**文章编号:**1000-8608(2022)04-0419-08

# 海面溢油图像特征识别双边分割算法研究

杜红彪<sup>1</sup>,于伟<sup>2</sup>,张 旭<sup>2</sup>,陈余庆<sup>\*2</sup>

(1.中国船舶重工集团公司第七一九研究所,湖北 武汉 430064;2.大连海事大学 船舶电气工程学院,辽宁 大连 116026)

摘要:重大海上溢油事故频发对海洋自然环境构成了巨大威胁.针对海面溢油图像的传统 特征识别方法智能性、准确性不足等问题,探索了一种新型深度学习语义分割智能算法.首先 分析了双边分割网络 BiSeNetV2 基本结构和功能模块单元.为了进一步降低现有网络参数 复杂度,对其语义分支 GE 层进行了改进设计,提升了网络的轻量性.进而在 BiSeNetV2 的两 个分支中引入双重注意力模块来解决类间相似性问题,增强了溢油图像特征识别的准确性. 通过实验比较分析,验证了改进后的轻量型双边分割网络针对海面溢油图像特征识别准确率 可达 91.9%.

关键词:溢油;图像识别;双边分割;双重注意力模块 中图分类号:U695;U169 文献标识码:A doi:10.7511/dllgxb202204011

#### 0 引 言

近年来,世界各国对能源的需求迅速增长,其 中石油需求量的增加带动了石油的海洋开采和海 上运输.船舶运输原油过程中发生碰撞或海上石 油开采平台因意外发生爆炸都会造成原油泄漏, 造成巨大的经济损失,并破坏海洋生态环境.因碰 撞沉入海底的巴拿马籍油轮中的 13×10<sup>4</sup> t 凝析 油造成了约 1 053 km<sup>2</sup> 的海洋污染<sup>[1]</sup>.墨西哥湾 某深水钻井平台发生的严重漏油事故<sup>[2]</sup>,对自然 环境造成了极大危害.溢油会对渔牧业、自然环境 和沿海居民健康等造成不同程度的危害<sup>[3]</sup>.因此, 海面溢油检测对保护海洋环境具有重要意义.

海面溢油事故通常具有突发性,迫切需要提 升海面溢油图像识别的智能性与准确性.溢油检 测技术按检测原理划分,主要包括雷达激光检测 和视觉图像检测. Miegebielle 等<sup>[4]</sup>通过遥感雷达 图像实现了溢油 UNet 网络检测分析,但是仍然 存在较多类似油污目标的误检测现象. Zia 等<sup>[5]</sup>借 助高光谱图像,建立了具有残差结构的 9 层卷积 神经网络,通过多尺度卷积的方法提取溢油特征, 并利用实验对识别出的结果做出相应的验证,验 证表明该模型与当时的 LeNet-5 等模型相比精度 较高. Song 等<sup>[6]</sup>构建了一个适用于 PolSAR 溢油 检测的深层卷积神经网络,通过替换分类器,提升 了网络的识别能力,有效降低了海杂波或生物油 膜引起的误报率,显著提高了溢油检测的准确性. 陈彦彤等<sup>[7]</sup>提出了深度语义分割(DSS)模型,对 多源遥感海上溢油图像进行检测,取得了较好的 成果.

本文在结合国内外研究成果的基础上,提出 一种改进的海面溢油图像特征识别智能算法.基 于 Ghost-Bottleneck 模块结构<sup>[8]</sup>,提出一种兼顾 检测精度与效率的 Ghost-GE 层(ghost gatherand-expansion layer)结构.同时针对高分辨率图 像中溢油特征的漏检现象,把位置注意力模块 (position attention module,PAM)<sup>[9]</sup>与本文提出 的上下文与通道注意力模块(context and channel attention module,CCAM)分别引入检测网络细 节分支和语义分支中,使得检测精度进一步提升.

收稿日期: 2022-01-26; 修回日期: 2022-05-24.

基金项目:国家自然科学基金青年基金资助项目(61203082);大连海事大学研究生教育教学改革研究项目(YJG2020604).

**作者简介:**杜红彪(1987-),男,工程师,E-mail:dmuwork@163.com;于 伟(1996-),男,硕士生;张 旭(1981-),男,博士,讲师; 陈余庆\*(1979-),男,博士,教授,硕士生导师,E-mail:chen@dlmu.edu.cn.

#### 1 双边分割算法

本文主要应用语义分割算法进行海面溢油检测,所以对检测的实时性要求比较高,现阶段主要 通过裁剪输入特征图、减少网络通道数和应用更 紧凑的框架的方式来提高网络的检测速度.这3 种方法都是折中精度以求速度,同时都存在着一 定的缺陷,难以付诸实践.而双边分割算法网络结 构的设计将空间信息和上下文信息分为两个路径 进行提取,既可以保障较高的精度又可以保证实 时性.

#### 1.1 BiSeNetV2 基本结构

BiSeNetV2有两条网络分支:细节分支和语 义分支<sup>[10]</sup>.其中细节分支由宽通道卷积层组成, 语义分支由 Stem 模块、聚集扩展层(gather-andexpansion layer, GE 层)和上下文嵌入模块 (context embedding block, CE 模块)组成.

#### 1.2 Ghost-GE 层设计

GE 层为语义分支中的重要结构之一,它是 由 MobileNetV2 的倒瓶颈残差结构进行改进得 到的,GE 层中采用了深度可分离卷积,这样能够 使得模型更加轻量化.此外,在目标检测精度方 面,考虑到 GhostNet 主干网络一般会优于多数 轻量型主干网络的性能,为了在模型轻量化的同 时进一步提升现有网络的准确性,本文基于 GhostNet 的 Ghost-Bottleneck 模块结构进一步 改进语义分支初始 GE 层,并称为 Ghost-GE 层, 其结构如图1所示.图1中H表示输入特征图高 度,W表示输入特征图宽度,C、C,C。表示输入特 征图不同的通道数,BN(batch normalization)表 示归一化操作,ReLU(rectified linear unit)表示 激活函数, GhostConv(ghost convolution)表示 Ghost 卷积, DWConv(depth-wise convolution) 表示深度可分离卷积.

图 2 为 BiSeNetV2 与 Ghost-BiSeNetV2 溢 油检测效果对比.图 2(a)为测试图,图 2(b)为人 工标注标签.图 2(c)为 BiSeNetV2 溢油检测效果 图,BiSeNetV2 的语义分支应用了 GE 层,虽然能 够检测出油污区域,但同时也出现了许多误检测 现象,将水中物体误检测为油污.图 2(d)为 Ghost-BiSeNetV2 溢油检测效果图,从图中可以 看出 Ghost-BiSeNetV2 油污检测能够有效改善







(a) 测试图

(b) GT



(c) BiSeNetV2

(d) Ghost-BiSeNetV2

- 图 2 BiSeNetV2 与 Ghost-BiSeNetV2 溢油 检测效果对比
- Fig. 2 The effect comparison of oil spill detection of BiSeNetV2 and Ghost-BiSeNetV2

#### 原网络中存在的误检测现象.

本文在语义分支中采用了 Ghost-GE 层设

计,对应双边分割网络称为 Ghost-BiSeNetV2.其 中第一个 GhostConv 作为扩展层,用于增加通道 数,第二个 GhostConv 作为收缩层,用于减少通 道数,当 Ghost-GE 层采用图 1(b)结构时,需要在 主路径和残差连接路径分别增加步长为 2 的可分 离卷积对其进行下采样操作. SE(squeeze and excite)模块也运用于 Ghost-GE 层.

#### 1.3 分支模块功能

BiSeNetV2 的语义分支起始阶段应用了 Stem 模块进行快速下采样. Stem 模块使用两种 不同的下采样方式来缩小特征表示. 其中一种方 式是通过步长为 2 的卷积来进行下采样,第二种 方式是通过池化来进行下采样,但是卷积下采样 跟池化下采样有很大区别. 池化操作可以起到平 移不变性,但可能会将有用的信息滤掉. 卷积下采 样可以降维,也可以提取一些特征,这样提取到的 输出特征图与输入特征图像素一样. 同时使用上 述两种方式进行下采样,既可以保留部分原始图 像信息,又可以提取语义特征,并且具有有效的特 征表达能力.

在语义分支的最后阶段应用 CE 模块. 该模 块使用了全局平均池化和残差连接. 其中全局平 均池化可以减少参数量和计算量,并且起到扩大 感受野来捕捉高级语义的作用.

由于细节分支输出特征图提取的是低级特征,语义分支输出特征图提取的是高级特征,两个 通道输出的特征图大小和提取的特征级别不同, 所以不能简单地将两个通道相加,BiSeNetV2 应 用了双边聚合层(bilateral guided aggregation layer, BGA层)来融合两条分支的特征.

#### 2 双重注意力机制网络

由于海面油污目标的外形、颜色等特征多变 且不固定,存在明显的类内相异性问题,尤其当场 景比较复杂时,会导致模型出现严重的预测错误. 类内相异性问题发生的主要原因是缺少上下文依 赖信息,尤其是包含强大语义信息的高阶上下文 信息. 文献 [11] 使用分解结构增大卷积核尺寸或 在网络顶部引入有效的编码层,来捕获更丰富的 全局信息. 文献「12]通过编码器-解码器结构来融 合中级和高级语义特征,在两种方法中,虽然上下 文融合有助于捕获不同比例的对象,但却无法利 用全局视图中对象之间的关系. 文献 [13] 使用循 环神经网络(recurrent neural network, RNN)隐 含地捕捉全局关系,但其有效性过于依赖长期记 忆的学习结果.为了解决上述问题,本文在细节分 支和语义分支上分别引入位置注意力模块和改进 后的上下文与通道注意力模块.

引入位置注意力模块能够有效捕获特征图中 任意两个位置之间像素点的空间依赖性,并通过 加权求和对所有位置的特征进行聚合更新.如图 3 所示为位置注意力模块结构示意图.在图 3 中, reshape 表示特征矩阵整型操作,其中 N 为H×W, transpose 表示特征矩阵转置操作,Softmax 表示 激活函数,A 表示输入特征图,E 表示输出特征 图,B、C、D、S 表示模块中不同形式特征图.



图 3 位置注意力模块结构示意图

Fig. 3 The structure diagram of position attention module

为了更好地获得上下文信息,本文将原始 CE 模块与通道注意力模块进行融合,将融合后的模

块称为上下文与通道注意力模块(CCAM),CCAM 结构示意图如图 4 所示.在图 4 中 GAPooling



图 4 CCAM 结构示意图

Fig. 4 The structure diagram of CCAM

(global average pooling)表示全局平均池化,X表示模块中不同形式特征图.

本文将 BiSeNetV2 语义分支中的 GE 层替 换成 Ghost-GE 层,同时在细节分支和语义分支 中增加双重注意力模块,优化后的网络称为 Ghost-DABiSeNetV2,网络结构如图 5 所示.在 图 5 中 Loss 表示损失函数.

为了验证每个注意力机制的重要性,本文进行 了一系列剥离实验,分别对两条分支上增加注意力 模块前后的网络特征图进行了可视化对比分析.



图 5 Ghost-DABiSeNetV2 结构示意图 Fig. 5 The structure diagram of Ghost-DABiSeNetV2

图 6 为增加双重注意力模块前后检测效果对 比.图 6(a)为测试图.图 6(f)为人工标注标签.图 6(b)为细节分支未加 PAM 时特征图,网络特征 图中丢失了大量的空间细节特征,这样会影响网 络的检测准确率.图 6(d)为细节分支增加 PAM 后特征图,油污的大体轮廓信息更加完整,同时也 进一步提升了对油污位置信息提取的准确性.图 6(c)为语义分支未加 CCAM 时输出的特征图,从 图中可以看出溢油目标区域像素点与周围非油污 区域像素点区别较为模糊,这样会影响网络最终 的检测精度.图 6(e)为语义分支增加 CCAM 后 特征图,油污区域像素点分类效果取得了大幅提



图 6 增加双重注意力模块前后检测效果对比

Fig. 6 The detection effect comparison before and after adding the dual attention module

升,从而减少了误分类现象.最后,分别在语义分 支和细节分支上增加 CCAM 和 PAM.从图 6(g) 中可 以看 出未 加 双 重 注 意 力 模 块 的 Ghost-BiSeNetV2 存在误检测现象.图 6(h)为增加双重 注意力模块后的 Ghost-BiSeNetV2 检测效果图, 加入双重注意力模块很明显减少了误检测现象.

CCAM 与 CBAM (convolutional block attention module)<sup>[14]</sup>有一定的相似性. 但是在溢油检测过程中,由于海面油污目标的外形、颜色等特征多变且不固定,并且存在明显的类内相异性问题,采用 CBAM 会缺少上下文依赖信息,导致预测错误. 而 CCAM 可以更好地捕捉全局上下文中对象的关系,获取上下文信息,从而形成全局上下文视图,使得相似的语义特征实现相互增益.

#### 3 实验测试验证与结果分析

本文通过岸基平台搭载海康威视 DS-2TD6566T-50H2LX/V2 云台摄像机和无人机大 疆经纬 M600 Pro 搭载禅思 XT2 相机进行图像 数据采集,获取了不同视角和不同距离下的大量 溢油检测实验数据.主要采集的溢油种类有原油、 汽油、柴油和废机油等.可见光数据集包括训练集 图像 8 324 幅,验证集图像 872 幅,测试集图像 832 幅.其中岸基平台摄像机采集数据的分辨率 为1 280×720,无人机搭载相机采集数据的分辨 率为1 920×1 080.由于该数据集包含了多平台、 多视角拍摄的多种类油污信息,具有较强的泛化 能力.

#### 3.1 网络训练参数

优化后的 BiSeNetV2 进行训练时,首先需要 确定训练所需的参数值.如表 1 所示为训练时参 数值的设定.

BiSeNetV2应用 Online hand example mining cross-entropy loss (OhemCELoss)损失函数,在 训练过程中可以关注困难样本,对其施加更高权 重的一种训练策略.首先对样本求取交叉熵损失函 数如式(1)所示,筛选出损失最大的样本,然后将筛 选得到的这些样本应用在随机梯度下降中训练.

$$L = -\left(\sum_{i=1}^{N} y^{(i)} \lg \hat{y}^{(i)} + (1 - y^{(i)}) \lg (1 - \hat{y}^{(i)})\right)$$

(1)

Tab.1 Th	e training parameter settings
项目	参数
优化器	SGD
动量	0.9
衰减率	0.000 5
学习率	0.05
损失函数	OhemCELoss
训练批次	100 000

 $720 \times 960$ 

训练参数设定

表 1

输入分辨率

式中: $y^{(i)}$ 代表真实值, $\hat{y}^{(i)}$ 代表预测值,N代表类 别数.在双边分割网络中应用了 1 个主损失函数 和 4 个辅助损失函数,如式(2)所示.其中  $l_p$  表示 主损失, $l_i$  表示辅助损失, $\alpha$  表示损失函数的权 重.

$$L(\hat{y}^{(i)}; y^{(i)}) = l_{p}(\hat{y}^{(i)}; y^{(i)}) + \alpha \sum_{i=1}^{4} l_{i}(\hat{y}^{(i)}; y^{(i)})$$
(2)

#### 3.2 Ghost-DABiSeNetV2 内部模块细节操作

Ghost-DABiSeNetV2 整体结构主要分为细 节分支和语义分支.将两条分支分为几个阶段进 行分析研究,每个阶段中集成了多个模块操作,其 中 Ghost-DABiSeNetV2 中各阶段内部模块细节 操作如表 2 所示.其中 k 表示卷积核大小,c 表示 通道数,e 表示扩展因子,s 表示卷积操作步长,r 表示该层操作重复次数.

#### 3.3 结果与分析

本节的网络训练和性能评估实验均在同一平 台下进行,训练迭代步数为 500,网络输入特征图 大小统一为 480×480.对不同网络的均交并比 (MIoU)即准确性指标、参数量(parameter)、计算 量(FLOPs)进行对比.表 3 为几类语义分割网络 检测的准确性和实时性对比结果.

基于控制变量的思想,首先对以 GhostNet 为主干网络的 BiSeNetV1 和 BiSeNetV2 进行性 能参数对比,然后将 BiSeNetV2 和改进后的 BiSeNetV2(包括 Ghost-BiSeNetV2 和 Ghost-DABiSeNetV2)进行性能参数对比.其网络训练 输入特征图大小为 720×960,网络的检测速度性 能指标 FPS 的测试视频帧分辨率为 1 280×720. 本文对可见光图像进行了对比实验,性能见表 4. 表 2 Ghost-DABiSeNetV2 内部模块细节操作

Tab. 2 The detailed operation of the module in Ghost-DABiSeNetV2

阶段	细节分支				语义分支								
	操作	k	С	\$	r	操作	k	С	е	\$	r	SE	尺寸
输入													720×960
第一阶段	Conv2d	3	64	2	1	Stem	3	16	_	4	1		360×480
	Conv2d	3	64	2	1								360×480
第二阶段	Conv2d	3	64	2	1								$180 \times 240$
	Conv2d	3	64	1	2								$180 \times 240$
第三阶段	Conv2d	3	128	2	1	Ghost-GE	3	32	6	2	1	1	90×120
	Conv2d	3	128	1	2	Ghost-GE	3	32	6	1	1	_	$90 \times 120$
	PAM												90×120
第四阶段						Ghost-GE	3	64	6	2	1	_	45×60
						Ghost-GE	3	64	6	1	1	1	45×60
第五阶段						Ghost-GE	3	128	6	2	1	1	23×30
						Ghost-GE	3	128	6	1	3	_	23×30
						CCAM							23×30

表 3 语义分割网络性能对比

Tab. 3 The semantic segmentation network performance comparison

方法	主干网络	均交 并比/%	参数量/106	计算量/10 <sup>9</sup>
PSPNet	ResNet50	79.6	48.76	162.11
ENet	—	77.6	0.35	1.69
LedNet	_	78.2	2.31	5.52
BiSeNet	ResNet50	87.6	27.98	23.14

- 表 4 网络改进前后在可见光图像上的性能对比
  - Tab. 4 The performance comparison of the network on the visible light image with and without the improvement

网络	主干网络	均交 并比/%	参数量/ 10 <sup>6</sup>	FPS
BiSeNetV1	GhostNet	86.6	8.55	19.45
BiSeNetV2	GhostNet	87.3	9.44	17.17
BiSeNetV2	—	87.8	3.65	26.64
Ghost-BiSeNetV2	—	88.9	3.11	26.25
Ghost-DABiSeNetV2	—	91.9	3.76	23.19

Ghost-DABiSeNetV2 在可见光图像上的检测性能指标均优于其他 4 个网络. 将改进前后的BiSeNetV2 分别在可见光图像上进行溢油检测可视化实验,结果如图 7 所示.

在各列图像中,图7(a)为测试图,图7(b)为 人工标注标签,图7(c)为BiSeNetV2溢油检测效 果图,图7(d)为Ghost-BiSeNetV2溢油检测效果 图,图7(e)为Ghost-DABiSeNetV2溢油检测效 果图.在第一行检测结果中,网络优化前存在误检 测现象,在此基础上,通过在网络的双分支上引入 双重注意力模块后,能够完全消除水中目标误检 测现象(如绿色框选区域所示). 而在第二行检测 结果中,优化前后的网络对远处薄油膜区域均出 现了不同程度的漏检测现象,该种现象不能通过 优化网络结构来解决(如黄色框选区域所示).第 三行中 BiSeNetV2 对近距离的油污区域出现漏 检测现象,第四行对于高分辨率油污检测图像进 行溢油检测时,局部薄油膜区域均出现了一定程 度的漏检现象(如绿色框选区域). 通过增加双重 注意力模块可以提升高分辨图像下溢油检测精 度,有效抑制近距离低对比度溢油区域的漏检测 现象.





Fig. 7 The detection effect diagram on the visible light image before and after network optimization

#### 4 结 语

本文提出了一种新的轻量型双边分割网络, 用于检测海面溢油.该网络基于无人机和配备光 学摄像机的岸基平台,通过从多个平台收集数据, 组合成高质量的可见光数据集.将 BiSeNetV2 网 络中的 GE 层替换为 Ghost-GE 层,其中改进后 的 Ghost-GE 层能够使模型的精度和速度均得到 提升.最后针对高分辨率图像漏检测和误检测现 象,本文将 PAM 和改进的 CCAM 分别加入 BiSeNetV2 的细节分支和语义分支中.改进后的 检测网络在保证实时性的前提下,使得检测精度 大幅提升.

### 参考文献:

- [1] 张 果. 近距离海面溢油监测系统的设计与实现[D]. 西安:西安电子科技大学,2018.
  ZHANG Guo. Design and implementation of close-range sea surface spill oil monitoring system [D].
  Xi'an: Xidian University, 2018. (in Chinese)
- [2] DALY K L, REMSEN A, OUTRAM D M, et al. Resilience of the zooplankton community in the northeast Gulf of Mexico during and after the Deepwater Horizon oil spill [J]. Marine Pollution Bulletin, 2021, 163: 111882.

- [3] 柳婷婷,田珊珊.海上溢油事故处理及未来发展趋势[J].中国水运,2006,4(11):27-29.
  LIU Tingting, TIAN Shanshan. Management with leaking oil on the sea and its future development trend [J]. China Water Transport, 2006, 4(11):27-29. (in Chinese)
- [4] MIEGEBIELLE V, CONCHE B, HUANG Zhexuan, et al. Use of remote sensing radar images for offshore oil slick detection in oil and gas domain; Manual and automatic interpretation [C]// 2019 IEEE International Geoscience and Remote Sensing Symposium, IGARSS 2019 — Proceedings. Piscataway: IEEE, 2019; 5871-5874.
- [5] ZIA T, ABBAS A, HABIB U, et al. Learning deep hierarchical and temporal recurrent neural networks with residual learning [J]. Machine Learning and Cybernetics, 2020, 11(4): 873-882.
- [6] SONG Dongmei, ZHEN Zongjin, WANG Bin, et al. A novel marine oil spillage identification scheme based on convolution neural network feature extraction from fully polarimetric SAR imagery [J]. IEEE Access, 2020, 8(1): 59801-59820.
- [7] 陈彦彤,李雨阳,吕石立,等.基于深度语义分割的多源遥感图像海面溢油监测[J].光学精密工程,2020,28(5):1165-1176.
  CHEN Yantong, LI Yuyang, LÜ Shili, et al.

Research on oil spill monitoring of multi-source remote sensing image based on deep semantic segmentation [J]. **Optics and Precision Engineering**, 2020, **28**(5): 1165-1176. (in Chinese)

- [8] HAN Kai, WANG Yunhe, TIAN Qi, et al. GhostNet: More features from cheap operations [J]. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2020(2020); 1577-1586.
- [9] FU Jun, LIU Jing, TIAN Haijie, et al. Dual attention network for scene segmentation [C]// Proceedings 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition, CVPR 2019. Washington D C: IEEE Computer Society, 2019: 3141-3149.
- [10] YU Changqian, GAO Changxin, WANG Jingbo, et al. BiSeNetV2: Bilateral network with guided aggregation for real-time semantic segmentation [J]. International Journal of Computer Vision, 2021, 129: 3051-3068.
- [11] PENG Chao, ZHANG Xiangyu, YU Gang, et al. Large kernel matters - improve semantic

segmentation by global convolutional network [C]// Proceedings — 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017. Piscataway: IEEE, 2017: 1743-1751.

- [12] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C]// Computer Vision — ECCV 2018 — 15th European Conference, 2018, Proceedings. Munich: Springer Verlag, 2018: 833-851.
- [13] BYEON W, BREUEL T M, RAUE F, et al. Scene labeling with LSTM recurrent neural networks [C]// IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2015. Washington D C: IEEE Computer Society, 2015: 3547-3555.
- [14] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [C]// Computer Vision — ECCV 2018 — 15th European Conference, 2018, Proceedings. Munich: Springer Verlag, 2018: 3-19.

## Research on bilateral segmentation algorithms for feature recognition of sea surface oil spill images

DU Hongbiao<sup>1</sup>, YU Wei<sup>2</sup>, ZHANG Xu<sup>2</sup>, CHEN Yuqing<sup>\*2</sup>

(1. The 719th Research Institute of China Shipbuilding Industry Corporation, Wuhan 430064, China;

 $\hbox{2.College of Marine Electrical Engineering, Dalian Maritime University, Dalian 116026, China ) } \\$ 

**Abstract:** The frequent occurrence of major offshore oil spills poses a great threat to the marine natural environment. Aiming at the problems of insufficient intelligence and accuracy of the traditional feature recognition methods of sea surface oil spill images, a new intelligent algorithm of deep learning semantic segmentation is explored. Firstly, the basic structure and functional modules of bilateral segmentation network (BiSeNetV2) are analyzed. In order to further reduce the complexity of the existing network parameters, the GE layer of the semantic branch is improved to enhance the lightweightness of the network. Then, double attention module is added to the two branches of BiSeNetV2 to solve the problem of similarity between classes, which enhances the accuracy of oil spill image feature recognition. Through experimental comparison and analysis, it is verified that the recognition accuracy of the improved lightweight bilateral segmentation network for the characteristics of sea surface oil spill image can reach 91.9%.

Key words: oil spill; image recognition; bilateral segmentation; dual attention module