

DOI:10.16136/j.joel.2023.12.0076

基于自注意力机制和 CycleGAN 的高分三号 ScanSAR 图像的扇贝效应抑制

孙增国^{1,2}, 彭学俊¹, 刘慧霞^{3*}, 陈卫荣⁴, 王鑫鹏¹

(1. 陕西师范大学 计算机科学学院, 陕西 西安 710119; 2. 地理信息工程国家重点实验室, 陕西 西安 710054;
3. 南通大学 电气工程学院, 江苏 南通 226019; 4. 中国资源卫星应用中心, 北京 100094)

摘要: 高分三号卫星是我国首颗分辨率达到 1 m 的 C 波段多极化合成孔径雷达 (synthetic aperture radar, SAR) 卫星, 其中扫描式合成孔径雷达 (scan synthetic aperture radar, ScanSAR) 模式是高分三号卫星重要的工作模式之一, 由于该模式的工作机制导致生成的图像可能发生扇贝效应, 一般呈现为明暗相间的条纹。本文针对高分三号卫星 ScanSAR 模式下存在的扇贝效应, 提出自注意力机制与循环一致对抗网络 (cycle-consistent adversarial networks, CycleGAN) 结合的模型对 ScanSAR 图像进行处理, 从而抑制扇贝效应产生的条纹现象。本文所示方法与传统扇贝效应抑制方法和深度学习相关算法进行比较, 并通过亮度均值、平均梯度等指标进行分析。实验结果表明, 本文方法可以对高分三号 ScanSAR 图像存在的扇贝效应进行较好的处理, 有效抑制图像的条纹现象, 使得图像质量得到提升, 具有较大的实用意义。

关键词: 高分三号; 扫描式合成孔径雷达 (ScanSAR) 图像; 扇贝效应; 循环一致对抗网络 (CycleGAN); 自注意力机制

中图分类号: TP751 **文献标识码:** A **文章编号:** 1005-0086(2023)12-1279-09

Descalloping of GF-3 ScanSAR image based on self-attention mechanism and CycleGAN

SUN Zengguo^{1,2}, PENG Xuejun¹, LIU Huixia^{3*}, CHEN Weirong⁴, WANG Xinpeng¹

(1. School of Computer Science, Shaanxi Normal University, Xi'an, Shaanxi 710119, China; 2. State Key Laboratory of Geo-Information Engineering, Xi'an, Shaanxi 710054, China; 3. School of Electrical Engineering, Nantong University, Nantong, Jiangsu 226019, China; 4. China Centre for Resources Satellite Data and Application, Beijing 100094, China)

Abstract: GF-3 satellite is the first C-band multi-polarimetric synthetic aperture radar satellite with a space resolution up to 1 m in China, in which scan synthetic aperture radar (ScanSAR) is one of the important mode of GF-3. The working mechanism of this mode results in the phenomena of serious nonuniformity, generally showing bright and dark stripes, also known as scalloping. In view of scalloping in ScanSAR mode of GF-3, this paper proposes a model combining self-attention mechanism and cycle-consistent adversarial networks (CycleGAN), so as to perform descalloping. The proposed descalloping method is compared with traditional descalloping methods and deep learning related algorithms, and analyzed by indicators such as brightness average and average gradient. The experimental results demonstrate that the proposed method in this paper can better complete descalloping in the GF-3 ScanSAR image, effectively suppress the stripes phenomenon of the image, and improve the image quality, which is of great practical significance.

Key words: GF-3; scan synthetic aperture radar (ScanSAR) image; scalloping; cycle-consistent adversarial networks (CycleGAN); self-attention mechanism

* E-mail: liuhx@ntu.edu.cn

收稿日期: 2022-02-13 修订日期: 2022-04-04

基金项目: 国家自然科学基金(61102163)和地理信息工程国家重点实验室基金(SKLGIE2019-M-3-5)资助项目

0 引 言

合成孔径雷达(synthetic aperture radar, SAR)作为一种主动空间微波遥感技术,具有分辨率高、全天候工作、覆盖域广等特点,在海洋监测、目标识别等领域都有着广泛的应用^[1]。高分三号卫星是我国第一颗分辨率达到 1 m 的 C 波段多极化 SAR 卫星,也是“国家高分辨率对地观测系统重大专项”中唯一的民用雷达遥感卫星^[2,3]。其中,扫描式合成孔径雷达(scan synthetic aperture radar, ScanSAR)模式是高分三号卫星重要的工作模式之一,该模式可在工作时改变天线的角度,依次扫描多个条带而获得更大的测绘带宽^[4]。由于 ScanSAR 的扫描机制导致它的系统函数是时变的,接收回波信号的强度会随着方位向和距离向位置周期性变化,使得 ScanSAR 图像可能产生了严重的不均匀现象,这种不均匀现象意味着 SAR 系统的传递函数随空间和时间的变化很严重,也称之为扇贝效应(scalloping)^[5]。该现象在成像处理之后,呈现明暗相间的条纹,严重影响了图像的质量,增加了图像的判读难度。因为这是系统特性导致的问题,在硬件上克服十分困难,需要寻求软件算法上的解决途径^[6]。

现有的去除扇贝效应的方法可以分为两类:第一类方法应用于处理 SAR 原始信号,即通常纳入 level0 级的 SAR 处理链^[7-10]。通常为,通过构建一个与方位向位置相关的加权函数来去除扇贝效应,这个函数可以准确地补偿 ScanSAR 回波强度在方位向的周期性波动,校正了扇贝效应^[8]。这类方法的最大缺点是需要雷达传感器的先验数据信息作为支持,无法仅对一幅问题图像进行修正处理。第二类方法是基于图像后处理的方法,因为 SAR 原始信号或者无传感器的先验数据信息无法获取,所以这一类方法对于大部分遥感图像的用户而言是唯一可行的方法^[6,11-14]。如,基于傅里叶域自适应滤波器^[11]和基于卡尔曼滤波的抑制扇贝效应方法等^[12]。这类方法通过对图像空间域或频域的一系列的处理,需要进行大量的逻辑推导和计算,且扇贝效应抑制效果直接与特定的成像平台和场景密切相关^[12,14]。

随着深度学习的发展,人们在图像处理领域中获得了重大的突破。其中生成式对抗网络(generative adversarial networks, GAN)的无监督学习,为图像生成提供了一种新的解决方案^[15],并且存在很多的改进,如 DCGAN(deep convolutional generative adversarial networks)提出了使用转置卷积层实现的生成网络,大大地降低了网络

参数量,同时图片的生成效果也大幅提升^[16]; WGAN(Wasserstein generative adversarial networks)从理论层面分析了原始的 GAN 使用 JS 散度存在的缺陷,并提出了可以使用 Wasserstein 距离来解决这个问题^[17]。ZHU 等^[18]提出的循环一致对抗网络(cycle-consistent adversarial networks, CycleGAN)解决了图像翻译领域难以获得成对训练图像的问题,也为图像修复提供一个新思路。CycleGAN 增设了循环一致性损失(cycle consistency loss)去实现图像的效果转换,由于算法清晰简单,实验效果完成的较好,而在各领域得到广泛应用^[15]。由于 CycleGAN 网络中的卷积操作每次只针对单个感受野进行提取特征,对图像特征的提取能力有限,所以需要对网络进行改进来克服该缺点。自注意力机制是注意力机制的改进,通过对全局的上下文信息进行建模来捕捉数据或特征的内部相关性,从而建立全局特征的长距离依赖^[19]。本文结合自注意力(self-attention)机制对 CycleGAN 网络进行改进,使网络具有远程依赖性建模的能力,能够有效地突出局部区域的显著特征,使网络能够建立全局特征的长距离依赖,更好地捕获图像的结构特征^[19]。因此本文以 CycleGAN 网络为基础,针对高分三号 ScanSAR 图像中因扇贝效应无法获得该区域的正常图像的情况,提出一种将自注意力机制与 CycleGAN 结合的模型对 ScanSAR 图像进行处理。对构建的高分三号 ScanSAR 图像数据集进行训练测试,验证该模型能够抑制扇贝效应,并且抑制效果明显好于传统的扇贝效应抑制算法和其他深度学习方法。

1 相关工作

1.1 CycleGAN 网络简介

CycleGAN 是一个通用型较强的 GAN 模型^[18],与大部分 GAN 不同的是, CycleGAN 是一个结构上对称的 GAN,其主要功能为图像翻译^[20],并且生成模型的输入数据是图像,不是随机的高斯白噪声,相较于 pix2pix 模型^[21],在实现时不需要准备成对图像作为数据集,结构简单且对样本要求相对较低。

CycleGAN 模型如图 1 所示,其中有两个生成器 G_X 、 G_Y ,构成了一个环形网络,两边各一个判别器 D_X 、 D_Y 。 G_X 和 D_Y 、 G_Y 和 D_X 分别构成了一个 GAN。CycleGAN 同时不断学习生成器 G_X 和 G_Y ,使得网络可以将 X 类图片转换到 Y 类后还能再转换回来。

CycleGAN 利用了对抗损失和循环一致损失来更新网络,使得网络收敛,能够稳定地将 X 类图像和 Y 类图像互相转换。所以 CycleGAN 不仅能够稳定

地实现图像风格的转换^[18],同时也在其他各领域有着广泛的应用,如结构化预测任务中,通过学习域间映射而提高其性能^[22];在图像融合任务中利用循环一致性损失来提高边界处的匹配精度^[23];以及利用 CycleGAN 的循环对抗机制完成多对多语音转换^[24]等。




图 1 CycleGAN 示意图

Fig. 1 Diagram of CycleGAN

但 CycleGAN 使用了大量的卷积操作,而卷积网络是对在较小的卷积核中的特征进行提取的,无法轻易建立特征的长距离依赖,所以本文使用自注意力机制对 CycleGAN 网络进行改进。

1.2 自注意力机制简介

自注意力机制是注意力机制的改进,而注意力机制的思路来源于人类大脑的视觉信号处理机制。人类在观测图像时,会快速扫描全局图像,获得需要重点关注的目标区域,而后对这一区域投入更多注意力资源,以获取更多需要关注目标的细节信息,并抑制无用信息^[25,26]。注意力机制在模拟长期依赖性

能力与计算和统计效率之间表现出更好的平衡。在 20 世纪 90 年代,注意力机制被运用于计算机视觉领域。2014 年,BAHDANAU 等人将注意力模型运用在机器翻译中^[27],并将注意力权重形象化,使其成为人工神经网络的重要概念。2017 年,Google 机器翻译团队发表了一篇名为《Attention is all you need》的论文,文中使用了大量的自注意力机制学习文本表示^[19],于是自注意力机制成为了深度学习的又一研究热点。自注意力机制在注意力机制的基础上减少了外部信息依赖,更擅长捕捉特征的内部相关性^[19]。本文使用自注意力机制建立全局特征的长距离依赖,有效解决图像中局部图像效果良好而全局存在偏差的问题。

2 基于自注意力机制和 CycleGAN 的改进网络

由于 CycleGAN 网络中的卷积操作针对感受野内进行提取特征,图像特征的提取能力有限,所以本文结合自注意力机制对 CycleGAN 进行改进,对存在扇贝条纹的异常图像进行修复。

2.1 基础网络模型

基础网络模型如图 2 所示。模型结构和 CycleGAN 相似,由两个判别器 D_X 、 D_Y 和两个生成器 G_X 、 G_Y 组成。 G_X 和 D_Y 、 G_Y 和 D_X 分别构成了一个




图 2 改进网络模型

Fig. 2 Improved network model

GAN。

在该模型中,使用两类图像 X 类和 Y 类对网络进行训练, X 通过生成器 G_X 生成一个假的 Y 类图像,即 $G_X(X)$,同时判别器 D_Y 会判定生成器生成的图像 $G_X(X)$ 为真或假;同理 Y 通过生成器 G_Y 生成一个假的 X 类图像,即 $G_Y(Y)$,同时判别器 D_X 会判定生成器生成的图像 $G_Y(Y)$ 为真或假。

因此 G_X 与其判别器 D_Y 的对抗损失为:

$$L_{GAN}(G_X, D_Y, X, Y) = E_{y \sim P_{data}(y)} [\log D_Y(y)] + E_{x \sim P_{data}(x)} \{\log [1 - D_Y(G_X(x))]\}, \quad (1)$$

G_Y 与其判别器 D_X 的对抗损失为:

$$L_{GAN}(G_Y, D_X, Y, X) = E_{x \sim P_{data}(x)} [\log D_X(x)] + E_{y \sim P_{data}(y)} \{\log [1 - D_X(G_Y(y))]\}, \quad (2)$$

式中, $E_{x \sim P_{data}(x)} [f(x)]$ 表示当随机变量 x 满足 P_{data}

的概率分布时, $f(x)$ 关于 P_{data} 的期望。

该模型引入了循环一致性,即在理想状态下 X 类图像通过生成器 G_X 翻译成 Y 类图像后,该 Y 类图像应可以通过生成器 G_Y 翻译成原来 X 的类图像,即满足下式:

$$\begin{aligned} G_Y[G_X(x)] &\approx x \\ G_X[G_Y(y)] &\approx y. \end{aligned} \quad (3)$$

循环一致性可以避免 X 类图像映射到同一张 Y 类图像,从而保证模型的鲁棒性,因此,对于 CycleGAN 模型的循环一致性损失为:

$$\begin{aligned} L_{cyc}(G_X, G_Y) = & E_{x \sim P_{data}(x)} \{ \| G_Y[G_X(x)] - x \|_1 \} + \\ & E_{y \sim P_{data}(y)} \{ \| G_X[G_Y(y)] - y \|_1 \}. \end{aligned} \quad (4)$$

CycleGAN 模型的损失函数如下,其中, λ 系数的作用是控制两个对象的相对重要性。

$$L(G_X, G_Y, D_X, D_Y) = L_{GAN}(G_X, D_Y, X, Y) +$$

$$L_{GAN}(G_Y, D_X, Y, X) + \lambda L_{cyc}(G_X, G_Y). \quad (5)$$

因此该模型的学习策略为:

$$G_X^*, G_Y^* = \arg \min_{G_X, G_Y} \max_{D_X, D_Y} L(G_X, G_Y, D_X, D_Y). \quad (6)$$

网络目的是为取得最优生成器 G_X^* 和 G_Y^* ,即在 D_X, D_Y 使损失函数 $L(G_X, G_Y, D_X, D_Y)$ 最大的情况下,寻找 G_X, G_Y 使损失函数 $L(G_X, G_Y, D_X, D_Y)$ 最小。

2.2 结合自注意力机制的生成器

在模型中,改进的生成器结构分为 5 个部分,如图 3 所示。

1) 编码部分

该部分由 3 层卷积构成,每一层卷积包括一层卷积网络、实例归一化和 ReLU 激活函数。3 层卷积中的卷积核数依次增加,分别为 32、64、128 个,保证编码部分提取到足够的特征。




图 3 生成器示意图

Fig. 3 Diagram of generator

2) 自注意力模块

该模块如图 4 所示,将输入为初始特征(convolution feature maps) x ,然后通过 1×1 的卷积核得到两个特征空间(feature space) $f = W_f x$ 和 $g = W_g x$ (W_f, W_g 为可学习的权重矩阵),然后使用 f 和 g 来计算注意力,如式(7)所示:

$$\beta_{j,i} = \frac{\exp(s_{ij})}{\sum_{i=1}^N \exp(s_{ij})}, s_{ij} = f(x_i)^T g(x_j). \quad (7)$$

通过 Softmax 归一化得到注意力特征图(attention map),即 β ,其中 $\beta_{j,i}$ 表示在生成第 j 个位置的特征对于第 i 个特征的相关程度。接着使用得到的注意力图和通过另一个 1×1 卷积核得到的特征空间计算得到注意力层的输出,最终自注意力的输出为 $o = (o_1, o_2, \dots, o_j, \dots, o_n)$,如下式所示:

$$\begin{aligned} o_j = & v(\sum_{i=1}^N \beta_{j,i} h(x_i)), h(x_i) = \\ & W_h x_i, v(x_i) = W_v x_i. \end{aligned} \quad (8)$$




图 4 自注意力示意图

Fig. 4 Diagram of self-attention

上述的权重矩阵 W_v, W_o 也是可学习的,通过训练学习建立了合理的全局信息关联方式。最后将自注意力的输出 o 按比例和原始特征图 x 对应位置进行结合,过程如下式所示:

$$y_i = \gamma o_i + x_i, \quad (9)$$

得到的 y 为自注意力模块的最终输出。其中 γ 初始设置为 0,使得模型从简单的局部特征学起,逐渐学习到全局。自注意力模块输出的自注意力特征图结合了图像的深层的结构特征,输入到生成器的后续网络中完成生成任务。

3) 图像转换部分

该部分由 7 个残差模块组成,是通过提取的特征完成图像不同类别的转换。残差模块不改变特征图大小,输入通道和输出通道均为 128,激活函数均为 Leaky ReLU。

4) 自注意力模块

该模块对转换之后的特征图中的全局特征进行凸显,提高图像的复原质量。

5) 解码部分

解码部分有 3 个反卷积层,输入通道为 52;第 1 个反卷积层滤波器数量为 26,步长为 2,Padding 策略为 1;第 2 个反卷积层滤波器数量为 13,步长为 2,Padding 策略为 1;卷积层滤波器数量为 1,Padding 策略为 0,反卷积核大小为 7×7 ;前 2 个反卷积层用的激活函数为 Leaky ReLU,最后一个反卷积层用的激活函数为 Tanh;Decoder 作用是将图像还原为输入图像大小(512×512),并输出图像。同时,对于每一层都使用了归一化(normalization)。

2.3 基于 Patch 策略的判别器

在模型中,改进的判别器结构如图 5 所示。




图 5 判别器示意图

Fig. 5 Diagram of discriminator

本文方法采用 Patch-GAN 中判别器的 Patch 策略,构建一个全卷积网络的判别器,使得判别器可以达到较好的分类效果。该判别器的神经网络模型有 5 个卷积层,输入通道为 1;第 1 个卷积层滤波器数量为 13,步长为 2;第 2 个卷积层滤波器数量为 26,步长为 2;第 3 个卷积层滤波器数量为 52,步长为 2;第 4 个卷积层滤波器数量为 104,步长为 1;第 5 个卷积层滤波器数量为 1,步长为 1;Padding 策略均为 1;运用的激活函数均为 Leaky ReLU;判别器最终会输出一个通道为 1、大小为 64×64 的预测映射(prediction map)。

3 实验过程与结果分析

3.1 实验使用的计算机配置

CPU: i7-8700K; 内存: 64 GB; GPU: NVIDIA RTX 2080Ti 11G; 深度学习框架: Tensorflow。

3.2 数据集的构造

本文将 18 景高分三号 ScanSAR 图像裁剪成若干个 512×512 大小的子图,筛选出了 480 张存在扇贝效应的异常子图,作为 X 类图像;筛选出了 400 张

正常图像,作为 Y 类图像,如图 6 所示。




图 6 数据集示例:(a) 异常图像;(b) 正常图像

Fig. 6 Examples of datasets;

(a) Abnormal image; (b) Normal image

3.3 CycleGAN 的训练

对于改进的 CycleGAN,针对判别器使用随机梯度下降(SGD)作为优化器。由于判别器的训练任务较为单一,所以选取 SGD 可以使用较少的计算量同时保持判别器的稳定训练。

针对生成器使用自适应性矩估计(adaptive moment estimation, ADAM)作为优化器,它能基于训练数据迭代地更新神经网络权重。ADAM 优化算法

可以为不同的参数设计单独的自适应学习率,保持生成器的持续收敛。

在训练过程中,选定合适图像数量构建每个样本批次大小(batch size)进行训练,如 8 张图像为一个样本。构建小批量的样本,即保证各个批量样本都包含较丰富的样本特征,使得生成器有足够的特征进行学习,从而保证图像的生成质量;同时也使得不同样本之间在空间上有合适的距离,促进生成器可以对不同样本的相同特征进行拟合,增强生成器的鲁棒性,避免出现模型坍塌。

3.4 实验结果与分析

在模型训练完毕后,将异常图像导入模型,获得输出图像,如图 7 所示。为对图像条纹现象进行定性分析,对图像内的每行像素分别计算灰度均值,最终做出该区域的灰度均值分布结果,如图 8 所示。可见,异常图像由于扇贝效应,在图像中存在明显的条纹现象,图像灰度存在周期性的亮暗变化,严重干扰图像的解译,经过本文提出的方法处理后,图像灰度均值分布并无明显的周期性变化,条纹现象得到有效抑制,且图像亮度有所提升,图像的细节信息可以更好地展示。总之,本文方法既能有效抑制条纹现象,又能在一定程度上提升图像亮度凸显图像细节,提高了图像质量。




图 7 处理结果:(a) 异常图像;(b) 本文所提方法

Fig. 7 Processing result: (a) Abnormal image;
(b) Method of this paper




图 8 图像灰度均值分布

Fig. 8 Distribution of image gray mean

3.5 本文方法与传统方法的对比分析

为充分验证本文方法的有效性,本节将本文方法与传统方法进行对比。将自适应滤波、卡尔曼滤波和本文方法分别对异常图像的扇贝效应进行处理,结果如图 9 所示。由图可见自适应滤波、卡尔曼滤波对图像的扇贝效应都能起到一定抑制作用,但对条纹现象抑制效果不够彻底。并且自适应滤波导致图像亮度较暗,影响对图像细节部分的观测。而本文方法处理得到的图像,扇贝效应产生的条纹现象得到较好的消除,且处理的图像整体亮度有所提升,能够较好地凸显图像细节。




图 9 传统算法与本文所提方法比较:

(a) 异常图像;(b) 自适应滤波;
(c) 卡尔曼滤波;(d) 本文所提方法

Fig. 9 Comparison of traditional algorithms with proposed method of this paper: (a) Abnormal image;
(b) Adaptive filtering; (c) Kalman filter;
(d) Method of this paper

3.6 本文方法与深度学习方法的对比分析

本节使用其他深度学习网络对扇贝效应进行处理,并和本文方法进行对比,各方法的处理结果如图 10 所示。由于扇贝效应问题难以获得异常图像对应区域的正常图像,为对结果进行合理的定量分析,本文分别对各种方法计算亮度均值、平均梯度、信息熵等定量指标进行比较分析,见表 1。其中亮度均值 $\bar{x}$ 表示整幅图像灰度值的平均值,计算过程如下式所示,其中图像行列数为 M 和 N , $f(i, j)$ 表示第 i 行、第 j 列处的灰度值。如果亮度均值适中,则图像的整

体视觉效果良好:

$$\bar{x} = \frac{\sum_{i=1}^M \sum_{j=1}^N f(i,j)}{M \cdot N} \quad (10)$$

平均梯度 $\nabla \bar{g}$ 反映了图像的细节丰富程度。一般来说,图像的平均梯度越大,细节对比度越大,图像层次越丰富,图像越清晰。平均梯度定义如下:

$$\nabla \bar{g} = \frac{\sum_{i=1}^{M-1} \sum_{j=1}^{N-1} \sqrt{\frac{[f(i,j) - f(i+1,j)]^2 + [f(i,j) - f(i,j+1)]^2}{2}}}{(M-1) \cdot (N-1)} \quad (11)$$

信息熵 H 反映影像的信息量的大小,计算方法如下式所示:

$$H = - \sum_{i=0}^{L-1} p_i \log(p_i) \quad (12)$$

式中, L 为图像的最大灰度级别, p_i 代表整个影像中灰度级为 i 的概率。

根据图 10 和表 1 可知,异常图像由于条纹现象

的存在,图像亮度基本偏低,所以图像亮度均值较低,且图像细节被条纹掩盖,平均梯度和信息熵也较低。WGAN 网络对扇贝效应的抑制较差,无法消除扇贝效应的条纹现象,且处理过的图像较为模糊,使得其结果的平均梯度甚至低于原始的异常图像;CycleGAN 网络对条纹现象的抑制强于 WGAN,但依然不够彻底,在图像较暗的区域依然可以观察到条纹现象,且图像细节纹理特征有所丢失,导致图像模糊,信息熵和平均梯度较低。本文方法可以较为彻底地抑制扇贝效应,有效消除图像较暗区域的条纹现象。由于引入了自注意力机制,使得网络可以学习到更多的特征信息,生成的图像较为清晰,所以平均梯度最大;同时可以更大程度地保留图像细节,所以处理过后的图像信息熵最大,并在一定程度上提升图像整体亮度,能够较好地恢复图像细节。总之,本文方法可以在较为彻底地抑制条纹现象的同时,能够有效恢复图像的细节信息,较好实现对异常图像的修复。




图 10 其他深度学习方法与本文所提方法比较:(a) 异常图像;(b) WGAN;(c) CycleGAN;(d) 本文所提方法

Fig. 10 Comparison of other deep learning methods with proposed method of this paper:

(a) Abnormal image; (b) WGAN; (c) CycleGAN; (d) Method of this paper

表 1 各方法的定量指标比较

Tab. 1 Comparison of quantitative indexes of various methods

	Abnormal image	WGAN	CycleGAN	Method of this paper
Brightness mean	77.03	82.42	80.75	87.99
Average gradient	142.38	139.51	141.22	146.25
Information entropy	6.92	7.04	7.47	7.62

4 结 论

本文针对高分三号卫星 ScanSAR 模式下存在的扇贝效应,提出自注意力机制与 CycleGAN 结合的模型对 ScanSAR 图像进行处理,从而抑制扇贝效应产生的条纹现象。并通过构建的异常图像和正常图像的数据集对该网络进行训练,验证所提方法的有效性,并和传统方法及深度学习方法的处理结果作一比较。实验结果表明,本文方法可以对高分三号 ScanSAR 图像存在的扇贝效应进行较好的处理,有效抑制图像的条纹现象,并恢复图像细节,使得图像质量得到明显的提升,具有较大的实用价值。

参考文献:

- [1] ZHU S L, ZHU B S, WANG H W. Remote sensing image processing and application[M]. Beijing: Science Press, 2006:10-16.
朱述龙,朱宝山,王红卫.遥感影像处理与应用[M].北京:科学出版社,2006:10-16.
- [2] LIU J Y, QIU X L, HAN B, et al. Study on geo-location of sliding spotlight mode of GF-3 satellite[C]//5th IEEE Asia-Pacific Conference on Synthetic Aperture Radar, September 1-4, 2015, Singapore. New York: IEEE, 2015: 417-420.
- [3] GUO Y J, CHEN E, GUO Y, et al. Deep highway unit network for land cover type classification with GF-3 SAR imagery[C]//2017 SAR in Big Data Era: Models, Methods and Applications (BIGSARDATA), November 13-14, 2017, Beijing, China. New York: IEEE, 2017: 1-6.
- [4] MING F, HONG J, WU Y R. Scalping radiation error of ScanSAR[J]. Journal of Electronics & Information Technology, 2006(10): 48-50.
明峰,洪峻,吴一戎. ScanSAR 的 Scalping 辐射误差研究[J]. 电子与信息学报, 2006(10): 48-50.
- [5] ZHAO T, DENG Y K, WANG Y. Improved sliding Mosaic full-aperture imaging algorithm based on scallop effect correction[J]. Journal of Radars, 2016, 5(5): 548-557.
赵团,邓云凯,王宇. 基于扇贝效应校正的改进滑动 Mosaic 全孔径成像算法[J]. 雷达学报, 2016, 5(5): 548-557.
- [6] SCHIAVULLI D, SORRENTINO A, MIGLIACCIO M. An innovative technique for postprocessing descalloping[J]. IEEE Geoscience and Remote Sensing Letters, 2013, 10(3): 424-427.
- [7] HAWKINS R K, VACHON P W. Modelling SAR scalloping in burst mode products from RADARSAT-1 and Envisat [C]//SAR Workshop on Calibration/Validation, September 24-26, 2002, London, United Kingdom. Noordwijk, The Netherlands: ESA Publications Division, 2003.
- [8] BAMLER R. Optimum look weighting for burst-mode and ScanSAR processing[J]. IEEE Transactions on Geoscience and Remote Sensing, 1995, 33(3): 718-725.
- [9] VIGNERON C M. Radiometric image quality improvement of Scansar data[D]. Ottawa: Carleton University, 1994: 52-58.
- [10] SHIMADA M. Long-term stability of L-band normalized radar cross section of Amazon rainforest using the JERS-1 SAR[J]. Canadian Journal of Remote Sensing, 2005, 31(1): 132-137.
- [11] ROMEISER R, HORSTMANN J, GRABER H. A new scalloping filter algorithm for ScanSAR images[C]//2010 IEEE International Geoscience and Remote Sensing Symposium, July 25-30, 2010, Honolulu, HI, USA. New York: IEEE, 2010: 4079-4082.
- [12] IQBAL M, CHEN J, YANG W, et al. Kalman filter for removal of scalloping and inter-scan banding in ScanSAR images[J]. Progress in Electromagnetics Research, 2012, 132: 443-461.
- [13] SORRENTINO A, SCHIAVULLI D, MIGLIACCIO M. A post-processing technique for scalloping suppression over ScanSAR images[C]//2012 6th European Conference on Antennas and Propagation, March 26-30, 2012, Prague, Czech. New York: IEEE, 2012: 2078-2081.
- [14] LANDMARK K, SOLBERG A H S. Reducing scalloping in synthetic aperture radar images using a composite image transform[C]//2015 Image and Signal Processing for Remote Sensing XXI, September 14-23, 2015, Toulouse, France. Bellingham, Washington, USA: SPIE, 2015, 9643: 96431B.
- [15] ZHU X C, TANG G J. A survey on generative adversarial

- networks in image processing[J]. Journal of Nanjing University of Posts and Telecommunications: Natural Science Edition, 2019, 39(3): 1-12.
- 朱秀昌, 唐贵进. 生成对抗网络图像处理综述[J]. 南京邮电大学学报: 自然科学版. 2019, 39(3): 1-12.
- [16] RADFORD A, METZ L, CHINTALA S. Unsupervised representation learning with deep convolutional generative adversarial networks[C]//2015 International Conference on Learning Representations, May 7-9, 2015, San Diego, USA. Washington, DC: ICLR, 2015: 1-15.
- [17] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein GAN[EB/OL]. (2017-12-06) [2022-02-13]. <https://arxiv.org/pdf/1701.07875v2.pdf>.
- [18] ZHU J Y, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[C]//2017 IEEE International Conference on Computer Vision, July 10-13, 2017, Venice, Italy. New York: IEEE, 2017: 2242-2251.
- [19] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//31st International Conference on Neural Information Processing Systems, December 4-10, 2017, Long Beach, CA, USA. New York: ACM, 2017: 6000-6010.
- [20] YI Z L, ZHANG H, TAN P, et al. DualGAN: unsupervised dual learning for image-to-image translation[C]//2017 The IEEE International Conference on Computer Vision, July 10-13, 2017, Venice, Italy. New York: IEEE, 2017: 28-49.
- [21] ISOLA P, ZHU J Y, ZHOU T, et al. Image-to-image translation with conditional adversarial networks[C]//2017 IEEE Conference on Computer Vision & Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE, 2017: 5967-5976.
- [22] YANG H, SUN J, CARASS A, et al. Unpaired brain MR-to-CT synthesis using a structure cons trained CycleGAN[C]//2018 International Workshop on Deep Learning in Medical Image Analysis, August 26-30, 2018, Granada, Spain. Berlin: Springer, 2018: 1-8.
- [23] ALMAHARIRI A, RAJESWAR S, SORDONI A, et al. Augmented CycleGAN: learning many-to-many mappings from unpaired data[C]//2018 International Conference on Machine Learning, July 10-15, 2018, Stockholm, Sweden. New York: PMLR, 2018: 195-204.
- [24] KANEKO T, KAMEOKA H. Parallel-data-free voice conversion using cycle-consistent adversarial networks[EB/OL]. (2017-12-20) [2022-02-13]. <https://arxiv.org/pdf/1711.11293.pdf>.
- [25] CHENG J, DONG L, LAPATA M. Long short-term memory networks for machine reading[C]//2016 Conference on Empirical Methods in Natural Language Processing, November 1-5, 2016, Austin, USA. Stroudsburg: ACL, 2016: 551-561.
- [26] PARIKH A P, TÄCKSTRÖM O, DAS D. A decomposable attention model for natural language inference[C]//2016 Conference on Empirical Methods in Natural Language Processing, November 1-5, 2016, Austin, USA. Stroudsburg: ACL, 2016: 2249-2255.
- [27] BAHDANAU D, CHO K, BENGIO Y. Neural machine translation by jointly learning to align and translate[EB/OL]. (2016-05-19) [2022-02-13]. <https://arxiv.org/pdf/1711.11293.pdf>.

作者简介:

刘慧霞 (1979—), 女, 博士, 副教授, 硕士生导师, 研究方向为智能制造、复杂系统建模。