

基于深度学习的 SAR 辅助下光学遥感图像去云方法

王梦瑶, 孟祥超*, 邵枫**, 符冉迪

宁波大学信息科学与工程学院, 浙江 宁波 315211

摘要 针对现有基于深度学习的 SAR 辅助下光学图像去云方法对光学图像纹理、光谱信息考虑不足, 导致去云后影像往往存在模糊、光谱损失等现象, 根据杭州市余杭区哨兵一号 (Sentinel-1) 和哨兵二号 (Sentinel-2) 卫星影像, 构建了 SAR 辅助下光学图像去云数据库, 并充分考虑光学遥感图像的细节、纹理以及色彩信息, 建立了基于条件生成对抗网络 (conditional generative adversarial network, cGAN) 的 SAR 辅助下的光学遥感图像去云模型, 实现了 SAR 辅助下光学图像薄云、雾、厚云等覆盖下地物信息的有效复原与重建。实验结果表明, 所提方法可有效实现 SAR 辅助下的光学图像去云, 相比于其他方法具有更优性能。

关键词 遥感; 云去除; 条件生成对抗网络 (cGAN); 合成孔径雷达 (SAR) 图像; 光学图像; 影像融合

中图分类号 TP751.1

文献标志码 A

doi: 10.3788/AOS202141.1228002

SAR-Assisted Optical Remote Sensing Image Cloud Removal Method Based on Deep Learning

Wang Mengyao, Meng Xiangchao*, Shao Feng**, Fu Randi

Faculty of Electrical Engineering and Computer Science, Ningbo University, Ningbo, Zhejiang 315211, China

Abstract The existing deep learning based SAR-assisted cloud removal methods do not take full into account the texture and spectral information of the optical images, which results in blurring and spectral loss. In this paper, we constructed a data set for SAR-assisted cloud removal based on the Sentinel-1 and Sentinel-2 satellite images in Yuhang District of Hangzhou. In addition, we established a conditional generative adversarial network (cGAN) based model by fully considering the details, texture, and color information of optical remote sensing images, achieving information recovery and reconstruction in the case of optical images covered by thin clouds, fog, and thick clouds. The results show that the proposed method outperforms other methods in SAR-assisted cloud removal.

Key words remote sensing; cloud removal; conditional generative adversarial network (cGAN); synthetic aperture radar (SAR) image; optical image; image fusion

OCIS codes 100.2000; 110.2960; 280.6730; 350.2660

1 引言

光学卫星遥感图像具有分辨率高、视觉特征明显、可解释性强等优点, 但易受到云雾覆盖等的影响。合成孔径雷达 (SAR) 具有全天时、全天候成像的优势, 可为光学遥感图像中云雾的去除提供有效辅助信息。但光学遥感图像和 SAR 图像的成像方

式迥异, 其图像地物表达存在较大差异, 因此实现 SAR 辅助下的光学遥感图像去云, 得到无云覆盖的光学遥感图像具有重要意义。

目前, 已提出大量光学遥感图像去云方法, 其总体可分为三类^[1]: 基于光谱的云去除方法、基于空间的云去除方法和基于时间的云去除方法。基于光谱的云去除方法主要以对云雾有较强穿透能力的波段

收稿日期: 2021-01-06; 修回日期: 2021-01-21; 录用日期: 2021-02-01

基金项目: 国家自然科学基金(41801252)、国家自然科学基金(62071261)、中国博士后科学基金(2020M672490)

* E-mail: mengxiangchao@nbu.edu.cn; ** E-mail: shaofeng@nbu.edu.cn

作为辅助信息,利用谱带之间的相关性,对云污染波段进行去云处理,如基于多项式拟合的方法^[2-6],该类方法主要适用于薄云处理,当图像所有波段都对云雾不透明时,如厚云覆盖,该类方法将不可用。基于空间的方法主要基于云覆盖区域与图像中其他区域具有类似统计分布和几何结构的假设,利用自身无云覆盖区域对云覆盖区域进行信息复原与重建,代表性方法包括插值法^[7-8]、传播扩散法^[9-10]、基于变分的方法^[11]以及基于示例的方法^[12]等。但此类方法通常用于小区域缺失信息的修复,对云覆盖区域较大的影像处理效果有限。基于时间的方法利用其他时相无云覆盖数据对云覆盖影像进行修复,主要包括替换法^[13-18]、过滤法^[19]和基于学习的方法^[20-21]等,但该类方法需假设不同时相影像无较大的地物变化,对数据获取要求较高。SAR 具有全天时、全天候观测能力,不受云雾覆盖的影响,可以为光学遥感图像云的去云提供有效辅助信息,因此,基于 SAR 图像辅助的光学遥感图像去云方法近年来受到广泛关注。如 Hoan 等^[22]在 SAR 数据和光学遥感数据中地物相似的前提下,提出一种基于 SAR 数据的插值去云方法,然而,该方法难以完美重建云覆盖下缺失的地物细节。Huang 等^[23]基于稀疏表达将低分辨率 MODIS 光学图像和 SAR 图像作为辅助图像来重建高分辨率 Landsat 图像的受云污染区域,但在实际应用中,针对其他卫星影像同时获取低分和高分 SAR 图像存在较大难度。Liu 等^[24]试图通过利用循环一致性生成对抗网络(cycleGAN)将 SAR 图像转换成光学图像,以取代光学遥感图像中受云污染的区域,之后 Reyes 等^[25]讨论了文献^[24]提出模型的有效性和可行性。Grohnfeldt 等^[26]通过利用条件生成对抗网络(cGAN)直接将 SAR 图像和受云污染的光学图像进行融合,最终获得无云的光学遥感图像。

总体而言,SAR 辅助下的光学图像去云方法已引起关注,并形成了一些实用的方法,其中,基于深度学习的 SAR 辅助下光学图像去云方法为研究热点,但现有研究存在两方面问题亟待解决:1)缺少 SAR 辅助下光学图像去云数据库;2)现有基于深度学习对目标光学图像的亮度和光谱信息考虑欠佳,导致去云后影像存在模糊效应,且地物往往存在光谱畸变。针对上述问题,本文建立了 SAR 辅助光学遥感图像数据库,并提出一种基于条件生成对抗网络的 SAR 图像辅助下的光学遥感图像去云算法,综合考虑图像的细节、纹理以及色彩信息,可以更好地

恢复出被云遮挡的光学遥感图像。此外,相比于传统方法,本文方法可同时处理薄云、厚云遮挡图像。

2 生成对抗网络

生成对抗网络(GAN)由 Goodfellow 等^[27]首次提出,已广泛应用于语义分割^[28]、图像分辨^[29]、图像翻译^[30]等领域。GAN 的基本思想是同时训练两个对抗性网络即生成器 G 和判别器 D,其中生成器 G 的目标是使输出图像更接近真实图像,利用判别器 D 判别生成图像是否为“真实”,输出图片是否为真实的概率,如果输出为 1,就代表此图片为真实图片,而若输出为 0,就代表其不可能是真实图片。因此,输出结果越接近 1,则生成图像越接近真实图像。GAN 的损失函数定义为

$$\min_G \max_D \mathcal{L}_{\text{GAN}}(G, D) =$$

$$E\{\log[D(\mathbf{x})]\} + E\{\log[1 - D[G(\mathbf{z})]]\}, \quad (1)$$

式中: E 为期望值; \mathbf{x} 为真实数据; \mathbf{z} 为随机噪声向量; $D(\mathbf{x})$ 表示判断输入数据是否真实的概率; $G(\mathbf{z})$ 表示由生成器生成的图像; $D[G(\mathbf{z})]$ 表示判断生成器生成的图像是否真实的概率。

GAN 有很好的生成能力,通过让生成网络和判别网络相互对抗并学习,使网络达到纳什均衡,但 GAN 网络很难训练,容易出现模式崩溃等问题。此外,GAN 是一种无监督网络,它通过一个随机噪声来生成服从某一分布的随机图像,所以其生成的结果是不受控制的。在实际问题中,经常需要根据某些条件来生成特定的图像,例如人们想要通过一个人年轻时的照片生成他老年时的模样,这就要求生成的图像要拥有某些输入图像的特征。为此,Isola 等^[31]提出了 cGAN,在 GAN 网络中加入条件信息,使得生成的结果能够得到控制,以达到预期的效果。cGAN 的损失函数被定义为

$$\min_G \max_D \mathcal{L}_{\text{cGAN}}(G, D) =$$

$$E\{\log[D(\mathbf{x}, \mathbf{y})]\} + E\{\log[1 - D[G(\mathbf{y}), \mathbf{x}]]\}, \quad (2)$$

式中: \mathbf{y} 为条件信息; $D(\mathbf{x}, \mathbf{y})$ 表示将 \mathbf{x} 与 \mathbf{y} 输入判别网络后的输出; $G(\mathbf{y})$ 表示将 \mathbf{y} 输入生成网络后的输出; $D[G(\mathbf{y}), \mathbf{x}]$ 表示 $G(\mathbf{y})$ 生成的 \mathbf{x}' 与 \mathbf{x} 输入判别网络后的输出。在 cGAN 中生成网络的生成结果不再是随机的,而是基于输入的条件信息,这个条件信息可以是向量、标签或者图像。当生成网络的条件信息是图像时,生成网络将提取输入图像的特征,然后用于生成基于条件信息的图像。与 GAN

网络不同,cGAN 的判别网络除了要判断输入图像是否为真外,还需要判断输入图像与辅助图像是否匹配。不同的条件信息可以作为不同的目标函数,因此通过更改条件信息就能得到所需要的图像。目前,cGAN 被应用到越来越多的图像生成问题中。

3 本文方法

3.1 总体框架

本研究提出一种改进条件生成对抗神经网络的 SAR 辅助下的光学遥感图像去云方法,总体框架如图 1 所示。

1) 基于哨兵一号(Sentinel-1) SAR 和哨兵二号(Sentinel-2)光学图像(下载网址为 <https://scihub.copernicus.eu/dhus/>),建立 SAR 辅助下光学图像去云数据库。构建的 Sentinel-1 SAR 和 Sentinel-2

光学图像数据库位于浙江省杭州市余杭区(29°42'N~30°41'N,121°1'E~119°53'E),其中,Sentinel-1 SAR 图像选取干涉测量宽幅(IW)模式的地距多视(GRD)数据,空间分辨率为 10 m,并使用垂直发射水平接收(VH)通道的数据。Sentinel-2 光学图像选取 4、3、2 三个波段,空间分辨率为 10 m。首先,对来自 Sentinel-1 卫星的 SAR 图像利用哨兵应用平台(SNAP)软件^[32]进行轨道校正、热噪声去除、辐射定标、相干斑滤波和地形校正的预处理,然后将上述预处理后的 SAR 图像和光学图像进行配准,并将两者重合的区域进行裁剪与分块处理,最终得到 4214 对 256 pixel×256 pixel 的 SAR 和光学图像数据,其中包含有云、无云、不同时相以及不同地物类型(如植被、水体和建筑物)的 SAR 和光学图像数据。部分图像样例见图 2。

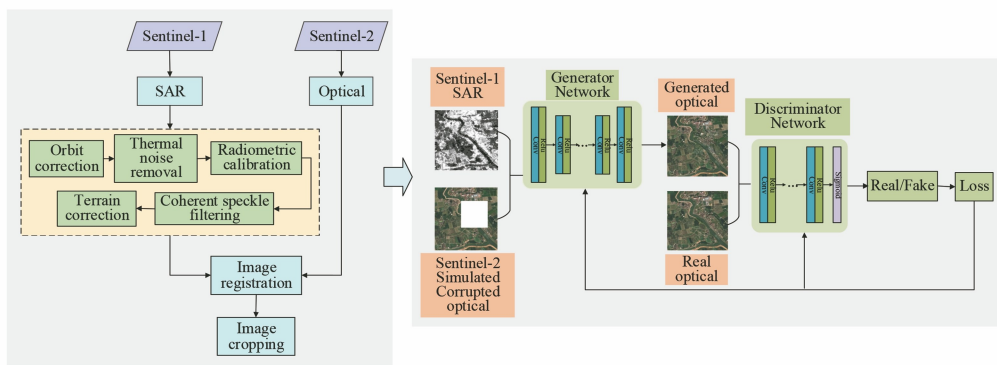


图 1 本文方法的总体流程图

Fig. 1 Overall flowchart of proposed method




图 2 图像样例

Fig. 2 Image samples

2) 基于构建的数据库,现有基于深度学习方法对目标光学图像的亮度和光谱信息考虑欠佳,导致去云后影像存在模糊效应,且地物光谱往往存在畸变的问题,基于 cGAN 网络,充分考虑图像的细节、纹理以及色彩信息,引入 SSIM 和 L1 范数构建 SAR 图像辅助下的光学遥感图像去云模型,将 SAR

图像和受云污染的光学图像作为生成网络的输入,并将所生成的光学图像与真实光学图像通过判别网络进行判别,以辨别所生成结果的真伪。

本文方法中生成网络分为编码-解码网络^[33]和跳跃连接两部分。在编码-解码网络的编码阶段,使用卷积核来提取输入图像的特征,并对图像进行下

采样;在解码阶段,同样使用卷积核来提取特征,并通过转置卷积^[34]对图像进行上采样。同时,所生成网络采用 U-net 结构^[35],由 8 个上采样层和 8 个下采样层构成,该结构在网络的第 i 层和第 $n-i$ 层之间设置跳跃连接,将编码过程中得到的特征图与解码过程中得到的特征图进行级联,实现了特征的重复使用,从而保证了生成图像的质量。同时为了防止网络过拟合,并加快网络训练的收敛速度,在卷积之后进行了批标准化(batch normalization)^[36]处理。

本文方法中判别网络不但需要判断输入数据是否为真实数据,还需要将数据与 SAR 图像进行匹配。判别网络先使用卷积层进行特征学习,然后将特征展开,使用全连接层得到一个向量,最后通过 sigmoid 函数得到一个 0 到 1 之间的概率值,该数值可以看作是输入图像为真并且与辅助信息匹配的概率。将生成网络生成的图像输入判别网络,当输出的结果越接近 1,则表示判别网络认为生成图像的分布越接近真实图像的分布,并且拥有辅助信息的特征。为了提高融合效果,本研究将 SAR 图像和云覆盖的光学图像一并作为生成网络的输入。

3.2 模型构建

本文方法的损失函数由对抗损失、 \mathcal{L}_1 损失和 SSIM 损失组成,即

$$L = \mathcal{L}_{\text{GAN}} + \lambda_1 \mathcal{L}_1 + \lambda_2 \mathcal{L}_{\text{SSIM}}, \quad (3)$$

式中: λ_1 和 λ_2 分别为 \mathcal{L}_1 和 $\mathcal{L}_{\text{SSIM}}$ 在损失函数中的权重系数。对抗损失 \mathcal{L}_{GAN} 可以表示为

$$\mathcal{L}_{\text{GAN}} = E \{ \log \{ D[\mathbf{I}_{\text{SAR}}, \mathbf{G}(\mathbf{I}_{\text{SAR}}, \mathbf{I}_{\text{CO}})] \} \} + E \{ \log [1 - D(\mathbf{I}_{\text{SAR}}, \mathbf{I}_{\text{GT}})] \}, \quad (4)$$

式中: \mathbf{I}_{SAR} 为 SAR 图像; \mathbf{I}_{CO} 为被云遮挡的光学图像; \mathbf{I}_{GT} 为真实的光学图像; $\mathbf{G}(\mathbf{I}_{\text{SAR}}, \mathbf{I}_{\text{CO}})$ 表示云覆盖图像和 SAR 图像辅助生成的光学图像。

\mathcal{L}_1 损失即 L1 范数的损失能量函数,反映了两幅图像之间的距离,距离越小说明两幅图像的差异越小。将生成网络生成的光学图像与真实的光学图像做 L1 范数运算,使生成的光学图像接近目标图像。本研究的 \mathcal{L}_1 损失可以表示为

$$\mathcal{L}_1 = E [\| \mathbf{I}_{\text{GT}} - \mathbf{G}(\mathbf{I}_{\text{SAR}}, \mathbf{I}_{\text{CO}}) \|]. \quad (5)$$

SSIM 系数^[37]反映了融合去云后图像与光学图像之间的结构相似性,图像纹理特征主要由图像的局部统计特征来表示,SSIM 可通过对两幅图像的均值、方差等数值进行计算得到,因此 SSIM 函数可以在一定程度上表征两幅图像纹理之间的相似度。本研究的 SSIM 损失可以定义为

$$V_{\text{SSIM}}[\mathbf{G}(\mathbf{I}_{\text{SAR}}, \mathbf{I}_{\text{CO}}), \mathbf{I}_{\text{GT}}] = \frac{2u_{\mathbf{G}(\mathbf{I}_{\text{SAR}}, \mathbf{I}_{\text{CO}})}u_{\mathbf{I}_{\text{GT}}} + C_1}{u_{\mathbf{G}(\mathbf{I}_{\text{SAR}}, \mathbf{I}_{\text{CO}})}^2 + u_{\mathbf{I}_{\text{GT}}}^2 + C_1} \cdot \frac{2\sigma_{[\mathbf{G}(\mathbf{I}_{\text{SAR}}, \mathbf{I}_{\text{CO}}), \mathbf{I}_{\text{GT}}]} + C_2}{\sigma_{\mathbf{G}(\mathbf{I}_{\text{SAR}}, \mathbf{I}_{\text{CO}})}^2 + \sigma_{\mathbf{I}_{\text{GT}}}^2 + C_2}, \quad (6)$$

式中: $u_{\mathbf{G}(\mathbf{I}_{\text{SAR}}, \mathbf{I}_{\text{CO}})}$ 和 $u_{\mathbf{I}_{\text{GT}}}$ 分别为生成网络生成的光学图像和真实光学图像的均值; $\sigma_{\mathbf{G}(\mathbf{I}_{\text{SAR}}, \mathbf{I}_{\text{CO}})}$ 和 $\sigma_{\mathbf{I}_{\text{GT}}}$ 分别为生成网络生成的光学图像和真实光学图像的标准差; $\sigma_{\mathbf{G}(\mathbf{I}_{\text{SAR}}, \mathbf{I}_{\text{CO}})}^2$ 和 $\sigma_{\mathbf{I}_{\text{GT}}}^2$ 分别为生成网络生成的光学图像和真实光学图像的方差; $\sigma_{[\mathbf{G}(\mathbf{I}_{\text{SAR}}, \mathbf{I}_{\text{CO}}), \mathbf{I}_{\text{GT}}]}$ 为生成网络生成的光学图像和真实光学图像的协方差; C_1 和 C_2 是为避免分母为 0 而设置的常数。SSIM 表征图像的局部相似性,在计算两幅图像的 SSIM 值时,通常先选取一个窗口 P 内的像素来计算 SSIM 值,然后滑动窗口并取平均值得到整幅图像的 SSIM 值。本研究选取的 SSIM 滑动窗口大小为 11 pixel×11 pixel。在计算 SSIM 时,图像的均值、标准差和协方差由一个标准差为 σ_G 的高斯滤波器计算得出,滤波器的大小与选取滑动窗口的大小相同,则窗口 P 的 SSIM 损失可以定义为

$$\mathcal{L}_{\text{SSIM-P}}(\mathbf{p}_{\mathbf{G}(\mathbf{I}_{\text{SAR}}, \mathbf{I}_{\text{CO}})}, \mathbf{p}_{\mathbf{I}_{\text{GT}}}) = 1 - V_{\text{SSIM}}(\mathbf{p}_{\mathbf{G}(\mathbf{I}_{\text{SAR}}, \mathbf{I}_{\text{CO}})}, \mathbf{p}_{\mathbf{I}_{\text{GT}}}), \quad (7)$$

式中: $\mathbf{p}_{\mathbf{G}(\mathbf{I}_{\text{SAR}}, \mathbf{I}_{\text{CO}})}$ 和 $\mathbf{p}_{\mathbf{I}_{\text{GT}}}$ 分别为窗口 P 的生成网络生成的光学图像和真实的光学图像。将所有窗口的 SSIM 求平均可以得到整幅图像的 SSIM 值,则本研究的 SSIM 损失可以表示为

$$\mathcal{L}_{\text{SSIM}}[\mathbf{G}(\mathbf{I}_{\text{SAR}}, \mathbf{I}_{\text{CO}}), \mathbf{I}_{\text{GT}}] = \frac{1}{N} \sum \mathcal{L}_{\text{SSIM-P}}(\mathbf{p}_{\mathbf{G}(\mathbf{I}_{\text{SAR}}, \mathbf{I}_{\text{CO}})}, \mathbf{p}_{\mathbf{I}_{\text{GT}}}). \quad (8)$$

在网络的训练过程中,对判别网络和生成网络进行交替训练。在训练判别网络时,通过 Adam^[38]对网络参数进行优化。在训练生成网络时,先固定判别网络,再对网络参数进行优化。当生成网络和判别网络的训练到达纳什均衡后,生成网络可以作为去云模型。

4 实验结果与分析

4.1 数据和参数设置

在网络训练过程中,将生成网络的输入尺寸设置为 256 pixel×256 pixel×4 pixel,输出尺寸设置为 256 pixel×256 pixel×3 pixel,判别网络的输入尺寸设置为 256 pixel×256 pixel×9 pixel。设置参数 $\lambda_1 = 100$, $\lambda_2 = 100$, 并采用 Adam 来对网络参数进行优化,设置学习率为 0.0002,参数 β 为 0.5,生成网络和判别网络的交替训练比率设为 2,训练次数设为 200。

实验平台为 NVIDIA GeForce GTX 1080ti 和 Intel core i7 四核处理器,操作系统为 Windows 10,深度学习框架采用 TensorFlow,程序采用 Python

语言实现。

模拟实验和真实实验所使用的 SAR 和光学数据的相关信息见表 1。

表 1 模拟实验和真实实验的相关信息

Table 1 Information about simulated experiments and real experiments

Dataset	Simulated experiment			Real experiment		
	SAR	Optical	Simulated corrupted optical	SAR	Similar time phase optical	Real corrupted optical
Obtain time	2020.04.29	2020.04.28	2020.04.28	2020.05.23	2020.05.13	2020.06.17

4.2 模拟实验

基于余杭地区 4 月份 2107 对 SAR 和光学遥感影像数据集进行模拟实验。首先,对无云覆盖光学遥感影像进行掩模处理,以模拟被云遮挡的光学遥感图像。为避免掩模区域大小和位置导致的模式单一问题,随机选取掩模大小和位置进行数据模拟。然后,随机选取数据集中 80% 的数据作为训练集进

行网络模型训练,剩余 20% 的数据作为测试集对模型进行验证。为验证本文方法的有效性,选取 cGAN^[26]、pix2pix^[31] 网络模型进行对比分析。此外,为充分验证方法的有效性,本文方法中只利用 cGAN+SSIM 损失进行对比分析,同时,为了消除训练样本对不同网络的影响,本研究在训练不同网络时使用相同的训练集。实验结果如图 3 所示。

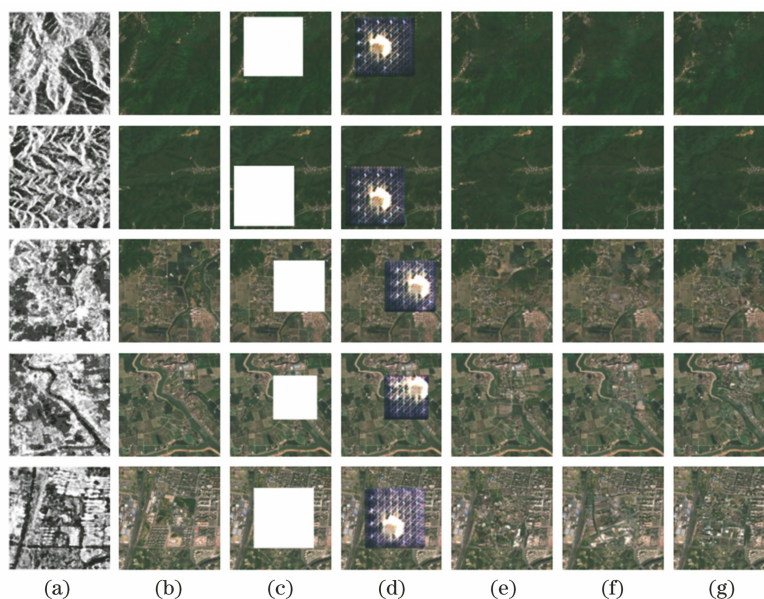


图 3 模拟实验结果。(a) SAR 图像;(b)真实光学图像;(c)模拟被云污染的光学图像;(d) cGAN 模型实验结果;(e) pix2pix 模型实验结果;(f) cGAN+SSIM 模型实验结果;(g)本文模型的实验结果

Fig. 3 Results of simulation experiments. (a) SAR images; (b) real optical images; (c) simulated optical images contaminated by clouds; (d) experimental results of cGAN model; (e) experimental results of pix2pix model; (f) experimental results of cGAN+SSIM model; (g) experimental results of proposed model

图 3(a)~(c)所示分别为 SAR 图像、真实光学图像以及模拟被云污染的光学图像,图 3(d)~(g)所示分别为 cGAN 模型、pix2pix 模型、cGAN+SSIM 模型以及本文模型的实验结果。此外,为了评价不同方法的生成结果,使用结构相似性指数(SSIM)、相关系数(CC)、峰值信噪比(PSNR)、全局相对误差(ERGAS)以及光谱角(SAM)作为客观评价指标。其中:结构相似性是用来衡量两幅图像相

似程度的指标,其数值越大表示两幅图像的相似度越高;相关系数是用来衡量两个变量之间线性相关程度的指标,其数值越大表示相关性越高;峰值信噪比是用来衡量图像失真程度的指标,其数值越大表示图像质量越好;全局相对误差是从整体上反映图像质量的指标,其数值越小表示光谱质量越高;光谱角是用来衡量图像像素间相关程度的指标,其数值越小表示两幅图像之间像素匹配度越高。模拟实验

的各个客观评价指标的均值及其 95% 置信区间如表 2 所示,其中,最优结果以粗体显示,次优结果以下划线表示。

从图 3 所示的模拟实验结果可以看出:cGAN 模型的生成结果较差,基本上没有恢复出光学遥感图像中被云污染的部分;pix2pix 模型、cGAN+SSIM 模型以及本文模型的生成结果基本上能将光学遥感图像被云污染部分恢复出来,并且可以

将光学图像的颜色和结构信息恢复得很好。相对于 pix2pix 模型和 cGAN+SSIM 模型的生成结果,本文模型的生成结果不仅可以很好地恢复光学图像的颜色和结构信息,而且可以更好地恢复光学图像的部分细节信息,使其更接近目标图像。同时,从表 2 可以看出,本文方法生成结果的客观评价指标均优于其他 3 种方法,体现了本文模型的优越性。

表 2 模拟实验定量评价结果(均值和 95% 置信区间)

Table 2 Quantitative evaluation results of simulation experiments (mean and 95% confidence interval)

	Model	Proposed model	cGAN+SSIM	pix2pix	cGAN
SSIM	Mean	0.8655	<u>0.8604</u>	0.8558	0.7241
	95% confidence interval	(0.860,0.871)	<u>(0.855,0.866)</u>	(0.850,0.861)	(0.718,0.730)
CC	Mean	0.8443	<u>0.8399</u>	0.8349	0.3732
	95% confidence interval	(0.836,0.852)	<u>(0.832,0.848)</u>	(0.827,0.843)	(0.359,0.388)
PSNR	Mean	27.5886	<u>27.5141</u>	27.3213	16.2218
	95% confidence interval	(27.218,27.960)	<u>(27.126,27.902)</u>	(26.937,27.705)	(16.158,16.285)
ERGAS	Mean	20.2244	<u>20.2382</u>	20.8326	76.6522
	95% confidence interval	(19.640,20.809)	<u>(19.630,20.846)</u>	(20.208,21.457)	(72.501,80.803)
SAM	Mean	1.9194	2.0704	<u>2.0117</u>	6.5556
	95% confidence interval	(1.874,1.965)	(2.028,2.113)	<u>(1.979,2.056)</u>	(6.415,6.696)

4.3 真实实验

基于真实数据对本文方法进行验证。为验证本文方法的有效性,选取同一区域临近时间无云覆盖

的光学遥感图像作为目标图像,实验结果见图 4。

图 4(a)~(c)所示分别为真实实验结果中 SAR 图像、相近时相的无云覆盖光学影像以及真实被云

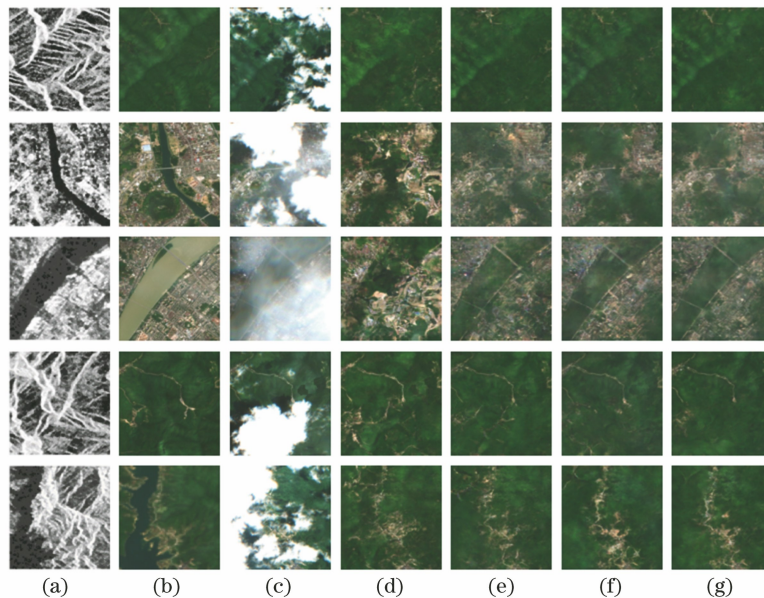


图 4 真实实验结果。(a) SAR 图像;(b)相近时相的无云覆盖光学影像;(c)云覆盖光学遥感图像;(d) cGAN 实验结果;(e) pix2pix 实验结果;(f) cGAN+SSIM 实验结果;(g)本文模型实验结果

Fig. 4 Results of real experiments. (a) SAR images; (b) optical images without cloud cover in a similar time phase; (c) optical remote sensing images with cloud cover; (d) experimental results of cGAN model; (e) experimental results of pix2pix model; (f) experimental results of cGAN+SSIM model; (g) experimental results of proposed model

覆盖的光学遥感图像,图 4(d)~(g)所示分别为 cGAN 模型、pix2pix 模型、cGAN+SSIM 模型以及本文模型的实验结果。此外,真实实验的客观评价

指标 SSIM、CC、PSNR、ERGAS、SAM 的均值及其 95%置信区间如表 3 所示,最优结果以粗体显示,次优结果以下划线表示。

表 3 真实实验定量评价结果(均值和 95%置信区间)

Table 3 Quantitative evaluation results of real experiments (mean and 95% confidence interval)

	Model	Proposed model	cGAN+SSIM	pix2pix	cGAN
SSIM	Mean	0.7467	<u>0.7371</u>	0.7073	0.6149
	95% confidence interval	(0.737, 0.756)	<u>(0.728, 0.747)</u>	(0.697, 0.718)	(0.601, 0.629)
CC	Mean	0.5820	<u>0.5655</u>	0.5455	0.4398
	95% confidence interval	(0.558, 0.606)	<u>(0.542, 0.589)</u>	(0.522, 0.569)	(0.415, 0.465)
PSNR	Mean	23.8033	<u>23.5446</u>	23.3409	20.5477
	95% confidence interval	(23.448, 24.158)	<u>(23.199, 23.891)</u>	(22.998, 23.684)	(20.215, 20.880)
ERGAS	Mean	29.9719	<u>31.0080</u>	31.4202	43.5042
	95% confidence interval	(28.981, 30.963)	<u>(30.062, 31.955)</u>	(30.453, 32.388)	(42.023, 44.986)
SAM	Mean	4.3423	4.7061	<u>4.5815</u>	5.3864
	95% confidence interval	(4.202, 4.483)	(4.570, 4.842)	<u>(4.440, 4.723)</u>	(5.213, 5.560)

从图 4 所示的真实实验结果可以看出,cGAN、pix2pix、cGAN+SSIM 以及本文方法生成的光学图像都具有相对准确的光谱信息,并且能在一定程度上反映地物信息,但是前 3 种方法生成的光学图像中纹理信息恢复得不够好,本文方法在纹理信息还原上的表现优于其他 3 种方法。此外,如图 4 所示,本文方法可同时去除薄云和厚云,对于云量较少区域,本文方法可有效复原云覆盖下的地物信息;而对于大面积厚云覆盖区域,本文方法和其他对比方法均难以充分利用自身信息实现云覆盖下真实地物信息的有效重建,即图 4 最后一行图像中的河流信息未得到有效修复。从表 3 所示的真实实验各客观评价指标的均值以及 95%置信区间也可以看出本文方法的优越性。总之,主观评价结果和客观评价指标均说明了本文方法相对于其他方法的优越性。

综上所述,本文模型是一个融合 SAR 图像和光学图像的模型,输出结果中不仅含有 SAR 图像的特征,还将直接继承光学图像中未被云覆盖区域的特点,因此所生成图像不论从纹理、结构还是颜色上都表现出较好的结果。在不同地物上,不同的方法也有不同的表现,比如在只有水体和植被的区域,本文模型所生成的光学图像效果较好,而在包含信息较多,地物较复杂的区域,所生成的光学图像效果相对来说就差一些。总而言之,在大多数区域,本文方法所生成的图像具有较高的质量指数和较好的视觉效果。

5 结 论

现有的 SAR 辅助下光学遥感图像去云方法中主要存在两个方面的问题:1)缺少 SAR 辅助下光学

图像去云数据库;2)传统方法难以同时去除薄云、雾、厚云。而现有基于深度学习方法对光学图像纹理、光谱信息考虑不足,导致去云后影像往往存在模糊、光谱损失等现象。本研究构建了浙江省杭州市余杭区 Sentinel-1 SAR 图像和 Sentinel-2 光学图像数据库,建立了一种基于改进条件生成对抗网络模型的 SAR 图像辅助下的光学图像去云模型,综合考虑 SAR 和光学图像的特性,实现了光学遥感图像薄云、厚云下地物信息的有效复原与重建。主观评价和客观评价结果均表明,该方法具有良好的视觉效果和较高的精度,可以有效去除光学遥感图像中的云遮挡。

本文方法虽然获得了一定的效果,并优于其他类似的方法,但仍存在一些局限性,如本文方法对厚云覆盖下缺失地物细节难以完美重建;所构建数据库中仅包含 4214 对余杭地区 SAR 和光学图像数据,数据库偏小。后续研究将在现有数据库的基础上进行扩充,构建大型多时相 SAR 辅助下的光学遥感图像去云数据库,充分利用多时相数据增强模型的稳健和泛化能力。此外,本实验中网络输入与输出图像的尺寸均为 256 pixel×256 pixel,而在实际工程应用中,遥感图像的尺寸通常远大于该尺寸,在实验中需要将遥感图像分割成许多小尺寸的图像进行验证,这往往会导致图像中的一些信息丢失,难以满足工程应用需求,后续将结合大场景遥感影像的去云需求,研究基于深度学习的 SAR 辅助下光学遥感图像去云方法。

参 考 文 献

- [1] Shen H F, Li X H, Cheng Q, et al. Missing

- information reconstruction of remote sensing data: a technical review [J]. *IEEE Geoscience and Remote Sensing Magazine*, 2015, 3(3): 61-85.
- [2] Wang L L, Qu J J, Xiong X X, et al. A new method for retrieving band 6 of Aqua MODIS [J]. *IEEE Geoscience and Remote Sensing Letters*, 2006, 3(2): 267-270.
- [3] Rakwatin P, Takeuchi W, Yasuoka Y. Restoration of Aqua MODIS band 6 using histogram matching and local least squares fitting[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 47(2): 613-627.
- [4] Shen H F, Zeng C, Zhang L P. Recovering reflectance of AQUA MODIS band 6 based on within-class local fitting [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2011, 4(1): 185-192.
- [5] Gladkova I, Grossberg M D, Shahriar F, et al. Quantitative restoration for MODIS band 6 on Aqua [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(6): 2409-2416.
- [6] Shen H F, Li X H, Zhang L P, et al. Compressed sensing-based inpainting of Aqua moderate resolution imaging spectroradiometer band 6 using adaptive spectrum-weighted sparse Bayesian dictionary learning[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(2): 894-906.
- [7] Zhang C, Li W, Travis D. Gaps-fill of SLC-off Landsat ETM + satellite image using a geostatistical approach [J]. *International Journal of Remote Sensing*, 2007, 28(22): 5103-5122.
- [8] Yu C, Chen L F, Su L, et al. Kriging interpolation method and its application in retrieval of MODIS aerosol optical depth [C] // 2011 19th International Conference on Geoinformatics, June 24-26, 2011, Shanghai, China. New York: IEEE Press, 2011: 1-6.
- [9] Maalouf A, Carre P, Augereau B, et al. A bandelet-based inpainting technique for clouds removal from remotely sensed images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 47(7): 2363-2371.
- [10] Mendez-Rial R, Calvino-Cancela M, Martin-Herrero J. Anisotropic inpainting of the hypercube[J]. *IEEE Geoscience and Remote Sensing Letters*, 2012, 9(2): 214-218.
- [11] Shen H F, Zhang L P. A MAP-based algorithm for destriping and inpainting of remotely sensed images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 47(5): 1492-1502.
- [12] Cheng Q, Shen H F, Zhang L P, et al. Inpainting for remotely sensed images with a multichannel nonlocal total variation model[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(1): 175-187.
- [13] Lin C H, Tsai P H, Lai K H, et al. Cloud removal from multitemporal satellite images using information cloning [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, 51(1): 232-241.
- [14] Zeng C, Shen H F, Zhang L P. Recovering missing pixels for Landsat ETM + SLC-off imagery using multi-temporal regression analysis and a regularization method [J]. *Remote Sensing of Environment*, 2013, 131: 182-194.
- [15] Shen H F, Wu J G, Cheng Q, et al. A spatiotemporal fusion based cloud removal method for remote sensing images with land cover changes[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2019, 12(3): 862-874.
- [16] Li Z W, Shen H F, Cheng Q, et al. Thick cloud removal in high-resolution satellite images using stepwise radiometric adjustment and residual correction[J]. *Remote Sensing*, 2019, 11(16): 1925-1943.
- [17] Qin Y, Fu Z L, Li Y. Algorithm for cloud restoring based on texture synthesis algorithm[J]. *Journal of Nanchang University (Engineering & Technology)*, 2017, 39(2): 194-199.
- 秦永, 付仲良, 李颖. 基于纹理合成算法的光学影像云层修复[J]. *南昌大学学报(工科版)*, 2017, 39(2): 194-199.
- [18] Zhao S. The image restoration algorithm based on texture synthesis [D]. Chengdu: University of Electronic Science and Technology of China, 2014.
- 赵胜. 基于纹理合成的图像修复算法研究[D]. 成都: 电子科技大学, 2014.
- [19] Chen J, Jönsson P, Tamura M, et al. A simple method for reconstructing a high-quality NDVI time-series data set based on the Savitzky-Golay filter[J]. *Remote Sensing of Environment*, 2004, 91(3/4): 332-344.
- [20] Lorenzi L, Melgani F, Mercier G. Missing-area reconstruction in multispectral images under a compressive sensing perspective [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, 51(7): 3998-4008.
- [21] Li X H, Shen H F, Zhang L P, et al. Recovering quantitative remote sensing products contaminated by thick clouds and shadows using multitemporal dictionary learning [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(11):

- 7086-7098.
- [22] Hoan N T, Tateishi R. Cloud removal of optical image using SAR data for ALOS application: experimenting on simulated ALOS data[J]. *Journal of the Remote Sensing Society of Japan*, 2009, 29(2): 410-417.
- [23] Huang B, Li Y, Han X Y, et al. Cloud removal from optical satellite imagery with SAR imagery using sparse representation[J]. *IEEE Geoscience and Remote Sensing Letters*, 2015, 12(5): 1046-1050.
- [24] Liu L, Lei B. Can SAR images and optical images transfer with each other? [C] // 2018 IEEE International Geoscience and Remote Sensing Symposium, July 22-27, 2018, Valencia, Spain. New York: IEEE Press, 2018: 7019-7022.
- [25] Reyes M F, Auer S, Merkle N, et al. SAR-to-optical image translation based on conditional generative adversarial networks: optimization, opportunities and limits[J]. *Remote Sensing*, 2019, 11(17): 2067-2085.
- [26] Grohnfeldt C, Schmitt M, Zhu X X. A conditional generative adversarial network to fuse sar and multispectral optical data for cloud removal from Sentinel-2 images [C] // 2018 IEEE International Geoscience and Remote Sensing Symposium, July 22-27, 2018, Valencia, Spain. New York: IEEE Press, 2018: 1726-1729.
- [27] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets [C] // *Neural Information Processing Systems*, December 8-13, 2014, Montreal, Canada. New York: Curran Associates, 2014: 2672-2680.
- [28] Wang E D, Qi K, Li X P, et al. Semantic segmentation of remote sensing image based on neural network [J]. *Acta Optica Sinica*, 2019, 39(12): 1210001.
王恩德, 齐凯, 李学鹏, 等. 基于神经网络的遥感图像语义分割方法 [J]. *光学学报*, 2019, 39(12): 1210001.
- [29] Xiao J S, Liu E Y, Zhu L, et al. Improved image super-resolution algorithm based on convolutional neural network [J]. *Acta Optica Sinica*, 2017, 37(3): 0318011.
肖进胜, 刘恩雨, 朱力, 等. 改进的基于卷积神经网络的图像超分辨率算法 [J]. *光学学报*, 2017, 37(3): 0318011.
- [30] Li Y, Fu R D, Meng X C, et al. A SAR-to-optical image translation method based on conditional generation adversarial network (cGAN) [J]. *IEEE Access*, 2020, 8: 60338-60343.
- [31] Isola P, Zhu J Y, Zhou T H, et al. Image-to-image translation with conditional adversarial networks [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 5967-5976.
- [32] Zuhlke M, Fomferra N, Brockmann C, et al. SNAP (Sentinel Application Platform) and the ESA Sentinel 3 Toolbox [C] // *Sentinel-3 for Science Workshop*, June 2-5, 2015, Venice, Italy. Oxford: ESA Special Publication(SP-734), 2015, 978: 21.
- [33] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks [J]. *Science*, 2006, 313(5786): 504-507.
- [34] Zeiler M D, Taylor G W, Fergus R. Adaptive deconvolutional networks for mid and high level feature learning [C] // 2011 International Conference on Computer Vision, November 6-13, 2011, Barcelona, Spain. New York: IEEE Press, 2011: 2018-2025.
- [35] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation [C] // *Proceedings of the 18th International Conference on Medical Image Computing and Computer-Assisted Intervention*, October 5-9, 2015, Munich, Germany. *Lecture Notes in Electrical Engineering*, Singapore: Springer, 2015, 9351: 234-241.
- [36] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C] // *Proceedings of the 32nd International Conference on Machine Learning(ICML)*, July 6-11, 2015, Lille, France. *JMLR Workshop and Conference Proceedings*, 2015, 37: 448-456.
- [37] Wang Z, Bovik A C, Sheikh H R, et al. Image quality assessment: from error visibility to structural similarity [J]. *IEEE Transactions on Image Processing*, 2004, 13(4): 600-612.
- [38] Kingma D P, Ba J L. Adam: a method for stochastic optimization [C/OL]. (2014-12-22) [2020-10-18]. <https://arxiv.org/abs/1412.6980>.