

## 基于改进 FCN 的多极化 SAR 影像海上溢油检测

杜艳玲<sup>1</sup>, 崔建华<sup>1</sup>, 魏泉苗<sup>2</sup>, 黄冬梅<sup>3\*</sup><sup>1</sup>上海海洋大学信息学院, 上海 201306;<sup>2</sup>自然资源部东海局, 上海 200136;<sup>3</sup>上海电力大学, 上海 200090

**摘要** 海上溢油对海洋生态环境造成的危害巨大, 完成溢油区域的准确检测对海洋异常现象的快速应急处理具有重要意义。现阶段, 合成孔径雷达(SAR)为海上溢油检测提供重要数据基础, 但广泛存在海上生物油膜、低风区及 SAR 影像本身显著的斑点噪声等溢油疑似区域, 极大限制了海上溢油检测精度。针对上述问题, 提出一种基于改进全卷积神经网络(FCN)的多极化 SAR 影像海上溢油智能检测框架。首先, 对极化 SAR 影像进行 Pauli 分解和 Refined-Lee 滤波预处理, 在保证 SAR 影像极化特征信息同时降低疑似溢油噪声对检测精度的影响; 其次, 针对 FCN 模型对空间信息考虑的不足, 提出不同层级卷积层融合机制, 实现高层语义特征与低层空间细节特征融合, 进而提升海上溢油区域检测精度。经实验对比分析可知, 基于改进 FCN 的海上溢油智能检测框架可有效降低疑似溢油区域对检测精度的影响, 同时兼顾考虑多极化与边缘特征信息, 实现基于像素的溢油区域检测, 最优检测精度可达 95.7%。

**关键词** 机器视觉; 极化合成孔径雷达; 溢油检测; 降噪; 极化融合; 全卷积神经网络

中图分类号 P315.69

文献标志码 A

doi: 10.3788/LOP202259.0415005

## Marine Oil-Spill Detection in Multi-Polarization Image-Based SAR on Improved FCN

Du Yanling<sup>1</sup>, Cui Jianhua<sup>1</sup>, Wei Quanmiao<sup>2</sup>, Huang Dongmei<sup>3\*</sup><sup>1</sup>College of Information Technology, Shanghai Ocean University, Shanghai 201306, China;<sup>2</sup>East China Sea Bureau of Ministry of Natural Resources, Shanghai 200136, China;<sup>3</sup>Shanghai University of Electric Power, Shanghai 200090, China

**Abstract** Marine oil spills cause great harm to the marine ecological environment; thus, an accurate detection of the oil-spill area is of great essential for a rapid emergency treatment. At this stage, synthetic aperture radar (SAR) provides an important data basis for marine oil-spill detection, but the widespread marine biological oil film, the presence of low wind areas, and the considerable speckle noise of SAR images are very likely to be oil spills, limiting the accuracy of marine oil-spill detection. Therefore, the present research proposes an improved fully-convolutional network (FCN)-based marine oil-spill intelligent detection framework in multi-polarized SAR image. The first step is to perform Pauli decomposition and Refined-Lee filtering preprocessing on the polarized SAR image to ensure the polarization characteristic information while reducing the effect of the suspected oil-spill noise on the detection accuracy. Secondly, considering the lack of consideration of the spatial information in the FCN model, the fusion

收稿日期: 2021-03-22; 修回日期: 2021-04-04; 录用日期: 2021-04-14

基金项目: 国家自然科学基金青年项目(41906179)、上海市科委地方院校能力建设项目(20020500700)、上海市教育发展基金(AASH2004)

通信作者: \*dmhuang@shou.edu.cn

mechanism of convolutional layers with different levels is used to realize the fusion of high-level semantic features and low-level spatial details, thereby improving the accuracy of marine oil-spill area detection. Experimental comparison and analysis show that the marine oil-spill intelligent detection framework, based on an improved FCN, can effectively reduce the effect of suspected oil-spill areas on detection accuracy, while considering multi-polarization and edge feature information to achieve pixel-based oil-spill area detection. The excellent detection accuracy can reach 95.7%.

**Key words** machine vision; polarimetric synthetic aperture radar; oil spill detection; noise reduction; polarization fusion; fully convolutional network

## 1 引言

海上溢油是影响海洋生态环境安全的重要问题<sup>[1]</sup>。尤其随着海上运输、远洋捕捞、海洋科考和海上油田勘察等人类活动的快速发展,海上溢油事件频发,对海洋生态环境危害巨大,且海上溢油事故具有分布广、扩散快、控制难的特点<sup>[2]</sup>。2017年9月10日,发生在雅典的萨拉米斯岛附近的油轮原油泄漏事故中,最初只有油轮附近海域受到污染,但随着风力与海浪的作用,污染迅速扩大,造成了极其严重的生态事故<sup>[3]</sup>。屡发不止的海上溢油事件对人类保护海洋生态环境安全提出了巨大挑战,因此准确快速地进行海洋溢油检测对海洋环境保护与生态资源开发具有重要意义。

合成孔径雷达(SAR)具有全天候不受天气条件影响的观测优势,为海洋溢油检测研究提供了不可替代的数据基础。在SAR图像中,被油膜覆盖的像素会因为海面上泄漏的油而使Bragg散射减弱<sup>[4]</sup>,在SAR图像上呈现出黑斑或者带状黑条。以往海面溢油检测主要通过阈值分割实现,通过应用无油表面和被油膜覆盖表面生成的双峰直方图来确定阈值,将图像分成两部分,阈值分割包括单阈值分割方法<sup>[5]</sup>、双阈值分割方法<sup>[6]</sup>和自适应阈值分割方法<sup>[7]</sup>。这类方法的原理简单、实现速度快,但易受海面斑点噪声和图像灰度分布不均匀的影响,而导致油膜分割的准确性偏低。Kim等<sup>[8]</sup>利用海面覆盖类型的纹理信息,提出了一种改进的基于目标与背景像素强度差的溢油检测算法,该算法可以排除部分疑似溢油的干扰,比如洋流和风,但是疑似溢油仍然很难和石油区分开来。极化SAR(Pol-SAR)数据提供了更丰富的信息,增强了识别和区分海上不同目标的散射行为,利用Pol-SAR检测溢油的一些特殊系数被提出和发展<sup>[9]</sup>,2017年Song等<sup>[10]</sup>联合使用多个Pol-SAR特征作为小波网络的输入,该方法的分类精度比采用单一极化特征方法的分类准确度提高了7.75%。

近年来,深度学习在计算机视觉领域取得了优异的成绩,为遥感图像分类研究提供了新的思路<sup>[10]</sup>。2015年,Long等<sup>[11]</sup>提出的全卷积网络(FCN)由于能够以端到端的方式处理基于像素的分类任务,得到广泛的应用。2018年,Wang等<sup>[12]</sup>利用FCN对Pol-SAR图像进行分类,相对于其他方法,取得了较高的准确度。2018年,Li等<sup>[13]</sup>引入滑动窗口FCN和稀疏编码(SFCN-SC)用于Pol-SAR图像分类,同样取得了较好的效果。

SAR影像为海上溢油检测提供了重要数据基础<sup>[14]</sup>,但由于海洋环境的复杂性以及SAR影像成像方式,SAR影像中存在大量的噪声。此外,海洋表面广泛存在着多种疑似油区,疑似溢油(低风区域、船行驶尾波、生物油膜等)会对溢油检测造成干扰甚至错误检测<sup>[15]</sup>;同时,由于油膜具有高流动性<sup>[16]</sup>,很难对其形状参数进行准确的描述与定义,对海面溢油检测提出了巨大挑战<sup>[17]</sup>。

针对Pol-SAR影像中普遍存在的海洋生物油膜、低风区以及自身显著斑点噪声等疑似溢油现象,本文利用Pol-SAR影像,提出一种改进的FCN溢油智能检测框架。首先,选取合适的预处理方法对Pol-SAR影像进行降噪处理;其次,基于FCN对溢油区域进行像素级分类,并针对FCN对空间信息考虑不足的问题,对FCN进行改进;最后,通过不同层级卷积层的融合,实现高层语义特征与低层空间细节特征的融合,提高溢油区域的检测精度。

## 2 数据预处理和样本集构建

### 2.1 数据预处理

设计有效、完备的数据集是提高目标检测精度的关键。使用的数据集为全极化RadarSAT-2 SAR影像,拍摄于2011年的墨西哥湾,数据信息如表1所示。海上广泛存在生物油膜、低风区以及SAR影像自身斑点噪声等疑似溢油的暗斑区域,导致海上溢油检测的漏检或误检现象严重。为更好地利用SAR影像极化信息提取目标并降低暗斑噪声的影

响,首先采用 Pauli 分解对全极化 SAR 影像进行处理,其次采用 Refined-Lee 滤波对 SAR 影像进行相干斑滤波。对比结果发现,3×3 窗口对降低相干斑噪声的效果较好,同时在溢油区域的边缘信息保持得比较清晰完整,有利于海上溢油区域检测。

表 1 RadarSAT-2 SAR 影像信息

Table 1 Information on the RadarSAT-2 SAR image used in this study

Parameter	Single look complex(SLC)
Start time	2011-06-17T11:48:20
Beam mode	FQ25
Polarization	HH, VV, HV, VH
Look direction	Right
Pixel spacing / (m×m)	4.73×5.05
Incidence angle	4.36E1-4.49E1
Covered area / (km×km)	37.17×19.34

### 2.1.1 Pauli 分解

SAR 影像的极化特征为海上溢油精准检测提供了丰富信息。Pauli 分解作为一种常见的目标分解方法,可在一定程度上抑制 SAR 成像系统自身产生的相干斑噪声,由 Pauli 目标分解的散射特征参数能够准确获得与其地物物理特性相对应的极化特征。采用 Pauli 分解方法对全极化 SAR 影像进行预处理,在充分保持海上溢油极化特征信息前提下,对其斑点噪声进行一定程度上的抑制。在分解中,用于目标分解的 4 个 Pauli 基矩阵分别为  $S_a = \frac{1}{\sqrt{2}} \begin{bmatrix} 0 & -i \\ i & 0 \end{bmatrix}$ ,  $S_b = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}$ ,  $S_c = \frac{1}{\sqrt{2}} \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$ ,  $S_d = \frac{1}{\sqrt{2}} \begin{bmatrix} 0 & -i \\ i & 0 \end{bmatrix}$ , 4 个 Pauli 基对应不同的实际散射机制,分别为平面一次散射、0° 相对取向的二面角反射器的二次散射、45° 相对取向的二面角反射器的二次散射、反对称分量。则散射矩阵可以写成

$$[S] = a[S_a] + b[S_b] + c[S_c] + d[S_d], \quad (1)$$

式中:  $a, b, c, d$  分别为对应的散射强度。写成向量  $K$  的形式:

$$K[abcd] = \frac{1}{\sqrt{2}} [S_{HH} + S_{VV}S_{HH} - S_{VV}S_{HV} + S_{VH}i(S_{HV} - S_{VH})]^T, \quad (2)$$

式中:  $H$  表示水平方向,  $V$  表示垂直方向;  $S_{VH}$  表示水平极化发射、垂直极化接收的回波强度。

### 2.1.2 Refined-Lee 滤波

Refined-Lee 滤波是一种简化了参数估计过程的简便滤波方法。采用 Refined-Lee 滤波方法对

SAR 影像的斑点噪声进行进一步处理, Refined-Lee 滤波器在滤除相干斑噪声的同时对溢油区域的边缘特征信息保持很好<sup>[18]</sup>。它首先探测出窗口的匀质区域和非匀质区域,并把来自同质区域的像素的功率值  $P_{span}$  ( $P_{span} = C_{11} + C_{22} + C_{33}$ ) 作为滤波系数  $k$  的统计量,最后对滤波窗口内的像素的功率进行估计,表达式为

$$\hat{C} = E(C) - k[E(C) - C], \quad (3)$$

式中:  $C$  为协方差矩阵;  $E$  为期望。

### 2.2 海上溢油样本集的构建

海上溢油样本集采用预处理后的多极化 SAR 影像数据进行构建,基于 Labelme 公开图像标注平台,采用目视解译的方法进行海上溢油区域标注。首先,手动对原始 SAR 影像溢油区域进行裁剪,并对裁剪后的影像进行标注,溢油区域像素值设置为 1,无油区域像素设置为 0;其次,通过旋转、翻转、平移等方式对标注影像进行扩充,最终将带有标签的样本集作为网络的输入。具体实现过程如下。

1) 对原始 SAR 影像进行 Pauli 分解和 Refined-Lee 滤波操作。

2) 基于预处理后的 SAR 影像,采用人工方式对原始的 4 幅极化 SAR 影像进行裁剪,其中每景影像选取 400 个样本,共 1600 个样本。数据集选取的 4 个区域分别是:每一幅影像中选取低噪声区域 100 个样本,高噪声区域 100 个样本,弱边界区域 100 个样本,强边界区域 100 个样本。

3) 为了提高模型训练的泛化性,对裁剪后的 SAR 影像进行翻转、平移等操作,得到 1600 个样本,将样本合并,一共得到 3200 个样本。

## 3 基于 FCN 的海上溢油智能检测框架

针对海上疑似溢油区域对检测精度的影响,提出基于 FCN 的 Pol-SAR 影像海上溢油智能检测框架。该框架首先对 Pol-SAR 影像进行预处理操作;其次,基于预处理后的 Pol-SAR 影像,构建并扩充海上溢油样本集;最后,采用改进的 FCN 方法实现端到端的海上溢油智能检测。框架如图 1 所示。

FCN 的产生使得像素级分类成为可能,解决了语义级别的图像分割问题<sup>[11]</sup>。同时,FCN 可以接受任意尺寸的输入图像,通过采用反卷积层对最后一个卷积层的 feature map 进行上采样,使它恢复到与输入图像相同的尺寸,从而可以对每个像素都产生



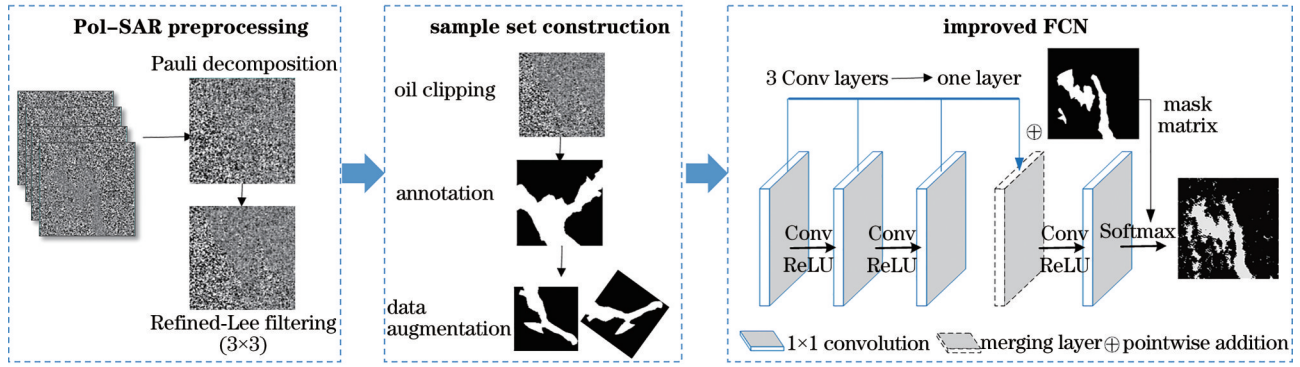


图 1 基于改进 FCN 的极化 SAR 影像智能检测框架

Fig. 1 Intelligent detection framework of Pol-SAR image based on improved FCN

一个预测。

然而,在 FCN 池化层的下采样期间,影像的空间精度会丢失,从而导致输出分辨率较低。为了补偿分辨率损失导致的空间信息丢失,通过将前三个卷积层融合为一层,将高层语义特征与浅层细节特征相融合,实现多级特征的表达。而后再次采用卷积层对其进行特征提取,并通过上采样操作将特征图转换到与输入影像同等大小,最后通过 Softmax 函数生成最终的溢油检测结果图。

在 FCN 模型中,仅使用了  $1 \times 1$  的卷积核,确保只在当前极化通道域内学习特征,并且特征图的大小与原始影像保持一致。卷积层的每个通道可以表示为

$$C^i = f\left[\sum_j (\omega^i X^j) + b^i\right], \quad (4)$$

式中:  $C^i$  表示第  $i$  个通道的卷积特性图;  $\omega^i$  是第  $i$  个卷积核;  $X^j$  是上一层的  $j$  通道;  $b^i$  是第  $i$  特征图的偏差项;  $f(X) = \max(0, X)$  表示线性单元函数。由于所有卷积核的核大小均为  $1 \times 1$ , 所以原来的二维卷积退化为点积。

特征的提取和表达是网络的核心,与浅层细节特征相比,高层语义特征更抽象、更健壮;同时,随着网络层次的加深,在卷积过程中也存在信息丢失的风险。为此,将前三个卷积层合并为一层,并在合并层中添加一个逐点加法,最后新增第四个卷积层。第四个卷积层的第  $i$  个通道可以计算为

$$C^i = f\left(\sum_j \omega_4^i \sum_{k=1}^3 C_k^j + b_4^i\right), \quad (5)$$

式中:  $C_k^j$  是第  $k$  个卷积层的第  $j$  通道;  $\omega_4^i$  和  $b_4^i$  是相应的权值和偏差项。

## 4 实验及结果分析

### 4.1 评价指标

采用两种评价指标对所提海上溢油智能检测框

架的性能进行定量分析与评价,即像素精度(PA)和类内像素平均精度(MA)。其中,PA 为被预测正确的像素占总像素的比例,MA 为计算每个类内被正确分类像素数的比例,之后求所有类的平均。假设共有  $N$  个类别(从 0 到  $K$  类中,包括一个空类或背景类),  $n_{ij}$  表示本属于类别  $i$  的像素被预测为类  $j$  的像素数量。即  $n_{ij}$  表示真正的数量,而  $n_{ii}$ 、 $n_{ji}$  表示假正和假负的数量。  $t_i = \sum_j n_{ij}$  表示类别为  $i$  的像素总和。

像素精度的表达式为

$$P_{PA} = \frac{\sum_i n_{ii}}{\sum_i t_i}. \quad (6)$$

平均像素精度的表达式为

$$P_{MA} = \frac{1}{N} \sum_i \frac{n_{ii}}{t_i}. \quad (7)$$

### 4.2 实验结果与分析

#### 4.2.1 Pol-SAR 影像预处理前后溢油检测精度比较分析

极化方式对雷达波束响应的影响较大<sup>[19]</sup>,一般情况下,交叉极化(HV 和 VH)的回波强度比同极化(HH 和 VV)低很多,并且同极化油膜识别度较高<sup>[20]</sup>。为了分析不同极化方式对海上溢油检测精度的影响,分别对 VV、HH、HV、VH 四种极化方式的原始 SAR 影像进行溢油检测,得到的结果如图 2 所示。很显然,图 2(a)和图 2(b)的溢油检测效果明显优于图 2(c)和图 2(d),即同向极化 VV、HH 溢油检测精度明显优于异向极化 VH 和 HV。海面 VV 和 HH 极化通道后向散射能量最强,更加适合于海上溢油检测研究。

为了验证 Pol-SAR 影像预处理操作的有效性,与未经预处理的 Pol-SAR 影像进行对比实验。其中,Refined-Lee 滤波窗口大小的选择将对检测精度产生显著影响,为了选择合适的窗口大小,滑动窗




图 2 不同极化方式下溢油区域检测对比

Fig. 2 Comparison of oil spill area detection under different polarization modes

口分别设置为 $3 \times 3$ 、 $5 \times 5$ 和 $7 \times 7$ ,实验结果如表 2 所示。

由表 2 可以看出,Pauli 分解联合 Refined-Lee 滤波预处理操作后的 Pol-SAR 影像溢油检测精度得到了显著的提升。VV 极化方式下的溢油检测最优,相对于原始影像,PA 和 MA 分别提升了 1.7 个百分点和 2.6 个百分点,HH 极化方式下溢油检测 MA 提升 4.3 个百分点,但 PA 提升了 2.2 个百分点,验证了所提 Pol-SAR 影像预处理方法对海上溢油检测精度提升效果显著。

表 2 Pol-SAR 影像预处理后溢油检测结果对比

Table 2 Detection result comparison of oil spill after Pol-SAR image preprocessing

Polarization	Index	Original image	Pauli decomposition	Pauli decomposition + Refined-Lee ( $3 \times 3$ )	Pauli decomposition + Refined-Lee ( $5 \times 5$ )	Pauli decomposition + Refined-Lee ( $7 \times 7$ )
VV	PA	0.917	0.927	0.934	0.921	0.920
	MA	0.896	0.901	0.922	0.916	0.913
HH	PA	0.905	0.916	0.927	0.923	0.919
	MA	0.868	0.905	0.911	0.906	0.898

由上述实验结果可知:HV 极化方式与 VV 极化方式融合情况下,MA 最优,达 0.931;PA 最好的是 VH-VV 和 HH-VV 的组合,为 0.951 和 0.952。由于同向极化与异向极化成像差异明显,VV 极化明显比 VH 极化回波强度高,并且油膜识别度较高;相反,异向极化 HV,VH 方式回波强度弱,对油膜识别度低<sup>[21]</sup>。所以 HV 极化与 VH 极化方式融合情况下,溢油区域检测精度出现显著降低,如图 3(d)所示。而 HH 极化与 VH 极化融合以及 HV 极化与

为了验证全极化方式下溢油检测效果的有效性,在原有实验的基础上,从测试集中选取具有代表性的 4 个区域,分别为(a)低噪声区域、(b)高噪声区域、(c)弱边界区域和(d)强边界区域,记录对应的全极化溢油检测结果,记录结果如表 5 所示。

由实验可以看出,全极化方式下的溢油检测精度

#### 4.2.2 多极化融合 SAR 影像溢油检测精度比较分析

此外,基于不同极化信息间存在信息的互斥或协作,对四种极化方式 SAR 影像进行不同融合,得到 6 种两种极化融合方式,4 种三种极化融合方式,1 种全极化融合方式。分别在最优预处理以及网络超参设置条件下进行实验对比分析,得到如图 3 所示的溢油区域检测结果图,其中溢油区域检测精度信息如表 3 所示。

VV 极化融合情况下,溢油检测 PA 与 MA 均表现出明显的提升,同时其他极化融合方式下 MA 相对于单一极化方式都有一定的提升。

图 4(a)~(d)为三种极化方式融合的溢油检测结果图,图 4(e)为全极化下的溢油检测结果图,对应的检测精度如表 4 所示。其中,最优精度是全极化融合方式,PA 可达 0.957,MA 可达 0.930,实验结果进一步验证了 SAR 影像极化特征对海上溢油检测的有效性。

效果显著,在低噪声及强边界区域的检测效果最佳。

#### 4.2.3 不同深度学习模型溢油检测精度比较分析

为验证所提改进的 FCN 方法对 Pol-SAR 溢油检测的有效性,分别与 FCN 和 UNet 深度学习模型进行实验对比。按照 9:1 把 3200 样本数据集分成训练集和测试集。训练过程每次读入 1 张图片,训




图 3 两种极化融合 SAR 溢油检测结果比较。(a) HH-VV; (b) HH-HV; (c) HH-VH; (d) HV-VH; (e) HV-VV; (f) VH-VV

Fig. 3 Comparison of oil spill detections of two polarimetric fusion SAR images. (a) HH-VV; (b) HH-HV; (c) HH-VH; (d) HV-VH; (e) HV-VV; (f) VH-VV

表 3 两种极化融合 SAR 的溢油检测精度比较

Table 3 Comparison of oil spill detection accuracy of two polarimetric fusion SAR images

Index	HH-VV	HH-HV	HH-VH	HV-VH	HV-VV	VH-VV
PA	0.952	0.939	0.942	0.505	0.922	0.951
MA	0.927	0.893	0.916	0.516	0.931	0.917




图 4 三种极化融合及全极化溢油结果图。(a) HH-HV-VH; (b) HH-HV-VV; (c) HH-VH-VV; (d) HV-VH-VV; (e) HH-VV-HV-VH

Fig. 4 Oil spill results of three-polarimetric fusion and full-polarimetric fusion. (a) HH-HV-VH; (b) HH-HV-VV; (c) HH-VH-VV; (d) HV-VH-VV; (e) HH-VV-HV-VH

表 4 三种极化融合及全极化溢油检测精度比较

Table 4 Comparison of oil spill detection accuracy of three-polarimetric fusion and full-polarimetric fusion

Index	HH-HV-VH	HH-HV-VV	HH-VH-VV	HV-VH-VV	HH-VV-HV-VH
PA	0.942	0.913	0.945	0.949	0.957
MA	0.906	0.922	0.919	0.890	0.930

表 5 不同区域全极化溢油检测精度

Table 5 Accuracy of fully polarized oil spill detection in different regions

Index	(a)	(b)	(c)	(d)
PA	0.953	0.947	0.941	0.950
MA	0.926	0.922	0.914	0.921

训练次数 epoch 定为 100, 采用的是固定学习率 0.001, 得到的溢油区域检测结果如图 5 所示。

图 5(a)~(e) 分别为四个不同区域的原始 Pol-SAR 影像、标注后的溢油区域、FCN 的溢油区域检测结果、UNet 的溢油区域检测结果、所提改进 FCN 的溢油区域检测结果。通过表 6 溢油区域检测精度



结果可以看出,所提方法的精度相对于传统的 FCN 均有一定程度的提高,检测精度提升了 8.7 个百分

表 6 不同区域溢油检测精度

Table 6 Oil spill detection accuracy in different regions

Area	Evaluation index	FCN	UNet	Improved FCN
Area 1	PA	0.891	0.913	0.948
	MA	0.834	0.865	0.927
Area 2	PA	0.866	0.905	0.953
	MA	0.852	0.885	0.934
Area 3	PA	0.884	0.916	0.941
	MA	0.835	0.898	0.935
Area 4	PA	0.863	0.927	0.936
	MA	0.815	0.905	0.911

点,并且三种方法中改进的 FCN 溢油区域检测精度最优。

## 5 结 论

利用全极化 SAR 影像,针对海上生物油膜、低风区及影像本身显著的相干斑噪声等疑似溢油区域导致的检测精度低的问题,提出一种基于改进 FCN 的极化 SAR 影像海上溢油智能检测方法。首先对原始溢油 SAR 影像进行 Pauli 分解,并通过

Refined-Lee 滤波对溢油 SAR 影像进行降噪处理,在此基础上,基于 FCN 模型提出不同层级卷积层融合策略,实现高层语义特征与低层空间细节特征融合,提高海上溢油的检测精度。通过实验结果对比分析,预处理后极化 SAR 影像的溢油区域检测精度都有一定程度的提升。此外,通过对不同极化方式融合的 SAR 影像检测结果进行对比分析,得出同向极化与异向极化成像差异明显,VV 极化回波强度明显比 VH 极化回波强度高,并且油膜识别度较高。与其他极化融合方式相比,全极化溢油区域检测精度最好,PA 和 MA 分别可达 0.957 和 0.930。相比传统 FCN 和 UNet 深度学习模型,实验结果表明,所提方法的溢油检测结果表现出显著的优势。

FCN 是有监督的预训练模型,网络的训练和更新依赖大量的标记图像,在数据标记过程中需要消耗大量的人力,并且容易受到主观因素的影响。因此,将来的工作应转向弱监督或者无监督的训练过程,以便提高算法应用的便利性。




图 5 不同方法溢油区域检测结果。(a)原始图像;(b)标注后的图像;(c) FCN; (d) UNet; (e)改进的 FCN

Fig. 5 Results of oil spill area detected by different methods. (a) Original imgs; (b) labeled imgs; (c) FCN; (d) UNet; (e) Improved FCN

## 参 考 文 献

- [1] Adams S M. Assessing cause and effect of multiple stressors on marine systems[J]. *Marine Pollution Bulletin*, 2005, 51: 649-657.
- [2] Gill D A, Picou J S, Ritchie L A. The Exxon Valdez and BP oil spills[J]. *American Behavioral Scientist*, 2012, 56(1): 3-23.
- [3] Xie G Q. Oil spill detection based on the compact polarimetric SAR[D]. Wuhan: China University of Geosciences, 2018.  
谢广奇. 基于简缩极化 SAR 的海洋溢油检测[D]. 武汉: 中国地质大学, 2018.
- [4] Alpers W, Hühnerfuss H. Radar signatures of oil films floating on the sea surface and the Marangoni effect[J]. *Journal of Geophysical Research Atmospheres*, 1988, 93(C4): 3642-3648.
- [5] Bern T I, Wahl T, Andersen T, et al. Oil spill detection using satellite based SAR-experience from a field experiment[J]. *Photogrammetric Engineering & Remote Sensing*, 1993, 59, 3(3): 423-428.
- [6] Kanaa T F N, Tonye E, Mercier G, et al. Detection of oil slick signatures in SAR images by fusion of hysteresis thresholding responses[C]//2003 IEEE International Geoscience and Remote Sensing Symposium, July 21-25, 2003, Toulouse, France. New York: IEEE Press, 2003: 2750-2752.
- [7] Solberg A H S, Brekke C, Husoy P O. Oil spill detection in radarsat and envisat SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2007, 45(3): 746-755.
- [8] Kim D, Jung H S. Mapping oil spills from dual-polarized SAR images using an artificial neural network: application to oil spill in the Kerch strait in November 2007[J]. *Sensors*, 2018, 18(7): 2237.
- [9] Migliaccio M, Nunziata F, Montuori A, et al. A multifrequency polarimetric SAR processing chain to observe oil fields in the gulf of Mexico[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 49(12): 4729-4737.
- [10] Song D M, Ding Y X, Li X F, et al. Ocean oil spill classification with RADARSAT-2 SAR based on an optimized wavelet neural network[J]. *Remote Sensing*, 2017, 9(8): 799.
- [11] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 39(4): 640-651.
- [12] Wang Y, He C, Liu X L, et al. A hierarchical fully convolutional network integrated with sparse and low-rank subspace representations for PolSAR imagery classification[J]. *Remote Sensing*, 2018, 10(2): 342.
- [13] Li Y Y, Chen Y Q, Liu G Y, et al. A novel deep fully convolutional network for PolSAR image classification[J]. *Remote Sensing*, 2018, 10(12): 1984.
- [14] Lu X W, Liu H, Shang Z H. NVST image denoising based on self-supervised deep learning[J]. *Laser & Optoelectronics Progress*, 2021, 58(6): 0610018.  
陆县委, 刘辉, 尚振宏. 基于自监督深度学习的 NVST 图像去噪[J]. *激光与光电子学进展*, 2021, 58(6): 0610018.
- [15] Tian S, Ren Y F, Shao X Y, et al. Multi-focus image fusion with filter operator and double scale decomposition[J]. *Laser & Optoelectronics Progress*, 2021, 58(6): 0610010.  
田帅, 任亚飞, 邵馨叶, 等. 结合滤波算子与双尺度分解的多聚焦图像融合[J]. *激光与光电子学进展*, 2021, 58(6): 0610010.
- [16] Shao J T, Du C Q, Zou B. Lidar ground segmentation method based on point cloud cluster combination feature[J]. *Laser & Optoelectronics Progress*, 2021, 58(4): 0428001.  
邵靖滔, 杜常清, 邹斌. 基于点云簇组合特征的激光雷达地面分割方法[J]. *激光与光电子学进展*, 2021, 58(4): 0428001.
- [17] Henry C, Azimi S M, Merkle N. Road segmentation in SAR satellite images with deep fully convolutional neural networks[J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 15(12): 1867-1871.
- [18] Yommy A S, Liu R K, Wu A S. SAR image despeckling using refined lee filter[C]//2015 7th International Conference on Intelligent Human-Machine Systems and Cybernetics, August 26-27, 2015, Hangzhou, China. New York: IEEE Press, 2015: 260-265.
- [19] Choe B H, Kim D J, Hwang J H, et al. Detection of oyster habitat in tidal flats using multi-frequency polarimetric SAR data[J]. *Estuarine, Coastal and Shelf Science*, 2012, 97: 28-37.
- [20] Shu Y M, Li J, Yousif H, et al. Dark-spot detection from SAR intensity imagery with spatial density thresholding for oil-spill monitoring[J]. *Remote Sensing of Environment*, 2010, 114(9): 2026-2035.
- [21] Fu H T, Qin P. Comparison of sea surface oil film identification in different polarization-based GF-3 SAR images: a case study of the "Sangji" accident[J]. *Ocean Development and Management*, 2019, 36