

基于匹配提取和跨尺度特征融合网络的 风云四号卫星影像超分辨率重建

卢峥松¹, 阚希^{2*}, 李燕², 陈乃源¹

¹南京信息工程大学自动化学院, 江苏 南京 210044;

²无锡学院物联网工程学院, 江苏 无锡 214105

摘要 针对风云四号卫星图像近红外和短波红外波段空间分辨率远低于相应的可见光波段的问题, 提出一种基于匹配提取和跨尺度特征融合网络的超分辨率方法, 以高分辨率波段图像作为参考图像, 辅助重建低分辨率的可见光与近红外波段。首先, 使用匹配提取模块, 利用高分辨率图像与低分辨率图像间的相似性, 将高分辨率图像的细小纹理信息融合到低分辨率图像中。然后, 使用跨尺度特征融合方法将仍存在亮度、颜色、结构等差异的参考图像特征图和低分辨率特征图融合。最后, 结合空间-光谱总变异损失和 L1 损失保证重建结果的空间和光谱可信度。实验结果表明, 所提方法在空间和光谱可信度方面取得了良好的结果。与 Bicubic、RDN、RCAN、EDSR、Dsen2 等方法相比, 该方法取得了最优的质量评价指标, 能有效提高风云四号卫星影像的空间分辨率。

关键词 图像处理; 风云四号; 超分辨率; 特征匹配提取; 跨尺度特征融合

中图分类号 TP391.4

文献标志码 A

DOI: 10.3788/LOP222009

Super-Resolution Reconstruction of FY-4 Images Based on Matching Extraction and Cross-Scale Feature Fusion Network

Lu Zhengsong¹, Kan Xi^{2*}, Li Yan², Chen Naiyuan¹

¹School of Automation, Nanjing University of Information Science and Technology,
Nanjing 210044, Jiangsu, China;

²School of the Internet of Thing Engineering, Wuxi University, Wuxi 214105, Jiangsu, China

Abstract A super-resolution method based on matching extraction and a cross-scale feature fusion network is proposed to address the problem that the spatial resolution of the FY-4 satellite image's near-infrared and short-wave infrared bands is far lower than the corresponding visible band. The high-resolution band image is used as the reference image to assist in the reconstruction of the low-resolution visible and near-infrared bands. First, using the similarity between the high-resolution image and the low-resolution image, the matching extraction module is used to fuse the fine texture information of the high-resolution image into the low-resolution image. The cross-scale feature fusion method is then used to combine the reference image feature map and the low-resolution feature map, which still differ in brightness, color, structure, and so on. Finally, by combining the total spatial spectral variation loss and the L1 loss, the spatial and spectral reliability of the reconstruction results is ensured. Experimental results demonstrate that the proposed method achieves good results in spatial and spectral reliability. This method achieves the best quality evaluation index and can effectively improve the spatial resolution of FY-4 satellite images compared with Bicubic, RDN, RCAN, EDSR, Dsen2, and other methods.

Key words image processing; FY-4; super-resolution; feature matching and extraction; cross-scale feature fusion

1 引言

卫星成像仪受成像环境、存储和传输带宽限制, 导

致高空间分辨率影像难以获取。随着遥感影像技术的快速发展, 遥感影像的应用越来越广泛, 而质量较低的遥感影像会严重降低重要指标的估算精度, 很大程度

收稿日期: 2022-07-06; 修回日期: 2022-08-12; 录用日期: 2022-09-13; 网络首发日期: 2022-09-23

通信作者: *kanxi@nuist.edu.cn

上限制了卫星影像数据的研究与应用。因此,开发低分辨率(LR)影像数据的超分辨率方法,使低分辨率波段具有更高的空间分辨率,是遥感研究的重要课题之一。风云四号 A 星是我国新 1 代静止轨道气象卫星^[1],广泛应用于天气监测与预报^[2]、防灾减灾、气候变化预测^[3-6]等领域。多通道扫描成像辐射计(AGRI)是其搭载的主要载荷之一,然而在 AGRI 数据中,可见光与近红外的第 1、3 谱段的空间分辨率仅为可见光近红外第 2 谱段的 1/2,短波红外谱段仅为可见光近红外第 2 谱段的 1/4,极大地限制了风云四号卫星图像的应用范围。因此,对风云四号卫星进行超分辨率重建,提高卫星影像的空间分辨率,对风云四号影像后续应用具有非常重要的价值与意义。

图像超分辨率技术已经应用于多种不同种类的遥感影像上,如美国陆地卫星(Landsat)专题制图仪(TM)影像、中分辨率成像光谱仪(MODIS)影像、哨兵二号多光谱成像仪(MSI)等^[7-14]。目前,遥感图像的超分辨率技术可分为基于学习的方法和基于重建的方法,基于学习的方法通过训练学习,建立高分图像与低分图像的映射关系,实现超分辨率重建^[15]。随着深度学习的发展,基于学习的方法逐渐成为热点。在自然图像超分辨率领域中,国内外研究学者提出 SRCNN^[16]、DRCN^[17]、EDSR^[18]、SRGAN^[19]、ESRGAN^[20]等多种网络结构。程德强等^[21]利用边缘信息融合和多尺度共享,学习清晰的边缘和复杂的纹理细节,取得了较好的视觉效果。高青青等^[22]将多尺度模块作为基本的递归模块,提取图像在不同尺度下的特征信息,取得了良好的重建效果。辛元雪等^[23]使用多尺度密集连接模块并添加注意力机制,获得了更加清晰的图像边缘重建图像。然而,多尺度模块虽然可有效融合位置信息和细节信息,增大感受野,但是应用在存在亮度、颜色、结构等差异的遥感图像中仍存在较大问题。在遥感图像超分辨率领域中,Pouliot 等^[24]利用 Sentinel-2 图像训练 Landsat 图像的浅层和深层卷积神经网络,在重建加拿大的景观环境的研究中取得良好效果。Banaras 等^[14]提出一种基于卷积神经网络的超分辨率方法,该方法显著提高了 Sentinel-2 波段的分辨率并可保存光谱特征。Zhang 等^[25]提出一种基于生成对抗网络的超分辨率方法(S2GAN),S2GAN 提高了 Sentinel-2 图像 20 m 和 60 m 波段的空间分辨率,并可准确地从低分辨率波段提供具有显著细节的高分辨率波段。Xiao 等^[26]提出一种五层端到端网络,该网络结合非线性映射网络的输出和高维特征来构建联合损失函数,使用吉林一号卫星视频数据作为训练集,对卫星视频数据进行超分辨率重建。贺智等^[27]使用卷积回归网络对高分四号卫星图像中波红外谱段进行超分辨率重建,有效提高了中波红外谱段空间分辨率。然而,这些方法通常简单地将高分辨率图像与低分辨率图像连接起来输入卷积层,对高分辨率与低分辨率波

段的相关性考虑较少。

针对上述问题,本文以风云四号 A 星数据为例,结合图像超分辨率方法,提出一种基于匹配提取和跨尺度特征融合的超分辨率方法。该方法可进行 2 倍超分辨率重建和 4 倍超分辨率重建,将可见光 1000 m 波段和近红外 2000 m 波段的空间分辨率提高到可见光波段的 500 m 分辨率。该方法使用匹配提取模块,根据图像间的相似性,匹配高分辨率图像和低分辨率图像的纹理信息,并通过跨尺度特征融合方法将仍存在亮度、颜色、结构等差异的参考图像特征图和低分辨率特征图融合。再结合 L1 损失和空间光谱总变异损失函数,提高空间和光谱的相关性。实验结果表明,所提方法可以有效提高遥感影像的空间分辨率。

2 数据处理

2.1 样本集制作

风云四号卫星装载的静止轨道辐射成像仪可提供 14 个光谱波段的多光谱图像,以 500 m、1000 m、2000 m、4000 m 等 4 种不同的空间分辨率获取可见光与近红外、短红外波、中红外波和长红外波等波段,具体如表 1 所示。其中,1~6 波段是反射率数据,7~14 波段是亮温数据。在反射率数据的 6 个波段中,可见光近红外波段有 3 个波段,仅有第 2 波段的空间分辨率为 500 m,第 1 波段与第 3 波段的空间分辨率为 1000 m。第 4、5、6 波段是短波红外波段,空间分辨率仅有 2000 m。

表 1 风云四号影像参数
Table 1 Image parameters of FY-4

Band	Type	Spectral bandwidth / μm	Spatial resolution /km
1	Visible and near-infrared	0.45-0.49	1
2		0.55-0.75	0.5-1
3		0.75-0.90	1
4	Shortwave infrared	1.36-1.39	2
5		1.58-1.64	2
6		2.1-2.35	2-4
7	Medium wave infrared	3.5-4.0(high)	2
8		3.5-4.0(low)	4
9	Water vapor	5.8-6.7	4
10		6.9-7.3	4
11		8.0-9.0	4
12	Long wave infrared	10.3-11.3	4
13		11.5-12.5	4
14		13.2-13.8	4

传统的自然图像超分辨率网络通常将高分辨率图像降采样为低分辨率图像作为网络的输入,在风云四号 AGRI 遥感影像中,1000 m 和 2000 m 波段不具有可获得的真值。因此,与哨兵二号影像超分辨率任务类

似,所提方法基于一个重要的假设^[14],即图像纹理的光谱相关性在一个有限的尺度范围内是自相似的。假设通过传输 500 m 高分辨率图像细节,可以从 2000 m 和 8000 m 的真实图像中学习到 2000 m 到 500 m 的上采样,同样,也可采用类似的方式学习到 1000 m 到 500 m 的上采样。在此假设下,只需要将原始 AGRI 图像按所需比例因子进行下采样,将下采样后的数据作为输入,以生成的原始数据作为输出,这样就可以根据深度学习需要,获得几乎无限的训练数据。

FY-4A/AGRI 遥感数据预处理包括辐射定标^[28]、几何校正、影像裁剪等几个重要处理环节。采用国家气象卫星中心官方网站提供的 FY-4A 数据行列号和经纬度查找表对 FY-4A 的 L1 级数据进行几何校正;采用 FY-4A 卫星的 L1 级数据中各个通道对应的定标表进行辐射定标。按照中国边界的经纬度最大值和最

小值将风云四号卫星图像裁剪出一个长方形区域。接着对 500 m 的第 2 波段数据、1000 m 的第 1、2、3 波段数据、2000 m 的第 1~6 波段的长方形图像进行规则网格裁剪,分别裁剪成宽、高、通道为 $512 \times 512 \times 1$ 、 $256 \times 256 \times 3$ 、 $128 \times 128 \times 6$ 的图像。训练时,2 倍超分辨率网络的输入由下采样 2 倍后大小为 $256 \times 256 \times 1$ 的 500 m 分辨率图像以及下采样后大小为 $128 \times 128 \times 3$ 的 1000 m 分辨率图像组成,部分训练样本示例如图 1(a)所示。其中,第 1 列为 500 m 分辨率第 2 波段图像,第 2~4 列为 1000 m 分辨率第 1~3 波段图像。4 倍超分辨率网络的输入由下采样 4 倍后大小为 $128 \times 128 \times 1$ 的 500 m 分辨率图像以及大小为 $32 \times 32 \times 6$ 的 2000 m 分辨率图像组成,部分训练样本示例如图 1(b)所示。其中,第 1 列为 500 m 分辨率第 2 波段图像,第 2~7 列为 2000 m 分辨率第 1~6 波段图像。

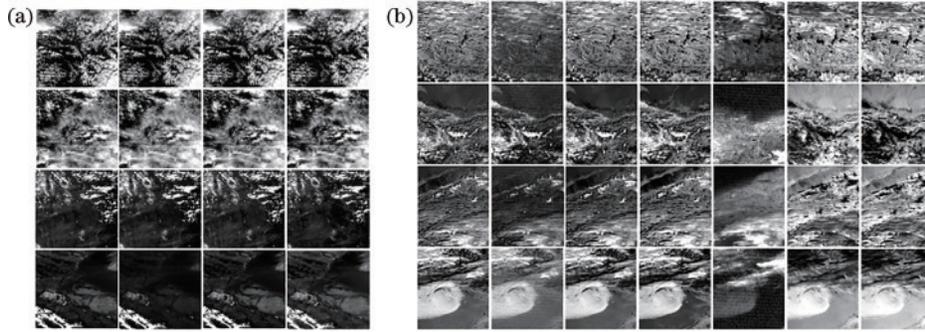


图 1 训练集样本示例。(a)2 倍网络训练集样本;(b)4 倍网络训练集样本

Fig. 1 Sample examples of training set. (a) $2 \times$ network training set samples; (b) $4 \times$ network training set samples

3 匹配提取与跨尺度特征融合网络

3.1 匹配提取模块

在遥感图像中,不同波段的图像和同一波段的图像内部的相邻像素很可能具有相似的亮度、颜色、纹理、结构等。在对低分辨率波段进行重建时,可以考虑利用高分辨率图像局部的相似性和不同波段间图像的相似性,将高分辨率图像的细小纹理信息融合到低分辨率图像中。因此,引入特征匹配提取模块^[29],利用风云四号卫星 500 m 波段图像辅助 1000 m 和 2000 m 波段图像恢复小尺度区域的纹理细节。特征匹配提取模块计算方式如图 2 所示。

1) 粗匹配,在特征空间中找到块之间的对应关系。首先,将低分辨率图像展开为 K 个非重叠块 $\{\mathbf{B}_{LR}^0, \mathbf{B}_{LR}^1, \dots, \mathbf{B}_{LR}^{K-1}\}$,找到每个 \mathbf{B}_{LR}^k 块最相关的下采样后的图像(Ref \downarrow)块 $\mathbf{B}_{Ref\downarrow}^k$ 。然后,通过计算每个 \mathbf{B}_{LR}^k 块的中心 patch 与 $\mathbf{B}_{Ref\downarrow}^k$ 的每一个 patch 的余弦相似度,在 $\mathbf{B}_{Ref\downarrow}^k$ 中找到最相似的 patch,记为 \mathbf{p}_c^k :

$$r_{c,j}^k = \left\langle \frac{\mathbf{p}_c^k}{\|\mathbf{p}_c^k\|}, \frac{\mathbf{q}_j}{\|\mathbf{q}_j\|} \right\rangle \quad (1)$$

然后以这个 patch 为中心,裁剪大小为 $d_x \times d_y$ 的

块,记为 $\mathbf{B}_{Ref\downarrow}^k$ 。根据局部相似性,对于 \mathbf{B}_{LR}^k 中的所有 patch,他们最相似的 patch 都可能分布在这个 $\mathbf{B}_{Ref\downarrow}^k$ 中。但是如果 \mathbf{B}_{LR}^k 的大小远远大于 patch 的大小,可能会造成其中心 patch 无法代表 \mathbf{B}_{LR}^k 的全部内容,从而找到不相关的 $\mathbf{B}_{Ref\downarrow}^k$,因此使用具有不同膨胀率的中心 patch 来计算相似度,如图 2 的 step 1 中的蓝色块代表扩张率为 1 的情况,绿色块代表扩张率为 2 的情况。最后从原始参考图像中,裁剪出大小为 $s d_x \times s d_y$ 的块,记为 $\mathbf{B}_{Ref\downarrow}^{k,s}$ 。

2) 精细匹配,对 \mathbf{B}_{LR}^k 和 $\mathbf{B}_{Ref\downarrow}^{k,s}$ 进行密集 patch 匹配。以 $(\mathbf{B}_{LR}^k, \mathbf{B}_{Ref\downarrow}^{k,s})$ 为例,首先对 \mathbf{B}_{LR}^k 和 $\mathbf{B}_{Ref\downarrow}^{k,s}$ 中的每一个 patch 计算相似度:

$$r_{i,j}^k = \left\langle \frac{\mathbf{p}_i^k}{\|\mathbf{p}_i^k\|}, \frac{\mathbf{q}_j^k}{\|\mathbf{q}_j^k\|} \right\rangle, \quad (2)$$

式中: \mathbf{p}_i^k 是 \mathbf{B}_{LR}^k 中的第 i 个 patch; \mathbf{q}_j^k 是 $\mathbf{B}_{Ref\downarrow}^{k,s}$ 中的第 j 个 patch; $r_{i,j}^k$ 是计算后的相似度得分。通过计算相似度,可以得到一组索引映射和相似度映射。 \mathbf{D}_k 的第 i 个元素记为索引 D_i^k ,表示 $\mathbf{B}_{Ref\downarrow}^{k,s}$ 中与 \mathbf{B}_{LR}^k 的第 i 个 patch 最相似的 patch:

$$D_i^k = \operatorname{argmax}_j r_{i,j}^k \quad (3)$$

最高相似性得分 R_i^k 表示 \mathbf{B}_{LR}^k 中的第 i 个 patch 对应的最高相似度得分:

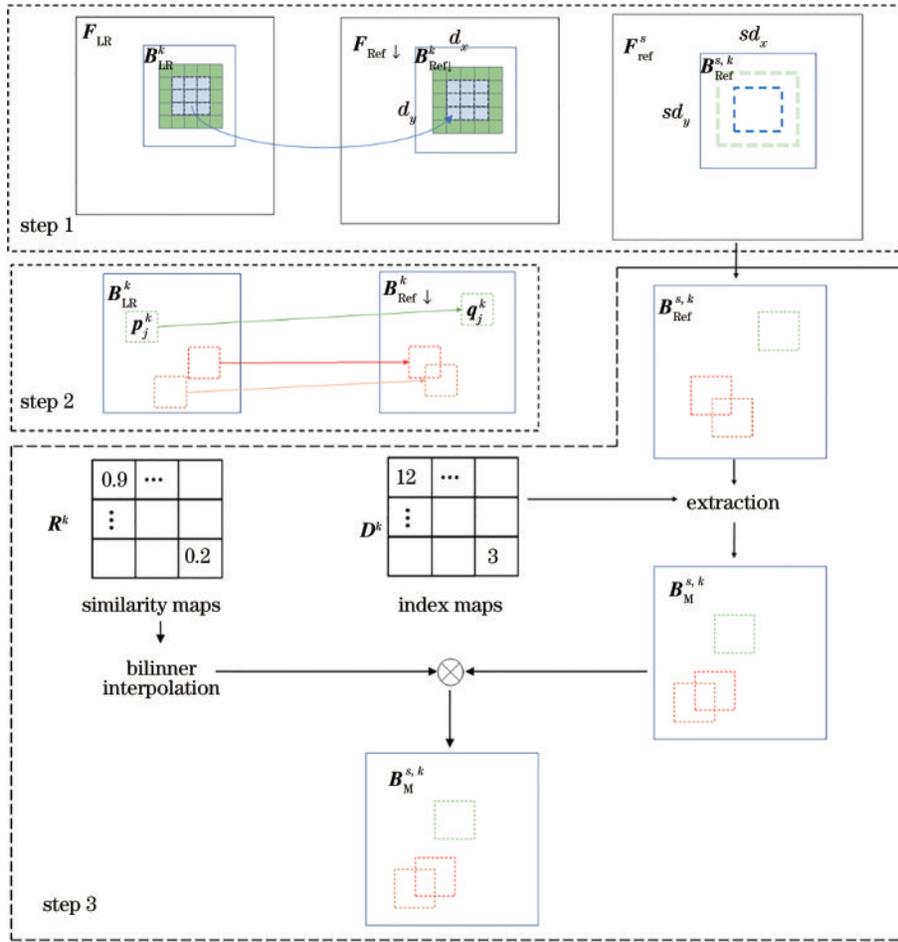


图 2 特征匹配提取模块

Fig. 2 Matching and extraction module

$$R_i^k = \max_j r_{i,j}^k \quad (4)$$

3) 特征提取。首先根据索引 D_k 从 $B_{Ref}^{s,k}$ 提取 patch, 记为新的特征图 $B_M^{s,k}$, 将 D_i^k 个 $B_{Ref}^{s,k}$ 中的 patch 作为 $B_M^{s,k}$ 的第 i 个 patch。由于相似性得分更高的特征图更有用, 将 $B_M^{s,k}$ 与相应的 R^k 加权相乘, 表达式如下:

$$B_M^{s,k} = B_M^{s,k} \odot (R^k) \uparrow \quad (5)$$

式中: \odot 表示两个矩阵对应位置元素乘积; \uparrow 表示双线性插值。最终得到输出 $\{B_M^{s,0}, B_M^{s,1}, B_M^{s,2}, \dots, B_M^{s,K-1}\}$, 并

通过 step 1 的逆向操作将特征图折叠在一起。其他的匹配方法往往将整张特征图与参考图像的特征图进行相似度计算, 在匹配提取模块中, 通过由粗到细的匹配方式显著降低计算量。图 3 为所提网络中待重建图像和参考图像经过该模块后部分通道的特征图。图 3 (a) 为特征提取后的低分辨率图像部分特征图, 图 3 (b) 为该模块提取的参考图像的部分特征图。可以看出, 匹配提取模块有效匹配了参考图像中与低分辨率图像相似的 patch。

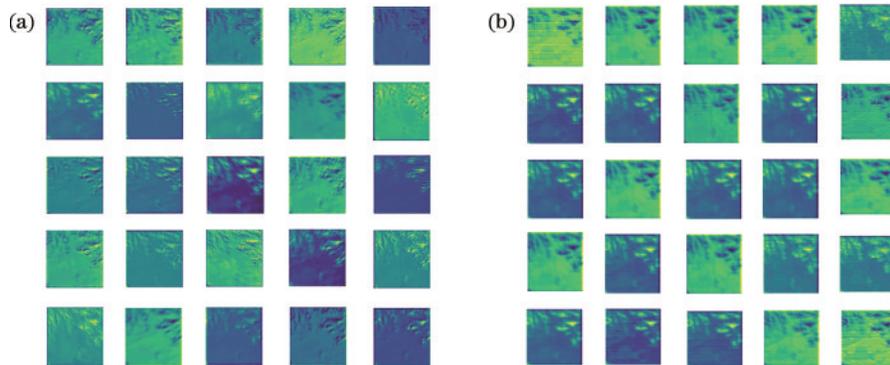


图 3 图像特征可视化。(a)低分辨率图像;(b)参考图像

Fig. 3 Image feature visualization. (a) LR images; (b) reference images

3.2 跨尺度特征融合

在许多情况下,低分辨率图像和参考图像可能有相似的内容和纹理,但是颜色和亮度的分布是不一致的。因此,提取的参考图像特征的分布可能与低分辨率图像特征的分布不一致。所以,简单地将参考图像

和低分辨率图像特征连接在一起并将它们输入下面的卷积层中并不是最合适的选择。针对此问题,提出一种跨尺度特征融合模块(cross-scale module),将低分辨率图像特征与提取的参考图像高分辨率特征融合。图 4 为跨尺度模块的网络结构图。

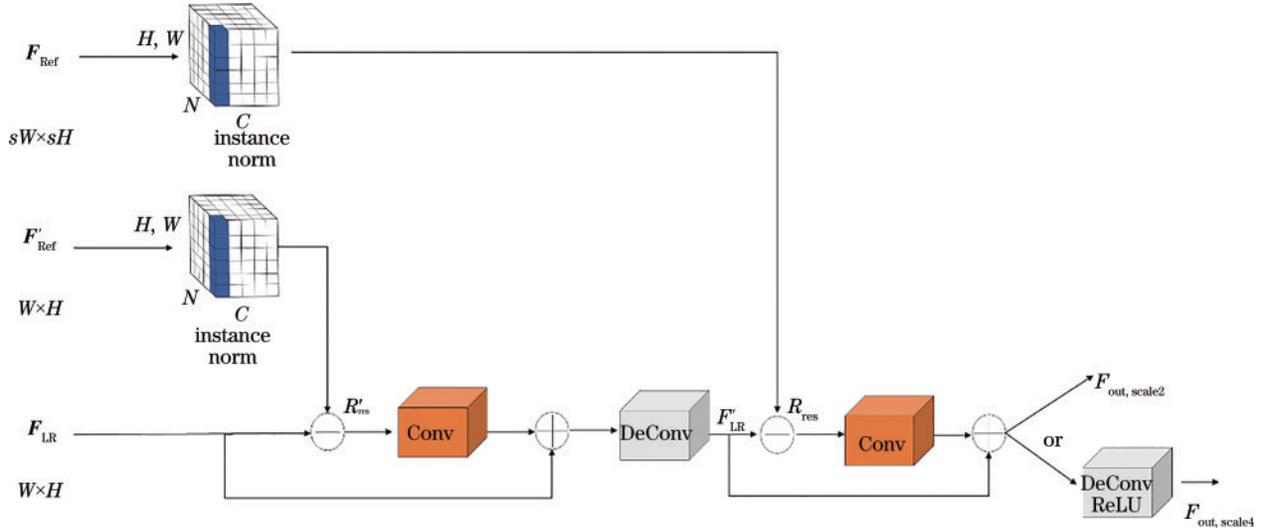


图 4 跨尺度特征融合模块结构

Fig. 4 Cross-scale module structure

首先,对于由参考图像提取到的大小为 (W, H) 的特征图 F'_{Ref} 进行通道层面的归一化,计算公式分别为

$$F'_{Ref} \leftarrow \frac{F'_{Ref} - \mu_{Ref}^c}{\sigma_{Ref}^c}, \quad (6)$$

$$\mu_{Ref}^c = \frac{1}{HW} \sum_{y,x} F'_{Ref}{}^{c,y,x}, \quad (7)$$

$$\sigma_{Ref}^c = \sqrt{\frac{1}{HW} \sum_{y,x} (F'_{Ref}{}^{c,y,x} - \mu_{Ref}^c)^2}, \quad (8)$$

式中: μ_{Ref}^c 和 σ_{Ref}^c 分别为通道 c 中 F'_{Ref} 的均值和标准差。

然后,获取 F'_{Ref} 中存在但 F_{LR} 中不存在的细节,记为 R'_{res} ,这种残差结构仅仅关注不同特征图之间不同的特殊信息,可以使网络进行更具判别性的特征学习。接着, R'_{res} 经过一个卷积层和激活函数后与 F_{LR} 融合。最后,通过反卷积扩大特征图的大小,以相同的方法,进一步与特征图 F_{Ref} 融合,输出记为 $F_{out, scale2}$ 。与 2 倍网络不同,在 4 倍网络中,需要将输出再进行一次反卷积操作,输出记为 $F_{out, scale4}$ 。上述过程可描述为

$$R'_{res} = F'_{Ref} - F_{LR}, \quad (9)$$

$$F'_{LR} = \text{ReLU} \left\{ \text{DeConv} \left\{ \text{ReLU} \left[\text{Conv} \left(R'_{res} \right) \right] + F_{LR} \right\} \right\}, \quad (10)$$

$$R_{res} = F_{Ref} - F'_{LR}, \quad (11)$$

$$\begin{cases} F_{out, scale2} = \text{ReLU} \left[\text{Conv} \left(R_{res} \right) + F'_{LR} \right] \\ F_{out, scale4} = \text{ReLU} \left\{ \text{DeConv} \left\{ \text{ReLU} \left[\text{Conv} \left(R_{res} \right) + F'_{LR} \right] \right\} \right\} \end{cases} \quad (12)$$

3.3 整体网络结构

所提基于匹配提取与跨尺度特征融合的网络模型

使用参考图像超分辨率重建方法,利用最高分辨率 (500 m) 的纹理、细节信息,辅助重建较低分辨率波段 (2000 m 和 1000 m)。2 倍网络整体结构如图 5 所示。

首先,对输入的低分辨率图像、下采样后的图像、参考图像使用编码器 (encoder) 进行初步特征提取,通过步长为 2 的卷积减小特征图大小。对于低分辨率图像和下采样后的图像,经过编码器后的特征图大小为 64×64 。对于参考图像,通过编码器获得 3 个不同尺度的特征图。然后,将获得的特征图送入特征匹配提取模块进行由粗到细的匹配和特征提取。接着,将从参考图像中提取到的特征图进行特征融合。再将融合参考图像信息的特征图通过解码器 (decoder),并与经过双三次插值的低分辨率图像相加,再经过卷积后获得最终重建结果。4 倍超分网络在输入上与 2 倍网络略有区别,参考图像大小为 4 倍下采样的原始图像,大小为 $128 \times 128 \times 1$,下采样后的图像大小为 $32 \times 32 \times 1$,低分辨率图像大小为 $32 \times 32 \times 6$,其余网络结构基本相同。

网络中的解码器与编码器均使用超分辨率网络中常用的残差模块构建,但是在解码器中加入通道注意力机制,增加通道之间的差异性。所使用的通道注意力机制利用特征通道之间的相互依赖性,使网络专注于更多信息特征。首先使用全局平均池化获取 $1 \times 1 \times C$ 的特征图,再通过 2 个卷积层分别进行通道压缩和恢复,最后再通过 Sigmoid 函数获取每个通道的权值并与原始特征图对应通道的二维矩阵相乘。图 6 为解码器与编码器中基本模块的结构示意图。

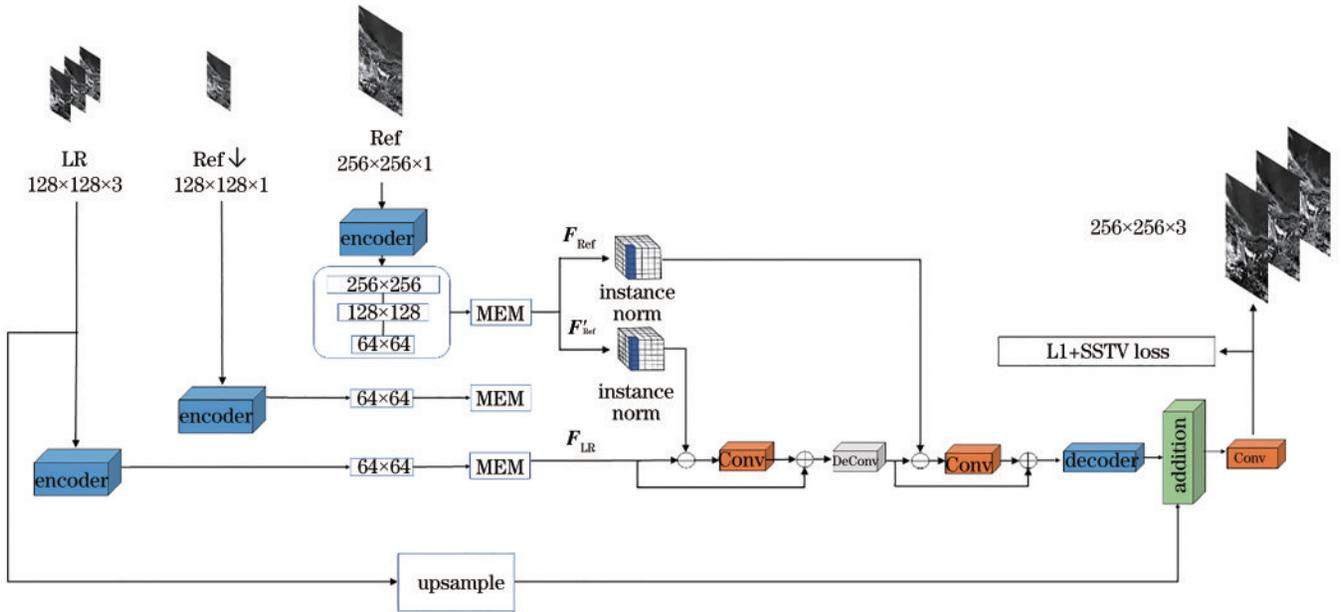


图 5 2倍网络整体结构

Fig. 5 Structure of 2× network

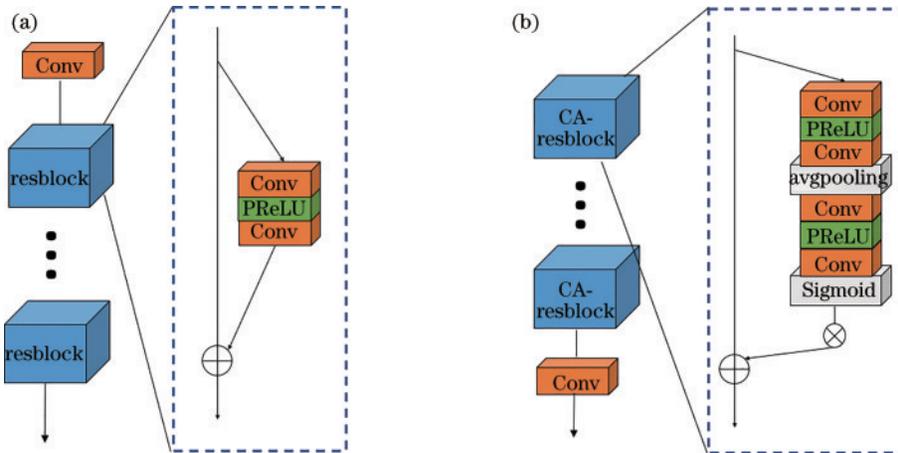


图 6 基本模块结构。(a)编码器结构;(b)解码器结构

Fig. 6 Basic module structure. (a) Encoder structure; (b) decoder structure

3.4 损失函数

在目前的研究中,L2、L1、感知损失和对抗性损失是最常用的损失函数。感知损失通常使用通过ImageNet数据集上预训练的ResNet^[30]或VGG^[31],将真实图片卷积得到的特征图与生成图片的特征图比较,然而遥感数据的数据分布与预训练使用的数据差异很大,且所提网络的输入通道也较多,所以感知损失并不适合本研究的超分辨率任务。对抗损失可以有效生成清晰且视觉上令人满意的图像,但是会恢复原始图像中不存在的、遥感领域不希望看到的细节,对后续图像的利用产生不利影响。L2损失计算的是实际值与目标值之间绝对差值的平方总和,容易产生过于平滑、模糊的图像。由于L1损失可以有效地惩罚小误差,并且在整个训练阶段保持较好的收敛性,

所以采用L1损失来衡量网络的重构精度。使用L1损失函数,通过优化真实高分辨率图像 I_{HR} 与重建图像 I_{SR} 之间的平均绝对误差(MAE)优化网络。L1损失的表达式为

$$L_1(\theta) = \frac{1}{N} \| I_{HR}^i - I_{SR}^i \|_1, \quad (13)$$

式中, N 表示一批中图像的个数。

然而,上述损失主要是为一般的图像恢复任务设计的。虽然它们可以很好地保留超分辨率结果的空间信息,但由于忽略了光谱特征之间的相关性,重构后的光谱信息可能会失真。为了同时保证重建结果的空间和光谱可信度,引入空间光谱总变异(SSTV)^[33]损失,其扩展了传统的total variation(TV)损失,并考虑了空间和光谱的相关性, L_{SSTV} 的表达式为

$$L_{\text{SSTV}}(\theta) = \frac{1}{N} \sum_{n=1}^N \left(\|\nabla_h \mathbf{I}_{\text{SR}}^i\|_1 + \|\nabla_w \mathbf{I}_{\text{SR}}^i\|_1 + \|\nabla_c \mathbf{I}_{\text{SR}}^i\|_1 \right), \quad (14)$$

$$L(\theta) = L_1 + \alpha L_{\text{SSTV}}, \quad (15)$$

式中： ∇_h 、 ∇_w 、 ∇_c 分别为计算 \mathbf{I}_{SR} 水平、垂直和光谱梯度的函数； α 为 10^{-3} 。将SSTV与L1损失相加，以同时增强空间和光谱平滑。

4 实验结果与分析

4.1 实验平台

所提算法在ubuntu 18.04操作系统中实现，深度学习框架为PyTorch 1.10.0，使用GPU加速工具CUDA 11.3，编程语言采用Python 3.8。硬件配置包括i7-11700K CPU、Nvidia GeForce RTX 3090 GPU、128 GB内存。

4.2 数据集和模型训练参数

本实验的数据集图像格式为tif，2倍超分辨率网络的训练集由大小为 $512 \times 512 \times 1$ 的500 m分辨率图像以及大小为 $256 \times 256 \times 3$ 的1000 m分辨率图像组成。4倍超分辨率网络的训练集由大小为 $512 \times 512 \times 1$ 的500 m分辨率图像以及大小为 $128 \times 128 \times 6$ 的2000 m分辨率图像组成，2倍和4倍训练集均为3525张图像，测试集为816张图像。两个网络的批尺寸(batch size)都设为4，迭代次数(epoch)都设为80。模型训练时采用Adam优化器对网络进行优化，初始的学习率为 10^{-4} ，且每迭代一万次就调整学习率为当前的一半。

4.3 评价指标

使用均方根误差(E_{RMSE})、误差相对总量(S_{ERGAS})、光谱角映射(A_{SAM})和信号重构误差比(R_{SRE})作为评价指标。 E_{RMSE} 是一种度量光谱相近性的评价指标，衡量观测值与真实值之间的偏差。其值越小，表示算法所得的图像与原始图像越匹配。

$$E_{\text{RMSE}} = \sqrt{\frac{1}{M \times N} \sum [X_k(i, j) - Y_k(i, j)]^2}, \quad (16)$$

式中： X 和 Y 分别是参考图像和超分辨率图像； k 是图像波段数； M 、 N 为图像的宽和高。

R_{SRE} 是一种用来测量相对信号功率误差的评价指标。其值越大，表示算法所得的图像与原始图像越匹配。

$$R_{\text{SRE}} = 10 \log_{10} \frac{\mu_x^2}{\|\hat{x} - x\|^2/n}, \quad (17)$$

式中： \hat{x} 是每个重构波段向量； x 是矢量化的真值带； n 是 x 中的像素数； μ_x 是 x 的平均值； R_{SRE} 的值以分贝(dB)表示。

A_{SAM} 是一种度量光谱矢量间夹角的评价指标。其值越小，表示算法所得的图像与原始图像越匹配。

$$A_{\text{SAM}} = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N \arccos \left\{ \frac{\sum_{k=1}^K X_k(i, j) Y_k(i, j)}{\sqrt{\sum_{k=1}^K [X_k(i, j)]^2 \sum_{k=1}^K [Y_k(i, j)]^2}} \right\}. \quad (18)$$

S_{ERGAS} 综合考虑所有通道的相对误差，表示两幅图像的差异，其值越低，图像就越相似。

$$S_{\text{ERGAS}} = \frac{100}{R} \sqrt{\frac{1}{C} \sum_{c=1}^C \left[\frac{E_{\text{RMSE}}(X_k, Y_k)}{u(X_k)} \right]^2}, \quad (19)$$

式中： C 表示图像的波段数； $u(X_k)$ 为图像 X_k 的均值。

4.4 结果分析

为了验证所提算法的有效性，将其与目前公认较为先进的超分辨率算法RCAN^[33]、RDN^[34]、EDSR^[18]、Dsen2^[14]进行对比，不同算法的计算量(Flops)和参数量(Params)如图7所示。此外，作为基线，使用双三次插值来说明未考虑光谱相关性的上采样。

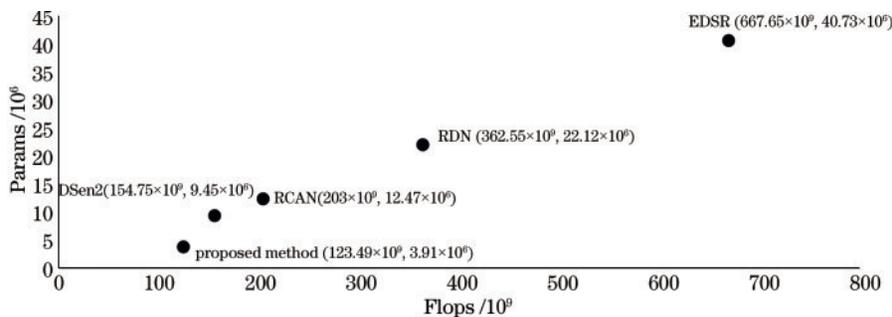


图7 各方法的计算量和参数量

Fig. 7 Calculation quantity and parameter quantity of each method

由于无法获取1000 m和2000 m分辨率的真实参考图像，对于FY-4A图像的定量评价只能在模型训练的较低尺度上进行。即1、3波段在超分辨率2000 m到1000 m的任务上进行2倍超分辨率重建，再将重建结果与1000 m分辨率真实值对比。4、5、6波段在超

分辨率8000 m到2000 m的任务上进行4倍超分辨率重建，再将重建结果与2000 m分辨率真实值对比。表2给出了各方法的定量评价结果，具体数值为各重建波段计算得到指标的平均值。

从表2的实验数据可直观看出，所提算法的客观

表 2 实验结果对比

Table 2 Comparison of experimental results

Scale	Method	RMSE ↓	SAM ↓	ERGAS ↓	SRE ↑
×2	Bicubic	0.0226	4.6186	2.2585	19.6897
	RCAN	0.0123	2.4320	1.2539	22.1579
	RDN	0.0112	2.2722	1.1694	22.3547
	EDSR	0.0131	2.5058	1.4677	21.5478
	Dsen2	0.0108	2.1348	1.0837	22.4453
	Proposed method	0.0099	1.9680	1.0473	22.6309
×4	Bicubic	0.0102	3.3016	1.8374	17.9813
	RCA	0.0077	3.0336	1.4486	18.9836
	RDN	0.0086	3.0931	1.6154	18.3778
	EDSR	0.0080	2.9217	1.5645	18.7661
	Dsen2	0.0071	2.6580	1.4074	19.3066
	Proposed method	0.0063	2.3580	1.1408	19.9214

评价指标显著优于其他算法。在缩放因子为 2, 即 1、3 波段的 2 倍超分辨率重建任务中, 所提算法的 E_{RMSE} 值相对 Bicubic、RCAN、RDN、EDSR、Dsen2 分别降低 0.0127、0.0024、0.0013、0.0032、0.0009, A_{SAM} 值分别

降低 2.6506、0.464、0.3042、0.5378、0.1668, S_{ERGAS} 值分别降低 1.2112、0.473、0.1221、0.4204、0.0364, R_{SRE} 值分别提高 2.9412、0.2066、0.2762、1.0831、0.1856。在缩放因子为 4 时, 即 4、5、6 波段的 4 倍超分辨率重建任务中, 所提算法的 E_{RMSE} 值相对 Bicubic、RCAN、RDN、EDSR、Dsen2 分别降低 0.0039、0.0014、0.0023、0.0017、0.0008, A_{SAM} 值分别降低 0.9436、0.6756、0.7351、0.5637、0.3, S_{ERGAS} 值分别降低 0.6966、0.3078、0.4746、0.4237、0.2666, R_{SRE} 值分别提高 1.9401、0.9378、1.5436、1.1553、0.6148。此外, 对原始 2000 m 分辨率波段和 4 倍超分辨率网络处理后的 2000 m 波段的光谱情况使用 Envi 软件建立感兴趣区域并进行统计对比, 如图 8 所示。图 8(a) 为原始 2000 m 波段最小值、最大值和均值的统计结果, 图 8(b) 为超分辨率后的统计结果。在图 8(a) 和图 8(b) 的图例中, 从上到下依次为最小值、均值减标准差、均值、均值加标准差、最大值。图 8(c) 为原始 2000 m 数据 4、5、6 波段的直方图统计结果。图 8(d) 为超分辨率后的统计结果。可以看出, 超分辨率之后的遥感数据光谱曲线与原始数据基本一致, 说明所提算法有效保证了光谱的可信度。

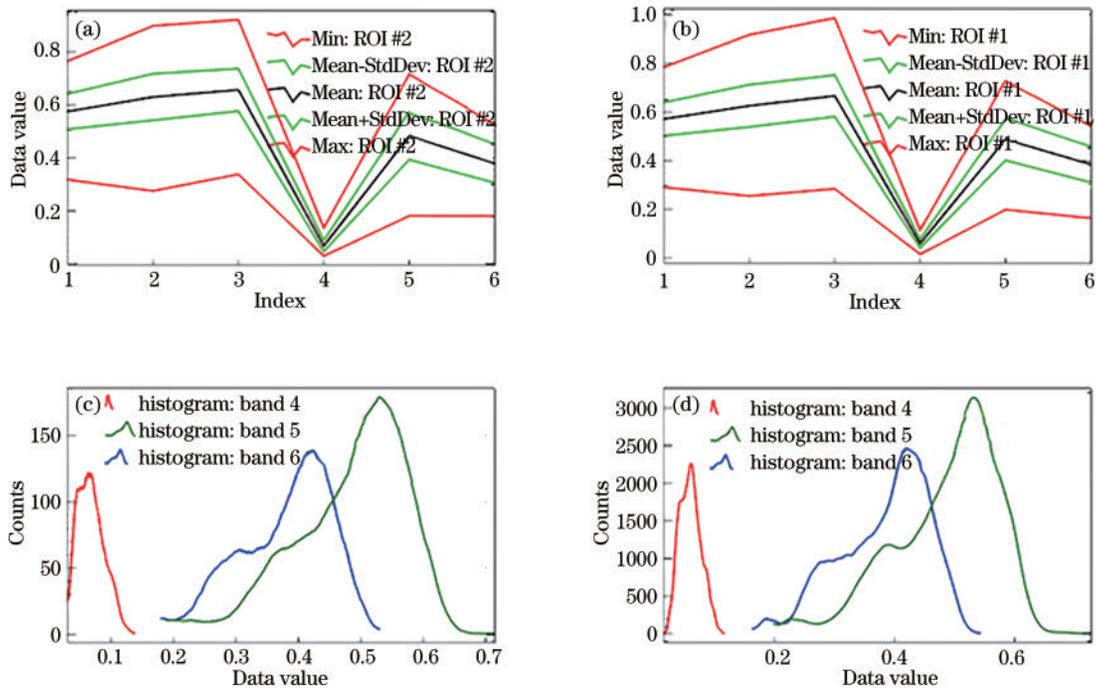


图 8 光谱曲线对比。(a)原始 2000 m 波段统计结果;(b)超分辨率后的统计结果;(c)原始 2000 m 数据 4、5、6 波段的直方图;(d)超分辨率后的统计结果

Fig. 8 Spectral curve comparison. (a) Original 2000 m band statistical results; (b) statistical results after super-resolution; (c) histograms of 4, 5, 6 bands of original 2000 m data; (d) statistical results after super-resolution

为了更加直观地感受所提算法重建图像的效果, 图 9 和图 10 分别展示了各超分辨率算法放大 2 倍和 4 倍后的重建图像细节, 图 9 中图像取自 2021 年 1 月 1 日世界时间 4 时整, 使用 2、3 波段合成, 图 10 中图像取自 2021 年 4 月 15 日世界时间 5 时整, 使用 4、5、6 波段

合成。可以看出, 所提算法重建图像具有较好的视觉效果。原始 1000 m 和 2000 m 图像的分辨率最低、视觉效果最模糊; Bicubic 方法重建的图像出现模糊、振铃效应、纹理不清晰等问题, 超分辨率效果有限; 基于深度学习的方法重建的图像视觉上比较平滑, 细节纹

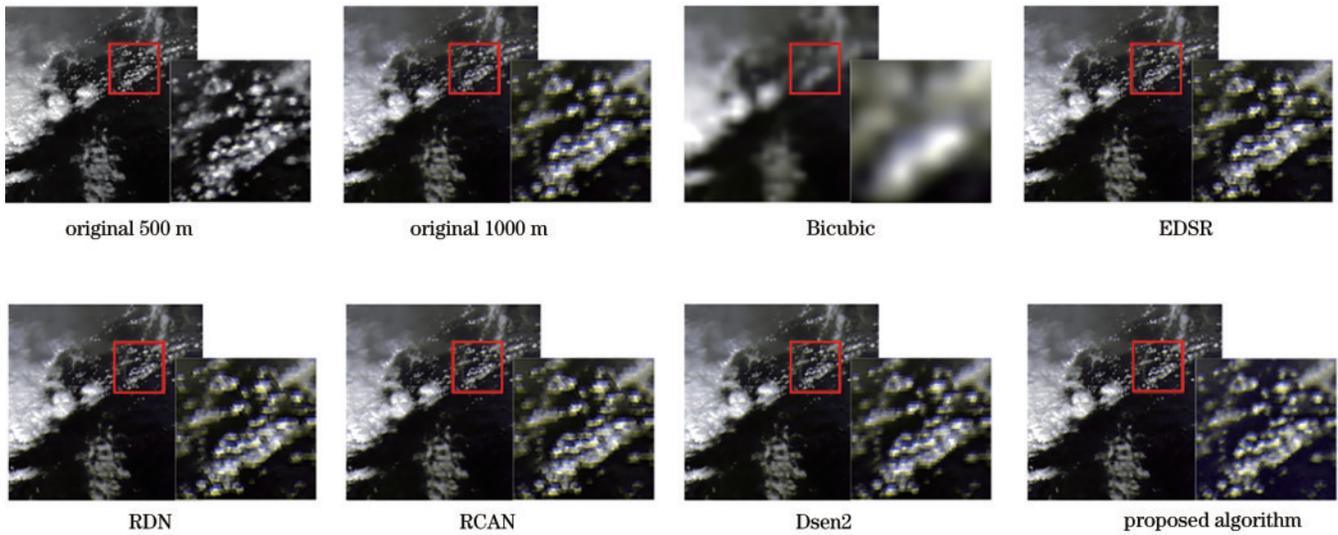


图 9 各算法 2 倍超分辨率重建结果

Fig. 9 2× super-resolution reconstruction results of each algorithm

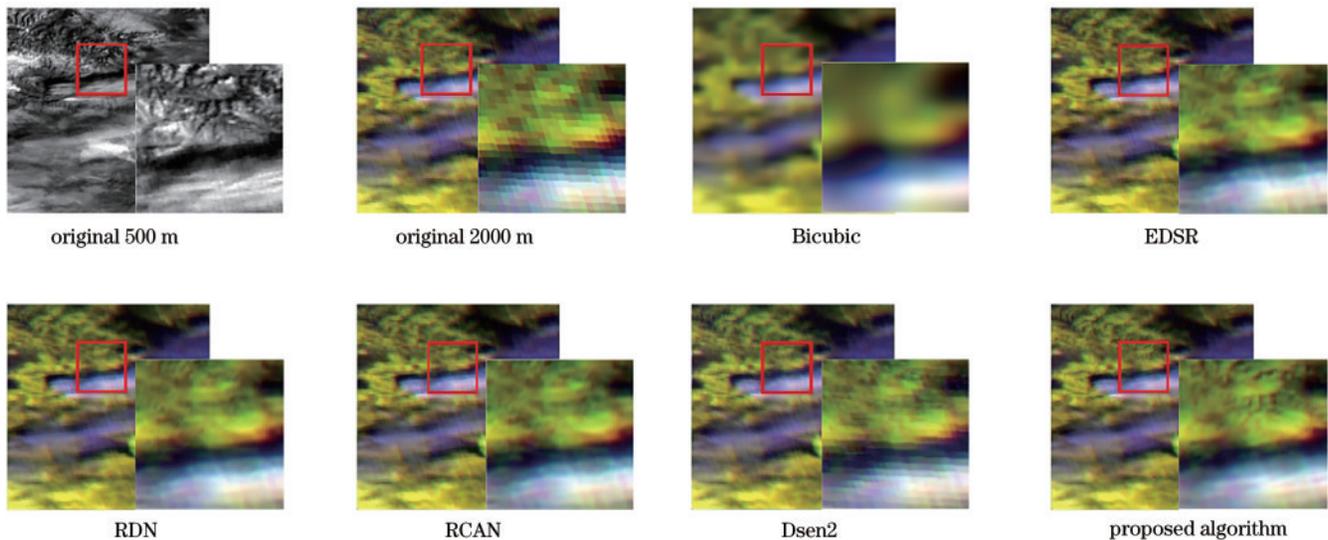


图 10 各算法 4 倍超分辨率重建结果

Fig. 10 4× super-resolution reconstruction results of each algorithm

理恢复较为自然,有效提升了图像的视觉效果;哨兵二号图像超分辨率方法 Dsen2 有效提高了重建图像的锐度和细节纹理,但是棋盘效应比较明显。由于所提算法更加考虑高分辨率图像与低分辨率图像之间的相关性,自适应融合低分辨率图像和高分辨率图像相似的内容和纹理特征,重建后的纹理细节更加清晰,重建效果优于其他算法。所提算法的客观评价指标 E_{RMSE} 值、 A_{SAM} 值、 S_{ERGAS} 值和 R_{SRE} 值也均优于其他算法。实验数据充分说明,所提算法相比其他算法客观评价指标有所提高,获得了更加清晰的细节纹理。

5 结 论

结合参考图像超分辨率方法,提出一种基于匹配提取与跨尺度特征融合的风云四号卫星图像超分辨率重建方法,以最高分辨率作为参考图像,辅助重建低分

辨率的可见光与近红外波段。实验结果表明,所提方法能充分利用可见光 500 m 最高分辨率波段信息来提高可见光 1000 m 波段和近红外 2000 m 波段的空间分辨率, E_{RMSE} 、 S_{ERGAS} 和 A_{SAM} 比其他方法更低、 R_{SRE} 更高,且重建结果细节信息更丰富,光谱曲线与原数据差异较小。即参考图像超分辨率方法在风云四号卫星图像超分辨率重建中具有较大的潜力。由于时间和水平有限,所提方法仅使用风云四号数据,不能有效地对其他卫星数据进行超分辨率重建,因此可考虑使用多种数据的图像信息一起放入训练模型中训练网络参数,增强网络的通用性。此外,将尝试把重建后的风云四号图像应用到积雪监测、水资源管理、气候变化等领域。

参 考 文 献

- [1] 高慧婷, 鲍书龙, 梁华, 等. 风云四号卫星闪电成像仪

- 虚警滤除方法[J]. 光学学报, 2021, 41(9): 0911001.
- Gao H T, Bao S L, Liang H, et al. Filtering algorithm for non lightning events using the FY-4 lightning mapping imager[J]. Acta Optica Sinica, 2021, 41(9): 0911001.
- [2] 王清平, 朱雯娜, 王勇, 等. FY-4A 资料在乌鲁木齐机场浓雾天气监测中的初步应用[J]. 气象, 2021, 47(5): 627-637.
- Wang Q P, Zhu W N, Wang Y, et al. Preliminary application of FY-4A satellite data in dense fog weather events at Urumqi international airport[J]. Meteorological Monthly, 2021, 47(5): 627-637.
- [3] 李涛, 王凌云, 王磊, 等. 一种基于 FY-4A 遥感数据的渤海海冰反演算法[J]. 电子设计工程, 2022, 30(1): 1-6.
- Li T, Wang L Y, Wang L, et al. An inversion algorithm of Bohai Sea ice based on FY-4A remote sensing data[J]. Electronic Design Engineering, 2022, 30(1): 1-6.
- [4] 张永宏, 曹海啸, 阚希. 基于 FY-4A/AGRI 时空特征融合的新疆地区积雪判识[J]. 遥感技术与应用, 2020, 35(6): 1337-1347.
- Zhang Y H, Cao H X, Kan X. Snow cover recognition for Xinjiang based on the fusion of FY-4A/AGRI spatial and temporal characteristics[J]. Remote Sensing Technology and Application, 2020, 35(6): 1337-1347.
- [5] 乔海伟, 张彦丽. 融合 FY-3C 号和 FY-4A 号卫星数据的积雪面积变化研究: 以祁连山区为例[J]. 遥感技术与应用, 2020, 35(6): 1320-1328.
- Qiao H W, Zhang Y L. FY-3C and FY-4A satellite data were combined to study the variation of snow cover area: a case study of Qilian Mountains[J]. Remote Sensing Technology and Application, 2020, 35(6): 1320-1328.
- [6] 姜红, 何清, 曾晓青, 等. 基于随机森林和卷积神经网络的 FY-4A 号卫星沙尘监测研究[J]. 高原气象, 2021, 40(3): 680-689.
- Jiang H, He Q, Zeng X Q, et al. Sand and dust monitoring using FY-4A satellite data based on the random forests and convolutional neural networks[J]. Plateau Meteorology, 2021, 40(3): 680-689.
- [7] 康军梅, 隋立春, 李丽, 等. 基于双稀疏度 K-SVD 字典学习的遥感影像超分辨率重建[J]. 计算机工程与应用, 2018, 54(16): 187-191.
- Kang J M, Sui L C, Li L, et al. Super-resolution reconstruction of remote sensing images based on double-sparse K-SVD dictionary learning[J]. Computer Engineering and Applications, 2018, 54(16): 187-191.
- [8] 周子勇. 运用经验模态分解和压缩感知方法进行遥感影像超分辨率重建[J]. 遥感技术与应用, 2018, 33(1): 96-102.
- Zhou Z Y. Super-resolution reconstruction of remote sensing images by using empirical mode decomposition and compressed sensing[J]. Remote Sensing Technology and Application, 2018, 33(1): 96-102.
- [9] Chan J C W, Ma J L, Kempeneers P, et al. Superresolution enhancement of hyperspectral CHRIS/Proba images with a thin-plate spline nonrigid transform model[J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(6): 2569-2579.
- [10] Galbraith A E, Theiler J, Thome K J, et al. Resolution enhancement of multi-look imagery for the multispectral thermal imager[J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(9): 1964-1977.
- [11] Ma J L, Chan J C W, Canters F. An Operational super-resolution approach for multi-temporal and multi-angle remotely sensed imagery[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2012, 5(1): 110-124.
- [12] Li F, Jia X P, Fraser D, et al. Super-resolution for remote sensing images based on a universal hidden Markov tree model[J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(3): 1270-1278.
- [13] Shen H F, Ng M K, Li P X, et al. Super-resolution reconstruction algorithm to MODIS remote sensing images[J]. The Computer Journal, 2007, 52(1): 90-100.
- [14] Banaras C, Bioucas-Dias J, Galliani S, et al. Super-resolution of Sentinel-2 images: learning a globally applicable deep neural network[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2018, 146: 305-319.
- [15] 石神, 尹增山, 王龙. 暗通道与交叉通道多先验联合多光谱超分辨率算法[J]. 光学学报, 2022, 42(10): 1010001.
- Shi S, Yin Z S, Wang L. Dark channel and cross channel based multi-prior combined multi-spectral super-resolution algorithm[J]. Acta Optica Sinica, 2022, 42(10): 1010001.
- [16] Dong C, Loy C C, He K M, et al. Image super-resolution using deep convolutional networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(2): 295-307.
- [17] Kim J, Lee J K, Lee K M. Deeply-recursive convolutional network for image super-resolution[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 1637-1645.
- [18] 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, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 1132-1140.
- [19] 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), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 105-114.
- [20] Wang X T, Yu K, Wu S X, et al. ESRGAN: enhanced super-resolution generative adversarial networks[M]//Leal-Taixé L, Roth S. Computer vision-ECCV 2018 workshops. Lecture notes in computer science. Cham: Springer, 2019, 11133: 63-79.
- [21] 程德强, 蔡迎春, 陈亮亮, 等. 边缘修正的多尺度卷积神经网络重建算法[J]. 激光与光电子学进展, 2018, 55(9): 091003.
- Cheng D Q, Cai Y C, Chen L L, et al. Multi-scale

- convolutional neural network reconstruction algorithm based on edge correction[J]. *Laser & Optoelectronics Progress*, 2018, 55(9): 091003.
- [22] 高青青, 赵建伟, 周正华. 基于递归多尺度卷积网络的图像超分辨率重建[J]. *模式识别与人工智能*, 2020, 33(11): 972-980.
- Gao Q Q, Zhao J W, Zhou Z H. Image super-resolution reconstruction based on recursive multi-scale convolutional networks[J]. *Pattern Recognition and Artificial Intelligence*, 2020, 33(11): 972-980.
- [23] 辛元雪, 朱凤婷, 史朋飞, 等. 基于改进增强型超分辨率生成对抗网络的图像超分辨率重建算法[J]. *激光与光电子学进展*, 2022, 59(4): 0420002.
- Xin Y X, Zhu F T, Shi P F, et al. Super-resolution reconstruction algorithm of images based on improved enhanced super-resolution generative adversarial network[J]. *Laser & Optoelectronics Progress*, 2022, 59(4): 0420002.
- [24] Pouliot D, Latifovic R, Pasher J, et al. Landsat super-resolution enhancement using convolution neural networks and sentinel-2 for training[J]. *Remote Sensing*, 2018, 10(3): 394.
- [25] Zhang K X, Sumbul G, Demir B. An approach to super-resolution of sentinel-2 images based on generative adversarial networks[C]//2020 Mediterranean and Middle-East Geoscience and Remote Sensing Symposium (M2GARSS), March 9-11, 2020, Tunis, Tunisia. New York: IEEE Press, 2020: 69-72.
- [26] Xiao A R, Wang Z Y, Wang L, et al. Super-resolution for Jilin-1 satellite video imagery via a convolutional network[J]. *Sensors*, 2018, 18(4): 1194.
- [27] 贺智, 贺丹. 基于深度学习的高分四号卫星图像超分辨率重建[J]. *遥感学报*, 2020, 24(12): 1500-1510.
- He Z, He D. Deep learning-based super-resolution for GF-4 satellite imagery[J]. *Journal of Remote Sensing*, 2020, 24(12): 1500-1510.
- [28] 李路, 倪卓娅, 漆成莉, 等. 风云四号B星干涉式红外探测仪发射前辐射定标[J]. *光学学报*, 2022, 42(6): 0630001.
- Li L, Ni Z Y, Qi C L, et al. Pre-launch radiometric calibration of geostationary interferometric infrared sounder on FengYun-4B satellite[J]. *Acta Optica Sinica*, 2022, 42(6): 0630001.
- [29] Lu L Y, Li W B, Tao X, et al. MASA-SR: matching acceleration and spatial adaptation for reference-based image super-resolution[EB/OL]. (2021-06-04) [2022-03-04]. <https://arxiv.org/abs/2106.02299>.
- [30] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [31] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2014-09-04) [2022-03-04]. <https://arxiv.org/abs/1409.1556>.
- [32] Aggarwal H K, Majumdar A. Hyperspectral image denoising using spatio-spectral total variation[J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 13(3): 442-446.
- [33] Zhang Y L, Li K P, Li K, et al. Image super-resolution using very deep residual channel attention networks[EB/OL]. (2018-07-08) [2022-03-04]. <https://arxiv.org/abs/1807.02758>.
- [34] Zhang Y L, Tian Y P, Kong Y, et al. Residual dense network for image super-resolution[EB/OL]. (2018-02-24) [2022-03-05]. <https://arxiv.org/abs/1802.08797>.