

文章编号 1004-924X(2023)14-2080-13

融合边缘增强与非局部模块的遥感图像超分辨率重建生成对抗网络

刘 杰^{1*}, 祁 箬¹, 韩 轲²

(1. 哈尔滨理工大学 测控技术与通信工程学院, 黑龙江 哈尔滨 150080;

2. 哈尔滨商业大学 计算机与信息工程学院, 黑龙江 哈尔滨 150028)

摘要:针对遥感图像成像过程中噪声污染严重,超分辨率重建图像存在目标边缘模糊和伪影等问题,本文提出一种融合边缘增强与非局部模块的遥感图像超分辨率算法(Edge-Enhanced and Non-local Modules Generative Adversarial Network, ENGAN)。为了使图像细节边缘更清晰,本文融合一种图像边缘增强模块;同时,为进一步扩大模型感受野和增强去除边缘噪声性能,改进边缘增强模块中的Mask分支;此外,引入非局部模块,通过更好地利用图像的内在特征相关性,进一步提升了网络的重建性能。本文在UCAS-AOD和NWPU VHR-10两种遥感图像数据集上进行多个算法的对比实验,结果表明本文提出的方法在多个评价指标上均有所改善。以退化类型IV为例,本文方法相比深度盲超分辨率退化模型,4倍超分辨率的SSIM提升了0.068,PSNR提升了1.400 dB, RMSE减少了12.5%,且重建后的遥感图像相较于原始图像可以得到更好的地面目标检测结果。

关键词:遥感图像;超分辨率;边缘增强;非局部特征;生成对抗网络

中图分类号:TP391 文献标识码:A doi:10.37188/OPE.20233114.2080

Generate adversarial network for super-resolution reconstruction of remote sensing images by fusing edge enhancement and non-local modules

LIU Jie^{1*}, QI Ruo¹, HAN Ke²

(1. College of Measurement and Control Technology and Communication Engineering,
Harbin University of Science and Technology, Harbin 150080, China;

2. School of Computer and Information Engineering, Harbin University of Commerce,
Harbin 150028, China)

* Corresponding author, E-mail: liujie@hrbust.edu.cn

Abstract: To address the serious noise pollution in the process of image remote sensing and the existence of object edge blur and artifacts in the super-resolution reconstructed image, this study proposes a remote sensing image super-resolution algorithm called edge-enhanced and non-local modules generative adversarial network (ENGAN). To make the image edge details clearer, the proposed algorithm integrated an image edge enhancement module. To further expand the receptive field of the model and enhance the edge

收稿日期:2022-07-30;修订日期:2022-10-30.

基金项目:黑龙江省自然科学基金资助项目(No. LH2020F009)

noise removal, the Mask branch in the edge enhancement module was simultaneously improved. The use of the intrinsic feature correlation of images further improved the reconstruction performance of the network. In this study, comparison experiments of multiple algorithms were performed on two remote sensing image datasets, UCAS-AOD and NWPU VHR-10. The proposed method showed improvement in multiple evaluation indicators. Taking degradation type IV as an example, the 4x super-resolution SSIM was increased by 0.068, PSNR increased by 1.400 dB, and RMSE reduced by 12.5% compared with the deep-blind super-resolution degradation model. Moreover, the reconstructed remote sensing image can obtain better ground target detection results than the original image.

Key words: remote sensing image; super-resolution; edge enhancement; non-local features; generative adversarial network

1 引言

卫星遥感图像包含大量的地物信息,广泛用于土地覆盖分类、军事目标打击和城市经济水平评估等领域^[1]。分辨率是衡量遥感图像信息量的重要指标之一,高分辨率(High Resolution, HR)图像可以反映出更多的信息^[2]。然而,由于遥感图像成像过程相对复杂,以及硬件和工艺成本的限制,直接观测到的图像分辨率往往不能满足需求^[3];此外,高分辨率图像传输也相对困难。因此,遥感图像超分辨率(Super Resolution, SR)的目标是在低分辨率(Low Resolution, LR)遥感图像数据基础上,运用图像处理技术重建出高分辨率(High Resolution, HR)遥感图像^[4]。近年来,基于深度学习的方法在图像超分辨率领域取得了显著的成果^[5],可大致分为两类,基于卷积神经网络(Convolutional Neural Network, CNN)的方法与基于生成对抗网络(Generative Adversarial Network, GAN)的方法。其中基于卷积神经网络的方法:Dong等人^[6]提出SRCNN(Super Resolution CNN)首次使用卷积神经网络进行超分辨率重建;蔡体健等人^[7]提出一种通道注意力与残差级联超分辨率重构网络(Channel Attention and Residual Concatenation Network, CARCN),充分利用LR图像特征信息同时提升了网络对细节纹理的恢复能力;刘雪岩等人^[8]通过整合通道注意力机制,提高了光场腹腔镜四维成像的分辨率,间接地提高了光场腹腔镜的标定精度;耿铭昆等人^[9]提出一种轻量化残差递归空间遥感图像

超分辨率网络模型,在保证重建效果的同时降低网络参数量。基于生成对抗网络的方法:Wang等人^[10]的(Enhanced Super Resolution GAN, ESRGAN)通过引入残差密集块作为基本的网络单元,使重建图像纹理更加真实和自然;Ji等人^[11]的(Real-World Super-Resolution, RealSR)设计了一种真实图像退化框架,从而获得与真实图像共享一个域的LR图像;Xu等人^[12]提出的TE-SAGAN(Self-Attention and Texture Enhancement GAN)通过引入自注意力机制及纹理损失,改善重建图像的纹理细节;Wang等人^[13]提出的Real-ESRGAN(Real-World Enhanced Super-Resolution GAN)引入了一个高阶退化模型,以更好的模拟复杂的现实退化,同时考虑了合成过程中常见的振铃和超调伪影;Zhang等人^[14]通过使每个退化因素(即模糊、降采样和噪声)更加复杂和实用,并引入随机洗牌策略,提出一种深度盲超分辨率退化模型(Deep Blind Super-Resolution GAN, BSRGAN)。

遥感图像与同尺寸的常规图像相比,包含更丰富的外部轮廓、内部纹理等表征地物空间关系的信息,需要能够准确地恢复和刻画轮廓及内部纹理的算法。基于CNN的超分辨率技术相较于传统方法取得了更高的峰值信噪比,但得到的超分辨率图像过于平滑,边缘模糊,在大尺度因子下缺陷更为明显。基于GAN的方法重建图像的纹理细节更丰富,但这些方法用于遥感图像重建时,边缘细节仍不清晰,生成的图像中存

在一些伪影。同时现有的一些方法没有考虑全局空间连通性和纹理细化,导致全局遥感信息利用不足。为了获取边缘清晰、细节更丰富的遥感图像,本文提出一种融合边缘增强与非局部模块的遥感图像超分辨率重建生成对抗网络:

(1)融合一种边缘信息增强网络,并引入图像一致性损失改进边缘信息的重构;

(2)改进网络上采样方式为亚像素卷积,同时进一步改进边缘增强模块中的Mask分支用于扩大模型感受野;

(3)引入一种区域级非局部信息块,使网络能够更好地利用远距离像素间的依赖关系,充分挖掘图像自身信息,更好地重建遥感图像。

2 算法研究

2.1 GAN原理

GAN是Ledig等人^[15]提出的一种无监督学习模型,由生成器(Generator, G)和鉴别器(Discriminator, D)两个部分组成,采用了“博弈论”的思想。生成器负责学习真实数据分布特征,生成与真实数据相似的数据。鉴别器则通过不断的学习和优化来提高区分真实数据与生成数据的能力。GAN在训练过程中交替最小化公式(1)与公式(2)的值:

$$L_D = -E_I[\log D(I)] - E_x[\log(1 - D(G(x)))], \quad (1)$$

$$L_G = -E_x[\log D(G(x))], \quad (2)$$

其中: I 为原始高分辨率图像, $G(x)$ 为生成图像。




图1 ENGAN算法整体框架

Fig. 1 Overall framework of ENGAN algorithm

2.2 ENGAN模型

本文以BSRGAN为基线模型,设计一种基于边缘增强与非局部模块的遥感图像超分辨率方法(Edge-Enhanced and Nonlocal Modules Generative Adversarial Network, ENGAN),实现4倍因子的遥感图像超分辨率重建,整体框架如图1所示。在BSRGAN基础上融合边缘增强网络(Edge-Enhanced Network, EEN)并改

进mask分支,同时改进重建网络SRNet,引入非局部模块。退化网络用于生成LR图像,SRNet生成中间超分辨率图像 I_{Base} ,EEN提取 I_{Base} 的边缘信息进行增强。最后,用增强后的边缘信息替换 I_{Base} 中带有噪声和伪影的边缘信息得到最终超分辨率图像 I_{HR} 。鉴别器以基线模型BSRGAN中谱归一化的U-Net鉴别器^[16]为基础构建。

2.2.1 边缘提取与增强

现有的一些用于边缘增强的方法通过 CNN 模型近似滤波器来提取和保持图像边缘^[17-18],这些方法的目的是保留重要的结构和去除细节,不能准确地估计重建图像的边缘。为了解决这个问题,本文在 BSRGAN 模型基础上融合了一种

边缘增强网络 EEN,其中包含两个分支:(1)残差密集连接 (Residual-in-Residual Dense Connections, RRDC) 分支,用于提取边缘映射;(2) Mask 分支,用于自适应学习特定权重矩阵,聚焦真实边缘信息,达到去除噪声的目的。EEN 网络结构如图 2 所示。




图 2 边缘增强网络

Fig. 2 Edge-Enhanced Network

SRNet 生成中间超分辨率图像 I_{Base} , 经过 Laplacian 算子^[19]提取图像边缘信息, 图像在二阶导数之后在边缘处产生一个陡峭的零交叉点, 采用 $([-1, -1, -1], [-1, 8, -1], [-1, -1, -1])$ 的卷积核, Laplacian 算子边缘提取过程表示为式(3):

$$E(x, y) = L(x, y) \otimes I(x, y), \quad (3)$$

其中: $L(x, y)$ 为离散卷积掩码, $E(x, y)$ 为提取到的边缘映射, $\otimes$ 为卷积运算符。

经过 Laplacian 算子提取的图像边缘信息, 采用跨步卷积提取边缘映射, 并将其转换至 LR 空间。转换后的特征通过 Mask 分支对图像掩码进行学习, 对边缘提取过程中产生的虚假边缘点进行检测和清理。残差密集连接分支由与基线网络中相同的 RRDB 基本块组成。上采样运算将增强后的边缘映射到 HR 空间。这个过程可以用公式(4)表示:

$$I_{Edge}^* = S(F(D(I_{Edge})) \otimes M(D(I_{Edge}))), \quad (4)$$

其中: $D(\cdot)$ 为跨步卷积下采样, $F(\cdot)$ 为残差密集连接分支运算, $M(\cdot)$ 表示 Mask 分支, $S(\cdot)$ 表示上采样。

最后, 将增强后的边缘 I_{Edge}^* 替换掉中间超分辨率图像 I_{Base} 中提取的带有噪声的边缘 I_{Edge} , 获得最终超分辨率图像 I_{HR} 。

模型中上采样方式的不同会影响重建图像的质量。考虑图像亚像素级的影响, 本文方法将 SRNet 与 EEN 中的最近邻上采样方式替换为亚像素卷积, 从而优化传统插值方法中存在的不足, 获得更好的重建结果。

2.2.2 Mask 分支

边缘增强模块中的原 Mask 分支结构相对简单, 无法把握更大范围的信息。本文进一步改进了 Mask 分支, 用于增大模型感受野从而获得更复杂的注意力图。改进前后的 Mask 分支结构如图 3 所示。为了尽可能地保留图像更多的细节信息, 采用跨步卷积和亚像素卷积的操作。跨步卷




图3 改进前后的Mask分支

Fig. 3 Mask branch before and after improvement

积增加1个基本块的感受野大小,随后经过2个基本块,缩小后的特征图通过亚像素卷积进行扩

展,再通过1个基本块和一个 1×1 的卷积层转换放大后的特征,最后通过sigmoid层将输出值归一化至 $[0,1]$ 。采用简化的剩余块RB Block作为基本块^[20]。

2.2.3 非局部块

卷积运算每次处理一个局部邻域,为了减少局部限制,一些基于非局部均值滤波的方法^[21-23]在整个LR图像上全局搜索相似的像素,即计算图像中所有像素的加权值,使距离较远的像素同时响应一个位置。本文在SRNet前后各引入一个区域级非局部模块 (Region-Level Non-Local module, RL-NL),如图4所示。非局部操作可以从整体图像中总结相关特征,非局部运算表示为式(5):

$$y_i = \frac{1}{\sum_{j_j} f(x_i, x_j)} \sum_{j_j} f(x_i, x_j) g(x_j), \quad (5)$$

其中: i 为输出特征位置索引, j 为列举所有可能位置的索引。 x 和 y 是非局部操作的输入和输出。成对函数 $f(x_i, x_j)$ 计算 x_i 和 x_j 之间的关系。函数 $g(x_j)$ 计算在位置 j 处输入的代表。

采用嵌入式高斯函数来评估两两关系,计算嵌入空间中的相似度,表示为公式(6):

$$f(x_i, x_j) = \exp((W_\theta x_i)^T W_\phi x_j), \quad (6)$$

式中: W_θ 和 W_ϕ 为权重矩阵。考虑线性嵌入形式的 $g: g(x_j) = W_g x_j$,非局部块的整体过程可表示为式(7):

$$z_i = W_z y_i + x_i, \quad (7)$$

式中: y 在式(5)中给出, W_z 为权重矩阵,“ $+x_i$ ”表示剩余连接。整体结构如图5所示。

然而,传统的全局非局部操作会大大增加计算负担,对于图像超分辨率任务,适当的邻域大




图4 SR网络框架

Fig. 4 SR network framework




图 5 非局部模块

Fig. 5 Non-local module

小的非局部操作是非常可取的^[24]。因此,将特征图划分为 2×2 的区域网格,每个块经过非局部运算后,特征表示被非局部增强,然后根据特征空间相关性将其送入后续层。

2.2.4 损失函数

损失函数度量网络模型生成的 I_{Base} 或 I_{HR} 图像和用于训练的 HR 图像之间的差异。为了获得边缘轮廓更清晰、风格更一致的结果,网络训练过程中在 L_1 像素损失、感知损失 L_{percep} ,以及对抗损失 L_{adv} 的基础上引入图像一致性损失 L_{cons} ,模型总体损失表示为公式(8):

$$L_{\text{G,een}} = \lambda_1 L_1 + \lambda_2 L_{\text{percep}} + \lambda_3 L_{\text{adv}} + \lambda_4 L_{\text{cons}}, \quad (8)$$

式中, $\lambda_1, \lambda_2, \lambda_3, \lambda_4$ 分别代表不同损失的权重参数。根据 3.4 中的实验结果设置 $\lambda_1=1, \lambda_2=1, \lambda_3=0.001, \lambda_4=5$ 。

图像一致性损失 L_{cons} 为图 2 中 I_{HR} 与 HR 图像之间的 Charbonnier 损失^[25], Charbonnier 损失相较于 L_1 损失更加稳定,能够处理训练过程中出现的异常值,提高重建精度。同时,为了抑制遥感图像超分辨过程中可能出现的边缘畸变,本文考虑引入边缘一致性损失 $L_{\text{edge_cons}}$,即计算从高分辨率图像中提取的边缘 $I_{\text{edge_HR}}$ 与图 2 中增强后的边缘 I_{edge} 之间的 Charbonnier 损失。通过 3.4 中的实验发现 $L_{\text{edge_cons}}$ 会引入不同程度的噪声,因此训练过程中仅引入图像一致性损失 L_{cons} ,上述过程可以表示为公式(9)和公式(10):

$$L_{\text{cons}}(\theta_G) = \rho(HR - I_{\text{HR}}), \quad (9)$$

$$L_{\text{edge_cons}} = \rho(I_{\text{edge_HR}} - I_{\text{edge}}^*), \quad (10)$$

式中, $\rho(\cdot)$ 是 Charbonnier 惩罚函数。

3 实验与分析

3.1 实验数据

本文采用 UCAS-AOD 和 NWPU VHR-10 两个遥感图像数据集进行训练和评估。NWPU VHR-10 数据集包含 800 张高分辨率的卫星图像,其中 650 张带有目标的图像,150 张背景图像,目标种类有 10 类。UCAS-AOD 数据集包含 2 420 张高分辨率卫星图像,其中包含 1 510 张带有目标的图像,910 张背景图像。在两个数据集中随机选取 160 张作为测试集,其余作为训练集。

现有的图像超分辨率研究工作大多采用理想的双三次下采样核来获取 LR 图像,然而,真实世界中存在的图像往往包含复杂的模糊和噪声退化,图像的退化过程可以表示为公式(11):

$$I_{\text{LR}} = D(x) = [(y \otimes k) \downarrow_s + n]_{\text{JPEG}}, \quad (11)$$

其中: k 为模糊核, $\downarrow_s$ 为下采样, n 为添加的噪声, JPEG 为真实图像中广泛存在的 JPEG 压缩。为了更加全面的验证本文提出的方法的优越性,测试集设置了四种不同的降解类型。类型 I: 仅设置采样因子为 4 的双三次下采样,不添加 k, n 和 JPEG 压缩项;类型 II: 设置采样因子为 4 的最近邻下采样, k 为各向异性高斯模糊核,不添加 n 与 JPEG 压缩;类型 III: 设置最近邻下采样比例为 2, 结合比例为 2 的双三次下采样,质量因子为 [41, 90] 的 JPEG 压缩, k 为各向异性高斯模糊核;类型 IV: 随机选取不同类型的模糊核 k 、下采样类型和噪声 n , 并进行随机洗牌。

3.2 实验细节

本文的实验环境为 12 GB NVIDIA GeForce RTX 3080 Ti GPU, 深度学习的框架为 Pytorch。首先训练一个仅包含生成器且具有 L_1 损失和 L_{cons} 损失的预训练模型为 ENNet, 再以此为基准训练最终的 ENGAN 模型。在训练过程中, 本文将图像裁剪为 320×320 的图像块, 放大因子设置为 4, batch size 为 4, ENNet 模型预训练的初始学习率为 0.000 1, iters 为 100 000, ENGAN 模型的初始学习率为 0.000 05, iter 为 100 000, 并采用 Adam 优化器。

评价重建效果采用的评价方式包含图像结构相似度^[26] (Structural Similarity Index Mea-

sure, SSIM)、峰值信噪比^[27] (Peak Signal to Noise Ratio, PSNR)和均方根误差(Root Mean Square Error, RMSE),其中,SSIM与PSNR值越大、RMSE值越小代表图像重建质量越好,同时采用人类视觉感知判别图像质量的优劣作为主观评价。此外,考虑到遥感图像后续通常用于地面目标检测任务,本文采用了目标检测结果的平均精度(mAP)来验证该方法的有效性。

3.3 不同算法对比

为了客观地分析本文提出算法的性能,在UCAS-AOD和NWPU VHR-10两个遥感图像数据集上分别对比了Bicubic,ESRGAN,RealSR,Real-ESRGAN和BSRGAN五种算法,ESRGAN,RealSR,Real-ESRGAN和BSRGAN为图像超分辨率领域经典算法或目前性能领先的算法,对不同的算法进行分组测试得到如表1所示的量化结果,表中加粗代表最优的结果,下划

线代表次优的结果。由表1可以得出以下结论:首先在类型I测试集上,ESRGAN取得了次优的PSNR结果,因为训练过程中采用双三次下采样降解,但网络不能很好地抑制对抗训练产生的噪声。其次,在类型II与类型III测试集上,RealSR由于引入了真实图像退化框架,整体结果优于ESRGAN,Real-ESRGAN由于存在高阶退化模型以及采用sinc滤波器模拟常见的振铃和超调伪影,在大部分类型测试集上获得了次优的结果。最后,在类型IV测试集上,几种算法的效果都有严重下降,而ENGAN算法得益于本文的改进方法及基线模型中的退化网络,得到了所有类型测试集的最优结果。同时相比于基线模型BSRGAN,在两种数据集不同退化类型的多个评价指标均有所提升。以类型IV为例,SSIM提升了0.068,PSNR提升了1.400 dB, RMSE提升了2.473。实验结果验证了本文提出的算法在遥感图像数据集上的有效性和优越性。

表 1 不同方法实验结果对比

Tab. 1 Comparison of experimental results of different methods

退化类型	指标	Bicubic	ESRGAN	RealSR	Real-ESRGAN	BSRGAN	ENGAN(Ours)
Type I	SSIM	0.814	0.765	0.758	<u>0.790</u>	0.766	0.793
	PSNR	27.511	<u>26.362</u>	25.587	<u>25.847</u>	25.591	26.800
	RMSE	12.141	14.833	14.725	<u>14.335</u>	14.538	12.851
Type II	SSIM	0.759	0.682	0.690	<u>0.736</u>	0.704	0.737
	PSNR	25.899	23.967	24.005	<u>24.464</u>	24.086	26.114
	RMSE	14.624	18.062	17.994	<u>17.071</u>	17.504	15.603
Type III	SSIM	0.755	0.701	0.724	<u>0.748</u>	0.732	0.769
	PSNR	26.427	24.093	24.251	<u>25.361</u>	25.194	26.404
	RMSE	13.799	17.739	17.232	15.338	<u>15.335</u>	13.563
Type IV	SSIM	0.547	0.473	0.495	<u>0.569</u>	0.557	0.625
	PSNR	23.512	22.164	22.496	<u>23.240</u>	23.110	24.510
	RMSE	19.098	20.108	19.933	<u>19.627</u>	19.738	17.265

图6比较了不同方法的视觉效果,结果表明,传统的Bicubic方法不能产生额外的细节;ESRGAN的方法容易产生过多的伪影;RealSR无法消除退化;Real-ESRGAN的方法重建图像虽

然有较好的视觉感知效果,但存在边缘过于锐利的问题;BSRGAN方法恢复图像自然纹理不够清晰,本文提出的ENGAN模型可以较好地改善这些问题,且恢复图像更接近原始HR图像。



图6 视觉效果对比

Fig. 6 Visual effect comparison

3.4 消融实验

为了进一步验证本文提出ENGAN算法的有效性,进行消融实验,结果如表2所示。首先只引入边缘增强模块与图像一致性损失 L_{cons} ,模型表示为EGAN;在EGAN的基础上将模型中上采样方式改为亚像素卷积,模型表示为EGAN*,在EGAN*的基础上改进Mask分支,模型表示为EGAN**,最后引入非局部块,表示为最终模型ENGAN。根据表中的评价结果,本文提出的改进方案均在不同程度上提高了算法重建高分辨率图像的性能。

为了更好地验证边缘增强结构的有效性,同时测试引入的图像一致性损失 L_{cons} 的超参数 λ_4 对模块的影响,实验改变 λ_4 的值对EGAN模型进行对比试验,结果如表3所示。由表3可知,当 $\lambda_4=5$ 时,模型能够很好地平衡图像一致性损失与原始损失,对模型训练具有更好的监督效果。

为了抑制重建图像可能出现的边缘畸变,本文实验考虑边缘一致性损失 $L_{\text{edge_cons}}$,对引入不同超参数 λ_5 的 $L_{\text{edge_cons}}$ 的EGAN模型进行对比实验,结果如表4所示,视觉效果如图7所示。由表4和图7可知,引入 $L_{\text{edge_cons}}$ 虽然可以使重建图像边缘更加锐利,但同时也会引入不同程度的噪声从而降低图像质量。

本文方法由SRNet生成中间超分辨率图像 I_{Base} ,经过边缘增强得到 I_{HR} 。鉴别器将不同阶段图像的判别结果反馈给生成器 G 会对模型重建结果产生影响,实验探究了训练过程中U-Net鉴别器分别用于输出 I_{Base} 与 I_{HR} 图像的全局(整个图像)和局部(逐像素)反馈,即判断图像是否属于真实类或虚假类,对重建结果进行对比,实验结果如表5所示。可知当鉴别器用于输出中间超分辨率图像 I_{Base} 的反馈时,模型可以获得更好的SSIM,PSNR及RMSE结果。

表 2 算法消融实验

Tab. 2 Algorithm ablation experiments

退化类型	指标	BSRGAN	EGAN	EGAN ⁺	EGAN ⁺⁺	ENGAN
Type I	SSIM	0.766	0.774	0.784	<u>0.784</u>	0.793
	PSNR	25.591	26.625	26.742	<u>26.783</u>	26.800
	RMSE	14.538	13.147	12.986	<u>12.927</u>	12.851
Type II	SSIM	0.704	0.720	0.728	<u>0.730</u>	0.737
	PSNR	24.086	25.017	25.079	<u>25.163</u>	26.114
	RMSE	17.504	15.901	15.800	<u>15.678</u>	15.603
Type III	SSIM	0.732	0.751	0.758	<u>0.761</u>	0.769
	PSNR	25.194	26.225	26.327	<u>26.392</u>	26.404
	RMSE	15.335	13.864	13.715	<u>13.633</u>	13.563
Type IV	SSIM	0.557	0.620	0.622	<u>0.623</u>	0.625
	PSNR	23.110	24.363	24.397	<u>24.482</u>	24.510
	RMSE	19.738	17.332	<u>17.285</u>	17.322	17.265

表 3 不同 λ_4 结果对比

Tab. 3 Comparison of different λ_4 results

退化类型	指标	$\lambda_4=0.1$	$\lambda_4=0.5$	$\lambda_4=1$	$\lambda_4=2$	$\lambda_4=5$	$\lambda_4=7$	$\lambda_4=10$
Type I	SSIM	0.725	0.729	0.754	<u>0.760</u>	0.774	0.744	0.732
	PSNR	25.483	25.781	26.284	<u>26.441</u>	26.625	26.091	25.774
	RMSE	14.690	14.552	13.644	<u>13.411</u>	13.147	13.985	14.298
Type II	SSIM	0.673	0.678	0.705	<u>0.710</u>	0.720	0.698	0.679
	PSNR	23.813	23.906	24.912	<u>25.007</u>	25.017	24.402	23.920
	RMSE	17.977	17.820	16.056	<u>15.902</u>	15.901	16.101	17.782
Type III	SSIM	0.703	0.707	0.734	<u>0.738</u>	0.751	0.726	0.709
	PSNR	24.815	24.847	25.892	<u>26.014</u>	26.225	25.612	24.856
	RMSE	15.913	15.863	14.341	<u>14.158</u>	13.864	14.685	15.839
Type IV	SSIM	0.574	0.581	0.603	<u>0.610</u>	0.620	0.591	0.585
	PSNR	22.875	23.132	23.923	<u>24.140</u>	24.363	23.501	23.294
	RMSE	19.547	19.162	18.143	<u>17.747</u>	17.332	18.752	18.980

表 4 不同 λ_5 结果对比

Tab. 4 Comparison of different λ_5 results

退化类型	指标	$\lambda_5=0$	$\lambda_5=0.05$	$\lambda_5=0.1$	$\lambda_5=0.5$	$\lambda_5=1$	$\lambda_5=2$	$\lambda_5=5$	$\lambda_5=7$	$\lambda_5=10$
Type I	SSIM	0.774	0.735	0.739	0.733	0.734	0.739	<u>0.744</u>	0.729	0.703
	PSNR	26.625	25.180	25.385	25.373	25.381	25.685	<u>25.940</u>	25.391	24.752
	RMSE	13.147	15.372	15.525	15.440	15.412	15.372	<u>14.05</u>	15.503	16.002
Type II	SSIM	0.720	0.677	0.680	0.676	0.680	0.683	<u>0.693</u>	0.672	0.650
	PSNR	25.017	23.620	23.742	23.603	23.813	23.920	<u>24.605</u>	23.562	23.098
	RMSE	15.901	18.362	18.145	18.071	18.000	18.145	<u>16.522</u>	18.511	18.840
Type III	SSIM	0.751	0.702	0.706	0.703	0.707	0.711	<u>0.717</u>	0.698	0.677
	PSNR	26.225	24.506	24.763	24.582	24.808	24.820	<u>25.539</u>	24.491	23.706
	RMSE	13.864	16.179	15.962	16.098	15.940	16.920	<u>14.805</u>	16.997	17.959

续表 4 不同 λ_s 结果对比
Tab. 4 Comparison of different λ_s results

退化类型	指标	$\lambda_s=0$	$\lambda_s=0.05$	$\lambda_s=0.1$	$\lambda_s=0.5$	$\lambda_s=1$	$\lambda_s=2$	$\lambda_s=5$	$\lambda_s=7$	$\lambda_s=10$
Type IV	SSIM	0.620	0.533	0.535	0.532	0.537	0.542	0.579	0.561	0.542
	PSNR	24.363	22.590	22.709	33.504	22.850	23.006	23.783	23.485	22.954
	RMSE	17.332	20.522	20.445	20.571	20.301	19.809	18.337	18.901	19.733



图 7 引入边缘一致性损失 $L_{\text{edge_cons}}$ 对比图
Fig. 7 Comparison of $L_{\text{edge_cons}}$ with edge consistency loss

表 5 鉴别器用于不同阶段图像结果对比
Tab. 5 Discriminator used for the comparison of image results at different stages

退化类型	指标	判别 I_{Base}	判别 I_{HR}
Type I	SSIM	0.774	0.773
	PSNR	26.625	26.548
	RMSE	13.147	13.245
Type II	SSIM	0.720	0.719
	PSNR	25.017	24.981
	RMSE	15.901	15.950
Type III	SSIM	0.751	0.751
	PSNR	26.225	26.177
	RMSE	13.864	13.927
Type IV	SSIM	0.620	0.619
	PSNR	24.363	24.337
	RMSE	17.332	17.377

3.5 地面目标检测

为了验证本文提出的图像超分辨率算法对遥感图像后续地面目标检测的促进作用,实验采用 YOLOv5 目标检测模型分别对 NWPU VHR-10 数据集的 LR 图像与 SR 图像进行测试。采用 SR 图像作为训练集,本文的超分辨率方法在训练集和测试集均有应用。NWPU VHR-10 数据集目标包括飞机、舰船、油罐、棒球场、网球场、篮

球场、田径场、港口、桥梁和汽车共 10 类。该数据集包含 800 张图像,按照 7:1 比例随机划分为训练集和测试集。

YOLOv5 为单阶段目标检测算法,训练过程中,网络在初始锚框的基础上输出预测框,进而和真实标注框进行对比,计算两者差距,再反向更新迭代网络参数。实验采用平均检测精度 mAP,并计算预测框与真实标注框的交集/并集(IoU)来评估本文方法的有效性。通过计算精确率和召回率得到 AP,再对每个类的 AP 求均值得到 mAP。实验测试 IoU=0.5 与 IoU=0.5:0.95 (从 0.5 到 0.95,步长为 0.05)两种情况的 mAP 值,量化结果如表 6 所示。精确率(Precision)与召回率(Recall)分别表示为式(12)~式(13):

表 6 YOLOv5 检测结果
Tab. 6 YOLOv5 detection results

退化类型	LR		SR	
	mAP (IoU=0.5)	mAP (IoU=0.5:0.95)	mAP (IoU=0.5)	mAP (IoU=0.5:0.95)
Type I	0.683	0.382	0.683	0.383
Type II	0.671	0.362	0.685	0.370
Type III	0.530	0.291	0.633	0.351
Type IV	0.183	0.0885	0.338	0.188

$$\text{Precision} = \frac{|TP|}{|TP| + |FP|}, \quad (12)$$

$$\text{Recall} = \frac{|TP|}{|TP| + |FN|}, \quad (13)$$

其中: TP 为正确检测到的对象集合; FP 为错误检测到的对象集合; FN 为未被检测器检测到的对象集合。

图 8 展示了 YOLOv5 算法的检测结果。图 8(a) 中, 本文方法可以重建缺乏特征表达的小物体的判别信息, 扩大目标尺度, 获得更详细的信息, 使得目标更易于检测。图 8(b) 中通过提高图像的分辨率, 减少了网络中物体模糊对检测的干扰。结果表明, 本文提出的图像超分辨率方法可以有效提高遥感图像地面目标检测精度, 另外, 由于类型 I 中 LR 图像仅采用双三次下采样获得, 对地面目标没有模糊和噪声的影响, 所以 SR 图像检测结果提升不明显, 而在包含复杂退化的类型 III 和 IV 中 SR 图像检测结果有明显地提升, 这表明本文提出的算法可以很好地去除真实图像中广泛存在的噪声同时恢复锐利边缘, 在遥感图像领域具有很好的应用价值。

4 结 论


针对恢复高分辨率遥感图像结果不理想的问题, 本文提出了一种融合边缘增强与非局部块的遥感图像超分辨率重建方法。该方法的优势主要有两个方面: (1) 构建了含有边缘增强的遥感图像超分辨率重建网络, 同时改进 Mask 分支, 以端到端的方式学习图像的纹理和细节边缘;

参考文献:

- [1] 孙家柄, 舒宁, 关泽群. 遥感原理、方法和应用 [M]. 北京: 测绘出版社, 1997.
SUN J B, SHU N, GUAN Z Q. *Principle, Method and Application of Remote Sensing* [M]. Beijing: Sino Maps Press, 1997. (in Chinese)
- [2] 柏宇阳. 基于卷积神经网络的遥感图像超分辨率重建 [D]. 哈尔滨: 黑龙江大学, 2021.
BAI Y Y. *Super-Resolution Reconstruction of Remote Sensing Image Based on Convolutional Neural Network* [D]. Harbin: Helongjiang University, 2021. (in Chinese)



(a) 小目标图像
(a) Small target image



(b) 模糊目标图像
(b) Fuzzy target image

图 8 检测结果

Fig. 8 Test results

(2) 设计了一种结合非局部信息的生成网络, 进一步增强了网络提取全局目标特征的能力。实验结果表明, 与其他几种算法相比, 本文的方法在遥感图像数据集上的多个客观指标均有所提升, 以退化类型 IV 为例, 本文方法相比深度盲超分辨率退化模型, 4 倍超分辨率的 SSIM 提升了 0.068, PSNR 提升了 1.400 dB, RMSE 减少了 12.5%, 且具有更好的主观视觉效果。此外, 本文方法重建后的图像比原始图像更宜于进行地面目标检测。

在未来的研究中, 将考虑从退化核估计的角度研究如何减少重建高分辨率图像中存在的噪声污染, 以生成更高质量的遥感图像。

- [3] 唐艳秋, 潘泓, 朱亚平, 等. 图像超分辨率重建研究综述 [J]. 电子学报, 2020, 48(7): 1407-1420.
TANG Y Q, PAN H, ZHU Y P, *et al.* A survey of image super-resolution reconstruction [J]. *Acta Electronica Sinica*, 2020, 48(7): 1407-1420. (in Chinese)
- [4] 熊鹰飞. 基于生成对抗网络的多源跨区域遥感图像超分辨 [D]. 深圳: 中国科学院大学(中国科学院深圳先进技术研究院), 2021.
XIONG Y F. *Super-Resolution of Multi-Source and Cross-Regional Remote Sensing Images Based on Generative Countermeasure Network* [D]. Shen-

- zhen: Shenzhen Institutes of Advanced Technology, Chinese Academy of Sciences, 2021. (in Chinese)
- [5] 邵旻昊. 基于深度学习的遥感图像超分辨率重建算法研究[D]. 西安: 西安电子科技大学, 2021. SHAO M H. *Research on Super-Resolution Reconstruction Algorithm of Remote Sensing Image Based on Deep Learning* [D]. Xi'an: Xidian University, 2021. (in Chinese)
- [6] DONG C, LOY C C, HE K M, *et al.* *Learning a Deep Convolutional Network for Image Super-Resolution* [M]. Computer Vision - ECCV 2014. Cham: Springer International Publishing, 2014: 184-199.
- [7] 蔡体健, 彭潇雨, 石亚鹏, 等. 通道注意力与残差级联的图像超分辨率重建[J]. 光学精密工程, 2021, 29(1):142-151. CAI T J, PENG X Y, SHI Y P, *et al.* Channel attention and residual concatenation network for image super-resolution [J]. *Opt. Precision Eng.*, 2021, 29(1):142-151. (in Chinese)
- [8] 刘雪岩, 许聿达, 雷建昕, 等. 基于视差放大与超分辨率的三维光场腹腔镜标定[J]. 光学精密工程, 2022, 30(5):510-517. LIU X Y, XU Y D, LEI J X, *et al.* Three-dimensional light field endoscope calibration based on light field disparity amplifier and super-resolution network [J]. *Opt. Precision Eng.*, 2022, 30(5):510-517. (in Chinese)
- [9] 耿铭昆, 吴凡路, 王栋. 轻量化火星遥感影像超分辨率重建网络[J]. 光学精密工程, 2022, 30(12):1487-1498. GENG M K, WU F L, WANG D. Lightweight Mars remote sensing image super-resolution reconstruction network[J]. *Opt. Precision Eng.*, 2022, 30(12):1487-1498. (in Chinese)
- [10] WANG X T, YU K, WU S X, *et al.* *ESRGAN: Enhanced Super-Resolution Generative Adversarial Networks*[M]. Lecture Notes in Computer Science. Cham: Springer International Publishing, 2019: 63-79.
- [11] JI X Z, CAO Y, TAI Y, *et al.* Real-World Super-Resolution via Kernel Estimation and Noise Injection[C]. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. 14-19, 2020, Seattle, WA, USA. IEEE, 2020: 1914-1923.
- [12] XU Y Y, LUO W, HU A N, *et al.* TE-SA-GAN: an improved generative adversarial network for remote sensing super-resolution images[J]. *Remote Sensing*, 2022, 14(10): 2425.
- [13] WANG X T, XIE L B, DONG C, *et al.* Real-ESRGAN: Training Real-World Blind Super-Resolution with Pure Synthetic Data[C]. 2021 *IEEE/CVF International Conference on Computer Vision Workshops (ICCVW)*. 11-17, 2021, Montreal, BC, Canada. IEEE, 2021: 1905-1914.
- [14] ZHANG K, LIANG J Y, VAN GOOL L, *et al.* Designing a Practical Degradation Model for Deep Blind Image Super-Resolution [C]. 2021 *IEEE/CVF International Conference on Computer Vision (ICCV)*. 10-17, 2021, Montreal, QC, Canada. IEEE, 2022: 4771-4780.
- [15] LEDIG C, THEIS L, HUSZÁR F, *et al.* Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network [C]. 2017 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 21-26, 2017, Honolulu, HI, USA. IEEE, 2017: 105-114.
- [16] SCHÖNFELD E, SCHIELE B, KHOREVA A. A U-Net Based Discriminator for Generative Adversarial Networks[C]. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 13-19, 2020, Seattle, WA, USA. IEEE, 2020: 8204-8213.
- [17] XU L, REN J S J, YAN Q, *et al.* Deep edge-aware filters[J]. *32nd International Conference on Machine Learning, ICML 2015*, 2015, 2: 1669-1678.
- [18] LIU S F, PAN J S, YANG M H. *Learning Recursive Filters for Low-Level Vision via a Hybrid Neural Network*[M]. Computer Vision - ECCV 2016. Cham: Springer International Publishing, 2016: 560-576.
- [19] KAMGAR-PARSI B, KAMGAR-PARSI B, ROSENFELD A. Optimally isotropic Laplacian operator[J]. *IEEE Transactions on Image Processing*, 1999, 8(10): 1467-1472.
- [20] LAI W S, HUANG J B, AHUJA N, *et al.* Deep Laplacian Pyramid Networks for Fast and Accurate Super-Resolution [C]. 2017 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 21-26, 2017, Honolulu, HI, USA. IEEE, 2017: 5835-5843.

- [21] LIM B, SON S, KIM H, *et al.* Enhanced Deep Residual Networks for Single Image Super-Resolution[C]. 2017 *IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. 21-26, 2017, Honolulu, HI, USA. IEEE, 2017: 1132-1140.
- [22] 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 (CVPR'05)*. 20-25, 2005, San Diego, CA, USA. IEEE, 2005: 60-65.
- [23] DABOV K, FOI A, KATKOVNIK V, *et al.* Image denoising by sparse 3-D transform-domain collaborative filtering[J]. *IEEE Transactions on Image Processing: a Publication of the IEEE Signal Processing Society*, 2007, 16(8): 2080-2095.
- [24] WANG X L, GIRSHICK R, GUPTA A, *et al.* Non-Local Neural Networks [C]. 2018 *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 18-23, 2018, Salt Lake City, UT, USA. IEEE, 2018: 7794-7803.
- [25] DAI T, CAI J R, ZHANG Y B, *et al.* Second-Order Attention Network for Single Image Super-Resolution [C]. 2019 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 15-20, 2019, Long Beach, CA, USA. IEEE, 2020: 11057-11066.
- [26] WANG Z, BOVIK A C, SHEIKH H R, *et al.* Image quality assessment: from error visibility to structural similarity[J]. *IEEE Transactions on Image Processing: a Publication of the IEEE Signal Processing Society*, 2004, 13(4): 600-612.
- [27] YUAN F, HUANG L F, YAO Y. An Improved PSNR Algorithm for Objective Video Quality Evaluation [C]. 2007 *Chinese Control Conference*. 26-31, 2007, Zhangjiajie, China. IEEE, 2007: 376-380.

作者简介:



刘 杰(1980—),女,黑龙江齐齐哈尔人,副教授,硕士生导师,2002年于哈尔滨理工大学获得学士学位,2005年于哈尔滨工业大学获得硕士学位,2012年于哈尔滨理工大学获得博士学位,主要从事人工智能与图像处理、大数据模型及预测等方面的研究。E-mail: liujie@hrbust.edu.cn



祁 箬(1998—),女,河南新乡人,硕士研究生,2019年于河南工程学院获得学士学位,主要从事图像处理、深度学习等方面的研究。E-mail: qiruo123@163.com