

用于全色锐化的相对平均生成对抗网络

陈婷, 王松涛, 高涛, 刘梦尼, 陈友静

(长安大学信息工程学院, 710000, 西安)

摘要: 为解决全色锐化过程中对原图像特征提取不足导致融合结果细节信息易丢失,以及图像融合过程中因忽略不同区域的空间特征差异而导致信息冗余等问题,采用深度学习算法,提出一种用于全色锐化的相对平均生成对抗网络(Pan-RaGAN)。在生成器中利用改进的密集块结构对原图像进行特征提取,充分利用原图像各级特征,获取包含了更多细节信息的融合结果;提出基于空间注意力机制的特征细化模块,用于特征选择,可在保留有效高频信息的同时剔除冗余信息;利用图像重建模块将细化后的特征与上采样的低分辨率多光谱图像进行融合,以保持光谱信息;利用相对平均鉴别器改进网络的损失函数,进一步优化融合效果。在高分2号卫星和快鸟卫星图像数据集上的实验结果表明,与已有用于遥感图像全色锐化的生成对抗网络相比,Pan-RaGAN网络的光谱角映射指标平均降低了0.075,验证了Pan-RaGAN网络的有效性。

关键词: 全色锐化;图像融合;相对平均生成对抗网络;空间注意力机制;深度学习

中图分类号: TP391 **文献标志码:** A

DOI: 10.7652/xjtuxb202203006 **文章编号:** 0253-987X(2022)03-0054-11



OSID 码

A Relativistic Average Generative Adversarial Network for Pan-Sharpening

CHEN Ting, WANG Songtao, GAO Tao, LIU Mengni, CHEN Youjing

(School of Information Engineering, Chang'an University, Xi'an 710000, China)

Abstract: A relativistic average generative adversarial network for pan-sharpening (Pan-RaGAN) based on a deep learning algorithm is proposed to solve the problems that details of fusion result are easy to be lost due to insufficient feature extraction from original image in the pan-sharpening process and information redundancy is caused by ignoring spatial feature difference of different regions in image fusion process. Firstly, the improved dense block structure is utilized to extract the features of the original image in the generator, so as to make full use of the features from different layers of the original image and obtain better fusion results with more details. Secondly, a feature refinement module based on spatial attention mechanism is proposed for feature selection, which can make a better trade-off between retaining effective high-frequency information and eliminating redundant information. Furthermore, the image reconstruction module is utilized to fuse the refined features with the up-sampled low resolution multispectral images to preserve the spectral information. Finally, the relativistic average discriminator is utilized to improve the loss function of the network, and further optimize the fusion effect. Experimental results on Gao Fen-2 dataset and Quick Bird dataset and a comparison with the

收稿日期: 2021-06-28。 作者简介: 陈婷(1982—),女,副教授,硕士生导师;高涛(通信作者),男,教授,博士生导师。 基金项目: 国家重点研发计划资助项目(2019YFE0108300);国家自然科学基金资助项目(62001058);中央高校基本科研业务费专项资金资助项目(300102241201)。

网络出版时间: 2021-09-23

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1069.T.20210922.1059.004.html>

existing generative adversarial network for remote sensing image pan-sharpening show that the spectral angle mapper index of the proposed Pan-RaGAN network is reduced by 0.075 on average, which verifies the effectiveness of the proposed Pan-RaGAN network.

Keywords: pan-sharpening; image fusion; relativistic average generative adversarial network; spatial attention mechanism; deep learning

为充分利用不同传感器图像之间的互补特征,一些图像融合技术被相继提出^[1-3]。作为遥感图像融合的一种方式,全色锐化可将低空间分辨率的多光谱(LRMS)图像和高空间分辨率的全色(PAN)图像进行融合,从而获得高分辨率多光谱(HRMS)图像,目前已被广泛用于目标检测、土地覆盖分类^[4-5]等领域。然而,遥感卫星对地面同一区域拍摄时,仅能获得一对 LRMS 图像和 PAN 图像,导致遥感图像信息无法被充分利用。因此,如何通过图像融合来获得 HRMS 图像已经成为遥感图像处理领域的研究热点之一。

目前,全色锐化算法可大致分为 4 类^[6-7]。第 1 类是基于成分替代的全色锐化算法,最具有代表性的算法是基于强度色调饱和度(IHS)的全色锐化算法^[8]。该算法通过将原始多光谱图像从 RGB 空间转换到 IHS 空间,并使用 PAN 图像代替 IHS 空间的强度(intensity)分量,由此得到全色锐化图像。由于该变换只适用于三通道图像,Rahmani 等提出了 AIHS 算法,使该变换更适用于多通道图像^[9]。然而,基于成分替代的全色锐化算法普遍存在融合图像光谱失真的现象。第 2 类是基于多分辨率分析的全色锐化算法:King 等将小波变换用于全色锐化获得融合图像^[10];Liu J. 等提出了一种基于平滑滤波器的强度调制(SFIM)来调节注入的空间细节^[11]。但是,该类算法过于依赖图像配准的准确性。与第 1 类算法相比,基于多分辨率分析的算法能够有效保持光谱信息,但容易造成融合图像空间失真。第 3 类是基于变分模型的全色锐化算法,该类算法根据先验知识进行假设,并通过最优解得到融合结果。Tian 等提出了基于梯度稀疏表示的变分全色锐化算法,取得了良好的效果^[12]。然而,该类算法需要合理的假设,否则容易导致融合图像产生失真。第 4 类是基于深度学习的全色锐化算法。Masi 等提出了基于卷积神经网络的全色锐化算法(PNN)^[13],将 3 层简单超分辨率网络用于全色锐化,但该算法只是将全色锐化问题当作深度学习的一个黑盒子,缺乏合理的物理解释。为此,He 等将基于成分替代/基于多分辨率分析模型在一个统一

的细节注入框架中表示,使提出的网络结构具有明确的物理解释^[14]。然而,这种将原图像以堆叠方式输入网络的算法忽略了 LRMS 图像与 PAN 图像间的显著性差异,不利于特征提取。Liu X. 等利用两个 3 层子网络分别提取原图像的层次特征来获取 PAN 图像和 LRMS 图像之间的互补信息,并在特征维度对图像进行融合重建,使融合后的图像取得了良好的效果^[15]。Shao Z. F. 等利用两个不同深度的卷积层分别从 PAN 图像和 LRMS 图像中提取空间特征和光谱特征^[16]。另外,在深度学习算法中,由于对抗网络(GAN)能够生成现实中不存在的图像而被用于全色锐化^[17]。Liu Q. 等提出了 PS-GAN,首次将 GAN 用于全色锐化^[18]。在此基础上,Shao Z. M. 等提出了残差编解码器条件生成对抗网络(RED-cGAN),将自编码器与 GAN 相结合以保持光谱信息和空间信息^[19]。

虽然基于深度学习的全色锐化算法在全色锐化问题中取得了进展,但依然存在对原图像特征提取不充分而导致细节信息丢失,以及忽略了特征间的差异而导致特征冗余并产生融合失真的问题。针对这些问题,本文基于相对平均生成对抗网络(Ra-GAN)^[20]提出了一种用于全色锐化的相对平均生成对抗网络(Pan-RaGAN),融合后的图像具有更多的空间细节信息和光谱信息。

1 相关内容

1.1 相对平均生成对抗网络

GAN 的基本思想是通过生成器与鉴别器之间的对抗博弈使生成器生成足以以假乱真的假样本,网络结构如图 1 所示。




图 1 生成对抗网络结构
Fig. 1 Architecture of GAN

为解决 GAN 生成图像质量不高以及训练过程

不稳定的问题,一些 GAN 的变体被相继提出^[20-23]。相对平均鉴别器的使用有助于生成器恢复更真实的图像纹理细节,相对平均鉴别器的函数表达式为

$$D_{Ra}(x_r, x_f) = \sigma(S(x_r) - E_{x_f}[S(x_f)]) \rightarrow 1 \quad (1)$$

$$D_{Ra}(x_f, x_r) = \sigma(S(x_f) - E_{x_r}[S(x_r)]) \rightarrow 0 \quad (2)$$

式中: x_r 表示真实数据; x_f 表示生成器生成的数据; $S(x)$ 表示鉴别器网络的输出; $E[\cdot]$ 表示求平均值; σ 表示 Sigmoid 函数; $D_{Ra}(x_r, x_f)$ 表示真实数据比生成数据更真实的概率; $D_{Ra}(x_f, x_r)$ 表示生成数据比真实数据更真实的概率。此时,相对平均生成对抗网络的鉴别器损失函数 L_D^{Ra} 和生成器损失函数 L_G^{Ra} 分别表示为

$$L_D^{Ra} = -E_{x_r}[\ln(D_{Ra}(x_r, x_f))] - E_{x_f}[\ln(1 - D_{Ra}(x_f, x_r))] \quad (3)$$

$$L_G^{Ra} = -E_{x_r}[\ln(1 - D_{Ra}(x_r, x_f))] - E_{x_f}[\ln(D_{Ra}(x_f, x_r))] \quad (4)$$

1.2 特征提取

基于深度学习的全色锐化网络输入方式通常有堆叠的输入结构和两流输入结构这 2 种。PNN 使用堆叠的方式将 PAN 图像与 LRMS 图像进行堆叠,形成多通道图像作为网络输入。PSGAN 使用两流的 3 层结构作为网络输入,分别提取 PAN 图像与 LRMS 图像的特征。与堆叠的输入结构相比,两流输入结构虽然能够提升网络的性能,但由于网络结构简单,导致特征提取不足,如果通过增加网络

的深度来提取特征会造成网络训练困难等问题。Huang 等提出了一种密集块体系结构,在可以提取更多特征信息的同时改善了网络中的信息流和梯度,使网络易于训练^[24]。因此,本文提出使用密集块作为网络结构的特征提取模块。

1.3 注意力机制

注意力机制通过网络学习得到一组用于保留感兴趣特征的权重参数,同时能够抑制不必要的特征。陈一鸣等将注意力机制应用于低级视觉处理任务,并取得了成功^[25]。在全色锐化问题中,本文利用空间注意力机制对特征进行重新分配权重,从而获得了更多有用的细节信息作为融合图像的高频信息,有效地增强了细节信息的融合。Hu 等提出由两个卷积层构造的空间注意力单元(SA),其结构如图 2 所示^[26]。定义 C 表示图像的通道数, W 和 H 表示图像的宽和高, SA 中的卷积核尺度为 1×1 , 输出特征通道数分别为 $C \times n$ 和 1, n 为增加通道数的比例,本文设置为 2。若 $\mathbf{X}$ 是空间注意力模块的输入,尺寸为 $H \times W \times C$, 则空间注意力掩模 α 表示为

$$\alpha = \sigma(W^2 * \delta(W^1 * \mathbf{X} + \mathbf{b}^1) + \mathbf{b}^2) \quad (5)$$

式中: $*$ 和 δ 分别表示卷积运算和 ReLu 函数; $\mathbf{W}$ 和 $\mathbf{b}$ 表示网络的参数。将注意力掩模 α 与输入的特征 $\mathbf{X}$ 相乘得到空间注意力模块的输出 $\bar{\mathbf{X}}$

$$\bar{\mathbf{X}} = \alpha \cdot \mathbf{X} \quad (6)$$

式中: $\cdot$ 表示矩阵对应元素相乘; 输出特征 $\bar{\mathbf{X}}$ 与输入特征 $\mathbf{X}$ 具有相同的维度。




图 2 空间注意力单元结构

Fig. 2 Architecture of spatial attention unit

2 用于全色锐化的相对平均生成对抗网络

本文分别用 $\mathbf{M}$ 、 $\bar{\mathbf{M}}$ 、 $\mathbf{P}$ 、 $\mathbf{Y}$ 和 $\mathbf{R}$ 表示低分辨率多光谱图像、上采样的低分辨率多光谱图像、高分辨率全色图像、生成的融合图像和理想的高分辨率多光谱图像。 $\mathbf{M}$ 的尺寸为 $W \times H \times C$, $\mathbf{P}$ 的尺寸为 $rW \times rH$, $\bar{\mathbf{M}}$ 、 $\mathbf{Y}$ 和 $\mathbf{R}$ 的尺寸均为 $rW \times rH \times C$, r 为 $\mathbf{M}$ 与 $\mathbf{P}$ 的空间分辨率之比。

Pan-RaGAN 网络结构如图 3 所示,生成器网络包括特征提取、特征融合、特征细化和特征重建共

4 个部分,主要用于生成 HRMS 图像。鉴别器结构使用全卷积网络进行构建,主要用于判断图像是否为生成器生成的图像。

2.1 特征提取模块

由于 PAN 图像只含有一个较长波段范围的波段而 LRMS 图像由多个不同波长范围的波段组成(本文选用的 GF-2 卫星和 QB 卫星的 LRMS 图像具有 4 个通道),因此通常认为 PAN 图像具有丰富的空间信息,LRMS 图像具有更多的光谱信息。为充分利用原图像空间和光谱信息,Liu X. 等在两流输入结构中使用 3 层卷积网络来提取 PAN 图像与





图3 Pan-RaGAN 网络结构

Fig. 3 Architecture of Pan-RaGAN

LRMS 图像的互补信息^[15],这会导致对原图像特征提取不充分并最终影响融合效果。由于批归一化(BN)层在 GAN 网络训练下会产生伪影,缺少稳定性^[18],因此本文对密集块^[24]进行改进,剔除原密集块中的 BN 层,得到密集连接结构如图 4 所示。

在模块开始端输入原图像,将每个卷积层的输出都作为后面卷积层的输入,卷积层的输出特征表示为

$$x_i = \begin{cases} H_i(x_0), & i = 1 \\ H_i([x_1, \dots, x_{i-1}]), & i \neq 1 \end{cases} \quad (7)$$

式中: $H_i(\cdot)$ 表示 Conv-ReLu 运算; $[\cdot]$ 表示张量连接运算(concat); $i=\{1,2,\dots,K\}$ 表示第 i 个卷积层, K 表示卷积层总数,本文设置 $K=4$; x_i 表示第 i 个卷积层的输出特征; x_0 表示输入的图像。最终,得到改进的密集块输出为

$$F_{fe} = f_{DC}[x_1, \dots, x_K] \quad (8)$$

式中 f_{DC} 表示张量连接运算函数。

本文利用 DC 模块形成用于提取原图像特征的两流输入结构,如图 3a 中的 DC1 和 DC2 所示,通过这种输入结构尽可能多地利用原图像的中间层特征。两个密集块具有相同的结构不同的权值,由于 PAN 图像与 LRMS 图像具有不同的通道数量,因此密集块输入层的特征通道数分别为 1 和 4。

2.2 特征融合模块

为了将提取的特征进行融合,大多数算法使用张量连接将提取的特征进行拼接,然后送入下一卷积层进行处理,本文使用像素相加的融合策略将两个独立分支提取的 PAN 图像空间信息和 LRMS 图像光谱信息进行融合,该融合规则相比张量连接可以减少模型的参数。像素相加的融合策略可表示为

$$F_f = F_{fe}^1 + F_{fe}^2 \quad (9)$$

式中: F_{fe}^1 、 F_{fe}^2 分别为提取的 LRMS 图像特征和 PAN




图4 密集连接结构

Fig. 4 Architecture of dense connection

图像特征; F_l 为融合的特征。

2.3 特征细化模块

生成器网络的核心在于学习目标图像与LRMS图像之间的残差信息,这些残差信息主要包含图像的高频细节信息和少量的光谱信息,而特征提取融合后的信息对残差信息的构建具有不同的作用。为了从融合的特征中选择出PAN与LRMS图像的互补信息同时剔除冗余信息,本文通过特征细化模块对融合的特征重新分配权重,对残差信息构建贡献度较大的特征分配较大的权值,对残差信息构建贡献度较小的特征分配较小的权值,从而有效

地选择出高频信息。

由于叠加的残差块可以使神经网络表现得更好^[27],因此本文将注意力机制与残差块结合得到残差空间注意力模块(RSA),并使用 L 个RSA构成特征细化模块。图5是特征细化模块, F_{L-1} 是第 L 个RSA模块的输入,该输入先经过Conv-ReLu-Conv运算获得局部特征 X ,然后经过SA获得重新分配权重后的特征 $\bar{X}$,最后通过跳跃连接获得第 L 个RSA模块的输出特征,即

$$F_L = F_{L-1} + \bar{X} \quad (10)$$




图5 特征细化模块

Fig. 5 Module of feature refinement

2.4 图像重建模块

图像重建模块包含一个上采样层和一个卷积层,通过上采样层将细化的特征上采样到与目标图像相同的尺寸,卷积层输出理想图像与LRMS图像之间的残差,最后根据细节注入模型^[14],使用跳跃连接将上采样的LRMS图像与卷积层的输出相连接得到融合图像。

2.5 鉴别器结构

本文鉴别器由5层全卷积神经网络构成,如图3b所示。卷积滤波器的尺寸均为 3×3 。网络前3层卷积步长设置为2,等同于池化运算用于提取特征,最后两个卷积层步长设置为1。除最后一层使用Sigmoid函数用于预测图像的真实性外,其余4层均使用LeakyReLU激活函数。

2.6 损失函数

本文网络的损失函数包括生成器损失和鉴别器损失两个部分。生成器损失函数表示为

$$L_G = \alpha L_{adv} + \beta L_{cont} \quad (11)$$

式中: L_{cont} 为内容损失; α 和 β 为平衡参数,用于平衡对抗损失和内容损失,实验中分别设置为1和100^[18-19]; L_{adv} 表示生成器与鉴别器间的对抗损失,公式为

$$L_{adv} =$$

$$\frac{1}{N} \sum_{n=1}^N [-\ln(1 - D_{Ra}(\mathbf{R}, \mathbf{Y})) - \ln(D_{Ra}(\mathbf{Y}, \mathbf{R}))] \quad (12)$$

其中 N 表示训练样本数。

相比于 L_2 损失容易造成融合图像产生模糊现象^[13], L_1 损失则能较好地保持边缘细节信息^[18-19]。因此,本文使用 L_1 损失作为内容损失

$$L_{cont} = \frac{1}{N} \sum_{n=1}^N \|\mathbf{R} - \mathbf{Y}\|_1 \quad (13)$$

式中 $\|\cdot\|_1$ 表示 L_1 范数。

鉴别器损失函数表示为

$$L_D =$$

$$\frac{1}{N} \sum_{n=1}^N [-\ln(D_{Ra}(\mathbf{R}, \mathbf{Y})) - \ln(1 - D_{Ra}(\mathbf{Y}, \mathbf{R}))] \quad (14)$$

3 实验及结果分析

3.1 网络训练环境配置与参数设置

本文使用Tensorflow深度学习框架,在NVIDIA Quadro RTX 5000显卡上进行训练和测试。训练过程中使用Adam优化器,初始学习率为0.0002,动量为0.5,批量尺寸设置为32。

3.2 实验数据集与评价指标

本文使用GF-2卫星和QB卫星获取的图像作为网络的训练集与测试集。GF-2卫星拍摄的PAN图像与LRMS图像的空间分辨率分别为0.8和3.2m, QB卫星拍摄的PAN图像与LRMS图像的空间分辨率分别为0.6和2.4m。对原PAN图像与

LRMS 图像进行裁剪,得到 40 000 对 PAN 图像和 LRMS 图像作为训练集。

定量评估采用 5 种常用的低分辨率评价指标和 3 种全分辨率评价指标:低分辨率评价指标包括光谱角映射 (Γ)^[28]、相关系数 (T)、空间相关系数 (Z)^[29]、相对全局误差 (Δ)^[30]、平均通用图像质量指标 (Θ)^[31];全分辨率评价指标包括无参考质量指标 (Δ)^[32] 以及 QNR 中评价光谱细节损失的指标 (D_λ) 和评价空间细节损失的指标 (D_s)。

3.3 残差空间注意力模块数量的选择

考虑到不同数量的 RSA 模块会对网络的参数数量以及融合效果产生影响,本文在 GF-2 卫星数据集上对包含不同数量的 RSA 模块构成的网络进行实验,结果如图 6 所示,图中 L 表示 RSA 模块的数量。可以看出,不同的 L 对于指标 T 、 Z 和 Θ 影响较小,而对于指标 Γ 以及 Δ 则影响较大。当 $L=6$ 时,所有的指标均接近于最优值。考虑到计算效率和模型参数之间的平衡,实验中设置 RSA 模块的数量 $L=6$ 。




图 6 不同数量 RSA 模块构成的网络在 GF-2 卫星数据集上的指标均值对比

Fig. 6 Comparison of index mean values of networks with different number of RSA modules on GF-2 satellite datasets

3.4 视觉评估

本文对 GF-2 号卫星图像和 QB 卫星图像分别进行低分辨率测试和全分辨率测试。由于真实的 HRMS 图像并不存在,所以在对图像进行低分辨率实验时遵循 Wald 协议^[30],即将原始的 PAN 图像与 LRMS 图像均进行 4 倍的下采样,然后将原始的 LRMS 图像作为真实的 HRMS 图像。由于使用的卫星图像为不易直接显示的 4 通道(蓝、绿、红和近红外)图像,所以文中显示的图像都为 3 通道(红、绿、蓝)的真彩色图像。

图 7 和图 8 是不同算法对 GF-2 卫星和 QB 卫




图 7 不同算法对 GF-2 图像的低分辨率全色锐化结果
Fig. 7 Results of low resolution pan-sharpening of GF-2 images by different algorithms




图 8 不同算法对 QB 图像的低分辨率全色锐化结果
Fig. 8 Results of low resolution pan-sharpening of QB images by different algorithms

星的低分辨率图像全色锐化结果。可以看出,在图 7 中 SFIM^[11]、Wavelet^[10] 和 IHS^[8] 算法融合的图片偏白色,与真实的图像相比存在着光谱失真现象。另外,图 7c 和图 7d 出现严重伪影,造成不良的视觉效果。RED-cGAN^[19]、PSGAN^[18] 以及本文算法融合的图像则能够保持与真实图像相似的光谱信息。但是,在放大区域中,与图 7f 和图 7g 相比,图 7h 中包含更多的建筑物缝隙细节,因此本文算法的融合结果可以保持更多的细节信息,同时减少了光谱失真。从图 8 可以看出: SFIM^[11]、Wavelet^[10] 和 IHS^[8] 算法保持的纹理细节信息接近于 PAN 图像,然而由于基于成分替代以及多分辨率的算法未能合

理地向上采样的 LRMS 图像中注入空间细节信息,导致融合图像产生失真现象; RED-cGAN^[19]、PSGAN^[18] 以及本文的算法则可以更好地保持光谱信息;另外,从图 8f、8g 和 8h 中的红色方框区域可以看出,本文算法可以保持更多的细节信息。

图 9 和图 10 是不同算法对 GF-2 卫星和 QB 卫星的全分辨率图像全色锐化结果。可以看出,图 9c~9e 表现出不同程度的光谱失真,其颜色偏暗,与上采样的 LRMS 图像光谱信息差距较大,图 9f、9g、9h 与上采样的 LRMS 图像具有相似的光谱信息,图 9h 的空间结构保持效果优于图 9f 和 9g。在图 10 中的放大区域中,图 10d 和 10e 存在失真现象,这与在低分




图 9 不同算法对 GF-2 图像的全分辨率全色锐化结果

Fig. 9 Results of full resolution pan-sharpening of GF-2 images by different algorithms




图 10 不同算法对 QB 图像的全分辨率全色锐化结果

Fig. 10 Results of full resolution pan-sharpening of QB images by different algorithms

分辨率下的融合结果一致。另外,图 10c、10d、10g 出现的伪影造成了不良的视觉效果,相比图 10f,本文算法的融合结果具有良好的空间结构。综合可知,本文算法在 GF-2 卫星图像和 QB 卫星图像的全分辨率融合效果以及低分辨率融合效果都优于其他算法。

3.5 定量评估

由于视觉评估受主观因素影响较大,因此本文对 GF-2 卫星数据和 QB 卫星数据实验结果进行了定量实验,结果如表 1 和表 2 所示。可以看出,对于低分辨率评价指标,基于深度学习的算法优于传统算法。由于 Pan-RaGAN 根据细节注入模型将学习到的细节注入到上采样的 LRMS 图像,因此本文算

法的 I^* 获得了很大的提升;本文算法 T 较好,表明本文算法可以获得与理想图像更接近的效果。这与定性实验中的结果相符合,进一步说明了本文算法在低分辨率下测试结果的有效性。对于全分辨率参考评价指标,表 1 中本文算法在客观评价指标 D_s 上虽然没有取得最好的结果,但是从主观评价图 9 中可以看出,本文算法依然取得了良好的效果。在表 2 中,由于全分辨率评价指标将 PAN 图像和 LRMS 图像作为参考,而 IHS^[8] 算法使用 PAN 图像替换 LRMS 图像的空间成分,使得融合后的图像具有与 PAN 图像相似的细节信息,因此 IHS^[8] 算法获得了比本文算法更好的 D_λ 。

表 1 不同算法在 GF-2 数据集上的定量比较

Table 1 Quantitative comparison of different algorithms on GF-2 dataset

算法	低分辨率评价指标					全分辨率评价指标		
	I^*	T	Z	Δ	Θ	Δ	D_λ	D_s
SFIM	1.726 0	0.871 1	0.948 6	2.934 6	0.970 9	0.976 1	0.013 8	0.010 3
IHS	1.695 5	0.847 0	0.937 4	2.924 2	0.971 6	0.931 0	0.018 3	0.051 6
Wavelet	1.742 7	0.862 3	0.956 1	2.874 9	0.971 8	0.972 3	0.021 6	0.006 2
RED-cGAN	0.739 3	0.992 1	0.993 1	0.672 9	0.998 5	0.984 3	0.012 3	0.003 4
PSGAN	0.740 3	0.992 2	0.993 0	0.671 9	0.998 5	0.982 7	0.012 6	0.004 8
本文算法	0.665 3	0.993 6	0.994 5	0.589 6	0.998 8	0.987 5	0.001 9	0.010 6
理想值	0	1.000 0	1.000 0	0	1.000 0	1.000 0	0	0

注:表中加粗数据为最优值。

表 2 不同算法在 QB 数据集上的定量比较

Table 2 Quantitative comparison of different algorithms on QB dataset

算法	低分辨率评价指标					全分辨率评价指标		
	I^*	T	Z	Δ	Θ	Δ	D_λ	D_s
SFIM	1.565 5	0.951 6	0.968 7	2.508 4	0.949 5	0.977 3	0.004 9	0.017 9
IHS	1.678 4	0.965 6	0.978 3	1.883 3	0.968 9	0.971 3	0.002 1	0.026 6
Wavelet	1.863 3	0.950 1	0.975 8	2.392 0	0.907 6	0.975 1	0.008 8	0.016 3
RED-cGAN	1.357 2	0.985 2	0.984 5	1.326 5	0.984 5	0.980 9	0.005 1	0.014 1
PSGAN	1.333 2	0.987 2	0.986 9	1.236 9	0.986 9	0.962 5	0.018 1	0.019 8
本文算法	1.175 8	0.987 5	0.988 4	1.206 7	0.987 1	0.983 1	0.003 0	0.014 0
理想值	0	1.000 0	1.000 0	0	1.000 0	1.000 0	0	0

注:表中加粗数据为最优值。

3.6 相对平均鉴别器与条件鉴别器

由于 PSGAN 使用条件鉴别器损失函数获得了良好的效果,因此本文在网络中分别使用条件鉴别器损失函数和相对平均鉴别器损失函数构成 Pan-cGAN 网络以及 Pan-RaGAN 网络,并在 GF-2 卫星数据集进行训练和测试,以验证相对平均鉴别器损失函数的有效性,实验结果如图 11 所示。可以看

出,与 Pan-cGAN 的融合结果相比,本文算法的融合结果包含更多的细节信息。图 11 中黄色方框内,本文算法的结果更接近理想 HRMS 图像,而 Pan-cGAN 融合结果则出现空间细节模糊。

表 3 是使用相对平均鉴别器与条件鉴别器的全色锐化定量结果。可以看出,本文算法在低分辨率下的定量评价指标均优于 Pan-cGAN 的,进一步说



(a)Pan-cGAN (b)本文算法 (c)理想图像

图 11 使用相对平均鉴别器与条件鉴别器的全色锐化对比
Fig. 11 Contrast of pan-sharpening results between relative average discriminator and conditional discriminator

明了相对平均鉴别器损失函数的有效性。事实上，当使用相对平均鉴别器时，生成器损失函数受到理想 HRMS 图像和生成 HRMS 图像的共同作用，但是在条件对抗网络中，生成器损失函数只受生成 HRMS 图像的影响。因此，通过相对平均鉴别器可以提高融合图像与理想的 HRMS 图像之间的相似性。

表 3 使用相对平均鉴别器与条件鉴别器的全色锐化定量结果

Table 3 Quantitative results of pan-sharpening using relative average discriminator and conditional discriminator

算法	Γ	T	Z	Δ	Θ
Pan-cGAN	0.726 3	0.992 3	0.993 2	0.647 3	0.998 5
本文算法	0.665 3	0.993 6	0.994 5	0.589 6	0.998 8
理想值	0	1.000 0	1.000 0	0	1.000 0

注：表中加粗数据为最优值。

4 结 论

本文提出一种用于全色锐化的相对平均生成对抗网络，与现有算法相比，本文算法在主客观评价上均取得了良好的结果，可获得包含更丰富细节信息和光谱信息的融合图像。本文结论如下。

(1)改进的密集块结构和空间注意力机制能够提高融合图像的空间分辨率，同时保持光谱信息。在 QB 数据集上，本文算法的 Γ 比 PSGAN 算法的小 0.157 4， Δ 比 PSGAN 算法的大 0.020 6。

(2)在网络结构与参数相同的情况下，相对平均鉴别器损失函数与条件鉴别器损失函数相比，能更好地保持图像的细节信息。在 GF-2 数据集上，使用相对平均鉴别器损失函数的 Γ 和 Δ 比使用条件鉴别器损失函数的 Γ 和 Δ 分别小 0.061 和 0.057 7。

(3)虽然本文算法在全色锐化中取得了良好效果，但仍然存在泛化性不强的问题。下一步将探讨深度学习算法与传统算法的结合，进一步提高算法的泛化能力。

参考文献：

[1] 高雪琴,刘刚,肖刚,等. 基于 FPDE 的红外与可见光图像融合算法 [J]. 自动化学报, 2020, 46(4): 796-804.
GAO Xueqin, LIU Gang, XIAO Gang, et al. Fusion algorithm of infrared and visible images based on FP-DE [J]. Acta Automatica Sinica, 2020, 46(4): 796-804.

[2] 刘锐,赵旭,赵东利,等. 基于 MIM 软件行 CT-MRI 图像融合技术在脑胶质瘤精确放疗中的应用 [J]. 西安交通大学学报(医学版), 2020, 41(5): 668-672.
LIU Rui, ZHAO Xu, ZHAO Dongli, et al. Application of CT-MRI image fusion technology based on MIM software in accurate radiotherapy of glioma [J]. Journal of Xi'an Jiaotong University (Medical Sciences), 2020, 41(5): 668-672.

[3] 陈超迁,孟勇,杨平吕,等. 基于边缘增强与光谱特性保持的 Pan-sharpening 融合模型 [J]. 自动化学报, 2019, 45(2): 374-387.
CHEN Chaoqian, MENG Yong, YANG Pinglv, et al. Pan-sharpening model on account of edge enhancement and spectral signature preservation [J]. Acta Automatica Sinica, 2019, 45(2): 374-387.

[4] 李策,张亚超,蓝天,等. 一种高分辨率遥感图像视觉感知目标检测算法 [J]. 西安交通大学学报, 2018, 52(6): 9-16.
LI Ce, ZHANG Yachao, LAN Tian, et al. An object detection algorithm with visual perception for high-resolution remote sensing images [J]. Journal of Xi'an Jiaotong University, 2018, 52(6): 9-16.

[5] TONG Xinyi, LU Qikai, XIA Guisong, et al. Large-scale land cover classification in Gaofen-2 satellite imagery [C]// Proceedings of the 2018 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Piscataway, NJ, USA: IEEE, 2018: 3599-3602.

[6] LIU Yu, CHEN Xun, WANG Zengfu, et al. Deep learning for pixel-level image fusion: recent advances and future prospects [J]. Information Fusion, 2018, 42: 158-173.

[7] MENG Xiangchao, SHEN Huanfeng, LI Huifang, et al. Review of the pansharpening methods for remote sensing images based on the idea of meta-analysis: practical discussion and challenges [J]. Information Fusion, 2019, 46: 102-113.

[8] CARPER W J, LILLESAND T M, KIEFER R W. The use of intensity-hue-saturation transformations for merging SPOT panchromatic and multispectral image

- data [J]. Photogrammetric Engineering and Remote Sensing, 1990, 56(4): 459-467.
- [9] 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.
 - [10] KING R L, WANG Jianwen. A wavelet based algorithm for pan sharpening Landsat 7 imagery [C]//Proceedings of the 2001 International Geoscience and Remote Sensing Symposium (IGARSS). Piscataway, NJ, USA; IEEE, 2001: 849-851.
 - [11] LIU J G. Smoothing filter-based intensity modulation: a spectral preserve image fusion technique for improving spatial details [J]. International Journal of Remote Sensing, 2000, 21(18): 3461-3472.
 - [12] TIAN Xin, CHEN Yuerong, YANG Changcai, et al. A variational pansharpening method based on gradient sparse representation [J]. IEEE Signal Processing Letters, 2020, 27: 1180-1184.
 - [13] MASI G, COZZOLINO D, VERDOLIVA L, et al. Pansharpening by convolutional neural networks [J]. Remote Sensing, 2016, 8(7): 594.
 - [14] HE Lin, RAO Yizhou, LI Jun, et al. Pansharpening via detail injection based convolutional neural networks [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2019, 12(4): 1188-1204.
 - [15] LIU Xiangyu, LIU Qingjie, WANG Yunhong. Remote sensing image fusion based on two-stream fusion network [J]. Information Fusion, 2020, 55: 1-15.
 - [16] SHAO Zhenfeng, CAI Jiajun. Remote sensing image fusion with deep convolutional neural network [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2018, 11(5): 1656-1669.
 - [17] GASTINEAU A, AUJOL J F, BERTHOUMIEU Y, et al. Generative adversarial network for pansharpening with spectral and spatial discriminators [J/OL]. IEEE Transactions on Geoscience and Remote Sensing, 2021 [2021-05-01]. <https://ieeexplore.ieee.org/document/9371303>.
 - [18] LIU Qingjie, ZHOU Huanyu, XU Qizhi, et al. PS-GAN: a generative adversarial network for remote sensing image pan-sharpening [J/OL]. IEEE Transactions on Geoscience and Remote Sensing, 2020 [2021-05-01]. <https://ieeexplore.ieee.org/document/9306912>.
 - [19] SHAO Zhimin, LU Zexin, RAN Maosong, et al. Residual encoder-decoder conditional generative adversarial network for pansharpening [J]. IEEE Geoscience and Remote Sensing Letters, 2020, 17(9): 1573-1577.
 - [20] JOLICOEUR-MARTINEAU A. The relativistic discriminator: a key element missing from standard GAN [C/OL]//Proceedings of the 2019 International Conference on Learning Representations. London, UK; ICLR, 2019 [2021-05-01]. <https://arxiv.org/pdf/1807.00734.pdf>.
 - [21] WANG Xintao, YU Ke, WU Shixiang, et al. ESR-GAN: enhanced super-resolution generative adversarial networks [C]//Proceedings of the 2018 ECCV Workshops. Cham, Germany; Springer, 2019: 63-79.
 - [22] MA Jiayi, YU Wei, CHEN Chen, et al. Pan-GAN: an unsupervised pan-sharpening method for remote sensing image fusion [J]. Information Fusion, 2020, 62: 110-120.
 - [23] ZHOU Huanyu, LIU Qingjie, WANG Yunhong. PG-MAN: an unsupervised generative multiadversarial network for pansharpening [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2021, 14: 6316-6327.
 - [24] HUANG Gao, LIU Zhuang, VAN DER MAATEN L, et al. Densely connected convolutional networks [C]//Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA; IEEE, 2017: 2261-2269.
 - [25] 陈一鸣, 周登文. 基于自适应级联的注意力网络的超分辨重建 [J/OL]. 自动化学报, 2020 [2021-05-01]. <https://doi.org/10.16383/j.aas.c200035>.
CHEN Yiming, ZHOU Dengwen. Adaptive attention network for image super-resolution [J/OL]. Acta Automatica Sinica, 2020 [2021-05-01]. <https://doi.org/10.16383/j.aas.c200035>.
 - [26] HU Yanting, LI Jie, HUANG Yuanfei, et al. Channel-wise and spatial feature modulation network for single image super-resolution [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2020, 30(11): 3911-3927.
 - [27] LIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution [C]//Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Piscataway, NJ, USA; IEEE, 2017: 1132-1140.
 - [28] YUHAS R H, GOETZ A F H, BOARDMAN J W. Discrimination among semi-arid landscape endmembers

- using the spectral angle mapper (SAM) algorithm [C] // Proceedings of the Summaries of the Third Annual JPL Airborne Geoscience Workshop. Pasadena, CA, USA: JPL, 1992: 147-149.
- [29] ZHOU J, CIVCO D L, SILANDER J A. A wavelet transform method to merge Landsat TM and SPOT panchromatic data [J]. International Journal of Remote Sensing, 1998, 19(4): 743-757.
- [30] 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". Sophia Antipolis, France: SEE/URISCA, 2000: 99-103.
- [31] WANG Zhou, BOVIK A C. A universal image quality index [J]. IEEE Signal Processing Letters, 2002, 9(3): 81-84.
- [32] 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.
- (编辑 陶晴 刘杨)