



引文格式:陈立福,龙凤琪,李振洪,等.面向多源SAR图像的多级特征注意力水体提取网络[J].武汉大学学报(信息科学版), 2025, 50(7):1339-1345.DOI:10.13203/j.whugis20230041

Citation: CHEN Lifu, LONG Fengqi, LI Zhenhong, et al. Multi-level Feature Attention Fusion Network for Water Extraction from Multi-source SAR Images[J]. Geomatics and Information Science of Wuhan University, 2025, 50(7): 1339-1345. DOI: 10.13203/j.whugis20230041

面向多源SAR图像的多级特征注意力水体提取网络

陈立福¹ 龙凤琪¹ 李振洪^{2,3,4} 袁志辉¹ 朱武^{2,3,4} 蔡兴敏²

1 长沙理工大学电气与信息工程学院,湖南 长沙,410004

2 长安大学地质工程与测绘学院,陕西 西安,710054

3 长安大学地学与卫星大数据研究中心,陕西 西安,710054

4 自然资源部生态地质与灾害防控重点实验室,陕西 西安,710054

摘要:利用合成孔径雷达(synthetic aperture radar, SAR)图像进行水体提取在城市水体监测、海岸线监测、洪涝灾害监测等方面具有重要的应用价值。目前对单频段SAR图像数据水体提取已经取得了较大成功。但由于水体及地物目标在不同频段SAR图像中呈现的特性有较大差别,针对单频段SAR图像设计的深度学习网络,在应用到不同频段时提取精度较差,因此,如何实现多源SAR图像水体自动提取依然是个不小的挑战。对此,提出了一种新的网络框架,即多级特征注意力融合网络(multi-level feature attention fusion network, MFAFNet)。该网络由编码器和解码器组成,编码器先使用ResNet-101提取具有不同分辨率的4级特征,再由所提出的中间级特征融合模块和有效通道空洞空间卷积池化金字塔模块并行处理,对高级特征进行深度融合;在解码器中引入注意调制模块对低级特征进行权重分配,进一步与来自编码器的高级特征融合并进一步处理,获得水体提取结果。为了验证所提网络框架的有效性,对不同频段和分辨率的SAR图像(哨兵1号、TerraSAR和高分三号)进行了实验,并与3个典型网络进行了对比。结果表明,MFAFNet对多源SAR图像的水体提取效果显著优于其他网络,平均用户精度可达87%,平均交并比为0.80,实现了多源SAR图像水体的高精度自动提取。

关键词:合成孔径雷达;水体提取;深度学习;特征融合;注意力机制

中图分类号:P237

文献标识码:A

收稿日期:2023-04-20

DOI:10.13203/j.whugis20230041

文章编号:1671-8860(2025)07-1339-07

Multi-level Feature Attention Fusion Network for Water Extraction from Multi-source SAR Images

CHEN Lifu¹ LONG Fengqi¹ LI Zhenhong^{2,3,4} YUAN Zhihui¹ ZHU Wu^{2,3,4} CAI Xingmin²

1 School of Electrical and Information Engineering, Changsha University of Science and Technology, Changsha 410004, China

2 College of Geological Engineering and Geomatics, Chang'an University, Xi'an 710054, China

3 Big Data Center for Geosciences and Satellites, Chang'an University, Xi'an 710054, China

4 Key Laboratory of Ecological Geology and Disaster Prevention, Ministry of Natural Resources, Xi'an 710054, China

Abstract: Objective: At present, water extraction from single frequency-band synthetic aperture radar (SAR) images has achieved great success. However, due to the large differences in the characteristics of water bodies and other surface targets in SAR images with different frequency-bands, deep learning network designed for single frequency-band has poor extraction accuracy when applied to SAR images with different frequency bands. So, how to achieve excellent extraction performance for water automatically

基金项目:长安大学中央高校基本科研业务费专项资金(300102262902);陕西省科技创新团队(2021TD-51);陕西省地学大数据与地质灾害防治创新团队(2022)。

第一作者:陈立福,博士,副教授,主要从事SAR智能感知方面的研究。lif_u_chen@csust.edu.cn

通信作者:李振洪,博士,教授。zhenhong.li@chd.edu.cn

from multi-source SAR images is still a challenge. **Methods:** We propose a new network framework, namely multi-level feature attention fusion network (MFAFNet). The network consists of encoder and decoder. The encoder utilizes ResNet-101 to generate four-level features with different resolutions, which are then processed in parallel by the intermediate level feature fusion module and efficient channel atrous spatial pyramid pooling module, and the intermediate and high-level features are output after deep fusion. The attention modulation module attention mechanism is introduced into decoder to distribute the weight of low-level features, then which are further fused with the high-level features from the encoder to obtain the water extraction results. **Results:** Experiments are carried out on SAR images with different frequency bands and resolutions (Sentinel-1, TerraSAR and Gaofen-3), and three good networks have been compared. The results show that the MFAFNet extraction effect is obviously better than other networks, with an average pixel accuracy of 87% and an average intersection over union of 0.80. **Conclusions:** The water body extraction from multi-band and multi-resolution SAR images is achieved, which promotes the practical application value of deep learning network in water body detection.

Key words: synthetic aperture radar (SAR); water extraction; deep learning; feature fusion; attention mechanism

合成孔径雷达(synthetic aperture radar, SAR)不受天气影响,可以全天时、全天候成像,具有监测范围广、成本低、效率高等优势。SAR图像中水体后向散射系数相对较低,在图像上表现为暗色。利用SAR图像进行水体检测,在城市水体监测、海岸线监测、洪涝灾害监测等方面具有重要应用价值^[1-3]。

许多学者在水体检测方面进行了相关研究,传统方法大体分为两类:阈值法^[4]和分类器法^[5]。阈值法是根据水体的光谱特征曲线选择合适的光谱带来建立模型,并根据一定的阈值确定规则进行水体提取。分类器法则是先通过支持向量机(support vector machine, SVM)训练样本的纹理信息,然后获得决策函数来区分水体,其中最常用的分类器是SVM。自2006年Lecun等提出深度学习^[6]后,越来越多的基于深度学习的水体检测方法脱颖而出并占据主流,实现了水体检测的自动化。如受计算机视觉领域的多尺度特征融合算法的启发,许多研究者探索了各种利用多尺度特征来提高分类精度的方法^[7-8];还有研究者利用像素作为节点,将像素之间的关系作为边,充分利用标记图像和观察图像的空间邻域信息,有效获取空间上下文信息来细化提取边界^[9-10];在数据处理方面,有研究者引入迁移学习,将已有的训练样本类别标签信息迁移至未标注的样本以降低获取新样本的人工成本^[11];还有研究者将遥感图像与GIS数据结合进行配准,在提取水体的同时进行变化检测^[12]。虽然这些方法一定程度上解决了传统方法中的阴影干扰和阈值设定等问题,但由于水体的类间相似性和类内差异

性,从不同频段和不同分辨率的SAR图像中自动、高精度地检测水体仍然存在很大挑战。

目前,在水体检测方面的研究基本都是基于单频段的SAR图像,在应用到其他频段时,往往得不到较为满意的结果,泛化能力不强。为解决以上问题,本文提出了一种多级特征注意力融合网络(multi-level feature attention fusion network, MFAFNet)来进行多频段、多分辨率SAR图像的水体高精度自动检测,并提出了中间级特征融合模块(intermedia-level feature fusion module, IF-FM),实现了对ResNet-101中间层输出特征的有效融合,丰富了图像信息,加强了网络对水体细节特征的学习;编码与解码模块分别融合了有效通道注意力(efficient channel attention, ECA)和注意调制模块(attention modulation module, AMM),实现了通道间信息权重的有效分布和边缘信息的充分提取,让网络学习到更为关键的水体特征。

1 多频段多分辨率SAR水体提取方法

1.1 整体网络框架

为实现多频段、多分辨率SAR图像水体的高精度自动提取,本文提出了MFAFNet框架,具体结构如图1所示。该框架主要包括编码器和解码器两个部分,编码器在数据中找到模式,生成简洁有用的表征;解码器利用这些表征生成高分辨率数据,并生成新的描述性知识。编码器包括3部分:骨干网络ResNet-101对图像进行初步特征提取、有效通道空洞空间卷积池化金字塔(effi-

cient channel atrous spatial pyramid pooling, ECASPP)模块对骨干网络输出的高级特征进行多尺度特征深入提取,IFFM 模块融合骨干网络输出的中间两级特征并提升空间细节表达。解

码部分包含 3 个输入:来自 ECASPP 模块的多尺度高级特征、IFFM 产生的中间级融合特征和来自骨干网络的低级特征,通过对这些特征的融合和处理产生最终的水体提取结果。

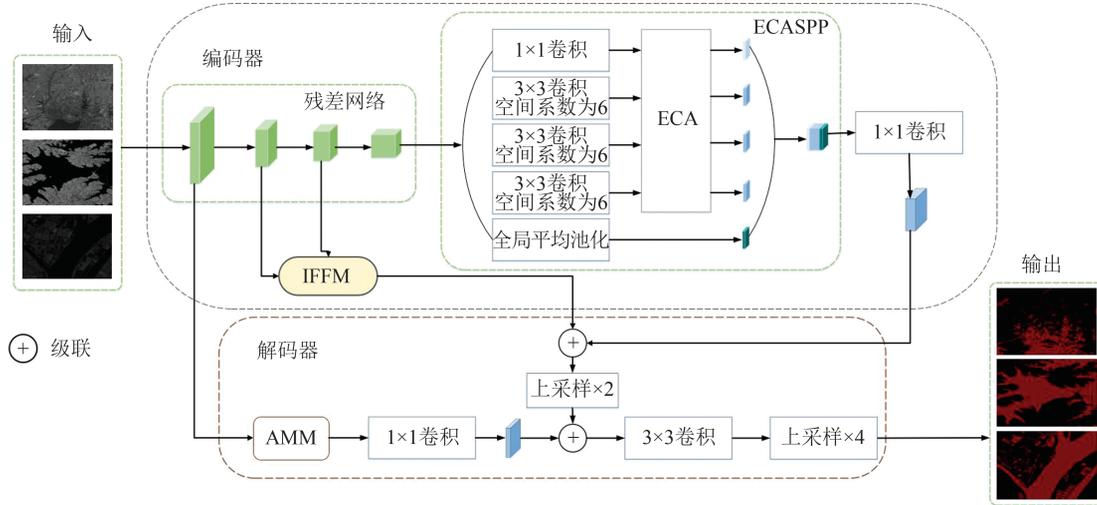


图 1 整体网络结构图

Fig. 1 Overall Network Structure Diagram

1.2 编码器

1.2.1 ResNet-101 主干网络

本文采用带有空洞卷积的 ResNet-101^[13] 作为骨干网络。ResNet 具有跳跃连接、优化残差等特点,非常适合搭建语义分割网络。首先经过一个卷积层和最大池化层降低图像分辨率,然后通过 4 个由残差单元组成的残差块进行初步语义特征提取。其中残差块 4 使用空洞系数分别为 2、4、8 的空洞卷积级联替换最后一个卷积层,加深网络层数,丰富特征图的语义信息。

1.2.2 IFFM

在深度学习网络中,融合不同尺度特征是提升分割性能的一个重要手段。低层特征分辨率更高,包含更多位置、细节信息,但是由于经过的卷积更少,其语义性更低,噪声更多。高层特征具有更强的语义信息,但是分辨率很低,对细节

的感知能力较差。如何将两者高效融合,对改善分割模型性能有着重要的作用。

因此,本文提出了 IFFM 来对 ResNet-101 输出的中间两层特征进行融合,具体结构如图 2 所示。首先将 ResNet-101 的第 3 层输出残差块 3 做 2 倍上采样,使其输出分辨率与第二层输出残差块 2 相等;然后对残差块 2 和修改分辨率后的残差块 3 分别使用 1×1 卷积和 3×3 卷积来统一通道个数;再将得到的两个特征图相乘得到初步融合结果,融合后的特征兼具高层特征的语义信息与低层特征的细节信息,推进了后续网络对图像像素的学习分类;接着经过一个 1×1 卷积使得融合后的特征通道数降为 256,以匹配经 ECASPP 模块处理后的高级特征,进而引入一个残差结构加深网络层数,在进行边缘信息定位的同时也确保分类精度的提升;最后输出到解码器。

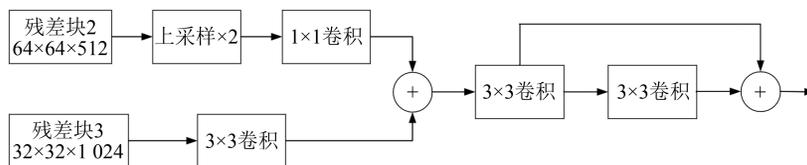


图 2 中间级特征融合 IFFM 结构

Fig. 2 IFFM Structure for Intermedia-Level Features Fusion

1.2.3 ECASPP 模块

本文构建的 ECASPP 模块由 5 个并行工作的分支组成(图 1),包括由 4 个不同空洞系数、不

同尺度的卷积与 ECA^[14]组成的 4 条并行注意力池化分支,以及一条全局平均池化(global average pooling, GAP)支路。ECASPP 的输入特征图包

含2048个通道和丰富的语义信息,其中GAP对特征图做降采样处理,以防止网络过拟合;4个不同尺度和空洞系数的卷积能有效从不同感受野上捕捉图像的上下文信息。ECA结合通道维度对多尺度特征进行优劣筛选,改善多尺度提取效果,提高了水体检测精度。

注意力机制被广泛应用于语义分割^[15]、目标检测^[16-17]等深度学习任务中。ECA先将输入特征图进行全局平均池化操作,然后进行卷积核大小为 k 的1维卷积操作,并经过Sigmoid激活函数得到各个通道的权重,将权重与原始输入特征图对应元素相乘,得到最终输出特征图。用一维卷积高效实现了局部跨通道交互来避免降维,提取通道间的依赖关系。卷积核 k 决定交互的覆盖范围,不同的通道数和不同卷积块交互范围可能会有所不同,因此认为 k 与通道维度 C 有关。当给定通道维度 C ,自适应确定内核大小 k ,计算公式为:

$$k = \psi(C) = \left\lfloor \frac{\log_2 C}{\gamma} + \frac{b}{\gamma} \right\rfloor_{\text{odd}} \quad (1)$$

式中, γ 取值为2; b 取值为1; C 为输入的通道维数; $\lfloor t \rfloor_{\text{odd}}$ 表示最接近 t 的奇数。

1.3 解码器

解码部分通过分步解码来提高像素间的连续性,内部结构如图1所示。它包含3个输入,即ECASPP模块输出的高级多尺度特征、骨干网络输出的低级特征、IFFM输出的中间融合特征。由于低层特征包含较多的冗余信息,因此本文引入AMM注意力机制^[18]增加边界信息权重,以获得更精准的水体边缘信息。

解码器首先对解码器输出的中级融合特征和多尺度高级特征拼接并进行2倍上采样得到融合特征,采用AMM注意力机制对ResNet-101输出的低级特征进行加权,加强水体目标权重,并通过 1×1 卷积减少通道冗余特征;然后将该特征与融合特征拼接,通过 3×3 卷积进行特征细化,再进行双线性插值4倍上采样得到最后的水体提取结果。

2 多频SAR水体检测实验结果分析

2.1 数据集

由于公开的高空间分辨率SAR数据集较少,本文在实验中使用的是自制数据集,使用Labelme软件进行水体区域人工标注并得到SAR专

家的确认。该数据集下包含3个子文件,分别为JPEGImages、SegmentationClass和ImageSets。其中,JPEGImages文件夹内是网络训练的SAR图像;SegmentationClass文件夹下存放的是与SAR图像相对应的标签;ImageSets文件夹内只有一个子文件夹Segmentation,包含两个txt文件,分别为train.txt和val.txt,用来记录训练集和验证集的图像名称。

本文采用的SAR图像来自3个SAR系统,分别为哨兵1号、TerraSAR和高分三号。其中哨兵1号是经过地理编码、地理配准后再进行去噪处理得到的干涉测量宽幅模式下的单极化强度影像,分辨率为 $5 \text{ m} \times 20 \text{ m}$,频段为C波段;TerraSAR影像是条带模式下、HH极化的单视复图像的强度图,分辨率为 3 m ,频段为X波段;高分三号是经过辐射定标、相干斑噪声滤波和强度影像生成最终产生的单极化强度图像,分辨率为 1 m ,频段为C波段。每个系统有3张 $20\,000 \times 20\,000$ 像素的高分辨率SAR图像,首先将大尺度的SAR图像使用滑窗切分方法生成 512×512 像素的图像,最终生成2895张样本,其中训练集和验证集的比例为4:1。此外,每个SAR系统预留出一张 $2\,000 \times 2\,000$ 像素的SAR图像进行独立测试。

2.2 训练参数设置

实验软件环境为:PyTorch 1.20, CUDA 10.0和Python 3.7;硬件环境为:CPU Intel至强金牌5120, GPU(单)NVIDIA RTX 2080Ti,显存为11 GB。

网络训练的过程中以ResNet为主干网络,学习率设置为0.005,权重衰减值为0.0005。输入图片的批大小为8,网络训练迭代100次,网络自动对比每次迭代后得到的新的损失,100次迭代结束后,网络自动找到损失最低的那次迭代得到的模型,为网络保存到最终训练结果最好的模型。

2.3 实验结果分析

为了更好地评估算法性能,本文采用用户精度(user's accuracy, UA)和交并比(intersection of union, IoU)作为评价指标。用 P_{UA} 描述水体提取精度; P_{IoU} 描述水体提取结果和水体标签之间的相似度,数值越大,意味着虚警越少,一般该数值超过0.5,就表示能获取不错的结果。计算公式如下:

$$P_{\text{UA}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}} \times 100\% \quad (2)$$

$$P_{IoU} = \frac{N_{TP}}{N_{TP} + N_{FP} + N_{FN}} \times 100\% \quad (3)$$

式中, TP(true positive)为真正例; FP(false positive)为假正例; FN(false negative)为假负例; N_{TP} 为被正确识别为水体的像素; N_{FP} 为被错误识别为水体的背景像素; N_{FN} 为被错分为背景的水体像素。

首先同时训练 3 个 SAR 系统的数据集, 然后分别测试不同的 SAR 系统图像, 每个系统预留了一个大尺度 SAR 影像进行算法的独立测试。为了验证本文提出的网络 MFANet 的有效性, 分别将本文算法与 DeepLabV3+^[19]、MF2AM(multilayer feature fusion attention mechanism)^[15]、SegFormer^[20] 3 个优秀分类网络进行对比实验。实验结果如图 3(哨兵 1 号数据)、图 4(TerraSAR 数据)和图 5(高分三号数据)所示, 图像大小均为 $2\,000 \times 2\,000$ 像素, 其中蓝色区域为水体部分, 绿色区域为漏检部分, 红色区域为虚警部分。

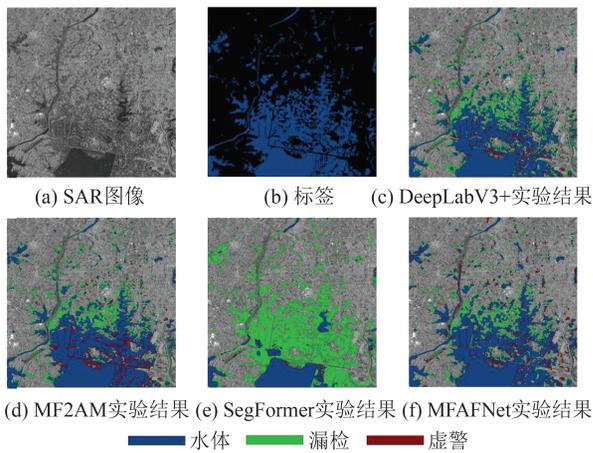


图 3 哨兵 1 号数据实验结果

Fig. 3 Experiment Results of Sentinel-1 Data

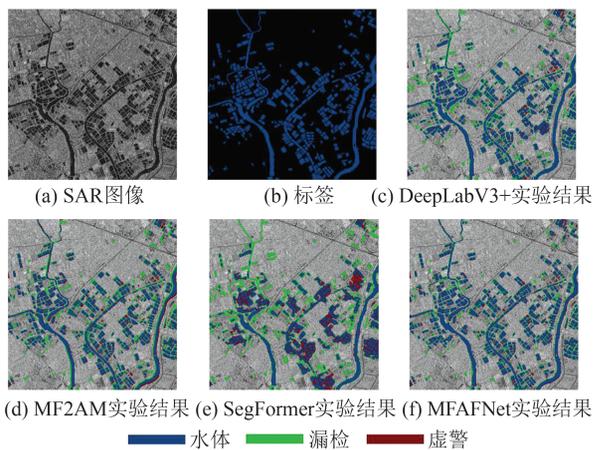


图 4 TerraSAR 数据实验结果

Fig. 4 Experiment Results of TerraSAR Data

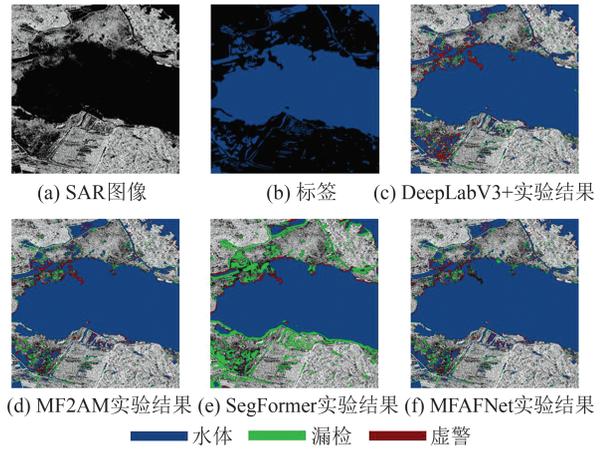


图 5 高分三号数据水体提取实验结果

Fig. 5 Experiment Results of Gaofen-3 Data

图 3 中 C 波段低分辨率的哨兵 1 号 SAR 图像中水体是一块大区域水体和多块小区域水体相邻, 还有一些零散的水体区域。由水体提取结果可知, 4 个网络水体提取结果和高分三号实验具有类似的特点, 其中 SegFormer 出现了太多的漏检, 本文提出的网络 MFANet 能较好地检测出水体目标。

图 4 为 TerraSAR 图像, 其中水体是由很多小块水体以及几条细长的河流组成, 整体上 4 个网络水体提取结果仍具有高分三号和哨兵 1 号水体提取的特点。但是 SegFormer 不仅出现了不少漏检, 还出现了较多的虚警; 本文提出的网络 MFANet 不仅漏检最少, 虚警也很少, 说明本文提出的 IFFM 和引入 AMM 对水体细节特征有更好的把握, 很好地学习到了水体特征。

由图 5 的高分三号 SAR 图像水体检测结果可知, 该 SAR 图像中主要是大片连通水域, 水体特征较为明显, 整体检测精度均较高。对于大区域水体部分, 几个算法基本都能正确检测, 而其他小块水域部分则出现了一些虚警和漏检。DeepLabV3+ 和 MF2AM 出现了明显的虚警, 漏警相对较少; SegFormer 虚警较少, 但出现了较多漏警; 本文提出的网络 MFANet 虚警较 DeepLabV3+ 和 MF2AM 大大减少, 漏检比 SegFormer 也少了很多, 取得了不错的检测效果。

由图 3~5 中不同波段和不同分辨率的 SAR 图像水体提取实验可知, 图像细节差别较大, 水体类型与特点也有很大不同。表 1 给出了 3 个实验对应的 4 个网络的水体检测指标。高分三号以大区域水体为主, 整体检测精度都比较高, 均达到了 90% 以上, 只有其中的 SegFormer 网络在 80% 左右, 本文网络比 DeepLabV3+ 提升了

2.3%。哨兵1号数据分辨率偏低,水体非大区域连通水体,检测精度有所降低,其中SegFormer网络精度只有26.0%,出现了大量漏检;而本文提出的网络MFAFNet检测精度达到了近84%,相比其他几个网络优势明显。TerraSAR图像为很多小块水体区域,对水体细节信息提取能力要求较高,整体水体检测精度都有所下降,其他网络都没有达到80%,MFAFNet实现了81.8%的检测精度,比其他网络有明显提升,比DeepLabV3+提高了7.5%。由这些指标可以发现,对于大尺度连通区域水体,大多数网络都能获取不错的检测结果,MFAFNet在检测效果上依然能有提升;而对于很多小的零散水体区域或规则的细长河流等水体,需要更强的细节信息和边缘信息的把握能力,MFAFNet的优势则凸显出来,检测精度较其他网络大大提升。

表1 不同网络对不同SAR系统水体提取指标/%

Table 1 Water Detection Indexes of Different Networks for Different SAR Systems/%

数据	网络算法	水体		背景	
		P_{UA}	P_{IoU}	P_{UA}	P_{IoU}
哨兵1号	DeepLabV3+	78.2	70.4	95.7	88.3
	MF2AM	81.8	71.8	94.5	88.4
	SegFormer	26.0	25.6	99.4	77.3
	MFAFNet	83.8	73.6	94.6	89.0
TerraSAR	DeepLabV3+	74.3	65.8	96.7	90.9
	MF2AM	77.1	72.5	97.5	93.3
	SegFormer	65.2	55.6	95.6	87.9
	MFAFNet	81.8	74.5	94.6	89.0
高分三号	DeepLabV3+	93.8	89.2	94.4	90.3
	MF2AM	93.9	91.7	95.5	92.6
	SegFormer	79.9	77.7	97.4	82.8
	MFAFNet	96.1	92.7	97.6	93.7

为更好地验证MFAFNet的效果,进行了消融实验,每个网络获得的3个独立测试区域的4个测试模型的平均水体检测精度如表2所示。由表2可知,利用原始DeepLabV3+网络检测3个不同波段和分辨率的平均水体检测精度为82.1%,交并比为75.1%。在原始DeepLabV3+中只替换了ECASPP模块,平均精度提升3.0%;只引入AMM模块,平均精度提升2.8%;只加入本文提出的IFFM模块,平均精度提升3.5%;这3个模块全部添加后(即本文提出的网络MFAFNet),平均精度提升了5.1%。由此可见,MFAFNet能有效提升多频SAR图像水体检测精度,且能获得较为满意的水体检测结果。

表2 消融实验结果

Table 2 Result of Ablation Experiment

网络算法	ResNet	ECASPP	AMM	IFFM	平均精度/%	
					P_{UA}	P_{IoU}
	✓	×	×	×	82.1	75.1
DeepLabV3+	✓	✓	×	×	85.1	79.7
	✓	×	✓	×	84.9	81.0
	✓	×	×	✓	85.6	80.8
	✓	✓	✓	✓	87.2	80.2

综合以上分析,本文提出的网络MFAFNet对水体区域的检测效果最好,漏检与虚警也最少,验证了本文算法提取水体区域的优越性。SegFormer的漏检最多,且在TerraSAR数据上虚警最多,MF2AM对高分三号与哨兵1号的虚警最多,说明其对特征的学习能力不够,网络不能很好地区分不同特征区域及其相似区域,因此检测完整性不高且存在虚警。而本文提出的IFFM加强了特征间的传递,编码器加入注意力舍弃了冗余特征,保留了有用特征,提高了网络对特征的学习能力;解码模块中引入AMM注意力,增强了网络对水体边缘信息的把握能力,因此MFAFNet能取得满意的水体提取结果。

3 结语

SAR图像水体检测具有重要的应用价值,目前仍以单频段SAR图像为主要数据源。但在应用中,对一种频段SAR图像产生的训练模型或设计的算法,应用到不同频段和分辨率的SAR图像中时,往往水体检测效果较差。因此,本文提出了MFAFNet,实现了对多频段、多分辨率SAR图像的水体提取,为后续学者利用SAR图像进行水体检测与实际应用提供参考。本文提出的IFFM和ECASPP模块以及融合的AMM注意力,使得MFAFNet把握水体细节特征和边缘信息的能力大大提升,获得了明显优于其他优秀分类网络的水体检测性能。

参考文献

- [1] MARTINIS S, GROTH S, WIELAND M, et al. Towards a Global Seasonal and Permanent Reference Water Product from Sentinel-1/2 Data for Improved Flood Mapping [J]. *Remote Sensing of Environment*, 2022, 278: 113077.
- [2] CHEN L F, ZHANG P, XING J, et al. A Multi-scale Deep Neural Network for Water Detection from SAR Images in the Mountainous Areas [J]. *Re-*

- ote Sensing*, 2020, 12(19): 3205.
- [3] ZHANG P, CHEN L F, XING J, et al. Water and Shadow Extraction in SAR Image Based on a New Deep Learning Network [J]. *Sensors*, 2019, 19(6): 3576.
- [4] XIE C, HUANG X, ZENG W X, et al. A Novel Water Index for Urban High-Resolution Eight-Band WorldView-2 Imagery [J]. *International Journal of Digital Earth*, 2016, 9(10): 925-941.
- [5] YAO F F, WANG C, DONG D, et al. High-Resolution Mapping of Urban Surface Water Using ZY-3 Multi-spectral Imagery [J]. *Remote Sensing*, 2015, 7(9): 12336-12355.
- [6] LECUN Y, BENGIO Y, HINTON G. Deep Learning [J]. *Nature*, 2015, 521(7553): 436-444.
- [7] LI Z Y, WANG R, ZHANG W, et al. Multiscale Features Supported DeepLabV3+ Optimization Scheme for Accurate Water Semantic Segmentation [J]. *IEEE Access*, 2019, 7: 155787-155804.
- [8] DUAN L H, HU X Y. Multiscale Refinement Network for Water-Body Segmentation in High-Resolution Satellite Imagery [J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 17(4): 686-690.
- [9] LI Y S, DANG B, ZHANG Y J, et al. Water Body Classification from High-Resolution Optical Remote Sensing Imagery: Achievements and Perspectives [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2022, 187: 306-327.
- [10] CHU Z Q, TIAN T, FENG R Y, et al. Sea-Land Segmentation with ResUNet and Fully Connected CRF [C]//IEEE International Geoscience and Remote Sensing Symposium, Yokohama, Japan, 2019.
- [11] 覃星力, 杨杰, 李平湘, 等. 迁移学习用于多时相极化 SAR 影像的水体提取 [J]. 武汉大学学报(信息科学版), 2022, 47(7): 1093-1102.
- QIN Xingli, YANG Jie, LI Pingxiang, et al. Water Body Extraction from Multi-temporal Polarimetric SAR Images Based on Transfer Learning [J]. *Geomatics and Information Science of Wuhan University*, 2022, 47(7): 1093-1102.
- [12] 眭海刚, 陈光, 胡传文, 等. 光学遥感影像与 GIS 数据一体化的水体分割、配准与提取方法 [J]. 武汉大学学报(信息科学版), 2016, 41(9): 1145-1150.
- SUI Haigang, CHEN Guang, HU Chuanwen, et al. Integrated Segmentation, Registration and Extraction Method for Water-Body Using Optical Remote Sensing Images and GIS Data [J]. *Geomatics and Information Science of Wuhan University*, 2016, 41(9): 1145-1150.
- [13] 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, Las Vegas, USA, 2016.
- [14] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: Efficient Channel Attention for Deep Convolutional Neural Networks [C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition, Seattle, WA, USA, 2020.
- [15] CAI X M, CHEN L F, XING J, et al. Automatic Extraction of Layover from InSAR Imagery Based on Multilayer Feature Fusion Attention Mechanism [J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 19: 4017705.
- [16] CHEN L F, LUO R, XING J, et al. Geospatial Transformer Is What You Need for Aircraft Detection in SAR Imagery [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5225715.
- [17] LUO R, CHEN L F, XING J, et al. A Fast Aircraft Detection Method for SAR Images Based on Efficient Bidirectional Path Aggregated Attention Network [J]. *Remote Sensing*, 2021, 13(15): 2940.
- [18] QIN J, WU J, XIAO X F, et al. Activation Modulation and Recalibration Scheme for Weakly Supervised Semantic Segmentation [J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2022, 36(2): 2117-2125.
- [19] CHEN L C, ZHU Y K, PAPANDREOU G, et al. Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation [C]//The European Conference on Computer Vision, Munich, Germany, 2018.
- [20] XIE E Z, WANG W H, YU Z D, et al. SegFormer: Simple and Efficient Design for Semantic Segmentation with Transformers [J]. *Advances in Neural Information Processing Systems*, 2021, 34: 12077-12090.