



引文格式: 梁烽, 张瑞祥, 柴英特, 等. 一种结合上下文与边缘注意力的 SAR 图像海陆分割深度网络方法[J]. 武汉大学学报(信息科学版), 2023, 48(8):1286-1295. DOI:10.13203/j.whugis20210078

Citation: LIANG Feng, ZHANG Ruixiang, CHAI Yingte, et al. A Sea-Land Segmentation Method for SAR Images Using Context-Aware and Edge Attention Based CNNs[J]. Geomatics and Information Science of Wuhan University, 2023, 48(8):1286-1295. DOI:10.13203/j.whugis20210078

一种结合上下文与边缘注意力的 SAR 图像 海陆分割深度网络方法

梁 烽^{1,2} 张瑞祥¹ 柴英特² 陈金勇² 茹国宝¹ 杨 文¹

¹ 武汉大学电子信息学院, 湖北 武汉, 430072

² 中国电子科技集团公司航天信息应用技术重点实验室, 河北 石家庄, 050002

摘要: 海陆分割对于合成孔径雷达 (synthetic aperture radar, SAR) 图像海洋目标检测、海岸线提取等任务具有重要意义。针对实际应用中多分辨率 SAR 图像海陆分割难题, 提出了一种基于上下文与边缘注意力的海陆分割方法。该方法利用通道注意力机制融合不同尺度和层次的上下文特征, 设计了边缘提取支路提供边缘信息, 进一步提高了海陆边界的分割准确率。同时, 构建了基于高分三号卫星数据的多分辨率 SAR 图像海陆分割数据集, 该数据集涵盖了多个分辨率, 包括港口、岛屿等多种海陆边界类型。并基于所构建的多分辨率 SAR 图像海陆分割数据集, 对所提网络的有效性和各模块的作用进行了实验分析。实验结果表明, 所提网络的整体预测准确率和平均交并比分别达到了 98.21% 和 96.47%, 能够较好地完成海陆分割任务。

关键词: 合成孔径雷达; 海陆分割; 边缘提取; 注意力机制

中图分类号: TP751; P237

文献标识码: A

收稿日期: 2021-02-12

DOI: 10.13203/j.whugis20210078

文章编号: 1671-8860(2023)08-1286-10

A Sea-Land Segmentation Method for SAR Images Using Context-Aware and Edge Attention Based CNNs

LIANG Feng^{1,2} ZHANG Ruixiang¹ CHAI Yingte² CHEN Jinyong²

RU Guobao¹ YANG Wen¹

¹ School of Electronic Information, Wuhan University, Wuhan 430072, China

² CETC Key Laboratory of Aerospace Information Application, Shijiazhuang 050002, China

Abstract: Objectives: Sea-land segmentation is of great significance for tasks such as ocean target detection and coastline extraction in synthetic aperture radar (SAR) image. To solve the problem of sea-land segmentation of multi-resolution SAR image in practical applications, this paper presents a sea-land segmentation method based on context and edge attention. **Methods:** The proposed method uses the channel attention mechanism to fuse context features of different scales and levels, and designs an edge extraction branch to provide edge information for further improving the segmentation result of the boundary area. In addition, a sea-land segmentation dataset of multi-resolution SAR image based on the Gaofen-3 satellite data is provided. The dataset covers multiple resolution images, including various sea-land boundary types such as ports, islands. Using this multi-resolution SAR image coastline segmentation dataset, we perform experimental analyses on the effectiveness of the proposed network and the contributions of each module. **Results and Conclusions:** Experimental results show that the proposed method can work well for the task of sea-land segmentation, the overall classification accuracy and mean intersection over union achieve 98.21% and

基金项目: 国家自然科学基金(61771351); 中国电子科技集团公司航天信息应用技术重点实验室开放基金(SXX19629X060)。

第一作者: 梁烽, 博士生, 主要从事遥感图像智能解译方面的研究。fengliang_ie@whu.edu.cn

通讯作者: 茹国宝, 博士, 教授。rgb@whu.edu.cn

96.47%, respectively.

Key words: synthetic aperture radar (SAR); sea-land segmentation; edge extraction; attention mechanism

海陆分割是进行海面舰船目标检测^[1-2]、海岸线提取^[3]等应用的重要步骤。准确的海陆分割能够去除陆地区域中强散射中心的干扰,有效地降低海洋目标检测的虚警率,同时提高检测效率^[4]。当前,对于光学遥感图像的海陆分割已经有较多的工作,如基于海陆边界跟踪的海陆分割方法^[5]、以海岸线数据库为基础对海陆进行分割的方法^[6]、利用像素点特征学习的方法^[7]等。此外,深度神经网络也在近年来被应用到海陆分割任务中^[8-12]。光学遥感图像易受恶劣天气和不良光照的影响,而合成孔径雷达(synthetic aperture radar, SAR)成像具有全天时、全天候、覆盖面积大、分辨率高等特点,因此研究 SAR 图像的海陆分割具有重要的实际意义。

现有的 SAR 图像海陆分割方法包括传统方法和基于深度学习的方法两大类。传统方法中,最为常用的是在全球数字高程模型的辅助下获得大概的海陆分界线,再利用有理多项式模型^[13]对 SAR 图像进行处理,实现海陆分割。文献[14]直接利用合成孔径雷达回波数据,提出了一种将方位向子孔径相关和距离多普勒域散射能量特征相结合的海岸线提取方法;文献[15]利用 SAR 图像中陆地区域与海洋区域在灰度特性上的差异,采用自动阈值的方法对海陆进行分割;文献[16]采用聚类和区域融合的方法对海陆进行分割;文献[17]提出一种基于简单的线性迭代聚类(simple linear iterative clustering, SLIC)超像素分割的 SAR 图像海陆分割算法,该算法首先对图像进行简单的 SLIC 超像素分割,再对分割后的图像进行区域显著性检测及显著值相似度聚类。此外,还有利用海岸线来辅助海陆分割的方法,文献[18]通过梯度矢量流和分水岭算法实现对海岸线的提取得到海陆的边界;文献[19]通过利用已有的海岸线数据库来获取海岸线的先验信息,得到海岸线区域,然后使用 CV(Chan-Vese)模型得到更加精细的分割结果;文献[20]将多尺度分析技术与水平集理论相结合,实现了快速地对 SAR 图像水体分割。传统方法大部分依赖于人工设计的特征,在简单场景下可以获得较好的海陆分割效果,但是在复杂情况下则具有各自的局限性,例如基于海陆差异的方法在海浪较大等情况下容易出现误分割,基于超像素分割的方法存在精细化不足的缺点,利用海岸线的方法则依赖于海岸线提取

的精度,在海岸线提取误差较大的情况下效果会受到较大影响。

神经网络具有强大的图像特征提取能力。近年来,深度卷积神经网络在图像分类、目标检测、语义分割等各类任务中取得了巨大的成功。文献[21]提出的全卷积网络方法利用卷积层替代了图像分类网络中的全连接层,实现了像素级别的分类,奠定了利用神经网络进行语义分割的基础;文献[22]提出反卷积网络可从低分辨率的特征图恢复细节信息,实现了对图像的精细分割;U-Net^[23]网络通过编码器-解码器结构和跳跃连接的方式将不同阶段的特征图进行结合,充分利用不同阶段的信息;文献[24-26]利用空洞卷积扩大网络的感受野,获取更为丰富的上下文信息;金字塔场景解析网络(pyramid scene parsing network, PSPNet)^[27]通过金字塔池化模块将不同尺度的上下文进行结合,实现了对不同尺度目标的有效分割。近年来,深度学习方法也被应用于海陆分割任务中,例如文献[11]提出改进的 U-Net 网络,在网络中使用密集残差模块来更好地提取特征,实现对遥感图像的海陆分割;文献[28]将深度可分离卷积应用于水陆分割任务中,解耦了特征图在二维平面特征和通道特征间的相关性,同时利用扩张卷积提升了网络的高分辨率特征提取能力;文献[29]将改进的双边网络应用于 SAR 图像海陆分割任务中,缩减了网络参数,提高了分割速度,同时提出了边缘增强损失函数策略,提升了模型分割性能。虽然当前用于海陆分割的深度神经网络凭借着神经网络的特征提取能力在分割精度上取得了较大提升,但是其网络模型均是在单一分辨率图像上训练,其网络结构没有考虑多分辨率图像的影响,因此在多分辨率图像海陆分割任务中具有一定的局限性。

此外,现有公开的 SAR 图像海陆分割数据集较少,数据集所包含的样本量偏小,且基本由单一分辨率数据组成,例如文献[28]基于高分三号卫星的滑动聚束模式数据建立了水域分割数据集。而在实际应用过程中往往存在需要对不同分辨率图像进行分割的情况,因此现有的 SAR 图像海陆分割数据集和分割方法难以满足实际应用需求。

针对上述问题,本文基于高分三号遥感卫星 SAR 图像数据构建了一个覆盖多个分辨率的

SAR图像海陆分割数据集,并构建了一个结合上下文与边缘注意力的深度网络实现对不同分辨率SAR图像的海陆分割。所提网络通过聚合不同层次和尺度的上下文信息实现像素级海陆分类,并利用边缘支路提供的边缘特征信息提高海陆边界区域的分割准确度。

1 SAR图像海陆分割数据集

目前已有SAR图像海陆分割工作中,所使用数据的样本量均较少,数据的多样性不足,且均为单一分辨率的图像。而在实际应用中,通过单一分辨率数据训练得到的模型在不同的分辨率数据上存在分割效果不佳的问题。本文基于国产高分三号卫星多个成像模式下的不同分辨率数据,构建了一个涵盖多个分辨率的SAR图像海陆分割数据集,包含港口、堤坝、自然海陆边界等多种复杂海陆边界区域。

高分三号遥感卫星是中国首颗自主研发的C频段多极化SAR卫星,具有高分辨率、大成像幅宽、高辐射精度、多成像模式和长工作时长等特点^[30]。本文构建的多分辨率SAR图像海陆分割数据集使用了高分三号卫星的滑块聚束模式、超精细条带模式和全极化条带1模式图像,3种工作模式的图像分辨率分别为1 m、3 m和8 m。其中滑块聚束模式和超精细条带模式原始数据为单极化数据,全极化条带1模式原始数据为全极化数据。为了保持数据的通道数统一,对于全极化条带1模式中的全极化数据,只使用其中水平发射、水平接收(horizontal transmit, horizontal receive, HH)的极化方式通道数据。将原始图像裁切为1 024×1 024像素后选取其中同时包含海洋与陆地区域的图像。为了得到更多类型的分辨率图像,提高数据集的多样性,将部分滑块聚束模式和超精细条带模式图像进行了线性下采样操作。对部分聚束模式数据进行5倍线性下采样获得分辨率为5 m的SAR图像数据,对部分超精细条带模式数据进行2倍线性下采样得到分辨率为6 m的SAR图像数据,而滑块聚束模式和超精细条带模式图像保持原有分辨率。经过上述处理后,最终得到一个包含1 m、3 m、5 m、6 m和8 m的多分辨率SAR图像海陆分割数据集。在数据集中,不同分辨率图像的顺序被打乱,并隐藏其分辨率信息,让模型根据数据来学习不同分辨率数据的特征,从而获得更为鲁棒的效果。表1展示了数据集中各模式、各分辨率数据的极化方式和数

据数量,其中分辨率为5 m和6 m的数据通过线性下采样得到。

表1 数据集中各模式数据数量统计

Tab.1 Number of Images with Different Imaging Modes

模式	分辨率/m	极化方式	数量
滑块聚束	1	单极化	212
超精细条带	3	单极化	211
全极化条带1	8	全极化	1 087
—	5	单极化	812
—	6	单极化	470

在数据的选择上,为了更好地学习海陆边界区域特征,数据集中只包含同时具有海洋和陆地区域的数据;在标注方法上,使用Labelme标注软件,在每一张图像上人工标注了分别代表陆地区域和海洋区域的多边形,从而获得每一张图像的标签;在标注原则上,本数据集以海岸线提取、海洋目标检测等实际应用需求为导向对图像进行标注,对于港口区域中的栈桥、海面上的船只并不划入陆地区域,对于内陆中的河流与湖泊也不计入海面区域。最终得到人工标注的图像总数为2 792幅,从中随机划分出400幅图像用于模型验证,600幅图像用于模型测试,剩余的1 792幅图像用于模型的训练。该数据集命名为SARSeaLand V1.0,数据集中的部分样本图像及其标注如图1所示(<https://github.com/FengLi-ang-Whu/SARSeaLandV1.0>)。

2 上下文与边缘注意力网络

在已有的基于深度网络模型的SAR图像海陆分割工作中,由于所使用的模型训练数据为单一分辨率数据,训练得到的网络只能对与训练数据分辨率相同的数据进行较好的分割,因此无法满足实际应用过程中不同分辨率图像的要求。已有的大部分语义分割模型,如U-Net^[23],由于使用了固定的卷积层数与卷积核尺寸,只能提取固定大小的上下文信息,因此难以应对图像分辨率不一致和物体尺度不一致等情况。部分使用了金字塔池化结构的网络,如PSPNet^[27],虽然能够获取不同尺度的上下文信息,但是其不同尺度的上下文采用相同的权重进行聚合,无法根据数据调节权值的大小,因此效果受到了限制。现有的SAR图像海陆分割模型没有在网络结构上对边缘的精细化提取做出针对性的改进,往往在海陆边缘区域分割模糊。本文提出的上下文与边缘

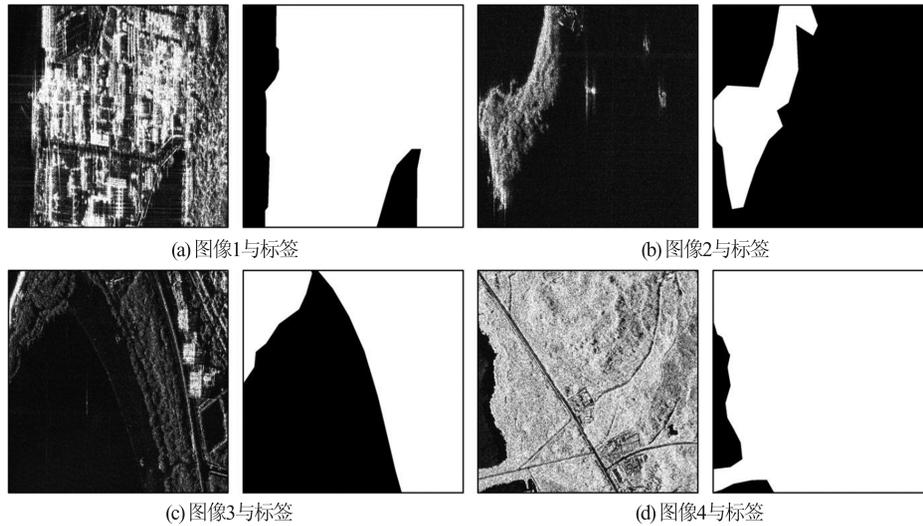


图1 数据集部分图像与标签
Fig. 1 Sample Images and the Corresponding Labels

注意力网络,首先通过空洞空间金字塔池化 (atrous spatial pyramid pooling, ASPP)^[26]和上下文跳跃链接获取不同尺度、不同层次的上下文信息,然后利用一个上下文注意力模块来显式地学习不同上下文特征的权重,并按照学习得到的权重来融合不同尺度上下文特征,从而获得更精确的上下文信息;同时本文提出的网络增加了一个边缘提取支路,采用多任务学习的方式提供边缘信息,提高边缘区域的分割准确度。

2.1 整体架构

图2展示了本文提出的上下文与边缘注意力的整体结构。该网络主要由语义分割分支与边缘提取分支组成。其中语义分割分支为网络的主干分支,包括用于提取图像特征的主干网络,用于聚合不同上下文特征的上下文注意力模块,聚合边缘特征的边缘注意力模块和恢复特征图尺寸和实现像素分类的上采样模块;边缘提取分支是网络的辅助分支,负责提取合适的边缘信息,帮助获得更为准确的边缘区域分割效果。

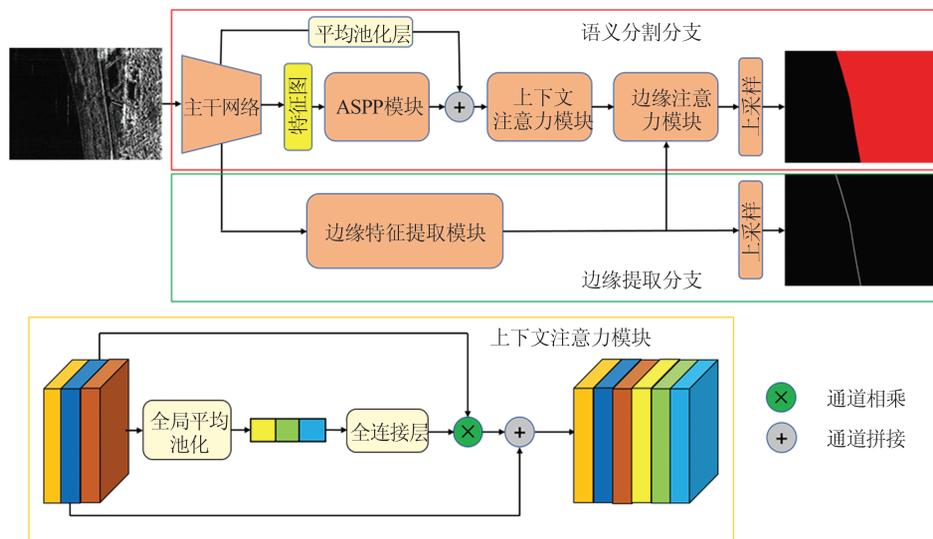


图2 基于上下文与边缘注意力的 SAR 图像海陆分割网络
Fig. 2 SAR Image Sea-Land Segmentation Network Based on Context and Edge Attention

2.2 语义分割分支

在传统的语义分割网络中,通常采用编码器-解码器结构,即通过一个主干网络提取特征,再通过一个反卷积模块或上采样模块将低分辨率

的特征恢复,得到分割结果。这种结构获取上下文信息的范围相对固定,无法适应不同分辨率图像的情形。本文所提网络采用的语义分割分支在此基础上增加了提供不同层级上下文特征的

跳跃连接和上下文注意力模块,从而能够更好地融合不同尺度、不同层次特征,获得更完善的上下文信息。语义分割分支主要由主干网络、ASPP模块、上下文注意力模块、边缘注意力模块和上采样模块组成。ResNet网络中的残差连接使得深层次的网络结构能够得到有效的学习,具有强大的特征提取能力。因此,所提网络采用去除最后3层全连接层的ResNet50作为骨干网络提取特征。同时为了适应数据中不同分辨率、不同尺度大小目标的特点,采用一个ASPP模块获取不同尺度的上下文信息。所使用的ASPP模块由并行的3个空洞卷积块和一个全局平均池化块组成。不同的空洞卷积块通过具有不同空洞卷积率的卷积层获得不同大小的上下文信息,而全局平均池化块则负责获取全局上下文信息,同时能够将不同层次上下文间的信息进行融合,使网络能够更好地恢复细节信息。在语义分割分支中,还增加了一个提供低层次上下文信息的跳跃连接。首先将ResNet50中的layer1和layer2的输出分别经过大小为8和4的平均池化层,然后将池化后的输出和ASPP模块的输出一起连接到上下文注意力模块。上下文注意力模块采用通道注意力机制进行混合,得到上下文聚合特征后再进一步和边缘提取分支提供的边缘特征在边缘注意力模块中聚合,最后通过上采样模块恢复特征图尺寸和实现像素分类,得到最终的海陆分割结果。

2.3 上下文注意力模块

上下文是影响语义分割效果的重要因素,合适的上下文信息能够有效提高分割的准确性^[31]。传统的上下文的聚合方式都使用相等的权值,即对不同的上下文信息等权重看待,无法根据数据自适应的调整。本文设计的上下文注意力模块,通过使用自注意力机制自适应地调整不同上下文权值,从而获得更优的上下文融合效果。该模块首先对输入的不同上下文特征图按通道维度进行拼接,然后进行全局平均池化得到与输入特征图维数相同的全局特征,最后通过两层全连接层学习得到一个与输入特征图通道数相同的向量。在最后一层全连接层中,采用Sigmoid激活函数将输出限制在 $[0, 1]$ 之间,从而使输出向量中的每一个值可以分别代表输入特征图中每一通道特征的权重。将学习得到的权值与输入的特征图中对应维度特征相乘,即可得到加权后的特征图。为了提高模块学习能力,在上下文注意力模块中按照文献[32]中的方式增加了残差连接,

将加权前后的特征图进行拼接,保证了网络的有效学习能力。

2.4 边缘提取分支

边缘提取分支的作用是为语义分割分支提供边缘特征信息,主要由边缘特征提取模块和边缘上采样模块组成。边缘特征提取模块的输入为骨干网络ResNet50中layer2的输出,具体结构由两层卷积块构成。每一层卷积块包括一个卷积核为3的卷积层、大小为2的最大化池化层、批量标准化层和激活层(ReLU)。该模块通过卷积和池化操作提取更高层次的特征,通过对数据进行标准化处理使网络学习更为高效,并利用激活层赋予网络非线性表达的能力。

边缘特征提取模块得到的边缘特征图,一方面输入到语义分割中的边缘注意力模块,为海陆分割提供边缘信息;另一方面输入到边缘上采样模块,经过通道降维后通过上采样将特征图恢复到输入图像大小,最后利用从标签中获得的边缘信息监督边缘提取网络的学习,从而得到边缘提取的结果。

2.5 边缘注意力模块

边缘注意力模块采用与上下文注意力模块相似的结构,从上下文注意力模块输出的上下文聚合特征与边缘特征采用加权拼接的方式结合,然后通过通道注意力机制学习得到不同特征的权值。与上下文注意力模块一样,边缘注意力模块最后也使用残差连接帮助网络提高学习效率。

2.6 上采样模块

在网络提取特征的过程中,为了节省计算资源,提高网络计算速度,通常需要对输入图像进行下采样操作,同时卷积块中的卷积与池化操作也会导致特征图的尺寸下降。而语义分割任务是对图像中的每一个像素点进行分类,需要得到与输入图像大小一致的输出结果图,因此需要对特征图进行上采样。

本文网络中的语义分割分支和边缘提取分支采用相似的上采样模块。上采样模块首先通过卷积核大小为 3×3 的卷积层对输入特征图进行降维,然后通过双线性插值的方式将特征图尺寸上采样到输入图像尺寸,得到分割结果。

2.7 损失函数

本文网络中语义分割分支使用训练集中样本的标签进行监督,边缘提取支路使用通过标签得到的边缘标签进行监督,因此网络的损失函数包括海陆分割损失 L_{s-l} 和边缘损失 L_e 两部分,网

网络的总体损失 L 可表示为:

$$L = L_{s-l} + \lambda L_e \quad (1)$$

式中,超参数 λ 为边缘损失的权值。本文网络均采用交叉熵损失函数,设输入图像的长和宽分别为 M 和 N ,则有:

$$L_{s-l} = \sum_{i=1}^M \sum_{j=1}^N p_s(i,j) \log \hat{p}_s(i,j) + p_l(i,j) \log \hat{p}_l(i,j) \quad (2)$$

$$L_e = \sum_{i=1}^M \sum_{j=1}^N p_e(i,j) \log \hat{p}_e(i,j) + p_{n-e}(i,j) \log \hat{p}_{n-e}(i,j) \quad (3)$$

式中, $p_s(i,j)$ 、 $p_l(i,j)$ 、 $p_e(i,j)$ 和 $p_{n-e}(i,j)$ 分别为 (i,j) 位置上像素点海洋类、陆地类、边缘类和非边缘类的标签,即属于该类别则为 1,否则为 0; $\hat{p}_s(i,j)$ 、 $\hat{p}_l(i,j)$ 、 $\hat{p}_e(i,j)$ 和 $\hat{p}_{n-e}(i,j)$ 分别为网络在 (i,j) 位置上对应类别的预测概率,且满足:

$$\hat{p}_s(i,j) + \hat{p}_l(i,j) = 1 \quad (4)$$

$$\hat{p}_e(i,j) + \hat{p}_{n-e}(i,j) = 1 \quad (5)$$

3 实验结果及分析

基于本文所构建的多分辨率 SAR 图像海陆分割数据集,针对所提网络的有效性与现有的典型语义分割网络在分割性能上进行了对比分析。

3.1 实验细节设置

实验平台配备的图形处理器为 GTX3090,操作系统为 Ubuntu 16.04,代码运行环境为 Python 3.7.9,深度学习环境配置为 CUDA 11.1、Pytorch 1.8.0。本文所有实验都在相同的实验环境中进行,实验设置每次训练输入的图像样本数量为 4,初始学习率设置为 0.01,并采用多项式算法调整学习率大小。具体计算如下:

$$l = l_0 \left(1 - \frac{i}{i_m}\right)^p \quad (6)$$

式中, i 为当前网络迭代数; i_m 为网络最大迭代数; l_0 为网络的初始学习率; $p=0.9$ 控制学习率的衰减速度。实验设置最大迭代次数为 40,采用超参数 $\lambda=0.7$ 控制边缘损失函数权重。所有实验均采用随机梯度下降法作为优化器对网络参数进行优化调整。

3.2 评价标准

海陆分割属于语义分割中的子任务,因此海陆分割的评价标准可以直接采用语义分割中的一般评价标准,如平均交并比(mean intersection over union, mIoU)和整体预测准确度(overall accuracy, OA)等。然而海陆分割任务也存在其特殊

性,海陆分割的图像中一般只存在海洋与陆地两种类别,因此通常会存在大片的内陆区域和广阔的海洋区域,这些区域的分类难度较低,导致模型的评价指标偏高,不利于区分模型性能的优劣。对于海陆分割而言,海陆边界的准确性是非常重要的,同时海陆边界地区的场景信息往往较为复杂,更能体现模型的泛化能力。传统的评价指标难以体现海陆边界提取的准确性,因此本文在使用传统的 mIoU 和 OA 之外,还采用了平均最小边界距离(mean minimum edge distance, mMED)作为新的评价指标,它能够较好地衡量模型的边界提取能力。mMED 通过计算分割结果中海陆边界上的点到标签中海陆边界上距离最近的点的平均距离来衡量边界提取的性能。计算如下:

$$A_{\text{mIoU}} = \frac{1}{2} \left(\frac{C_{\text{TP}_l}}{C_{\text{TP}_l} + C_{\text{FP}_l} + C_{\text{FN}_l}} + \frac{C_{\text{TP}_s}}{C_{\text{TP}_s} + C_{\text{FP}_s} + C_{\text{FN}_s}} \right) \quad (7)$$

$$A_{\text{OA}} = \frac{C_{\text{TP}_l} + C_{\text{TP}_s}}{C_{\text{TP}_l} + C_{\text{FP}_l} + C_{\text{TP}_s} + C_{\text{FP}_s}} \quad (8)$$

$$A_{\text{mMED}} = \frac{1}{n} \sum_{p_1 \in P_1, p_2 \in P_2} \min \|p_1 - p_2\| \quad (9)$$

式中, C_{TP_l} 、 C_{FP_l} 、 C_{FN_l} 分别为预测结果中陆地区域的真正例(true positive, TP)、假正例(false positive, FP)、假负例(false negative, FN); C_{TP_s} 、 C_{FP_s} 、 C_{FN_s} 分别为预测结果中海洋区域的真正例、假正例、假负例; P_1 和 P_2 分别为海陆分割结果和标签中的边界点集; p_1 和 p_2 分别为 P_1 和 P_2 中的点; n 为点集 P_1 中像素点的个数; $\|p_1 - p_2\|$ 表示点 p_1 和 p_2 之间的欧氏距离。

3.3 网络分割结果

为了验证本文方法的有效性,实验选取 U-Net、PSPNet^[27]、DeepLabV3^[26] 和 DeepLabV3+^[33] 网络进行对比分析。所有方法均在本文构建的 SAR 图像海陆分割数据集上的训练集上进行训练,并在测试集上进行测试。利用上述方法得到的海陆分割结果如图 3 所示。

由图 3 可知, U-Net、PSPNet、DeepLabV3 和 DeepLabV3+ 方法在内陆区域均出现了空洞现象,而在海洋区域, PSPNet 和 DeepLabV3+ 方法则将其中的船只误分割为海洋区域。而本文方法网络在陆地和海洋区域均有较优的分割效果,误分割区域较少。传统方法在上下文融合方面采用固定权值的方式导致其对不同分辨率图像

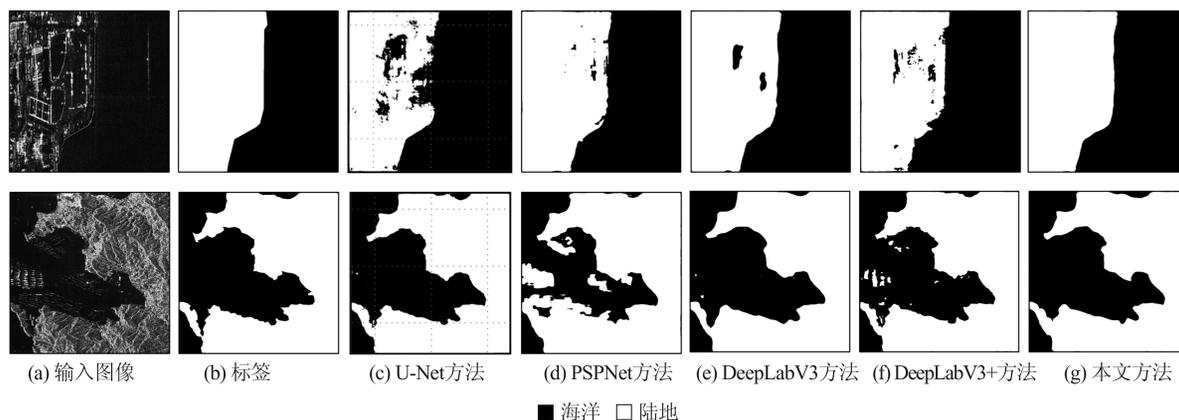


图3 不同方法的分割结果

Fig. 3 Segmentation Results Using Different Methods

的适应性不足,容易误将内陆辐射较弱、亮度较低区域误分割为海洋,将海洋中辐射较强的船只误分类为陆地。此外,由于缺乏边缘区域信息,PSPNet和DeepLabV3+方法在海陆边界区域的分割准确度也较低。本文方法虽然精度较高,但仍存在少部分区域边缘精细度不足的问题,具体表现为边缘中细小的突起或凹陷可能被平滑掉,原因可能是网络在边缘信息的监督下倾向于获取平滑的边缘。

表2展示了不同方法在整个数据测试集上的各类指标的统计结果。由表2可知,本文方法的mIoU、OA和mMED均优于传统方法,特别是在mMED指标上取得了较大优势。

表2 不同方法在测试集上的分割性能对比

Tab. 2 Segmentation Performance of Different Methods on the Test Dataset

方法	mIoU/%	OA/%	mMED/单位像素
U-Net	95.77	97.85	81.12
PSPNet ^[27]	93.39	96.61	73.91
DeepLabV3 ^[26]	94.84	97.36	41.72
DeepLabV3+ ^[33]	93.80	96.82	64.26
本文方法	96.47	98.21	25.35

3.4 网络结构有效性分析

为了验证本文所提网络中边缘支路和注意力模块的有效性,采用对比实验进行消融分析。

3.4.1 边缘支路有效性分析

为验证本文网络结构中边缘支路对网络分割性能的影响,分别采用具有边缘支路网络(即本文所提网络)和无边缘支路网络在同一实验条件下进行了对比实验。其中无边缘支路网络是在本文所提网络的基础上去除边缘支路,其余部分保持不变。分割结果如图4所示。由图4可知,在使用了边缘提取分支提供边缘信息后,网络在边缘区域的分类精度获得了较大提升,海陆边界也更为准确。

在各项定量测试指标上,无边缘支路网络和本文网络的mIoU分别为95.78%和96.47%;OA分别为97.85%和98.21%;mMED分别为35.75和25.35个单位像素。从定量结果可以看出,具有边缘支路网络(即本文网络)在各项指标上均优于无边缘支路网络,特别是在平均最小边界距离上具有较大的优势,说明边缘提取支路能够为语义分割分支提供更多的边缘信息,有效提高了边界区域分割效果。

3.4.2 注意力模块有效性分析

为验证本文网络结构中注意力模块对网络分割性能的影响,本文分别采用具有注意力模块网络(即本文所提网络,包括上下文注意力模块和边缘注意力模块)和无注意力模块网络在同一实验条件下进行了对比实验。其中无注意力模块网络是在本文所提网络的基础上去除上下文注意力模块和边缘注意力模块,各上下文特征图和边缘特征图均采用直接拼接的方式融合,其余部分保持不变。分割结果如图5所示。由图5可知,具有注意力模块的网络在边界和内陆较为复杂区域具有更好的分割效果。在各项定量测试指标上,无注意力模块网络和本文网络的mIoU分别为96.08%和96.47%;OA分别为97.95%和98.21%;mMED分别为31.75和25.35个单位像素。从上述定量结果中可以看出,在各项指标上,具有注意力模块的网络均优于无注意力模块网络,说明注意力模块能够更好地融合各类上下文,并将边缘信息更好地融入主干支路。

3.5 网络泛化性能分析

本文网络在基于高分三号卫星数据构建的多分辨率SAR图像海陆分割数据集中取得了优异的分割效果。为了验证本文网络的泛化性能,利用本文构建的多分辨率SAR图像海陆分割数据集上训练的模型在Radarsat-2卫星和TerraSAR-X卫星

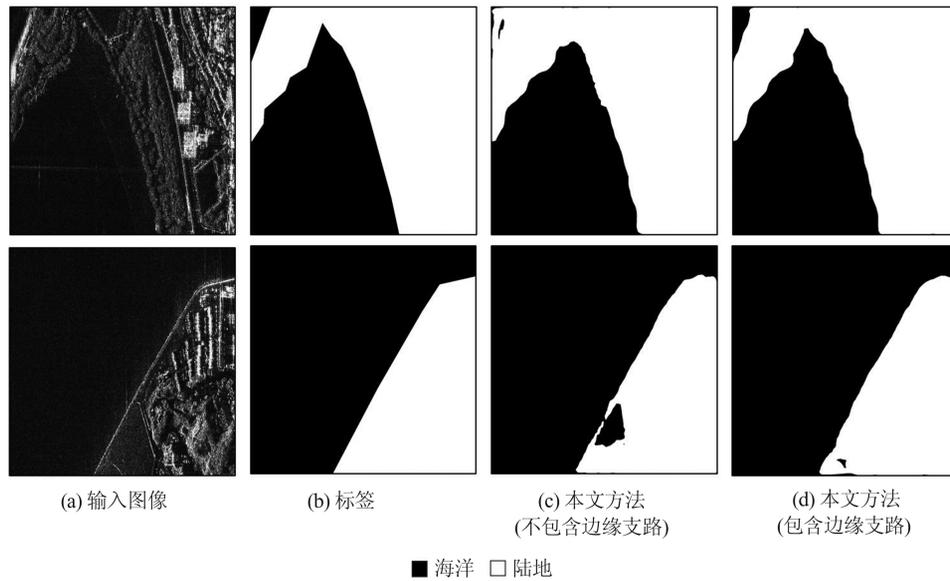


图 4 是否使用边缘支路的分割结果对比

Fig. 4 Comparison of Segmentation Results of Network with or Without Edge Information

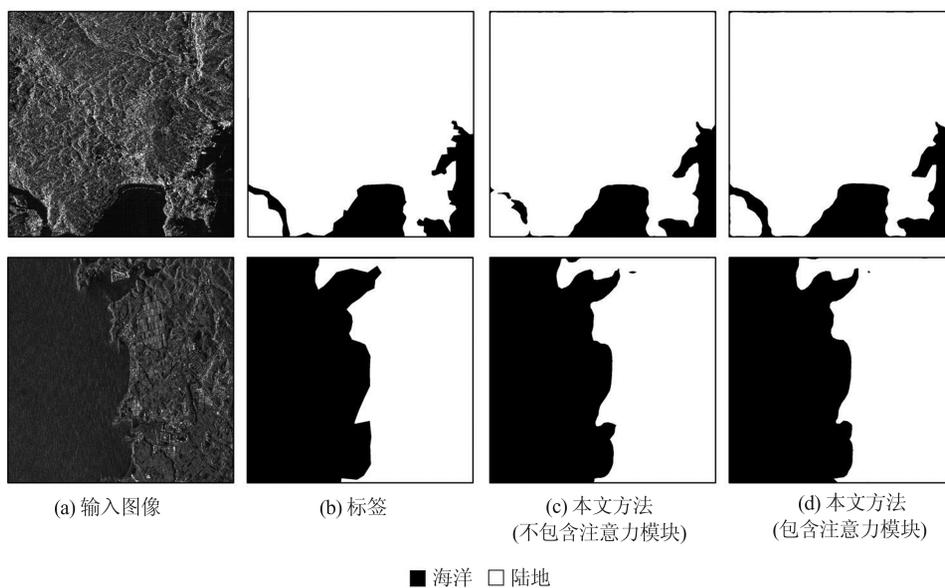


图 5 是否使用注意力模块的分割结果对比

Fig. 5 Comparison of Segmentation Results of Network with or Without Attention Module

数据上进行了实验。其中 Radarsat-2 数据为精细模式,分辨率为 8 m,数据极化方式为全极化,在实验中取其中的 HH 极化通道数据; TerraSAR-X 数据为高分辨率聚束模式,分辨率为 1 m,实验结果如图 6 所示。从图 6 可以看出,网络在 Radarsat-2 和 TerraSAR-X 卫星数据上能够较好地海洋和陆地进行分割,表明本文网络具有较好的泛化能力。

4 结 语

本文提出了一个基于上下文与边缘注意力的海陆分割方法,该方法利用 ASPP 模块和跳跃连接

获取多个尺度与层次的上下文信息,并利用边缘提取分支获取边缘信息,最后通过注意力机制融合上下文信息和边缘信息,有效提高了网络的信息聚合能力。同时,为了促进 SAR 图像海陆分割领域的研究,本文构建了一个基于高分三号卫星多个工作模式数据的 SAR 图像海陆分割数据集,该数据集包含多种分辨率数据,包括港口、岛屿等多类别海陆边界情景。实验结果表明,本文提出的海陆分割方法中的上下文自注意力模块能够自主学习不同上下文的权重值,从而更好地适应不同分辨率图像的特点,同时边缘注意力模块能够有效聚合边缘信息,在不同分辨率的图像上均取得了优异的海陆分

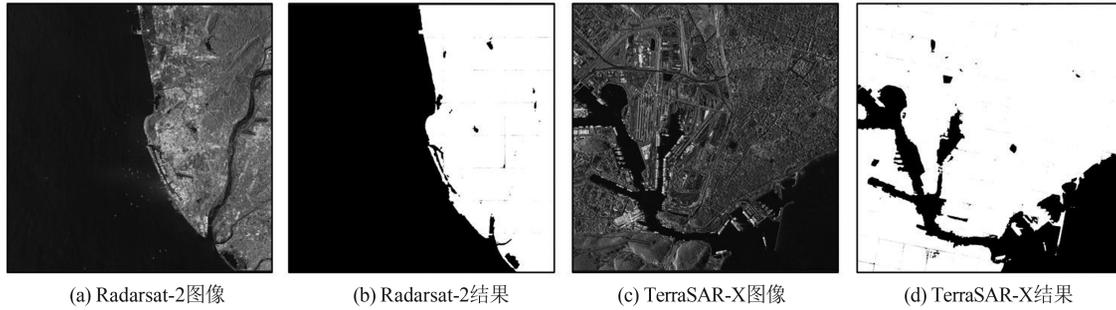


图6 Radarsat-2和TerraSAR-X SAR图像的海陆分割结果

Fig. 6 Segmentation Results of SAR Images from Radarsat-2 and TerraSAR-X

割性能,能够较好地满足实际应用需要。

参 考 文 献

- [1] Li Jianwei, Qu Changwen, Peng Shujuan. A Joint SAR Ship Detection and Azimuth Estimation Method [J]. *Geomatics and Information Science of Wuhan University*, 2019, 44(6): 901-907. (李健伟, 曲长文, 彭书娟. SAR图像舰船目标联合检测与方向估计[J]. 武汉大学学报(信息科学版), 2019, 44(6): 901-907.)
- [2] Yang Wen, Sun Hong, Xu Xin, et al. Detection of Ships and Ship Wakes in Spaceborne SAR Imagery [J]. *Geomatics and Information Science of Wuhan University*, 2004, 29(8): 682-685. (杨文, 孙洪, 徐新, 等. 星载SAR图像船舶及航迹检测[J]. 武汉大学学报(信息科学版), 2004, 29(8): 682-685.)
- [3] Li Peng, Pu Sixun, Li Zhenhong, et al. Coastline Change Monitoring of Jiaozhou Bay from Multi-source SAR and Optical Remote Sensing Images Since 2000[J]. *Geomatics and Information Science of Wuhan University*, 2020, 45(9): 1485-1492. (李鹏, 普思寻, 李振洪, 等. 2000年以来胶州湾海岸线光学与SAR多源遥感变化监测研究[J]. 武汉大学学报(信息科学版), 2020, 45(9): 1485-1492.)
- [4] Xing Xiangwei, Ji Kefeng, Kang Lihong, et al. Review of Ship Surveillance Technologies Based on High-Resolution Wide-Swath Synthetic Aperture Radar Imaging[J]. *Journal of Radars*, 2015, 4(1): 107-121. (邢相薇, 计科峰, 康利鸿, 等. HRWS SAR图像舰船目标监视技术研究综述[J]. 雷达学报, 2015, 4(1): 107-121.)
- [5] Li Chaopeng, Yang Guang. Fast Sea-Land Segmentation Method Based on Maritime Boundary Tracking [J]. *Computer Science*, 2014, 41(10): 84-86. (李超鹏, 杨光. 一种基于海陆边界跟踪的快速海陆分割方法[J]. 计算机科学, 2014, 41(10): 84-86.)
- [6] Zhang Jing, Jing Haitao, Fan Shenghua. Sea-Land Segmentation for Remote Sensing Imagery Based on Coastline Database [J]. *Electronic Measurement Technology*, 2020, 43(23): 115-120. (张静, 景海涛, 樊盛华. 基于海岸线数据库的遥感图像海陆分割[J]. 电子测量技术, 2020, 43(23): 115-120.)
- [7] Wang D, Cui X R, Xie F Y, et al. Multi-feature Sea-Land Segmentation Based on Pixel-Wise Learning for Optical Remote Sensing Imagery [J]. *International Journal of Remote Sensing*, 2017, 38(15): 4327-4347.
- [8] Cheng D C, Meng G F, Cheng G L, et al. SeNet: Structured Edge Network for Sea - Land Segmentation [J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(2): 247-251.
- [9] He L Y, Xu Q Z, Hu H M, et al. Fast and Accurate Sea-Land Segmentation Based on Improved SeNet and Coastline Database for Large-Scale Image [C]//The Fifth International Workshop on Earth Observation and Remote Sensing Applications (EORSA), Xi'an, China, 2019.
- [10] Chu Z Q, Tian T, Feng R Y, et al. Sea-Land Segmentation with Res-UNet and Fully Connected CRF [C]// IEEE International Geoscience and Remote Sensing Symposium, Yokohama, Japan, 2019.
- [11] Shamsolmoali P, Zareapoor M, Wang R L, et al. A Novel Deep Structure U-Net for Sea-Land Segmentation in Remote Sensing Images [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2019, 12(9): 3219-3232.
- [12] Cui B G, Jing W, Huang L, et al. SANet: A Sea-land Segmentation Network via Adaptive Multiscale Feature Learning [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 14: 116-126.
- [13] Zhang Guo, Li Deren, Qin Xuwen, et al. Orthorectification of High Resolution SAR Image Based on RPC Model [J]. *National Remote Sensing Bulletin*, 2008, 12(6): 942-948. (张过, 李德仁, 秦绪文, 等. 基于RPC模型的高分辨率SAR影像正射纠正[J]. 遥感学报, 2008, 12(6): 942-948.)
- [14] Lu Liming, Wang Runsheng, Li Wugao. A Method of Coastline Extraction from Synthetic Aperture Ra-

- dar Raw-Data [J]. *Journal of Software*, 2004, 15(4): 531-536. (陆立明, 王润生, 李武皋. 基于合成孔径雷达回波数据的海岸线提取方法[J]. 软件学报, 2004, 15(4): 531-536.)
- [15] An Chengjin, Niu Zhaodong, Li Zhijun, et al. Otsu Threshold Comparison and SAR Water Segmentation Result Analysis [J]. *Journal of Electronics & Information Technology*, 2010, 32(9): 2215-2219. (安成锦, 牛照东, 李志军, 等. 典型 Otsu 算法阈值比较及其 SAR 图像水域分割性能分析[J]. 电子与信息学报, 2010, 32(9): 2215-2219.)
- [16] Liu Z L, Li F, Li N, et al. A Novel Region-Merging Approach for Coastline Extraction from Sentinel-1A IW Mode SAR Imagery [J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 13(3): 324-328.
- [17] Li Zhi, Qu Changwen, Zhou Qiang, et al. A Sea-Land Segmentation Algorithm of SAR Image Based on the SLIC Superpixel Division [J]. *Radar Science and Technology*, 2017, 15(4): 354-358. (李智, 曲长文, 周强, 等. 基于 SLIC 超像素分割的 SAR 图像海陆分割算法[J]. 雷达科学与技术, 2017, 15(4): 354-358.)
- [18] Sheng G F, Yang W, Deng X P, et al. Coastline Detection in Synthetic Aperture Radar (SAR) Images by Integrating Watershed Transformation and Controllable Gradient Vector Flow (GVF) Snake Model [J]. *IEEE Journal of Oceanic Engineering*, 2012, 37(3): 375-383.
- [19] Huang Xiangli, Zhang Jie, Ji Kefeng, et al. Sea-Land Segmentation Algorithm of SAR Image Based on GSHHG Database and Improved CV Model [C]//The 5th China High Resolution Earth Observation Conference, Xi'an, China, 2018. (黄祥李, 张杰, 计科峰, 等. 基于 GSHHG 数据库与改进 CV 模型的 SAR 图像海陆分割算法[C]//第五届高分辨率对地观测学术年会论文集, 中国西安, 2018.)
- [20] Xu Chuan, Hua Feng, Sui Haigang, et al. Automatic Water Segmentation Method in SAR Images Using Multi-scale Level Set [J]. *Geomatics and Information Science of Wuhan University*, 2014, 39(1): 27-31. (徐川, 华凤, 眭海刚, 等. 多尺度水平集 SAR 影像水体自动分割方法[J]. 武汉大学学报(信息科学版), 2014, 39(1): 27-31.)
- [21] Shelhamer E, Long J, Darrell T. Fully Convolutional Networks for Semantic Segmentation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(4): 640-651.
- [22] Noh H, Hong S, Han B. Learning Deconvolution Network for Semantic Segmentation [C]// IEEE International Conference on Computer Vision (ICCV), Santiago, Chile, 2016.
- [23] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation [M]// Cham: Springer International Publishing, 2015: 234-241.
- [24] Chen L C, Papandreou G, Kokkinos I, et al. Semantic Image Segmentation with Deep Convolutional Nets and Fully Connected CRFS [J]. *arXiv*, 2014, DOI: 1412.7062.
- [25] 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*, 2018, 40(4): 834-848.
- [26] Chen L C, Papandreou G, Schroff F, et al. Rethinking Atrous Convolution for Semantic Segmentation Image Segmentation [EB/OL]. [2017-12-05]. <https://arxiv.org/abs/1706.05587v2>.
- [27] Zhao H S, Shi J P, Qi X J, et al. Pyramid Scene Parsing Network [C]// IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, USA, 2017.
- [28] Zhang Jinsong, Xing Mengdao, Sun Guangcai. A Water Segmentation Algorithm for SAR Image Based on Dense Depthwise Separable Convolution [J]. *Journal of Radars*, 2019, 8(3): 400-412. (张金松, 邢孟道, 孙光才. 一种基于密集深度分离卷积的 SAR 图像水域分割算法[J]. 雷达学报, 2019, 8(3): 400-412.)
- [29] Dai Muchen, Leng Xiangguang, Xiong Boli, et al. Sea-Land Segmentation Method for SAR Images Based on Improved BiSeNet [J]. *Journal of Radars*, 2020, 9(5): 886-897. (戴牧宸, 冷祥光, 熊博莅, 等. 基于改进双边网络的 SAR 图像海陆分割方法[J]. 雷达学报, 2020, 9(5): 886-897.)
- [30] Zhang Qingjun. System Design and Key Technologies of the GF-3 Satellite [J]. *Acta Geodaetica et Cartographica Sinica*, 2017, 46(3): 269-277. (张庆君. 高分三号卫星总体设计与关键技术[J]. 测绘学报, 2017, 46(3): 269-277.)
- [31] Cheng W S, Yang W, Pan Y Q, et al. Context Aggregation Network for Semantic Labeling in Aerial Images [C]// IEEE International Conference on Image Processing (ICIP), Taipei, China, 2019.
- [32] He K M, Zhang X Y, Ren S Q, et al. Deep Residual Learning for Image Recognition [C]// IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, USA, 2016.
- [33] Chen L C, Zhu Y K, Papandreou G, et al. Encoder-decoder with Atrous Separable Convolution for Semantic Image Segmentation [M]// Cham: Springer International Publishing, 2018.