

基于改进 Faster R-CNN 模型的 SAR 图像溢油检测方法

张天龙^{1,2,3}, 过杰^{1,2,4}

(1. 中国科学院烟台海岸带研究所 中国科学院环境过程与生态修复重点实验室, 山东 烟台 264003; 2. 中国科学院烟台海岸带研究所 山东省海岸带环境过程重点实验室, 山东 烟台 264003; 3. 中国科学院大学, 北京 100049; 4. 中国科学院海洋大科学中心, 山东 青岛 266071)

摘要: SAR(synthetic aperture radar)图像溢油暗斑准确识别对海上溢油应急工作具有重要的意义。为减少 SAR 图像特征提取、特征选择过程中人为因素对溢油检测精度的影响, 本文将 Faster R-CNN 卷积神经网络模型引入 SAR 图像溢油检测并进行了改进。针对溢油暗斑形状多样及 SAR 图像背景复杂的特点, 选用结构一致且实用性强的 VGG16 卷积网络获取图像特征, 并使用软化非极大值抑制算法(Soft-NMS)进行优化。同时基于相同的数据集, 提取常用的 SAR 图像几何特征、灰度特征和纹理特征, 构建反向传播(backpropagation, BP)神经网络溢油检测方法并与 Faster R-CNN 方法进行对比。实验结果表明, 基于改进 Faster-RCNN 模型的溢油检测方法溢油检测率达到 0.78, 且溢油检测虚警率低于 0.25, 相比 BP 神经网络溢油检测方法样本识别率、溢油检测率分别提高了 4%和 5%, 溢油虚警率降低了 5%。

关键词: SAR; Faster R-CNN; 溢油检测; BP 神经网络

中图分类号: P76 文献标识码: A 文章编号: 1000-3096(2021)05-0103-10

DOI: 10.11759/hyxx20200406001

海洋石油平台泄漏、运输船只事故及非法排放等造成的海洋溢油污染, 严重威胁海洋生态环境安全以及海洋产业的发展^[1-3]。因此, 如何及时监测溢油位置、面积, 准确识别油膜及估算溢油量, 是海洋溢油污染监测急需解决的问题, 这对于海洋溢油应急实施、保护海洋生态环境、减少溢油造成的经济损失具有重要的意义。

卫星遥感观测技术的快速发展使合成孔径雷达(synthetic aperture radar, SAR)以其全天时、全天候的优势在海洋溢油污染监测中发挥着“主力军”的作用^[4-5]。目前, 应用 SAR 数据进行海上溢油检测的方法主要有阈值法^[6-10]、概率统计方法^[11-13]、决策树方法^[14-15]、神经网络方法等^[16-19]。其中, 神经网络方法因其较强的自学习能力、泛化能力和容错能力, 能够较好地解决非线性分类问题, 被用于海面溢油和疑似溢油检测研究^[16-19]。Singha 等^[16]构建双层神经网络模型实现了 SAR 图像暗斑检测、特征提取及溢油暗斑目标分类的过程, 并分析了不同特征组合对神经网络溢油检测精度的影响。石立坚等利用方差分析方法对溢油识别特征参量进行筛选, 并利用反向传播(backpropagation, BP)神经

网络建立溢油识别模型实现了 SAR 图像溢油暗斑的有效识别^[19]。

近些年, 深度学习框架引领了计算机图像识别及相关学科的新一轮的研究热潮。图像特征的关注点由传统的图像全局特征转变为图像卷积多尺度特征。相比较于传统的图像识别框架, 深度学习框架图像特征自动提取的特点, 为机器学习的快速推广与应用带来了巨大的优势^[20-23]。深度学习框架在卷积神经网络(convolutional neural network, CNN)的基础上不断优化更新发展了 Fast R-CNN (fast region-convolutional neural network), Faster R-CNN (faster region-convolutional neural network), Mask R-CNN 等神经网络目标识别框架, 这些框架现已有较好的应用实例^[20, 24-26]。在 SAR 图像海上溢油识别方面,

收稿日期: 2020-04-06; 修回日期: 2020-05-11

基金项目: 国家重点研发计划项目(2017YFC1405600); 国家自然科学基金(42076197); 国家自然科学基金(41576032)

[Foundation: National Key Research & Development Program of China, No. 2017YFC1405600; National Science Foundation of China, No. 42076197; National Science Foundation of China, No. 41576032]

作者简介: 张天龙(1994—), 男, 山东淄博人, 硕士研究生, 研究方向: 海洋微波遥感应用, 电话: 0535-2109192, E-mail: tlzhang@yic.ac.cn; 过杰(1965—), 女, 通信作者, 河南开封人, 研究员, 研究方向: 海洋微波遥感及应用, 电话: 0535-2109192, E-mail: jguo@yic.ac.cn

已有学者进行了相关研究。Guo 等^[27]选取了 5 组 RADARSAT-2 数据的 6 种几何特征, 8 种纹理特征和 4 种极化特征, 组成优化特征子集输入到 CNN 神经网络中进行训练并使用测试样本进行分类测试, 测试结果表明 CNN 网络对 SAR 图像上溢油和疑似溢油区域有很好的区分能力。Nieto-Hidalgo 等^[28]针对机载侧视雷达(side-looking airborne radar, SLAR)数据构建了双层 CNN 神经网络模型, 用以区分船只和海面溢油, 并分析了不同训练参数对识别结果的影响, 比较了 11 种卷积神经网络, 结果表明双层 CNN 神经网络在卷积核窗口大小为 7 时, 识别精度最高。

目前, 多数研究^[16-19]通过图像全局特征提取及特征选择构建特征子集的方式, 构建基于人工神经网络的溢油检测方法, 而针对星载 SAR 数据使用深度卷积神经网络进行溢油和疑似溢油区分的研究相对较少。人工神经网络溢油检测方法虽能取得较好的溢油检测效果, 但此类方法特征提取、特征选择过程较为复杂, 且特征处理过程中易受到人为主观意识的影响。而深度卷积神经网络将特征提取、特征选择、识别定位及检测结果可视化, 集成于同一个神经网络中, 避免了在特征提取、特征选择等过程中人为因素的干扰。故本文提出基于改进 Faster R-CNN 神经网络模型的 SAR 图像溢油检测方法, 选用 VGG16 网络获取 SAR 图像卷积特征, 在 Faster R-CNN 神经网络中完成特征提取及特征选择过程, 使用软化非极大值抑制算法(soft non-maximum suppression, Soft-NMS)优化了传统的非极大值抑制算法(non-maximum suppression, NMS), 并基于相同的数据集与人工神经网络方法进行对比。

1 数据和方 法

1.1 数据及数据预处理

本文对选取的 26 景渤海海域 WSM(wide swath)观测模式、VV 极化模式的 ENVISAT ASAR 影像数据, 以及 20 景干涉宽幅观测模式、VV 极化模式的 Sentinel-1 GRDH 数据进行了辐射校正和几何校正。因两种数据的分辨率分别为 30 m×30 m 和 20 m×22 m, 故采用双线性插值法将 Sentinel-1 数据重采样为 30 m。本文选择增强型 Lee 滤波对 SAR 图像进行图像降噪处理, 图 1 为滤波窗口为 3、5 和 7

时的滤波结果。由图 1 可知增强型 Lee 滤波窗口大小为 7 时滤波效果最好且滤波窗口选择结果与文献^[29]实验结论一致; 若继续增大滤波器窗口, 则图像的边缘保持程度会降低, 运算量也相应的会增大^[29], 故本文增强型 Lee 滤波窗口大小设置为 7。基于上述处理后的 SAR 图像, 根据溢油的溢油判定规则^[8-9, 16-17]选取溢油与疑似溢油样本, 共计选取 602 个有效样本, 其中溢油暗斑样本 250 个, 疑似溢油暗斑样本 352 个。解译的样本中包含了溢油、船舶尾迹、低风速区、背风区、海洋内波等, 图 2 为选取典型的溢油和疑似溢油样本示例, 图 2 中 a 为溢油样本, b 为背风区样本, c 为低风速区样本, d 为船舶尾迹样本。

Faster-RCNN 神经网络虽然对输入的图像的大小没有具体的要求, 为能够记录暗斑在样本图像中的准确位置, 使用 LabelImg 开源软件^[30]对样本图像暗斑进行标记(图 3), 生成用于记录样本区域、类别及其他相关信息的 xml 文件, 实现了对输入图像的管理。将上述的溢油与疑似溢油数据集转换为 VOC2007 数据集格式^[31], 有利于 Faster R-CNN 神经网络进行训练和测试。在 Faster R-CNN 神经网络训练中, 训练集和测试集按照 7:3 的比例对数据集进行随机选取, 得到训练样本 421 个和测试样本 181 个。

为避免数据集不同对算法比较的客观性带来影响, 在人工神经网络溢油检测方法中, 将上述切分好的训练集再次按照 5:2 的比例对样本进行分配, 得到训练样本 301 个、验证样本 120 个。本文参考相关文献提取了溢油与疑似溢油样本的 10 个几何特征、14 个灰度特征以及 15 个纹理特征。其中, 10 个几何特征包括样本暗斑周长、面积、目标复杂度^[32]及 Hu 不变矩^[33]的前 3 阶的几何矩特征, 14 个灰度特征包括样本暗斑边缘梯度及目标灰度偏度等^[32], 15 个纹理特征则来源于洪继光^[34]提出的基于灰度共生矩阵的大小梯度优势及逆差等 15 个纹理特征。因某些特征提取时自身带有量纲(如周长)且特征数据的范围不一, 需先要对 39 个特征分别进行归一化处理, 归一化处理方法为:

$$y_{\text{norm}} = \frac{x_i - X_{\text{min}}}{X_{\text{max}} - X_{\text{min}}}, \quad (1)$$

式(1)中, y_{norm} 为归一化后的特征值, x_i 为原始特征值, X_{max} 和 X_{min} 为原始特征值中的最大值和最小值。

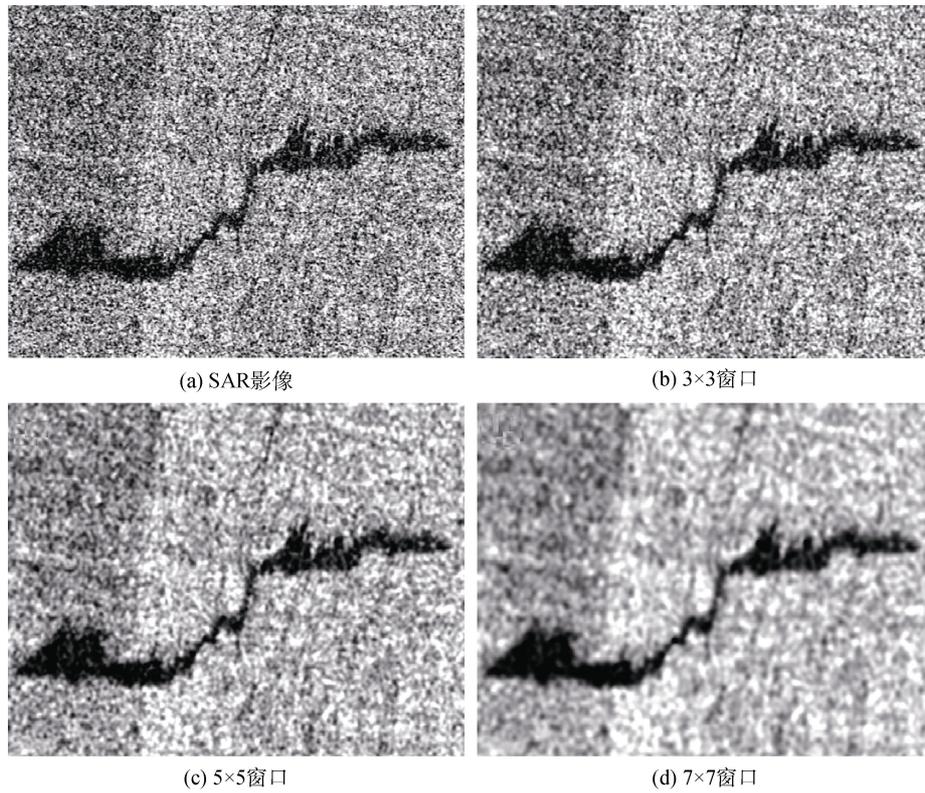


图 1 不同滤波窗口增强型 Lee 滤波结果对比图

Fig. 1 Comparison of the results of the enhanced Lee filtering with different filtering windows

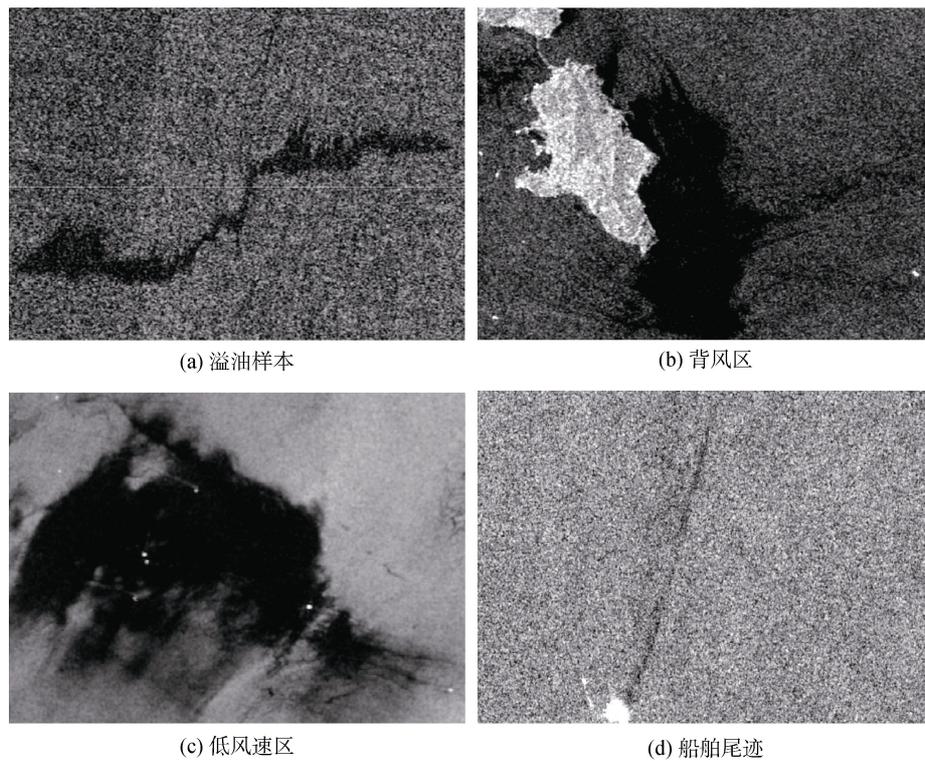
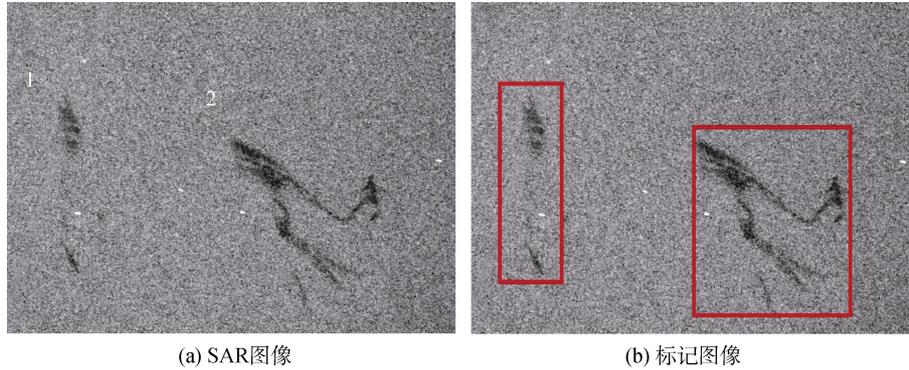


图 2 样本集中几种典型的溢油和疑似溢油样本

Fig. 2 Typical samples of oil spills and lookalikes from the sample dataset



(a) SAR图像 (b) 标记图像

图3 使用 labellmg 对样本进行标记
Fig. 3 Using Labellmg to mark the samples

1.2 改进的 Faster R-CNN 神经网络模型

任少卿等提出了 Faster R-CNN 神经网络模型^[35], 该模型首先在结构上做出了重大的改变, 模型将特征提取层、RPN(region proposal networks)层和包围框回归层及分类层集成在一个网络中, 这样可以在一个深度学习的框架中完成特征提取、分类以及位置修正的整个过程。Faster R-CNN 网络总体可分为 4 个部分: 卷积层、RPN 网络层、ROI pooling 层以及 Classification 层。卷积层主要通过卷积、池化等过程生成特征图。使用 RPN 网络代替 Selective search 等传统的候选框生成方法, 实现了网络的端到端训练, 极大地提升了检测框生成的速度。ROI pooling 层收集输入的特征图和建议候选框送入全连接层实现目标识别。Classification 层实现对检测框的再次准确定位, 通过全连接层与 Soft-max 分类器确定候选区具体的类别, 输出目标为某类别的概率向量; 同时再次利用包围框回归获得每个候选区的位置偏移量, 获取更加精确的目标检测框。因本文选用的样本为单波段图像, 故将图像数据的 Conv2d 函数的第一个参数设置为 1。

本研究针对海面油膜形状多样、大小不一且 SAR 数据信噪比相对较低、图像背景复杂的特点, 使用了一种结构简单、实用性强的 VGG16 网络^[36]获取图像卷积特征。VGG16 网络超参数较少, 结构一致; 模型使用 3 个窗口为 3 的卷积核代替了原来窗口为 7 的卷积核, 在保证有相同感受野的条件下, 提升了网络的深度, 在一定程度上提升了特征提取的效果, 减少了权重参数的数量, 有利于提取尽可能多的特征。对 Faster R-CNN 神经网络模型检测框处理模块, 使用 Soft-NMS 对原模型中默认的非极大值抑制算法

NMS 进行改进^[37], 较好地解决了目标检测框因重叠覆盖而导致检测结果精度降低的问题。

NMS 算法是 Faster R-CNN 算法中重要的部分, 其将所有的检测框进行重叠度 IOU(intersection over union)的计算, 如果重叠度大于某个阈值则此检测框被抑制^[37]。为减少高度重叠的冗余的检测框的生成, 需要进行检测框优化后处理, 传统的 NMS 算法处理的计算公式为:

$$S_x = \begin{cases} S_x & \text{IOU}(H, C_x) < T_t \\ 0 & \text{IOU}(H, C_x) \geq T_t \end{cases}, \quad (2)$$

式(2)中, S_x 为第 x 个检测生成框的得分; H 为得分最大的检测生成框, C 为检测生成框的集合且 C_x 中第 x 个检测框, T_t 为某一设定的阈值。传统 NMS 采用了硬分类的判断方式决定是否保留相邻的检测生成框, 这种方法的问题在于阈值设置较低时, 包含在框内的同类目标会因硬分类的方式而导致目标不被检测, 造成检测结果的缺失^[37]。故使用 Soft-NMS 算法, 基于降低检测框置信度的方式减弱上述问题的影响, Soft-NMS 算法的计算公式为:

$$S_x = \begin{cases} S_x & \text{IOU}(H, C_x) < T_t \\ S_x [1 - \text{IOU}(H, C_x)] & \text{IOU}(H, C_x) \geq T_t \end{cases}, \quad (3)$$

1.3 BP 神经网络模型

神经网络因其非线性推理的特性及较强的学习归纳能力被众多的溢油检测研究使用^[16-19, 32], 本文选用应用广泛的 BP 神经网络完成溢油检测研究。BP 神经网络结构如图 4 所示。

BP 神经网络的输入层输入数据通常为特征向量的组合, 其节点的个数需要根据实验确定^[16, 19, 32]。输出层节点的个数一般由实际分类研究中分类数量来确定。隐含层层数及隐含层节点个数的确定是 BP

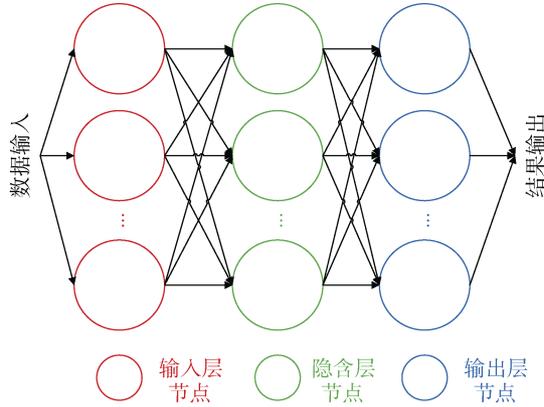


图 4 BP 神经网络结构示意图

Fig. 4 Structure diagram of the backpropagation (BP) neural network

神经网络训练学习过程中最重要的一环，隐含层调节的好坏将决定 BP 神经网络的分类精度。一般地，采用梯度下降算法对 BP 神经网络进行连接权值及反向误差的调节。BP 神经网络不同层的节点采用全连接模式，同层节点互不影响。BP 神经网络中各个节点基于反传误差的权重更新规则如下：

$$w_y^x(k+1) = w_y^x(k) + \Delta w_y^x(k+1), \quad (4)$$

$$\Delta w_y^x(k+1) = \sigma \Delta w_y^x(k) - \delta \frac{\partial L}{\partial w_y^x}, \quad (5)$$

式(4)、(5)中， k 为权重更新次数， $w_y^x(k)$ 和 $w_y^x(k+1)$ 分别为更新前后的权重， $\Delta w_y^x(k)$ 和 $\Delta w_y^x(k+1)$ 分别为更新前后权重的修正量， σ 和 δ 分别为动量系数和学习速率， x 和 y 表示第 x 层的第 y 个节点。 L 为训练损失函数，其定义为：

$$L = \sum_{m=1}^N (y_m - Y_m)^2, \quad (6)$$

式(6)中， y_m 为神经网络训练所要达到的目标值， Y_m 为神经网络给出的预测值， N 为输出层节点个数。因 BP 神经网络是一种学习过程显示型的人工神经网络，输入层的输入内容不能是样本图像，故需要对图像样本进行特征提取，提取后的特征组合可作为 BP 神经网络的输入。

2 结果与讨论

2.1 实验环境及评价指标

研究使用基于 CPU 版本的 Tensorflow 框架下的 Faster R-CNN 神经网络模型进行训练，训练时使用的硬件配置为 i7 处理器，运行内存大小为 16 GB；软

件环境为 Window 10 操作系统，Python 3.7 版本，Matlab 2019 版本。神经网络溢油检测方法则基于 Matlab 神经网络工具包实现。

为了能够客观评价改进的 Faster R-CNN 神经网络溢油检测方法以及人工神经网络溢油检测方法的溢油检测效果，选用了溢油检测率(D_R)，样本识别率(I_R)和溢油虚警率(F_{AR})对两种溢油检测方法进行评价。溢油检测率为对溢油样本进行正确分类的测度；样本识别率为能够正确识别溢油和疑似溢油两类的样本的测度，溢油虚警率为属于疑似溢油类别的样本被分类为溢油类别的测度，以上评价指标的定义分别如下：

$$D_R = \frac{R_R}{R_R + R_W}, \quad (7)$$

$$I_R = \frac{R_R + W_W}{R_R + R_W + W_R + W_W}, \quad (8)$$

$$F_{AR} = \frac{W_R}{W_R + R_R}, \quad (9)$$

其中， R_R 为溢油样本被正确分类的个数， R_W 为溢油样本被分类为疑似溢油样本的个数， W_R 为疑似溢油样本被分类为溢油样本的个数， W_W 为疑似溢油样本被正确分类的个数。

2.2 实验及结果分析

基于 1.1 小节中预处理后的样本集，分别应用改进的 Faster R-CNN 神经网络溢油检测方法和人工神经网络溢油检测方法进行了溢油检测方法实验。因海面 SAR 溢油检测容易受到疑似溢油暗斑的影响，疑似溢油暗斑也将参与 Faster R-CNN 的训练。在训练神经网络时，学习速率设置为 0.005，batch_size 设置为 16，每次读入 16 个样本图像。为加快训练收敛的速度且保证梯度下降的方向不变，本文梯度下降方式设置为动量梯度下降，以减弱训练过程中梯度振荡现象。RPN 网络的 IOU 阈值设置为 0.7，候选区域数量设置为 300，即选择 300 个最优的候选框传递给 Faster R-CNN 神经网络的分类层进行目标识别。迭代次数设置为 40 000 次。图 5 记录了 Faster R-CNN 神经网络每次训练的分类总损失。学习速率初始设置为 0.005，且学习速率衰减设置为每 10 000 次衰减一次。

由图 5 训练次数和分类总损失图可以看出，当训练次数达到 30 000 次时，神经网络收敛到较小的分类总损失，当迭代次数临近 40 000 次时，分类总损失进

一步减小且趋于稳定,说明本文 Faster R-CNN 神经网络训练 40 000 次可得到较好的训练结果。

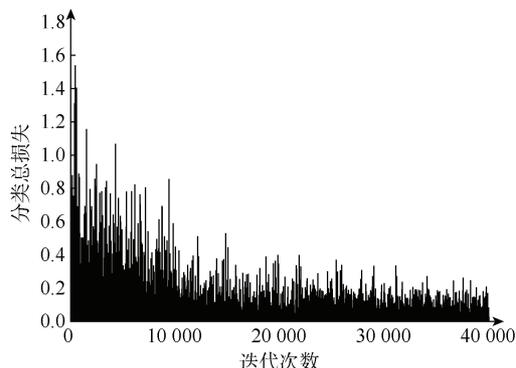


图 5 Faster-RCNN 神经网络训练次数与分类总损失

Fig. 5 Line chart for total classification loss with the number of iterations in Faster R-CNN

为完成 BP 神经网络溢油检测实验,应先确定 BP 神经网络结构。由相关文献可知^[16, 19, 32, 38],需对特征进行特征降维,以减小特征冗余并获取贡献度最大的特征。故本文采用主成分分析方法对提取的 39 个特征进行特征降维,依据特征降维结果选取了贡献度最大的 6 个特征作为 BP 神经网络的输入,这 6 个特征分别为:样本暗斑的面积、周长、暗斑目标与背景方差比值、相关系数、角二阶矩及熵。输出层设置为溢油和疑似溢油两个节点。隐含层层数为 1 层^[39]且隐含层节点个数根据文献[40]中的经验公式及多次样本训练确定本文 BP 神经网络隐含层节点个数为 11 个,文献[40]中的经验公式定义为:

$$n = \sqrt{i_n + o_{ut}} + a, \quad (10)$$

式(10)中, n 为隐层节点个数, i_n 为输入节点个数, o_{ut} 为输出节点个数, a 的取值范围为[1, 10]且 a 为整数。本文使用 trainidx 训练函数对 BP 神经网络进行训练,采用提前停止法防止 BP 神经网络过拟合^[32]。BP 神经网络的训练性能图如图 6 所示,当迭代次数达到 92 次时神经网络收敛,迭代训练停止。

将 VOC 格式测试集中的 SAR 图像样本输入本文溢油检测模型进行验证。将上述特征提取特征及特征选择后的测试集样本输入 BP 神经网络模型进行模型验证。验证集中包含 80 个溢油样本,101 个疑似溢油样本。基于本文 2.1 中的评价方法对本文两种溢油检测模型进行精度评价,评价结果如表 1 所示。由表 1 的评价结果可知,本文方法样本识别率达到

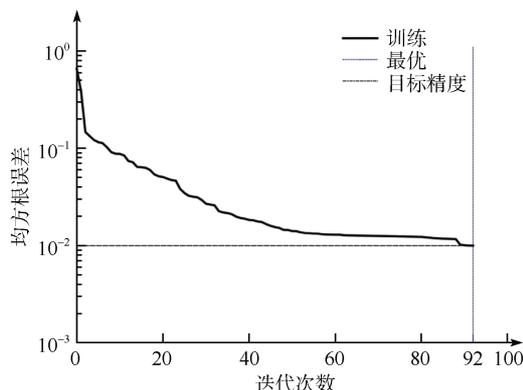


图 6 BP 神经网络训练性能图

Fig. 6 Training performance chart of the BP neural network

了 0.790, 溢油检测率达到了 0.775, 溢油虚警率为 0.244。对比表 1 中两种模型的评价结果可以发现,本文改进的 Faster R-CNN 神经网络溢油检测方法样本识别率提高了 4.4%, 溢油检测率提高了 5%, 溢油虚警率降低了 4.8%。实验结果表明,本文提出方法能对提升溢油检测率、降低溢油虚警率具有一定的效果。

表 1 两种神经网络模型验证结果

Tab. 1 Verification results of the two neural networks

指标	BP 神经网络检测结果	本文方法检测结果
I_R	0.75	0.79
D_R	0.73	0.78
F_{AR}	0.29	0.24

2.3 实例验证

本文获取 2 景中国海域的 SAR 卫星数据,验证两种溢油检测方法。图 7a 为黄海海域南部的 ERS-1 SAR 影像,影像获取日期为 1995 年 6 月 19 日,图 7b 为南海海域的 ERS-2 SAR 影像,获取日期为 1997 年 7 月 13 日。图 7a 和图 7b 中暗斑根据溢油判定规则^[8-9, 16-17]以及文献[19]、[41]中的解译结果对图中的溢油和疑似溢油暗斑进行了标记。图 7a 共解译了 11 个溢油和疑似溢油暗斑,图 7b 共解译了 10 个溢油和疑似溢油暗斑,红色序号标记的暗斑为溢油暗斑,白色序号标记的暗斑为疑似溢油暗斑。除图 7b 序号为 5、9 和 10 暗斑因背景较为复杂需要在绿色框范围进行特征提取外,图 7a 和图 7b 中大部分暗斑独立且易于 BP 神经网络方法特征提取。溢油和疑似溢油暗斑解译结果如图 7 所示。

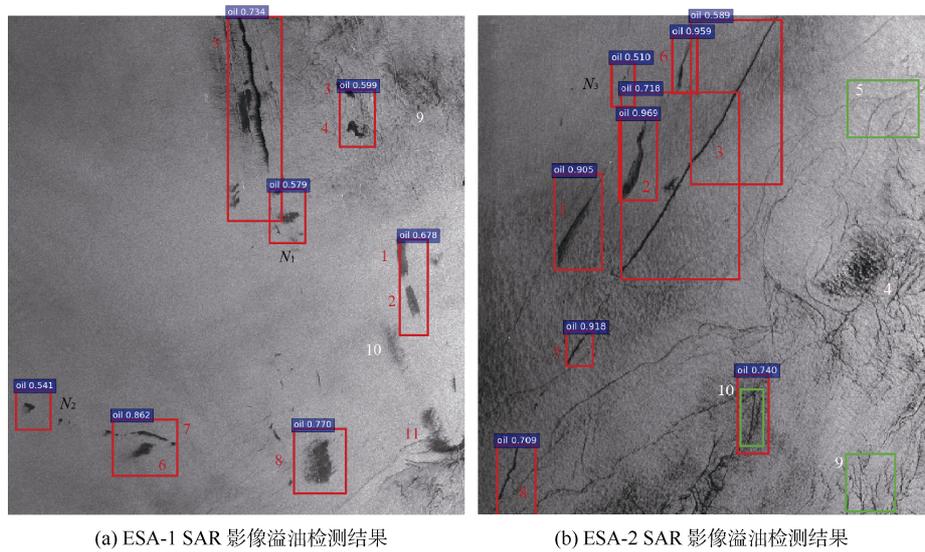


图 7 改进 Faster-RCNN 神经网络模型溢油检测结果
Fig. 7 Oil spill detection results of the improved Faster-RCNN model

图 7 展示了本文改进 Faster R-CNN 神经网络模型在验证图像上的溢油检测结果。图 7a 验证结果表明除序号为 11 的溢油暗斑未被检出, 其他的溢油暗斑均正确检测, 同时检测出了其他未标记的溢油暗斑(N_1 、 N_2), 由文献[41]可知, N_1 、 N_2 两者均为溢油暗斑。图 7a 中 11 个暗斑经人工神经网络方法检测后序号为 1~7 的溢油暗斑被正确检测, 8 号和 11 号溢油暗斑被人工神经网络方法判定为疑似溢油暗斑。观察分析图 7a 中 8 号和 11 号暗斑可知, 两个溢油暗斑与海水的边缘对比度较低, 呈现缓慢过度的趋势, 溢油暗斑与海水边缘的对比程度不如 1~7 号明显, 人工神经网络方法错误地将 8 号和 11 号暗斑检测为疑似溢油暗斑。图 7b 中除 10 号的疑似溢油暗斑被误判为溢油暗斑外, 其余溢油和疑似溢油暗斑均正确检测, 同时也检测出未标记溢油暗斑(N_3)。10 号暗斑与 7 号和 8 号溢油暗斑形状、灰度和纹理特征相似且区分度较低, 导致本文方法误将 10 号疑似溢油暗斑检测为溢油暗斑。图 7b 中 10 个暗斑经人工神经网络方法检测后, 序号为 1、2、3、6、8 的溢油暗斑被正确检测, 5 号疑似溢油暗斑被判定为溢油暗斑, 7 号溢油暗斑被判定为疑似溢油暗斑。5 号疑似溢油暗斑和 7 号溢油暗斑分别与条状溢油暗斑和船舶尾迹暗斑相似, 导致人工神经网络误判。由上述两种方法溢油检测验证结果分析可知, 基于改进 Faster R-CNN 神经网络模型溢油检测结果优于人工神经网络方法, 且能使溢油检测结果可视化。

3 结论

本文选取了 602 个 SAR 溢油和疑似溢油样本, 针对传统特征提取、特征选择过程易受到人为因素影响的问题, 提出了基于改进的 Faster R-CNN 神经网络模型的 SAR 图像溢油检测方法。利用上述样本数据集, 基于神经网络建模方式建立了人工神经网络溢油检测方法。基于测试集对两种方法溢油检测效果进行了客观评价, 评价结果表明: 本文方法相比 BP 神经网络方法样本识别率和溢油检测率分别提高了 4%和 5%, 溢油虚警率降低了 5%。实例验证结果表明, 本文方法能够有效地检测 SAR 图像上的溢油暗斑且可视化程度高, 具有一定的参考和应用价值。

本文尝试使用 Faster R-CNN 神经网络进行溢油检测并提高了 SAR 图像的溢油检测精度, 但本文溢油检测率仍然较低, 方法存在不足: 本文所使用的 SAR 图像溢油和疑似溢油暗斑样本较少, 故在后续工作中需增加样本并对神经网络模型进行训练, 调整溢油和疑似溢油暗斑样本比例, 进行更细致的神经网络参数调节和优化, 进一步对两种溢油检测模型开展分析和评价。此外, 后续工作中将考虑融入环境及位置信息(如风速大小、与陆地的距离等)以提高本文方法的溢油检测精度, 并将其与更多的溢油检测方法进行对比, 进一步验证本文方法的有效性。

参考文献:

- [1] WANG C Y, LI X, GUO J, et al. Biodegradation of marine oil spill residues using aboriginal bacterial consortium based on Penglai 19-3 oil spill accident, China[J]. *Ecotoxicology and Environmental Safety*, 2018, 159(sep): 20-27.
- [2] GUO J, LIU X, XIE Q. Characteristics of the Bohai Sea oil spill and its impact on the Bohai Sea ecosystem[J]. *Chinese Science Bulletin*, 2013, 58(19): 2276-2281.
- [3] LIU X, GUO J, GUO M, et al. Modelling of oil spill trajectory for 2011 Penglai 19-3 coastal drilling field, China[J]. *Applied Mathematical Modelling*, 2015, 39(18): 5331-5340.
- [4] LI X, LI C, YANG Z, et al. SAR imaging of ocean surface oil seep trajectories induced by near inertial oscillation[J]. *Remote Sensing of Environment*, 2013, 130: 182-187.
- [5] ZHANG B, PERRIE W, LI X, et al. Mapping sea surface oil slicks using RADARSAT-2 quad-polarization SAR image[J]. *Geophysical Research Letters*, 2011, 38, L10602.
- [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[M]. New York: IEEE, 2003.
- [7] INDREGARD M, SOLBERG A, CLAYTON P. D2-report on benchmarking oil spill recognition approaches and best practice[R]. European Commission, 2004.
- [8] SOLBERG A H S, DOKKEN S T, SOLBERG R. Automatic detection of oil spills in ENVISAT, RADARSAT and ERS SAR images[C]//IEEE. Piscataway, New Jersey: International Geoscience and Remote Sensing Symposium (IGARSS), 2003: 2747-2749.
- [9] SOLBERG A H S, STORVIK G, SOLBERG R, et al. Automatic detection of oil spills in ERS SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1999, 37(4): 1916-1924.
- [10] 孙元芳, 周斌, 盖颖颖, 等. 遥感监测墨西哥湾溢油目标识别算法[J]. *测绘科学*, 2015, 40(3): 63-67, 106.
SUN Yuanfang, ZHOU Bin, GAI Yingying, et al. Extraction algorithm of oil spill cases in Gulf of Mexico with RS data[J]. *Science of Surveying and Mapping*, 2015, 40(3): 63-67, 106.
- [11] MARGHANY M. RADARSAT for oil spill trajectory model[J]. *Environmental Modelling & Software*, 2004, 19(5): 473-483.
- [12] MARGHANY M. RADARSAT automatic algorithms for detecting coastal oil spill pollution[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2001, 3, 191-196.
- [13] 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.
- [14] 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.
DING Xintao, ZENG Kan, HE Mingxia. A Bagging-Ada Boost-DT multiple classifier system based on SAR image for marine oil spill automatic detection[J]. *Periodical of Ocean University of China*, 2018, 48(10): 132-142.
- [15] 施永春. 基于 Adaboost 的 SAR 图像溢油检测[J]. *电脑知识与技术*, 2011, 7(29): 7252-7254.
SHI Yongchun. Using Adaboost to detect oil spill in SAR images[J]. *Computer Knowledge and Technology*, 2011, 7(29): 7252-7254.
- [16] SINGHA S, BELLERBY T J, TRIESCHMANN O. Satellite oil spill detection using artificial neural networks[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2013, 6(6): 2355-2363.
- [17] SINGHA S, RESSEL R, VELOTTO D, et al. A combination of traditional and polarimetric features for oil spill detection using TerraSAR-X[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, 9(11): 4979-4990.
- [18] SINGHA S, VESPE M, TRIESCHMANN O. Automatic Synthetic Aperture Radar based oil spill detection and performance estimation via a semi-automatic operational service benchmark[J]. *Marine Pollution Bulletin*, 2013, 73(1): 199-209.
- [19] 石立坚, 赵朝方, 刘朋. 基于纹理分析和人工神经网络的 SAR 图像中海面溢油识别方法[J]. *中国海洋大学学报*, 2009, 39(6): 1269-1274.
SHI Lijian, ZHAO Chaofang, LIU Peng. Oil spill identification in marine SAR images based on texture feature and artificial neural network[J]. *Periodical of Ocean University of China*, 2009, 39(6): 1269-1274.
- [20] 张银松, 赵银娣, 袁慕策. 基于改进 Faster-RCNN 模型的粘虫板图像昆虫识别与计数[J]. *中国农业大学学报*, 2019, 24(5): 115-122.
ZHANG Yinsong, ZHAO Yindi, YUAN Muce. Insect identification and counting based on an improved Faster-RCNN model of the sticky board image[J]. *Journal of China Agricultural University*, 2019, 24(5): 115-122.
- [21] 张文达, 许悦雷, 倪嘉成, 等. 基于多尺度分块卷积神经网络的图像目标识别算法[J]. *计算机应用*, 2016,

- 36(4): 1033-1038.
ZHANG Wenda, XU Yuelei, NI Jiancheng, et al. Image target recognition method based on multi-scale block convolutional neural network[J]. *Journal of Computer and Applications*, 2016, 36(4): 1033-1038.
- [22] 田壮壮, 占荣辉, 胡杰民, 等. 基于卷积神经网络的 SAR 图像目标识别研究[J]. *雷达学报*, 2016, 5(3): 320-325.
TIAN Zhuangzhuang, ZHAN Ronghui, HU Jiemin, et al. SAR ATR based on convolutional neural network[J]. *Journal of Radars*, 2016, 5(3): 320-325.
- [23] 黄洁, 姜志国, 张浩鹏, 等. 基于卷积神经网络的遥感图像舰船目标检测[J]. *北京航空航天大学学报*, 2017, 43(9): 1841-1848.
HUANG Jie, JIANG Zhiguo, ZHANG Haopeng, et al. Ship detection in remote sensing images using convolutional neural network[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2017, 43(9): 1841-1848.
- [24] 林刚, 王波, 彭辉, 等. 基于改进 Faster-RCNN 的输电线巡检图像多目标检测及定位[J]. *电力自动化设备*, 2019, 39(5): 213-218.
LIN Gang, WANG Bo, PENG Hui, et al. Multi-target detection and location of transmission line inspection image based on improved Faster-RCNN[J]. *Electric Power Automation Equipment*, 2019, 39(5): 213-218.
- [25] 张中宝, 王洪元, 张继, 等. 基于 Faster-RCNN 的遥感图像飞机检测算法[J]. *南京师大学报(自然科学版)*, 2018, 41(4): 79-86.
ZHANG Zhongbao, WANG Hongyuan, ZHANG Ji, et al. Airplane detection in remote sensing image based on Faster-RCNN algorithm[J]. *Journal of Nanjing Normal University(Natural Science Edition)*, 2018, 41(4): 79-86.
- [26] YANG J F, WAN J H, MA Y, et al. Oil spill hyperspectral remote sensing detection based on DCNN with multi-scale features[J]. *Journal of Coastal Research*, 2019, 90: SI, 332-339.
- [27] GUO H, WU D, AN J. Discrimination of oil slicks and lookalikes in polarimetric SAR images using CNN[J]. *Sensors*, 2017(17), 1837.
- [28] NIETO-HIDALGO M, GALLEGO A J, GIL P, et al. Two-stage convolutional neural network for ship and spill detection using SLAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(9): 5217-5230.
- [29] 杜伟娜. 基于恒虚警率和几何特征的 SAR 影像海洋溢油检测方法研究[D]. 阜新: 辽宁工程技术大学, 2015.
DU Weina. Research on marine oil spill detection method using SAR image based on CFAR and geometric features[D]. Fuxin: Liaoning Technical University, 2015.
- [30] TZUTALIN. LabelImg. Git code. [CP/OL]. [2018-04-18]. <https://github.com/tzutalin/labelImg>.
- [31] EVERINGHAM M, VAN GOOL L, WILLIAMS C K I, et al. The Pascal visual object classes (VOC) challenge[J]. *International Journal of Computer Vision*, 2010, 88: 303-338.
- [32] 朱宗斌. SAR 海洋溢油监测多源信息融合研究[D]. 青岛: 中国海洋大学, 2015.
ZHU Zongbin. Study of multi-source information fusion on SAR ocean oil spill detection[D]. Qingdao: Ocean University of China, 2015.
- [33] HU M K. Visual pattern recognition by moment invariants[J]. *Information Theory*, 1962, 8(2): 179-187.
- [34] 洪继光. 灰度-梯度共生矩阵纹理分析方法[J]. *自动化学报*, 1984, 10: 2225.
HONG Jiguang. Gray level-gradient cooccurrence matrix texture analysis method[J]. *Acta Automatica Sinica*, 1984, 10: 2225.
- [35] 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: 1137-1149.
- [36] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[C]// BENGIO Y, LECUN Y. *International Conference on Learning Representations*. Lille, France: University of Oxford, 2015: 1-14.
- [37] BODLA N, SINGH B, CHELLAPPA R, et al. Soft-NMS - Improving object detection with one line of code[C] // *IEEE Proceedings of the IEEE International Conference on Computer Vision*. Venice, Italy: IEEE, 2017: 5561-5569.
- [38] 石立坚. SAR 及 MODIS 数据海面溢油监测方法研究[D]. 青岛: 中国海洋大学, 2008.
SHI Lijian. Sea surface oil spill detection method by SAR and MODIS[D]. Qingdao: Ocean University of China, 2008.
- [39] 吴丹妮. 基于 PolSAR 海面溢油和类似溢油区的分类研究[D]. 大连: 大连海事大学, 2018.
WU Danni. Study on discrimination of oil slicks and lookalikes in polarimetric SAR images using CNN[D]. Dalian: Dalian Maritime University, 2018.
- [40] 飞思科技产品研发中心. 神经网络理论与 MATLAB 7 实现[M]. 北京: 电子工业出版社, 2005.
- [41] 王栋. SAR 图像海面溢油检测技术研究[D]. 长沙: 国防科技大学, 2014.
WANG Dong. Study of oil spill detection technology in SAR imagery[D]. Changsha: National University of Defense Technology, 2014.

Oil spill detection method for SAR images based on the improved Faster R-CNN model

ZHANG Tian-long^{1, 2, 3}, GUO Jie^{1, 2, 4}

(1. CAS Key Laboratory of Coastal Environmental Processes and Ecological Remediation, Yantai Institute of Coastal Zone Research, Chinese Academy of Sciences (CAS), Yantai, Shandong 264003, China; 2. Shandong Key Laboratory of Coastal Environmental Processes, Yantai Institute of Coastal Zone Research, CAS, Yantai, Shandong 264003, China; 3. University of Chinese Academy of Sciences, Beijing 100049, China; 4. Center for Ocean Mega-Science, CAS, Qingdao 266071, China)

Received: Apr. 6, 2020

Key words: SAR; Faster R-CNN; oil spill detection; BP neural network

Abstract: Oil spill emergency work needs to detect oil spills accurately in synthetic aperture radar (SAR) images. To reduce the influence of human factors on oil spill detection accuracy in the SAR image feature extraction and selection processes, the Faster R-CNN model is introduced and improved in this study. Because of the various shapes of oil spills and the complex background, the VGG16 convolutional network with consistent structure and strong practicability is selected to obtain the image features. The Soft-NMS algorithm is used to optimize the Faster R-CNN model. On the basis of the same dataset, the most frequently used geometric, gray, and texture features of SAR images were extracted to build the backpropagation (BP) artificial neural network oil spill detection model, which is compared with the method proposed in this study. The experimental results show that the detection rate of the improved Faster R-CNN model is 0.78, and the false alarm rate is lower than 0.25. Compared with the BP artificial neural network method, the identification and detection rates of the improved Faster R-CNN model are increased by 4% and 5%, respectively, and the oil spill false alarm rate is decreased by 5%.

(本文编辑: 丛培秀)