

基于深度语义分割的多源遥感图像海面溢油监测

陈彦彤, 李雨阳, 吕石立, 王俊生

引用本文:

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 Yan-tong, LI Yu-yang, LV Shi-li, 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.

在线阅读 View online: <https://doi.org/10.3788/OPE.20202805.1165>

您可能感兴趣的其他文章

Articles you may be interested in

利用卷积神经网络的自动驾驶场景语义分割

Autonomous driving semantic segmentation with convolution neural networks

光学精密工程. 2019, 27(11): 2429–2438 <https://doi.org/10.3788/OPE.20192711.2429>

采用深度级联卷积神经网络的三维点云识别与分割

Recognition and segmentation of three-dimensional point cloud based on deep cascade convolutional neural network

光学精密工程. 2020, 28(5): 1187–1199 <https://doi.org/10.3788/OPE.20202805.1187>

基于多尺度特征融合的遥感图像场景分类

Scene classification of remote sensing images based on multiscale features fusion

光学精密工程. 2018, 26(12): 3099–3107 <https://doi.org/10.3788/OPE.20182612.3099>

基于卷积神经网络的光学遥感图像检索

Optical remote sensing image retrieval based on convolutional neural networks

光学精密工程. 2018, 26(1): 200–207 <https://doi.org/10.3788/OPE.20182601.0200>

三维语义场景复原网络

Three-dimensional reconstruction of semantic scene based on RGB-D map

光学精密工程. 2018, 26(5): 1231–1241 <https://doi.org/10.3788/OPE.20182605.1231>

文章编号 1004-924X(2020)05-1165-12

基于深度语义分割的多源遥感图像 海面溢油监测

陈彦彤¹, 李雨阳¹, 吕石立², 王俊生^{1*}

(1. 大连海事大学 信息科学技术学院, 辽宁 大连 116026;

2. 交通运输部 搜救中心, 北京 100736)

摘要: 针对遥感图像海面溢油区域通常受到斑噪声以及强度不均等因素的影响, 从而导致溢油区域监测效果较差的问题, 本文引入了深度语义分割的方法, 将深度卷积神经网络与全连接条件随机场相结合, 形成端对端连接。以 Resnet 结构为基础, 首先通过深度卷积神经网络对多源遥感图像粗分割并作为输入, 然后经过改进的全连接条件随机场, 利用高斯成对势和平均场近似定理, 建立条件随机场形成递归神经网络作为输出。通过多源遥感图像对海面溢油区域进行监测, 并利用可见光图像估计溢油区域面积。实验在所建立的多源遥感图像数据集上与其它先进模型进行对比, 结果表明本文方法提高了溢油区域的分割精度以及精细细节程度, 平均交并比为 82.1%, 监测效果具有明显地改善。

关键词: 海面溢油; 卷积神经网络; 语义分割; 条件随机场; 遥感图像

中图分类号: TP753 **文献标识码:** A **doi:** 10.3788/OPE.20202805.1165

Research on oil spill monitoring of multi-source remote sensing image based on deep semantic segmentation

CHEN Yan-tong¹, LI Yu-yang¹, LÜ Shi-li², WANG Jun-sheng^{1*}

(1. *Department of Information Science and Technology,
Dalian Maritime University, Dalian 116026, China;*

2. *Search and Rescue Center of the Ministry of Transport, Beijing 100736, China)*

* *Corresponding author, E-mail: wangjsh@dlnu.edu.cn*

Abstract: In remote sensing images, oil spill areas are usually affected by spot noise and uneven intensity, which leads to poor segmentation. A deep semantic segmentation method was introduced to combine a deep convolution neural network with a full connection conditional random field to form an end-to-end connection. Based on Resnet, first, the multi-source remote sensing image was roughly segmented as input by the deep convolutional neural network. Then, using Gaussian pairwise and mean field approximation, the conditional random field was established as the output of the recurrent neural network. The oil spill area on the sea surface was monitored by a multi-source remote sensing

收稿日期: 2019-11-07; 修订日期: 2019-12-02.

基金项目: 国家自然科学基金资助项目 (No. 61901081); 中央高校基本科研业务费专项资助项目 (No. 3132020199)

image and estimated by optical images. Experimental results show that the proposed method improves classification accuracy and captures finer details of oil spill are as compared with other models using the dataset established by the multi-source remote sensing image. The mean intersection over the union is 82.1%, and the monitoring effect is significantly improved.

Key words: spilled oil on the sea; Convolution Neural Network (CNN); semantic segmentation; conditional random field; remote sensing image

1 引言

近年来,随着世界各国对原油需求量不断增加,海洋石油运输业迅速发展,但国内外海面溢油污染事故却频繁发生。例如 2010 年,大连新港一艘外籍油轮在卸油时,导致陆地输油管线发生爆炸,事故造成 50 平方公里的海域被污染。2018 年,桑吉轮与货船在长江口发生碰撞^[1],事故造成大量石油泄漏溢入东海,对海洋生态环境造成巨大危害。当海面溢油事故发生后,能否准确地检测溢油区域位置和面积信息,对后续采取防治措施至关重要。因此,开展海面溢油监测对于海洋环境保护具有重要意义。

传统的海面溢油监测手段为航拍或实地调查,但是这种方法需要投入大量的人力物力,导致成本高、操作难度大。而遥感卫星^[2]可以不受国界领空的限制,长期且有效地监测海面溢油的情况,是目前海面溢油监测的最佳手段。目前基于遥感卫星的海面溢油监测通常使用星载合成孔径雷达^[3](Synthetic Aperture Radar, SAR),其具有覆盖范围广、全天候的优势,能够有效监测海面溢油位置,但 SAR 图像溢油监测的研究主要集中在探测溢油的有无,对油污面积计算较少。而可见光遥感图像^[4]具有分辨率高、颜色丰富等特征,可以有效估计溢油区域面积,这对海洋生态破坏评估、后续溢油治理起到至关重要的作用。

对于多源遥感图像海面溢油监测主要采用图像分割的方法,其中传统的海面溢油分割方法有:(1)基于阈值分割的方法^[5],原理是将图像像素点分为若干类。这种方法实现简单且计算量小,但易受海面噪声以及图像灰度分布不均的影响,导致分割准确度低;(2)基于边缘信息的检测方

法^[6],结合溢油区域的形状特征以及边缘信息,来获取溢油候选区域;(3)基于语义分割^[7-9]的检测方法,它是将图像中属于相同类别的像素聚类为一个区域。可以将溢油区域与海面进行明确的分类,语义分割对图像有更加细致的了解。用于语义分割的传统分类方法有:(1)随机决策森林(Random Decision Forests, RDF)^[10],利用多棵树对样本进行训练并预测的一种分类方法;(2)马尔科夫随机场(Markov Random Fields, MRF)^[11],它是一种无向图模型,为每个像素分配定义标记的问题;(3)条件随机场(Condition Random Field, CRF)^[12-13],表示的是给定一组输入随机变量 X 的条件下另一组输出随机变量 Y 的马尔可夫随机场。其中全连接条件随机场(Fully Connected Condition Random Field, FCCRF)克服了传统 CRF 漏掉细小结构的缺点。但是这些传统方法的分类效果依然较差。

近年来,深度学习已经广泛应用于计算机视觉领域^[14],尤其在图像分类方面获得了突破性的成功。LONG J 等人提出了全卷积网络^[15](Fully Convolutional Networks, FCN),应用于语义分割中,取得了较高的准确率。Deeplab^[16-17]模型是由 Google 团队提出的一种用于语义分割的办法,利用空洞卷积准确调节分辨率,扩大感受野,降低计算量,并用空洞卷积金字塔池化(Atrous Spatial Pyramid Pooling, ASPP)模块进行多尺度特征提取,得到全局和局部特征。最后用全连接条件随机场,优化边缘效果,解决了因为传统深度卷积神经网络^[18-20](Deep Convolutional Neural Network, DCNN)中连续的池化和降采样导致空间分辨率明显下降的问题,近一步提升分割效果。但是 Deeplab 模型依然存在一些问题,例如:(1)先用深度卷积神经网络进行粗分割,再利用全连接条件随机场进行细分割,无法实现端对端的训

练,导致分类精度低;(2)对海面溢油区域的精细细节提取较差且耗时长。

针对以上问题以及多源遥感图像的特点,本文以 Deeplab 模型为基础,提出一种新的卷积神经网络形式的多源遥感图像海面溢油语义分割模型,用于监测海面溢油区域,该模型将 CRF 与深度卷积神经网络相结合,利用高斯成对势和平均场近似定理,建立条件随机场形成递归神经网络(Recurrent Neural Networks, RNN)^[21],并将它作为神经网络的一部分,获得一个兼具卷积神经网络特性和 CRF 特性的深层端到端网络,将其命名为深度语义分割(Deep Semantic Segmentation, DSS)。利用该模型监测 SAR 以及可见光遥感图像的海面溢油区域,并用可见光遥感图像有效估计溢油面积。

2 Deeplab 模型

Deeplab 模型利用空洞卷积代替了标准的网络卷积操作,通过扩大感受野、缩小步幅对特征图

采样。它调整了卷积滤波器的感受野来捕捉多尺度的上下文信息,输出不同分辨率的特征。对于一维卷积结构,输出特征图 y 的每个位置 i ,卷积滤波器 w ,输入特征图 x ,空洞卷积计算如公式(1)所示。二维卷积结构原理如图 1 所示。

$$y[i] = \sum_k x[i + r \cdot k]w[k]. \quad (1)$$




图 1 空洞卷积原理

Fig. 1 Principle of atrous convolution

首先 Deeplab 改进了 Resnet 架构,将 Resnet 的全连接层转化为卷积层,最后两个池化层去掉了下采样,且后续卷积层的卷积核改为了空洞卷积,并对 Resnet 的权重进行微调,这样网络最后

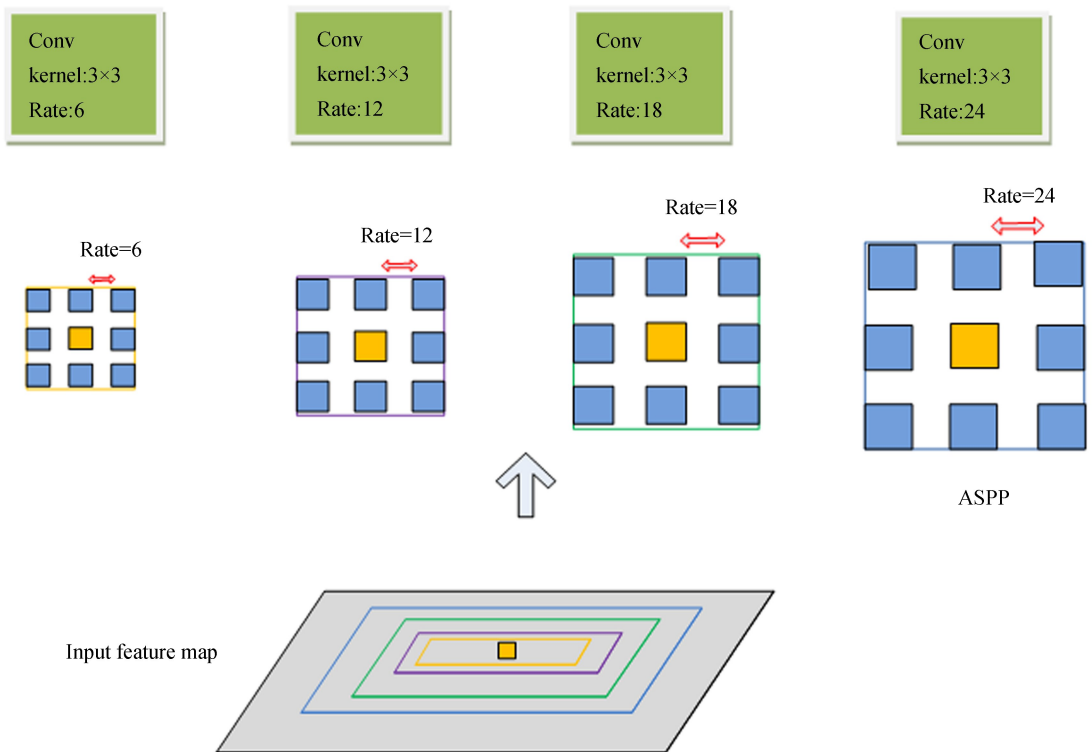


图 2 ASPP 模块原理

Fig. 2 Principle of Atrous Spatial Pyramid Pooling(ASPP)

输出的特征图分辨率提高,感受野变大。然后进行多尺度提取,ASPP 模块如图 2 所示,在给定的输入特征图上以 $r=(6,12,18,24)$ 的 3×3 空洞卷积并行采样,最后通过 ASPP 各个空洞卷积分支采样后结果融合到一起,得到最终预测结果。实际上就是通过不同的空洞卷积来对图像进行不同程度的缩放,从而获得了更好的分割效果。最后使用全连接条件随机场细化图片。

3 海面溢油监测

基于多源遥感图像的海面溢油区域普遍存在斑噪声和强度不均的现象。其中 SAR 图像中许多暗区域会被分类成溢油区域,可见光遥感图像中海杂波等会对目标检测产生影响。首先本文以 Deeplab 模型为基础,输入的图像经过深层卷积神经网络对其进行粗略地分割,然后将全连接条件随机场看做循环神经网络作为输出,再次对图像细分割,实现了深层卷积神经网络与全连接条件随机场端对端的连接,将 DCNN 与改进的全连接 CRF 模型优势结合在一个统一的端对端框架中。其次,本文在 ASPP 模块中加入了 BN 层,加快网格训练速度。最后,改进了基于平均场近似定理的全连接条件随机场算法,与 DCNN 端对端连接。

3.1 全连接条件随机场

传统的条件随机场用于平滑噪声,将邻近结点耦合,这样空间上接近的像素会被分配相同标记的标签。但是目前的深度卷积神经网络架构,得分图通常非常平滑。在这种情况下,使用传统的条件随机场模型会漏掉细小结构,目标恢复详细的局部结构。而全连接条件随机场可以克服这个缺点,捕获精细细节。首先将像素标签建模为随机变量,在全局观测条件下形成马尔科夫随机场,设图片为 \mathbf{I} , x_i 为像素 i 的标注,从标签 L_i 中取值, \mathbf{X} 为随机变量 x_1, x_2, \dots, x_N 产生的向量, \mathbf{I} 和 x 的关系可以建模为条件随机场,如公式(2)所示:

$$P(\mathbf{X} = x | \mathbf{I}) = \frac{1}{Z(\mathbf{I})} \exp(-E(x | \mathbf{I})). \quad (2)$$

由此可定义吉布斯分布如公式(3)所示。

$$E(x) = \sum_i \psi_u(x_i) + \sum_{i < j} \psi_p(x_i, x_j), \quad (3)$$

$$\psi_p(x_i, x_j) = \mu(x_i, x_j) \sum_{m=1}^M \omega^{(m)} k_G^{(m)}(\mathbf{f}_i, \mathbf{f}_j), \quad (4)$$

其中: $\sum_i \psi_u(x_i)$ 为衡量像素 i 取标签 x_i 的损失,由深层卷积神经网络获得。 $\sum_{i < j} \psi_p(x_i, x_j)$ 为衡量像素 i, j 同时取标签 x_i, x_j 的损失,依赖于图像平滑项,使得相似像素更有可能标注相同标签,具体如公式(4)所示。每一个 k_G^m 为作用于特征向量的高斯核, \mathbf{f}_i 和 \mathbf{f}_j 分别为像素 i, j 的特征向量,特征向量一般取图像二维位置坐标和颜色 RGB 向量。距离和颜色的差距越大,则影响越小。 m 表示高斯核的个数,取 1 或 2。 $\omega^{(m)}$ 为权重线性组合,不同卷积核权值不同,它是由网络训练所得, $\mu(x_i, x_j)$ 为兼容性函数,即惩罚项。

3.2 条件随机场看作循环神经网络

根据公式(3),最小化吉布斯分布 $E(x)$ 就可以得到标注结果,但是过程相对复杂且算法比较耗时,因而本文引入了平均场近似最大后验分布进行推理^[22]。 $Q(x)$ 为条件随机场 $P(x)$ 的近似,它作为 RNN 重构。平均场近似推理迭代算法具体步骤如表 1 所示。

表 1 平均场近似推理迭代算法

Tab. 1 Mean field approximate reasoning iterative algorithm

算法:平均场定理用于将 CRF 分解为常见的 CNN 操作	
$Q_i(l) \leftarrow \frac{1}{z_i} \exp(U_i(l))$ for all i	初始化
While not converged do	
$\tilde{Q}^{(m)}(l) \leftarrow \sum_{j \neq i} k^{(m)}(\mathbf{f}_i, \mathbf{f}_j) Q_j(l)$ for all m	消息传递
$\tilde{Q}_i(l) \leftarrow \sum_m \omega^{(m)} \tilde{Q}_i^{(m)}(l)$	权值调整
$\hat{Q}_i(l) \leftarrow \sum_{l'} l' \in L_i(l, l') \tilde{Q}_i(l')$	兼容性转换
$\check{Q}_i(l) \leftarrow U_i(l) - \hat{Q}_i(l)$	传递误差微分
$Q_i \leftarrow \frac{1}{z_i} \exp(\check{Q}_i(l))$	归一化
End while	

如表 1 所示,首先第 1 步初始化过程为初始概率值, U 为卷积神经网络的结果。这个过程相当于在每个像素的所有标签上对一元电位应用一个 Softmax 函数,不包含任何参数,可以看做神经网络的 Softmax 层。第 2 步应用高斯滤波器来实现消息传递,即概率转移。对 $Q(x)$ 进行高斯模糊,这个过程相当于神经网络的卷积运算。第 3 步为权值调整,对于每个类标签 l ,计算出上一步高斯滤波器输出的加权和。可以看作 1×1 的卷积层,对多个特征图进行卷积运算。第 4 步为兼容性转换,通过考虑不同标签之前的兼容性并相应的分配惩罚,这样可以获得更好的结果。即如果将不同的标签分配给具有类似属性的像素,这将会受到惩罚,可视为卷积层。第 5 步用一元势减去兼容性转换步骤的输出,传递误差微分,表示最终概率由卷积神经网络的结果 U 和全局概率转移结果 $\hat{Q}_i(l)$ 共同决定。第 6 步是归一化操作,将第 5 步的结果归一化传到下一次循环神经网络迭代作为初始概率。这个过程可以看作另一个没有参数的 Softmax 操作。

本文对平均场近似推理迭代算法的第 2 步和第 3 步进行了改进,原始的高斯核为 2,考虑了 x, y 的位置向量和颜色向量,实际上颜色向量在 DCNN 层中决定了分类的先验概率,所以可以不考虑颜色向量的高斯距离,仅考虑位置差异,这样高斯核为 1,距离越远差异就越小。并用全图距离权重网络代替传统的高斯核距离,将距离权重置于全图卷积网络中,该网络的权值由训练样本得到。第 2 步和第 3 步概率转移和权值调整合并变为新的算法,相当于卷积运算,如公式(5)所示:

$$\bar{Q}_i(l) = \sum_{i \neq j} a_{i,j} Q_j(l), \quad (5)$$

其中: a_i 为距离权重, l 为类别, $Q_j(l)$ 为每个点的类别概率。

该算法的迭代过程可表示为多个卷积神经网络层,如图 3 所示, f_θ 表示迭代带来的变化。多层平均场迭代可以重复上述过程实现,每一次迭




图 3 平均场近似推理算法迭代过程

Fig. 3 Mean field approximation reasoning algorithm iterative process

代都来源于之前迭代的结果,这就相当于将迭代平均场视为一个循环神经网络,网络方程如式(6)~式(8)所示, T 为平均场的迭代次数, $H_1(t)$ 初始值为 DCNN 归一化的结果、 $H_2(t)$ 为一次 CRF 过程。 $Y(t)$ 是第 T 次迭代的输出,当未达到迭代次数 T 时则继续迭代。当 $t = T$ 时,输出 $H_2(t)$ 为最终迭代结果。

$$H_1(t) = \begin{cases} \text{softmax}(U), & t = 0 \\ H_2(t - 1), & 0 < t \leq T \end{cases}, \quad (6)$$

$$H_2(t) = \{f_\theta(U, H_1(t), I), 0 \leq t \leq T, \quad (7)$$

$$Y(t) = \begin{cases} 0, & 0 \leq t < T \\ H_2(t), & t = T \end{cases}. \quad (8)$$

通过上述改进,模型整体流程图如图 4 所示,首先输入图片经过 Resnet 网络,将 Con3_x 与 Con4_x 的中间层改为空洞卷积,然后经过多尺度 ASPP 模块,通过不同的空洞卷积速率 Rate=(6, 12, 18, 24) 得到不同大小的特征图。其次经过多尺度 ASPP 模块,加入 BN 层后,它可以加快训练速度,提高网络的泛化能力。其中 ASPP 模块的卷积神经网络可视化如图 5 所示。当感受野较小的时候,提取到的是图像的细节特征。当感受野越来越大时,提取到的是图像的抽象特征。然后经过双线性插值输出特征图,提供了 CRF 的一元电位,直接以端到端连接到循环神经网络中。最后,进入循环卷积神经网络后,需要迭代 t 次才能离开循环,使用反向传播算法和随机梯度下降方法进行端到端的培训,一旦离开循环,Softmax 层进行网络的终止,输出分类结果。该算法统一了卷积神经网络与 CRF 的优势,形成了端对端的连接,并细化了分割边缘。

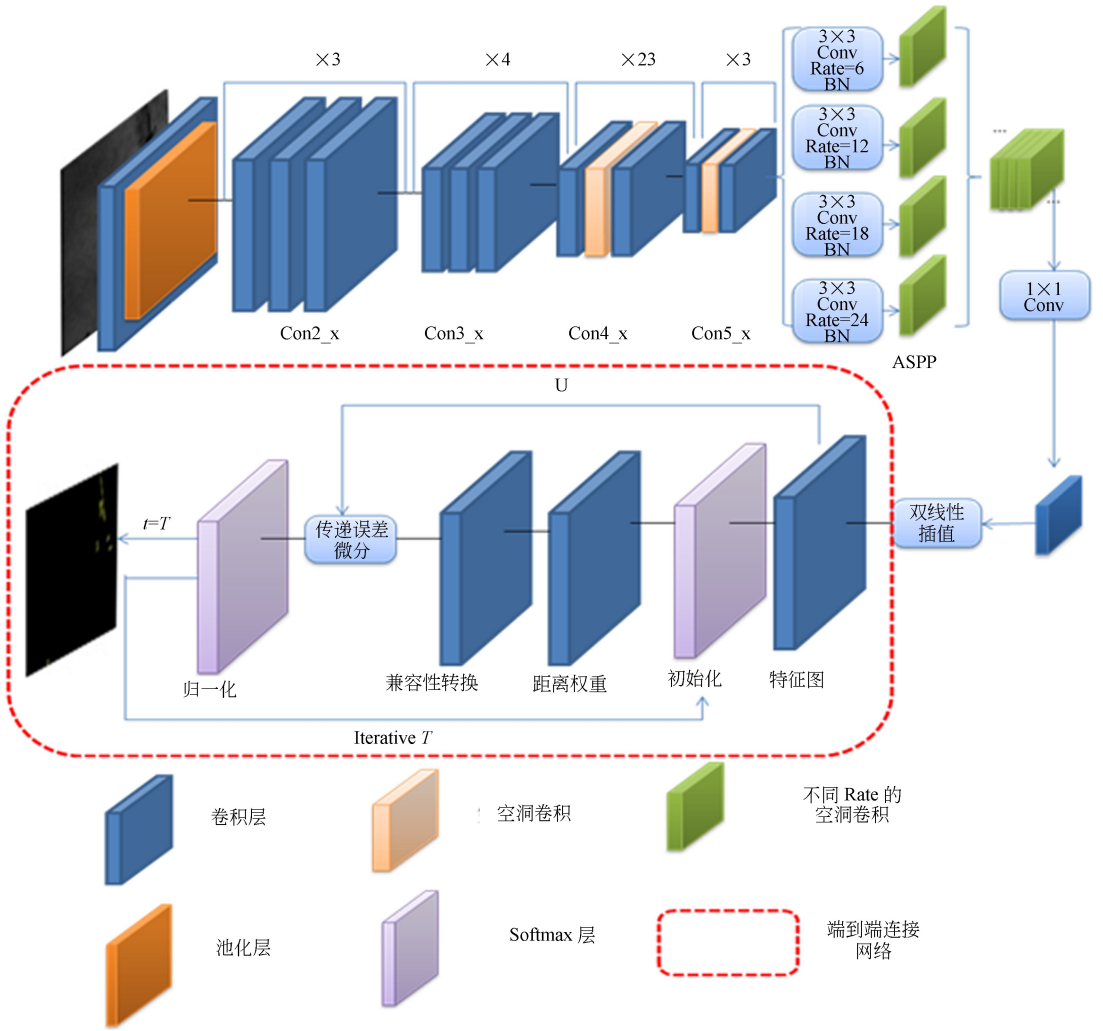


图 4 DSS 流程图

Fig. 4 DSS flow chart




图 5 ASPP 模块的多尺度可视化结果

Fig. 5 Multi scale visualization results of ASPP

4 实验结果与分析

实验对基于多源遥感图像的海面溢油区域进行检测,并与其他先进方法进行对比,验证本文模型的优越性。本实验电脑配置为 Intel i7 处理器,显卡为 NVIDIA RTX2080Ti,16 G 内存,在 Linux 系统下的 caffe 平台,并建立了高质量 SAR 图像与遥感图像数据集,其中可见光遥感图像来源

于 QuickBird, WorldView-2 等遥感卫星所拍摄到的海面溢油图像与 Google Earth 中的图像, SAR 图像来源于 c 波段雷达 sat-2 极化仪,共采集了 4 200 张海面溢油图像。所得到的数据集将图像中目标划分为三类,分别为背景、溢油区域、舰船。然后从图像中随机选择 60% 作为训练集,20% 作为验证集,另 20% 作为测试集。由于训练需要大量的图片,所以本文进行了数据增强,即对每张图像随机旋转 90°,180°,270°,最终得到了包含 8 400 张图像的数据集。实验在训练过程中应用 poly 学习策略,具体如公式(9)所示。本文将深度卷积神经网络中的迭代次数设为 20K,批量大小(batch size)为 20,epoch 表示训练集中全部样本训练一次,共 80 次。学习率的初始值为 0.001,为了防止学习率过大,在收敛到最优处会

不稳定,所以学习率应随着训练过程按指数级而下降。权重衰减为 0.000 5,动量因子为 0.9。

$$poly = \left(1 - \frac{iter}{max_iter}\right)^{power}, \quad (9)$$

其中: $power$ 为参数,值为 0.9, $iter$ 表示迭代次数, max_iter 表示最大迭代次数。

本实验包括了海面溢油区域的分类结果、mIOU 计算与损失函数、时间对比分析以及溢油面积计算。

4.1 海面溢油分类结果

本实验分别对比了遥感可见光图像与 SAR 图像的海面溢油分割情况,如下图所示,对比方法分别为 CRF-RNN, SPNet, 以及本文所提方法。

图 6~图 8 为可见光遥感图像的海面溢油分割结果,可见光遥感图像的油污与海水具有不同的表现。其中图 6(a)为原图,可以看出图中溢油

区域较明显,但存在海杂波的干扰。图 6(b)为 CRF-RNN 模型检测结果,它只是用传统的卷积神经网络进行粗分割,并且未对平均场定理进行改进,结果将部分海杂波错误分类为溢油区域。图 6(c)的 SPNet 模型基本正确分类了溢油区域,但是精确度较差。本文所提出的方法检测结果如图 6(d)所示,与图 6(b)相比,本文模型可以精确的分类出海杂波与溢油区域,捕获了目标精细细节。图 7(a)的溢油区域较分散且不明显,CRF-RNN 模型只正确分类了舰船,本文所提出的方法如图 7(d)所示,由图可知本文方法分类效果最好,由于实现了端对端的连接分割精度进一步提升。由图 8 所示,CRF-RNN 模型将舰船错误分类为溢油区域,SPNet 模型与本文模型都正确分类了舰船与溢油区域,但是本文模型对目标的精细分割能力较强,获得了良好的效果。




图 6 可见光遥感图像海面溢油分割结果

Fig. 6 Optical remote sensing image oil spill segmentation results




图 7 可见光遥感图像海面溢油分割结果

Fig. 7 Optical remote sensing image oil spill segmentation results




图 8 可见光遥感图像海面溢油分割结果

Fig. 8 Optical remote sensing image oil spill segmentation results




图 9 SAR 图像海面溢油分割结果

Fig. 9 SAR image oil spill segmentation results




图 10 SAR 图像海面溢油分割结果

Fig. 10 SAR image oil spill segmentation results




图 11 SAR 图像海面溢油分割结果

Fig. 11 SAR image oil spill segmentation results

图 9~图 11 为 SAR 图像的海面溢油分类结果。在 SAR 图像中,存在固有的相干斑噪声且不

同区域特性不均匀,导致分类难度增加,由 3 幅图可知,CRF-RNN 模型只能正确分类严重溢油区域,即图像中颜色较深的部分。SPNet 模型虽然正确分类了部分溢油区域但是对目标边缘比较模糊,本文所提出的方法分割结果均优于前两种模型。通过实验分析,无论是可见光遥感图像还是 SAR 图像,本文所提出的方法均适用且分割效果好。

4.2 mIOU 计算以及损失函数

将本文模型在所建立的数据集上与其他先进模型进行对比,评价指标为 mIOU,称为平均交并比,是语义分割的标准度量,具体如公式(10)所示。对比结果如表 2 所示。mIOU 值最低的为 FCN-8s,由于卷积网络的层数较少,从而导致结果较差。Deeplab 模型的值为 76.5,SPNet 模型的值仅次于本文所提出的模型,达到了 78.9,CRF-RNN 模型 mIOU 值为 71.8。本文方法与其他先进方法相比效果较好,mIOU 达到 82.1。

$$mIOU = \frac{1}{k+1} \sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij} + \sum_{j=0}^k p_{ji} - p_{ii}}, \quad (10)$$

其中: k 为类别, i 表示真实值, j 表示预测值, p_{ij} 表示将类 i 预测为类 j 。

表 2 不同模型 mIOU 对比

Tab.2 Comparison of different models mIOU

Method	mIOU
FCN-8s ^[23]	60.1
DeepLab-MSc ^[16]	70.3
CRF-RNN ^[22]	71.8
Deeplab ^[16]	76.5
HDC ^[24]	74.8
SPNet ^[25]	78.9
H-ReNet+DenseCRF ^[26]	76.8
OxfordTVG HO CRF ^[27]	77.9
Proposed	82.1

端对端模型迭代次数对实验的影响如表 3,由表可知,当迭代次数达到 5 以上,mIOU 提高的不是很明显,考虑迭代次数多所占用的时间,所以

本文选用迭代次数为 $T=5$ 。

表 3 迭代次数对模型的影响

Tab.3 Effect of number of iterations on model

Iteration	1	2	3	4	5
mIOU	79.5	80.0	81.2	81.7	82.1
Iteration	6	7	8	9	10
mIOU	82.2	82.3	82.4	82.5	82.6

本文利用了交叉熵损失函数(Cross Entropy Cost Function, CECF)来计算损失,其定义如公式(11)所示。交叉熵表示真实概率分布与预测概率分布之间的差异,在深度学习中,真实分布已经确定,交叉熵值越小,表示模型预测效果越好。损失函数收敛曲线如图 12 所示。

$$H(p, q) = - \sum_{i=1}^n p(x_i) \log(q(x_i)), \quad (11)$$

其中: $p(x_i)$ 表示真实概率分布, $q(x_i)$ 表示预测概率分布。




图 12 损失函数曲线

Fig.12 Loss function curve

4.3 时间分析

在建立的数据集上与其它先进方法的时间对比,如表 4 所示。由表可知 Deeplab 模型耗时最长为 1.4 s,是因为没有实现深度卷积神经网络与全连接条件随机场端对端的连接。耗时最短的模型为 FCN-8s,而本文所提出的 DSS 模型耗时相对较短,基本与 FCN-8s 模型处于同一个数量级上且保证了检测精度。

表 4 不同模型耗时分析

Tab. 4 Time-consuming analysis of different models

Method	Runtime/s
FCN-8s	0.55
Deeplab	1.4
SPNet	1.25
CRF-RNN	0.75
Proposed	0.8

4.4 溢油面积计算

海面溢油面积的计算可以为海面污染程度以及未来可能污染的程度提供依据,具有重要的意义。本文通过可见光遥感卫星的分辨率以及溢油区域的像素点数来估计溢油面积,由于可见光遥感图像分辨率高,通常 1 m 分辨率是指一个像素表示地面大约 1×1 m 的面积,因此利用溢油区域像素的数量乘以卫星分辨率的平方,即可求出海面溢油区域面积,具体如公式(12)所示:

$$S_{os} \approx N_{os} \times R^2, \quad (12)$$

其中: S_{os} 为海面溢油区域面积, N_{os} 为溢油区域像素点数, R 为卫星的分辨率。本文可见光遥感图像的溢油面积如表 5 所示。

表 5 可见光遥感图像溢油面积

Tab. 5 Oil spill area of visible remote sensing image

卫星	像素点数	卫星分辨率/m	溢油面积/m ²
可见光图像 1	78 112	0.61	29 065.5
可见光图像 2	29 774	0.5	7 443.5
可见光图像 3	61 548	0.5	15 387

5 结 论

本文以深层卷积神经网络为基础,空洞卷积代替最大池化层,并与全连接条件随机场实现端对端的连接,获得一个既有卷积神经网络特性又具有条件随机场特性的深层网络。克服了卫星图像对海面溢油监测的分类较差的问题,提升了捕获目标精细细节的能力。通过 SAR 和可见光遥感图像对海面溢油区域进行监测,在本文所建立的数据集上 mIOU 值达到了 82.1,对于遥感图像的分类效果均较好。并且利用可见光遥感图像高分辨率的特点,有效估计了溢油区域的面积,对海洋环境修复及查看海面污染程度具有重要的意义。

本文是以弱监督学习为基础的训练模型,网络的训练依赖大量的标记图像,这就需要大量的人力且会受到人为主观因素的影响。因此,未来的研究重点会转向非监督学习,提高算法的便利与可行性。

参考文献:

[1] 童丽珏,周伯煌. “桑吉”轮引发的海洋生态环境损害问题探析 [J]. 中国环境管理干部学院学报, 2018, 28(2): 12-14.
TONG L Y, ZHOU B H. Analysis on damage to the marine ecological environment caused by "San-chi" oil tanker [J]. *Journal of EMCC*, 2018, 28(2): 12-14. (in Chinese)

[2] 蒋兴伟,何贤强,林明森,等. 中国海洋卫星遥感应用进展 [J]. 海洋学报, 2019, 41(10): 113-124.
JIANG X W, HE X Q, LIN M S, et al.. Progresses on ocean satellite remote sensing application in China [J]. *Acta Oceanologica Sinica*, 2019, 41(10): 113-124. (in Chinese)

[3] 康利军,李晓峰,宋甜甜. SAR 图像海面溢油检测技术分析 [J]. 江苏科技信息, 2018, 35(20): 41-43.
KANG L J, LI X F, SONG T T. Analysis of oil spill detection techniques for SAR images [J]. *Jiangsu Science & Technology Information*, 2018, 35(20): 41-43. (in Chinese)

[4] 李宇,刘雪莹,张洪群,等. 基于卷积神经网络的光学遥感图像检索 [J]. 光学精密工程, 2018, 26(1): 200-207.
LI Y, LIU X Y, ZHANG H Q, et al.. Optical remote sensing image retrieval based on convolutional neural networks [J]. *Opt. Precision Eng.*, 2018, 26(1): 200-207. (in Chinese)

[5] AL-AMRI S S, KALYANKAR N V. Image seg-


- mentation by using threshold techniques [J]. *ArXiv Preprint ArXiv*:1005.4020, 2010.
- [6] 赵宏伟,陈霄,刘萍萍,等. 视觉显著目标的自适应分割[J]. *光学精密工程*, 2013, 21(2): 531-538. ZHAO H W, CHEN X, LIU P P, *et al.*. Adaptive segmentation for visual salient object [J]. *Opt. Precision Eng.*, 2013, 21(2): 531-538. (in Chinese)
- [7] 刘宁波,丁昊,田永华,等. 基于组合分形特征的海杂波中目标检测方法[J]. *航空兵器*, 2018(2): 38-42. LIU N B, DING H, TIAN Y H, *et al.*. Target detection method in sea clutter based on combined fractal characteristics [J]. *Aero Weaponry*, 2018(2): 38-42. (in Chinese)
- [8] NOH H, HONG S, HAN B. Learning deconvolution network for semantic segmentation [C]. *Proceedings of the IEEE international conference on computer vision*, 2015: 1520-1528.
- [9] CHEN L C, ZHU Y, PAPANDREOU G, *et al.*. Encoder-decoder with atrous separable convolution for semantic image segmentation [C]. *Proceedings of the European Conference on Computer Vision (ECCV)*, 2018: 801-818.
- [10] J SHOTTON, M JOHNSON, R CIPOLLA. Semantic texton forests for image categorization and segmentation [C]. *IEEE Conference on Computer Vision and Pattern Recognition*, 2008.
- [11] RANALI M, LAGONA F, PICONE M, *et al.*. Segmentation of sea current fields by cylindrical hidden Markov models: a composite likelihood approach [J]. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, 2018, 67(3): 575-598.
- [12] VARMA K I, KRISHNAMOORTHY S, PISIPATI R K. Natural language querying with cascaded conditional random fields[P]. United States Patent Application 20120254143, 280,535, 2016-3-8. <http://www.freepatentsonline.com/y2012/0254143.html>.
- [13] 汪萍. 基于多尺度条件随机场的语义图像分割深度卷积网络[J]. *宿州学院学报*, 2019, 34(7): 69-74. WANG P. Deep Convolutional network with multi-scale conditional random field for semantic image segmentation [J]. *Journal of Suzhou University*, 2019, 34(7):69-74. (in Chinese)
- [14] 唐聪,凌永顺,郑科栋,等. 基于深度学习的多视窗SSD目标检测方法[J]. *红外与激光工程*, 2018, 47(1):302-310. TANG C, LING Y SH, ZHENG K D, *et al.*. Object detection method of multi-view SSD based on deep learning [J]. *Infrared and Laser Engineering*, 2018, 47(1):302-310. (in Chinese)
- [15] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2015: 3431-3440.
- [16] CHEN L C, PAPANDREOU G, KOKKINOS I, *et al.*. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs [J]. *IEEE transactions on pattern analysis and machine intelligence*, 2017, 40(4): 834-848.
- [17] CHEN L C, PAPANDREOU G, KOKKINOS I, *et al.*. Semantic image segmentation with deep convolutional nets and fully connected crfs [J]. *arXiv preprint arXiv*:1412.7062, 2014.
- [18] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks [C]. *Advances in neural information processing systems*, 2012: 1097-1105.
- [19] 潘仙张,张石清,郭文平. 多模深度卷积神经网络应用于视频表情识别[J]. *光学精密工程*, 2019, 27(4): 963-970. PAN X ZH, ZHANG SH Q, GUO W P. Video-based facial expression recognition using multimodal deep convolutional neural [J]. *Opt. Precision Eng.*, 2019, 27(4): 963-970. (in Chinese)
- [20] SAINATH T N, MOHAMED A, KINGSBURY B, *et al.*. Deep convolutional neural networks for LVCSR [C]. 2013 *IEEE International Conference on Acoustics, Speech and Signal Processing, IEEE*, 2013: 8614-8618.
- [21] GRAVES A, MOHAMED A, HINTON G. Speech recognition with deep recurrent neural networks [C]. 2013 *IEEE International Conference on Acoustics, Speech and Signal Processing, IEEE*, 2013: 6645-6649.
- [22] G. LIN, C. SHEN, I. REID, A. van den Hengel. Efficient piecewise of deep structured models for semantic segmentation [J]. *ArXiv Preprint ArXiv*: 1504.01013, 2015.

- [23] DESMAISON A, BUNEL R, KOHLI P, *et al.*. Efficient continuous relaxations for dense CRF [C]. *European Conference on Computer Vision*, Springer, Cham, 2016: 818-833.
- [24] WANG P, CHEN P, YUAN Y, *et al.*. Understanding convolution for semantic segmentation [C]. 2018 *IEEE Winter Conference on Applications of Computer Vision (WACV)*, IEEE, 2018: 1451-1460.
- [25] XIAN Y, CHOUDHURY S, HE Y, *et al.*. Semantic projection network for zero-and few-label semantic segmentation [C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2019: 8256-8265.
- [26] Z YAN, H ZHANG, Y JIA, *et al.*. Combining the best of convolutional layers and recurrent layers: A hybrid network for semantic segmentation [J]. *ArXiv Preprint ArXiv*: 1603.04871, 2016.
- [27] A ARNAB, S JAYASUMANA, S ZHENG, P. Torr. Higher order potentials in end-to-end trainable conditional random fields [J]. *ArXiv Preprint ArXiv*: 1511.08119, 2015.

作者简介:



陈彦彤(1989—),男,辽宁沈阳人,讲师,硕士生导师,2012年于吉林大学获得学士学位,2017年于中国科学院长春光学精密机械与物理研究所获得博士学位,主要从事遥感图像处理及目标识别方面的研究。E-mail: chenyan-tong1@yeah.net



李雨阳(1995—),女,辽宁辽阳人,硕士研究生,2017年于大连海洋大学获得学士学位,主要从事遥感图像、目标识别处理等方面的研究。E-mail: lyy790819@163.com