

基于 ResNet-UNet 模型的 SAR 图像海面溢油检测

郭 杜, 杨鹏举

(延安大学 物理与电子信息学院, 陕西 延安 716000)

摘要: 针对合成孔径雷达 (SAR) 图像海面溢油检测问题, 采用 U-Net 模型、ResNet18-UNet 模型、ResNet34-UNet 模型、ResNet50-UNet 模型等 4 种卷积神经网络模型进行了 SAR 图像海面溢油检测的研究与实验, 挑选出更适合此次 SAR 图像海面溢油检测研究与实验的溢油检测模型; 通过利用 4 种卷积神经网络模型对同一数据集进行 SAR 图像海面溢油检测的方式, 对比分析了不同卷积神经网络模型之间的性能差异和溢油检测效果; 实验结果表明, 在此次 SAR 图像海面溢油检测研究与实验中, ResNet18-UNet 模型的性能在 U-Net 模型的基础上有了一定的优化, 而且与另外两种 ResNet-UNet 模型相比, ResNet18-UNet 模型在此次海面溢油检测实验中拥有最高的性能和最好的溢油检测效果, 获得了更高的检测精度和检测效率。

关键词: 合成孔径雷达; 海面溢油检测; 卷积神经网络; U-Net 模型; ResNet-UNet 模型

Detection of Sea Surface Oil Spill in SAR Images Based on ResNet-UNet Model

GUO Du, YANG Pengju

(School of Physics and Electronic Information, Yan'an University, Yan'an 716000, China)

Abstract: Aiming at the problem of oil spill detection in synthetic aperture radar (SAR) images, four convolutional neural network (CNN) models are used to study and test on oil spill detection in SAR images, including U-Net model, ResNet18-UNet model, ResNet34-UNet model, and ResNet50-UNet model. A more suitable mode for oil spill detection was selected for this research and experiment. By using the four CNN models for SAR image sea surface oil spill detection on the same dataset, the performance differences and oil spill detection effects among different CNN models were compared and analyzed. Experimental results show that by using the same SAR dataset for this oil spill detection, the performance of the ResNet18-UNet model has some advantages on the basis of the U-Net model, and compared with the other two ResNet-UNet models, the ResNet18-UNet model has the highest performance and the best oil spill detection effect in the detection experiment, achieving higher detection accuracy and efficiency.

Keywords: SAR; detection of sea surface oil spill; CNN; U-Net model; ResNet-UNet model

0 引言

当今世界, 各种清洁能源不断被发现, 但世界各国对石油资源依然有很强的依赖性, 人们日常生活中的很多地方都离不开石油。随着人们对石油资源的需求日益增大, 陆地上的石油资源逐渐被开发完毕, 于是人们将目光投向了尚未开发的海洋, 以满足人们的生活所需。然而海洋上方气候多变、海面风浪不断、危险难以预测, 这对石油的开采和运输会产生巨大的威胁, 因此在海洋石油开采和运输的过程中, 时常会发生海面溢油事

件, 海面溢油不仅破坏了海洋生态环境、影响了海洋经济, 还严重威胁着人民群众的生命财产安全。

为了避免海面溢油事故^[1]发生后, 溢油油膜对海洋造成过大的影响和破坏, 学者们利用各种各样的监测方法进行海面溢油监测^[2], 及时发现并了解海面溢油发生后的各种信息, 为处理海面溢油提供一些准确的数据支持。在现实生活中, 大多数的海面溢油监测都是利用微波遥感技术实现, 而合成孔径雷达技术 (SAR, synthetic aperture radar)^[3-4]作为一种高分辨率、高性能的微波遥感技术, 在海面溢油监测领域被广泛应用。SAR

收稿日期: 2023-12-06; 修回日期: 2024-02-23。

作者简介: 郭 杜 (1997-), 男, 硕士研究生。

杨鹏举 (1984-), 男, 副教授。

引用格式: 郭 杜, 杨鹏举. 基于 ResNet-UNet 模型的 SAR 图像海面溢油检测[J]. 计算机测量与控制, 2025, 33(3): 37-44.

技术不仅可以在变幻莫测的海洋气象下获得较为准确的海面溢油信息,而且可以得到更大的海面溢油监测范围、更迅速的信息传递方式、更加准确的海面溢油数据,同时也可以利用 SAR 图像分析海面溢油油膜的位置、厚度、运动方向等信息,为海面溢油处理工作提供更加合理且准确的数据支持,以便于制定出更加完美的海面溢油处理方案,提升海面溢油事故的处理效率,降低国家损失和环境污染。

自 20 世纪 70 年代开始, SAR 技术就已经被应用于海面溢油检测领域,但当时的 SAR 技术并不成熟,因此海面溢油的检测效率和检测效果并不理想。如今随着科学技术的不断发展, SAR 技术也不断完善,学者们陆续提出了一些具有高效率、高精度等优点的 SAR 图像海面溢油检测方法^[5]进行 SAR 图像海面溢油检测研究,例如完全卷积网络 (FCN, fully convolutional networks)^[6-7]、对象上下文语义分割 (OCR, object-contextual representations)^[8]、DeepLab 系列^[9-10]等。文献 [11] 描述了利用 SAR 图像研究分析了发生在马六甲海峡的特大船舶溢油事故,建立了溢油自动识别模型,同时利用 RADARSAT-1 卫星的图像数据、Fay 改进算法以及 Doppler 频率移动模型模拟了海面溢油油膜的运动轨迹^[11];文献 [12] 也描述了如何利用人工神经网络 (ANN, artificial neural network) 进行了海面溢油的图像分割研究,它不仅在一定程度上提升了图像分割的分割精度,还抑制了斑点噪声在溢油特征提取过程中的负面影响^[12];文献 [13] 和文献 [14] 描述了利用 SAR 图像结合 MODIS 影像分析的方法进行海面溢油检测识别研究,并且在利用 SAR 图像识别海面溢油和疑似溢油的同时,还引入了图像纹理特征参量,建立了区分海面溢油现象和疑似溢油现象的卷积神经网络

模型^[13-14]。

基于卷积神经网络 (CNN, convolution neural network) 的 SAR 图像海面溢油检测方法^[15]在进行海面溢油检测时,会先将海面溢油 SAR 图像以一定的大小划分,再利用 CNN 进行图像分割,提取溢油特征^[16],进而区分溢油与海面,完成对海面溢油的检测。由于不同的卷积神经网络模型对海面溢油的检测效果也有所差异,而 U-Net 模型不仅拥有良好的海面溢油检测效果,还能够表示不同渗入级别的海面溢油。因此,为了找到更适合当前状况的 SAR 图像海面溢油检测模型,本文选择在 U-Net 模型的基础上引入 ResNet 结构的 ResNet18-U-Net 模型、ResNet34-U-Net 模型、ResNet50-U-Net 模型进行 SAR 图像海面溢油检测实验,并与 U-Net 模型的检测结果进行对比、分析。

1 语义分割模型和残差网络

语义分割模型^[18]是在 FCN 模型的基础上,延伸得到的一种基于像素的图像分割模型,而残差网络 (Residual Network, ResNet)^[19]则是在 2015 年提出的一种可以解决深度卷积神经网络训练时出现的梯度消失、梯度爆炸等问题的网络。

1.1 语义分割模型 (U-Net) 基本结构

U-Net 模型是通过对像素点进行精准定位并分类,从而分割特征图,提取目标特征,最终实现高精度的目标检测。U-Net 模型在进行图像分割时,具有更高的图像分割准确率和更快的图像检测速率,因此被广泛应用于图像分割领域的各个方向,U-Net 模型的具体架构如图 1 所示。

图 1 中,实框表示多通道要素图,虚框表示复制的要素图,箭头表示不同操作,方框顶部的数字表示通道数,左下边缘的数字表示 $x \times y$ 的尺寸大小。

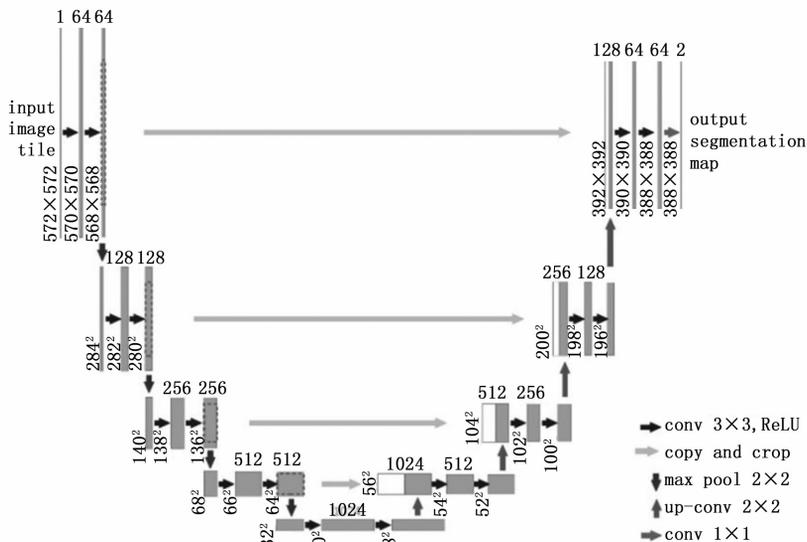


图 1 语义分割 (U-Net) 模型示意图

U-Net 模型的基本架构主要由一个收缩路径和一个与收缩路径对称的扩张路径组成, 而且模型中还引入了跳跃连接, 实现了通道维度上的融和学习 (叠操作), 有效地将低层次和高层次的图像特征进行融合, 进而提升了模型的图像分割精度, 优化了模型的性能。在训练 U-Net 模型时, 一般选择 Caffe 框架的随机梯度下降方法 (SGD, stochastic gradient descent)^[20] 利用输入图像及其相应的分割图完成对卷积神经网络模型的训练。

U-Net 模型在溢油检测训练过程中, 会先将特征图利用模型收缩路径中的下采样进行缩小, 从而挑选出激活程度较大, 忽略相对作用较小且信息冗余的溢油特征, 以提取出图像的浅层特征信息, 紧接着扩展路径会将特征图放大, 达到增大原特征图分辨率的目的, 从而获取图像的深层特征信息, 此时再利用卷积神经网络模型中的跳跃连接结构将提取出的特征信息进行信息融合, 即连接融合溢油图像的浅层特征信息和深层特征信息, 进而提高溢油检测精度, 实现目标的精确定位, 最后对得到的图像信息进行二分类操作, 将输出图像划分为背景区域和溢油区域, 得到海面溢油检测结果。

Caffe 框架的 SGD 传播所需的动量采用交叉熵损失和 Softmax 相结合的形式提供, Softmax 函数表示如下:

$$p_k(x) = \frac{\exp(a_k(x))}{\sum_{k'=1}^K \exp(a_{k'}(x))} \quad (1)$$

式中, $a_k(x)$ 表示每一个像素点 x 对应特征通道 k 的得分, K 表示类数, $p_k(x)$ 表示类 k 的对应像素点 x 的分类结果。

当 k 为具有最大激活 $a_k(x)$ 的 k 时, $p_k(x) \approx 1$; 当 k 为其他值时, $p_k(x) \approx 0$ 。

1.2 残差网络 (ResNet)

从理论上来说, 深度卷积神经网络模型在进行 SAR 图像海面溢油检测实验时, 卷积神经网络模型的网络深度越深, 模型的性能越好, 检测效果也越好。但经过诸多实验之后发现, 当卷积神经网络模型的网络深度达到一定程度后, 继续增加网络模型的深度, 不仅无法获得更优秀的模型性能和更好的海面溢油检测效果, 反而会导致卷积神经网络模型出现网络退化、信息丢失和损耗、梯度消失和梯度爆炸等问题, 使得深层次卷积神经网络模型的海面溢油检测效果变得更差, 模型性能劣化。ResNet 模型在一定程度上解决了这些问题, 大大增加了深度卷积神经网络模型的网络深度, 提升了模型性能。

残差网络本质上是一个不断拟合残差的过程, 它的核心思想是通过在卷积神经网络中增加一些直连通道, 将模型的编码器和解码器直接连接, 让特征矩阵隔层相加, 削弱了层与层之间的联系, 加快了卷积神经网络模型的收敛速度, 也使模型的收敛过程更加平稳。它可以

将输入的图像数据直接绕道传到输出模块, 不仅能够保护特征信息的完整性, 而且可以提高卷积神经网络模型的训练速率, 减少卷积神经网络模型需要的参数量, 提升模型的检测效果和检测精度, 同时也使得卷积神经网络可以构建的更深。

残差网络结构如图 2 所示。

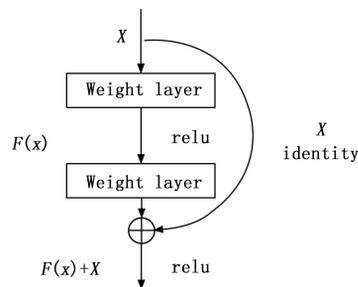


图 2 残差连接示意图

设残差连接的输入输出关系为 $G(X)$, 具体表示如下:

$$G(x) = X + F(X) \quad (2)$$

其中, X 表示输入, $F(X)$ 表示输出, F 表示卷积、激活等操作。

残差模块的输出需要在 $F(x) + X$ 之后再加上 ReLU 激活函数, 才能得到准确的输出结果。而且由于残差连接的 X 和 $G(X)$ 可能存在维度差异, 所以残差网络首先会对 X 进行卷积运算, 具体表示如下:

$$G(x) = h(X) + F(X) \quad (3)$$

其中: h 表示卷积运算。

与普通卷积神经网络模型的串行结构相比, ResNet 模型中增加了能将输入和输出直接相加的跳跃映射结构, 这种结构不仅使模型在训练时获得的数据更加完整, 而且令卷积神经网络模型的训练效率更高、检测效果更好, 极大程度上提升了卷积神经网络模型的性能。

2 ResNet-UNet 模型

ResNet-UNet 模型^[17]是由 U-Net 模型和 ResNet 模型组成, 它结合了两种卷积神经网络模型的优点, 能更有效地捕捉 SAR 图像中局部和全局的目标特征, 进而提升了模型分割图像和提取目标特征的效率, 使模型得到了优化。此模型在各种图像分割任务中都表现出了优越的性能。

2.1 ResNet18-UNet 模型的基本结构

ResNet18-UNet 模型是在 U-Net 模型的基础上引入了 ResNet18 结构, 即将 ResNet18 作为模型的编码路径替换掉 U-Net 模型的原始编码结构。ResNet18-UNet 模型在进行 SAR 图像海面溢油检测仿真实验时, 不仅能够通过编码器和解码器中包含的多个残差连接更好地提取图像的浅层信息和深层信息, 还可以利用残差连接

缓解模型训练过程中出现的语义信息缺失问题和梯度消失等问题，从而提高图像分割的准确率，使得模型在进行图像分割任务时拥有更好的性能表现。

本研究选择的深度卷积神经网络模型是采用 Res-Net18 替代 U-Net 模型的原始编码路径结构作为特征提取前端，同时利用 U-Net 模型的解码路径作为模型后端网络的 ResNet18-UNet 模型，进行 SAR 图像海面溢油检测模拟仿真。ResNet18 的网络深度为 18 层，即包含了 18 个卷积层，属于一种并不太深的深度卷积神经网络。与普通的卷积神经网络相比，ResNet18 每两层之间都会增加一个短路机制，这个短路机制使得卷积神经网络模型在提取溢油特征时，可以进行两层之间残差学习，图中的虚线表示特征图中的维度（通道数）发生了改变，ResNet18 的主干网络结构图如图 3 所示。

从 ResNet18 中选择一个两层的残差单元，令 α_i 表示残差单元的第一层输入， α_{i+2} 表示残差单元的第二层输出， $F(n_i)$ 则表示 n_i 在经过一个完整残差单元之后得到的输出， $Relu(n) = \max(n, 0)$ 表示激活函数。此时，输出 $F(n_i)$ 表示如下：

$$F(n_i) = \alpha_{i+2} =$$

$$Relu[W_{i+2} * Relu(W_{i+1} * \alpha_i + b_{i+1}) + b_{i+2}] + \alpha_i \quad (4)$$

当残差单元扩展为多个时，令 n_L 表示第 L 层的残差单元的输出，具体表示如下：

$$n_L = n_i + \sum_{i=1}^{L-1} F(n_i, \omega_i) \quad (5)$$

在模型训练过程中，图像数据会有一个反向传播过程，此时恒等映射 $identity = x$ ，模型训练的损失值在某一卷积层的梯度表示如下：

$$\frac{\partial loss}{\partial n_i} = \frac{\partial loss}{\partial n_L} \cdot \frac{\partial n_L}{\partial n_i} = \frac{\partial loss}{n_L} \left[1 + \frac{\partial}{\partial n_i} \sum_{i=1}^{L-1} F(n_i, \omega_i) \right] \quad (6)$$

式中，1 表示上一层的输入被无损的传输到下一层， $\frac{\partial}{\partial n_i} \sum_{i=1}^{L-1} F(n_i, \omega_i)$ 表示卷积神经网络各层权重对输出的影响。

假设模型在传递数据时，再乘以权重矩阵，则有 $i-identity = \lambda x$ ，梯度表示变为：

$$\frac{\partial loss}{\partial n_i} = \frac{\partial loss}{\partial n_L} \cdot \frac{\partial n_L}{\partial n_i} = \frac{\partial loss}{n_L} \left[\left(\prod_{i=1}^{L-1} \lambda_i \right) x_i + \frac{\partial}{\partial n_i} \sum_{i=1}^{L-1} F(n_i, \omega_i) \right] \quad (7)$$

根据公式可以看出，随着卷积神经网络深度的加深，网络有很大的可能出现梯度爆炸或梯度消失的情况。因此，为了避免模型训练过程出现问题，在传输图像数据时，采用恒等映射 $identity = x$ 直接传递必不可少。

ResNet18-UNet 模型在训练过程中，首先会将输入

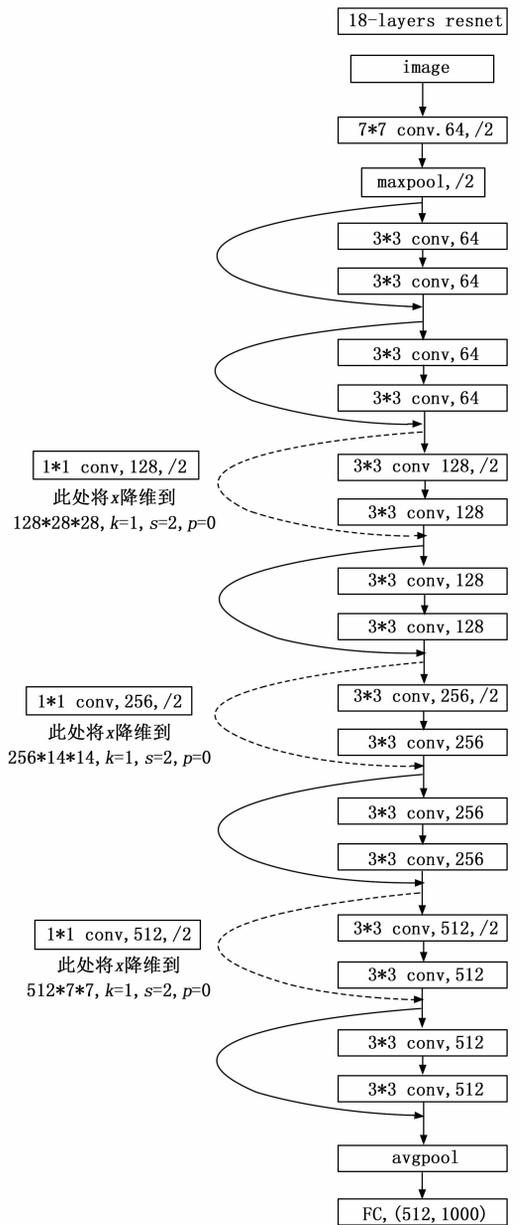


图 3 ResNet18 的主干网络结构图

的图像数据传输到卷积神经网络模型的特征提取前端，即神经网络的编码路径 ResNet18，在进入编码路径后，图像数据会进入卷积核大小为 7×7 的独立卷积结构，然后通过批量归一化处理、激活函数以及最大池化层的下采样过程处理特征图，紧接着再利用添加了残差结构的卷积模块提取海面溢油 SAR 图像的浅层数据至深层数据，并将溢油图像的浅层特征信息和深层特征信息进行特征信息的融合，同时将融合后的溢油特征信息传输到平均池化层处理，之后将得到的图像输入到全连接层，再通过分类器对图像进行二分类，区分背景和溢油，最后输出得到的 SAR 图像海面溢油检测结果，完成 SAR 图像海面溢油检测实验。

2.2 ResNet18-UNet 模型的损失函数

在卷积神经网络模型中, 损失函数可以用来表示模型预测值与真实值之间的差异程度, 是一种非负实值函数。因此, 卷积神经网络模型损失函数的值越小, 海面溢油检测模型的训练效果越好, 鲁棒性越强, 检测精度越高, 溢油检测效果和模型性能也越好。本研究选用了二进制交叉熵损失函数 (BCE, binary cross-entropy)、骰子损失 (DL, dice loss)、Focal Tversky Loss (FT) 等 3 种损失函数用来反映模型的 SAR 图像海面溢油检测效果。

交叉熵损失函数 (Cross-Entropy Loss) 本质上是基于最小化像素的方向误差, 它能够计算出给定随机变量的两个概率分布之间的差异, 但这种方式也会导致模型训练过程中, 过度表示损失中较大的对象, 忽略较小和信息冗余的对象。

对于二进制分类, 二进制交叉熵损失函数 (BCE, binary cross-entropy)^[21] 表示如下:

$$L_{\text{BCE}}(y, \hat{y}) = -[y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})] \quad (8)$$

式中, $y, \hat{y} \in (0, 1)^N$, \hat{y} 表示模型的预测值, y 表示模型的真值标签。

骰子损失 (DL, dice loss)^[22] 最初被用来评估分割图的重叠指数, 即表示分割图之间的相似程度, 后来被改编为损失函数, 广泛应用于深度学习领域。具体表示如下:

$$DL(y, \hat{p}) = 1 - \frac{2y\hat{p} + 1}{y + \hat{p} + 1} \quad (9)$$

式中, 分数的分子和分母上的 1 是为了确保函数在边缘的情况下不会未定义。

Focal Tversky Loss (FT)^[23] 通过参数 γ 降低易于分类的区域的权重, 令较难分类的区域的 Tversky loss 得到调整, 具体表示如下:

$$L_{\text{FT}} = \sum_c (1 - TI)^{1/\gamma} \quad (10)$$

$$TI = \frac{\sum_{i=1}^N p_{0i} g_{0i}}{\sum_{i=1}^N p_{0i} g_{0i} + \frac{7}{10} \sum_{i=1}^N p_{0i} g_{1i} + \frac{3}{10} \sum_{i=1}^N p_{1i} g_{0i}} \quad (11)$$

式中, $\gamma \in [1, 3]$, TI 表示 Tversky Index, p_{0i} 表示像素 i 为前景类的概率, p_{1i} 为像素 i 为背景类概率。

同时, 为了提升模型的检测效率和检测精度, 获得更好的检测效果, 会采用优化算法对模型进行一定程度的优化提升, 本研究选用的优化算法为自适应矩估计 (Adam, adaptive moment estimation)^[24] 优化算法, 它可以利用梯度的一阶矩估计和二阶矩估计动态调整各个参数的学习率, 从而获得了更快的收敛速度和更平稳的收敛过程, 进而使卷积神经网络模型得到了最佳的模型

性能和溢油检测效果。

2.3 ResNet34-UNet 模型和 ResNet50-UNet 模型

ResNet34-UNet 模型和 ResNet50-UNet 模型与 ResNet18-UNet 模型的基本原理和基本结构大体相同, 最大的区别就是神经网络的层数不同, 但它们都是通过残差结构使模型的可以构建的更深, 然而网络层数少的卷积神经网络和网络层数多的卷积神经网络所使用的残差结构也不相同, ResNet18 和 ResNet34 属于网络层数较少的卷积神经网络, 它们的残差结构如图 4 所示。

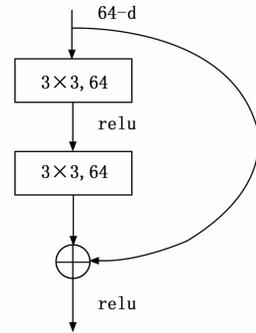


图 4 ResNet18 和 ResNet34 的残差结构示意图

适用于网络层数少的残差结构主要有两层 3×3 的卷积层组成, 它是能将输入和输出直接相加的跳跃映射结构。

而 ResNet50-UNet 属于网络层数多的卷积神经网络, 它的残差结构有一些差异, 具体如图 5 所示。

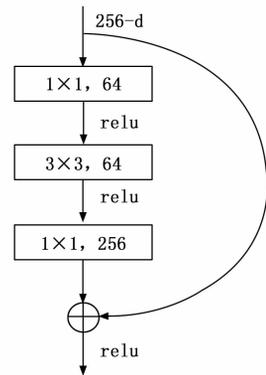


图 5 ResNet50 的残差结构示意图

图 5 的残差结构发挥作用时, 首先会使用 1×1 卷积降低特征通道数, 使用 3×3 卷积完成特征提取, 然后再使用 1×1 卷积增加特征通道数, 这种结构可以使深层的卷积神经网络减少计算量和参数量。

3 SAR 图像海面溢油检测模拟仿真实验、结果与分析

本研究选用的卷积神经网络模型是结合了残差网络 ResNet 和 U-Net 模型两者优点的 ResNet-UNet 网络模

型。实验不仅进行了 SAR 图像海面溢油检测实验的模拟仿真, 还将 U-Net 模型、ResNet18-UNet 模型、ResNet34-UNet 模型、ResNet50-UNet 模型等 4 种卷积神经网络模型的海面溢油检测结果进行对比, 进而分析卷积神经网络模型的海面溢油检测效果和模型性能, 挑选出更适合当下情况的溢油检测模型。

3.1 实验方法和实验数据

在 SAR 图像海面溢油检测实验过程中, 使用电脑的操作系统为 Window11 系统, 电脑硬件配置如下: 处理器为 Core (TM) i9-13900HX 2.20 GHz, 运行内存为 16 GB, 电脑搭载的显卡为 NVIDIA GeForce RTX 4060 Ti 显卡, 能够大幅度提升模型的训练速率。卷积神经网络模型运行的软件环境是基于 Anaconda3 和 Jupyter Notebook 软件平台, 通过 Pytorch 深度学习框架搭建并运行, 并行计算框架的 CUDA 版本为 CUDA11.8。

在进行 SAR 图像海面溢油检测仿真实验时, 为了提升溢油检测模型的检测效率和检测效果, 溢油图像数据在进入卷积神经网络之前会进行图像预处理, 而且卷积神经网络模型最终的溢油检测精度与模型中各项参数的具体数值也有密切的联系。一般来说, 在一定范围内, 模型训练的次数越多, 模型的溢油检测精度也越高, 但超出这个范围之后, 模型的检测精度就不会发生太大的变化。因此, 出于对模型训练效率和训练所需时间的考虑, 在本研究中, 溢油检测模型的总迭代次数设置为 90, 步长设置为 30, 单次传递数据的批量大小设置为 16。

3.2 数据集预处理

一个高精度、高性能的 SAR 图像海面溢油检测模型是需要通过运用大量数据对模型进行训练然后得到, 然而本研究选用的数据集是一个极小的 SAR 图像海面溢油数据集, 它仅仅包含了 790 张海面溢油 SAR 图像, 如果想要训练出一个检测精度高和检测效果良好的 SAR 图像海面溢油检测模型, 这个数据集的数据量还远远不够。因此, 在进行 SAR 图像海面溢油检测仿真实验时, 首先会对溢油数据集进行数据增强, 即随机将每张海面溢油 SAR 图像及其掩膜图像进行平移、翻转、镜像、等比例缩放等操作, 从而获得更多的海面溢油图像数据, 扩充数据集。而且增加数据集中包含的数据量还可以提高模型的泛化能力和鲁棒性、提升模型的性能、扩大应用范围。在海面溢油 SAR 图像数据集中, 80% 属于训练数据, 它是用于训练卷积神经网络模型的数据, 10% 是验证数据, 作用是验证模型的有效性, 评估模型的性能和调整超参数, 10% 是测试数据, 测试数据仅仅用来测试模型的训练效果, 评价模型的泛化能力。海面溢油 SAR 图像数据集的部分原始图像如图 6 所示。

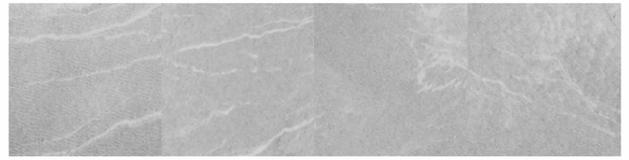


图 6 部分海面溢油原始图像

3.3 SAR 图像海面溢油检测仿真

在模型构建完成之后, 将海面溢油 SAR 图像数据集的训练数据分别输入到 U-Net、ResNet18-UNet、ResNet34-UNet、ResNet50-UNet 四种卷积神经网络模型中, 进行 SAR 图像海面溢油检测训练, 经过多次迭代训练之后, 得到了海面溢油检测效果良好的溢油检测模型, 接着利用数据集的验证数据和测试数据进行 SAR 图像海面溢油检测仿真实验, 测试模型的海面溢油检测效果, 评估模型的性能, 最终得到的 SAR 图像海面溢油检测结果如图 7 所示。相较于原始的海面溢油 SAR 图像, U-Net 模型和 ResNet-UNet 模型会对原始图像进行图像分割操作, 提取海面溢油特征, 再经过二分类, 最终将海面溢油 SAR 图像上面的区域划分为无溢油区域和有溢油区域, 输出海面溢油检测结果。

图 7 (a) 表示基于 U-Net 模型的 SAR 图像海面溢油检测结果。根据图像可以看出, 基于 U-Net 模型的 SAR 图像海面溢油检测模型对海面溢油有良好的检测效果, 能够准确地检测出海面溢油区域, 并获得溢油油膜的一些基本信息。但仔细观察可以发现, 同一图像中不同区域的溢油检测效果存在一些差异, U-Net 模型对海面溢油油膜集中、溢油特征明显的溢油区域明显拥有更好的溢油检测效果, 而对那些溢油特征较模糊、油膜较薄且扩散范围较大的溢油区域的溢油检测效果并不理想, 这是由于 U-Net 模型在溢油检测过程中存在对图像中较大的对象过渡表示, 并且忽略较小对象的问题。

图 7 (b)、(c)、(d) 分别表示 3 种 ResNet-UNet 模型的 SAR 图像海面溢油检测结果, 它们分别是 ResNet18-UNet 模型、ResNet34-UNet 模型、ResNet50-UNet 模型。根据图像可以看出, ResNet-UNet 模型不仅能够准确的检测出溢油海面中的溢油所在区域, 提取出海面溢油的溢油特征, 而且对于那些溢油特征较模糊、油膜较薄且扩散范围较大的区域的海面溢油油膜也有一定的检测效果, 能够获得更多、更细致海面溢油特征。

根据上述分析可以知道, 4 种溢油检测模型都具有良好的海面溢油检测效果, 都可以准确的判断出海面溢油所在区域, 并提取溢油特征。但通过仔细对比图 7 可以明显发现, 相较于 U-Net 模型, ResNet-UNet 模型拥有更加优秀的溢油检测效果, 而图 7 (b)、图 7 (c)、图 7 (d) 之间并没有特别明显的差异。

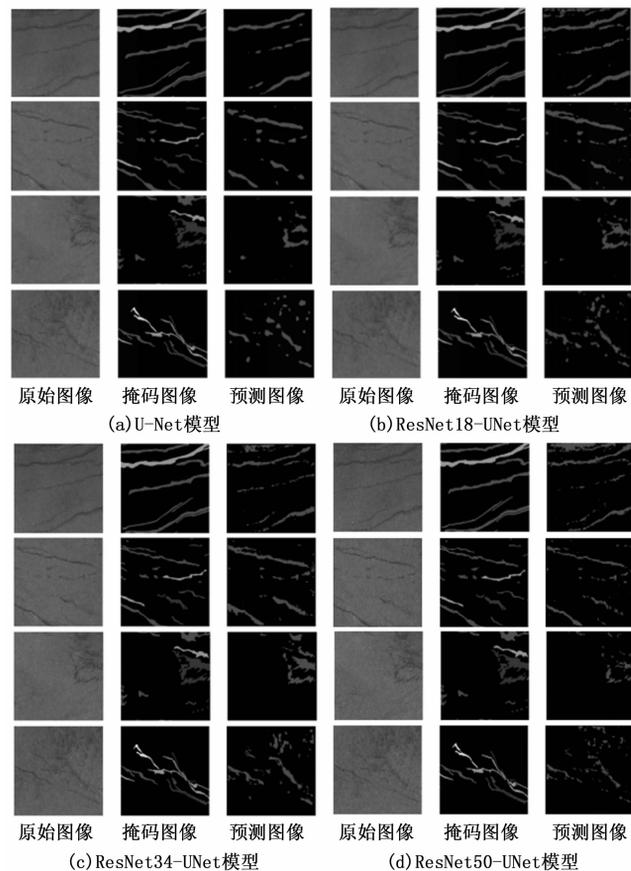


图 7 基于卷积神经网络的 SAR 图像海面溢油检测结果

ResNet-UNet 模型在进行 SAR 图像海面溢油检测实验时, 不仅可以检测出溢油油膜较小且较薄区域的海面溢油, 从而获得更多的海面溢油信息, 而且模型所提取的海面溢油边缘特征也更加细致, 轮廓更加清晰, 使得可以更准确地判断海面溢油的扩散范围。这代表了 ResNet-UNet 模型在 U-Net 模型的基础上有了优化, 它在一定程度上解决了 U-Net 模型在溢油检测实验时, 存在的对图像中较大的对象过渡表示, 忽略了较小对象的问题, 提升了模型的检测精度。

3.4 结果分析

根据上述讨论的结果, 同时仔细对比图 7 的预测图像可以清晰的发现, 虽然 U-Net 模型和 ResNet-UNet 模型最终检测到的溢油区域基本相同, 但 ResNet-UNet 模型不仅可以检测出更多、更细微的溢油区域, 而且模型检测时, 提取出的溢油特征也更精确, 轮廓更加细致, 并且 3 种 ResNet-UNet 模型的溢油检测图像并没有特别大的差异。为了进一步判断出 U-Net 模型、ResNet18-UNet 模型、ResNet34-UNet 模型、ResNet50-UNet 模型等 4 种卷积神经网络模型的 SAR 图像海面溢油检测效果的优劣程度, 同时深入对比 4 种卷积神经网络模型之间的性能差异, 本文选用了 3 种损失函数用来

表示模型的检测效果, 结果如表 1 所示。

表 1 损失函数和训练时间对比

模型	BCE	Dice	FT	训练时间/min
U-Net	0.413	8.029	7.307	26
ResNet18-UNet	0.400	7.392	6.446	11
ResNet34-UNet	0.471	7.678	6.822	8
ResNet50-UNet	0.48	8.103	7.39	9

由于卷积神经网络模型的损失函数能够用来估量模型预测值与真实值的不一致程度, 即损失函数的值能够在一定程度上反映 SAR 图像海面溢油检测的精确程度, 因此本研究利用损失函数从侧面表示模型的海面溢油检测效果和性能。根据表 1 可以看出, 此时 ResNet18-UNet 模型的 BCE Loss、Dice Loss、Focal Tversky Loss 等损失函数的值都是最小的, 这代表了在这 4 种溢油检测模型中 ResNet18-UNet 模型的鲁棒性最强, 检测精度最高, 模型性能最好。并且与 U-Net 模型相比, ResNet18-UNet 模型在训练过程中, BCE Loss 的值由 0.413 减小到了 0.400, Dice Loss 的值由 8.029 减小到了 7.392, Focal Tversky Loss 的值也由 7.307 减小到了 6.446, 而且 ResNet18-UNet 模型训练所耗费的时间也仅需 11 分钟, 比起 U-Net 模型训练所耗费的时间减少了 15 分钟, 是 U-Net 模型训练时间的 42%, 这也代表了 ResNet18-UNet 模型的预测值与真实值的不一致程度有所减小, 鲁棒性变强, 检测精度提升, 性能变强, 同时模型的检测效率也获得了提升。因此, 在当前的条件下, 在 U-Net 模型的基础上引入 ResNet18 的 ResNet18-UNet 模型更适合此次 SAR 图像海面溢油检测, 它具有更高的检测效率和更好的检测效果, 溢油检测模型的性能在一定程度上得到了提升。

4 结束语

本文基于 ResNet18-UNet 模型展开了 SAR 图像海面溢油检测的研究与实验, 分析了 U-Net 模型、ResNet18-UNet 模型、ResNet34-UNet 模型、ResNet50-UNet 模型的溢油检测结果, 比较了 4 种溢油检测模型之间的性能差异。通过对比 ResNet18-UNet 模型和 U-Net 模型的 SAR 图像海面溢油检测结果, 可以清晰的看出 ResNet18-UNet 模型在进行 SAR 图像海面溢油检测模拟仿真时, 不仅能够检测出更多、更细微的溢油区域, 提取出更精确的溢油特征, 而且 ResNet18-UNet 模型的 BCE Loss、Dice Loss、Focal Tversky Loss 等损失函数的值和训练所耗费时间分别降低到了 U-Net 模型的 96.85%、92.07%、88.22%、42%, 这代表了 ResNet18-UNet 模型可以在更短的时间内获得更多、更精确的海面溢油数据。据此可以判断, 在 U-Net 模型中引入 ResNet18 模型能够很好地提升模型的检测效率

与检测精度, 获得更加良好的 SAR 海面溢油检测效果和更加全面、准确的海面溢油数据, 更好的为处理海面溢油事故提供数据支持。再对 ResNet18-UNet 模型、ResNet34-UNet 模型、ResNet50-UNet 模型等 3 种模型的 SAR 图像海面溢油检测结果进行分析可以知道, 虽然 ResNet34-UNet 模型、ResNet50-UNet 模型是更深层的卷积神经网络, 理论上拥有更高的检测精度和检测效率, 但由于条件限制, 两种模型的海面溢油检测效果并不理想, 而 ResNet18-UNet 模型具有更高的检测效率和更好的检测效果。因此, ResNet18-UNet 模型更适用于此次的 SAR 图像海面溢油检测的研究与实验。由于本文所选用的数据集比较小, 数据量不足, 再加上其他条件的限制, 最终导致 ResNet34-UNet 模型和 ResNet50-UNet 模型在此次的 SAR 图像海面溢油检测的研究与实验中的性能表现并不理想, 因此本文下一步将考虑采用数据量充足的数据集和优越的基础设施进行 SAR 图像海面溢油检测研究, 充分展示 ResNet34-UNet 模型和 ResNet50-UNet 模型的优越性能, 同时选用更深的 ResNet-UNet 模型进行 SAR 图像海面溢油检测研究, 从而获得更多、更准确地海面溢油数据。

参考文献:

- [1] 李纯军. 海洋石油溢油探测与处理技术进展 [J]. 油气田环境保护, 2022, 32 (3): 52-57.
- [2] 任慧敏, 宋冬梅, 王 斌. 基于新极化特征参数的 SAR 海洋溢油检测 [J]. 遥感技术与应用, 2020, 35 (4): 934-942.
- [3] 李 煜, 陈 杰, 张渊智. 合成孔径雷达海面溢油探测研究进展 [J]. 电子与信息学报, 2019, 41 (3): 751-762.
- [4] 黄旭东. 星载合成孔径雷达海洋溢油智能探测研究 [D]. 南京: 南京信息工程大学, 2022.
- [5] 陈 韩, 谢 涛, 方 贺. 基于 SAR 极化比和纹理特征的海面溢油识别方法 [J]. 海洋学报, 2019, 41 (9): 181-190.
- [6] 李梦怡, 朱定局. 基于全卷积网络的图像语义分割方法综述 [J]. 计算机系统应用, 2021, 30 (9): 41-52.
- [7] 杜艳玲, 崔建华, 魏泉苗. 基于改进 FCN 的多极化 SAR 影像海上溢油检测 [J]. 激光与光电子学进展, 2022, 59 (4): 321-328.
- [8] 胡朝阳. 基于深度网络的上下文语义分割算法研究 [D]. 武汉: 华中科技大学, 2019.
- [9] 王云艳, 罗冷坤, 王重阳. Deeplab 网络的极化合成孔径雷达图像分类 [J]. 测绘科学, 2020, 45 (6): 110-117.
- [10] 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.
- [11] MARGHANY M. RADARSAT for oil spill trajectory model [J]. Environmental Modelling and Software, 2004, 19 (5): 473-483.
- [12] SINGHA S, BELLERBY J T, 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.
- [13] 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.
- [14] 梁小祎. 基于纹理分析的溢油 SAR 图像分类研究 [D]. 大连: 大连海事大学, 2007.
- [15] 魏 帆. 基于 Segnet 的 SAR 图像海面溢油暗斑检测 [D]. 大连: 大连海事大学, 2019.
- [16] 邢孟道, 谢意远, 高悦欣. 电磁散射特征提取与成像识别算法综述 [J]. 雷达学报, 2022, 11 (6): 921-942.
- [17] DROZDZAL M, VORONTSOV E, CHARTRAND G. The importance of skip connections in biomedical image segmentation [R]. Athens: International Workshop on Large-Scale Annotation of Biomedical Data and Expert Label Synthesis, 2016: 179-187.
- [18] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation [R]. Munich: International Conference on Medical Image Computing and Computer-Assisted Intervention, 2015: 234-241.
- [19] HE K, ZHANG X, REN S. Deep residual learning for image recognition [C] // Las Vegas: 2016 IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [20] JIA Y, SHELLHAMER E, DONAHUE J, et al. Caffe: convolutional architecture for fast feature embedding [C] // Orlando Florida: Proceedings of the 22nd ACM International Conference on Multimedia, 2014: 675-678.
- [21] XIE Z, HUANG Y, ZHU Y. Aggregation cross-entropy for sequence recognition [C] // Long Beach: 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019: 6531-6540.
- [22] H C S, WENQI L, TOM V. Generalised dice overlap as a deep learning loss function for highly unbalanced segmentations [R]. Québec City: International Workshop on Multimodal Learning for Clinical Decision Support, 2017: 240-248.
- [23] NABILA ABRAHAM, NAIMUL MEFRAZ KHAN. A novel focal tvsky loss function with improved attention U-Net for lesion segmentation [C] // Venice: IEEE 16th International Symposium on Biomedical Imaging, 2019: 683-687.
- [24] KINGMA P D, BA J. Adam: A method for stochastic optimization [R]. San Diego: International Conference on Learning Representations 2015, 2015: 1-15.