

文章编号:1001-5078(2024)11-1777-07

· 图像与信号处理 ·

基于 GAN 和 DWT 的船舶红外偏振图像超分辨率方法

宋施霖¹, 朱志宇¹, 张哲卿², 杜星月¹

(1. 江苏科技大学 自动化学院, 江苏 镇江 212100; 2. 海军装备部驻无锡地区军事代表室, 江苏 无锡 214000)

摘要:针对海面船舶红外偏振成像分辨率低、细节不清的问题,提出一种小波变换与生成对抗网络结合的方法提高图像分辨率。使用纯卷积神经网络模型(ConvNeXt)改进超分辨率网络(SRGAN),采用非局部均值对原始低分辨率船舶红外偏振图像进行去噪,用改进的SRGAN对低分辨率图像进行初始超分辨率,使用二维离散小波变换提取初始超分图像的细节信息,最后将细节信息通过小波逆变换与原始低分辨率的船舶红外偏振图像融合。与传统超分辨率方法相比,本文方法得到的超分辨率图像的峰值信噪比和结构相似性有明显提升。本文实现了红外偏振图像超分辨率与细节信息融合的同时进行,得到的超分辨率图像既保留了原始图像的红外偏振信息,又融合了高分辨率的细节信息。

关键词:船舶红外偏振图像;图像超分辨率;生成对抗网络;二维离散小波变换

中图分类号:TP391;TN219 **文献标识码:**A **DOI:**10.3969/j.issn.1001-5078.2024.11.019

Super-resolution of ship infrared-polarized image based on GAN and DWT

SONG Shi-lin¹, ZHU Zhi-yu¹, ZHANG Zhe-qing², DU Xing-yue¹

(1. School of Automation, Jiangsu University of Science and Technology, Zhenjiang 212100, China;

2. Naval Representative Office in Wuxi District Military Office, Wuxi 214000, China)

Abstract: Aiming at the problem of low resolution and unclear details of infrared polarization imaging of sea ships, a method combining wavelet transform and generative adversarial network is proposed to improve image resolution. Firstly, the pure convolutional neural network model (ConvNeXt) is used to improve the super-resolution network (SRGAN), and the original low-resolution ship infrared polarimetric image is denoised by using non-local mean. Then, the low-resolution image is initially super-resolved with the improved SRGAN, and the detail information of the initial super-resolved image is extracted using a two-dimensional discrete wavelet transform. Finally, the detail information is fused with the original low-resolution ship infrared polarization image through the inverse wavelet transform. Compared with the traditional super-resolution method, the peak signal-to-noise ratio and structural similarity of the super-resolution image obtained by the proposed method are significantly improved. In this paper, the infrared polarization image super-resolution and detail information fusion is achieved at the same time and the obtained super-resolution image not only retains the infrared polarization information of the original image, but also fuses the high-resolution detail information.

Keywords: ship infrared polarization images; image super-resolution; generate adversarial networks; wavelet transform

基金项目:江苏省研究生科研与实践创新计划项目(No. KYCX23_3887)资助。

作者简介:宋施霖(1999-),男,硕士研究生,研究方向为图像处理技术。E-mail:1120293144@qq.com

通讯作者:朱志宇(1971-),男,博士,教授,硕导,研究方向为先进控制理论与应用技术。E-mail:zzydzz@163.com

收稿日期:2024-01-08; **修订日期:**2024-02-20

1 引言

在海面船舶目标识别中,因为以金属材料为主体的舰船目标与海面 and 天空等自然背景偏振度相差较大,所以不同于可见光和普通红外图像,通过红外偏振成像系统得到的图像可以更好的地显现出金属船体与海面、天空等自然环境或物体的区别,极大提升目标识别成功率^[1]。然而在实际应用中,由于偏振片只允许特定震动方向的光通过而过滤掉其他方向的光,得到的红外偏振图像清晰度低于不使用偏振片的红外图像,并且图像采集设备与船舶目标之间距离较远,得到的图像分辨率较低,在待识别目标较小或细节信息较少时可能影响后续识别的实际效果。因此,对红外偏振图像进行超分辨率重建具有重要意义。

图像超分辨率重建旨在从一张低分辨率图像恢复到高分辨率图像,目的是重建出能够清晰展现图像纹理、边缘等信息的更高分辨率的图像^[2]。传统的超分辨率重建方法主要有基于插值的方法,如双线性插值(Bilinear)和双立方插值(Bicubic)^[3],这类算法仅基于相邻像素间的数值关系粗略计算重建的像素值,得到的图像无法保证清晰度。2014年,Dong等人将卷积神经网络应用到图像超分辨率算法,提出超分辨卷积神经网络(SRCNN)^[4],此方法显著提升了图像超分辨的整体效果。2015年,Dong等人针对SRCNN训练速度慢的问题对算法加以改进,将反卷积层加入网络模型中,提出了快速超分辨卷积神经网络(FSRCNN)^[5]。2016年,Kim等人将VGG模型应用到图像超分辨中,提出了超深层超分辨率卷积神经网络(VDSR)^[6]。2017年,Ledig等人将生成对抗网络(GAN)^[7]应用到图像超分辨中,提出了基于生成对抗网络的图像超分辨率算法(SR-GAN)^[8],通过优化损失函数、引入感知和对抗损失,得到视觉效果更好的重建图像。2019年,Tamar等人针对部分研究对象存在训练数据集样本数量少的问题,提出了基于单张图片的生成对抗网络模型(SinGAN)^[9],该模型仅在单张低分辨率图像上训练模型,通过一个全卷积的轻量级GANs金字塔^[9]实现图像的超分辨重建。2020年,吴浩博等人将小波(Wavelets)引入图像超分辨领域^[10],从图像的小波域进行超分辨重建,注重图像高频细节信息,提升图像重建效果。

海面背景下的船舶红外偏振图像色彩分布简单且细节信息较少,在超分辨过程中可能丢失更多细节信息。本文提出小波变换与生成对抗网络结合的方法,首先使用非局部均值对原始图像进行去噪,再采用改进的基于生成对抗网络的图像超分辨率算法(SR-GAN)对船舶红外偏振图像进行超分辨重建,并使用小波变换提取重建后图像的细节信息,再通过小波逆变换将细节信息与原始船舶红外偏振图像进行融合,最后得到超分辨率的船舶红外偏振图像。

2 算法原理

本文提出的船舶红外偏振图像超分辨率方法的总体框架如图1所示。

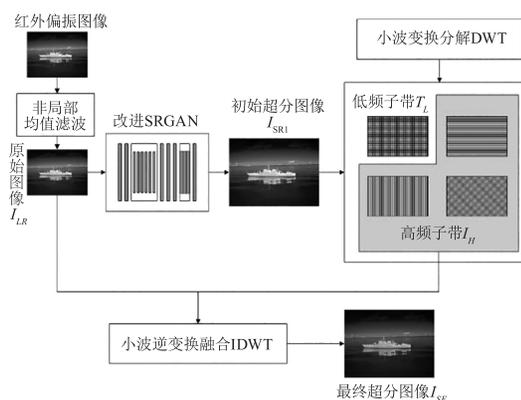


图1 船舶红外偏振图像超分辨率方法原理图

Fig. 1 Principle diagram of super-resolution method for infrared polarization images of ships

将采集到的船舶红外偏振图像使用非局部均值滤波处理,处理后图像称为原始图像 I_{LR} 。将 I_{LR} 输入改进的SRGAN生成初始的超分辨率图像 I_{SR1} 。将 I_{SR1} 通过小波变换分解为高频子带 I_H 和低频子带 I_L ,其中高频子带 I_H 包含了分解前图像的细节信息。同时,相比于原始图像 I_{LR} ,低频子带 I_L 的细节信息更少,因此本文在小波逆变换融合中将 I_L 替换为 I_{LR} ,即将 I_{SR1} 分解得到的高频细节信息 I_H 与原始图像 I_{LR} 进行小波逆变换融合,得到最终超分辨率图像 I_{SR} 。

2.1 船舶红外偏振图像非局部均值滤波

在红外偏振成像中,以海面为背景采集到的船舶图像容易受到高频噪声干扰,因此需要对采集到的图像进行去噪处理,同时还要保留去早前图像的细节特征,针对以上问题,本文提出使用非局部均值滤波算法作为船舶红外偏振图像去噪方法。

非局部均值滤波利用图像中小块的关联性,以图像块为单位在船舶红外偏振图像中寻找相似区域,再对这些区域进行加权平均运算,能够有效抑制图像中的噪声干扰。非局部均值滤波过程用下面公式表示:

$$u(i) = \sum_{j \in I} \omega(i,j)v(j) \quad (1)$$

其中, v 为去噪前的图像; u 为去噪后的图像; 权重系数 $\omega(i,j)$ 为像素 i 和像素 j 的相似度,大小由欧氏距离 $\|V(i) - V(j)\|^2$ 决定,如下所示:

$$\begin{cases} \omega(i,j) = \frac{1}{C(i)} e^{-\frac{\|V(i)-V(j)\|^2}{h^2}} \\ C(i) = \sum_{j \in I} e^{-\frac{\|V(i)-V(j)\|^2}{h^2}} \end{cases} \quad (2)$$

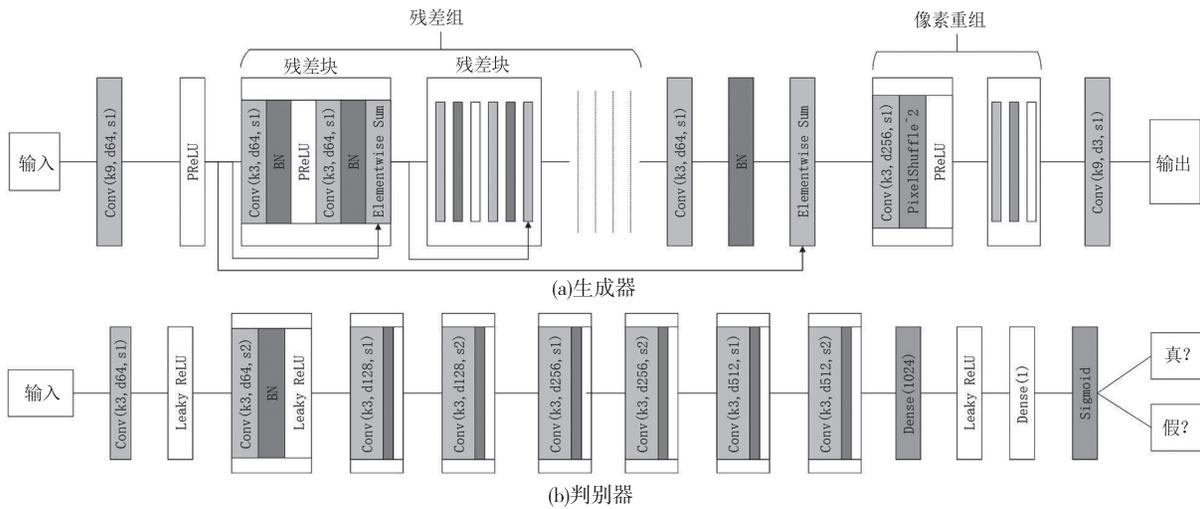


图2 SRGAN 的生成器和判别器的网络结构

Fig. 2 The network structure of SRGAN's generator and discriminator

SRGAN 的生成器的主体是由多个残差块构成的深度残差网络,在网络末端使用若干次像素卷积重组(Pixel-Shuffle)来放大图像尺寸。生成器网络使用残差结构加强信息跨层之间的流动,防止网络深度加深导致的梯度消失问题,相比于其他方式,SRGAN 能通过学习得到更真实的超分辨率图像。SRGAN 的判别器是一个普通的降采样卷积神经网络,逐步降低特征图的分辨率,最后使用 Dense 模块加 Sigmoid 函数对输入图像进行打分,判断输入图像是原始的高分辨率图像还是重建的高分辨率图像。

为了进一步提升 SRGAN 生成器的性能,本文使用一种新型的纯卷积神经网络模型 ConvNeXt^[12] 对 SRGAN 的生成器加以改进,该模型基于 Vision Transformer 进行改进,通过引入残差网络的特性来增强模型的性能和效率,在设计上 ConvNeXt 使用 7

式中, $V(i)、V(j)$ 为以 $i、j$ 为中心的大小相同的矩形相似块; $C(i)$ 为归一化参数; h 为控制滤波的衰减参数;随着 h 的增加,去噪效果逐渐增强,但图像细节丢失越严重。本文通过多次实验,得到在 h 设置为 8 时,可在保留了船舶红外偏振图像的细节特征的同时得到最佳去噪效果。

2.2 改进 SRGAN 超分辨率法

SRGAN 是将 GAN 算法引入超分辨率重建领域的成功尝试,该算法在生成器与判别器博弈优化的过程中逐渐产生质量高、细节多的高分辨率图像,有效解决了以往算法产生的图像过于平滑的问题^[11]。传统 SRGAN 模型的生成器、判别器结构如图 2 所示。

$\times 7$ 卷积核,减少激活函数个数并将其从 ReLU 替换为 GELU,减少 Norm 层,并将 Batch Norm 替换为 Layer Norm 且只在第一次卷积后使用 LN,ResNet 残差块与 ConvNeXt 残差块的结构对比如图 3 所示。

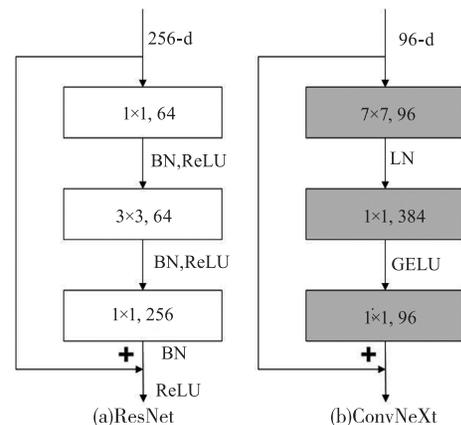


图3 ResNet 残差块与 ConvNeXt 残差块

Fig. 3 Residual blocks of ResNet and ConvNeXt

本文使用 ConvNeXt 残差块结构, 替换 SRGAN 生成器中的 ResNet 残差块, 改进后的 SRGAN 称为 SRGANx, 其生成器网络结构如图 4 所示。该网络由 4 个 ConvNeXt 残差组构成, 残差组内部结构如图 5 所示, 根据文献[12], 设计者通过大量实验, 对比了

不同块配置下的模型性能, 包括模型参数数量、计算效率等多个方面, 最终得到当 4 个残差组中的 ConvNeXt 残差块个数为 3、3、9、3 时网络效率提升最明显, 这种设计既平衡了模型的深度和宽度, 又在保持了模型效率的同时最大化性能。

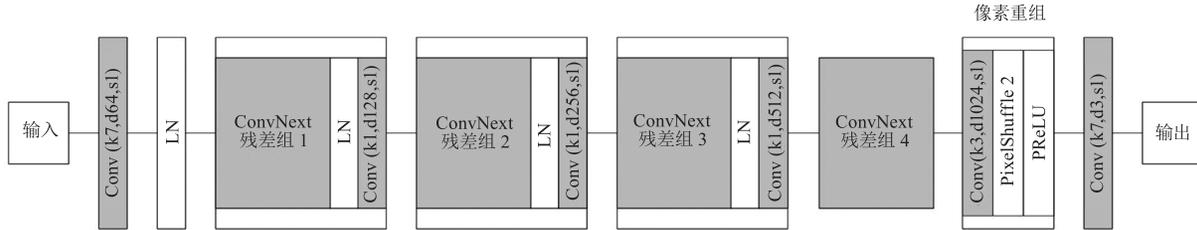


图 4 SRGANx 生成器网络结构

Fig.4 The network structure of generator of SRGANx

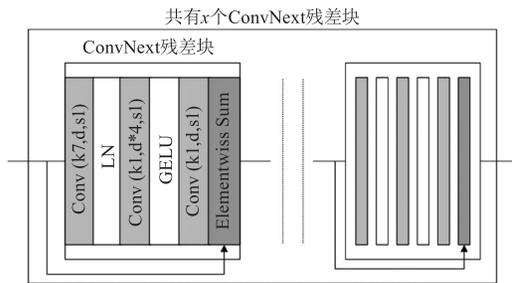


图 5 ConvNeXt 残差组内的 ConvNeXt 残差块连接方式
Fig.5 The connection mode of ConvNeXt residual block with
in ConvNeXt residual group

ConvNeXt 融合了 Transformer 和残差思想, 保留了 Transformer 的注意力机制元素, 这有助于模型聚焦于输入中的重要特征, 从而提高梯度传播效率, 同时层归一化 Layer Norm 的引入保持了数据分布的一致性, 有助于梯度的稳定传播, 所以在设计 SRGANx 生成器时取消总的跳跃连接, 解决了图像在模型运算前后通道不同的问题。

2.3 基于二维离散小波变换的图像融合

本文使用二维离散小波变换对图像进行细节提取和融合操作, 基本变换过程如图 6 所示。

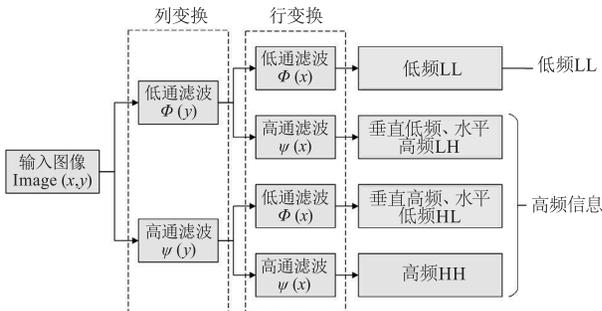


图 6 图像的二维离散小波变换过程

Fig.6 2D discrete wavelet transform process of an image

在一次二维离散小波变换过程中, 图像分别经过一次列变换和行变换, 得到 4 个分辨率为原来 1/2 的分量, 分别是原始图像的低频分量 (LL) 以及垂直方向 (LH)、水平方向 (HL) 和对角方向 (HH) 上的高频分量, 其中高频分量保留了图像的细节特征^[13]。

本文使用 haar 小波函数及其尺度函数构建二维尺度函数和二维小波函数对初始超分辨图像 I_{SR1} 进行分解。

haar 小波函数 $h(t)$:

$$h(t) = \begin{cases} 1, & 0 \leq t < 0.5 \\ -1, & 0.5 \leq t < 1 \\ 0, & \text{其他} \end{cases} \quad (3)$$

$$h_{j,k}(t) = h(2^j t - k), k = 0, 1, \dots, 2^j - 1$$

haar 尺度函数 $\phi(t)$:

$$\phi(t) = \begin{cases} 1, & 0 \leq t < 1 \\ 0, & \text{其他} \end{cases}$$

$$\phi_{j,k}(t) = \phi(2^j t - k), k = 0, 1, \dots, 2^j - 1 \quad (4)$$

3 船舶红外偏振图像超分辨算法流程

本文以实现船舶红外偏振图像的超分辨为目的, 结合二维离散小波变换, 将超分辨得到的细节特征融合进原始图像, 进而同时实现图像的超分辨与细节增强。算法具体流程如下:

(1) 图像预处理: 使用非局部均值对采集到的船舶红外偏振图像进行滤波处理;

(2) 初始超分辨: 使用改进的 SRGAN 对原始图像 I_{LR} 进行超分辨, 得到初始超分辨图像 I_{SR1} ;

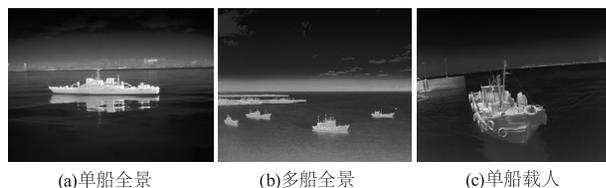
(3) 超分细节提取: 通过二维离散小波变换提取初始超分辨图像 I_{SR1} 中的高频细节信息 I_H ;

(4) 细节融合: 将缺少细节信息的低频分量 I_L 替换为原始图像 I_{LR} , 通过二维离散小波逆变换将高频细节信息 I_H 与原始图像 I_{LR} 进行融合, 得到最终的超分辨图像 I_{SR} ;

在图 1 中, 初始超分辨图像 I_{SR1} 经过一次二维离散小波变换, 得到分辨率降低 1/2 的低频信息 I_L 和 高频信息 I_H , 与原始图像 I_{LR} 的分辨率相同, 因此可以用原始图像 I_{LR} 来替换低频信息 I_L 做后续的逆变换融合; 相应的, 通过逆变换融合得到的最终的超分辨图像 I_{SR} 的分辨率会翻倍, 与初始超分辨图像 I_{SR1} 的分辨率相同, 这样, 就做到了使原始图像的细节增加的同时也实现了图像的超分辨。

4 实验及结果分析

本实验算法均在 PyCharm Community Edition 2022.2.3 中实现, 运行环境为 python 3.8, CUDA 11.6, pytorch 1.12.0。实验数据集来自艾瑞光电。如图 7 所示, 本文选取 3 幅船舶红外偏振图像作为源图像进行实验, 其中图 7(a) 代表单船全景, 图 7(b) 代表多船全景, 图 7(c) 代表单船载人, 共 3 种场景。



(a) 单船全景 (b) 多船全景 (c) 单船载人

图 7 实验用源图像

Fig. 7 Source images for experiments

4.1 消融实验

以图 7(a) 为例, 拍摄角度为侧面, 可以较为全面地观察到舰船的整体轮廓, 且目标的内部细节较为丰富, 可以检验本文算法改进前后的效率提升大小。

如图 8 为针对相同图像, 算法逐步改进的效果变化对比。图 8(b) 的结果为通过传统 SRGAN 得到的超分辨图像, 相比低分辨图像轮廓细节得到增强, 但是图中框出的部分显示舰船目标与海面背景的对比度不高, 舰船边缘轮廓不明显; 图 8(c) 的结果为只通过改进的 SRGANx 算法得到的超分辨图像, 相比与 SRGAN, 舰船的轮廓及内部细节得到增强; 图 8(d) 的结果为通过 SRGANx 和小波融合得到超分辨图像, 与图 8(c) 相比, 舰船边缘轮廓和内部细节得到进一步增强。

本单元采用峰值信噪比 (PSNR) 和结构相似性

(SSIM) 作为指标对算法的改进效果进行评价, 评价结果如表 1 所示。峰值信噪比 (PSNR) 由均方误差 (MSE) 决定, 设 I 为原始图像、 N 为 I 加上噪声的图像, 则均方误差为:

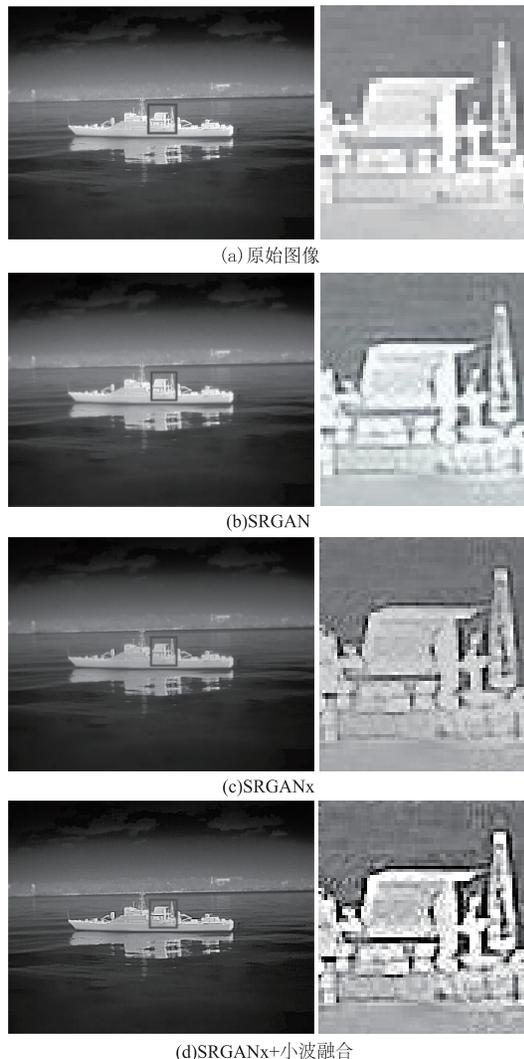


图 8 对原模型逐步改进的效果对比

Fig. 8 Comparison of effect for the improvement of the original model

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [I(i,j) - N(i,j)]^2 \quad (5)$$

由此得到峰值信噪比为:

$$PSNR = 10 \lg \left(\frac{MAX_I^2}{MSE} \right) = 20 \lg \left(\frac{MAX_I}{\sqrt{MSE}} \right) \quad (6)$$

其中, MAX 表示图像点颜色的最大数值。

结构相似性 (SSIM) 表示图像的失真程度, 即两张图像的相似程度, 公式表示为:

$$SSIM(x,y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (7)$$

其中, μ_x, μ_y 为两张图像像素的均值; σ_x, σ_y 为两张

图像像素的方差; σ_{xy} 为两张图像之间的协方差; C_1 、 C_2 为常数。

表1 对原模型逐步改进的指标对比

Tab. 1 Comparison of evaluation indexes for the improvement of the original model

算法	PSNR/dB	SSIM	时间/s
SRGAN	30.6744	0.8455	2.2834
SRGANx	31.8277	0.8473	1.7427
SRGANx + 小波融合	34.9477	0.8598	1.8653

从表1可以看出,对原模型的逐步改进使算法的PSNR和SSIM两项指标也逐步提升;对于运行时间,使用在相同训练集训练下得到的SRGANx模型,生成超分辨图像的时间低于SRGAN模型,但是由于小波变换需要消耗一定时间,所以在加入小波变换后总运行时间有小幅增加,但总时间仍小于传统SRGAN算法。

4.2 与其他算法比较分析

本文选取双立方插值(Bicubic)、超分辨率卷积神经网络(SRCNN)、生成对抗超分辨网络(SR-GAN)、文献[10]算法与本文算法进行增强效果对比,并计算不同情况下各个算法结果的峰值信噪比(PSNR)和结构相似性(SSIM)。各个超分辨算法结果如图9所示。

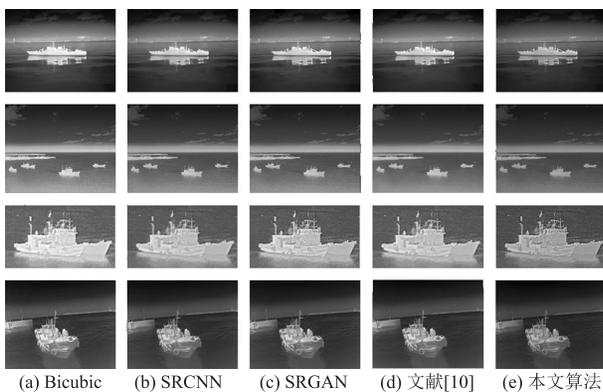


图9 不同超分辨算法效果对比

Fig. 9 Comparison of different super-resolution algorithm

图9中第1、2、4行分别为单船全景、多船全景、单船载人三种情况下的超分辨重建效果,第3行为多船全景情况下的局部放大效果图。可以观察到: Bicubic算法使用插值的方法对图像每个像素进行相同的计算,导致图像中存在细小密集的网格,如图9第3行局部放大效果图所示,得到的结果无法突出船舶目标及其细节信息; SRCNN算法由卷积神经

网络构成,相比插值细节更加丰富; SRGAN算法运用对抗思想,使得到的重建结果更加真实,但是对细节的还原不明显; 文献[10]与本文算法效果相近,但是文献[10]需要构建两个不同的生成器分别训练,并且数据集制作过程复杂; 本文算法在SRGAN的基础上进行改进,只需训练一个生成器并且无需对数据集进行预处理,同时加入小波变换对细节进行加强,在真实的基础上更好地还原了细节信息,图像更加接近原图像的纹理。

不同情况下各个算法结果的评价指标如表2所示。

表2 不同情况下每个算法结果的评价指标

Tab. 2 Evaluation index of the results of each algorithm under different conditions

情况	算法	PSNR/dB	SSIM
单船全景	Bicubic	24.4595	0.5975
	SRCNN	33.3315	0.7854
	SRGAN	31.6744	0.7246
	文献[10]	33.5914	0.8051
	本文算法	34.6524	0.8598
多船全景	Bicubic	23.4008	0.4911
	SRCNN	34.2952	0.7656
	SRGAN	33.7737	0.7414
	文献[10]	35.1495	0.7954
	本文算法	36.5819	0.8394
单船载人	Bicubic	25.2211	0.6337
	SRCNN	31.5658	0.8350
	SRGAN	31.1159	0.8223
	文献[10]	31.8403	0.8523
	本文算法	32.4956	0.8598

通过观察表2可以发现,在三种情况下,本文算法在指标上均有提升,且均优于文献[10]算法; 其中单船全景和多船全景两种情况有明显提升; 对于单船全景和单船载人两种情况,虽然两者都是全景图像,但是后者拍摄对象是渔船,无论是船体还是人体细节都过于复杂,结果显示后者指标提升幅度较小。

根据实验结果,本文算法在处理渔船载人这类复杂对象时性能提升效果不明显,可能是因为SRGANx生成器在设计时为了解决前后通道不一致的问题取消了总的跳跃连接,虽然在内部结构上加以

改进可以稳定梯度的传递,但这些改进可能仍不如保留总的跳跃连接效果更好,可以考虑在后续的研究中通过一些方法尝试保留总的跳跃连接以增加算法处理复杂对象时的效果提升幅度。

5 结 语

本文针对在采集海面背景下的船舶红外偏振图像时,得到的图像分辨率降低、细节信息确实的问题,提出一种生成对抗网络与小波变换结合的图像超分辨率方法。使用 ConvNeXt 残差块结构,替换传统 SRGAN 生成器中的 ResNet 残差块,只对生成器结构进行改进,不增加生成器的数量,避免了复杂的网络训练;利用小波变换提取超分辨率图像的细节信息,再通过逆变换将细节信息融合进原始船舶红外偏振图像,利用小波变换的特性实现细节融合与超分辨率的同时进行。通过本文算法重建的高分图像既包含原始图像的红外偏振信息,又包含超分辨率图像的细节信息,三种情况下的船舶红外偏振图像的峰值信噪比、结构相似性指标均有提升,为解决后续海面背景下的船舶目标检测之前的图像预处理方法提供了新思路。

参考文献:

- [1] Cui Juan. Application of infrared polarization imaging technology in shiptarget detection[J]. Ship Science and Technology, 2020, 42(18): 82-84. (in Chinese)
崔娟. 红外偏振成像技术在船舶目标探测中的应用[J]. 舰船科学技术, 2020, 42(18): 82-84.
- [2] Cao Bangqi. Research on image super-resolution in real scenes[D]. Chengdu: University of Electronic Science and Technology of China, 2023. (in Chinese)
曹邦琪. 真实场景下的图像超分辨率重建方法研究[D]. 成都: 电子科技大学, 2023.
- [3] Khaledyan D, Amirany A, Jafari K, et al. Low-cost implementation of bilinear and bicubic image interpolation for real-time image super-resolution[C]//2020 IEEE Global Humanitarian Technology Conference (GHTC). IEEE, 2020: 1-5.
- [4] Dong C, Loy C C, He K, et al. Learning a deep convolutional network for image super-resolution[C]//Computer Vision-ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014.
- [5] Li Jie. Optimization algorithm of image super-resolution reconstruction based on learning[D]. Chengdu: University of Electronic Science and Technology of China, 2022. (in Chinese)
李劫. 基于学习的图像超分辨率重建优化算法研究[D]. 成都: 电子科技大学, 2022.
- [6] Kim J, Lee J K, Lee K M. Deeply-recursive convolutional network for image super-resolution[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1637-1645.
- [7] Creswell A, White T, Dumoulin V, et al. Generative adversarial networks: an overview[J]. IEEE signal processing magazine, 2018, 35(1): 53-65.
- [8] Ledig C, Theis L, Huszár F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4681-4690.
- [9] Shaham T R, Dekel T, Michaeli T. Singan: Learning a generative model from a single natural image[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 4570-4580.
- [10] Wu Haobo. Research on super-resolution image reconstruction algorithms based on generative adversarial networks[D]. Xi'an: Xi'an University, 2021. (in Chinese)
吴浩博. 基于生成对抗网络的图像超分辨率重建算法研究[D]. 西安: 西安电子科技大学, 2021.
- [11] Li Peiyu, Zhang Yali. Face image super-resolution reconstruction based on improved SRGAN Model[J]. Computer Engineering, 2023, 49(4): 199-205. (in Chinese)
李培育, 张雅丽. 基于改进 SRGAN 模型的人脸图像超分辨率重建[J]. 计算机工程, 2023, 49(4): 199-205.
- [12] Liu Z, Mao H, Wu C Y, et al. A convnet for the 2020s[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 11976-11986.
- [13] Zhang Yuchen, Li Jianguo. Polarization image fusion based on wavelet transform[J]. Laser & Infrared, 2020, 50(5): 578-582. (in Chinese)
张雨晨, 李江勇. 基于小波变换的中波红外偏振图像融合[J]. 激光与红外, 2020, 50(5): 578-582.