

基于双重注意力机制的 CycleGAN 海岸线自动提取方法

卢鹏, 张娜, 邹国良*, 王振华, 郑宗生

上海海洋大学信息学院, 上海 201306

摘要 将遥感图像进行像素级海陆分割是海岸线提取的一项基础性工作。由于海岸线的动态变化, 获取精准的海岸线标记数据集比较困难, 为此采用 Google Aerial photo-Maps 配对样本, 在对 Google Maps 进行海陆二值化处理并构建了新的配对数据集。针对新数据集样本较少问题, 在循环生成对抗网络(CycleGAN)模型的基础上, 提出了基于双重注意力机制的 DAM-CycleGAN。新模型全面考虑遥感图像和海陆二值化图像之间的结构相似性, 改进了循环一致性损失, 并设计通道注意力模块和空间注意力模块来凸显显著性特征和区域, 以增强模型在小样本训练下的特征学习能力。在均方误差、平均像素精度和平均交并比(MIoU)三个评价指标上, 与全卷积神经网络模型、DeepLab 模型在多个规模数据集训练下的实验结果对比, 改进模型转换的海陆二值化图像与真值图像更加吻合, MIoU 值分别至少提高 7%、6% 以上, 验证了所提方法的有效性和可行性。

关键词 图像处理; 遥感; 循环生成对抗网络; 注意力机制; 循环一致性损失; 小样本

中图分类号 TP301.6

文献标志码 A

DOI: 10.3788/LOP202259.1210005

CycleGAN Coastline Automatic Extraction Method Based on Dual Attention Mechanism

Lu Peng, Zhang Na, Zou Guoliang*, Wang Zhenhua, Zheng Zongsheng

College of Information, Shanghai Ocean University, Shanghai 201306, China

Abstract The pixel-level sea-land segmentation of remote sensing images is a basic work for coastline extraction. Owing to the dynamic changes in the coastline, obtaining accurate coastline marker datasets is difficult. In this study, Google Aerial Photo-Maps-paired samples were used to construct a paired dataset after the sea-land binarization processing of Google Maps. Thus, we proposed the dual attention mechanism-cycle generative adversarial network (CycleGAN) based on the CycleGAN model to solve the problem of fewer samples in the new dataset. The new model fully considers the structural similarity between remote sensing images and sea-land binarized images, improves cycle consistency loss, and designs both channel and spatial attention modules to highlight salient features and regions to enhance the model's performance in small feature learning ability under sample training. Furthermore, we applied three evaluation indicators, i. e., mean square error, mean pixel accuracy, and mean intersection over union (MIoU), and compared our experimental results to those of the full convolutional neural network and DeepLab models under multiple-scale dataset training. Results show that the improved model conversion of the sea-land binarized images is more consistent with the true value images and the MIoU values are increased by at least 7% and 6%, respectively, verifying the effectiveness and feasibility of the

收稿日期: 2021-05-07; 修回日期: 2021-05-31; 录用日期: 2021-06-02

基金项目: 上海市地方能力建设项(19050502100)、上海海洋大学科技发展专项(A2-2006-20-200211)

通信作者: *glzou@shou.edu.cn

proposed method.

Key words image processing; remote sensing; cycle generative adversarial network; attention mechanism; cycle consistency loss; small sample

1 引言

海岸线指陆地与海洋的分界线,包括大陆海岸线和岛屿海岸线^[1]。由于受地壳运动、全球气候变暖、涨潮落潮等自然因素以及人类活动的影响^[2],海岸线一直处于变化之中。动态监测海岸线变化并及时提取海岸线对于海洋资源开发、生态环境保护等具有十分重大的意义。

遥感技术成像的遥感影像具有观测范围广、成像分辨率高、获取信息速度快周期短等特点^[3],能够快速获取海岸地貌类型及其相关地面信息,非常适合大范围的海岸研究^[4]。利用遥感图像提取海岸线是遥感图像处理领域的重要研究内容。目前海岸线提取方法可以在总体上分为两大类:目视解译方法和计算机解译方法。传统目视解译方法虽然解译精度高,但是解译进度慢、效率低下,且易受主观因素影响。计算机解译方法中常用方法有阈值分割方法^[5-6]、边缘检测算子方法^[7-8]、区域生长法^[9-10]等。阈值分割方法具有简单有效、易于实现的特点,但是面对灰度较暗、海岸带区域背景复杂等情况时提取效果欠佳。边缘检测算子对噪声较为敏感,在海岸线背景复杂情况下提取的海岸线连续性较差。区域生长法在提取水边线方面具有提取算法简单、速度快、结果稳定连续等优点,但也易受噪声影响,且在海岸线周围地物背景复杂时易造成水边线变形^[11]。

传统的海岸线提取方法不仅人工代价大,而且易受主观以及噪声、背景复杂等情况影响。深度学习因其强大的特征提取能力和复杂问题的拟合能力也被逐步应用到遥感图像分割任务中。目前深度学习广泛应用于计算机视觉领域的图像分类^[12]、目标检测^[13]和语义分割^[14]等任务中,并取得了巨大的成功。在遥感图像处理上,Hu等^[15]提出了一维卷积神经网络对高光谱图像的光谱域进行分类;Xia等^[16]提出用Faster R-CNN^[17]实现遥感图像的目标检测,利用“锚”框来获得有效的预测候选框;Shelhamer等^[18]提出全卷积神经网络(FCN)用于图像语义分割,将图像级别的分类扩展到像素级别的分类;Chen等^[19]创造性地结合深度卷积神经网络

(DCNN)和条件随机场算法(CRF)提出了DeepLab语义分割模型,扩大空洞卷积的感受野,从而提高遥感图像的分割精度;王振华等^[20]针对遥感影像大范围覆盖的特征,提出基于DeepLab神经网络结构的海岛岸线粗分割,将粗分割结果作为海岛岸线优化的初始边界,并利用全连接条件随机场优化海岛岸线,实现海岛岸线的细分割提取,从而有效提高了海岛岸线的分割精度;Zhao等^[21]提出金字塔场景解析网络(PSPNet),通过聚合不同区域的上下文信息来提高获取全局信息的能力,在遥感图像的场景解析任务中表现出了良好的效果;Li等^[22]在U-Net网络^[23]的基础上提出了新型的深度卷积神经网络(DeepUNet),通过设计DownBlocks模块和UpBlock模块代替卷积层,提高了高分辨率遥感影像的分割精度;Shamsolmoali等^[24]提出了在复杂和高密度遥感影像中用于像素级海域分割的残差密集U-Net网络(RDU-Net),主要是在各层之间具有较短距离的反向传播中设计紧密连接的残差网络块,系统地聚合多尺度上下文信息,从而改善了海域的分割效果。

基于深度学习的图像分割方法需要依赖大量成对的遥感图像和人工精确标记图像进行训练,但是目前这种公开数据集较少,而CycleGAN^[25]较图像分割模型依赖的训练样本相对偏小。因此,本文使用CycleGAN代替图像分割模型来处理遥感图像中海岸线的提取任务。CycleGAN是图像转换任务中常用网络之一,由加州大学伯克利分校Zhu等^[25]提出,是一种跨域图像之间的风格转换技术,主要应用场景包括风格转换、物体变形、季节转换、使用绘画生成图片、图像增强等。2018年,CMU和Facebook的研究者给CycleGAN加上时间约束提出了一种新型无监督视频重定向方法Recycle-GAN^[26]。2020年,Fang等^[27]提出了具有识别机制的CycleGAN模型,用于人脸照片合成与识别。

虽然目前有很多公开的遥感数据集,但是经过人工精确标记的成对的公开数据集较少,且人工标注代价太高。双重注意力机制通过在图像特征的空间维度和通道维度分别抓取特征之间的全局依

赖关系来增强特征的表达能力,能够有效提升网络模型的性能,且在小样本训练的情况下模型性能的提升更加明显。因此针对小样本训练,本文提出了基于双重注意力机制的 DAM-CycleGAN 算法。选择成对的 Google Aerial photo-Maps 公开数据集作为模型的原始数据集,对 Google Maps 进行海陆二值化处理,构建了 DAM-CycleGAN 网络所使用的配对的遥感图像——海陆二值化图像数据集。网络采用改进的循环一致性损失来增强转换后的海陆二值化图像和遥感图像之间的结构相似性,并通过设计双重注意力模块加强海陆的边界特征表达能力,优化了网络模型的性能,提升了网络转换后的海陆二值化图像质量,进而提高了海岸线的提取精度。

2 相关工作

CycleGAN 是在生成对抗网络 (GAN) 的基础上提出的。GAN 在 2014 年被 Goodfellow 等^[28]提出,该模型结构上受博弈论中的二人零和博弈的启发^[29],包含一个生成器和一个判别器。生成器通过学习真实图像的数据分布来生成一个伪图像,判别器则判别样本是真实图像还是伪图像。生成器和判别器在博弈过程中,生成器生成的数据分布会更加接近真实数据分布,直至成功迷惑判别器。GAN 的提出满足了许多领域的研究和应用需求,图像和视觉领域则是 GAN 研究和应用最广泛的一个领域。

CycleGAN 结构上由两个镜像对称的 GAN 网络组成,主要目的是实现域 X 和域 Y 之间的相互转化。CycleGAN 包含两个生成器 G 、 F ,以及两个鉴别器 D_X 、 D_Y ,如图 1 所示。生成器 G 用于生成符合域 X 分布的图像 Y' ,生成器 F 用于生成符合域 Y 分布的图像 X' ;而判别器 D_X 、 D_Y 则用于判断图像 X' 、 Y' 是否属于相应的域。




图 1 CycleGAN 结构

Fig. 1 CycleGAN architecture

3 基于双重注意力机制的 CycleGAN 遥感图像海岸线自动提取算法

3.1 DAM-CycleGAN 算法流程

针对小样本训练,本文引入双重注意力机制,提出新的 DAM-CycleGAN 模型来实现遥感图像中海岸线的自动提取,新模型的算法流程如图 2 所示。

第一步,对成对的 Google Aerial photo-Maps 原始数据集进行预处理获得模型的输入,即成对的遥感图像——海陆二值化图像;

第二步,从遥感图像数据集 X 中选择一个样本 x ,通过基于双重注意力机的生成器 G 变换为海陆二值化图像数据集 Y 中的一张假图像 $G(x)$;

第三步,将假图像 $G(x)$ 通过基于双重注意力机的生成器 F 变换回域 X ,得到 $F[G(x)]$,生成的假图像分别送入相应的判别器进行判定;

第四步,另一半网络执行相同的步骤;

第五步,计算判别器 D_X 、 D_Y 的损失,以及 x 与 $F[G(x)]$ 、 x 与 $F(y)$ 、 y 与 $G[F(y)]$ 、 y 与 $G(x)$ 之间的损失,进而优化生成器 G 、 F 和判别器 D_X 、 D_Y ;

第六步,当达到迭代次数时,循环终止,进入模型测试阶段,转换输出测试集中遥感图像相对应的海陆二值化图像。

3.2 融合双重注意力机制后的网络架构

本文提出的基于 CycleGAN 网络的海岸线自动提取算法沿用了传统 CycleGAN 网络的主体框架,整体的网络架构如图 3 所示。网络选择公开数据集中的成对的 Google Aerial photo-Maps 数据集作为原始数据集,对 Google Maps 进行海陆二值化处理后构建了 DAM-CycleGAN 网络使用的样本库,即配对的遥感图像、海陆二值化图像数据集。本文网络模型对遥感图像和相对应的海陆二值化图像对进行端到端训练,即图 3 中 X 和 Y 。本文采用基于双重注意力机制的生成器 Generator_DA 根据输入 X 和 Y 的内容特征和风格特征生成转换后图像 Y' 和 X' ;再将 Y' 和 X' 输入 Generator_DA 中获得重建图像 X'' 和 Y'' ,然后通过判别器 D_Y 和 D_X 分别判别生成图像是否符合源目标图像的样本分布。另一半网络执行相同的操作。图中 $L_{cyc,X}$ 、 $L_{cyc,Y}$ 、 $L_{ssim,X}$ 和 $L_{ssim,Y}$ 分别表示 X 与 X'' 、 Y 与 Y'' 、 X 与 X' 以及 Y 与 Y' 之间的损失。训练过程中,本文使用改进的循环一致性损失指导生成器 Generator_DA 图像生成质量。

生成器 Generator_DA 主要由编码器、转换器、

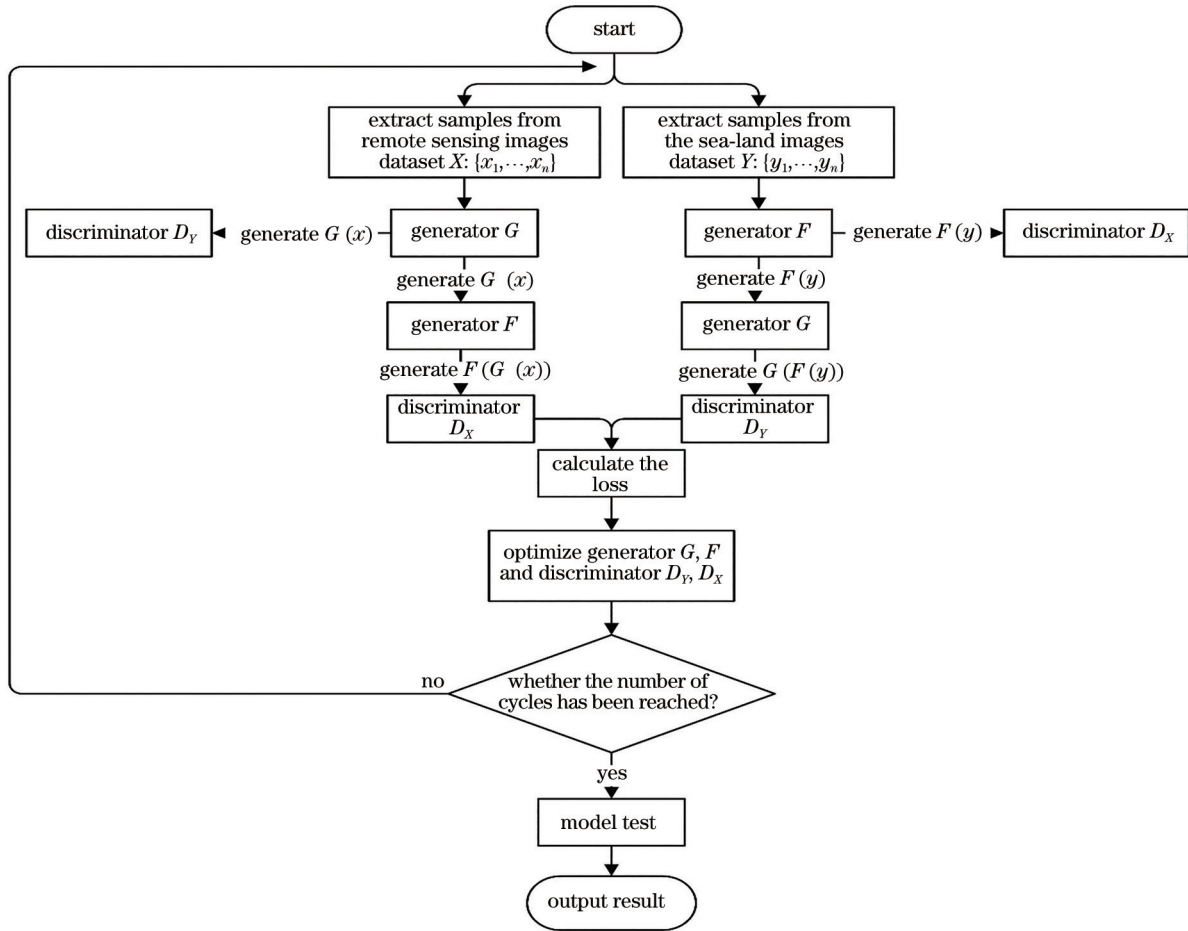


图 2 DAM-CycleGAN 算法流程图

Fig. 2 DAM-CycleGAN algorithm flowchart

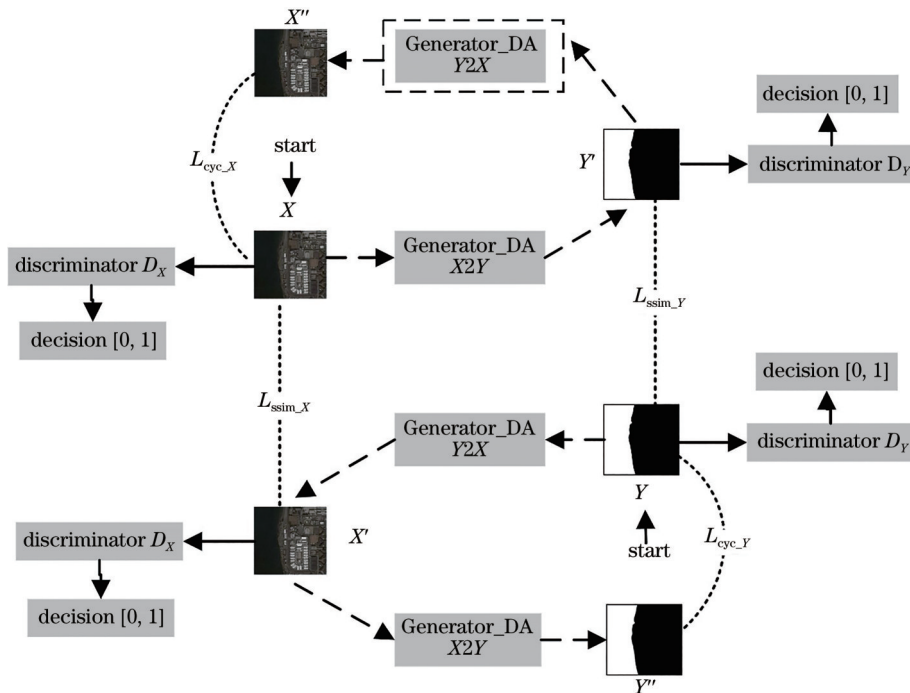


图 3 基于双重注意力机制的 CycleGAN 网络架构

Fig. 3 CycleGAN network architecture based on dual attention mechanism

解码器三部分组成,如图 4 所示。编码器使用 3 层卷积层(Conv Layer)提取遥感图像的不同特征,即从 $128 \times 128 \times 3$ 的图像中提取 $32 \times 32 \times 128$ 维特征。然后转换器通过 5 个残差块(Resnet Block)将前一步得到的特征向量转换为海陆二值化图像的特征向量。最后解码器利用反卷积层(DeConv Layer)、双重注意力模块(CBAM)以及卷积层完成从特征向量中还原低级特征的工作,从而输出

$128 \times 128 \times 3$ 的海陆二值化图像。其中双重注意力模块主要是将注意力机制同时运用到通道和空间两个维度上,通过通道注意力模块为不同通道分配权重,获取遥感图像和海陆二值化图像中的显著特征;再通过空间注意力机制根据不同区域特征的空间关系为各区域分配权重,并根据图像中权重大的区域及其相关度高的区域进行图像转换。

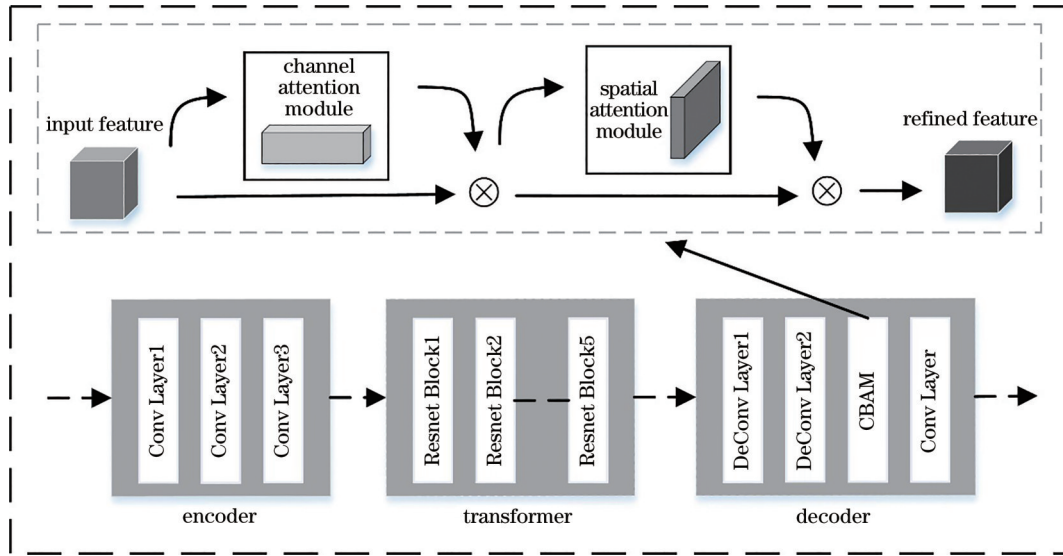


图 4 基于双重注意力机制的 Generator_DA 模型结构

Fig. 4 Generator_DA model structure based on dual attention mechanism

3.3 网络损失函数改进

3.3.1 原始损失函数

CycleGAN 主要包括对抗损失和循环一致性损失。对抗损失主要控制生成器生成的图像无限逼近目标图像。生成器 $G: X \rightarrow Y$ 和相应判别器 D_Y 对应的损失函数为

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

式中: $P_{data}(x)$ 表示图像域 X 的样本分布; $P_{data}(y)$ 表示图像域 Y 的样本分布。由于生成器 G 和 F 是相同的, 所以生成器 $F: Y \rightarrow X$ 和相应判别器 D_X 对应的损失函数可表示为 $L_{GAN}(F, D_X, X, Y)$ 。

循环一致性损失主要用于保留输入图像的内容结构和目标图像的特征。当图像 x 和图像 y 从源域转换到目标域后, 也可以再通过生成器从目标域返回到源域, 即使 $F[G(x)] \approx x$ 以及 $G[F(y)] \approx y$ 。这样做的目的是规范化映射, 防止 G 和 F 发生冲突。因此, 循环一致性损失可定义为

$$L_{cyc}(G, F, X, Y) = E_{x \sim P_{data}(x)} \left\{ \left\| F[G(x)] - x \right\|_1 \right\} + E_{y \sim P_{data}(y)} \left\{ \left\| G[F(y)] - y \right\|_1 \right\}. \quad (2)$$

传统 CycleGAN 的最终损失由以上三部分组成, 因此总损失可表示为

$$L = L_{GAN}(G, D_Y, X, Y) + L_{GAN}(F, D_X, X, Y) + \lambda L_{cyc}(G, F, X, Y). \quad (3)$$

3.3.2 循环一致性损失函数改进

循环生成对抗网络的总损失 L 由对抗损失 L_{GAN} 和循环一致性损失 L_{cyc} 两个部分组成。由于 WGAN-GP 具有稳定模型训练和生成更真实图像的优点, 本文将使用 WGAN-GP、WGAN 损失替换原始 LSGAN、GAN 损失作为对抗损失。为了弥补普通的 L2 距离无法衡量图片的结构相似性的缺陷, 已有研究在循环一致性损失中增加结构相似性(SSIM)损失和 L1 损失, 从而增强图像转换过程中源图像和目标图像的结构相似性。Zhao 等^[30]在 2017 年发表的论文中总结出了 MS-SSIM 损失和 L1 损失的组合效果最好, 并设置系数比重分别为 0.84 和 0.16。以图 2

为例,在训练过程中,相关研究主要考虑 X 与 X'' 、 Y 与 Y'' 的结构相似性和 L1 损失,但并没有考虑 X 与 X' 、 Y 与 Y' 之间的关系对图像重建的影响。因此,本文将 X 与 X' 、 Y 与 Y' 的结构相似性和 L1 损失作为两个损失项纳入 L_{cyc} 损失中,从更全面的角度来衡量源图像和目标图像的结构相似性。

SSIM 由亮度因子 (l)、对比度因子 (c) 和结构因子 (s) 三部分组成,计算公式为

$$S_{SSIM}(x, y) = l(x, y) * c(x, y) * s(x, y), \quad (4)$$

其中,

$$l(x, y) = \frac{2\mu_x\mu_y + c_1}{\mu_x^2 + \mu_y^2 + c_1}, \quad (5)$$

$$c(x, y) = \frac{2\sigma_{xy} + c_2}{\sigma_x^2 + \sigma_y^2 + c_2}, \quad (6)$$

$$s(x, y) = \frac{\sigma_{xy} + c_3}{\sigma_x\sigma_y + c_3}, \quad (7)$$

式中: μ_x 、 μ_y 分别为 x 和 y 的均值; σ_x^2 、 σ_y^2 分别是 x 和 y 的方差; σ_{xy} 为 x 和 y 的协方差; c_1 、 c_2 和 c_3 为常数,避免除零情况, $c_1 = (k_1L)^2$, $c_2 = (k_2L)^2$, $c_3 = \frac{c_2}{2}$, L 表示像素值的范围, k_1 、 k_2 的默认值为 0.01 和 0.03。根据以上分析,本文考虑结构相似性和 L1 损失,构建如下损失函数:

$$L_{ssim1} = [1 - S_{SSIM}(X, X'')] + [1 - S_{SSIM}(Y, Y'')], \quad (8)$$

$$L_{1L_1} = \|X'' - X\|_1 + \|Y'' - Y\|_1, \quad (9)$$

$$L_{ssim2} = [1 - S_{SSIM}(X, X')] + [1 - S_{SSIM}(Y, Y')], \quad (10)$$

$$L_{2L_1} = \|X' - X\|_1 + \|Y' - Y\|_1. \quad (11)$$

所以本文的循环一致性损失为

$$L_{cyc} = \lambda_1 L_{ssim1} + \lambda_2 L_{1L_1} + \lambda_3 L_{ssim2} + \lambda_4 L_{2L_1}, \quad (12)$$

式中: $\lambda_1 + \lambda_2 + \lambda_3 + \lambda_4 = 1$ 。本文引用 Zhao 等提出的系数比重作为 λ_1 和 λ_2 两者之间比例关系。由于 L_{ssim2} 损失和 L_{2L_1} 损失随机性较大,因此本文设置 $\lambda_3 = \lambda_4 = 0.05$, 所以 $\lambda_1 = 0.756$, $\lambda_2 = 0.144$ 。



图 5 实验数据。(a)原始数据集;(b)本文使用的数据集;(c)通过海陆二值化操作将谷歌地图转换成海陆二值化图像
Fig. 5 Experimental data. (a) Original dataset; (b) dataset used in this paper; (c) Google Maps converted into sea-land binarized image by sea-land binarization operation

4 实 验

4.1 实验数据集及数据预处理

本文选用 CycleGAN 公共数据集中的 Aerial photo-Maps 数据集作为实验的原始数据集,该数据集下载自 Kaggle 官网 (<https://www.kaggle.com/suyashdamle/cyclegan>),如图 5(a)所示。原始数据集由成对的航拍遥感图像和谷歌地图组成,包括训练集 1096 对,测试集 1098 对,像素尺寸均为 600 pixel × 600 pixel。其中,训练集和测试集中包括海洋和陆地的样本共 330 对。由于图 5(a)谷歌地图中的特征过多,为了减少模型计算量,本文对 330 对图像的谷歌地图进行了海陆二值化操作来去除无关的特征。本文将 RGB 空间的图像转换到 HSV 空间,之后在 HSV 空间中定义蓝色并获得相应的掩模,最后设置阈值提取出图像中的海洋区域和陆地区域分别为白色和黑色,从而实现海洋和陆地的分割,如图 5(b)所示。HSV 颜色空间的参数包括色调 (H)、饱和度 (S) 和明度 (V),计算公式为

$$U = \min(R, G, B), \quad (13)$$

$$V = \max(R, G, B), \quad (14)$$

$$S = \frac{V - U}{V}, \quad (15)$$

$$H = \begin{cases} \frac{G - B}{V - U} \cdot 60, & R = V \\ 120 + \frac{B - R}{V - U} \cdot 60, & G = V \\ 240 + \frac{R - G}{V - U} \cdot 60, & B = V \end{cases} \quad (16)$$

当 $H < 0$ 时, $H = H + 360$ 。其中蓝色的色调、饱和度和明度的范围分别为 (100, 124)、(43, 255)、(46, 255)。再通过下采样操作将图 5(c)中的遥感图像、海陆二值化图像的图像尺寸降至 128 pixel × 128 pixel,并作为模型的输入。通过随机选择构建两组消融实验数据,第一组包括 35 对训练集和

50对测试集,第二组包括100对训练集和50对测试集。根据文献[20]中350景的训练集规模,构建了两组对比实验数据,第一组包含200对训练集和30对测试集,第二组则扩充至与文献[20]相当的数据规模,即包含300对训练集和30对测试集,以测试本文算法在不同规模数据集下的性能。本文将测试集中的海陆二值化图像作为真值,用于和模型转换的海陆二值化图像做比较。

4.2 实验参数与评价指标

4.2.1 实验环境及参数设置

实验模型在Windows操作系统上采用Tensorflow框架,使用GTX2060 16 GB的GPU对其进行训练。实验的输入输出图像尺寸均为128 pixel×128 pixel, batch size设置为1,训练次数为200轮。初始学习率设置为0.0002,实验采用Adam优化器自适应调整学习率,前100轮保持学习率不变,后100轮学习率由0.0002线性衰减到0。

4.2.2 评价指标

为了定量分析实验结果,本文采用均方误差(MSE)、平均像素精度(MPA)和平均交并比(MIoU)三个评价指标对模型转换后的海陆二值化图像进行评价。MIoU是衡量图像分割精度的重要指标,为了对比本文模型和深度学习的图像分割模型的性能,本文引入该指标作为评价标准之一。

1) 均方误差是一种反映估计量与被估计量之间差异程度的度量,即估计量与被估计量之差平方的期望值。在本文中,MSE的值越小,表示模型转换后的海陆二值化图像与真值差距越小。公式为

$$E_{MSE} = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2, \quad (17)$$

式中: \hat{y}_i 为转换后的海陆二值化图像; y_i 为真值; n 为样本总数。

2) 平均像素精度是指预测图像标记正确的像素占真实图像总像素的比例。MPA的值越大表示预测图像越接近真实图像,差异越小。

3) 平均交并比是指所有类真实值与预测值的交集和并集比值的平均值。公式为

$$M_{IoU} = \frac{1}{k+1} \sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij} + \sum_{j=0}^k (p_{ji} - p_{ii})}, \quad (18)$$

式中: k 代表类别,包含一个背景类共 $k+1$ 个类; p_{ij} 表示本属于类 i 但被预测为类 j 的像素数量。 p_{ii} 表示真正例的数量,而 p_{ij} 和 p_{ji} 则分别表示被解释为假正例和假负例的像素数量。

4.3 消融实验

为了验证本文所提方法的有效性,分别进行了两组实验对五种方法进行了比较。方法一使用CycleGAN原网络;方法二是在方法一网络的基础上组合SSIM损失和L1损失作为网络的循环一致性损失;方法三则使用改进的循环一致性损失替换方法二中的循环一致性损失;方法四是在方法二的基础上加入双重注意力机制;方法五是本文提出的新网络DAM-CycleGAN,即使用改进的循环一致性损失和双重注意力机制。第一组实验使用的是第一组数据集,即35对训练集、50对测试集。第二组实验使用的是第二组数据集,即100对训练集、50对测试集。

图6分别展示了消融实验中五种方法在100对

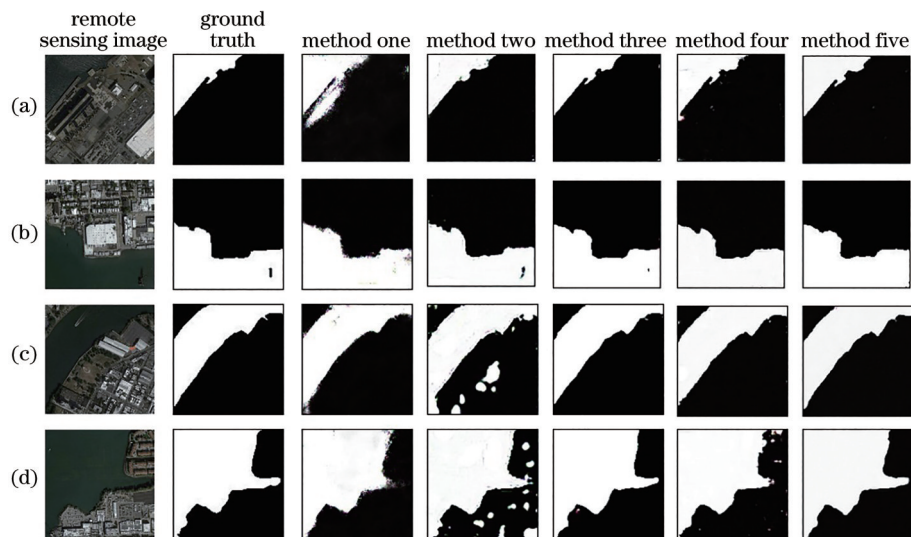


图6 转换后的海陆二值化效果图(100对训练集)

Fig. 6 Converted sea-land binarization effect maps (100 pairs of training set)

训练集 50 对测试集中的遥感图像上转换的海陆二值化效果图。为了判断本文模型的精确程度,分别对两组实验的五种方法进行测试,同时以转换图像的均方误差、平均像素精度以及平均交并比作为最终结果,如表 1、表 2 所示。方法三在训练样本较小时模型效果欠佳,但随着训练样本集的增大,模型性能提升明显。方法四在小样本训练下也能取得较好的效果,但转换得到的效果图与真值图像存在一定偏差。综合来看,方法五转换得到的效果图与真值图像较为一致,且不受训练样本规模的影响。

表 1 35 对训练集 50 对测试集 MSE、MPA 和 MIoU 对比结果

Table 1 Comparison results of MSE, MPA, and MIoU on 35 pairs of training sets and 50 pairs of test sets

Method	MSE	MPA	MIoU
Method one	2648.66	0.8219	0.8956
Method two	2052.87	0.8953	0.9179
Method three	2655.68	0.8922	0.9074
Method four	2047.31	0.9100	0.9241
Method five	1642.98	0.9201	0.9363

4.4 对比实验

深度学习图像分割领域最具代表性的方法有 FCN 和 DeepLab 等。FCN 是对图像进行像素级分类,用于解决语义级别的图像分割问题。与经典的

表 2 100 对训练集 50 对测试集 MSE、MPA 和 MIoU 对比结果

Table 2 Comparison results of MSE, MPA, and MIoU on 100 pairs of training sets and 50 pairs of test sets

Method	MSE	MPA	MIoU
Method one	4207.07	0.8208	0.8389
Method two	1857.45	0.9013	0.9157
Method three	1323.26	0.9305	0.9384
Method four	1400.98	0.9178	0.9268
Method five	1126.54	0.9258	0.9390

卷积神经网络(CNN)不同在于 FCN 可以接受任意尺寸的输入图像,通过转置卷积层将中间层的特征图恢复到输入图像相同的尺寸,保留原始输入图像中的空间信息,并在空间维上产生相对应的预测结果。DeepLab 是由谷歌团队提出的图像分割模型,结合了深度卷积神经网络(DCNNs)和概率图模型(Dense CRFs),并使用空洞卷积替代标准卷积,在保持计算量的同时增大感受野。

为了验证本文模型的可行性,分别进行了两组实验对 FCN、DeepLab 和本文 DAM-CycleGAN 三个模型进行比较。实验数据集采用本文 4.1 节的两组对比实验数据。

图 7 分别展示了对比实验中三个模型在 300 对训练集 30 对测试集中的遥感图像上的海陆分割图

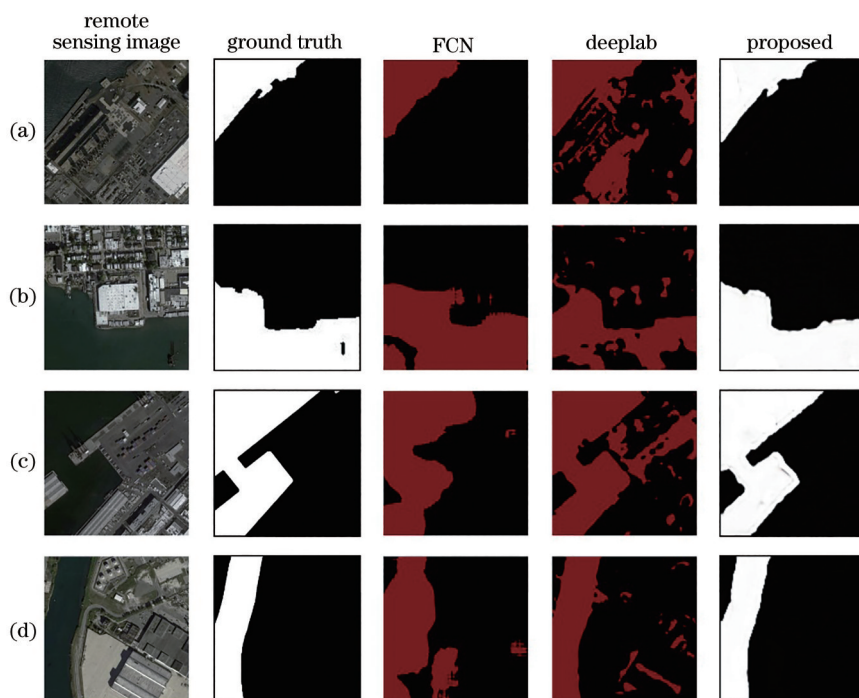


图 7 不同模型实验结果图(300 对训练集)

Fig. 7 Experimental results of different models (300 pairs of training sets)

像。由图 7 可知,FCN、DeepLab 分割模型在小样本训练的情况下,海陆分割效果不理想,而本文提出的 DAM-CycleGAN 模型能够清晰地实现遥感图像和海陆二值化图像的转换,并与真值图像具有很高的吻合度。从表 3、表 4 可以进一步看出,DAM-CycleGAN 模型相较其他模型,MSE 和 MIoU 两个指标性能均有大幅提升,且 MIoU 值较其他模型提高了超 6%,体现了本文模型的优越性。

表 3 200 对训练集 30 对测试集的 MSE、MPA 和 MIoU 对比结果

Table 3 Comparison results of MSE, MPA, and MIoU on 200 pairs of training sets and 30 pairs of test sets

Model	MSE	MPA	MIoU
FCN	3685.87	0.9384	0.8608
DeepLab	3761.87	0.9351	0.8736
DAM-CycleGAN	1043.04	0.9310	0.9533

表 4 300 对训练集 30 对测试集的 MSE、MPA 和 MIoU 对比结果

Table 4 Comparison results of MSE, MPA, and MIoU on 300 pairs of training sets and 30 pairs of test sets

Model	MSE	MPA	MIoU
FCN	4533.15	0.9259	0.8852
DeepLab	3125.88	0.9453	0.8944
DAM-CycleGAN	946.40	0.9335	0.9568

5 结 论

在现有的海岸线提取方法中,传统方法人工代价大且易受主观以及噪声、海岸线背景复杂等情况的影响,而基于深度学习的图像分割方法需要依赖大量样本进行模型训练。虽然目前公开的遥感数据集数量较多,但经过人工精确标记的成对的公开数据集却较少,因此针对小样本训练,本文提出基于双重注意力机制的 DAM-CycleGAN 海岸线自动提取算法。在 CycleGAN 模型的基础上使用改进的循环一致性损失来增强转换后的海陆二值化图像和遥感图像的结构相似性,并融合双重注意力机制,增强细节特征表达能力。通过消融实验和对比实验发现,本文模型在小样本训练下转换得到的二值化图像与真值图像更加吻合,且获得了最高的 MIoU 评价指标得分,不仅表明本文模型能够有效实现遥感图像到海陆二值化图像的转换,而且体现了本文算法的优越性。最后,本文首次使用图像转换方法研究遥感图像中的海岸线提取工作,并且取

得了不错的结果,但是就如何保留海岸更多的细节信息,转换得到更加精准的海岸线,还需要做更深入的研究工作。

参 考 文 献

- [1] 于彩霞,许军,许坚,等.一种从 LiDAR 点云中提取海岸线的新方法[J].测绘通报,2015(5):66-68.
Yu C X, Xu J, Xu J, et al. A new method of extracting coastlines from LiDAR point clouds[J]. Bulletin of Surveying and Mapping, 2015(5): 66-68.
- [2] 马小峰,赵冬至,邢小罡,等.海岸线卫星遥感提取方法研究[J].海洋环境科学,2007,26(2):185-189.
Ma X F, Zhao D Z, Xing X G, et al. Means of withdrawing coastline by remote sensing[J]. Marine Environmental Science, 2007, 26(2): 185-189.
- [3] 邵芸,张凤丽,田维,等.海洋环境微波遥感应用研究进展[J].遥感学报,2009,13(S1):154-159.
Shao Y, Zhang F L, Tian W, et al. Progresses on application of microwave remote sensing in ocean environment[J]. Journal of Remote Sensing, 2009, 13(S1): 154-159.
- [4] 杨坤.基于改进的 UNet 连云港海岸线提取研究[J].软件,2020,41(10):208-212.
Yang K. Research on coastline extraction of Lianyungang based on improved UNet[J]. Computer Engineering & Software, 2020, 41(10): 208-212.
- [5] 王岱良,杨蕴.核估计的最佳阈值 SAR 图像海岸线提取[J].雷达科学与技术,2019,17(3):310-318.
Wang D L, Yang Y. Kernel estimation for optimal threshold SAR image coastline extraction[J]. Journal of Radar Science and Technology, 2019, 17(3): 310-318.
- [6] 李宗梅,罗玉忠,满旺,等.基于遥感和 GIS 的福建省海岸线的提取和变化研究[J].应用海洋学报,2017,36(1):125-134.
Li Z M, Luo Y Z, Man W, et al. Extraction and analysis of coastline of Fujian province based on RS and GIS[J]. Journal of Applied Oceanography, 2017, 36(1): 125-134.
- [7] 蒋科迪,殷勇,范开桂,等.基于 Canny 算子的南通江海岸线研究[J].测绘通报,2019(10):83-88.
Jiang K D, Yin Y, Fan K G, et al. Study on Nantong coastlines based on Canny operator[J]. Bulletin of Surveying and Mapping, 2019(10): 83-88.
- [8] Alonso M T, Lopez-Martinez C, Mallorqui J J, et al. Edge enhancement algorithm based on the wavelet transform for automatic edge detection in SAR images[J]. IEEE Transactions on Geoscience and

- Remote Sensing, 2011, 49(1): 222-235.
- [9] 詹雅婷, 朱利, 孙永华, 等. 海岸线遥感光谱角度—距离相似度生长模型自动化提取[J]. 遥感学报, 2017, 21(3): 458-469.
- Zhan Y T, Zhu L, Sun Y H, et al. Automatic extraction of coastline via spectral angle-distance similarity growth model[J]. Journal of Remote Sensing, 2017, 21(3): 458-469.
- [10] 谢明鸿, 张亚飞, 付琨. 基于种子点增长的 SAR 图像海岸线自动提取算法[J]. 中国科学院研究生院学报, 2007, 24(1): 93-98.
- Xie M H, Zhang Y F, Fu K. Algorithm of detection coastline from SAR images based on seeds growing [J]. Journal of the Graduate School of the Chinese Academy of Sciences, 2007, 24(1): 93-98.
- [11] 梁立, 刘庆生, 刘高焕, 等. 基于遥感影像的海岸线提取方法综述[J]. 地球信息科学学报, 2018, 20(12): 1745-1755.
- Liang L, Liu Q S, Liu G H, et al. Review of coastline extraction methods based on remote sensing images[J]. Journal of Geo-Information Science, 2018, 20(12): 1745-1755.
- [12] 赵雪梅, 吴军, 陈睿星. RMFS-CNN: 遥感图像分类深度学习新框架[J]. 中国图象图形学报, 2021, 26(2): 297-304.
- Zhao X M, Wu J, Chen R X. RMFS-CNN: new deep learning framework for remote sensing image classification[J]. Journal of Image and Graphics, 2021, 26(2): 297-304.
- [13] Chen L F, Cui X L, Li Z H, et al. A new deep learning algorithm for SAR scene classification based on spatial statistical modeling and features recalibration[J]. Sensors, 2019, 19(11): 2479.
- [14] Chen L F, Tan S Y, Pan Z H, et al. A new framework for automatic airports extraction from SAR images using multi-level dual attention mechanism[J]. Remote Sensing, 2020, 12(3): 560-584.
- [15] Hu W, Huang Y Y, Wei L, et al. Deep convolutional neural networks for hyperspectral image classification[J]. Journal of Sensors, 2015, 2015: 258619.
- [16] Xia G S, Bai X, Ding J, et al. DOTA: a large-scale dataset for object detection in aerial images[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 3974-3983.
- [17] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [18] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640-651.
- [19] Chen L C, Papandreou G, Kokkinos I, et al. Semantic image segmentation with deep convolutional nets and fully connected CRFs[EB/OL]. (2014-12-22) [2021-05-09]. <https://arxiv.org/abs/1412.7062v2>.
- [20] 王振华, 钟元芾, 何婉雯, 等. 改进 DeepLab 网络的遥感影像海岛岸线分割[J]. 中国图象图形学报, 2020, 25(4): 768-778.
- Wang Z H, Zhong Y F, He W W, et al. Island shoreline segmentation in remote sensing image based on improved DeepLab network[J]. Journal of Image and Graphics, 2020, 25(4): 768-778.
- [21] Zhao H S, Shi J P, Qi X J, et al. Pyramid scene parsing network[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6230-6239.
- [22] Li R R, Liu W J, Yang L, et al. DeepUNet: a deep fully convolutional network for pixel-level sea-land segmentation[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2018, 11(11): 3954-3962.
- [23] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[M]//Navab N, Hornegger J, Wells W M, et al. Medical image computing and computer-assisted intervention-MICCAI 2015. Lecture notes in computer science. Cham: Springer, 2015, 9351: 234-241.
- [24] Shamsolmoali P, Zareapoor M, Wang R L, et al. A novel deep structure U-net for sea-land segmentation in remote sensing images[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2019, 12(9): 3219-3232.
- [25] 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, October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 2242-2251.
- [26] Bansal A, Ma S G, Ramanan D, et al. RecycleGAN: unsupervised video retargeting[M]//Ferrari

- V, Hebert M, Sminchisescu C, et al. Computer vision-ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11209: 122-138.
- [27] Fang Y K, Deng W H, Du J P, et al. Identity-aware CycleGAN for face photo-sketch synthesis and recognition[J]. Pattern Recognition, 2020, 102: 107249.
- [28] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets[C]//Annual Conference on Neural Information Processing Systems 2014, December 8-13, 2014, Montreal, Quebec, Canada. New York: Curran Associates, 2014: 2672-2680.
- [29] 王坤峰, 苟超, 段艳杰, 等. 生成式对抗网络 GAN 的研究进展与展望[J]. 自动化学报, 2017, 43(3): 321-332.
- Wang K F, Gou C, Duan Y J, et al. Generative adversarial networks: the state of the art and beyond [J]. Acta Automatica Sinica, 2017, 43(3): 321-332.
- [30] Zhao H, Gallo O, Frosio I, et al. Loss functions for image restoration with neural networks[J]. IEEE Transactions on Computational Imaging, 2017, 3(1): 47-57.