

基于多注意力机制的生成对抗网络的遥感图像 超分重建^{*}

李宣韩^{1,2} 罗毅^{1,2} 赵俊^{1,2} 刘忠灵^{1,2} 王盛^{1,2}

(1. 人工智能四川省重点实验室 宜宾 644000; 2. 四川轻化工大学自动化与信息工程学院 宜宾 644000)

摘要:针对现有超分辨率算法重建后的遥感图像模糊,含有伪影和噪声等问题,提出一种基于多注意力机制的生成对抗网络。首先,在生成器的残差块中引入高效注意力机制,增强全局相关性,提高模型的特征提取能力;其次,利用迭代注意特征融合模块对输入的图像和经过生成器生成的高层语义特征图进行融合,代替长跳跃连接常用的相加操作,减少输入图像进行相加操作时导致的信息损失,使重建后的图像更加清晰;最后,基于 WGAN 网络优化模型训练,促进网络训练的稳定性,加快损失函数的收敛。在不同数据集上验证上述方法,结果表明,相较于优算法,所提方法在峰值信噪比(PSNR)和结构相似度(SSIM)上分别提高了 0.062~0.122 dB 和 0.03~0.08。

关键词:生成对抗网络;图像超分辨;高效注意力机制;迭代注意特征融合模块

中图分类号: TP751.2 **文献标识码:** A **国家标准学科分类代码:** 510.40

Super-resolution reconstruction of remote sensing images based on generative adversarial networks

Li Xuanhan^{1,2} Luo Yi^{1,2} Zhao Jun^{1,2} Liu Zhongling^{1,2} Wang Sheng^{1,2}

(1. Artificial Intelligence Key Laboratory of Sichuan Province, Yibin 644000, China; 2. School of Automation and Information Engineering, Sichuan University of Science and Engineering, Yibin 644000, China)

Abstract: Aiming at the problems of blurred remote sensing images containing artefacts and noise after reconstruction by existing super-resolution algorithms, a generative adversarial network based on multiple attention mechanisms is proposed. Firstly, an efficient channel attention is introduced into the residual block of the generator to enhance global correlation and improve the feature extraction capability of the model. Secondly, an iterative attention feature fusion module is used to fuse the input image and the high-level semantic feature map generated by the generator, replacing the common summing operation of long jump connections, reducing the information loss caused by the summing operation of the input image and making the reconstructed image clearer. Finally, the method is validated on different datasets, and the results show that the proposed method improves the peak signal to noise ratio (PSNR) and structural similarity ratio (SSIM) by 0.062~0.122 dB and 0.03~0.08, respectively, compared with the suboptimal algorithm.

Keywords: generative adversarial networks; image super-resolution; efficient channel attention; iterative attentional feature fusion

0 引言

随着航空航天事业的发展,无人机、卫星等设备被应用与遥感图像的获取,遥感图像拥有的大量信息也被广泛的运用到城市交通、生态检测、农业发展等其他领域。由

于自然因素,设备内部噪声等导致获取的图像清晰度差、细节信息丢失等问题不利于后续小目标检测等任务^[1-2]。因此,对遥感图像进行超分辨的研究具有重要的意义和价值。

由于深度学习的不断发展,基于学习的图像超分算法

收稿日期:2022-11-15

^{*} 基金项目:四川省科技计划(2020YFS0019)、四川轻化工大学研究生创新基金(y2021083)项目资助

方法优于传统的超分算法,利用多层的神经网络提取数据的高层抽象信息,该方法克服了传统算法的缺点^[3]。Dong等^[4]在2014年提出SRCNN,首次将深度学习应用到了图像超分重建领域中,相比传统的超分重建通过上采样放大图像的方式,SRCNN通过亚像素卷积层间接放大图像,提高了重建效率,但SRCNN生成图像过度平滑,丢失了较多的细节信息。Goodfellow等^[5-6]提出了生成对抗网络(generative adversarial network, GAN),生成器和判别器本质上都是函数,通常用深层神经网络来实现。Ledig等^[7]提出SRGAN将生成对抗网络用于图像超分重建,加入感知损失使重建后的图像和原始图像的分布更加相似,生成图像保留了更多的高频信息,但生成的图像含有大量伪影。Wang等^[8-9]提出ESRGAN和Real-ESRGAN,通过密集残差块构建深层次的神经网络,取消批量标准化层(BN)的使用,并利用先验信息改善感知损失,提高对图像纹理的恢复,但也导致生成的纹理不真实,纹理过度锐化。Liu等^[10]提出WGAN,使用Wasserstein距离代替JS散度去衡量两个分布之间的距离,解决了当判别器在最优情况下,生成损失函数梯度消失的问题。Ji等^[11]通过在SRCNN上应用CycleGAN的训练策略,绕过低分辨率图像和高分辨率图像对的要求,实现更高的通用性和适用性,降低了对遥感数据集的依赖。Jiang等^[12]提出EEGAN,通过边缘增强网络和超密集网络改进SRGAN网络,提高遥感图像的边缘信息。Lei等^[13]提出CDGAN,通过构建双通道网络提取特征,并构建了专用的损失函数,增强了判别器对遥感图像低频区域的判别能力。Ma等^[14]提出SPSR,在GAN的框架下设计了一个额外梯度的分支来预测超分辨率的梯度图,以提供额外的结构性先验,辅助超分重建。蔡非凡等^[15]提出基于空间金字塔的SPyGAN,通过改进SPYGAN的网络结构和损失函数,有效的提升了图像视觉质量和高频细节。

上述研究主要通过改进生成对抗网络结构中的残差模块,损失函数进行改进,采用不同的训练策略增强网络的训练能力,目前通过残差连接的超分算法忽略了对输入的低分辨率图像的利用,而采用特征融合的方式能有效地减少遥感图像信息量少,信息真假混杂的问题^[16]。

本文针对目前超分算法存在的问题,在SRGAN的基础上提出一种基于多注意力机制的生成对抗网络。首先在残差卷积块构成的生成器和判别器中引入高效注意力机制(ECA)增加全局相关性,提升对图像特征信息的提取。然后采用迭代注意特征融合模块代替长连接中的相加操作,将输入的不同尺度下的低分辨图像与生成图像融合,提高输入的低分辨遥感图像的利用率,降低残差网络中通过求和或拼接操作所带来的信息损失。最后依据WGAN网络优化模型训练,促进网络训练的稳定性。

1 生成对抗网络

生成对抗网络是由两个相互对抗的深度学习网络生

成器和判别器构成。GAN的灵感来源于博弈论,生成器和判别器通过相互竞争达到“纳什均衡”,如图1所示。生成器从训练数据中捕获数据分布,通过捕获的数据分布生成与其相同分布的生成数据,并期望判别器将生成数据判断为训练数据。判别器通过训练数据给出的标准,对生成数据进行判断,并将判断结果反馈给生成器,促进生成器生成更加接近训练数据的生成数据。通过这两个网络的相互博弈、相互竞争、相互对抗,不断的自我优化的目的,达到生成真实训练数据的目的,对抗网络的损失函数如下:

$$\min_G \max_D V(D, G) = E_{x \sim P_{data}(x)} [\log D(x)] + E_{z \sim P_g(z)} [\log(1 - D(G(z)))] \quad (1)$$

式中: x 表示输入网络的真实样本; E 表示输入真实样本的期望; $D(\cdot)$ 表示判别器的输出值; $G(\cdot)$ 表示生成器的输出值。




图1 生成对抗网络结构

2 基于多注意力机制的生成对抗网络构建

针对现有算法在遥感图像重建过程中的不足,提出一种基于多注意力机制的生成对抗网络。网络由生成网络和判别网络构成,如图2所示。首先通过生成器对低分辨率遥感图像进行重建,然后将重建后的生成图像与训练图




图2 基于多注意力机制的生成对抗网络

像输入判断器中进行判断,判断网络将判断的结果反馈给生成网络,最后若判断器能够分辨生成图像和训练图像,则促进生成网络生成接近训练图像分布的高分辨率图像,若无法分辨,则表明网络达到了“纳什均衡”。

2.1 生成器的构建

生成器是提取和重建图像的重要部分。主要由前残差块、残差块、后残差块、迭代注意特征融合模块(iterative attentional feature fusion, iAFF)^[17]、上采样块、最终的卷积层6个部分构成。前残差块包含一个2维卷积层,将输入图像通道数扩展成64通道数。残差块包含两个2维卷积层,一个BN层,并在每个卷积层的后面引入了ECA模块,通过ECA模块学习不同通道的相关性,引导模型对特征进行有区分度的加权学习,提高残差块对图像特征的提取。后残差块包含一个2维卷积层和一个BN层。iAFF模块利用两块MS-CAM模块对输入的低分辨率图像和生成图像进行特征融合,代替长跳连接中的相加操作所进行的初始层内的特征融合,提高对低分辨率图像内容信息的利用,增强网络对低分辨率图像重建的能力。上采样块采用两个子像素卷积模(Subpixel)^[18]进行像素清洗,子像素卷积将原始图像的通道数扩大,使得图像的尺寸变大,相比于其他的放大方式,能更好地拟合像素之间的关系。最终卷积层包含一个2维卷积层,降维成3通道的图像。其中,所有2维卷积层的卷积核大小为 3×3 ,除最终卷积层采用tanh作为激活函数外,残差块中都采用PReLU作为激活函数。

1) 迭代注意特征融合模块

为了减少低分辨遥感图像通过简单的融合方式如元素级相乘和元素级求和导致的图像信息损失。本文引入iAFF模块作为长跳跃连接中图像融合的方式。iAFF利用MS-CAM注意力机制实现网络模型对输入的中间特征图像的颜色特征、纹理特征和形状特征等全局特征以及特征图像的边缘、角点、线、曲线等局部特征的提取,并对全局特征的注意力权值和局部特征注意力权值进行聚合,MS-CAM结构如图3所示。MS-CAM为特征图在iAFF特征融合阶段分配了更优的权重值,同时为了防止初始特征融合的质量受到影响,使用第2块MS-CAM模块再次进行特征融合,该方法有效的增强了低分辨率遥感图像在网络中的利用率。公式如下。

$$G(Z) = B(W_2 \delta(B(W_1(g(Z)))))) \quad (2)$$

$$L(Z) = B(PWConv_2(\delta(B(PWConv_1(Z)))))) \quad (3)$$

式中: Z 表示输入的中间特征图; $g(Z)$ 表示通过全局平均池化层(global average pooling, GAP)获得的全局中间特征; W_1 是一个降维层; W_2 是一个增维层; B 表示BN层; δ 表示ReLU激活函数; $G(Z)$ 表示全局特征;PWConv表示逐点卷积层; $L(Z)$ 表示局部特征,与输入特征具有相同的形状,保留和突出了低级特征中的细微细节。

$$Z' = Z \otimes M(Z) = Z \otimes \sigma(L(Z)) \oplus G(Z) \quad (4)$$

式中: Z' 表示MS-CAM细化后的特征; $M(Z)$ 表示MS-CAM生成的注意力权值; σ 表示Sigmoid函数; $\oplus$ 表示元素求和; $\otimes$ 表示元素相乘。

$$X \cup Y = M(X \oplus Y) \otimes X + (1 - M(X \oplus Y)) \otimes Y \quad (5)$$

式中: X 表示低分辨率遥感图像; Y 表示低分辨率图像在经过残差块进行特征提取后得到的图像特征; $X \cup Y$ 表示特征融合; $M(\cdot)$ 表示MS-CAM模块。融合不同特征的注意力权值,输出一个在0~1之间的实数值。




图3 MS-CAM结构

2) 高效注意力机制

遥感图像包含的信息量大,在网络传输过程中,更高的维数,更多的通道数能够呈现更完整的图像特征信息,过多的通道信息也会导致网络很难筛选有用的通道信息。针对这个问题,本文选择ECA^[19]通过避免降维以及适当的通道跳跃交互操作,建立通道注意机制,实现深层卷积神经网络注意力机制。高效注意力模块使得网络能够将更多的注意力放在有用的特征信息上,提升网络模型的计算效率,抑制无用的信息。高效注意力模块在不通过升维—降维的情况下,通过考虑每个通道及其 k 个邻居,采用一个大小为 k 的一维卷积实现本地的跨通道信息交流。首先输入维度是 $H \times W \times C$ 的遥感特征图,通过GAP对输入特征图的空间信息进行压缩,然后使用 1×1 卷积对压缩后的特征图,进行通道特征学习得到通道注意力信息,最后通道逐乘输出包含通道注意力权值的遥感特征图像,如图4所示。




图4 ECA结构

2.2 判断器的构建

判断器是对输入的生成图像和训练图像进行分辨,判别结果直接影响生成图像的好坏。本文采用改进后的sr-gan判断器。受WGAN的启发,为了防止梯度爆炸等问题,去除掉判断器中的Sigmoid层,采用LeakyReLU作为

激活函数。判断器通过7个卷积块进行特征图提取,每个卷积块后面都有一个批归一化层,并在全连接层前增添1个ECA模块扩大网络感受野,提高判断器在特征空间对图像进行特征映射时的准确性,并加快损失函数的收敛。网络末端连接两个全连接层,相当于一个分类器,最后输出判别结果。

2.3 损失函数与训练过程

为了提高对低分辨率遥感图像的清晰重建,本文采用由像素级 MSE 损失、VGG 损失构成的内容损失函数和基于 WGAN 优化后的对抗损失函数共同作为本文的目标函数,训练过程如图5所示。




图5 训练过程

其中, I^{LR} 表示由生成器重建的遥感图像, I^{HR} 表示真实的遥感图像。首先,将 I^{LR} 和 I^{HR} 输入经过预训练的 VGG19 网络中提取特征映射,VGG 损失基于这些提取的特征映射,计算 I^{LR} 和 I^{HR} 的特征映射之间的欧氏距离,VGG 损失通过寻找特征空间上图像纹理的相似度,让重建的遥感图像达到更好的视觉效果。公式如下:

$$L_{VGG} = \frac{1}{WH} \sum_{x=1}^W \sum_{y=1}^H (\epsilon(I^{HR})_{x,y} - \epsilon(G_{\theta_G}(I^{LR}))_{x,y})^2 \quad (6)$$

式中: ϵ 表示 VGG19 网络生成的特征映射; $\epsilon(I^{HR})$ 表示真实图像中得到的特征映射; $G_{\theta}(I^{LR})$ 表示生成网络生成的清晰图像; $\epsilon(G_{\theta_G}(I^{LR}))$ 表示从生成的清晰图像中得到的特征映射; W, H 表示 VGG 特征图尺寸。

由 MSE 损失通过图片元素的颜色值的差异,计算 I^{LR} 和 I^{HR} 在对应像素之间的像素差的平方均值,生成在图像空间分布上 I^{LR} 更接近与 I^{HR} 的遥感图像,公式如下:

$$L_{MSE} = \frac{1}{r^2 WH} \sum_{x=1}^{rW} \sum_{y=1}^{rH} (I^{HR} - G_{\theta_G}(I^{LR}))_{x,y}^2 \quad (7)$$

然后,将 I^{LR} 和 I^{HR} 输入判断器中,通过对抗损失进行训练。为了防止网络训练不稳定,采用 WGAN 作为判别器损失和对抗损失。判断损失用于对判断器进行更新,使判断器能对 I^{LR} 和 I^{HR} 进行分辨,对抗损失是判断损失在多次迭代后达到“最优”时的体现,但生成对抗网络的训练是交替进行的,所以判断器的不断更新促使生成器生成更清晰的遥感图像。判断损失函数如下:

$$L_D = \sum_{n=1}^N D_{\theta_G}(G_{\theta_G}(I^{HR})) - D_{\theta_G}(G_{\theta_G}(I^{LR})) \quad (8)$$

对抗损失函数如下:

$$L_{GEN} = \sum_{n=1}^N -D_{\theta_G}(G_{\theta_G}(I^{LR})) \quad (9)$$

最后,通过 VGG 损失和 MSE 构成的内容损失函数和对抗损失函数构建生成损失函数,并用生成损失函数对生成器进行训练,生成损失函数如下:

$$L = 1.0 \times L_x + 0.001 \times L_{GEN} \quad (10)$$

式中: L 表示生成损失函数的总和; L_x 表示内容损失。

3 实验与分析

3.1 数据集预处理与实验环境

为验证本文算法的超分重建性能,本文选择遥感图像公开数据集 NWPU-RESISC45(NR45)^[20] 和 Lnrria Aerial Image Labeling Dataset(LAI)^[21]。NR45 遥感图像数据集保证了实验数据的真实性和多样性,包含 45 个不同场景下的机载遥感图像,包括飞机、港口、湖泊、高速公路、商业区等场景,每类图像有 700 张,共 31 500 张图像,图像大小为 256×256 ,从各类图像中随机选择 50 张,共 2 250 张图像组成训练集,再随机选择 450 张组成测试集进行测试。LAI 数据集是包含了建筑、湖泊、树木、街道等的像素级遥感图像数据集,共 2 500 张图像,像素大小为 512×512 ,随机选择 450 张作为测试集。初始化学率 10^{-4} ,batch size 设置为 90,epoch 设置为 1 000,将预加载的图像从任意位置裁剪为 96×96 的图像,然后进行双线性下采样,得到 24×24 的图像,将该图像作为低分辨率图像与裁剪后的清晰图像作为训练对输入网络进行训练。实验环境如表 1 所示。

表1 实验环境配置表

实验硬件	AMD Ryzen5 5600X 6-Core 六核
内存	16 GB
GPU	GeForce RTX 3060 Ti
主板	华硕 B550M-PLUS
深度学习	Pytorch1.9.1
操作系统	Windows 10

3.2 实验结果分析

在 NWPU-RESISC45 数据集上进行训练,选择在超分重建领域具有代表性的算法 Bicubic、SRCNN、SRGAN、ESRGAN、SPSR 从客观评价指标峰值信噪比(PSNR)、结构相似性(SSIM)和视觉感受两个方面与本文算法进行对比。在客观指标上,本文算法相比其他算法取得了较好的结果,相比 ESRGAN 本文算法在 PSNR 和 SSIM 上分别增加了 0.095 dB 和 0.08,如表 2 所示。

在视觉感知上,本文算法重建的遥感图像在整体的色彩和真实度都优于其他算法重建的图像,实现了对图像去噪并抑制了伪影的产生。本文从 NWPU-RESISC45 数据

表 2 NR45 测试集上的对比结果

评价指标	PSNR	SSIM
Bicubic	24.32	0.653
SRCNN	24.76	0.681
SRGAN	25.026	0.702
ESRGAN	25.124	0.710
SPSR	25.155	0.713
本文算法	25.250	0.721

集中随机选择 airplane_459、airplane_497、church_002 三张遥感图像进行双线性下采样作为低分辨率样本图像,如图 6 所示,分别是不同算法的重建结果对比。为了突出展示本文算法重建图像的优越性,将红色方框内的图像进行

放大。传统算法 Bicubic 重建的图像都含有明显的网格状暗纹。SRCNN 重建后的图像含有大量伪影,细节丢失严重,存在色差。SRGAN 算法重建的图像比较真实,能够重建出逼真的视觉感受,对 church_002 的重建中,房顶的线条应该从图像左下角向右上角延长,呈三角形,但 SRGAN 重建的房顶线条整体扭曲,黑色线条在接近图像右上角的位置,呈现出矩形的形状。ESRGAN 相比之前的算法更为清晰,恢复了部分高频信息,但重建后的图像含有大量的噪声,影响图像整体感知。SPSR 利用额外梯度的分支来预测超分辨率的梯度图,在图像的几何形状上更接近真实图像,但相比本文算法,对高频信息的恢复不够明显,如 airplane_497 的重建图像,本文算法重建后的黑色斑点清晰度更高,色彩饱和度更好。




图 6 NR45 的重建效果对比

为了验证本文算法的泛化能力和鲁棒性,在 LAI 数据集上进行测试,并采用相同的方法从两个方面进行对比,客观指标对比结果如表 3 所示,本文算法相比 ESRGAN 在 PSNR 和 SSIM 上分别提高了 0.122 dB 和 0.03。本文从 LAI 数据集上随机选择 3 张遥感图像 35TMB2SZ7G、59FQCR829L、JFSGUDFFP5 进行双线性下采样作为低分辨率图像,不同算法重建后的结果,如图 7 所示。验证了本文算法能重建出更为清晰,保留更多丰富内容的遥感图像。

表 3 LAI 测试集上的对比结果

评价指标	PSNR	SSIM
Bicubic	23.65	0.583
SRCNN	23.82	0.615
SRGAN	24.019	0.648
ESRGAN	24.214	0.650
SPSR	24.228	0.651
本文算法	24.350	0.654




图7 LAI的重建效果对比

为分析本文算法在引入 ECA 模块和 IAFF 结构对超分辨的影响,在遥感数据集 NR45 上对比不同模型下客观指标 PSNR、SSIM 的值,消融实验如表 4 所示。结果表明同时引入两个模块时效果最好。

表 4 消融实验结果对比			
ECA	iAFF	PSNR	SSIM
×	×	25.026	0.702
✓	×	25.112	0.710
✓	✓	25.250	0.721

为了验证通过 WGAN 能有效优化训练过程,加快损失函数的收敛,本文在 NR45 数据集上对原网络和经过 WGAN 优化过后的网络截取前 150 次的迭代过程,对迭代后的内容损失函数曲线进行对比,如图 8 所示,可以看出优化后的网络损失函数振荡幅度明显小于原网络,在标出的第 3、41、87、92 的迭代位置,原网络损失值向上波动明显,在第 48、105、121、144 的迭代位置都低于前 150 次原网络的损失值,整体损失值的下降和收敛速度快于原网络结构。




图8 损失函数效果对比

4 结 论

本文提出一种基于多注意力机制的生成对抗网络算法,应用到遥感图像的重建中。针对重建图像与真实图像差距较大,含有伪影、噪声等问题,本文在生成对抗网络的框架下,将 ECA 模块插入生成器的残差块中,使不同通道间的特征信息能有效交互,提高网络对浅层信息和深层信

息的提取,增强生成网络对图像特征的学习。其次,在生成器中引入了 iAFF 特征融合模块,代替长连接中的相加操作,更大的保留低分辨率图像的内容信息,利用原始信息引导和约束生成器的训练,使得生成的遥感图像内容更完整,清晰度更高。针对生成对抗网络训练困难的问题,本文采用 WGAN 的训练策略对损失函数进行优化,降低训练奔溃的风险,提升训练效率。最后,通过在不同数据集上进行对比实验,验证了本文算法的鲁棒性和有效性。

参考文献

- [1] 李壮飞,杨风暴,郝岳强.一种基于残差网络优化的航拍小目标检测算法[J].国外电子测量技术,2022,41(8):27-33.
- [2] 潘伟豪,徐赛博,郭弘扬,等.基于D-S证据理论的高分遥感影像建筑物变化检测[J].电子测量与仪器学报,2022,36(8):194-203.
- [3] 王延年,刘航宇,刘宏涛,等.基于小波深度残差网络的图像超分辨率重建[J].国外电子测量技术,2021,40(9):160-164.
- [4] DONG C, LOY C C, HE K, et al. Image super-resolution using deep convolutional networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(2):295-307.
- [5] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks [J]. Advances in Neural Information Processing Systems, 2014(3):2672-2680.
- [6] GOODFELLOW I, BENGIO Y, COURVILLE A. Deep Learning [M]. Cambridge: The MIT Press, 2016:26-29.
- [7] LEDIG C, THEIS L, HUSZAR 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.
- [8] WANG X, YU K, WU S, et al. ESRGAN: Enhanced super-resolution generative adversarial networks[C]. Proceedings of the European Conference on Computer Vision Workshops (ECCV-W), Part V, 2018:63-79.
- [9] WANG X, XIE L, DONG C, et al. Real-ESRGAN: Training real-world blind super-resolution with pure synthetic data[C]. Proceedings of 2021 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW), 2021: 1905-1914.
- [10] LIU H, GU X, SAMARAS D. Wasserstein gan with quadratic transport cost[C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 4832-4841.
- [11] JI H, GAO Z, MEI T C, et al. Vehicle detection in remote sensing images leveraging on simultaneous super-resolution[C]. IEEE Geoscience and Remote Sensing Letters, 2020, 17(4):676-680.
- [12] JIANG K, WANG Z, YI P, et al. Edgeenhanced GAN for remote sensing image superresolution[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(8):5799-5812.
- [13] LEI S, SHI Z W, ZOU Z X. Coupled adversarial training for remote sensing image super-resolution[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 58(5):3633-3643.
- [14] MA C, RAO Y M, CHENG Y, et al. Structure-preserving super resolution with gradient guidance[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2020: 7766-7775.
- [15] 蔡非凡,万旺根.基于空间金字塔的视频超分辨率重建算法[J].电子测量技术,2022,45(5):100-104.
- [16] 闫钧华,张琨,施天俊,等.融合多层次特征的遥感图像地面弱小目标检测[J].仪器仪表学报,2022,43(3):221-229.
- [17] DAI Y M, GIESEKE F, OEHMCKE S, et al. Attentional feature fusion[C]. The IEEE/CVF Winter Conference on Applications of Computer Vision, 2021:3560-3569.
- [18] SHI W, CABALLERO J, HUSZAR 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, 2016: 1874-1883.
- [19] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2020:11531-11539.
- [20] CHENG G, HAN J, LU X. Remote sensing image scene classification: Bench-mark and state of the art[C]. Proceedings of the IEEE, 2017:1-19.
- [21] MAGGIORI E, TARABALKA Y, CHARPIAT G, et al. Can semantic labeling methods generalize to any city? The inria aerial image labeling benchmark[C]. 2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 2017:2153-7003.

作者简介

李宣韩,硕士研究生,主要研究方向为图像处理。

E-mail:568317750@qq.com

罗毅(通信作者),教授,主要研究方向为智能电力/智能控制等。

E-mail:lyly@126.com

赵俊,博士,副教授,主要研究方向为智能感知与检测。

E-mail:zhaojun@suse.edu.cn

刘忠灵,硕士研究生,主要研究方向为人工智能、图像处理。

E-mail:ayaling@yeah.net

王盛,硕士研究生,主要研究方向为人工智能、图像处理。

E-mail:2537098726@qq.com