

董建宾, 李卫国, 戴佩玉, 等. 基于残差多尺度提取网络模型(ResMSFCN)和无人机遥感影像的蟹塘水草信息提取[J]. 江苏农业学报, 2026, 42(2): 349-356.

doi: 10.3969/j.issn.1000-4440.2026.02.013

# 基于残差多尺度提取网络模型(ResMSFCN)和无人机遥感影像的蟹塘水草信息提取

董建宾<sup>1,2</sup>, 李卫国<sup>1,2</sup>, 戴佩玉<sup>2</sup>, 毛星<sup>2</sup>, 金晶<sup>2</sup>

(1.南京信息工程大学生态与应用气象学院, 江苏 南京 210044; 2.江苏省农业科学院农业信息研究所, 江苏 南京 210014)

**摘要:** 蟹塘中的水草不仅能够净化水质、增加溶氧量、提供饵料, 夏季高温期还可为螃蟹提供遮阳和栖息的场所。目前, 水产养殖过程中水草种植信息的获取主要依靠人工判断, 存在劳动力成本高、时效性差以及效率低等问题。为了有效解决以上问题, 本研究选取南京市高淳区和无锡市宜兴市大闸蟹养殖塘作为研究区, 将卷积神经网络与无人机高空间分辨率多光谱影像相结合, 构建基于无人机多光谱影像的多时相蟹塘水草分布数据集, 提出基于残差多尺度提取网络的水草信息精细提取模型(ResMSFCN), 并与 U-Net 模型和 DeepLabv3+模型进行精度比较。结果表明, ResMSFCN 模型具有较好的水草影像提取能力, 准确率达 0.963, 交并比达 0.804。此外, 该模型能精准识别 6 月份至 10 月份 5 个时相的水草分布区域均匀度。本研究提出的基于无人机多光谱影像和 ResMSFCN 结合的蟹塘水草信息提取模型能高精度、高效率获取蟹塘多时相水草覆盖信息, 为蟹塘水草资源快速评估提供科学依据。

**关键词:** 蟹塘; 水草; 卷积神经网络; 无人机遥感; 多光谱影像

**中图分类号:** S127 **文献标识码:** A **文章编号:** 1000-4440(2026)02-0349-08

## Extraction of aquatic plant information in crab ponds using a residual multiscale fully connected neural network (ResMSFCN) and unmanned aerial vehicle remote sensing images

DONG Jianbin<sup>1,2</sup>, LI Weigu<sup>1,2</sup>, DAI Peiyu<sup>2</sup>, MAO Xing<sup>2</sup>, JIN Jing<sup>2</sup>

(1. School of Ecology and Applied Meteorology, Nanjing University of Information Science & Technology, Nanjing 210044, China; 2. Institute of Agricultural Information, Jiangsu Academy of Agricultural Sciences, Nanjing 210014, China)

**Abstract:** Aquatic plants in crab ponds not only purify water quality, increase dissolved oxygen, and provide food, but also offer shading and habitats for crabs during the high-temperature period in summer. Currently, the acquisition of aquatic plant planting information in aquaculture mainly relies on manual judgment, which has problems such as high labor costs, poor timeliness, and low production efficiency. To effectively solve these issues, this study selected crab ponds for Chinese mitten crabs in Gaochun District of Nanjing and Yixing City of Wuxi as the research areas. Combining convolutional neural networks with high-spatial-resolution multispectral images acquired by unmanned aerial vehicles (UAVs), a multi-

temporal dataset of aquatic plant distribution in crab ponds based on UAV multispectral images was constructed. A fine extraction model for aquatic plants based on the residual multiscale fully connected neural network (ResMSFCN) was proposed, and its accuracy was compared with U-Net and DeepLabv3+ models. The results showed that the ResMSFCN model had better ability to

收稿日期: 2025-05-07

基金项目: 江苏省重点研发计划项目(BE2022366); 江苏现代农业产业单项技术研发项目[CX(23)3131]

作者简介: 董建宾(1999-), 男, 山东聊城人, 硕士研究生, 研究方向为农业遥感信息技术及应用。(E-mail) kovacs991@163.com

通讯作者: 戴佩玉, (E-mail) pydai@whu.edu.cn

extract aquatic plant images, with an accuracy of 0.963 and an intersection over union (*IoU*) of 0.804. In addition, this model could accurately identify the uniformity of aquatic plant distribution areas across five temporal phases from June to October. The model proposed in this study, which combines UAV multispectral images with ResMSFCN for aquatic plant extraction in crab ponds, can acquire multi-temporal aquatic plant coverage information with high precision and efficiency, and also offer a scientific basis for the rapid evaluation of aquatic plant resources in crab ponds.

**Key words:** crab pond; aquatic plants; convolutional neural network; unmanned aerial vehicle remote sensing; multispectral images

作为中国水产养殖业的重要组成部分,大闸蟹(*Eriocheir sinensis*)养殖的产业规模与经济产值均处于领先地位<sup>[1]</sup>。水草在蟹塘生态系统中具有关键作用,不仅能通过调节水体溶氧量维持生态平衡,还能在夏季高温时为大闸蟹提供蜕壳栖息与遮阳场所,同时可作为补充饵料供其摄食<sup>[2]</sup>。因此,在集约化大闸蟹养殖模式下,水草群落的构建、监测与维护是保障大闸蟹产量的重要环节。传统蟹塘水草监测主要依赖人工现场勘查,不仅耗时耗力,难以快速获取大范围水草分布信息,且监测结果易受天气与人为因素干扰。随着现代信息技术的快速发展,大数据、人工智能、无人机遥感等技术手段为蟹塘数字化、智能化管理提供了新契机。这不仅能实现大闸蟹养殖的科学化、精细化管理,助力水产养殖信息化水平全面提升,而且能推动水产养殖业高质量发展,为现代化农业建设提供有力支撑。

结合卫星遥感影像,大型内陆湖泊水生植物监测已取得诸多进展<sup>[3-9]</sup>,相关方法主要分为基于光谱特征提取的分类方法和基于深度学习的语义分割方法两大类。在基于光谱特征提取的分类方法中,研究者普遍采用美国 Landsat 系列、国产 HJ-CCD 等中空间分辨率卫星影像,综合植被指数、水体指数等特征,运用 ISODATA 聚类、决策树、随机森林等算法开展水生植被信息提取与分类研究。例如, Dai 等<sup>[4]</sup>基于美国 Landsat 影像开发自动分类算法,对长江流域湖泊水下植被进行分类; Albright 等<sup>[5]</sup>结合多平台卫星遥感图像与 ISODATA 聚类分析算法,监测美国夏普湖中卷曲水草的分布动态; Zhao 等<sup>[7]</sup>利用美国 Landsat 影像数据,联合归一化差值植被指数 (*NDVI*)、改进的归一化水体指数 (*MNDWI*) 构建决策树模型,实现太湖水生植被信息的提取; 闫大鹏等<sup>[8]</sup>将国产 HJ-CCD 影像与浮叶植被敏感光谱指数 (*FVSI*)、沉水植被敏感光谱指数 (*SVSI*) 相结合,构建分类决策树模型,完成洪泽湖水生植被分类; 侍昊

等<sup>[9]</sup>基于美国 Landsat 8 影像,通过构建多个特征变量并结合随机森林模型,实现太湖水生植被分类。尽管该类方法对水生植被的监测效果显著,但依赖大量高质量训练数据,在复杂场景处理中存在一定局限性。随着深度学习技术的发展,基于神经网络的水生植被分类方法逐渐成为研究热点。Gao 等<sup>[10]</sup>利用 Sentinel-2 MSI 数据,提出基于 Res-U-Net 的水生植被分类模型,其分类精度与 Kappa 系数均优于传统方法,且在云阴影和水华影响下仍能保持较高识别能力; Pande-Chhetri 等<sup>[11]</sup>采用 CASI 高光谱传感器获取航空影像,对比机器学习 (Machine learning, ML)、人工神经网络 (Artificial neural network, ANN)、支持向量机 (Support vector machine, SVM) 等算法在复杂水体水生植被分类中的表现,证实了深度学习方法的优越性。

由于蟹塘普遍面积较小、养殖密度较高,加上水生植物分布不规则,所以中等空间分辨率影像难以满足蟹塘水草信息精确提取的需求。随着无人机 (Unmanned aerial vehicle, UAV) 技术的飞速发展,无人机影像凭借高空间分辨率和信息获取灵活等优势<sup>[12-13]</sup>,在农业与生态监测方面得到广泛应用<sup>[13-20]</sup>。目前已有研究人员围绕无人机可见光影像<sup>[14,19]</sup>、多光谱影像<sup>[17,20]</sup>及高光谱影像<sup>[21-24]</sup>在农业领域展开探索,这些成果为蟹塘水草信息提取研究提供了新的突破口。然而在实际应用场景中,蟹塘水草无人机遥感数据仍然匮乏,同时将深度学习模型直接迁移应用于水草信息提取任务时,其泛化能力不足的问题也较为突出,这些挑战严重制约了蟹塘水草信息的提取。

针对上述问题,本研究提出一种将无人机多光谱遥感影像与 ResMSFCN 网络结合的蟹塘水草信息提取方法,对研究区内水草信息进行提取,为大闸蟹养殖的科学化管理提供信息依据。该方法主要包含两个创新点:一是构建基于无人机多光

谱影像的蟹塘水草分布数据集。该数据集适配蟹塘面积小、养殖密度高、水生植物分布不规则的场景特点,解决了当前蟹塘水草无人机影像数据集缺失的问题;二是提出残差多尺度提取网络(Residual multiscale fully connected neural network, ResMSFCN)。该网络包含4大创新模块:通过引入残差学习机制,有效缓解梯度消失问题,进而帮助网络学习到更深层次的水草特征;集成通道注意力机制,让模型自适应学习不同特征通道的重要性,增强对水草关键区分特征的关注度;采用多尺度特征融合模块,融合不同层级特征信息,同时捕捉水草的全局分布特征与局部细节特征;引入Focal Loss损失函数,动态调整易分与难分样本的损失权重,使模型更专注于学习较难分类的样本,以应对样本类别不平衡问题。

## 1 材料与方法

### 1.1 研究区概况

研究区位于江苏省南京市高淳区和无锡市宜兴市大闸蟹养殖示范基地,采集的蟹塘水花生和苦草如图1所示。无人机多光谱影像数据采集时间为2024年6月至10月。



图1 蟹塘中水花生和苦草示例

Fig.1 Examples of *Alternanthera philoxeroides* and *Vallisneria natans* in crab ponds

### 1.2 无人机多光谱影像采集与处理

采用大疆DJI精灵4无人机多光谱版作为主要数据采集设备,在距离地面100m的固定高度采集蟹塘水草多光谱影像。为避免光谱畸变,确保数据准确性,每次影像采集时间控制在9时至14时。该无人机配备了先进的成像系统,包含1个可见光成像(RGB)的彩色传感器和5个多光谱成像的单个传感器:蓝(B)、绿(G)、红(R)、红边(RE)、近红外(NIR)光谱成像传感器<sup>[25]</sup>。摄像头传感器的波段信息如表1所示。

表1 无人机传感器波段信息

Table 1 Unmanned aerial vehicle (UAV) sensor band information

波段	中心波长 (nm)	波长带宽 (nm)
蓝(B)	450	±16
绿(G)	560	±16
红(R)	650	±16
红边(RE)	730	±16
近红外(NIR)	840	±26

为保证数据质量,本研究对原始影像进行了一系列预处理:首先,使用DJI Terra软件对航拍影像进行初步处理,包括航线裁剪、靶标布设、辐射校正和形变校正。其次,利用ArcGIS软件对校正后的影像进行地理配准,确保其与实际地理位置的一致性。最后,在ENVI软件中对5个波段的影像进行波段合成,并进行坐标投影变换,从而得到覆盖整个研究区的高质量多光谱遥感影像。预处理后的无人机影像空间分辨率为0.05m。

按照领域专家指导以及实地调研结果,通过ENVI、ArcGIS等软件在经过预处理的无人机影像上手动标注水草位置,构建蟹塘水草分布数据样本库。水草样本标签如图2所示,人工标注的标签,白色区域表示水草,黑色区域表示背景。




图2 水草样本标注示例

Fig.2 Examples of aquatic plant sample labeling

采用滑动窗口的方式将预处理后的无人机影像及其标签影像裁剪为256×256大小的数据块,以提升GPU的计算效率,同时更好适配CNN网络层的卷积核滑动和池化操作。通过水平、垂直、主对角线和副对角线等镜像变换操作进行数据增强,最终构建蟹塘水草分布数据集。经过数据增强后,将数据

集按比例进行划分,用于蟹塘水草分类模型的训练、验证及测试,其中训练集12 660张,验证集3 165张,测试集5 714张。

### 1.3 ResMSFCN 网络

针对蟹塘水草在无人机多光谱影像中形态多变、边界模糊、易受水体环境干扰等问题,本研究提出了一种残差多尺度提取网络(Residual multiscale

fully connected neural network, ResMSFCN),该网络基于 U-Net 架构,融合了残差学习、多尺度融合、通道注意力和边界细化机制,旨在提升特征表达能力、融合多尺度信息并提高水草边缘分割精度。模型将 5 通道多光谱影像作为输入,输出影像对应尺寸的二值分割掩膜。基于多光谱遥感影像和 ResMSFCN 结合的蟹塘水草信息提取架构如图 3 所示。

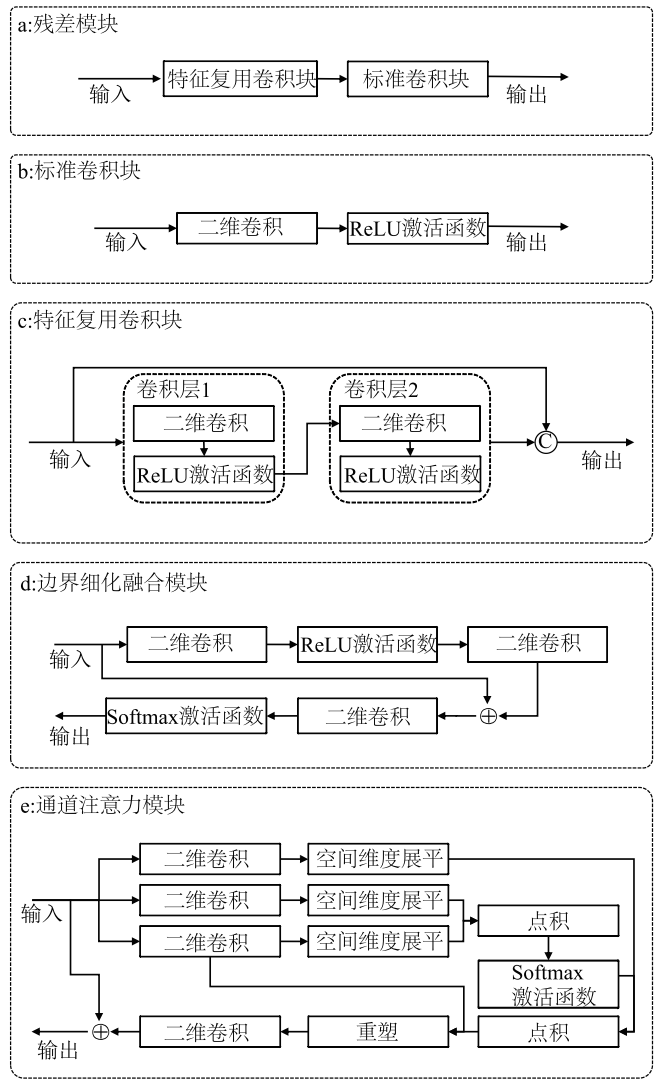
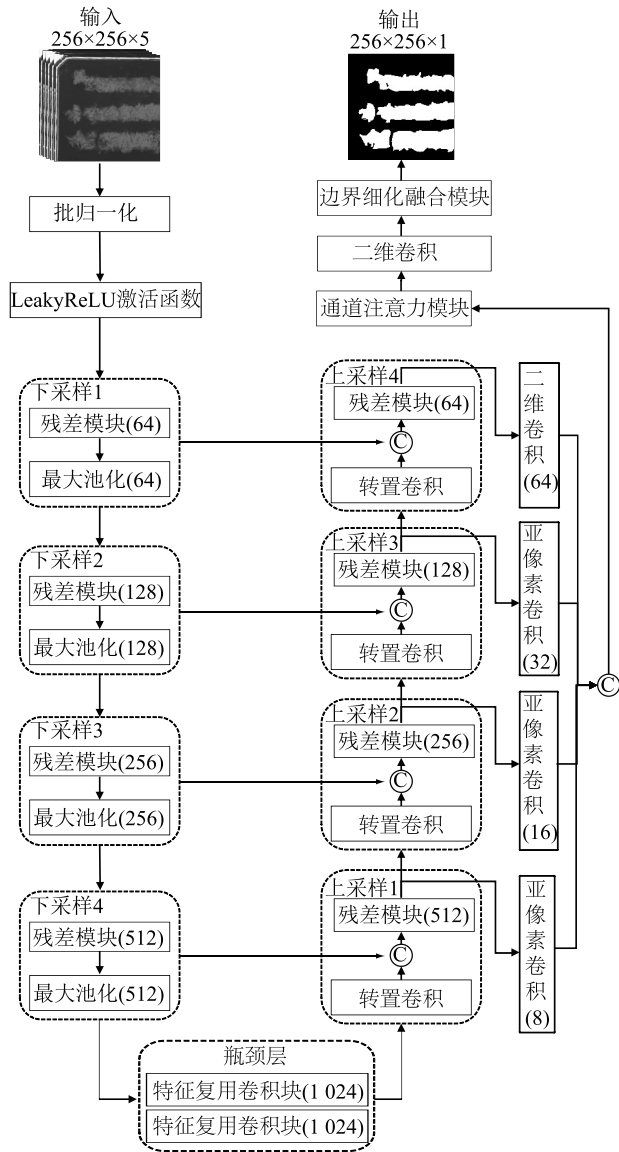


图 3 多光谱遥感影像和 ResMSFCN 结合的蟹塘水草信息提取架构

Fig.3 Architecture for extracting aquatic plant information in crab ponds based on multispectral remote sensing images and residual multi-scale fully connected neural network ( ResMSFCN)

与标准 U-Net 使用普通卷积层不同,ResMSFCN 在编码器和解码器的多个阶段均采用残差学习模块(图 3a)替代传统的卷积层。残差连接使网络在训

练过程中更容易学习输入与输出之间相同的映射关系,有助于缓解训练中的梯度消失问题。其中,残差模块内的标准卷积块(图 3b)由“二维卷积→ReLU

激活函数”组成;特征复用卷积块(图 3c)则通过“卷积层 1(二维卷积→ReLU 激活函数)→卷积层 2(二维卷积→ReLU 激活函数)”的结构实现特征复用与强化。在解码层后,通过多尺度特征融合模块,将不同阶段提取的特征输出,利用亚像素卷积操作进行高效上采样至原始输入分辨率并串联,以增强模型对不同尺寸水草目标的感知能力,同时多阶段的特征融合可有效保留更多细节信息,减少特征损失。在通道注意力模块之后引入边界细化融合(BRF)模块(图 3d),将经过通道注意力模块处理后的特征图作为输入,先通过卷积与 ReLU 激活函数生成掩码,初步筛选特征,再利用 2 次卷积操作,提取并增强输入特征图中的边界信息,最后,将主分支与掩码分支的结果相加,有助于细化边界,增强水草边缘及关键特征,缓解梯度消失问题。引入通道注意力模块(CAM)<sup>[26]</sup>(图 3e),旨在自适应地学习每个特征通道的重要性,通过对通道间相互依赖关系进行精确建模,量化通道之间的关联性,对信息量大的特征通道进行权重增强处理,在特征层面实现高效筛选的同时去除特征冗余信息。针对蟹塘水草图像中存在的类别不平衡问题,在损失计算过程中引入了焦点损失函数(Focal Loss)。蟹塘水草影像中,水体像素远多于水草像素,通过动态调整易分和难分样本在损失计算中的权重,使模型在训练过程中更专注于学习比较难分类的水草样本,例如水草边缘、小目标以及被遮挡的部分,提升模型对少量样本部分的识别精度。Focal Loss 的计算公式如下所示:

$$FL(p_i) = -\alpha_i(1-p_i)^\gamma \lg(p_i) \quad (1)$$

式中, $\alpha_i$  为权重因子; $p_i$  为样本预测概率。当真实标签为 1 时, $\alpha_i = \alpha$ ;  $p_i = p$ 。当真实标签为 0 时, $\alpha_i = 1-\alpha$ ;  $p_i = 1-p$ 。其中  $\alpha$  是超参数,研究中取值为 0.25; $\gamma$  是调节因子,用于降低容易分类样本的权重,研究中取值为 2。

#### 1.4 试验环境与评价指标

模型训练使用 Ubuntu 系统服务器平台,基于 Tensorflow 1.15.3 和 Keras 2.2.5 深度学习框架实现,计算设备为 NVIDIA-A100-PCIE-40GB 显卡。训练参数设置方面,初始学习率为  $1 \times 10^{-4}$ ,批处理大小为 32。在模型测试阶段,选取最优模型(训练过程中经过验证集交叉验证得到的损失最低的模型)进行性能评估。

为了评估模型性能,选取准确率(Accuracy)、召

回率(Recall)、精确率(Precision)和交并比(IoU)共 4 个图像分割评价的常用指标评估模型性能。准确率是模型正确预测的样本数占总样本数的比例,用来反映整体分类或分割的准确程度。召回率指模型正确预测为正类的样本数占实际正类样本数的比例,体现识别正类样本的能力。精确率是模型预测为正类的样本中真正为正类的比例,衡量预测正类的准确性。交并比通过计算预测的分割区域与真实目标区域的交集和并集的比例,综合评估分割的精确性和完整性,是语义分割任务中最关键的评价指标之一。4 个指标的计算公式如下:

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$

$$Recall = \frac{TP}{TP+FN} \quad (4)$$

$$IoU = \frac{TP}{TP+FP+FN} \quad (5)$$

式中,TP 表示实际类别为正类,模型预测为正类的样本数量;FP 表示实际类别为负类,但模型预测为正类的样本数量;TN 表示实际类别为负类,模型预测为负类的样本数量;FN 表示实际类别为正类,但模型预测为负类的样本数量。

## 2 结果与分析

### 2.1 不同卷积神经网络模型水草信息提取效果对比

本研究在无人机多光谱蟹塘水草分布数据集上对 3 种深度学习模型进行了训练和测试,并通过客观评价指标对水草信息提取结果进行量化分析。表 2 为 U-Net、DeepLabv3+、ResMSFCN 3 种模型提取效果对比。如表 2 所示,U-Net 模型虽然在召回率方面表现最佳(0.956),但其精确率(0.796)明显低于另外 2 个模型,说明该模型将背景误判为水草的情况较多。主要是因为其相对简单的 U 形编码器-解码器结构,在区分视觉特征相似的水草与复杂背景时表现不佳,导致分割精确度不高,存在过分割误检现象,容易受到噪声干扰。DeepLabv3+模型的精确率(0.882)高于另外 2 个模型,说明其在减少误分类方面表现好。主要得益于其使用的空洞卷积和 ASPP 模块,能够扩大感受野,使模型捕获到更广泛的空间上下文信息,有助于理解水

草与周围水体环境的关系,从而减少错误分类。但是其召回率(0.891)相对较低,表明模型在识别真实水草时较为保守,会存在遗漏情况,可能是在下采样的过程中丢失了一定的细节信息导致的。ResMSFCN 以较为简单的结构以及丰富的集成模块,在综合表现上获得了最优性能,准确率与交并比均为三者中最佳,分别达到 0.963 与 0.804。这得益于其残差连接结构有效缓解了深层网络的梯度消失问题,同时结合通道注意力机制聚焦于水草的重要特征通道,以及多尺度特征融合模块捕获不同尺度的水草特征信息,实现了各项指标的良好平衡表现。由表 2 可以看到,所测试的 3 种卷积神经网络模型均在水草信息提取任务上展现出良好性能,验证了深度学习方法在蟹塘水草识别任务中的有效性以及对相关领域的适用性。

表 2 不同模型在无人机多光谱蟹塘水草数据集上的提取效果

Table 2 Extraction effect of different models on unmanned aerial vehicle (UAV) multispectral crab pond aquatic plant dataset

模型	准确率	召回率	精确率	交并比
U-Net	0.945	0.956	0.796	0.767
DeepLabv3+	0.956	0.891	0.882	0.796
ResMSFCN	0.963	0.913	0.870	0.804

## 2.2 不同水草提取模型的分割效果对比


图 4 展示了 U-Net 模型、DeepLabv3+ 模型与 ResMSFCN 模型的部分蟹塘水草信息提取结果。I 区中 3 种模型均有不错的水草信息提取结果,ResMSFCN 模型效果最好,水草边缘分割明确,与标签最接近。II 区中 U-Net 模型对影像的分割结果整体粘连情况严重,DeepLabv3+ 模型在水草边缘误检较多且细节信息提取不足,ResMSFCN 模型细节信息提取较好、边界识别清晰、误检较少,识别效果较好。III 区中 ResMSFCN 模型对细节信息识别更加丰富,整体效果较好。IV 区中 U-Net 模型误检严重且细节信息提取不足,DeepLabv3+ 模型粘连情况明显,ResMSFCN 模型提取结果与标签重合度最高,误检区域极少,整体提取效果最好。V 区域中 U-Net 模型边缘细节粗糙,DeepLabv3+ 模型存在漏检情况,ResMSFCN 提取效果优异,误检情况较少,边缘信息提取准确,整体细节信息充足。

U-Net 模型的目视效果验证了其高召回率和低精确率的性能表现。如图 4C 所示,在部分水面反光或水

底阴影的情况下,U-Net 模型容易将背景元素误分类为水草,误检区域表现为散点状或小块状,存在明显的过分割现象。对于水草边界的分割准确性较差,容易混淆视觉上相似的背景与水草。DeepLabv3+ 模型的目视结果(图 4D)显示,对于大片连贯的水草区域识别效果不错,但在处理部分零散分布的小块水草区域时,时常会出现漏检或错误合并的情况。并且预测结果的水草边缘相对粗糙,分割边缘会呈现出锯齿状,对于水草的轮廓细节信息无法做到精确提取。这种情况验证了其召回率较低、交并比表现一般的结果。小目标的提取效果较差可能是由于模型的空洞卷积感受野过大,解码器在重建小目标时细节能力不足。ResMSFCN 模型(图 4E)对水草图像的整体分割效果在 3 个模型中表现最佳,水草边缘分割清晰,大、小块水草信息提取较为完整,细节信息提取清晰,其提取结果与真实标签相比差异较少。但在水体较深或光照不佳的区域,ResMSFCN 模型存在将水下阴影或饲料沉积物等非水草目标误判为水草的情况,导致一定程度的误检。同时,对于受到水体轻微遮挡的浅层水草以及处于阴影下半遮蔽状态的水草区域存在一定的漏检现象。说明该模型在水体环境复杂时存在一定的局限性,特别是在光谱特征受到水体干扰的场景下,对这些特殊特征的提取学习能力不足。从目视判读结果来看,与表 3 的结论基本一致。所有模型都能够基本正确识别蟹塘中的水草区域,但不同模型在细节处理、边界保持和复杂场景适应性上存在差异。

对不同时期提取的水草影像进行对比分析,结果如图 5 所示,包括 6 月份影像(图 5I)、7 月份影像(图 5II)、8 月份影像(图 5III)、9 月份影像(图 5IV)、10 月份影像(图 5V)。从影像提取效果看,U-Net 模型容易将部分背景误判为水草,尤其是在 7 月份,此时水草处于快速生长期,塘内水草长势较旺盛,植被面积明显增多。在水草较密集区域,分割结果容易将大片区域粘连在一起(图 5C)。DeepLabv3+ 模型对大面积水草信息的提取较为清晰完整;但在 8 月份,由于高温天气水草易受高温胁迫致死,塘内水草覆盖面积大幅减少。在水草稀少并且较破碎的背景下,DeepLabv3+ 模型对于小尺度水草信息的提取效果较差,也会有粘连现象(图 5D)。ResMSFCN 模型对水草信息的提取效果整体发挥较为出色,无论是 6 月份水草生长前期,还是 7 月、9 月大面积正常生长的水草,漏检误检情况均较少,并且边缘分割清晰、区块信息提取

完整、细节信息提取比较准确(图 5E)。



I ~ V:蟹塘中不同区域影像。A:假彩色影像;B:标签;C:U-Net 模型提取的结果;D:DeepLabv3+模型提取的结果;E:ResMSFCN 模型提取的结果。


图 4 不同模型对蟹塘中不同区域水草影像的提取结果

Fig.4 Extraction results of aquatic plant images from different regions in crab ponds by different models

### 3 讨论

从蟹塘水草信息提取效果来看,U-Net 模型的经典语义分割网络架构相对简单,在复杂背景下难以精准区分水草与背景,易将部分背景误判为水草,分割能力有限,但整体效果尚可。DeepLabv3+模型通过空洞卷积与空洞空间金字塔池化,能有效捕获多尺度上下文信息,在大面积水草识别中具有优势,但对零碎区域水草常出现漏检、误检情况,且水草边缘信息提取相对粗糙。本研究基于 U-Net 模型结构改进构建的 ResMSFCN 模型,以相对轻量且易实现的网络结构,取得了优异的蟹塘水草影像分割性能,不仅水草信息提取边缘清晰、区块完整,细节信息提取也更准确。

尽管 ResMSFCN 模型在蟹塘水草提取任务中表现优异,但仍存在一定局限性,有进一步改进空间;在模型层面,可针对性优化 ResMSFCN 网络,提升其在复杂水体环境中的水草信息提取精度;在数据源方面,本研究采用多光谱影像数据进行分类提取,未来



I:6月影像;II:7月影像;III:8月影像;IV:9月影像;V:10月影像。A:假彩色影像;B:标签;C:U-Net 模型提取的结果;D:DeepLabv3+模型提取的结果;E:ResMSFCN 模型提取的结果。

图 5 不同模型在不同月份水草影像提取结果

Fig.5 Extraction results of aquatic plant images by different models across different months

可尝试将现有模型与高光谱图像等其他数据源相结合,进一步提高分割精度,增强模型对不同数据源的适配性;本研究聚焦水草与非水草二分类任务,后续可拓展至多种水草类型的识别与分类,为蟹塘养殖环境的精细化管理提供更详实的信息支持;模型的时空泛化能力可进一步提升,本研究数据集仅覆盖 2024 年 6 月至 10 月,而水草分布会随年份养殖情况动态变化,未来研究工作可扩展至更广泛的时间与地理空间范围,系统评估模型的时空泛化能力。

### 4 结论

针对蟹塘水草信息提取任务中存在的边界模糊、样本类别不均衡及复杂水体环境干扰等问题,本研究以 U-Net 模型为基础进行改进,通过引入残差学习、多尺度特征融合、通道注意力机制(CAM)、边界细化融合模块(BRF)以及 Focal Loss 损失函数,构建残差多尺度全连接神经网络模型(ResMSFCN)。该模型对无人机多光谱影像蟹塘水草分布数据集具有较好的分割提取性能:(1)结合无人机多光谱影像数据,构建了覆盖多时相的蟹塘水草数据

集,解决目前尚未有公开蟹塘水草无人机影像数据集的问题,实现了对蟹塘水草分布的高精度语义分割。(2) ResMSFCN 模型在蟹塘水草测试集上的准确率和交并比分别达到 0.963 和 0.804,显著优于 U-Net 模型和 DeepLabv3+模型。(3) ResMSFCN 模型的残差模块有效缓解了深层网络的梯度消失问题,通道注意力机制通过自适应筛选关键特征通道增强了模型对水草光谱特征的关注度,多尺度融合模块整合了全局与局部的特征信息,边界细化融合模块则针对性地提升了对水草边缘的分割精度。此外,Focal Loss 损失函数的引入缓解了水草与背景像素的类别不均衡问题,使模型更专注于难分类样本的学习。

#### 参考文献:

- [1] 赵德安,罗吉,孙月平,等. 河蟹养殖自动作业船导航控制系统设计与测试[J]. 农业工程学报,2016,32(11):181-188.
- [2] 沈启扬,朱虹,孙龙霞,等. 虾蟹池塘养殖水草收割机应用现状及发展前景[J]. 江苏农机化,2020(1):13-15.
- [3] 马荣华,孔繁翔,段洪涛,等. 基于卫星遥感的太湖蓝藻水华时空分布规律认识[J]. 湖泊科学,2008,20(6):687-694.
- [4] DAI Y H, FENG L, HOU X J, et al. An automatic classification algorithm for submerged aquatic vegetation in shallow lakes using Landsat imagery[J]. Remote Sensing of Environment,2021,260:112459.
- [5] ALBRIGHT T P, ODE D J. Monitoring the dynamics of an invasive emergent macrophyte community using operational remote sensing data[J]. Hydrobiologia,2011,661(1):469-474.
- [6] 李俊生,吴迪,吴远峰,等. 基于实测光谱数据的太湖水华和水生高等植物识别[J]. 湖泊科学,2009,21(2):215-222.
- [7] ZHAO D H, LV M T, JIANG H, et al. Spatio-temporal variability of aquatic vegetation in Taihu Lake over the past 30 years[J]. PLoS One,2013,8(6):66365.
- [8] 闫大鹏,周兴东,刘伟,等. 一种基于高斯拟合的水生植被遥感分类阈值确定方法[J]. 西安科技大学学报,2018,38(5):776-782.
- [9] 侍昊,李旭文,牛志春,等. 基于随机森林模型的太湖水生植被遥感信息提取[J]. 湖泊科学,2016,28(3):635-644.
- [10] GAO H Y, LI R R, SHEN Q, et al. Deep-learning-based automatic extraction of aquatic vegetation from Sentinel-2 images: a case study of lake Honghu[J]. Remote Sensing,2024,16(5):867.
- [11] PANDE-CHHETRI R, ABD-ELRAHMAN A, JACOBY C. Classification of submerged aquatic vegetation in Black River using hyperspectral image analysis[J]. Geomatica,2014,68(3):169-182.
- [12] 于堃,单捷,王志明,等. 无人机遥感技术在小尺度土地利用现状动态监测中的应用[J]. 江苏农业学报,2019,35(4):853-859.
- [13] 宋恩泽,张颖,邵光成,等. 基于无人机多光谱遥感的农业园区地物分类研究[J]. 江苏农业学报,2023,39(9):1862-1871.
- [14] 孙月平,刘勇,郭佩璇,等. 基于改进 YOLO v8n-seg 的蟹塘水草区域分割与定位方法[J]. 农业工程学报,2024,40(17):224-233.
- [15] YU Z J, XIE T Y, ZHU Q B, et al. Aquatic plants detection in crab ponds using UAV hyperspectral imagery combined with transformer-based semantic segmentation model[J]. Computers and Electronics in Agriculture,2024,227:109656.
- [16] 曹梦娇,白石,唐攀攀,等. 基于无人机多光谱遥感的水稻二化螟冬前虫量测算[J]. 江苏农业学报,2025,41(2):305-312.
- [17] 洪国军,张灵,徐恒,等. 多高度无人机多光谱成像在枣树不同生育期 LAI 监测中的应用[J]. 江苏农业学报,2024,40(11):2093-2101.
- [18] 王德兴,何勇,袁红春. 基于 YOLO v8-BAN 模型的水下生物目标检测方法[J]. 江苏农业学报,2025,41(1):101-111.
- [19] 李鑫. 基于无人机遥感数据的蓝藻识别应用研究[D]. 郑州:解放军信息工程大学,2017.
- [20] 高敏,谢娅,李潇屹,等. 基于大面阵无人机多光谱遥感的水生植被精细分类研究[J]. 南京信息工程大学学报,2025,17(3):414-422.
- [21] 戴佩玉,张欣,毛星,等. 利用空间-光谱双分支特征和动态选择的高光谱影像农作物分类[J]. 农业工程学报,2023,39(16):160-170.
- [22] ZHONG Y, HU X, LUO C, et al. WHU-Hi: UAV-borne hyperspectral with high spatial resolution (H2) benchmark datasets and classifier for precise crop identification based on deep convolutional neural network with CRF[J]. Remote Sensing of Environment,2020,250:112012.
- [23] 朱庆,李俊生,张方方,等. 基于海岸带高光谱成像仪影像的太湖蓝藻水华和水草识别[J]. 遥感技术与应用,2016,31(5):879-885.
- [24] 丁铭,李旭文,姜晟,等. 基于无人机高光谱遥感的太湖蓝藻水华监测中的一次应用[J]. 环境监测管理和技术,2022,34(1):49-51,71.
- [25] 谢雨涵,史建康,孙晓慧,等. 基于大疆精灵 4 无人机多光谱影像的西沙植被监测[J]. 遥感技术与应用,2022,37(5):1170-1178.
- [26] BASTIDAS A A, TANG H L. Channel attention networks[C]// IEEE/CVF. 2019 IEEE/CVF conference on computer vision and pattern recognition workshops (CVPRW). Long Beach, CA, USA: IEEE,2019.

(责任编辑:黄克玲)