

DOI:10.19651/j.cnki.emt.2519745

# 基于改进的 DeepLabV3+ 的海岸线遥感图像分割方法

连帅

(中国飞行试验研究院 西安 710089)

**摘要:** 针对海岸线遥感图像存在的不规则边界精细化分割困难的问题,本文提出了非对称性多路解码的海岸线分割网络(AMDNet)。以 Deeplabv3+作为主干网络,通过使用 EfficientNet-B0 作为特征提取器,大幅降低网络计算量,并在改进的 ASPP 中引入 D-LKA 模块,添加额外的偏移量来调整标准卷积的采样位置,允许卷积核灵活调整采样网格,结合 DUpsampling 技术实现上采样过程中的高精度还原,提高图像分割的精确度。AMDNet 模型在 Aerial photo-maps 数据集上的准确率、灵敏度、Dice 和 Jaccard 分别达到了 96.77%、93.03%、90.42%、86.67%,性能提升明显。

**关键词:** 海岸线遥感图像分割;DeepLabV3+;可变大核注意力;EfficientNet

中图分类号: TP391.4; TN911.73 文献标识码: A 国家标准学科分类代码: 520.6040

## Coastal remote sensing image segmentation method based on the improved DeepLabV3+

Lian Shuai

(Chinese Flight Test Establishment, Xi'an 710089, China)

**Abstract:** Aiming at the difficulty in fine segmentation of irregular boundaries in coastal remote sensing images, this paper proposes an Asymmetric Multi-path Decoding Network for Coastline Segmentation (AMDNet). Taking Deeplabv3+ as the backbone network, the network uses EfficientNet-B0 as the feature extractor to significantly reduce the computational load of the network. Additionally, the D-LKA module is introduced into the improved ASPP to add extra offsets for adjusting the sampling positions of standard convolution, allowing the convolution kernel to flexibly adjust the sampling grid. Combined with DUpsampling technology to achieve high-precision restoration during the upsampling process, the accuracy of image segmentation is improved. The accuracy, sensitivity, Dice and Jaccard of the AMDNet model on the Aerial photo-maps dataset reach 96.77%, 93.03%, 90.42% and 86.67% respectively, showing a significant performance improvement.

**Keywords:** coastal remote sensing image segmentation; DeepLabV3+; deformable large kernel attention; EfficientNet

## 0 引言

海岸线作为海洋与陆地的动态交界线,是地球表面最为活跃和复杂的地理单元之一,不仅是海洋生态系统与陆地生态系统物质循环、能量交换的关键界面,还承载着港口建设、渔业生产、旅游开发、国防安全等多重战略功能,对沿海地区的经济发展、生态保护及社会稳定具有不可替代的作用<sup>[1]</sup>。然而,在全球气候变化与人类活动双重作用下,海岸线正面临着前所未有的动态变化挑战,海平面上升引发的海岸侵蚀、风暴潮导致的岸线后退、围填海工程造成的岸线人工改造、滨海湿地退化引发的岸线形态改变等问题日

益突出,准确掌握海岸线的时空变化规律已成为应对全球环境变化、保障沿海地区可持续发展的核心需求。

随着遥感技术的飞速发展,其具备的大范围覆盖、高时空分辨率、多光谱信息、周期性观测等优势,为海岸线监测提供了全新的技术途径。基于遥感影像的海岸线分割技术能够捕捉不同时空尺度、不同光谱特征的海岸带信息,已成为当前海岸线检测的主流技术。高分辨率遥感影像能够提供丰富的地物信息,如何有效利用遥感影像的纹理信息,克服遥感影像中同物异谱和异物同谱的挑战,是目前遥感影像分割技术急需解决的重要问题。

传统图像分割方法依赖数学模型、拓扑学及浅层图像

处理技术,通过人工设计特征实现地物与背景的分离,核心思路是利用地物的颜色、纹理、梯度等低级语义信息构建分割准则,主要分为基于边缘检测、基于阈值、基于区域及基于传统机器学习的四类方法<sup>[2-5]</sup>。边缘检测及阈值分割方法基于灰度、纹理或光谱的突变或者阈值设定进行图像识别,具有计算效率高、易实现的特点,但对复杂光谱混合的适应性较差。区域生长通过将相似像素(基于光谱、纹理或空间邻近性)聚合为区域实现分割,能有效保留地物的区域完整性,但对种子点依赖性强,易出现过生长或欠生长。传统机器学习方法通过训练数据学习地物特征与类别间的映射关系,摆脱了对人工特征的完全依赖,适用于多特征融合的遥感分割场景<sup>[6]</sup>。主流算法包括支持向量机(support vector machine, SVM)<sup>[7]</sup>、随机森林(random forest, RF)<sup>[8]</sup>、K-Means 聚类<sup>[9]</sup>及条件随机场(conditional random field, CRF)<sup>[10]</sup>等,但受限于特征表达能力,难以处理高分辨率遥感影像的复杂语义信息。

随着深度学习在计算机视觉领域的突破,卷积神经网络(convolutional neural networks, CNN)<sup>[11-12]</sup>、Transformer<sup>[13-14]</sup>等方法凭借强大的自主特征学习能力,成为遥感影像分割的主流技术。这类方法无需人工设计特征,能自动捕捉影像的高级语义信息,有效解决了传统方法对复杂场景适应性差的问题。近年来,Transformer凭借其强大的全局建模能力,被广泛应用于遥感图像分割领域。例如王立波采用基于Transformer的双路径网络结构,增设高分辨率特征提取路径,设计多层次特征融合模块和通道维度特征改善模块,提升建筑物边缘提取与优化能力<sup>[15]</sup>。此外,众多学者尝试通过注意力机制改善分割网络的特征捕捉能力。例如,Li等<sup>[16]</sup>提出一种协同注意力模块,通过协同机制让空间特征与通道特征在建模过程中相互引导,提升特征的判别能力,尤其针对弱目标、离散目标的识别精度。Yin等<sup>[17]</sup>提出多尺度上下文与线性自注意力的协同框架,有效提升了模型对边缘区域以及小目标的分割能力。

由于海岸线遥感图像中存在复杂地物特征背景,光谱信息特征多样、海岸线特征分布不清晰。为了提升方法准确性,基于深度学习技术的遥感图像分割方法需要大量的标记数据来进行训练,特别是对于遥感图像这种复杂的数据类型,数据获取与计算成本较高。

针对上述问题,本文提出了基于改进的DeepLabV3+的遥感影像分割网络。以Deeplabv3+作为主干网络,通过使用EfficientNet-B0作为特征提取器大幅降低网络计算量,并在改进的空洞空间金字塔池化(atrous spatial pyramid pooling, ASPP)方法中引入可变大核注意力(deformable large kernel attention, D-LKA)模块,添加额外的偏移量来调整标准卷积的采样位置,允许卷积核灵活调整采样网格,结合DUpsampling技术实现上采样过程中的高精度还原,提高图像分割的精确度。与传统基于编码-

解码结构的遥感影像分割方法相比,本文提出的模型更有效地融合了低级特征与高级语义特征,达到更高精度的分割效果。

## 1 网络模型总体设计

本文模型基于改进的DeeplabV3+[18]结构。现有模型在处理图像时常常面临复杂边界、误判等难题。此外,采用Xception(extreme inception)作为编码器基础架构,并与ASPP模块相结合时,会因为多次卷积操作导致模型中的参数数量大幅上升,这不仅增加了训练时间,还会导致网络收敛速度减缓,从而严重影响了模型的训练效率。

针对deeplabv3+网络存在的诸多缺陷,本文提出了如图1所示的改进遥感图像海岸线分割网络。首先利用Efficientnet-B0优势,替代了原来的Xception网络作为骨干网络,能够在更深层次及更广范围内提取语义特征,同时极大减少模型计算量。其次,由于原网络采用的上采样方法恢复精度较低,所以引入了可学习的上采样模块DUpsampling,使得网络模型的参数量和网络复杂度有了进一步的降低,与此同时保持了网络的分割性能。与此同时,引入了一个新的复合大核空洞卷积块(D-LKA atrous spatial pyramid pooling, DASPP),它能够捕获丰富的多尺度上下文信息,并生成更具深度的特征映射。而为了处理海岸遥感图像边缘模糊、不规则的问题,引入了D-LKA可变形大核卷积注意力,在采样时可以更贴近物体的形状和尺寸,更具有鲁棒性。

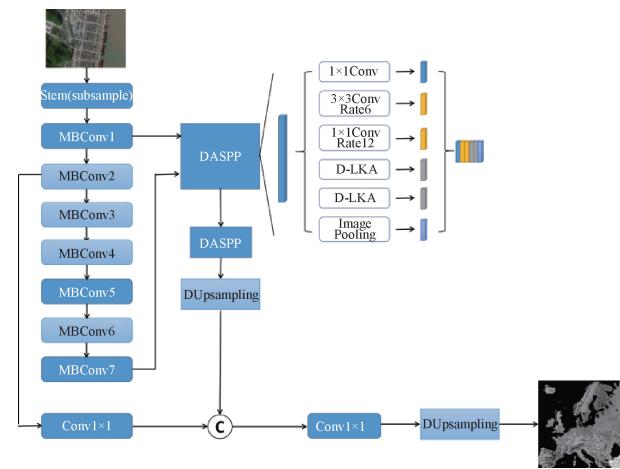


图 1 网络总体结构

Fig. 1 Overall network structure

## 2 详细设计

### 2.1 Efficient 网络

本文采用Efficientnet<sup>[19]</sup>替换传统DeeplabV3+的特征提取网络。EfficientNet-B0采用了一种创新的缩放策略,区别于传统的单一维度缩放(如仅深度或宽度),它采用一组预先设定的缩放系数,同步地调整网络的深度、宽度以

及分辨率,以实现更高效的模型优化。这种方法实现了网络结构的均衡扩展,保证了在各个维度上的增长是协调一致的。因此,选择 EfficientNet-B0 作为海岸线遥感图像分割的 backbone,能够充分利用其高效的特性来提高网络性能。如表 1 所示,模型一共分为 8 个 stage,表中的卷积层后默认都跟有 BN 以及 Swish 激活函数。stage 1 是一个  $3 \times 3$  的卷积层。stage 2~stage 8 是重复堆叠 MBConv。表中分辨率是每个输入特征矩阵的高度和宽度,层数则是将 Operator 重复多少次。

MBConv 模块结构如图 2 所示,执行流程始于对输入特征图应用  $1 \times 1$  的逐点卷积,目的是增加通道数,实现升维。接下来,采用深度卷积,其中使用的卷积核尺寸为  $k \times k$ ( $k$  通常为 3 或 5),步长为 1 或 2。此后,通过 SE 模块对通道间的关系权重进行学习。紧接着,经过  $1 \times 1$  的逐点卷积恢复到初始的通道数,后跟 Dropout 层。最终,通过添加

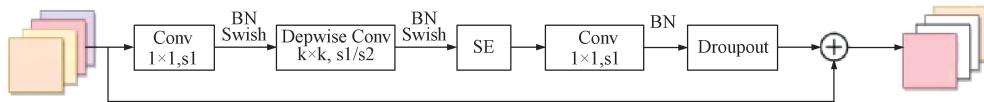


图 2 MBConv 结构图

Fig. 2 MBConv structure diagram

## 2.2 DUpsampling 模块

在语义分割任务中,编解码方案的上采样环节是至关重要的,它负责将特征图的分辨率恢复到与原始输入相同的尺寸。此过程中,常用的技术有双线性插值和卷积的组合使用。当其与随后的卷积操作相结合时,能够达到与转置卷积相近的效果。然而,若采用诸如外围补零等其他策略,则可能会不必要地引入大量冗余信息,从而影响模型性能。

本文不采用普通的上采样方法其原因在于,那些方法并未充分考虑到像素点标签之间的关联性,即数据间的独立性,这在一定程度上限制了其在语义分割任务中的性能表现。这一情况将导致两个方面的问题:

1)采用多个扩张卷积来降低整体编码步长。然而,这种做法带来了更高的计算复杂性和内存占用,从而阻碍了在大规模数据训练和实时应用部署方面的进展。

2)解码器在语义分割过程中负责整合来自不同层级的信息,特别是较低层级的特征。然而,由于双线性上采样在恢复特征细节方面的能力有限,最终预测的精细程度往往受到低层级特征分辨率的制约。因此,为了生成更高分辨率的预测结果,解码器需要采取策略将高分辨率特征有效地嵌入到较低层次的表示中。

为了应对这些挑战,引入了 DUpsampling,该方法巧妙利用了分割标签空间中的冗余信息,使得像素级预测的精准恢复成为可能,同时减轻了对卷积解码器的高度依赖。因此,无需大幅减小整体步幅,这一改进不仅简化了分割框架,更显著降低了整个计算过程中的时间和内存消耗,其结构如图 3 所示。

跳跃连接,实现特征矩阵的相加输出,通过跳跃连接加速训练过程,提升模型的性能。与传统卷积相比,这种结构大大减少了参数量,并显著增强了学习能力。

表 1 EfficientNet-B0 网络参数

Table 1 EfficientNet-B0 network parameters

阶段	运算操作	分辨率	通道数	层数
1	Conv $3 \times 3$	$224 \times 224$	32	1
2	MBCov1	$112 \times 112$	16	1
3	MBCov6	$112 \times 112$	24	2
4	MBCov6	$56 \times 56$	40	2
5	MBCov6	$28 \times 28$	80	3
6	MBCov6	$14 \times 14$	112	3
7	Conv $1 \times 1$	$7 \times 7$	1 280	1

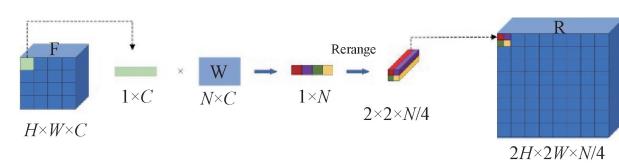


图 3 DUpsampling 结构图

Fig. 3 DUpsampling structure diagram

如图 3 所示,上采样过程将特征图的分辨率扩大,例如将尺寸为  $H \times W \times C$  的特征图上采样至  $2H \times 2W \times N/4$ 。这意味着每个特征图中的像素会被扩展为 4 个像素的表示。在 DUpsampling 方法中,对于特征图中的每个像素(其维度为  $1 \times C$ ),通过乘以一个待训练的权重矩阵  $W$ (其维度为  $N \times C$ ),最终得到  $1 \times N$  的特征表示。然后通过 rearrange 操作,将  $1 \times N$  的特征表示重新排列为  $2 \times 2 \times N/4$  的格式,完成上采样过程。权重矩阵  $W$  的计算依据是已知的训练标签,而真实的分割结果在训练集中是已知的。通过对每个分割图进行矩阵转换,将其映射到与特征图相同的维度,以便更好地完成上采样任务。

## 2.3 D-ASPP 架构

ASPP 模块对所给定的输入以不同采样率空洞卷积并行采样,用于提取多尺度特征。然而,如果卷积步长和膨胀率的设置不当,某些像素在空洞卷积计算过程中,可能始终未参与计算,使得提取特征丢失了部分重要的局部信息。因此,本文采用如图 4 所示的方法,在 ASPP 模块中,增加了 D-LKA 模块,通过可变形大核卷积注意力,增强模型的感受野,提升对复杂不规则边界的特征提取能力。

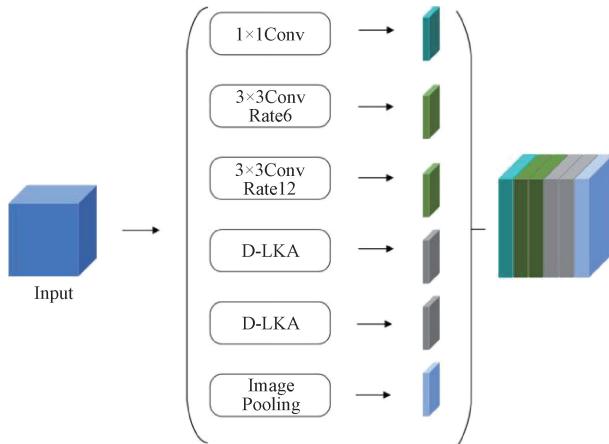


图 4 改进的 ASPP 结构示意图

Fig. 4 Improved ASPP structure diagram

如图 5 所示, D-LKA 的核心理念是将大核注意力和可变形卷积的相结合, 以实现类似自我关注的感受野, 同时避免了传统自我关注方法所带来的高计算成本。此外, D-LKA 还通过可变形卷积的方式来动态地调整采样网格, 从而使模型更灵活地适应不同尺度的目标。

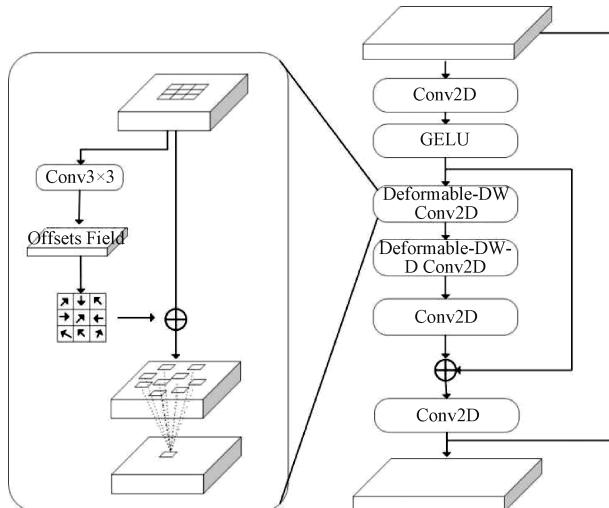


图 5 D-LKA 结构示意图

Fig. 5 D-LKA structure diagram

大核注意力采用大卷积核捕捉长距离依赖关系, 它将  $K \times K$  卷积核分解为一个深度膨胀卷积、深度卷积和  $1 \times 1$  卷积, 可以用更少的参数和计算来构造大卷积核。对于  $H \times W$  维输入和通道  $C$ , 构造  $K \times K$  核的深度卷积和深度膨胀卷积的核大小方程如式(1)和(2)所示。

$$DW = (2d - 1) \times (2d - 1) \quad (1)$$

$$DW - D = \left\lceil \frac{K}{d} \right\rceil \times \left\lceil \frac{K}{d} \right\rceil \quad (2)$$

可变形卷积基于特征本身学习形变, 实现自适应卷积核的生成。这种灵活的卷积核形状有助于更好地捕捉海岸线边界特征, 从而提高了目标特征的捕捉能力。负责计

算偏移的卷积层遵循其相应卷积层的核大小和膨胀。对于不在图像网格上的偏移量, 采用插值来计算像素值。

D-LKA 模块特征提取输出可以表述为:

$$\text{Attention} = \text{Conv}1 \times 1(\text{DDW} - D - \text{Conv}(\text{DDW} - \text{Conv}(F'))) \quad (3)$$

$$\text{Output} = \text{Conv}1 \times 1(\text{Attention} \otimes F') + F \quad (4)$$

其中, 输入特征表示为  $F \in R^{C \times H \times W}$ ,  $F' = \text{GELU}(\text{Conv}(F))$ 。注意力分量  $\text{Attention} \in R^{C \times H \times W}$  表示为注意力映射, 每个值表示相应特征的相对重要性。运算符  $\otimes$  表示按元素的乘积运算。DDW-Conv 表示可变形深度卷积, DDW-D-Conv 表示可变形深度膨胀卷积, Conv  $1 \times 1$  表示  $1 \times 1$  卷积。

### 3 实验设计与分析

#### 3.1 数据集简介

本研究采用空中摄影地图(aerial photo-maps)数据集<sup>[20]</sup>, 该数据集是结合了高分辨率航空摄影图像和地图元素(如标签、街道名称和重要地标)的地图。该数据集包含了成对的航拍所得的遥感图像以及对应的谷歌地图。该数据集共训练集包括 1 096 对图像, 测试集包括 1 098 对图像, 每对图像的像素尺寸为  $600 \times 600$ 。如图 6 所示, 本文经过图像二值化, 从中挑选出包含海洋和陆地的数据样本共 340 对, 处理出标准图像, 将无用的语义特征去除。

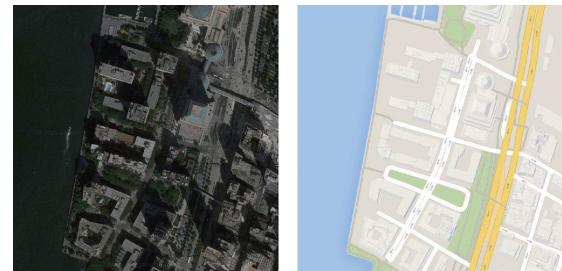


图 6 Aerial photo-maps 数据集样本图

Fig. 6 Aerial photo-maps dataset sample image

本文基于谷歌地图的灰度图像, 人工标定海洋位置初始种子, 采用区域生长法将地图分为海洋与非海洋目标的二值图像, 以此作为遥感影像对应的标注数据。模型评估采用 100 对样本作为训练集, 240 对样本作为测试集。

Aerial photo-maps 数据集提供了城区与海洋的遥感信息, 可用于海岸线变化监测, 从而指导陆地及基础海防设施的建设。

#### 3.2 实验环境

如表 2 所示为本次实验所用的计算机配置和实验环境。

#### 3.3 评价指标

为了量化评估本文提出的模型的有效性, 本文采用了以下 4 种评估指标, 包括 Dice 相似系数(DC)、Jaccard 指数(JA)、灵敏度(SE)和精确度(AC)。评价指标如式(5)~(8)所示。

表 2 计算机配置和实验环境表

Table 2 Computer configuration and experimental environment

设备名称	型号
GPU	Tesla V100
CPU	Core i7-13900K
操作系统	Ubuntu 20.04
编程语言	Python 3.7.3
深度学习算法框架	PyTorch1.13.1
加速库	CUDA11.6

$$DC = \frac{2 \times TP}{(2 \times TP + FP + FN)} \quad (5)$$

$$JA = \frac{TP}{(TP + FP + FN)} \quad (6)$$

$$SE = \frac{TP}{TP + FN} \quad (7)$$

$$AC = \frac{TP + TN}{TP + FP + TN + FN} \quad (8)$$

DC(Dice 系数)和 JA(Jaccard 指数)是用于评估预测的图像分割结果与真实标签之间重合程度的标准。精度(AC)衡量的是模型预测的准确性,而敏感度(SE)衡量的是模型预测的完整性。

### 3.4 实验结果分析

图 7 对比了本文方法与 DeepLabV3+ 的模型参数量,相比于原始网络结果,本文模型参数量也从 54 713 557 减少到 8 603 375,减少至原网络的 1/6,有效降低了模型的计算开销。

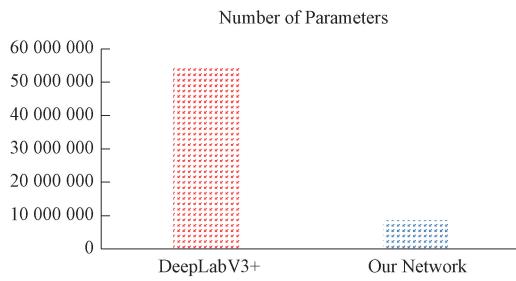


图 7 参数量比较

Fig. 7 Parameter quantity comparison

为了获得本文方法的最优参数,表 3 对比了不同优化方法、学习率、批大小、迭代次数的模型准确率。

在比较 Adam 优化器与随机梯度下降法(SGD)后发现,Adam 在平均精度和训练收敛速度上均优于 SGD。在学习率的设置上,实验对比了 0.001、0.000 1、0.000 2 三个不同设置,结果显示 0.001 的学习率能够获得更好的检测效果。迭代次数的实验表明,当迭代次数达到 60 次时,模型性能趋于饱和。最后,通过对批大小进行比较,发现当批大小设置为 8 时,模型表现最佳。根据模型训练损失图 8 可以看出,模型经过 60 个 epoch 时趋于收敛。

为了进一步证明本文提出的模块的有效性,本文分别基于 50 对训练数据以及 100 对训练数据进行了以下消融实验。以原始的 deeplabv3+ 作为基准,通过控制不同主干网络、特征提取模块以及上采样模块的加入与否进行实验分析,验证模块的有效性,实验结果如表 4、5 所示。从表中可知,本文算法的精度、灵敏度、Dice 系数、Jaccard 指数均优于其他组合方法,表明本文算法具有较强的分割能力,总体性能较好。

表 3 参数优化实验表

Table 3 Parameter optimization experiment

实验编号	优化方法	学习率	批大小	迭代次数	准确率 / %
1	SGD	0.000 1	4	50	95.65
2	SGD	0.000 2	4	50	95.78
3	AdamW	0.000 1	4	50	95.73
4	AdamW	0.000 2	4	50	95.84
5	AdamW	0.000 1	8	50	96.02
6	AdamW	0.000 1	16	50	95.38
7	AdamW	0.000 1	32	50	95.39
8	AdamW	0.001	4	50	95.93
9	<b>AdamW</b>	<b>0.001</b>	<b>8</b>	<b>60</b>	<b>96.77</b>
10	AdamW	0.001	8	40	94.41
11	AdamW	0.001	8	80	96.63

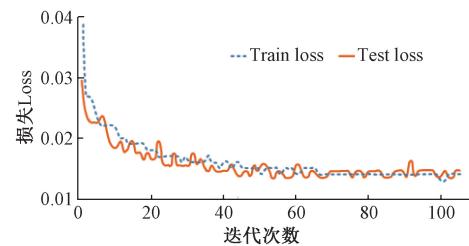


图 8 模型训练损失曲线图

Fig. 8 Model training loss curve chart

表 4 50 对训练数据消融实验

Table 4 Ablation experiment with 50 pairs of training data

实验编号	Efficiency	DA	DUpsampling	AC	SE	DC	JA
1				88.27	85.36	82.15	79.23
2	✓			90.33	86.41	84.76	81.57
3		✓		89.10	87.38	83.76	81.03
4			✓	90.86	86.75	84.12	81.28
5	✓	✓		91.74	88.32	85.34	81.98
6		✓	✓	92.03	89.21	85.97	82.13
7	✓		✓	91.98	89.19	85.24	81.83
8	✓	✓	✓	<b>92.73</b>	<b>89.70</b>	<b>86.34</b>	<b>82.67</b>

为了进一步验证模型的性能,对各组消融对比方法进行 10 次重复统计验证,以 10 次结果的均值与方差作为模型性能的对比指标,结果如图 9、10 所示。从图中可以发

现,本文算法在具有较高的精度、灵敏度、Dice 系数、Jaccard 指数的同时,其误差分布范围在大部分情况优于对比方法,模型稳定性较好。

表 5 100 对训练数据消融实验

Table 5 Ablation experiment with 100 pairs of training data

实验 编号	Efficien- tB0	DA SPP	DUpsa- mpling	AC	SE	DC	JA
1				92.52	90.34	87.52	81.53
2	✓			93.36	91.08	87.81	83.74
3		✓		92.61	90.75	87.64	82.83
4			✓	93.47	91.46	88.10	84.36
5	✓	✓		94.78	91.89	88.93	85.31
6		✓	✓	95.63	92.43	89.41	85.97
7	✓		✓	95.47	92.18	88.96	85.55
8	✓	✓	✓	<b>96.77</b>	<b>93.03</b>	<b>90.42</b>	<b>86.67</b>

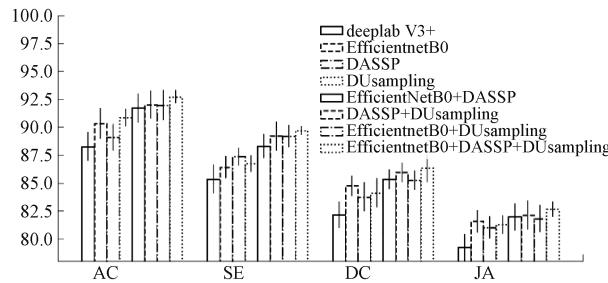


图 9 50 对训练数据消融实验

Fig. 9 Ablation study on 50 pairs of training data

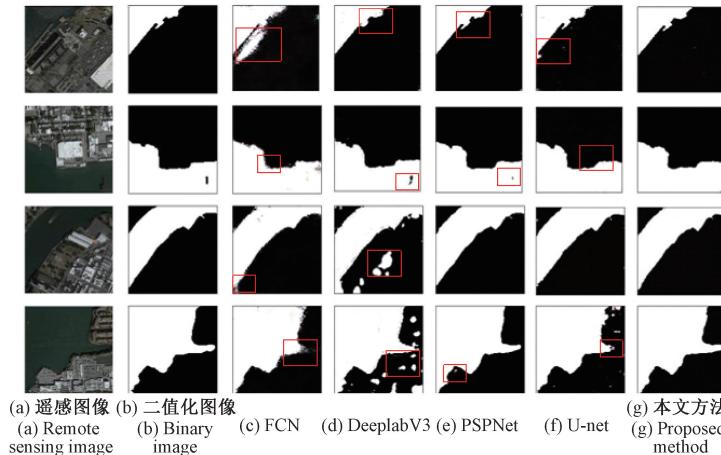


图 11 不同模型实验结果图

Fig. 11 Comparison chart of experimental results for different models

表 6 本研究实验对比结果

Table 6 Comparison results of experiments in this study

网络模型	AC	SE	DC	JA
FCN	86.52	89.56	84.89	83.56
U-Net	93.82	92.61	89.62	85.33
PSPNet	94.15	91.85	85.82	84.72
DeepLabV3+	92.52	90.34	87.52	81.53
本研究方法	<b>96.77</b>	<b>93.03</b>	<b>90.42</b>	<b>86.67</b>

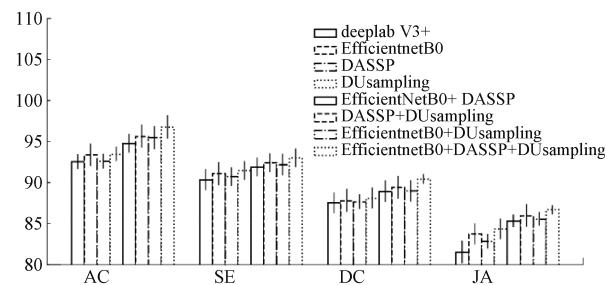


图 10 100 对训练数据消融实验

Fig. 10 Ablation study on 100 pairs of training data

为进一步验证模型性能,本文对比了 FCN(全卷积网络)、DeepLabV3+ 模型、U-net 模型、PSPNet<sup>[21]</sup>等典型分割方法。图 11 为不同方法的分割效果图,从图中可知,FCN 和 DeepLab V3+ 两个分割模型,海岸线边缘划分较模糊。而目前主流网络 U-net 和 PSPNet 在分割清晰度上与本研究提出方法不相上下,但是在背景不同的情况下细节处理方面有所缺失,有众多边缘细小噪音块,网络并不适用复杂背景下的遥感图像分割中。而本文方法分割精度与实际分割边界十分接近,并且在有复杂背景影响下,分割效果图中,没有明显噪音块。

上述各算法的具体性能如表 6 所示。从表 6 中可得,本文提出的海岸线遥感图像分割网络取得了比较好的实验效果。准确率相比于其他网络模型提高了 2.26%~

10.25%,灵敏度提高了 0.42%~3.47%,相似系数提高了 0.8%~5.53%,Jaccard 系数值提高了 1.34%~4.14%,性能提升明显。

## 4 结 论

本文提出改进的 DeepLapV3+ 的海岸线遥感图像高效分割模型,以 EfficientNet-B0 作为主干架构,成功强化了图像内部特征的提取,利用改进的 D-ASPP 架构提升模

型对复杂边界的分割能力,引入了 DUpsampling 技术,实现对目标特征更为细致的关注,使得网络在图像分割任务中更加精准。但由于本文方法的特征提取设计,使得模型更容易过拟合与当前数据集特征,模型在未知数据集泛化性能有待提升。如何提升模型对于海岸线泛化特征的提取将是未来研究工作的重点。

本文方法针对复杂背景下不规则海岸线的分割及检测更加准确,能够提高国防测绘、海岸线检测、灾害预警等应用的效率和精度。

## 参考文献

- [1] 吴一全,刘忠林.遥感影像的海岸线自动提取方法研究进展[J].遥感学报,2019,23(4):582-602.  
WU Y Q, LIU ZH L. Research progress on methods of automatic coastline extraction based on remote sensing images[J]. Journal of Remote Sensing, 2019, 23(4): 582-602.
- [2] 董亦凡,孙文礼,赵洋,等.遥感图像半监督语义分割方法研究综述[J/OL].计算机工程与应用,1-21[2025-09-01 ]. <https://link.cnki.net/urlid/11.2127.TP.20250619.1548.010>.  
DONG Y F, SUN W L, ZHAO Y, et al. A review of semi supervised semantic segmentation methods for remote sensing images[J/OL]. Computer Engineering and Applications, 1-21 [ 2025-09-01 ]. <https://link.cnki.net/urlid/11.2127.TP.20250619.1548.010>.
- [3] WANG ZH B, WANG E, ZHU Y. Image segmentation evaluation: A survey of methods[J]. Artificial Intelligence Review, 2020, 53: 5637-5674.,
- [4] SUN R, LEI T, CHEN Q, et al. Survey of image edge detection[J]. Frontiers in Signal Processing, 2020, 2:826967.
- [5] YU Y, WANG CH P, FU Q, et al. Techniques and challenges of image segmentation: A review [J]. Electronics, 2023, 12(5):1199.
- [6] MINAEE S, BOYKOV Y, PORIKLI F, et al. Image segmentation using deep learning: A survey[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 44(7):3523-3542.
- [7] YANG AI M, BAI Y J, LIU H X, et al. Application of SVM and its improved model in image segmentation[J]. Mobile Networks and Applications, 2022, 27 ( 3 ): 851-861.
- [8] 王荣康,熊俊楠,唐浩然,等.融合高程信息与随机森林模型的改进区域合并算法[J].测绘通报,2025(4):114-119.  
WANG R K, XIONG J N, TANG H R, et al. Improved region merging algorithm combining elevation information with random forest model[J]. Bulletin of Surveying and Mapping, 2025 ( 4 ): 114-119.
- [9] 姬强,孙艳丰,胡永利,等.深度聚类算法研究综述[J].北京工业大学学报,2021,47(08):912-924.  
JI Q, SUN Y F, HU Y L, et al. Review of clustering with deep learning[J]. Journal of Beijing University of Technology, 2021,47(8):912-924.
- [10] SAHIN H M, MIFTAHUSHUDUR T, GRIEVE B, et al. Segmentation of weeds and crops using multispectral imaging and CRF-enhanced U-Net[J]. Computers and Electronics in Agriculture, 2023, 211: 107956.
- [11] HUSSAIN T, SHOUNO H, MOHAMMED M A, et al. DCSSGA-UNet: Biomedical image segmentation with DenseNet channel spatial and semantic guidance attention [ J ]. Knowledge-Based Systems, 2025, 314:113233.
- [12] HE Q B, SUN X, DIAO W H, et al. Multimodal remote sensing image segmentation with intuition-inspired hypergraph modeling[J]. IEEE Transactions on Image Processing, 2023, 32:1474-1487.
- [13] JAIN J, LI J, CHIU M T, et al. Oneformer: One transformer to rule universal image segmentation[C]. IEEE/CVF conference on Computer Vision and Pattern Recognition(CVPR), 2023:2989-2998.
- [14] XU ZH Y, ZHANG W C, ZHANG T X, et al. Efficient transformer for remote sensing image segmentation [ J ]. Remote Sensing, 2021, 13 (18):3585.
- [15] 王立波,高智,王桥.融合遥感指数协同推理的地表异常检测方法[J].电子与信息学报,2025, 47 ( 6 ): 1669-1678.  
WANG L B, GAO ZH, WANG Q. A novel earth surface anomaly detection method based on collaborative reasoning of deep learning and remote sensing indexes [ J ]. Journal of Electronics & Information Technology, 2025, 47(6): 1669-1678.
- [16] LI X, XU F, LIU F, et al. A synergistical attention model for semantic segmentation of remote sensing images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2023,61:1-16.
- [17] YIN P, ZHANG D M, HAN W, et al. High-resolution remote sensing image semantic segmentation via multiscale context and linear self-attention [ J ]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2022, 15:9174-9185.
- [18] YU L J, ZENG ZH X, LIU AO, et al. A lightweight

- complex-valued DeepLabv3 + for semantic segmentation of PolSAR image[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2022, 15: 930-943.
- [19] TAN M. Efficientnet: Rethinking model scaling for convolutional neural networks [J]. ArXiv preprint arXiv: 1905.11946, 2019.
- [20] CHEN L, 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.
- [21] ZHAO H SH, SHI J P, QI X J, et al. Pyramid scene parsing network[C]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 2881-2890.

### 作者简介

连帅(通信作者),硕士,高级工程师,主要研究方向为飞行试验测试与测量技术、试验数据处理技术等。  
E-mail:lianshuai9@163.com