

## 基于生成对抗网络的遥感图像锐化方法

闫艳, 隋毅, 司建伟

### 引用本文

闫艳, 隋毅, 司建伟. 基于生成对抗网络的遥感图像锐化方法[J]. 计算机科学, 2023, 50(8): 133-141.

YAN Yan, SUI Yi, SI Jianwei. [Remote Sensing Image Pan-sharpening Method Based on Generative Adversarial Network](#) [J]. Computer Science, 2023, 50(8): 133-141.

---

### 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

#### Similar articles recommended (Please use Firefox or IE to view the article)

#### [基于改进的ResNeXt网络结构的遥感图像分类](#)

Remote Sensing Image Classification Based on Improved ResNeXt Network Structure

计算机科学, 2023, 50(6A): 220100158-6. <https://doi.org/10.11896/jsjcx.220100158>

#### [基于数据融合的半监督高分遥感影像语义分割](#)

Semi-supervised Semantic Segmentation for High-resolution Remote Sensing Images Based on DataFusion

计算机科学, 2023, 50(6A): 220500001-6. <https://doi.org/10.11896/jsjcx.220500001>

#### [基于移位窗口金字塔Transformer的遥感图像目标检测](#)

SPT:Swin Pyramid Transformer for Object Detection of Remote Sensing

计算机科学, 2023, 50(1): 105-113. <https://doi.org/10.11896/jsjcx.211100208>

#### [基于Hachimoji DNA和QR分解的遥感图像可逆隐藏算法](#)

Reversible Hidden Algorithm for Remote Sensing Images Based on Hachimoji DNA and QR Decomposition

计算机科学, 2022, 49(8): 127-135. <https://doi.org/10.11896/jsjcx.210700216>

#### [改进Faster R-CNN的光学遥感飞机目标检测](#)

Remote Sensing Aircraft Target Detection Based on Improved Faster R-CNN

计算机科学, 2022, 49(6A): 378-383. <https://doi.org/10.11896/jsjcx.210300121>

# 基于生成对抗网络的遥感图像锐化方法

闫艳<sup>1</sup> 隋毅<sup>1</sup> 司建伟<sup>2</sup>

1 青岛大学计算机科学技术学院 山东 青岛 266071

2 中国海洋大学信息科学与工程学院 山东 青岛 266100

(2020020641@qdu.edu.cn)

**摘要** 现有遥感图像锐化方法普遍采用 Wald 协议,导致重建图像存在空间纹理细节和颜色模糊、边缘过于平滑的问题。针对该问题,提出基于生成对抗网络(Generative Adversarial Networks,GAN)的遥感图像锐化方法 PAN-GAN。该方法将多光谱图像作为参考图像,使用灰度化的参考图像模拟全色图像,并与模糊化的参考图像共同作为生成器输入,由生成器分别提取前者的纹理细节特征和后者的光谱特征并进行融合重构;引入感知损失,联合对抗损失和像素损失共同优化重构图像,使重构图像具有更加逼近参考图像的光谱和纹理细节特征。在 QuickBird、GaoFen-2 和 WorldView-2 这 3 个遥感卫星的图像数据集上进行实验,结果表明:与常用方法相比,使用 PAN-GAN 得到的重构图像具有更加逼真的光谱和空间纹理细节;使用灰度化的参考图像能够显著提升原有方法的性能并且平均灰度化提升最为明显;感知损失的引入进一步优化了重构结果,验证了所提方法的有效性。

**关键词**: 遥感图像;锐化;对抗性生成网络;感知特征

**中图分类号** TP391;TP751

## Remote Sensing Image Pan-sharpening Method Based on Generative Adversarial Network

YAN Yan<sup>1</sup>, SUI Yi<sup>1</sup> and SI Jianwei<sup>2</sup>

1 College of Computer Science and Technology, Qingdao University, Qingdao, Shandong 266071, China

2 Faculty of Information Science and Engineering, Ocean University of China, Qingdao, Shandong 266100, China

**Abstract** Remote sensing image pan-sharpening methods are generally based on Wald protocol, resulting in blurred texture details, colors and ambiguous boundaries of the reconstructed images. To solve the problem, a remote sensing image pan-sharpening method based on generative adversarial networks(GAN), PAN-GAN, is proposed in this paper. The multispectral image is employed as the reference image. The grayscale reference image is applied to simulate the panchromatic image and the blurred reference image is adopted as input of the generator. The generator extracts the texture details of the grayscale reference image and spectral features of the blurred reference image for the fusion reconstruction. Meanwhile, the perceptual loss is introduced to optimize the reconstruction results with adversarial loss and pixel loss, so that the reconstructed images have spectral and texture detail features closer to the reference image. Experiments are carried out on the datasets of three remote sensing satellites including QuickBird, GaoFen-2 and WorldView-2. The results show that the reconstructed images obtained by PAN-GAN have more realistic spectral and spatial texture details compared with common methods. The usage of grayscale reference images can significantly improve the performance of the original method, and the average grayscale improvement is the most obvious. The perceptual loss can further optimize the reconstruction results and verify the effectiveness of the proposed method.

**Keywords** Remote sensing images, Pan-sharpening, Generative adversarial networks, Perceptual features

### 1 概述

近年来,高分辨率光学地球观测卫星的陆续发射为不同研究领域提供了大量遥感数据。然而,卫星仅能提供低分辨率的多光谱图像(Low Resolution Multi-Spectral image, LRMS)和高分辨率的全色图像(Panchromatic image, PAN),

在生成图像时无法同时兼顾空间细节与色彩特性。因此,为了获得高分辨率的多光谱图像(High Resolution Multi-Spectral image, HRMS),学者们将同一区域相同时间段获取的 LRMS 图像和 PAN 图像融合,这一融合过程也被称作“全锐化”(Pan-sharpening)。

现有的遥感图像锐化方法大致可分为两类:传统的遥感

到稿日期:2022-06-07 返修日期:2022-10-11

基金项目:国家自然科学基金青年科学基金(41706198)

This work was supported by the Young Scientists Fund of the National Natural Science Foundation of China(41706198).

通信作者:隋毅(suiyi@qdu.edu.cn)

图像融合方法和基于深度学习神经网络的遥感图像融合方法。传统的遥感图像融合方法有分量替换(Component Substitution, CS)、多分辨率分析(Multi-resolution Analysis, MRA)和基于模型优化的方法等<sup>[1-5]</sup>。基于分量替换的遥感图像融合算法的基本思想是使用新的向量空间对原始的光谱空间进行光谱变换完成泛锐化过程。经典的算法有主成分分析(Principal Component Analysis, PCA)、IHS(Intensity Hue Saturation)色彩空间变换及其各种变形<sup>[6-8]</sup>。虽然此类融合算法计算效率较高,但是易产生光谱扭曲现象。与上述算法相比,多分辨率分析的思想是对原始图像进行多尺度分解后再根据不同的融合规则分别对不同信息进行融合,最后经过逆变换得到融合图像。MRA方法使用空间滤波获得更多空间细节信息,例如小波变换(Additive Wavelet Luminance Proportional, AWLP)<sup>[9]</sup>、高通滤波法(High-Pass Filtering)等,虽然能在一定程度上解决光谱失真问题,但多分辨率分解会导致全色图像丢失部分空间细节,从而使融合图像出现空间扭曲、局部模糊等现象。

近年来,深度学习技术在各种计算机视觉任务中取得了巨大的成功,因此,学者们也将该技术应用到遥感图像融合问题中。目前,基于深度学习的图像融合方法<sup>[10-22]</sup>主要将遥感图像锐化问题视为遵循Wald协议<sup>[23]</sup>的自监督超分辨率任务。Giuseppe等<sup>[10]</sup>提出基于深度的遥感图像融合网络(CNN-based Pan-sharpening, PNN),该网络使用由3个卷积层组成的CNN结构对PAN图像和LRMS图像进行特征提取并得到重建图像。Scarpa等<sup>[11]</sup>将水源、植物通过非线性辐射指数归一化,并将其添加到输入并使用与文献<sup>[10]</sup>相同结构的CNN网络进行特征提取,从而得到泛锐化图像。Yang等<sup>[12]</sup>提出基于深度学习的遥感图像融合方法(Deep Network Architecture for Pan-sharpening, PanNet),该网络将高通滤波处理后的LRMS图像与PAN图像输入残差网络,然后将网络输出与上采样LRMS图像相加获得融合图像。Dong等<sup>[13]</sup>和Lei等<sup>[14]</sup>将LRMS图像进行不同尺度下采样后与PAN图像进行处理,然后将处理后的图像作为多尺度输入并使用深度神经网络得到重建图像。Azarang等<sup>[15]</sup>使用自编码器生成LRMS图像后与PAN图像经过特征提取,从而得到重建图像。Wang等<sup>[16]</sup>使用反馈网络对输入的LRMS图像和PAN图像进行特征提取后得到重建图像,并使用基于VGG-16的感知损失对网络进行优化。此外,生成对抗网络(Generative Adversarial Networks, GAN)<sup>[17]</sup>也被广泛用于遥感图像融合。Yang等<sup>[19]</sup>使用由特征金字塔构成的生成器获得重建

图像,并在损失函数中加入感知损失以提高重建图像的质量。Ma等<sup>[20]</sup>提出由生成器和双判别器组成的图像融合网络,其中生成器用来获取重建图像,双判别器分别用来获取输入LRMS图像和PAN图像的损失函数。Liu等<sup>[21]</sup>提出了基于GAN的遥感图像融合网络(Pansharpening GAN, PSGAN)。该网络将原始LRMS图像进行下采样-上采样操作后与PAN图像共同作为生成器输入,从而获得重建图像。

上述研究在遥感图像锐化质量上取得了较好的效果,然而,由于在实际中无法获得真实的高空间分辨率多光谱图像,因此已有研究大多采用Wald协议将原始的LRMS图像作为真实标签图像,对原始LRMS和PAN图像进行下采样,将其作为模型输入,通过模型参数学习,最小化模型输出与真实标签之间的差异,重建标签图像。由于该训练方式以下采样的原始图像作为输入,因此训练得到的模型只对低空间分辨率图像的重建有效,当将原始的LRMS图像和PAN图像作为模型输入(模型应用)时,重建效果就不够理想<sup>[22]</sup>。此外,已有方法大多以输出图像与参考图像之间的所有像素的累计均方误差作为优化目标,导致输出的重建图像边缘细节较为平滑,视觉效果不佳。

针对上述问题,本文提出了基于GAN的遥感图像锐化模型PAN-GAN,该模型在训练阶段将原始LRMS图像作为真实标签(记为参考HRMS图像)进行有监督学习,并使用灰度化的参考图像模拟全色图像(记为GrayPAN),将其和模糊化后的参考图像(记为BlurLRMS)作为生成器的输入。引入感知损失优化重构结果得到光谱和纹理细节清晰的融合图像,从而得到与参考图像高度相似的重建图像。此外,模型使用判别器D得到重建图像的预测概率值,为提高锐化图像的质量,建立融合RaGAN损失<sup>[24]</sup>、像素损失和感知损失的优化器对生成器和判别器进行优化。在模型训练阶段,标签图像和输入的全色图像具有相同的空间分辨率,因而生成器构建的图像能够很好地学习到全色图像的纹理细节特征。在模型应用阶段,将PAN图像和参考HRMS图像作为模型输入,由生成器构建融合图像,得到高分辨率多光谱图像。

## 2 PAN-GAN 网络结构

在计算机视觉领域,GAN网络因其强大的图像生成能力而被广泛应用在不同的任务中。为解决遥感图像融合过程中空间信息缺失、图像边缘模糊所带来的视觉感受差等问题,本文提出了基于GAN网络的遥感图像融合方法PAN-GAN,包括生成器、判别器和优化器,方法如图1所示。

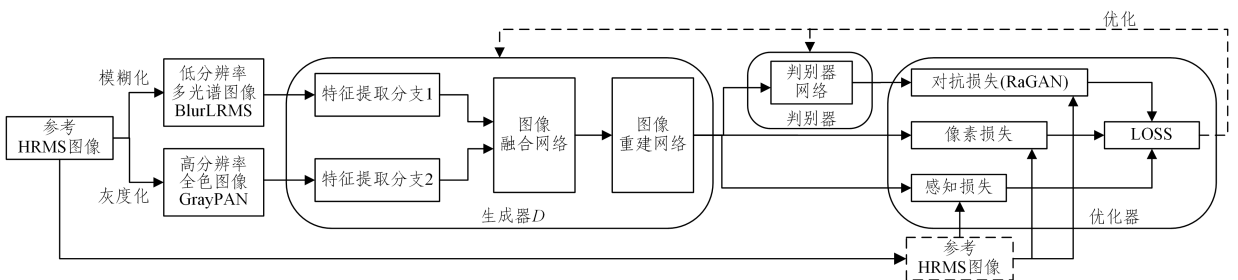


图1 PAN-GAN方法的总体结构

Fig. 1 Overall structure of PAN-GAN

将原始 LRMS 图像作为参考 HRMS 图像,对其进行模糊化和灰度化后得到 BlurLRMS 图像和 GrayPAN 图像,并将它们同时输入生成器中,从而产生与参考 HRMS 图像接近的融合图像  $\hat{Y}_G$ 。其中,灰度化选用通道平均方法完成;模糊过程包括下采样和上采样操作,前者采用最大化采样方式,采样率为  $4\times$ ,后者采用双线性插值方式。此外,在训练过程中,使用融合 RaGAN 损失、像素损失和感知损失的优化器对生成器和判别器进行优化,使得重构图像与参考 HRMS 图像高度相似。

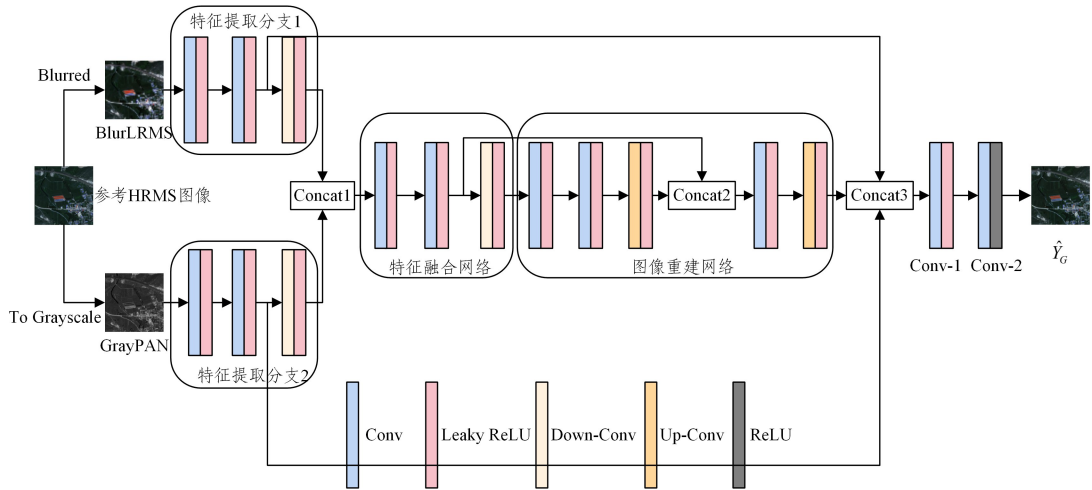


图2 生成器网络结构

Fig. 2 Architecture of generator network

经过特征提取分支 1 与分支 2 网络后,其输出分别作为特征融合网络的输入,该网络作为编码器,将两个输入进行拼接操作(图 2 中表示为 Concat1)得到特征向量,然后将该向量依次输入至两个卷积层和一个下采样层中。为使图像的特征具有更强的语义性,下采样层采用步长为 2 的卷积与激活操作,而非传统的池化策略(如最大池化<sup>[25]</sup>)。经过采样和激活的特征即为融合特征,用于图像重建。

经过特征融合网络结构后,其输出作为图像重建网络的输入,该网络作为解码器,对其输入先通过两个卷积层和上采样层得到特征向量,其中,上采样层通过反卷积和激活函数实现。其次,将该向量与特征融合网络中进行下采样前的特征向量进行拼接操作(图 2 中表示为 Concat2),得到 Concat2 特征向量。最后,该向量经过一个卷积层和上采样层后得到图像重建特征向量。

经过图像重建网络所得的特征向量与特征提取分支 1 和分支 2 进行下采样前的特征进行拼接操作(图 2 中表示为 Concat3),得到 Concat3 特征向量。最后,再次采用两个卷积层(图 2 中表示为 Conv-1 和 Conv-2)提取特征信息,得到生成器输出  $\hat{Y}_G$ 。

表 1 列出了生成器中不同部分的网络结构参数,包括名称、卷积类型、卷积核参数、模块输入和输出特征图大小。其中,每个模块包含的卷积类型和卷积核参数顺序(上-下)代表图 2 中对应模块中的卷积层顺序(左-右);卷积核参数“(3×3,32),1”表示该卷积层使用 32 个 3×3 的卷积核进行卷积操作,步长为 1,填充方式为“SAME”。对于激活函数而言,除

## 2.1 生成器

PAN-GAN 中的生成器用于产生与参考 HRMS 图像尽可能相似的高光谱图像,其结构如图 2 所示,其输入为模糊化 BlurLRMS 图像和灰度化 GrayPAN 图像。为充分利用光谱和空间信息,本文使用两个特征提取子网络(特征提取分支 1 与分支 2)分别提取 BlurLRMS 图像的光谱特征和 GrayPAN 图像的空间纹理特征。特征提取子网络均由两个卷积层和一个下采样层组成,每层均由卷积操作和激活函数构成。

Conv-2 使用 ReLU<sup>[26]</sup> 激活函数之外,其余卷积和采样层激活函数均使用 LeakyReLU<sup>[27]</sup>。

表 1 生成器网络结构参数

Table 1 Network structure parameters of generator

名称	卷积类型	卷积核参数	输入	输出
特征提取分支 1	Conv	(3×3,32),1	(256,256,1)	(128,128,64)
	Conv	(3×3,32),1		
	Down-Conv	(2×2,64),2		
特征提取分支 2	Conv	(3×3,32),1	(256,256,1)	(128,128,64)
	Conv	(3×3,32),1		
	Down-Conv	(2×2,64),2		
特征融合网络	Conv	(3×3,32),1	(128,128,128)	(64,64,256)
	Conv	(3×3,32),1		
	Down-Conv	(2×2,64),2		
图像重建网络	Conv	(3×3,256),1	(64,64,256)	(256,256,128)
	Conv	(3×3,256),1		
	Up-Conv	(2×2,128),1		
	Conv	(3×3,128),1		
Up-Conv	(2×2,128),1			
Conv-1	Conv	(3×3,64),1	(256,256,192)	(256,256,64)
Conv-2	Conv	(3×3,4),1	(256,256,64)	(256,256,4)

## 2.2 判别器

判别器用来提供对抗损失,以最大限度地区分生成图像与参考 HRMS 图像,其结构如图 3 所示。该网络以生成器得到的重建图像  $\hat{Y}_G$  和对应的参考 HRMS 图像  $P$  作为输入,经过由 3 个下采样层和两个卷积层组成的网络后,得到预测输出概率值,并将其用于生成对抗损失。其中,下采样层均由下采样操作和 LeakyReLU 激活函数组成,卷积核个数分别为 32,64 和 128,大小为  $2\times 2$ ;两个卷积层分别由卷积操作与

不同的激活函数组成,其中,卷积核个数分别为 256 和 1,大小为  $3 \times 3$ ,激活函数分别为 LeakyReLU 和 Sigmoid,经过 Sigmoid 卷积函数后,得到概率判别结果。为进一步提升重建图像的质量,PAN-GAN 使用生成器得到对抗损失,并将其用于构建融合损失优化器,具体见 2.3 节。




图3 判别器网络结构

Fig. 3 Architecture of discriminator network

### 2.3 融合损失优化器

优化器损失函数的设定是影响图像融合结果的重要因素。在不同的视觉任务中,逐像素优化方法<sup>[28]</sup>已经被广泛采用,虽然该方法可以使得模型在不同的评价指标上具有较好的性能,但是该方法忽略了图像的全局相似性,使生成器所重建的图像在视觉效果上存在颜色模糊、边缘过于平滑等问题。为了解决图像模糊问题的同时提升图像视觉感受,PAN-GAN 在 RaGAN 损失的基础上,将其与像素损失和感知损失进行融合,从而重建出包含丰富的感知信息、更符合人类视觉感受且拥有更多空间细节的高质量图像。优化器主要包括像素损失函数  $L_1$ 、对抗损失函数  $L_{\text{RaGAN}}$  和特征损失函数  $L_P$  共 3 部分,其结构如图 1 所示,计算式如式(1)所示:

$$L = L_1 + \alpha L_{\text{RaGAN}} + \beta L_P \quad (1)$$

其中, $\alpha$  和  $\beta$  是调节各个损失项的权重因子,在实验中分别设置为 0.005 和 0.5。

#### 2.3.1 像素损失函数

为在重建时保证网络结构生成图像与参考的 HRMS 图像在低频部分保持图像结构的一致性,采用  $L_1$  损失作为重建 HRMS 图像  $\hat{Y}_G$  和参考 HRMS 图像  $P$  像素之间的像素损失项,如式(2)所示:

$$L_1 = \sum_{i=1}^N \| P^i - \hat{Y}_G^i \|_1 \quad (2)$$

其中, $P$  为参考 HRMS 图像, $N$  为一个 batch size 大小的训练样本数量。

#### 2.3.2 对抗损失函数

为使生成的图像分布更接近于多光谱图像并且提高生成图像的清晰度,使用 RaGAN 损失作为对抗性损失,如式(3)和式(4)所示:

$$L_{\text{RaGAN}}^D = -E[\log(\sigma(D(P) - E[D(\hat{Y}_G)]))] - E[\log(1 - \sigma(D(\hat{Y}_G), E[D(P)]))] \quad (3)$$

$$L_{\text{RaGAN}}^G = -E[\log(\sigma(D(\hat{Y}_G) - E[D(P)]))] - E[\log(1 - \sigma(D(P) - E[D(\hat{Y}_G)]))] \quad (4)$$

其中, $\sigma$  为 ReLU 激活函数。

#### 2.3.3 感知损失函数

为提高生成图像的清晰度,在损失函数中加入感知特征损失,其整体结构如图 4 所示。分别对重建图像  $\hat{Y}_G$  和参考

HRMS 图像使用相同的网络结构进行特征提取。该网络结构包含 5 个特征提取模块,FE-1,FE-2 和 FE-5 模块均由卷积层和激活函数构成,其中,卷积核个数分别为 64,128 和 512,大小为  $3 \times 3$ ,激活函数为 ReLU,步长为 1,填充方式为“SAME”;FE-3 和 FE-4 模块由卷积层、激活函数和下采样操作组成,卷积核个数分别为 256 和 512,大小为  $2 \times 2$ ,其余参数设置与 FE-1 相同。为最小化生成图像与真实高清图像在图像语义级别上的差异,感知损失函数由不同模块特征的均方误差得到。具体而言,为了得到更加全面的感知损失,该过程先求得每个特征提取模块中卷积后的特征的均方误差,然后对不同模块中的均方误差进行融合,得到最终的感知损失,其计算过程如式(5)所示:

$$L_P = \sum_{j=1}^5 L_{\text{MSE}}^j \quad (5)$$

其中, $L_{\text{MSE}}^j = \| FE^j(\hat{Y}_G) - FE^j(P) \|_2^2$ , $FE^j$  代表特征提取结构中的第  $j$  个特征提取模块。




图4 感知损失整体结构

Fig. 4 Overall structure of perceptual loss

### 2.4 网络训练过程

PAN-GAN 网络的训练过程是生成器与判别器相互对抗(博弈)的过程。在训练过程中,生成器用来生成与原始多光谱图像尽可能接近的融合图像,从而达到欺骗判别器的目的,而判别器用来判断模型的输入是真(假)样本的概率。

在训练过程中,PAN-GAN 网络结构的训练过程分阶段完成,首先固定生成器  $G$ ,训练判别器  $D$ ;然后,固定判别器  $D$ ,训练生成器  $G$ ;最后,重复此操作,每次都是判别器训练操作执行完成后训练生成器,并不断进行优化训练。上述训练实现过程中使用优化器对生成器和判别器进行优化,从而提升各自的性能。在训练过程中使用 Adam 优化算法对网络进行优化,其初始学习率为 0.0001,动量大小为 0.5。并使用反向传播策略更新参数,衰减率大小设置为 0.99。batch size 大小设置为 6,训练轮次设置为 100。

## 3 实验结果与分析

### 3.1 数据集介绍

QuickBird, GaoFen-2 和 WorldView-2 这 3 个遥感卫星搭载了多光谱相机和全色相机,采集的多光谱图像包含红、绿、蓝和近红外 4 个波段。表 2 列出了数据集的具体信息,数据来源于文献[21]。在实验中,每个波段随机选用 8 对图像用于模型训练,剩余 1 对用于模型测试。

表 2 数据集简介

Table 2 Intraduction of exepeimental datasets

Dataset	Training Samples	Testing Samples	Spatial Resolution
QB	4821	81	0.6/2.4
WV-2	11552	324	0.5/2.0
GF-2	15388	961	0.8/3.2

为解决缺少理想融合参考图像的问题,根据 Wald 协议制作数据集。具体过程为将卫星图像中的 LRMS 图像进行  $4\times$  下采样和上采样操作后得到低分辨率 BlurLRMS 图像,并将参考 HRMS 图像(LRMS 图像)灰度化后的 GrayPAN 图像作为高分辨率全色图像进行后续处理。对数据集中 BlurLRMS 图像和 GrayPAN 图像均进行切片处理,其大小分别为  $256\times 256\times 4$  和  $256\times 256\times 1$ ,经过切分后的训练集和测试集样本数目如表 2 所列。

### 3.2 评价指标

本文采用常用评价指标对不同模型的性能进行评估,包括光谱角映射(Spectral Angle Mapper, SAM)<sup>[29]</sup>、相关系数(The Correlation Coefficient, CC)、空间相关系数(spatial Correlation Coefficient, sCC)<sup>[30]</sup>、相对全局尺寸综合误差(Relative Dimensionless Global Error in Synthesis, ERGAS)、质量指数(The Quality index,  $Q_4$ )<sup>[31]</sup>及感知相似性(Learned Perceptual Image Patch Similarity, LPIPS)<sup>[32]</sup>。其中, SAM 用来

衡量参考 HRMS 图像和锐化图像的光谱失真程度,其值越小越好;CC 用来评价锐化图像和其相应的参考图像之间的相似性,取值范围为  $[-1, 1]$ ,且其值越大越好;sCC 用来评估锐化图像与其参考图像之间的空间细节相似性,其值越大越好;ERGAS 是一种常用的全局质量指数,其值越小越好; $Q_4$  是一个全局融合质量评价指标,其值越大越好;LPIPS 用来评价参考 HRMS 图像和锐化图像的人类视觉感知差距,其值越小越好。

### 3.3 GrayPAN 图像有效性验证

为探究输入对重建图像质量的影响,在实验数据集上使用不同输入的模型进行性能对比。实验主要使用 PAN 图像(PAN)和参考 HRMS 图像灰度化得到的 PAN 图像(GrayPAN)作为输入对模型性能进行评估,模型主要为 PSGAN 和 PAN-GAN。实验过程中,将 BlurLRMS 图像分别与 PAN 图像和 GrayPAN 图像作为输入对上述模型进行性能评估,其余参数设置均与 PAN-GAN 相同。实验结果如表 3 所列,由表可得,对于 PSGAN 和 PAN-GAN 而言,使用 GrayPAN 作为输入后,模型的性能在所有指标上均有大幅提升,这也说明了 GrayPAN 图像作为输入的有效性。此外,本文对不同实验进行可视化分析,如图 5 所示,可以看出,在使用 GrayPAN 图像作为输入后,更多的空间细节得到了保留,边缘也更加锐化,重建图像的效果更好。

表 3 使用不同输入的网络模型性能比较结果

Table 3 Performance comparison of models with different inputs

Dataset	Methods	SAM(inf-0)	CC(0-1)	sCC(0-1)	ERGAS(inf-0)	$Q_4 \uparrow$	LPIPS $\downarrow$
WV-2	PSGAN(PAN)	0.9127	0.9973	0.9975	1.6452	0.9971	0.1701
	PSGAN(GrayPAN)	0.7174	0.9975	0.9972	1.3083	0.9980	0.1551
	PAN-GAN(PAN)	0.8889	0.9974	0.9975	1.6188	0.9973	0.1428
	PAN-GAN(GrayPAN)	<b>0.7123</b>	<b>0.9985</b>	<b>0.9985</b>	<b>1.3024</b>	<b>0.9989</b>	<b>0.1087</b>
QB	PSGAN(PAN)	1.2048	0.9899	0.9890	0.9704	0.9939	0.1424
	PSGAN(GrayPAN)	1.1939	0.9954	0.9953	0.8414	0.9954	0.1321
	PAN-GAN(PAN)	1.1850	0.9956	0.9950	0.9502	0.9942	0.1401
	PAN-GAN(GrayPAN)	<b>1.1842</b>	<b>0.9964</b>	<b>0.9957</b>	<b>0.7804</b>	<b>0.9960</b>	<b>0.1023</b>
GF-2	PSGAN(PAN)	0.9275	0.9853	0.9891	1.2065	0.9961	0.1523
	PSGAN(GrayPAN)	0.9015	0.9924	0.9923	1.1385	0.9992	0.1034
	PAN-GAN(PAN)	0.9065	0.9895	0.9787	1.2045	0.9948	0.1418
	PAN-GAN(GrayPAN)	<b>0.7227</b>	<b>0.9976</b>	<b>0.9955</b>	<b>0.5281</b>	<b>0.9993</b>	<b>0.0561</b>




图 5 QB 数据集不同输入模型重建图像可视化结果

Fig. 5 Visulization of reconstructed images on QB dataset

为探究 HRMS 图像灰度化方法对模型性能的影响,对采用不同的灰度化方法的 PAN-GAN 网络进行模型性能评估,

包括通道平均灰度化方法(Channel-mean)和取其 RGB 三通道灰度化方法。其中,RGB 灰度化方法包括平均法(RGB-mean)和加权平均法(RGB-weighted),如式(6)和式(7)所示。实验结果如表 4 所列。

$$Gray_{RM} = R \times (1/3) + G \times (1/3) + B \times (1/3) \quad (6)$$

$$Gray_{RW} = R \times 0.299 + G \times 0.587 + B \times 0.114 \quad (7)$$

其中,R,G,B 分别表示实验中参考 HRMS 图像的 R,G,B 通道。

表 4 使用不同灰度化方法的 PAN-GAN 模型性能比较结果

Table 4 Performance comparison of different grayed measures

Dataset	Methods	SAM	CC	sCC	ERGAS	$Q_4 \uparrow$
WV-2	RGB-mean	0.8780	0.9984	0.9985	1.3584	0.9968
	RGB-weighted	0.8774	0.9982	0.9983	1.4460	0.9968
	Channel-mean	<b>0.7123</b>	<b>0.9985</b>	<b>0.9985</b>	<b>1.3024</b>	<b>0.9989</b>
QB	RGB-mean	1.3855	0.9950	0.9950	0.9122	0.9910
	RGB-weighted	1.3506	0.9952	0.9955	0.9066	0.9950
	Channel-mean	<b>1.1842</b>	<b>0.9964</b>	<b>0.9957</b>	<b>0.7804</b>	<b>0.9960</b>
GF-2	RGB-mean	0.8825	0.9900	0.9933	0.8230	0.9915
	RGB-weighted	0.8462	0.9923	0.9950	0.7803	0.9901
	Channel-mean	<b>0.7227</b>	<b>0.9976</b>	<b>0.9955</b>	<b>0.5281</b>	<b>0.9993</b>

由表 4 可知,采用平均灰度化方法的 PAN-GAN 网络具有最佳性能,因此 PAN-GAN 选用该灰度化方法对参考 HRMS 图像进行灰度化处理。

### 3.4 融合损失有效性验证

为分析损失函数对重建图像质量的影响,针对 PAN-GAN 网络,使用不同损失函数组成的优化器进行模型性能对比,分别为  $L_{GAN} + L_1$ ,  $L_{GAN} + L_1 + L_P$ ,  $L_{R_{aGAN}} + L_1$  和  $L_{R_{aGAN}} + L_1 + L_P$ 。在  $L_{GAN} + L_1$  所组成的优化器中,权重分别设置为 1.0 和 100.0;在  $L_{GAN} + L_1 + L_P$  所组成的优化器中,前两者权重如上, $L_P$  权重为 1.0;  $L_{R_{aGAN}} + L_1$  所组成的优化器的权重分别设置为 1.0 和 100.0,实验过程中其他参数设置均相同。实验对比结果如表 5 所列,可以看出,PAN-GAN 在 3 种不同数据集上与不同优化方法相比,除 WV-2 数据集的 CC 指标外,其余客观评价指标均具有最佳实验结果。在不同的

数据集中,仅使用对抗损失加像素重建损失 ( $L_{GAN} + L_1$ ) 会导致生成图像模糊,即过于平滑的结果,该现象由重建损失的特性所引起,如在像素方面,倾向于平均局部邻域细节的最小误差损失。在原损失  $L_{GAN} + L_1$  的基础上加入感知损失  $L_P$  后,PAN-GAN 在 3 种遥感图像数据集上均有更佳的实验结果,尤其是感知相似性度量指标均有一定程度下降,在 WV-2 数据集上下下降最为明显,下降幅度为 0.0238。此外,采用  $R_{aGAN}$  loss 作为对抗损失的模型具有比上述结果更佳的评价指标值,这是由于该损失函数可以使得生成图像分布更接近于参考图像的分布,且能提供清晰的细节信息。为使得模型重建图像更符合人类感知视觉,在此基础上加入感知损失  $L_P$ ,除 WV-2 数据集的 CC 指标外,其余指标在实验数据集上都显示出了优于对比方法的性能,尤其是在 GF-2 数据集上取得了最佳结果,感知相似性度量指标值为 0.0561。

表 5 使用不同 Loss 函数的模型性能比较结果

Table 5 Performance comparison with different Loss functions

Dataset	Loss function	SAM (inf-0)	CC (0-1)	sCC (0-1)	ERGAS (inf-0)	$Q_4 \uparrow$	LPIPS $\downarrow$
WV-2	$L_{GAN} + L_1$	0.7174	0.9975	0.9972	1.3083	0.9980	0.1551
	$L_{GAN} + L_1 + L_P$	0.7169	0.9983	0.9973	1.3067	0.9982	0.1313
	$L_{R_{aGAN}} + L_1$	0.7157	<b>0.9986</b>	0.9980	1.3098	0.9985	0.1192
	$L_{R_{aGAN}} + L_1 + L_P$	<b>0.7123</b>	0.9985	<b>0.9985</b>	<b>1.3024</b>	<b>0.9989</b>	<b>0.1087</b>
QB	$L_{GAN} + L_1$	1.1939	0.9954	0.9953	0.8414	0.9954	0.1321
	$L_{GAN} + L_1 + L_P$	1.1926	0.9956	0.9954	0.8213	0.9958	0.1213
	$L_{R_{aGAN}} + L_1$	1.1901	0.9960	0.9954	0.7876	0.9958	0.1134
	$L_{R_{aGAN}} + L_1 + L_P$	<b>1.1842</b>	<b>0.9964</b>	<b>0.9957</b>	<b>0.7804</b>	<b>0.9960</b>	<b>0.1023</b>
GF-2	$L_{GAN} + L_1$	0.9015	0.9924	0.9923	1.1385	0.9992	0.1034
	$L_{GAN} + L_1 + L_P$	0.8979	0.9934	0.9934	1.1089	0.9992	0.0989
	$L_{R_{aGAN}} + L_1$	0.7447	0.9974	0.9953	0.9096	0.9992	0.0572
	$L_{R_{aGAN}} + L_1 + L_P$	<b>0.7227</b>	<b>0.9976</b>	<b>0.9955</b>	<b>0.5281</b>	<b>0.9993</b>	<b>0.0561</b>

此外,在不同数据集上,对使用不同损失函数的重建方法进行可视化对比实验,多光谱图像显示 R,G,B 3 个通道,实验结果如图 6 所示。图 6 展示了 GaoFen-2 数据集的 BlurLRMS 图像、GrayPAN 图像、参考 HRMS 图像,以及采用不同优化器组合方式重建的 HRMS 图像。可以看出,采用  $L_{GAN} + L_1$  损失函数重建出的图像存在着图像较为平滑、视觉感受差、部分细节重建效果差等问题。使用  $L_{GAN} + L_1 + L_P$

损失函数的方法重建出的 HRMS 图像蕴含着丰富的纹理信息,但局部仍存在轻微的光谱失真现象,如局部放大图所示。使用了  $L_{R_{aGAN}} + L_1$  损失函数的全色锐化方法重建图像的整体效果较好,存在些许视觉效果差的问题。由于加入了感知损失,使用 PAN-GAN 网络重建的图像在光谱信息与空间细节等方面效果较好,且与参考图像具有较高相似度,也验证了该优化器在遥感图像锐化方面的有效性。




图 6 GF-2 数据集中使用不同损失函数的重建图像

Fig. 6 Reconstructed images of different methods on GF-2 dataset

### 3.5 参数对比实验

为探究模型不同参数对 PAN-GAN 网络性能的影响,实验中该模型采用不同的参数设置,具体调节的参数为参考 HRMS 图像下采样方式和生成器卷积核大小,采用的评价指标为 SAM,CC,sCC,ERGAS 和  $Q_4$ 。

#### 3.5.1 参考图像下采样方式

为探究采样率对重建图像的影响,将实验数据集中采用不同下采样方式的参考 HRMS 图像作为 PAN-GAN 的输入,

包括平均下采样 (Mean-pooling)、最大化下采样 (Max-pooling) 和随机下采样 (Random-pooling) 方式,实验过程中,PAN-GAN 参数设置均与第 2 节中相同。实验结果如表 6 所列,由表可知,在实验数据集中使用平均下采样方式的模型性能最差。由于最大化下采样方式和随机下采样方式较平均下采样方式能保留更多的图像纹理细节,因此使用上述两种采样方式的模型性能接近。但是,在实验数据集中使用最大化下采样方式的模型得到的重建图像在所有指标上均优于对比

方法,因此 PAN-GAN 选用该下采样方式进行实验。

表 6 不同下采样方式模型性能比较结果

Dataset	Methods	SAM	CC	sCC	ERGAS	$Q_4 \uparrow$
WV-2	Mean-pooling	0.7145	0.9970	0.9972	1.4521	0.9980
	Max-pooling	<b>0.7123</b>	<b>0.9985</b>	<b>0.9985</b>	<b>1.3024</b>	<b>0.9989</b>
	Random-pooling	0.7130	0.9982	0.9984	1.3090	0.9985
QB	Mean-pooling	1.2001	0.9952	0.9948	0.8012	0.9955
	Max-pooling	<b>1.1842</b>	<b>0.9964</b>	<b>0.9957</b>	<b>0.7804</b>	<b>0.9960</b>
	Random-pooling	1.1901	0.9960	0.9952	0.7895	0.9956
GF-2	Mean-pooling	0.8122	0.9970	0.9946	0.6032	0.9975
	Max-pooling	<b>0.7227</b>	<b>0.9976</b>	<b>0.9955</b>	<b>0.5281</b>	<b>0.9993</b>
	Random-pooling	0.7250	0.9970	0.9949	0.5299	0.9988

### 3.5.2 卷积核大小

为探究生成器中卷积核大小对模型性能的影响,对生成器中的卷积核进行相关实验,实验过程为将生成器网络中所有  $3 \times 3$  卷积核替换为  $5 \times 5$  和  $7 \times 7$ 。实验过程中,除卷积核大小改变外,其余参数均与 PAN-GAN 相同。实验结果如表 7 所列。从表中可以看出,改变卷积核后,相关性指标并未发生明显变化,考虑到实验条件及训练时间和空间复杂度等因素,在生成器中选择卷积核的大小为  $3 \times 3$ 。

表 7 生成器使用不同规格卷积核的模型性能比较结果

Table 7 Performance comparison of generator with different convolutional kernels

Dataset	Methods	SAM	CC	sCC	ERGAS	$Q_4 \uparrow$
WV-2	$5 \times 5$	0.7138	0.9984	0.9980	1.3096	0.9980
	$7 \times 7$	0.7145	0.9983	0.9982	1.3110	0.9988
	$3 \times 3$	<b>0.7123</b>	<b>0.9985</b>	<b>0.9985</b>	<b>1.3024</b>	<b>0.9989</b>
QB	$5 \times 5$	1.1956	0.9958	0.9955	0.7830	0.9955
	$7 \times 7$	1.2001	0.9960	<b>0.9960</b>	0.7815	0.9952
	$3 \times 3$	<b>1.1842</b>	<b>0.9964</b>	0.9957	<b>0.7804</b>	<b>0.9960</b>
GF-2	$5 \times 5$	0.7411	0.9970	0.9948	0.5353	0.9950
	$7 \times 7$	0.7401	0.9965	0.9950	0.5560	0.9989
	$3 \times 3$	<b>0.7227</b>	<b>0.9976</b>	<b>0.9955</b>	<b>0.5281</b>	<b>0.9993</b>

### 3.6 模型整体性能评估

为验证 PAN-GAN 在重建图像质量方面的有效性,将其与目前主流的图像融合模型进行性能比较,主要包括两种传统锐化方法(Brovey 算法<sup>[4]</sup>和 HSV 算法<sup>[5]</sup>)以及 3 种基于深度学习的方法(PNN<sup>[10]</sup>, PanNet<sup>[12]</sup>和 PSGAN<sup>[21]</sup>)。比较结果如表 8 所列,  $\uparrow$  表示该评价指标与模型性能成正比,即指标值越大代表模型生成的图像越好,反之亦然。同时,在表 8 中对最佳实验结果进行加粗表示。

表 8 不同数据集上模型性能比较结果

Table 8 Performance comparison on various datasets

Dataset	Methods	SAM(inf-0)	CC(0-1)	sCC(0-1)	ERGAS(inf-0)	$Q_4 \uparrow$	LPIPS $\downarrow$
WV-2	Brovey	1.4023	0.9896	0.9890	3.1459	0.9891	0.3127
	HSV	1.4022	0.9895	0.9893	3.1017	0.9900	0.3001
	PNN	1.4746	0.9955	0.9950	2.1630	0.9951	0.2018
	PanNet	0.9810	0.9966	0.9966	1.8530	0.9964	0.1934
	PSGAN	0.9127	0.9973	0.9975	1.6452	0.9971	0.1701
	PAN-GAN	<b>0.7123</b>	<b>0.9985</b>	<b>0.9985</b>	<b>1.3024</b>	<b>0.9989</b>	<b>0.1087</b>
QB	Brovey	1.8421	0.9629	0.9628	2.0563	0.9735	0.3021
	HSV	1.8324	0.9685	0.9685	2.5006	0.9632	0.2987
	PNN	1.6100	0.9721	0.9738	1.8792	0.9786	0.1721
	PanNet	1.2884	0.9889	0.9889	1.3839	0.9862	0.1638
	PSGAN	1.2048	0.9899	0.9890	0.9704	0.9939	0.1424
	PAN-GAN	<b>1.1842</b>	<b>0.9964</b>	<b>0.9957</b>	<b>0.7804</b>	<b>0.9960</b>	<b>0.1023</b>
GF-2	Brovey	1.4301	0.9789	0.9789	2.9327	0.9900	0.2321
	HSV	1.4379	0.9703	0.9703	2.9899	0.9891	0.2729
	PNN	1.3023	0.9803	0.9802	1.7330	0.9952	0.1836
	PanNet	0.9891	0.9836	0.9836	1.4530	0.9958	0.1827
	PSGAN	0.9275	0.9853	0.9891	1.2065	0.9961	0.1523
	PAN-GAN	<b>0.7227</b>	<b>0.9976</b>	<b>0.9955</b>	<b>0.5281</b>	<b>0.9993</b>	<b>0.0561</b>

由表可知,由于深度学习较传统方法特征提取能力更好,因此基于深度学习的算法在不同数据集上的性能整体优于传统方法。由于 PanNet 使用具有较强特征提取

能力的残差网络结构,因此其在所有实验数据集均具有比 PNN 更佳的性能指标值,但其仍然存在重建图像模糊的问题(见图 7)。




图 7 WV-2 数据集上不同模型重建图像可视化结果

Fig. 7 Visualization of reconstructed images on WV-2 dataset

与上述算法相比,PSGAN 使用 GAN 网络,其生成对抗的训练过程使其具有比卷积神经网络更好的特征提取能力,性能优于 PanNet。但由于未充分考虑感知损失和空间信息

严重缺失等问题,PSGAN 的重建图像仍存在图像边缘平滑等问题。本文提出的 PAN-GAN 网络在所有指标上均具有最佳性能,这也说明充分考虑感知损失和空间信息的重要性。

此外,在图 7 中,针对不同对比方法的重建图像进行可视化分析,从图中可以看出,由于对上述因素的考虑,与对比方法相比,PAN-GAN 重建的图像也具有较对比方法更佳的视觉效果。具体而言,其具有更加锐化的边缘和纹理细节,以及更多空间细节,尤其是在局部放大图区域,这也说明了 PAN-GAN 在图像融合方面的有效性。

### 3.7 模型应用

为探究 PAN-GAN 的实际应用能力,在 WV-2 数据上将原始 LRMS 图像和全色 PAN 图像作为模型输入进行对比实验,由生成器构建融合图像,得到高分辨率多光谱图像,对比方法的选择与 3.6 节相同。由于实验结果无参考图像,因此选用光谱指标  $D_\lambda$ 、空间指标  $D_s$  和无参考质量评价指标, QNR 对重建结果进行量化分析<sup>[39]</sup>,其中,  $D_\lambda$  和  $D_s$  分别用来量化光谱失真与空间失真,取值范围为  $[0, 1]$ ,且其值越大越好; QNR 指标越高代表重建图像质量越好。实验结果如表 9 所列,由表 9 可得,PAN-GAN 在所有数据集上均优于其他方法。此外,图 8 给出了 WV-2 数据集上的重建图像可视化结果,从图中可以看出,PAN-GAN 重建的图像较对比方法有更丰富的空间特征和纹理细节,这也说明了该模型在实际应用中的优越性能。

表 9 模型实际应用性能比较结果

Table 9 Comparison of practical application performance of different models

Dataset	Methods	$D_\lambda \downarrow$	$D_s \downarrow$	QNR $\uparrow$
WV-2	Brovey	0.0250	0.0201	0.9554
	HSV	0.0206	0.0178	0.9620
	PNN	0.0095	0.0120	0.9786
	PanNet	0.0060	0.0122	0.9819
	PSGAN	0.0025	0.0060	0.9915
	PAN-GAN	0.0022	0.0045	0.9933

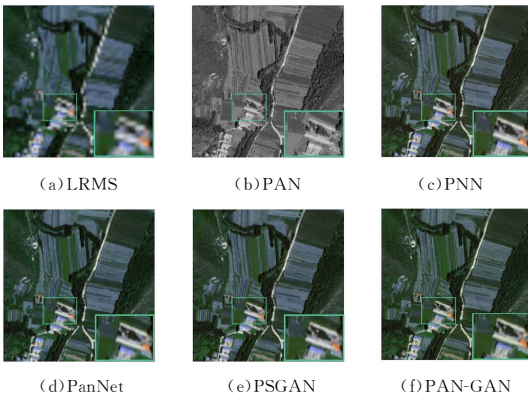


图 8 WV-2 数据集上重建图像对比结果

Fig. 8 Reconstructed images of different methods on WV-2 dataset

**结束语** 本文提出了基于 GAN 网络的遥感图像融合模型 PAN-GAN,一方面,使用 GrayPAN 图像作为输入得到更多空间信息;另一方面,在优化器中引入感知损失优化重构结果得到光谱和纹理细节清晰的融合图像,并使用融合 RaGAN 损失、像素损失和感知损失的优化器优化生成器和判别器。本文实验在 QB、GF-2 和 WV-2 数据集上进行,实验结果表明,PAN-GAN 网络在不同评价指标上均具有最佳效果,且可视化实验结果也表明该网络产生的融合图像具有更多的

空间特征和光谱特征。同时,实验结果也表明 PAN-GAN 可以有效提高生成图像的质量和视觉效果。

在未来的工作中,将进一步考虑优化器中不同的特征及其相关关系,提高优化器的优化能力,从而增加更多特征来增强模型细节特征重构的能力,以达到更好的融合效果。

### 参考文献

- [1] WANG X, YONG L, JIANG Z. An IHS Fusion Method based on Structural Similarity[J]. Remote Sensing Technology and Application, 2011, 26(5): 670-676.
- [2] PING S, LEI D, JUAN N. Multi-scale Remote Sensing Image Fusion Method based on Region Segmentation[J]. Remote Sensing Technology and Application, 2013, 27(6): 844-849.
- [3] ZENG D, HU Y, HUANG Y, et al. Pan-sharpening with structural consistency and 1/2 gradient prior[J]. Remote Sensing Letters, 2016, 7(12): 1170-1179.
- [4] GILLESPIE A R, KAHLE A B, WALKER R E. Color enhancement of highly correlated images. II. Channel ratio and "chromaticity" transformation techniques[J]. Remote Sensing of Environment, 1987, 22(3): 343-365.
- [5] PADWICK C, DESKEVICH M, PACIFICI F, et al. WorldView-2 pan-sharpening[C]// Proceedings of the ASPRS 2010 Annual Conference. San Diego, CA, USA, 2010: 1-14.
- [6] FENG J, ZEREN L, XIA C, et al. Remote sensing image fusion method based on PCA and NSCT transform[J]. Journal of Graphics, 2017, 38(2): 247-252.
- [7] RAHMANI S, STRAIT M, MERKURJEV D, et al. An adaptive IHS pan-sharpening method[J]. IEEE Geoscience and Remote Sensing Letters, 2010, 7(4): 746-750.
- [8] LIU J, LI X, ZHU K, et al. Distributed Compressed Sensing Based Remote Sensing Image Fusion Algorithm[J]. Journal of Electronics & Information Technology, 2017, 39(10): 2374-2381.
- [9] RANCHIN T, WALD L. Fusion of high spatial and spectral resolution images: The ARSIS concept and its implementation[J]. Photogrammetric Engineering and Remote Sensing, 2000, 66(1): 49-61.
- [10] GIUSEPPE M, DAVIDE C, LUISA V, et al. Pansharpening by Convolutional Neural Networks[J]. Remote Sensing, 2016, 8(7): 594.
- [11] SCARPA G, VITALE S, COZZOLINO D. Target-adaptive CNN-based pansharpening[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(9): 5443-5457.
- [12] YANG J, FU X, HU Y, et al. PanNet: A Deep Network Architecture for Pan-Sharpener[C]// 2017 IEEE International Conference on Computer Vision (ICCV). IEEE, 2017: 5448-5457.
- [13] DONG W Q, ZHANG T Z, QU J H, et al. Laplacian Pyramid Dense Network for Hyperspectral Pansharpening[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, (60): 1-13.
- [14] LEI D J, DU J H, ZHANG L P, et al. Multi-stream Architecture and Multi-scale Convolutional Neural Network for Remote Sensing Image Fusion[J]. Journal of Electronics & Information

- Technology,2022,44(1):8.
- [15] AZARANG A,MANOOCHEHRI H E,KEHTARNAVAZ N. Convolutional autoencoder-based multispectral image fusion[J]. IEEE Access,2019,7:35673-35683.
- [16] WANG L,YANG X M. Remote Sensing Image Pansharpening Feedback Network Based on Perceptual Loss [J]. Computer Science,2021,48(8):91-98.
- [17] GOODFELLOW I,POUGET-ABADIE J,MIRZA M,et al. Generative Adversarial Nets[C]//Proceedings of the 27th International Conference on Neural Information Processing Systems-Volume 2. 2014:2672-2680.
- [18] DONG W Q,HOU S X,XIAO S,et al. Generative Dual-Adversarial Network With Spectral Fidelity and Spatial Enhancement for Hyperspectral Pansharpening [J]. IEEE Transactions on Neural Networks and Learning Systems,2021 (99):1-15.
- [19] YANG J,LI W J,WANG W G,et al. Generative adversarial network for image super-resolution combining perceptual loss[J]. Journal of Image and Graphics,2019,24(8):1270-1282.
- [20] MA J,XU H,JIANG J,et al. DDcGAN: A dual-discriminator conditional generative adversarial network for multi-resolution image fusion[J]. IEEE Transactions on Image Processing,2020,29:4980-4995.
- [21] LIU Q,ZHOU H,XU Q,et al. PSGAN: A generative adversarial network for remote sensing image pan-sharpening[J]. IEEE Transactions on Geoscience and Remote Sensing,2020,59(12):10227-10242.
- [22] OZCELIK F,ALGANCI U,SERTEL E,et al. Rethinking CNN-based pansharpening: Guided colorization of panchromatic images via GANs[J]. IEEE Transactions on Geoscience and Remote Sensing,2020,59(4):3486-3501.
- [23] WALD L. Quality of high resolution synthesised images: Is there a simple criterion? [C]//Proceedings of the Third Conference "Fusion of Earth Data: Merging Point Measurements, Raster Maps and Remotely Sensed Images". 2000:99-103.
- [24] JOLICOEUR-MARTINEAU A. The relativistic discriminator: a key element missing from standard GAN [J]. arXiv: 1807.00734,2018.
- [25] LIN M,CHEN Q,YAN S. Network in network [J]. arXiv: 1312.4400,2013.
- [26] NAIR V,HINTON G E. Rectified Linear Units Improve Restricted Boltzmann Machines Vinod Nair[C]//Proceedings of the 27th International Conference on Machine Learning (ICML-10). Haifa,Israel,2010:807-814.
- [27] XU B,WANG N,CHEN T,et al. Empirical evaluation of rectified activations in convolutional network [J]. arXiv: 1505.00853,2015.
- [28] ISOLA P,ZHU J Y,ZHOU T,et al. Image-to-image translation with conditional adversarial networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu,HI,USA;IEEE Press,2017:1125-1134.
- [29] YUHAS R H,GOETZ A F,BOARDMAN J W. Discrimination among semi-arid landscape endmembers using the spectral angle mapper (SAM) algorithm[C]//Proceedings of the JPL, Summaries of the Third Annual JPL Airborne Geoscience Workshop Volume 1: AVIRIS Workshop. 1992:147-149.
- [30] ZHOU J,CIVCO D L,SILANDER J. A wavelet transform method to merge Landsat TM and SPOT panchromatic data[J]. International Journal of Remote Sensing,1998,19(4):743-757.
- [31] WANG Z,BOVIK A C. A universal image quality index[J]. IEEE Signal Processing Letters,2002,9(3):81-84.
- [32] ZHANG R,ISOLA P,EFROS A A,et al. The unreasonable effectiveness of deep features as a perceptual metric[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018:586-595.
- [33] ALPARONE L,AIAZZI B,BARONTI S,et al. Multispectral and Panchromatic Data Fusion Assessment Without Reference [J]. Photogrammetric Engineering & Remote Sensing, 2008,74(2):193-200.



**YAN Yan**, born in 1996, master candidate. Her main research interests include deep learning and image processing.



**SUI Yi**, born in 1984, Ph. D, associate professor, master supervisor. Her main research interests include big data modeling and analysis, artificial intelligence and image processing.

(责任编辑:何杨)