

基于小样本生成对抗网络的光学遥感影像溢油语义分割

刘川^{1,2}, 马玉娟², 范剑超³

(1.上海海洋大学 信息学院, 上海 201306; 2.国家海洋环境监测中心 海洋遥感技术室, 辽宁 大连 116023; 3.大连理工大学 控制科学与工程学院, 辽宁 大连 116024)

摘要: 光学卫星遥感具有高时空、高光谱分辨率的特点, 可实现海洋溢油灾害的有效监测。而光学影像易受天气影响, 导致利用光学卫星影像进行智能提取的数据极为缺乏。针对以上问题, 本文设计了一种基于光学卫星遥感数据的海洋溢油智能提取方法, 构建小样本生成对抗网络 (small sample generation adversarial network, SSGAN) 对光学卫星影像中溢油区域进行语义分割, 解决溢油光学卫星影像数据缺乏的局限性, 同时在模型中融合空间注意力机制以提升溢油智能提取的准确性。通过 2020—2023 年 GF-1/2/6 卫星长时序溢油监测数据进行模型验证比较, 实验结果表明, SSGAN 模型在溢油语义分割方面优于其他模型, 根据提取结果还可制作多幅高分系列光学卫星溢油监测专题产品图。

关键词: 海洋溢油监测; 光学影像; 小样本; 生成对抗网络

中图分类号: X87

文献标识码: A

文章编号: 1007-6336(2025)01-0107-09

Small sample generation adversarial network semantic segmentation based on optical remote sensing oil spill images

LIU Chuan^{1,2}, MA Yujuan², FAN Jianchao³

(1.Shanghai Ocean University, School of Information, Shanghai 201316, China; 2.National Marine Environmental Monitoring Center, Department of Marine Remote Sensing, Dalian 116023, China; 3.Dalian University of Technology, School of Control Science and Engineering, Dalian 116024, China)

Abstract: Optical satellite remote sensing has the characteristics of high spatial and temporal resolution and high spectral resolution, which can realize the effective monitoring of sea oil spill disasters. However, optical images are easily affected by weather, resulting in a great lack of data for intelligent extraction and training using optical satellite image data. Aiming at the above problems, this paper designs an intelligent extraction method for sea oil spills based on optical satellite remote sensing data and constructs a small sample generation adversarial network (SSGAN) to perform semantic segmentation of oil spill areas in optical satellite images. It solves the limitation of the lack of optical satellite image data and fuses the spatial attention mechanism in the model to improve the accuracy of oil spill intelligent extraction. Through the long-term oil spill monitoring data of the GF-1/2/6 satellite from 2020 to 2023, the model verification and comparison are carried out. The experimental results show that the proposed SSGAN model is superior to other models in terms of oil spill semantic segmentation, and a number of Gaofen series of optical satellite oil spill monitoring special product

收稿日期: 2024-01-02, 修订日期: 2024-02-09

基金项目: 国家自然科学基金资助项目 (42076184, 41876109, 41706195); 国家高分重大科研专项 (41-Y30F07-9001-20/22); 国家重点研发计划项目 (2021YFC2801000)

作者简介: 刘川 (1997—), 男, 河南周口人, 硕士, 主要研究方向为遥感影像处理与生成对抗网络, E-mail: m210911486@st.shou.edu.cn

通信作者: 范剑超 (1985—), 男, 内蒙古巴彦淖尔人, 教授, 主要研究方向为遥感信息智能处理与应用, E-mail: fjchao@dlut.edu.cn

images are produced according to the extraction results.

Key words: marine oil spill monitoring; optical image; small sample; generative adversarial networks

频繁的海上活动增加了海洋溢油事故出现的概率^[1-2],作为一种污染面积广、发生频率高、危害程度大的海洋污染,海洋溢油事故给生态、社会、经济带来了极大的危害^[3]。溢油的产生可能由重大灾难^[4],如油轮撞击导致沉没、海底石油管道破裂、非法清理油轮或泵送舱底水等造成^[5]。据统计,全球每年泄漏的石油量超过450万吨^[6]。海洋溢油严重污染海洋环境、破坏海洋生态系统,清理也需要消耗巨大的人力和物力。因此,快速、准确地识别海洋溢油对于保护海洋生态环境具有重要意义。

卫星遥感具有监测范围广、效率高等优势,被广泛应用于海洋溢油监测中。近年来,国内外研究人员已经利用光学遥感卫星开展了众多的研究工作。李颖等^[7]利用HJ-1C卫星数据,用溢油光谱特征与纹理分析相结合的方法对蓬莱19-3油田溢油事件进行研究,实验表明,该方法能较好地识别可见光卫星数据中的溢油目标。Seydi等^[8]基于Landsat-5卫星数据构建了溢油检测框架,实验表明,该框架在Landsat-5可见光卫星数据上较其他深度学习算法有更好的性能。Kolokoussis等^[9]利用Sentinel-2卫星数据开发了两种溢油分析的方法,通过希腊雅典南海岸溢油事件长时序Sentinel-2溢油数据集,验证了该方法在可见光卫星数据上的适用性。丁新涛等^[10]应用4种类型(随机森林、支持向量机、深度神经网络以及差分池化)的机器学习模型验证了模型的鲁棒性,结果与以往的研究结果一致。Li等^[11]提出了一种基于多时间域的无监督、半自动、高效的溢油检测方法,实验结果验证了该方法的有效性。对于经典的机器学习方法,溢油特征的提取和选择都是人工进行的,需要丰富的专家经验和大量的时间成本。深度学习神经网络具有自动提取特征和检测精度高的优势,因此,被应用于溢油检测工作^[12-13]。大多数深度学习均依赖于大量的训练数据以保证检测结果的准确性^[14-15],而在现实工作中,光学溢油遥感影像又是相对缺乏的。

综上所述,在光学卫星溢油影像样本有限的情况下,如何通过深度学习实现溢油影像的准确识别是一个关键问题。解决样本有限的一个简单方法是通过数据增强来增加训练样本的数量,然而,这种方法需要人为设计。而解决样本有限问题的另一种方法是样本生成,通过样本生成不仅可以扩大样本的数量,而且可以丰富样本的内容,提高模型的泛化能力,抑制过拟合的风险。2014年,研究者首次提出生成对抗网络(generative adversarial networks, GAN),这是一种新兴的样本生成模型^[16],通过对抗网络生成器生成大量的伪样本。由于原始的GAN的生成器不受约束,对原始GAN进行改进后,提出条件生成对抗网络来引导生成器合成假样本,并将卷积神经网络与生成对抗网络相结合,有效实现了高质量的图像生成。Gulrajani等^[17]在WGAN(wasserstein generative adversarial network)方案的基础上提出改进,以解决训练不稳定的问题。随着生成对抗网络的逐步发展,其应用领域也越来越广泛,不仅在数据生成方面,在图像分割^[18-19]、图像分类^[20-21]等方面也有应用。因此,GAN也可以作为溢油检测的一种方法,Yu等^[22]使用了一种具有对抗性f-散度学习的检测模型进行(synthetic aperture radar, SAR)影像中溢油自动识别。Li等^[23]开发了一个多尺度条件对抗网络(multiscale conditional adversarial networks, MCAN)进行SAR影像信息提取。Fan等^[24]设计了一种多任务生成对抗网络(multi-task generative adversarial networks, MTGANs)进行溢油识别和信息提取。基于目前的研究,GAN网络可以进行SAR影像溢油信息提取。但是,针对光学卫星溢油遥感影像进行智能提取仍然是一项具有挑战性的关键任务。

为解决上述问题,本文探索了高分系列卫星中光学卫星在海洋溢油监测方面的能力,充分挖掘光学卫星数据的环境遥感应用潜力,通过搭建小样本生成对抗网络模型开展溢油影像智能提取的研究,实现遥感影像的智能分割并实际应用,形成海洋溢油遥感产品监测结果。

1 数据与方法

1.1 研究数据

卫星遥感技术具有高时间分辨率、高信噪比等技术特点,本次研究综合考虑了卫星数据类型、分辨率和重访周期,选择高分系列光学卫星中 GF-1、GF-1B/C/D、GF-2 和 GF-6 建立溢油监测体系,卫星具体信息见表 1。依托上述卫星进行重访周期长、覆盖范围大的光学卫星溢油遥感组网观测,设计高分系列光学卫星遥感海洋溢油监测总体流程、开展溢油监测并进行智能解译,实现光学遥感卫星海洋溢油智能提取。

表 1 研究区所用数据

Tab.1 Data used in the study area

卫星名称	类型	分辨率/m	重访周期/d
GF-1	光学	2/8/16	2/4
GF-1B	光学	2/8	2/4
GF-1C	光学	2/8	2/4
GF-1D	光学	2/8	2/4
GF-2	光学	1/4	69
GF-6	光学	2/8/16	4

1.2 研究流程

对高分系列卫星开展溢油监测的研究,高分系列卫星主要分为光学卫星和 SAR 卫星,这两类卫星数据处理流程基本相同,但细则稍有差异。针对光学卫星设计的海洋溢油监测总体流程如图 1 所示。

光学卫星数据虽然波段信息丰富,但极易受云层等环境因素的干扰而难以有效解译。因此,在提取光学卫星溢油信息前,首先,去除云层覆盖范围大、能见度较差的可见光影像;其次,将得到的光学卫星数据进行辐射定标、几何校正和大气校正等预处理;再次,将预处理后的遥感影像通过纹理、光谱等特征提取方法,提取遥感影像中可见光油膜的显著性特征;最后,使用生成对抗网络搭建模型进行溢油信息提取,结合溢油风险源辅助专家进行综合分析,排查溢油事件的发生原因,验证识别结果^[25]。对卫星影像溢油区域识别后,提取溢油信息,确定溢油区域,制作溢油监测专题图。

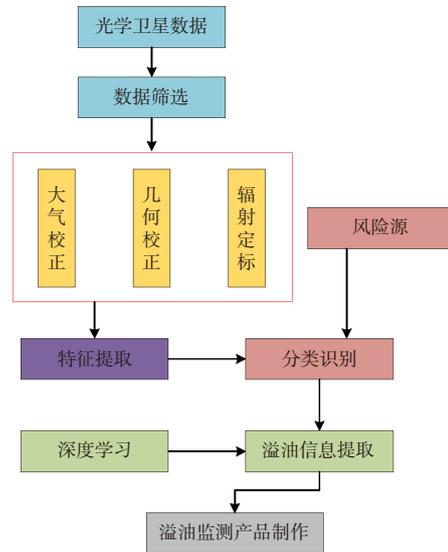


图 1 海洋溢油监测总体流程

Fig. 1 Overall flow of marine oil spill monitoring

1.3 研究方法

1.3.1 总 述

本文搭建基于一个生成器和一个判别器的小样本生成对抗网络 (small sample generation adversarial network, SSGAN) 应用于光学溢油语义分割任务中。基于小样本训练的溢油检测是一种很有前景和实际意义的学习方法。将收集到的影像进行预处理后输入生成器,生成器从判别器的损失中自动学习、训练,生成溢油分割图。真实的光学溢油图像、生成的分割图和分割标签图一起输入判别器。判别器学习真实映射和生成映射间的分布差距,并根据判别结果反向优化生成器,指导生成器生成更真实的溢油分割图,最终实现光学溢油图像的语义分割。

1.3.2 网络结构

搭建 SSGAN 模型,网络架构如图 2 所示。SSGAN 模型主要由生成器 G 和判别器 D 组成,生成器的网络先有一个卷积层,其后连接 N 个卷积块,每个卷积块包含卷积层、空间注意力模块 (spatial attention module, SAM)、归一化层和 LeakyReLU 激活函数。最后接一个卷积层和 Tanh 激活函数。判别器的构造由 N 个卷积块组成,每个卷积块包含卷积层、空间注意力模块、归一化层和 LeakyReLU 激活函数,判别器的最后一个卷积块只有卷积层。网络中的卷积层可以有效地提取输入的溢油数据的特征,并为后续

的网络层提供更有意义和更高级别的特征。归一化层是将数据进行标准化处理,用以加速神经网络的训练过程,并提高模型的性能和稳定性。

LeakyReLU 激活函数能增强网络的非线性能力,使其更好地拟合复杂数据,使用 LeakyReLU 激活函数可以提高神经网络的性能和稳定性。

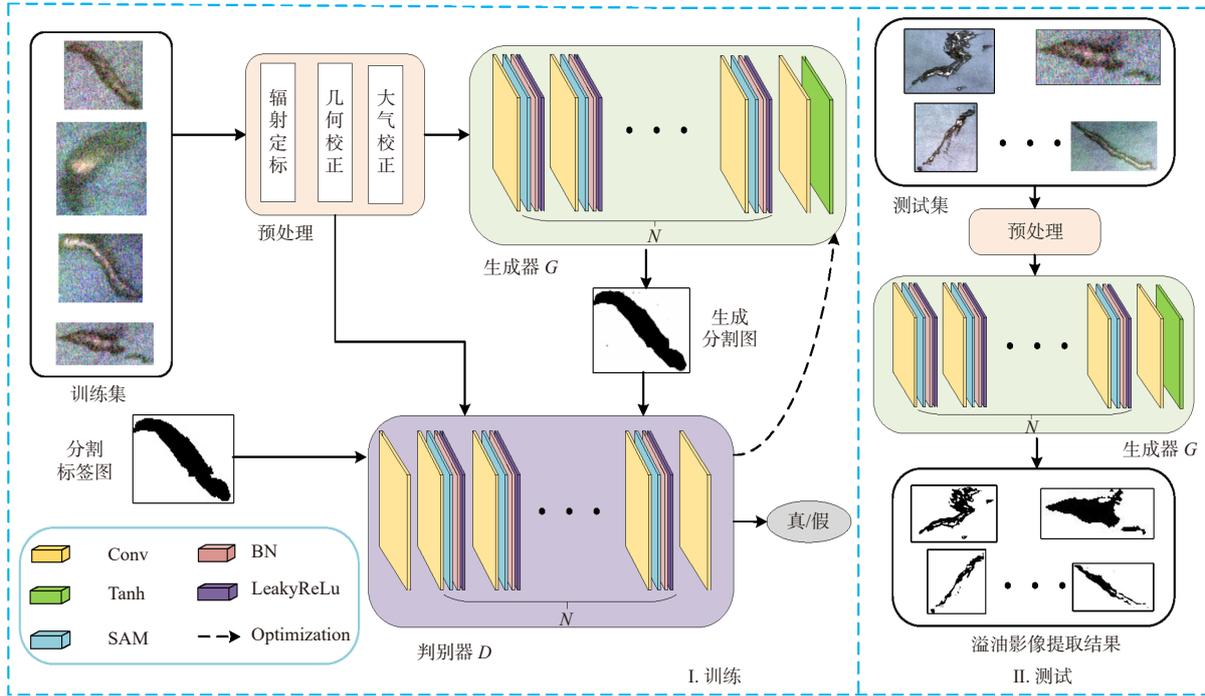


图2 SSGAN 模型架构

Fig. 2 Diagram of SSGAN model architecture

首先,光学溢油原始影像作为生成器的输入,经过生成器后生成溢油分割图,判别器将光学溢油原始图像、生成器生成的溢油分割图和溢油分割标签图作为输入项。其次,生成器生成溢油分割图与溢油分割标签图进行残差学习,以增强网络表示能力。再次,判别器通过输入的溢油原始图像、溢油分割图和溢油分割标签图进行判别。最后,溢油原始图像和溢油分割标签图使判别器学习溢油原始图像中溢油区域的特征信息,对生成器生成的溢油分割图和溢油分割标签图进行区分,并学习它们之间的数据分布差异,分别输出判别分数并反向优化生成器,指导生成器生成更加精确的溢油分割图,从而实现光学溢油影像的智能提取。

1.3.3 SAM 模块

在溢油的信息提取中,模型可能只对溢油图像中的小部分溢油区域感兴趣,导致模型不能有效提取溢油的全部信息。空间注意力机制有助于模型更加关注重要的空间区域。本文融入

SAM 也是一种空间注意力机制,即关注特征图中重要的位置信息。通过图像空间维度的不同区域进行加权,帮助模型集中注意力关注图像中的溢油区域,减少无关信息的处理,以便更好地捕捉重要特征,从而提高模型的性能。

SAM 模块的网络结构(图 3)首先通过卷积层提取溢油特征。其次,基于通道进行平均池化以及最大池化操作来生成注意力图,再计算得到每个位置的注意力权重。再次,根据计算得到的注意力权重,将权重通过卷积进行特征融合并应用到原始特征图,以获得加权特征图。这样重要的区域将获得更高的权重,而无关紧要的区域会获得较低的权重。最后,通过 Sigmoid 激活函数操作来生成权重图叠加回原始的输入特征图,从而使溢油目标区域得以增强。SAM 模型的公式如下:

$$\begin{aligned}
 M(F) &= \text{Sig}(f^{7 \times 7}([\text{AvgPool}(F); \text{MaxPool}(F)])) \\
 &= \text{Sig}(f^{7 \times 7}([F_{\text{Avg}}; F_{\text{Max}}]))
 \end{aligned}
 \tag{1}$$

式中: F 代表提取的溢油图像通道特征; Sig 代表 Sigmoid 激活函数; AvgPool 和 MaxPool 分别代表平均池化和最大池化操作, 使用两个池化操作聚合成一个特征图的通道信息, 生成两幅图 ($1 \times H \times W$ 的 F_{Avg} 图和 $1 \times H \times W$ 的 F_{Max} 图)。 $f^{7 \times 7}$ 表示滤波器为 7×7 的卷积运算。 $M(F)$ 则是生成的空间注意力图, 该空间注意力图编码了需要关注或压制的位置。通过融入 SAM 模块可以更好地关注图像中的重要区域, 从而提高模型的溢油图像提取性能。

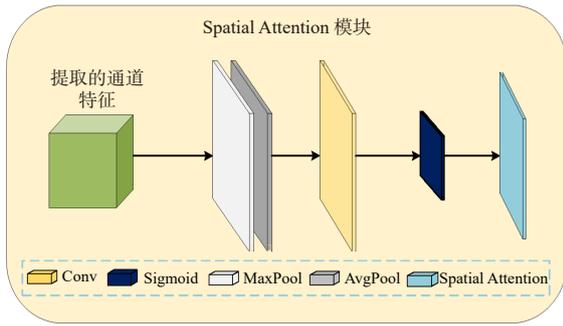


图 3 SAM 模块结构

Fig. 3 SAM module structure diagram

1.3.4 损失函数

在训练过程中, 生成器的目标就是尽量生成真实的溢油分割图去欺骗判别器。而判别器的目标就是把生成器生成的溢油分割图和真实的溢油分割标签图区分开来。这样生成器和判别器就构成了一个动态的博弈过程, 生成器的目标函数见公式(2)。

$$L_D = \alpha \|S - \hat{S}\|_1 - D_s(O, \hat{S}) \quad (2)$$

式中: α 为 L_1 范数的平衡参数; S 为输入真实分割标签图; \hat{S} 为生成器生成的溢油分割图; O 为真实的溢油图像; $\|S - \hat{S}\|_1$ 为 L_1 范数, 它惩罚溢油分割标签图和生成的溢油分割图之间的逐像素距离。最小化训练生成器生成更加真实的溢油分割图, 最终能成功地欺瞒判别器。

在 SSGAN 模型训练过程中, 判别器的目标函数如下:

$$L_D = \beta (\|\nabla_{\hat{S}} D_s(S - \hat{S})\|_2 - 1)^2 + D(O, \hat{S}) - D(O, S) \quad (3)$$

式中: β 为权重平衡参数; S 为输入真实分割标签图; \hat{S} 为生成器生成的溢油分割图; O 为真实的

溢油图像; $D(O, \hat{S}) - D(O, S)$ 代表对抗损失, 用来增加判别器的判别能力; $(\|\nabla_{\hat{S}} D(S - \hat{S})\|_2 - 1)^2$ 代表惩罚梯度损失, 会产生稳定的梯度, 既不会消失也不会爆炸; \tilde{S} 表示在 S 和 \hat{S} 之间均匀采样的随机变量。最小化训练判别器, 可区分生成的溢油分割图和溢油分割标签图。

SSGAN 模型总体目标函数如下:

$$\min_G \max_D V(D, G) = \alpha \|S - \hat{S}\|_1 - \beta (\|\nabla_{\tilde{S}} D(S - \tilde{S})\|_2 - 1)^2 + D(O, S) - D(O, \hat{S}) \quad (4)$$

使用损失公式(4)训练网络, 直到网络达到平衡状态。训练结束以后, 保留生成器, 丢弃判别器, 利用训练好的生成器执行溢油信息提取任务。

2 结果与讨论

2.1 实验设置

所有实验均在 Windows 10 下编译, python 3.8、pytorch 1.7.1 和 cuda 10.1, GeForce RTX 2080 Ti GPU 环境下运行和测试。网络的优化器采用 Adam 优化器, 学习率设置为 0.0005, L_1 范数的平衡参数为 $\alpha=10$, 梯度惩罚权重参数设置为 $\beta=10$, 生成器和判别器的网络层数 $N=5$, 模型训练次数设为 200 轮。

将收集的光学卫星溢油影像进行数据整理, 预处理后根据溢油特征进行分析, 确定溢油区域后进行裁剪, 制作成光学溢油影像数据集, 在本模型中仅使用 4 张光学溢油图像作为网络的训练, 剩余的 10 张图像作为测试集用以验证和评估模型的性能。

将本文提出的 SSGAN 模型与五种分割算法进行对比, 分别是 MCAN^[23]、U-net++^[26]、DeepLabv3+^[27]、MDOAU-net^[28] 和 MSSGU^[29] 模型, 为验证所提模型的有效性, 所有的对比方法均采用相同的训练集和测试集。

2.2 评价指标

溢油区域信息提取的性能指标通过混淆矩阵来计算, 下列公式(5)到公式(10)中的 T_p 代表实际为溢油并且预测为溢油像素的数量, T_N 代表实际为海面并且预测为海面像素的数量, F_p 代表实际为海面但是预测为溢油像素的数量, F_N 代表实际为溢油但是预测为海面像素的

数量。使用五种指标评价模型性能。 OA 表示生成的溢油分割图中正确预测的总比例,公式如下:

$$OA = \frac{T_P + T_N}{T_P + T_N + F_N + F_P} \quad (5)$$

Precision表示在预测的溢油分割图中溢油区域中真正是溢油的比例,公式如下:

$$P = \frac{T_P}{T_P + F_P} \quad (6)$$

F_1 -score同时考虑准确率和召回率,公式如下:

$$F_1 = \frac{2T_P}{2T_P + F_N + F_P} \quad (7)$$

MIoU用于衡量模型在像素级别上的预测结果与真实标签之间的相似度,公式如下:

$$M = \frac{1}{2} \left(\frac{T_P}{T_P + F_N + F_P} + \frac{T_N}{T_N + F_N + F_P} \right) \quad (8)$$

Kappa用于计算溢油分割图像与溢油分割标签的一致性,公式如下:

$$K = \frac{OA - P_e}{1 - P_e} \quad (9)$$

$$P_e = \frac{(T_N + F_P) + (T_N + F_N) + (T_P + F_P) + (T_P + F_N)}{N \times N} \quad (10)$$

2.3 实验结果

对溢油分割结果进行对比分析,图4是6种模型下4幅光学溢油图像的分割结果。本实验选取的溢油图像大多是溢油面积较大的溢油图像。在使用少量数据集训练模型的过程中,由于U-net++模型也支持少量数据集训练模型,因此,本实验中U-net++也保持着优异的性能。虽

然MCAN、DeepLabv3+和MDOAU-net在本实验中表现亦良好,但是分割精度不如U-net++。数据集的缺乏导致DeepLabv3+模型分割图中溢油区域的边缘信息较为模糊。相比之下,U-net++在边缘区域表现更好,但是U-net++模型可能会将海面误判为溢油区域。MDOAU-net方法优化了边缘信息,却在预测图中存在大量误判。DeepLabv3+模型使用了一个编码器和一个解码器。编码器提供高层特征语义信息,解码器逐步恢复边界信息,在关注边界信息的同时提升分割效果。MCAN方法采用了多尺度生成对抗网络的方式,可以有效地提取溢油区域,但网络层数较浅并不能有效地提取溢油的全部信息,导致海面被严重误判为溢油区域。MSSGU在多层图上学习多尺度特征,通过从精细到粗糙逐渐合并相邻的超像素,有效地提取溢油的局部信息,但容易丢失溢油的全局信息。本文提出的SSGAN方法在分割模型中集成了多个卷积块,多个卷积块可以提取的溢油信息。在模型每个卷积块中加入了空间注意力SAM模块使模型更加关注溢油区域,提升模型的性能,同时判别器对生成器生成溢油分割图具有指导作用。此外,生成器可以生成大量的伪样本,从而丰富样本数量并增强模型的泛化能力。因此,本文提出的SSGAN模型即使在少量训练样本的情况下,溢油分割的精度也优于其他模型,具有优异的溢油图像分割性能。

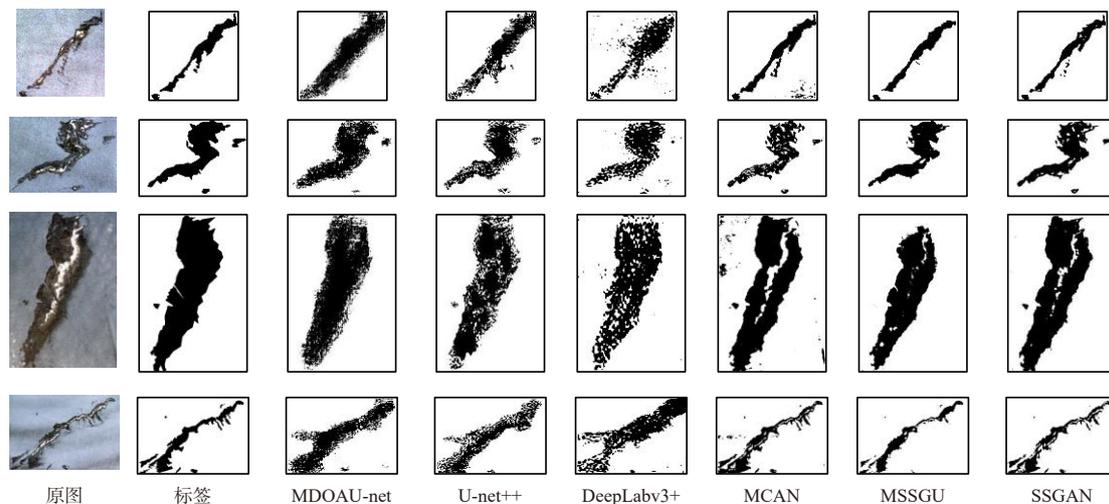


图4 溢油分割方法对比实验结果

Fig. 4 Oil spill segmentation methods compared with experimental results

在测试集上对 6 种方法多次运行后计算平均性能指标(表 2), 然后进行比较。从表 2 中可以看出, 本文提出的 SSGAN 模型在 5 种性能指标中都是最高的。 K 值通常用于检验图像分类的空间一致性。本文提出的 SSGAN 模型在光学溢油影像上的平均 K 值为 62.38%, 当 K 值为 61% ~ 80% 时, 可认为具有高度一致性, 所以性能指标结果与目视解译结果一致, 与 U-net++, MCAN, MSSGU、DeepLabv3+和 MDOAU-net 模型相比, SSGAN 模型具有优异的分割精度。因此, 本文提出的 SSGAN 模型在光学溢油影像训练集较少的情况下也能保证较高的分割精度。

表 2 测试集上 6 种分割方法的平均性能指标

Tab.2 The average performance index of the six segmentation methods on the test set

模型	OA	P	F_1	K	M	文献
MCAN	82.54	80.18	79.25	59.66	63.34	[23]
U-net++	83.04	78.32	79.93	58.89	67.04	[26]
Deeplabv3+	80.55	76.25	77.81	54.70	63.99	[27]
MDOAU-net	79.94	76.28	77.85	54.61	63.67	[28]
MSSGU	84.36	81.56	80.16	61.45	67.67	[29]
SSGAN	85.17	82.72	81.77	62.38	69.72	

2.4 消融实验

为验证加入空间注意力 SAM 对实验结果的影响, 设计对比实验。图 5 分别是未加入 SAM 和加入 SAM 后 SSGAN 模型的实验对比结果, 从结果来看, 未加入 SAM 的模型中会学习与溢油区域无关的信息特征, 导致预测结果中出现误判情况, 将海面预测为溢油区域, 影响溢油区域信息提取准确度。而加入 SAM 后 SSGAN 模型则会更加关注溢油区域, 减少了无关区域的预测, 从而能有效地提高溢油区域分割的准确性。对实验结果进行性能指标对比(表 3), 结果进一步证实了加入空间注意力 SAM 模块有助于提高模型对溢油区域提取的准确性。

此外, 在测试集上通过调整 α 和 β 参数的值进行实验对比, 结合 5 种性能评价指标对分割结果进行分析。分别将参数值 α 和 β 设置为 1 到 10, 实验结果如图 6、图 7 所示。实验发现, 当 $\alpha=10$ 、 $\beta=10$ 时, 性能指标非常理想, 此时对溢油

分割性能最优。

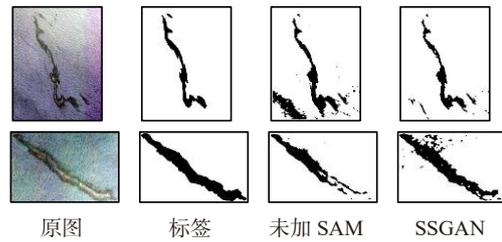


图 5 加入 SAM 后对实验影响的结果

Fig. 5 The influence of SAM on the experiment diagram

表 3 测试集上加入 SAM 后的平均性能指标对比

Tab.3 Comparison of average performance indicators after SAM is added to the test set

模型	OA	P	F_1	K	M
未加入 SAM	82.93	80.18	79.47	59.82	64.90
SSGAN	85.17	82.72	81.77	62.38	69.72

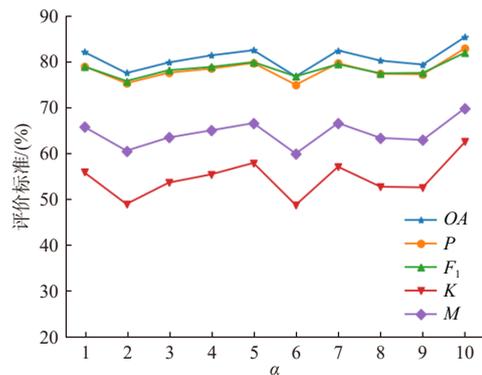


图 6 平衡参数 α 值对实验影响的结果

Fig. 6 The influence of the equilibrium parameter α on the experiment results diagram

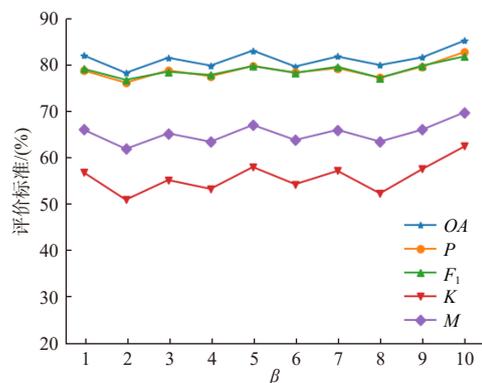


图 7 平衡参数 β 值对实验影响的结果

Fig. 7 The influence of the equilibrium parameter β on the experiment results diagram

SSGAN模型的判别器和生成器由多个卷积块组成。为展示卷积块的层数对溢油分割精度的影响,将卷积块的层数 N 分别设置为1到10进行实验,结果如图8所示。因为更深的生成器层数会导致更长的训练时间和网络过拟合的趋势,所以更深的生成器层数并不一定具有更好的性能。较少的层数对网络学习特征信息没有帮助。通过实验并结合5种性能指标综合分析比较后发现,当网络的层数 $N=5$ 时,对溢油分割性能最优。这也表明,将模型中生成器和判别器的层数设置为5对获得良好的分割性能至关重要。

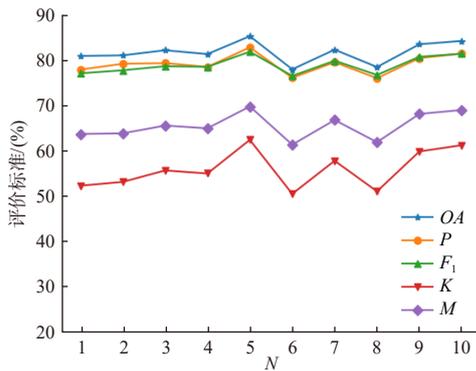


图8 生成器和判别器层数对实验影响的结果

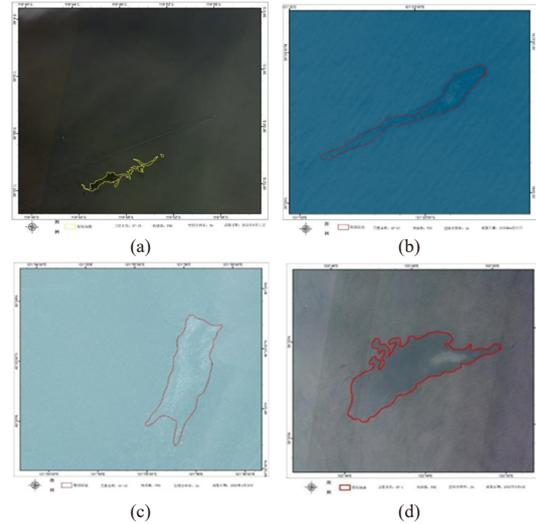
Fig. 8 The number of layers of generator and discriminator influencing the results of the experiment diagram

2.5 海洋溢油监测专题产品

开展海洋溢油监测研究与应用,设计研究区溢油监测流程,制作多幅海洋溢油监测专题产品(图9),图9包含采用的卫星数据、传感器、卫星数据空间分辨率、成像日期以及溢油区域智能解译结果和具体分布范围,通过溢油区域的长时序跟踪监测,并结合多源遥感监测技术,确保溢油识别结果准确性。

3 结论

本文基于光学遥感卫星中的GF-1/2/6卫星,设计光学遥感海洋溢油卫星监测整体流程,由于光学卫星遥感极易受天气的影响,导致可利用的光学卫星数据极为匮乏。因此,搭建SSGAN模型来解决光学卫星数据缺少的局限性,并融合空间注意力机制以提升模型的性能,可以有效地利



注:(a)2021年6月11日监测产品图;(b)2020年4月27日监测产品图;(c)2020年4月30日监测产品图;(d)2020年5月5日监测产品图

图9 溢油监测产品

Fig. 9 Oil spill monitoring product diagram

用光学卫星遥感数据进行海洋溢油监测。通过2020—2023年开展的海洋溢油长时序监测,验证了SSGAN模型在光学卫星海洋溢油监测中的有效性,并制作了多幅高分系列卫星溢油监测专题产品。

参考文献:

- [1] 张永宁,丁倩,李栖筠.海上溢油污染遥感监测的研究[J].大连海事大学学报,1999,25(3):1-5.
- [2] 胡佳臣,王迪峰.基于遥感的海洋溢油监测方法[J].环境保护科学,2014,40(1):68-73.
- [3] 陈涛.海洋污染事件的类型、特征及其社会效应研究[J].太平洋学报,2015,23(3):87-96.
- [4] 金杰,吴雅男,康仲林.基于多特征的SAR影像溢油暗斑提取[J].测绘与空间地理信息,2018,41(2):53-56.
- [5] MIGLIACCIO M, TRANFAGLIA M, ERMAKOV S A. A physical approach for the observation of oil spills in SAR images[J]. IEEE Journal of Oceanic Engineering, 2005, 30(3): 496-507.
- [6] MAHR R, CHASE C R. Oil spill detection technology for early warning spill prevention[C]//Proceedings of the OCEANS 2009. Biloxi: IEEE, 2009: 1-8.
- [7] 李颖,兰国新,刘丙新.辅以纹理特征的HJ-CCD海上溢油信息提取——以PL19-3溢油为例[J].中国环境科学,2012,32(8):1514-1520.
- [8] SEYDI S T, HASANLOU M, AMANI M, et al. Oil spill de-

- tection based on multiscale multidimensional residual CNN for optical remote sensing imagery[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 10941-10952.
- [9] KOLOKOUSSIS P, KARATHANASSI V. Oil spill detection and mapping using sentinel 2 imagery[J]. *Journal of Marine Science and Engineering*, 2018, 6(1): 4.
- [10] 丁新涛, 曾 侃, 贺明霞. 用于SAR图像海面溢油自动识别的Bagging-AdaBoost决策树分类器系统[J]. *中国海洋大学学报*, 2018, 48(10): 132-142.
- [11] LI Y, YU Q L, XIE M, et al. Identifying oil spill types based on remotely sensed reflectance spectra and multiple machine learning algorithms[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 9071-9078.
- [12] LIU S C, CHI M M, ZOU Y X, et al. Oil spill detection via multitemporal optical remote sensing images: a change detection perspective[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(3): 324-328.
- [13] ZENG K, WANG Y X. A deep convolutional neural network for oil spill detection from spaceborne SAR images[J]. *Remote Sensing*, 2020, 12(6): 1015.
- [14] ZHU Q Q, ZHANG Y N, LI Z Q, et al. Oil spill contextual and boundary-supervised detection network based on marine SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5213910.
- [15] FAN J C, ZHANG S, WANG X Z, et al. Multifeature semantic complementation network for marine oil spill localization and segmentation based on SAR images[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2023, 16: 3771-3783.
- [16] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]//*Proceedings of the 27th International Conference on Neural Information Processing Systems*. Montreal: MIT Press, 2014: 2672-2680.
- [17] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved training of Wasserstein GANs[C]//*Proceedings of the 31st International Conference on Neural Information Processing Systems*. Long Beach: Curran Associates Inc., 2017: 5769-5779.
- [18] ZHANG Z Z, YANG L, ZHENG Y F. Translating and segmenting multimodal medical volumes with cycle-and shape-consistency generative adversarial network[C]//*Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake City: IEEE, 2018: 9242- 9251.
- [19] PAN X, ZHAO J, XU J. Conditional generative adversarial network-based training sample set improvement model for the semantic segmentation of high-resolution remote sensing images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(9): 7854-7870.
- [20] MA A L, YU N, ZHENG Z, et al. A supervised progressive growing generative adversarial network for remote sensing image scene classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5618818.
- [21] FENG J, YU H P, WANG L, et al. Classification of hyperspectral images based on multiclass spatial-spectral generative adversarial networks[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(8): 5329-5343.
- [22] YU X R, ZHANG H, LUO C B, et al. Oil spill segmentation via adversarial f -divergence learning[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(9): 4973-4988.
- [23] LI Y Q, LYU X R, FRERY A C, et al. Oil spill detection with multiscale conditional adversarial networks with small-data training[J]. *Remote Sensing*, 2021, 13(12): 2378.
- [24] FAN J C, LIU C. Multitask GANs for oil spill classification and semantic segmentation based on SAR images[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2023, 16: 2532-2546.
- [25] 柯丽娜, 李云昊, 张 帅, 等. 渤海海域多源遥感溢油风险评价与长序监测[J]. *海洋科学*, 2022, 46(2): 17-27.
- [26] ZHOU Z W, SIDDIQUEE M R, TAJBAKHS N, et al. UNet++: redesigning skip connections to exploit multiscale features in image segmentation[J]. *IEEE Transactions on Medical Imaging*, 2020, 39(6): 1856-1867.
- [27] CHEN L C, ZHU Y K, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]//*Proceedings of the 15th European Conference on Computer Vision*. Munich: Springer, 2018: 833-851.
- [28] WANG J C, FAN J C, WANG J. MDOAU-Net: a lightweight and robust deep learning model for SAR image segmentation in aquaculture raft monitoring[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 4504505.
- [29] LIU Q C, XIAO L, YANG J X, et al. Multilevel superpixel structured graph U-Nets for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5516115.

(本文编辑: 曲丽梅)