSIM)、参数(param)等性能指标如表2所示。从表2可以看出,所提 RSRN 方法在 PSNR、SSIM 性能指标上都达到了很好的结果,并且在各种网络模型参数数量的对比中,所提网络结构参数数量是最少的,这表明了所

表 2 不同方法的性能指标结果对比

Table 2 Comparison of performance of different methods

Method	PSNR	SSIM	Param /MB
SRN ^[13]	39.49	0.98738	3.76
MTRNN ^[15]	39.23	0.98737	2.64
SIUN ^[32]	35.77	0.98191	24.5
MPRNet ^[33]	35.67	0.98007	20.1
Proposed method	39.69	0.98774	2.56

提方法对毫米波辐射图像去模糊的优势。所提方法性能提升的原因主要在于:MSEB 和 NL 发挥了作用。正如之前分析的那样,NL 能够更加精准地选择高频特征信息,MSEB 能够充分利用多尺度的特征信息,级联残差连接能够更有效地进行特征重用。

在不同方法的性能指标结果对比中,所提方法在测试阶段对毫米波辐射图像取得了很好的去模糊性能。同时,为了验证所提方法在原始毫米波辐射图像上的有效性,图9给出了对原始未添加模糊的毫米波辐射图像的去模糊效果对比,展示了不同的模型对原始毫米波辐射图像的去模糊效果,以此来验证所提方法的有效性。为了方便对不同去模糊方法的测试效果进行对比,对去模糊后的毫米波辐射图像中主要的对象进行了放大处理。从图9可以看出:MTRNN 能够对原始毫米波辐射图像进行去模糊处理,但是去模糊后的毫米波辐射图像出现了过度去模糊的情况,图像的细节信息遭遇了严重的失真;MPRNet 对原始毫米波辐射图像虽然具有一定的去模糊效果,但是该网络对于原始毫米波辐射图像的去模糊效果并不明显,在图中视觉效果的对中很难看出去模糊后的结果与输入图像之间的差异;而所提方法对原始毫米波辐射图像具有一定的去模糊效果,图中的放大部分展现了明显的图像去模糊效果,并且没有出现过度去模糊的情况,对图像的细节部分实现了很好的去模糊处理。即,RSRN 在所有情况下都可以产生清晰的轮廓和细节,显著优于其他去模糊方法。




图9 视觉比较效果

Fig. 9 Visual comparison

4 结 论

针对毫米波辐射图像去模糊的高度不定问题,提出残差尺度递归算法,并设计了一个端到端的由粗到精的深度分层去模糊网络。与以前的研究不同,该算法避免了与核估计相关的问题,充分利用了编解码器网络与残差块的结合提取图像结构与模糊核信息;与现有的深度去模糊框架相比,所提模型在 PSNR 和 SSIM 客观指标上均优于现有方法。该模型遵循由“粗”到“精”的方法在多尺度空间中对网络进行训练,还生成了一个用于实验的真实模糊数据集,实现了高效的监督学习和严格的评估。实验结果表明,所提方法在定性和定量两方面都优于现有的方法。下一步的

工作,希望改进网络结构使其可以应用到其他毫米波图像处理任务中。

参 考 文 献

- [1] Pan J S, Sun D Q, Pfister H, et al. Blind image deblurring using dark channel prior[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 1628-1636.
- [2] Xu L, Zheng S C, Jia J Y. Unnatural L_0 sparse representation for natural image deblurring[C]//2013 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2013, Portland, OR, USA. New York: IEEE Press, 2013: 1107-1114.

- [3] Kingma D P, Welling M. Auto-encoding variational Bayes[EB/OL].(2014-05-01)[2021-05-21]. <https://arxiv.org/abs/1312.6114>.
- [4] 陈晨, 许金鑫, 危才华, 等. 基于显著性强度和梯度先验的多尺度图像盲去模糊[J]. 激光与光电子学进展, 2020, 57(4): 041505.
Chen C, Xu J X, Wei C H, et al. Multi-scale image blind deblurring based on salient intensity and a priori gradient[J]. *Laser & Optoelectronics Progress*, 2020, 57(4): 041505.
- [5] 高敏, 王肖霞, 杨风暴, 等. 面向 SAR 图像像素级变化检测的去模糊化处理方法[J]. 激光与光电子学进展, 2020, 57(22): 221105.
Gao M, Wang X X, Yang F B, et al. Deblurring processing method for pixel level change detection of SAR images[J]. *Laser & Optoelectronics Progress*, 2020, 57(22): 221105.
- [6] Shen Z Y, Lai W S, Xu T F, et al. Deep semantic face deblurring[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 8260-8269.
- [7] Hu Z, Cho S, Wang J, et al. Deblurring low-light images with light streaks[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2014, Columbus, OH, USA. New York: IEEE Press, 2014: 3382-3389.
- [8] Fergus R, Singh B, Hertzmann A, et al. Removing camera shake from a single photograph[J]. *ACM Transactions on Graphics*, 2006, 25(3): 787-794.
- [9] Shan Q, Jia J Y, Agarwala A. High-quality motion deblurring from a single image[J]. *ACM Transactions on Graphics*, 2008, 27(3): 1-10.
- [10] Krishnan D, Tay T, Fergus R. Blind deconvolution using a normalized sparsity measure[C]//CVPR 2011, June 20-25, 2011, Colorado Springs, CO, USA. New York: IEEE Press, 2011: 233-240.
- [11] Kupyn O, Budzan V, Mykhailych M, et al. DeblurGAN: blind motion deblurring using conditional adversarial networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 8183-8192.
- [12] Nah S, Kim T H, Lee K M. Deep multi-scale convolutional neural network for dynamic scene deblurring [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 257-265.
- [13] Tao X, Gao H Y, Shen X Y, et al. Scale-recurrent network for deep image deblurring[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 8174-8182.
- [14] Gao H Y, Tao X, Shen X Y, et al. Dynamic scene deblurring with parameter selective sharing and nested skip connections[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 3843-3851.
- [15] Park D, Kang D U, Kim J, et al. Multi-temporal recurrent neural networks for progressive non-uniform single image deblurring with incremental temporal training [M]//Vedaldi A, Bischof H, Brox T, et al. *Computer vision-ECCV 2020. Lecture notes in computer science*. Cham: Springer, 2020, 12351: 327-343.
- [16] Li X, Jimmy S J R, Ce L, et al. Deep convolutional neural network for image deconvolution[C]//Advances in Neural Information Processing Systems 27, December 8-13, 2014, Montreal, Quebec, Canada. [S. l.: s. n.], 2014: 1790-1798.
- [17] Jian S, Cao W F, Xu Z B, et al. Learning a convolutional neural network for non-uniform motion blur removal[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition, June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 769-777.
- [18] Kupyn O, Martyniuk T, Wu J R, et al. DeblurGAN-v2: deblurring (orders-of-magnitude) faster and better[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27-November 2, 2019, Seoul, Korea (South). New York: IEEE Press, 2019: 8877-8886.
- [19] Mao X D, Li Q, Xie H R, et al. Least squares generative adversarial networks[C]//2017 IEEE International Conference on Computer Vision, October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 2813-2821.
- [20] 祁清, 郭继昌, 陈善继. 基于图像边缘判别机制的盲图像去模糊方法[J]. 激光与光电子学进展, 2020, 57(24): 241022.
Qi Q, Guo J C, Chen S J. Blind image deblurring based on image edge determination mechanism[J]. *Laser & Optoelectronics Progress*, 2020, 57(24): 241022.
- [21] Zhang H G, Dai Y C, Li H D, et al. Deep stacked hierarchical multi-patch network for image deblurring [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 5971-5979.
- [22] Su S C, Delbracio M, Wang J, et al. Deep video deblurring for hand-held cameras[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 237-246.
- [23] Anwar S, Huynh C P, Porikli F. Class-specific image deblurring[C]//2015 IEEE International Conference on Computer Vision, December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 495-503.
- [24] Liu Z W, Yeh R A, Tang X O, et al. Video frame synthesis using deep voxel flow[C]//2017 IEEE International Conference on Computer Vision, October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 4473-4481.
- [25] Tao X, Gao H Y, Liao R J, et al. Detail-revealing deep video super-resolution[C]//2017 IEEE International Conference on Computer Vision, October 22-29, 2017,

- Venice, Italy. New York: IEEE Press, 2017: 4482-4490.
- [26] Xu N, Price B, Cohen S, et al. Deep image matting[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 311-320.
- [27] Zhang J W, Pan J S, Ren J, et al. Dynamic scene deblurring using spatially variant recurrent neural networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 2521-2529.
- [28] Chakrabarti A. A neural approach to blind motion deblurring[M]//Leibe B, Matas J, Sebe N, et al. Computer vision-ECCV 2016. Lecture notes in computer science. Cham: Springer, 2016, 9907: 221-235.
- [29] Schuler C J, Hirsch M, Harmeling S, et al. Learning to deblur[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(7): 1439-1451.
- [30] López-Tapia S, Molina R, de la Blanca N P. Deep CNNs for object detection using passive millimeter sensors[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2019, 29(9): 2580-2589.
- [31] 郭俊东, 冯辉, 徐海祥. 基于生成对抗网络的船舶图像去模糊算法[J]. 武汉理工大学学报(交通科学与工程版), 2021, 45(5): 901-906.
- Guo J D, Feng H, Xu H X. Ship image motion deblurring algorithm based on generative adversarial network[J]. Journal of Wuhan University of Technology (Transportation Science & Engineering), 2021, 45(5): 901-906.
- [32] Ye M Y, Lü D, Chen G S. Scale-iterative upscaling network for image deblurring[J]. IEEE Access, 2020, 8: 18316-18325.
- [33] Zamir S W, Arora A, Khan S, et al. Multi-stage progressive image restoration[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 20-25, 2021, Nashville, TN, USA. New York: IEEE Press, 2021: 14816-14826.