

doi:10.6041/j.issn.1000-1298.2023.12.023

基于改进 DeepLabv3+ 的水稻田间杂草识别方法

曹英丽^{1,2} 赵雨薇¹ 杨璐璐¹ 李静¹ 秦列列¹

(1. 沈阳农业大学信息与电气工程学院, 沈阳 110866; 2. 辽宁省农业信息化工程技术中心, 沈阳 110866)

摘要: 针对实际稻田环境中水稻与杂草相互遮挡、难以准确区分的问题, 提出一种基于改进 DeepLabv3+ 的水稻杂草识别方法。以无人机航拍的复杂背景下稻田杂草图像为研究对象, 在 DeepLabv3+ 模型的基础上, 选择轻量级网络 MobileNetv2 作为主干特征提取网络, 以减少模型参数量和降低计算复杂度; 融合通道和空间双域注意力机制模块, 加强模型对重要特征的关注; 提出一种基于密集采样的多分支感受野级联融合结构对空洞空间金字塔池化模块 (ASPP) 进行改进, 扩大对全局和局部元素特征的采样范围; 对模型解码器部分进行改进。设置消融试验验证改进方法的有效性, 并与改进前 DeepLabv3+、UNet、PSPNet、HrNet 模型进行对比试验。试验结果表明, 改进后模型对水稻田间杂草的识别效果最佳, 其平均交并比 (MIoU)、平均像素准确率 (mPA)、F1 值分别为 90.72%、95.67%、94.29%, 较改进前模型分别提高 3.22%、1.25%、2.65 个百分点; 改进后模型内存占用量为 11.15 MB, 约为原模型的 1/19, 网络推算速度为 103.91 f/s。结果表明改进后模型能够实现复杂背景下水稻与杂草分割, 研究结果可为无人机精准施药提供技术支撑。

关键词: 杂草识别; 水稻田间; 无人机遥感; 深度学习; DeepLabv3+

中图分类号: S126; TP751 文献标识码: A 文章编号: 1000-1298(2023)12-0242-11 OSID: 

Weed Identification Method in Rice Field Based on Improved DeepLabv3 +

CAO Yingli^{1,2} ZHAO Yuwei¹ YANG Lulu¹ LI Jing¹ QIN Lielie¹

(1. College of Information and Electrical Engineering, Shenyang Agricultural University, Shenyang 110866, China

2. Liaoning Engineering Research Center for Information Technology in Agriculture, Shenyang 110866, China)

Abstract: To address the challenges of mutual occlusion and accurate differentiation between rice and weeds in real-world environments, an improved method for rice-weed recognition was proposed based on DeepLabv3+. The research focused on images of rice field weeds captured by UAV in complex backgrounds, the MobileNetv2 was used as the backbone feature extraction network to reduce the number of parameters and computational complexity of the model; channel and spatial dual-domain attention modules were integrated to strengthen the model's attention to important features. A multi-branch receptive field cascade fusion structure was proposed based on dense sampling to improve the ASPP module to expand the sampling range. In addition, improvements to the decoder were made. Experimental results demonstrated that the improved model achieved the best performance in rice-weed recognition, with a mean intersection over union (MIoU) of 90.72%, mean pixel accuracy (mPA) of 95.67%, and F1_score of 94.29%, which were 3.22, 1.25, and 2.65 percentage points higher than that of the basic model. The improved model had a size of 11.15 MB, which was 1/19 of the original model's size, and achieved an average network inference speed of 103.91 frames per second per image. The results demonstrated that the improved model can accurately segment rice and weeds in complex backgrounds, supporting precise pesticide application using UAV.

Key words: weed recognition; rice field; UAV remote sensing; deep learning; DeepLabv3 +

收稿日期: 2023-06-11 修回日期: 2023-10-09

基金项目: 国家重点研发计划项目(2017YFD0300700)和辽宁省教育厅重点攻关项目(JYFZD2023123)

作者简介: 曹英丽(1977—), 女, 教授, 主要从事农业信息化研究, E-mail: caoyingli@163.com

0 引言

水稻作为中国最主要的粮食作物之一,其高质量和高产量对于保障我国粮食安全具有重要意义^[1-2]。尽管种植过程中会对稻田进行封闭处理^[3],但在水稻分蘖期仍然存在难以防治的恶性杂草,与水稻叶片深入交叠,影响作物生长。目前我国大多数农户采用无差别喷洒除草剂的方式进行田间杂草管理,这种方式成本高,农药利用率低,大量农药沉积会对土壤和水体造成污染^[4]。利用植保无人机变量施药可在不影响杂草防控效果的前提下,节约农药用量,符合绿色农业的发展趋势^[5-6],其中杂草精准识别是实现变量施药的重要环节。因此,为实现农田大面积喷药向植保无人机精准喷药的转变,准确快速地检测农田中杂草的分布情况,对于制定无人机的施药方案和田间精细化管理具有重要指导意义。

近年来,在基于无人机低空遥感的杂草识别研究中,根据机载传感器特性及数据处理方式,可分为基于多光谱成像和 RGB 数码影像的杂草识别方法^[7]。光谱成像结合光谱和图像技术,获取光谱特征信息,并将其映射到空间位置的像素点上^[8]。SU 等^[9]提取 5 个原始光谱特征及 18 个光谱指数作为潜在特征,贝叶斯优化的随机森林分类器的麦田黑草识别准确率为 93%。YU 等^[10]提出 WDVI 植被指数对稻田杂草识别准确率为 93.47%。XIA 等^[11]提出 WSRI 指数构建 DCNN 评价模型,对稻田稗草、绒叶识别准确率为 81.1%、92.4%。但多光谱传感器成本高、特征提取复杂,对于背景杂乱植物的数据处理复杂,缺乏应用可行性^[12]。

无人机获取的 RGB 图像有较高的空间分辨率^[13],可通过基于传统机器视觉的检测方法和基于深度卷积神经网络的识别方法实现对杂草目标的精确识别^[14]。黄华盛^[15]提取稻田杂草的颜色、纹理特征,采用 BP 分类器尺度参数为 100 时的结果最优,其平均交并比、准确率分别为 68.7%、83.6%。朱圣等^[16]对 100 像素×100 像素的水稻杂草图像,采用 Ada Boost 的综合识别精度为 90.25%。但以上算法识别精度不高,需人工多次试验进行特征选取,分类结果依赖于特征表现效果^[17]。深度学习模型可从原始数据中自动学习特征,在杂草识别领域得到广泛应用。GENZE 等^[18]使用 ResNet-34 作为特征提取器的 UNet 对高粱田运动模糊的杂草图像识别准确率为 93.01%。CAI 等^[19]基于 PSPNet 将 ECA 模块插入网络的 SPP 层进行改进,网络对菠萝田中杂草的识别准确率为 86.18%。亢洁等^[20]提出

基于多尺度融合模块和特征增强的杂草检测模型,对甜菜与杂草图像的平均检测精度为 88.84%。

以上研究均对杂草识别达到较高的精度,但未对模型复杂度以及模型部署和应用的速度展开研究。鉴于此,部分学者对模型的轻量化深入研究。其中,RAZFAR 等^[21]使用 SLIC 超像素算法将无人机航拍图像裁剪后的图像进一步分割成单杂草片段,设计了 5 层 CNN 架构对其进行训练,模型准确率为 95.12%,单幅杂草片段延迟速度为 9.853 ms。孟庆宽等^[22]对 SSD 轻量化改进,在 480 像素×720 像素的玉米杂草数据集上的平均精度为 88.27%、检测速度为 32.26 f/s。上述学者通过改进模型结构来平衡模型的识别精度和速度,在一定程度上提高了模型实时性。但对于杂草目标的研究均为背景干扰小的单株杂草的识别。而在实际农田环境中,同一类别的杂草受生长环境的影响也会呈复杂的细节变化,同时,杂草通常和作物相互遮挡,呈不规则密集分布,导致对复杂背景下杂草识别准确率低^[23]。

本文以自然环境下复杂背景的水稻田间杂草图像为研究对象,提出一种基于改进 DeepLabv3+ 的水稻杂草识别模型。使用轻量化 MobileNetv2 作为主干网络,融合注意力模块提高模型关键特征的权重,提出一种多分支感受野级联融合结构来增加模型对杂草特征的共享,同时对解码器进行改进,以期提高模型的准确性和实时性,为精准施药提供技术支持。

1 数码影像采集与处理

1.1 试验设计与杂草数码影像获取

田间试验地点位于辽宁省开原市业民镇二寨子村的绿色优质高效水稻品种抗病性鉴定及绿色防控技术示范区,如图 1 所示。属温带大陆性季风气候,年无霜期 150~160 d,年平均降水量 678 mm,育有的水稻品种包括北梗 1705 和铁梗 11。该区域以野慈姑为优势杂草,其叶片宽大肥厚且为球型根茎,分布多而不均。

试验于 2022 年 7 月 8 日(水稻分蘖盛期)在该示范区进行。此时,野慈姑大多处于 2~3 叶期,为稻田二次封闭后防治杂草的主要喷药时期。采用大疆精灵 4RTK 型无人机搭载高分辨率数码相机作为遥感平台,无人机水平悬停精度为 ±0.3 m,垂直悬停精度为 ±0.5 m,最大可承受风速 10 m/s。搭载数码相机有效像素为 2×10^7 ,分辨率 5 472 像素×3 648 像素。图像采集时间为 10:00—14:00,试验期间天气晴朗,风力较弱或微风。拍摄获取试验区

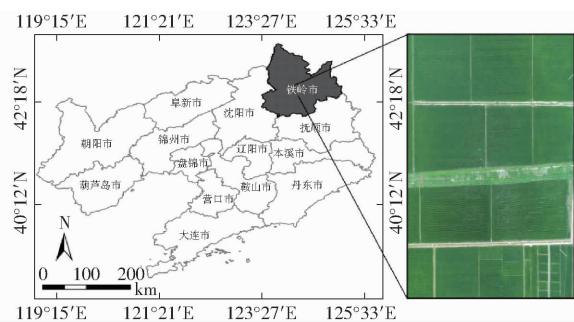


图 1 开原市水稻示范区

Fig. 1 Kaiyuan City rice demonstration area

域正射数码影像,得到复杂背景下航拍高度 1.6 m 图像 366 幅,航拍高度 2 m 图像 180 幅,航拍高度 3 m 图像 182 幅,共 728 幅。

1.2 数据标注与数据集构建

利用无人机获取的数码影像易受光照变化、无人机飞行姿态等因素影响导致图像质量不均,需对获取的 728 幅图像进行筛选,剔除模糊及不包含杂草目标的图像,筛选得到图像共 436 幅。为适应计算机运算性能,同时加快模型训练收敛速度,利用滑窗法得到 512 像素 \times 512 像素的图像 950 幅。将图像中包含的对象分为杂草和背景两类,将杂草以外的其他像素标注为背景类,使用图像标注工具 LabelMe 生成杂草的标注掩码,得到 json 文件并将其转换为 8 位灰度图作为标签,如图 2 所示,制作 VOC 格式数据集。为避免样本数量较少而导致的模型过拟合问题,增强模型泛化能力,对样本和标签同时进行随机平移旋转、翻转、高斯噪声、随机明亮度等数据增强操作,扩充数据集规模至原来的 3 倍,共得到 2850 幅图像和对应的标签图像。按照比例 8:2 划分训练集和验证集对模型进行训练和测试,其中训练集 2280 幅,验证集 570 幅。为验证模型在极端复杂环境下对杂草的分割效果,在不同航拍高度、不同光照强度,以及杂草被水稻不同程度遮挡的情况下,对模型泛化性做进一步测试。此外,随机选取 30 幅全尺度无人机图像对杂草进行精确认识和定位。

2 水稻田间杂草图像分割模型设计

田间环境下野慈姑与水稻相互遮挡且获得的图像背景复杂,本文结合杂草数据集的特征,以 DeepLabv3+ 模型为基础,通过大量试验对模型进行优化,来提高模型的准确性和实时性。

2.1 DeepLabv3+基础网络模型搭建

DeepLabv3+ 为典型的逐像素语义分割模型,能够为输入图像中的每个像素分配相应的类别标签。DeepLabv3+ 模型通过编码-解码结构实现对输入图像的逐像素分割,其网络结构如图 3 所示。首先,在编码器中以 Xception 作为主干特征提取网络,提取图像浅层特征并传入解码器。在空洞空间金字塔池化模块 (Atrous spatial pyramid pooling, ASPP) 中通过 1×1 卷积,膨胀率 (Rate) 分别为 6、12、18 的多尺度空洞卷积以及池化 (Image pooling),将 ASPP 的多个输出结果拼接融合 (Concat) 得到深层特征图。其次,在解码器中,对获取到的深层特征进行 4 倍上采样 (Upsample),并与浅层特征融合后再经过 4 倍双线性插值 (Bilinear interpolation) 上采样恢复到原尺寸,输出最终的预测结果。

2.2 改进的水稻田间杂草图像分割模型设计

采用 DeepLabv3+ 基础模型在田间杂草数据集上进行了预试验,识别结果如图 4 所示。从图 4 可得,在杂草与水稻存在交叠情况下,该模型未能准确地识别出边缘等细节特征。此外,由于模型本身网络结构层数多^[24],需要大量的计算资源和时间,从而限制了其在无人机设备上的应用。本文对其改进如下:①使用 MobileNetv2 作为主干特征提取网络,减少模型参数量,提高模型效率,更好地适应边缘设

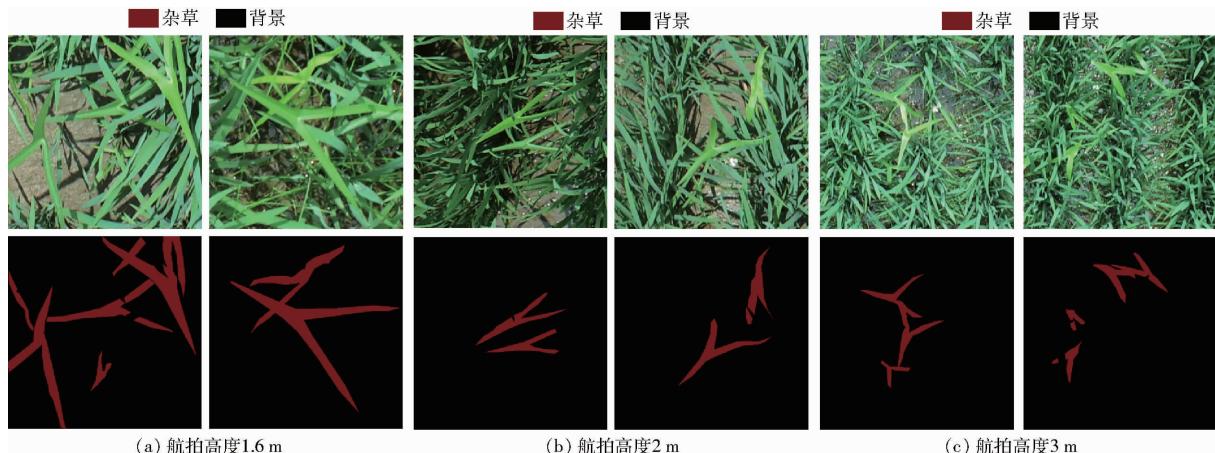


图 2 水稻及杂草分割掩码图

Fig. 2 Segmentation mask of rice and weeds

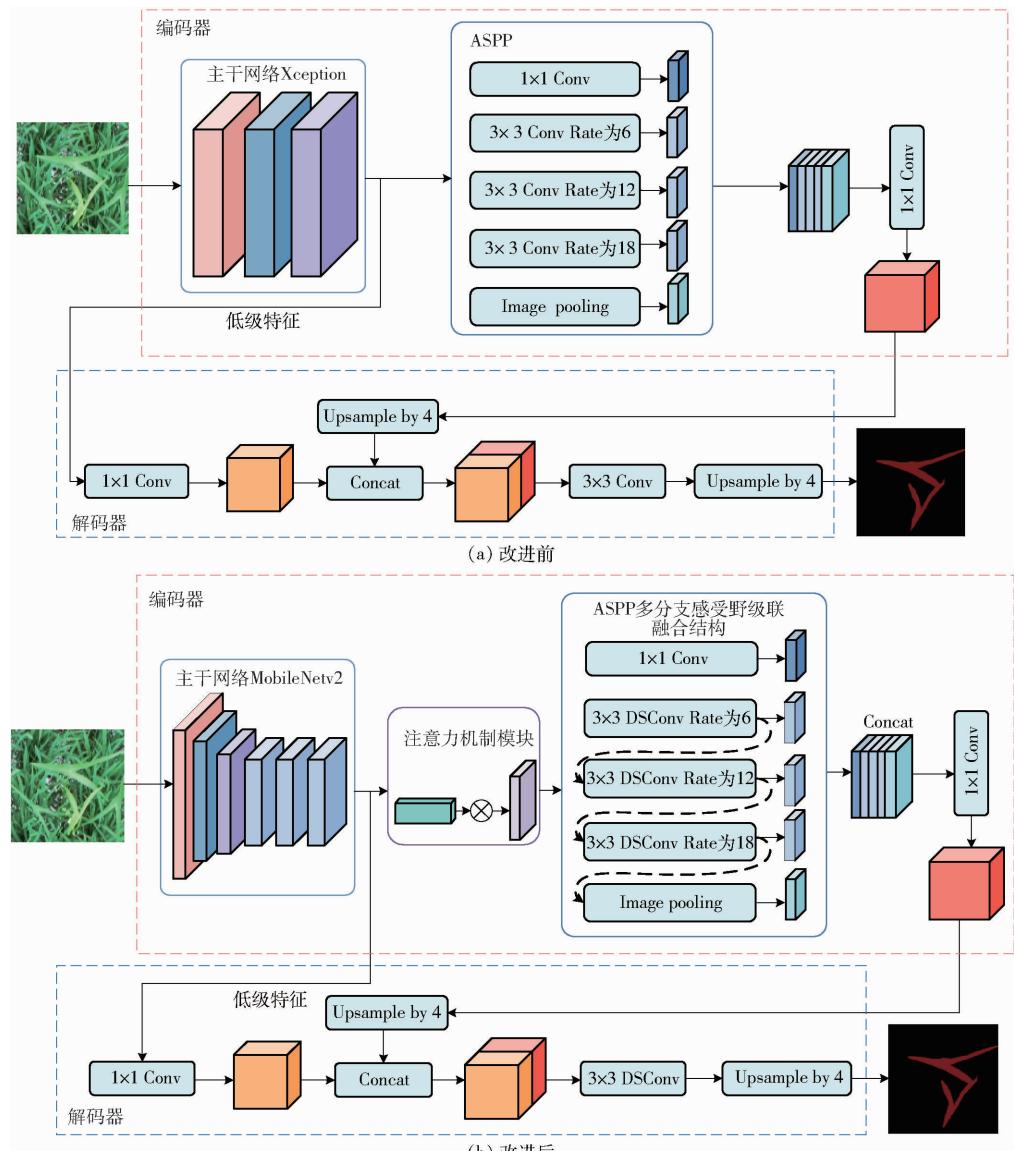


图 3 改进前后的 DeepLabv3+ 模型网络结构对比

Fig. 3 Network structure of DeepLabv3 +



图 4 DeepLabv3+ 对水稻杂草识别结果

Fig. 4 DeepLabv3+ recognition results for weeds

备。②融合通道空间注意力机制模块增加对杂草关键特征的权重,并减少对无效特征的关注,进一步提升模型分割精度。③针对原模型对边缘等细节特征识别不充分的问题,提出一种对 ASPP 模块改进的多分支感受野级联融合结构,加强 ASPP 各分支间杂草特征的共享,增加模型对杂草细节特征的解释能力。④在解码器部分,引入深度可分离卷积,替换解码器中的普通卷积操作,进一步提升模型的实时

性。改进后模型的网络结构如图 3b 所示。图中 DSConv 代表深度可分离卷积操作。

2.2.1 主干特征提取网络

DeepLabv3+ 原模型以 Xception 作为主干网络,其结构如图 5 所示,由 Entry flow、Middle flow、Exit flow 3 部分构成,共包含 14 个模块。Xception 的网络层次深,参数量达 2.27×10^7 (表 1),在训练和应用中的计算量庞大。在实际应用于无人机等资源受限的平台时,较大的参数量可能导致推理时间增加,从而影响设备的响应速度。为提高计算效率,采用 MobileNetv2 作为主干特征提取网络,其模型结构如图 6 所示。MobileNetv2 采用倒残差结构 (Inverted residual block),使得网络在保持较小参数量和计算复杂度的同时,仍具有相对较好的特征提取能力。首先进行 1×1 卷积进行升维 (Expansion layer),得到更多的特征,然后进行 3×3 深度可分离卷积操

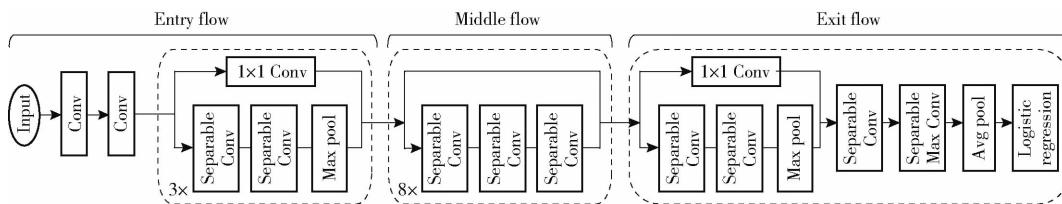


图 5 Xception 网络结构
Fig. 5 Xception network structure

表 1 模型参数量和计算量对比

Tab. 1 Parameter count and FLOPs comparision

模型	参数量	计算量
Xception	2.27×10^7	1.674×10^{10}
MobileNetv2	3.44×10^6	6.0×10^8

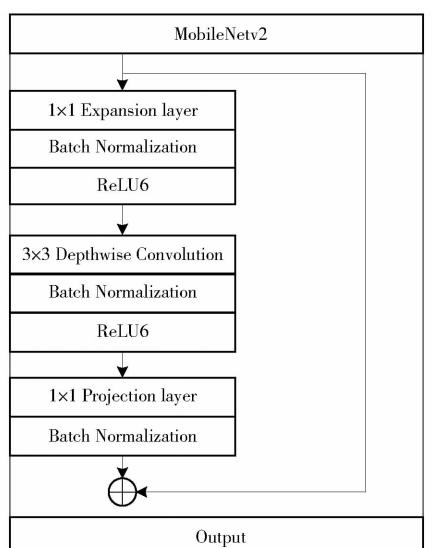


图 6 MobileNetv2 网络结构
Fig. 6 MobileNetv2 network structure

作,最后再用 1×1 卷积降维(Projection layer),使用 shortcut(快捷连接)将两者相加输出。其参数量和计算复杂度如表 1 所示。

由表 1 可知,MobileNetv2 相较于 Xception 模型,拥有更少的参数量和更低的计算复杂度,能够更好地适应无人机等移动设备的特殊环境。因此,采用 MobileNetv2 作为主干特征提取网络,使模型具有更好的实时性能,能够更快速地响应任务需求。

2.2.2 融合注意力机制模块

在水稻和杂草的精细分割任务中,由于环境的复杂性,杂草和水稻在一定程度上具有相似性。因此,本文在编码部分引入通道空间注意力模块(图 7),抑制网络对非重要特征的关注,同时弥补网络轻量化带来的精度损失。通道空间注意力模块在两个维度上对杂草关键特征进行加权。在通道维度上,假设输入特征图的大小为 $H \times W \times C$,通过全局平均池化(Global average pooling)和全局最大池化(Maximum pooling)操作,得到 2 个特征图 F_{Avg} 和

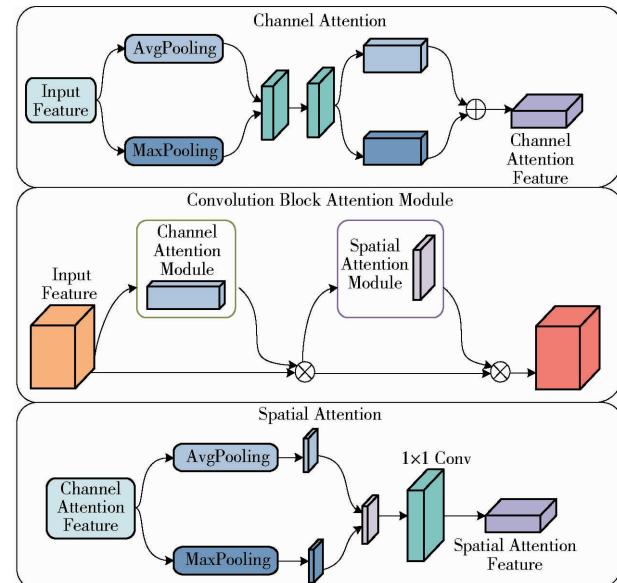


图 7 注意力机制模块结构图

Fig. 7 Attention mechanism module

$F_{\text{Max}} (F_{\text{Avg}} \in R^{1 \times C}, F_{\text{Max}} \in R^{1 \times C}, C \text{ 为特征图通道数})$ 。利用两层 1×1 卷积对通道进行加权并把其输出结果相加,通过 Sigmoid 函数,得到通道权重系数,将权重系数与原始特征图相乘,得到加权通道特征图 F_c ,即

$$F_c = \sigma_c(F) \otimes F \quad (1)$$

式中 F ——原始特征图

σ_c ——Sigmoid 激活函数

在空间维度上给定 $H \times W \times C$ 的特征图,采取相同的处理方式,得到两个特征图 F_{Avg} 和 F_{Max} ($F_{\text{Avg}} \in R^{K \times 1}, F_{\text{Max}} \in R^{K \times 1}, K \text{ 为图像维度}$),将其按照通道拼接在一起。其次,通过一个 7×7 的卷积,并使用 Sigmoid 激活函数,得到权重系数,最后,将权重系数与加权的通道特征图相乘,得到最终特征图 F_s ,即

$$F_s = \sigma_{HW}(F_c) \otimes F_c \quad (2)$$

式中 σ_{HW} ——Sigmoid 激活函数

2.2.3 多分支感受野级联融合结构设计

在 ASPP 模块中,通过不同采样率的空洞卷积和金字塔池化等操作,可以在不同尺度上提取图像的语义信息。然而,ASPP 模块中并行的各分支缺少对提取到的杂草特征信息的共享,无法充分利用数据的空间特征。为克服 ASPP 模块的局限性,本文提出特征组多分支感受野级联融合结构,如图 8 所

示。多分支感受野采用多个不同膨胀率的空洞卷积来扩大不同尺度的感受野, 并进行特征层级联融合。

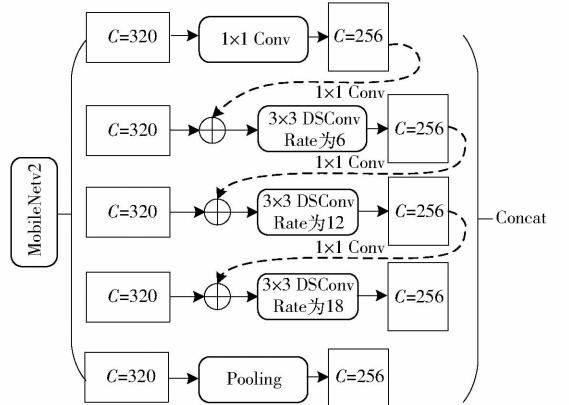


图 8 多分支感受野级联融合

Fig. 8 Receptive field cascade fusion

通过 1×1 卷积进行降维, 调整通道数为 256, 通过控制 stride、padding 和 dialate rate 参数获得不同尺度感受野, 构建空洞卷积金字塔, 利用多尺度空洞卷积层扩大感受野的范围, 感受野计算公式为

$$R_F = (D_r - 1)(s - 1) + s \quad (3)$$

式中 R_F —感受野 D_r —膨胀率

s —卷积核尺寸

采用多分支空洞卷积层设计级联融合结构来减少语义信息丢失率。将每个分支的输出通过 1×1 卷积调整通道数为 320, 作为下一分支的附加特征。通过主干特征提取网络, 每个分支获得了粗糙的特征表示。然后, 将这些粗糙特征与上一分支的附加特征进行融合学习, 解决 ASPP 模块中存在“空洞”问题, 以确保信息的完整传递、减少数据丢失。将特征层级联融合后各分支输出得到的 5 个特征层进行特征拼接, 即将 4 次卷积后的输出与池化层的输出进行特征堆叠, 从而充分利用不同尺度的特征层, 提取具有更丰富语义信息的高级语义特征信息。同时在 ASPP 中使用 3×3 深度可分离卷积块替换普通卷积操作, 即深度可分离空洞卷积, 使网络更加高效。

2.2.4 解码器改进

为进一步提高模型效率, 在解码器部分引入深度可分离卷积替换普通卷积。深度可分离卷积操作将传统的标准卷积拆分为深度卷积 (Depthwise convolution) 和逐点卷积 (Pointwise convolution) 两个步骤, 如图 9 所示。其中, 深度卷积对输入特征层的 N 个通道分别使用一个卷积核, 得到 N 个通道数为 1 的特征层, 将输出得到的 N 个特征层按顺序拼接即得 N 通道的特征层。点卷积卷积核尺寸为 $1 \times 1 \times N$, 利用卷积核个数调整输出通道数。在网络的

参数量和计算量上明显低于普通卷积。利用深度可分离卷积来拆分普通卷积, 减少模型冗余参数, 加快模型训练的收敛速度和推演运算速度。同时模型复杂度的降低减少了其过拟合的风险, 更能满足实时杂草识别的需求。

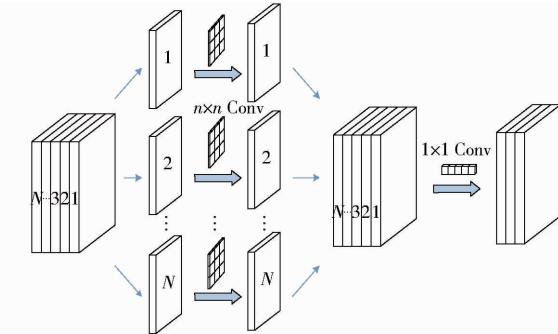


图 9 深度可分离卷积块

Fig. 9 Depthwise separable convolution block

3 试验结果与分析

3.1 试验环境配置及参数设置

本试验处理平台为 Intel(R) Xeon(R) Silver 4116 CPU, 主频 2.10 GHz, 128 GB 内存, GPU 型号为 NVIDIA Corporation GV100GL [Tesla V100 PCIe 32 GB] 服务器, 软件环境由 Cuda 10.0 + conda 4.10.1 + Python 3.7.10 搭建, 操作系统为 Linux 64 位。在模型训练时采用迁移学习策略, 使用预训练 CIFAR10 数据集权重参数, 设置初始学习率为 0.007, 批处理大小 (Batch size) 设为 8。使用随机梯度下降法 SGD 优化器更新权重参数, 学习率衰减值设为 0.0001, 采用交叉熵和 Dice Loss 作为损失函数, 训练每迭代 10 次衰减一次, 迭代次数设为 120 次, 保证充分拟合。

3.2 评价指标

为客观评价网络模型在水稻田间杂草图像上的分割效果, 选用平均交并比 (Mean intersection over union, MIoU)、平均像素准确率 (Mean pixel accuracy, mPA) 和 F1 值作为不同算法性能的评价指标。通过运算速度和模型内存占用量来对模型在实际应用中的可行性进行评估验证。

3.3 模型分割结果

3.3.1 不同模型分割性能对比

改进后的 DeepLabv3+ 模型分别与 DeepLabv3+、UNet、PSPNet、HrNet 几种主流语义分割模型在同样的训练参数和验证集下进行训练, 改进后模型训练过程中损失函数变化曲线如图 10 所示, 损失值均随着迭代次数的增加而逐渐减小, 并趋于稳定。分别对比不同模型的 MIoU、mPA、F1 值、运算速度、参数量以及模型内存占用量, 如表 2 所示。

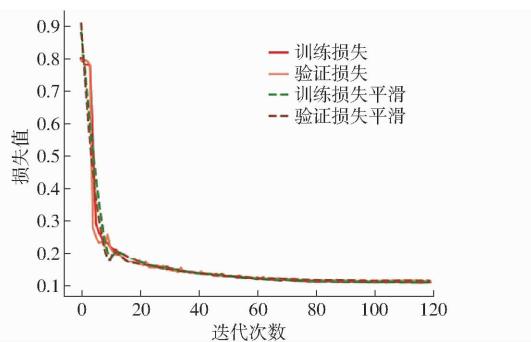


图 10 改进后模型训练过程损失函数曲线

Fig. 10 Model training process loss function

表 2 不同检测模型性能对比

Tab. 2 Performance comparison of different detection models

模型	MIoU/%	mPA/%	F1 值/%	运算速度/(f·s ⁻¹)	参数量	内存占用量/MB
	%	%	%	(f·s ⁻¹)		
DeepLabv3 +	87.50	94.42	91.64	24.2	5.47×10^7	208.70
UNet	89.39	95.54	93.82	18.89	4.39×10^7	167.59
PSPNet	87.08	92.49	93.03	44.4	4.67×10^7	178.17
HrNet	88.61	93.68	93.73	11.7	9.40×10^6	35.84
本文模型	90.72	95.67	94.29	103.91	2.90×10^6	11.15

由表 2 可知, 本文模型实时性和准确性更好, 在 5 个模型中的平均交并比、平均像素准确率和 F1 值

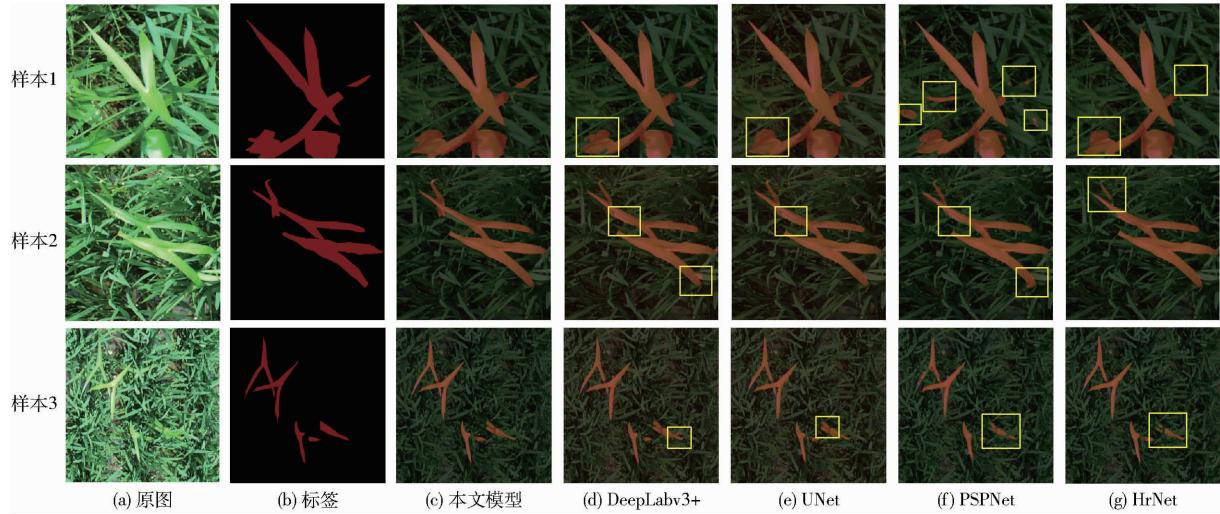


图 11 不同模型分割结果比较

Fig. 11 Comparison of segmentation results of different models

3.3.2 消融试验结果

设计与 DeepLabv3 + 原模型的对比消融试验来验证改进的有效性, 对改进前基础模型记为 A, 对模型的不同修改方法如表 3 所示。

模型训练和测试均使用同一数据集和验证集。为确保试验的可靠性, 分别对每个网络进行 2 次训练, 取其结果的平均值进行比较。试验结果如表 4 所示。

由表 4 可得, 改进后的 DeepLabv3 + 在性能方

面有了较大提升, 提出的各模块不仅提升了模型推

5 种模型在验证集上的实际预测结果如图 11 所示, 其中, 黄色框标记的区域表示存在误识、漏识现象, 即被错误表示为杂草或背景的区域。由图 11 可知, 相比改进后模型而言, DeepLabv3 + 原模型的分割结果存在漏识、误识的情况, 对细节的处理不够好; UNet 可以实现对细小特征的提取, 但分割边缘不准确; PSPNet 存在分割结果不连续、误识的问题; HrNet 对于边缘细节特征的处理不足, 同时存在误识、漏识现象。改进后模型在整体和局部分割精度均优于其他模型, 误识率低, 能够实现对杂草边缘细小特征的提取, 同时分割边缘光滑、清晰。

表 3 不同改进方法

Tab. 3 Different improving methods

处理方法	模型				
	A	B	C	D	本文模型
使用 MobileNetv2 主干网络	✓	✓	✓	✓	✓
通道空间注意力模块		✓	✓	✓	✓
ASPP 多分支感受野级联融合			✓	✓	
解码器部分改进					✓

面有了较大提升, 提出的各模块不仅提升了模型推

表 4 不同方法对模型的影响

Tab. 4 Effects of different methods on model

模型	MIoU/ %	mPA/ %	运算速度/ (f·s ⁻¹)	模型内存占 用量/MB
A	87.50	94.42	24.20	208.7
B	88.36	94.54	75.85	22.18
C	89.24	94.83	73.46	22.64
D	90.42	95.63	89.45	16.86
本文模型	90.72	95.67	103.91	11.15

理速度,而且有效改善了分割精度。使用轻量化 MobileNetv2 作为主干网络后,由于缩减了模型深度,保留了更多的低级特征,使模型在提升分割精度的同时,模型内存占用量缩小为原来的 1/9 左右;在模型中加入通道空间注意力机制后,提升了模型的关注能力,模型精度有所提升,但注意力机制的引入增加了模型复杂度,影响处理速度;增加 ASPP 模块多分支感受野级联融合后,由于融合了多层次的感受野,MIoU 和 mPA 分别提升 1.18、0.80 个百分点,运算速度上升 15.99 f/s;使用深度可分离卷积替换解码器的卷积层后,优化了解码器结构,模型的整体性能得到有效提升,MIoU 和 mPA 分别提升 0.30、0.04 个百分点,同时随着模型内存占用量的降低,大幅提升了模型处理速度。改进后的模型对水稻杂草有效特征提取能力更强,同时在实时性上表现效果更好,能更好地完成水稻田间杂草检测任务。

3.3.3 不同航拍高度对杂草识别模型性能的影响

植保无人机喷药作业中,通常与农田作物保持固定高度 1~3 m。为保证不同高度作业时的识别准确率,从验证集中选取 30 幅不同航拍高度的图像进行测试,测试结果如表 5 所示。

表 5 不同航拍高度下模型性能

Tab. 5 Model performance at different aerial heights

航拍高度/m	MIoU	mPA	F1 值	%
1.6	91.25	95.83	94.49	
2.0	90.37	94.62	93.98	
3.0	89.94	93.79	92.56	

3 个航拍高度下杂草识别平均像素准确率分别为 95.83%、94.62%、93.79%,模型对不同高度样本的实际预测结果如图 12 所示。以上试验均证明改进后的模型能够满足不同航拍高度的作业。

3.3.4 不同光照强度对杂草识别模型性能的影响

无人机航拍图像易受光照影响,可能导致对水稻的误识或对杂草的漏识。为验证模型在不同光照条件下的性能,选取测试集中强光、弱光下的不同样

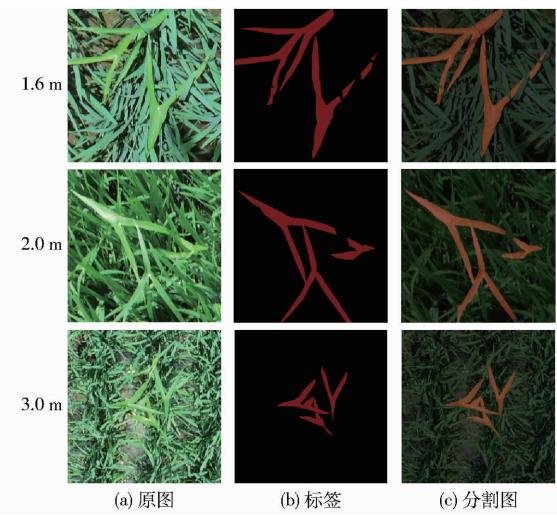


图 12 不同航拍高度下识别结果

Fig. 12 Recognition results at different aerial heights

本进行进一步测试,试验结果如图 13 所示。改进后的模型能够实现对不同光照强度下杂草的识别。

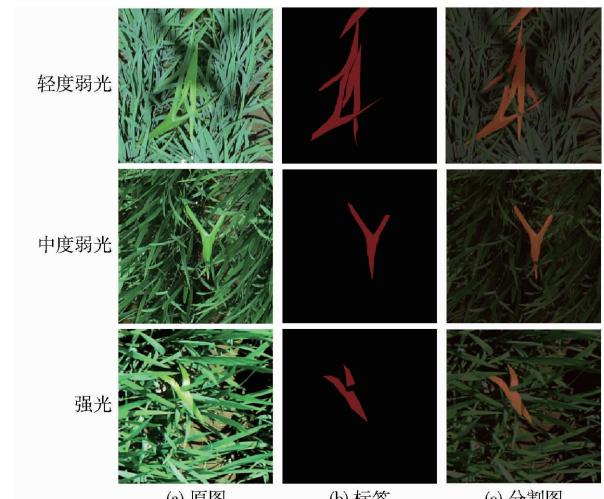


图 13 不同光照强度下识别结果

Fig. 13 Recognition results under different light intensities

3.3.5 不同遮挡情况对杂草识别模型性能的影响

在实际农田环境中,杂草通常分布密集,且与水稻叶片深度交叠。为验证本文模型在田间复杂环境的识别效果,选取不同遮挡情况下图像样本进行测试,结果如表 6 所示,由表 6 可知,改进后的模型对复杂背景下的稻田杂草图像也具有较强的识别能力。模型实际预测结果如图 14 所示,由图 14 中严重遮挡识别结果可知,本文模型能够成功识别杂草接近于被水稻叶片完全遮挡时的情况,进一步验证了其在复杂田间环境下也具有较好的泛化性。但在杂草被水稻严重遮挡、背景包含较多干扰因素时,识别精度略有下降,其原因可能是杂草的有效识别面积减小,关键语义特征缺失,同时图像中正负样本分布不均匀,从而导致识别准确率在一定程度上降低。在后续的试验中通过增加占比较少类别的样本或使

用类别平衡的损失函数来平衡各类样本的分布,从而进一步提高模型的泛化性能。

表 6 不同遮挡情况下模型性能

Tab. 6 Model performance under occlusions %

样本	MIoU	mPA	F1 值
轻度遮挡	85.70	89.24	90.47
中度遮挡	88.74	92.73	93.52
严重遮挡	81.84	87.41	88.65

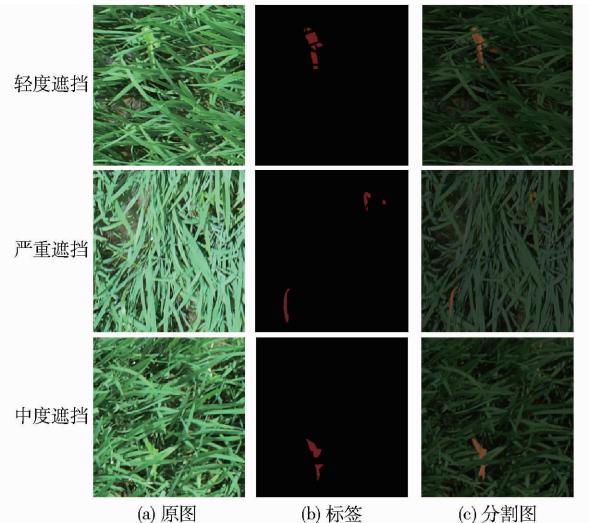


Fig. 14 Weed recognition results with different occlusions

3.4 全尺度图像杂草识别定位

由于设备性能限制,在对全尺度无人机图像进行测试时,首先将全尺度图像调整为 2 736 像素 \times 1 824 像素输入到网络模型中,通过滑窗法对图像逐块识别并进行拼接,从而更有效地捕捉到图像中的细节特征,取得更精确的识别效果。选取 30 幅全尺度图像进行测试,其平均交并比为 88.92%,平均处理速度为 4.94 f/s,预测结果如图 15 所示。结果表明,本文模型在全尺度图像上的速度和精度能满足精准作业的需求。

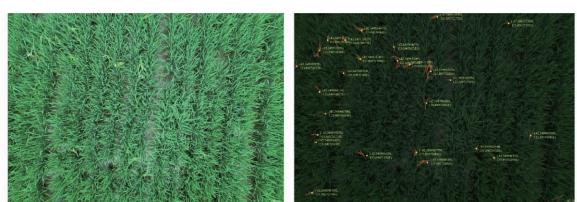


图 15 全尺度图像杂草识别结果

Fig. 15 Full-scale image weed recognition results

根据大疆无人机产品内置的卫星定位系统,获取无人机相机当前位置坐标。建立识别结果图中杂草像素点 $P(u_0, v_0)$ 与真实世界位置 $P'(X_w, Y_w, Z_w)$ 的映射模型,如图 16 所示。

(1) 像素坐标系转换到图像坐标系。像素坐标系 $O'uv$,坐标原点为左上角,单位为像素。图像坐

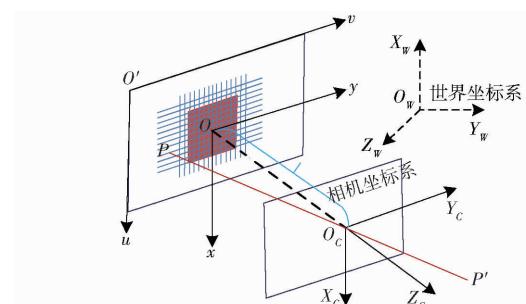


图 16 针孔模型原理图

Fig. 16 Pinhole model principle

标系 Oxy 描述相机焦距处成像的坐标,坐标原点为相机光轴与像平面的交点,即

$$\begin{bmatrix} x \\ y \\ 1 \end{bmatrix} = \begin{bmatrix} d_x & 0 & -u_0 d_x \\ 0 & d_y & -v_0 d_y \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} u \\ v \\ 1 \end{bmatrix} \quad (4)$$

式中 d_x, d_y —— 在 x 轴和 y 轴上宽度, mm

(2) 图像坐标系转换到相机坐标系。相机坐标系 $O_c X_c Y_c Z_c$, 坐标原点为镜头的中心。二者依据相似三角形原理进行转换,即

$$Z_c \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} = \begin{bmatrix} f & 0 & 0 & 0 \\ 0 & f & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} X_c \\ Y_c \\ Z_c \\ 1 \end{bmatrix} \quad (5)$$

式中 f —— 焦距, m

(3) 相机坐标系转换到世界坐标系。其属于刚体变化,即两者之间仅需平移和旋转操作即可实现相互转换,即

$$\begin{bmatrix} X_c \\ Y_c \\ Z_c \\ 1 \end{bmatrix} = \begin{bmatrix} \mathbf{R} & \mathbf{T} \\ 0 & 1 \end{bmatrix} \begin{bmatrix} X_w \\ Y_w \\ Z_w \\ 1 \end{bmatrix} \quad (6)$$

式中 \mathbf{R} —— 旋转矩阵 \mathbf{T} —— 偏移向量

根据上述模型,得到杂草像素点的世界坐标并标记在图 15 识别结果的相应位置,其中杂草真实位置与定位位置的平均误差约为 19.43 cm,误差在可接受范围内^[25],结果满足精细农业的需求。

4 结论

(1) 提出改进的 DeepLabv3+ 杂草识别模型,与改进前 DeepLabv3+、UNet、PSPNet、HrNet 模型对比测试,结果证明,在同一验证集上,本文模型对杂草的识别效果最好,平均交并比为 90.72%,平均像素准确率为 95.67%,F1 值为 94.29%。改进后模型的实时性最好,模型推理速度为 103.91 f/s。

(2) 使用 MobileNetv2 作为主干网络、融合注意

力模块、增加 ASPP 多分支感受野级联融合结构以及改进解码器后,在验证集上,模型表现最好,相比原模型 MIoU、mPA 分别提升 3.22、1.25 个百分点,模型推理速度提升 79.71 f/s,验证了改进的有效性。

(3) 在不同航拍高度、不同光照条件以及不同遮挡情况的数据集上对改进后的模型进行测试,结

果表明,在以上 3 种条件下,模型均能满足识别的需要,进一步证明模型具有泛化性。

(4) 在全尺度航拍图像中应用本文模型对稻田杂草识别定位,通过滑窗法逐块识别并拼接得到全尺度杂草识别图,并利用卫星定位系统获取杂草像素所在的位置,为精准施药提供支持。

参 考 文 献

- [1] 朱晶,臧星月,李天祥.新发展格局下中国粮食安全风险及其防范[J].中国农村经济,2021(9):2-21.
ZHU Jing, ZANG Xingyue, LI Tianxiang. China's food security risks and prevention strategy under the new development pattern [J]. Chinese Rural Economy, 2021(9):2-21. (in Chinese)
- [2] 袁洪波,赵努东,程曼.基于图像处理的田间杂草识别研究进展与展望[J].农业机械学报,2020,51(增刊2):323-334.
YUAN Hongbo, ZHAO Nudong, CHENG Man. Review of weeds recognition based on image processing [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(Supp. 2):323-334. (in Chinese)
- [3] 龙成,田家顺.5种除草剂对水稻移栽田杂草的封闭除草效果[J].湖南农业科学,2022(8):52-54.
LONG Cheng, TIAN Jiashun. Study on the blocking effect of five herbicides on weeds in the rice transplanting field [J]. Hunan Agricultural Sciences, 2022(8):52-54. (in Chinese)
- [4] 徐霞红,权浩然,何开雨,等.农田环境中农药残留比例型荧光传感系统研究[J].农业机械学报,2020,51(11):229-234.
XU Xiaohong, QUAN Haoran, HE Kaiyu, et al. Proportional fluorescence sensing analysis of pesticide residues in agricultural environment [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(11):229-234. (in Chinese)
- [5] 杨文超,何进,周靖凯,等.基于机器视觉和北斗定位的小麦变量喷雾系统研究[J].农业机械学报,2022,53(7):150-161.
YANG Wenchao, HE Jin, ZHOU Jingkai, et al. Design of wheat variable spray system based on machine vision and Beidou positioning [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(7):150-161. (in Chinese)
- [6] 杨光玉,孔辉,兰玉彬,等.精准变量施药关键技术及应用现状[J].农业技术与装备,2022(1):96-97.
YANG Guangyu, KONG Hui, LAN Yubin, et al. Key technologies and application status of precise variable application [J]. Agricultural Technology & Equipment, 2022(1):96-97. (in Chinese)
- [7] 兰玉彬,邓小玲,曾国亮.无人机农业遥感在农作物病虫草害诊断应用研究进展[J].智慧农业,2019,1(2):1-19.
LAN Yubin, DENG Xiaoling, ZENG Guoliang, et al. Advances in diagnosis of crop diseases, pests and weeds by UAV remote sensing [J]. Smart Agriculture, 2019, 1(2):1-19. (in Chinese)
- [8] 赵静,李志铭,鲁力群,等.基于无人机多光谱遥感图像的玉米田间杂草识别[J].中国农业科学,2020,53(8):1545-1555.
ZHAO Jing, LI Zhiming, LU Liqun, et al. Weed identification in maize field based on multi-spectral remote sensing of unmanned aerial vehicle [J]. Scientia Agricultura Sinica, 2020, 53(8):1545-1555. (in Chinese)
- [9] SU J Y, YI D, COOMBES M, et al. Spectral analysis and mapping of blackgrass weed by leveraging machine learning and UAV multispectral imagery [J]. Computers and Electronics in Agriculture, 2022, 192:106621.
- [10] YU F H, JIN Z Y, GUO S E, et al. Research on weed identification method in rice fields based on UAV remote sensing [J]. Frontiers in Plant Science, 2022, 13:1037760.
- [11] XIA F L, QUAN L Z, LOU Z X, et al. Identification and comprehensive evaluation of resistant weeds using unmanned aerial vehicle-based multispectral imagery [J]. Frontiers in Plant Science, 2022, 13:938604.
- [12] 陈学深,熊悦淞,王宣霖,等.基于触觉感知的稻田苗带区域杂草密度等级评估[J].农业工程学报,2023,39(2):116-125.
CHEN Xueshen, XIONG Yuesong, WANG Xuanlin, et al. Evaluation of weed density grade in paddy field seedling line zone based on tactile perception [J]. Transactions of the CSAE, 2023, 39(2):116-125. (in Chinese)
- [13] 王紫腾.基于深度迁移学习与多特征网络融合的高分辨率遥感图像分类[D].南京:南京邮电大学,2022.
WANG Ziteng. High-resolution remote sensing image classification based on deep transfer learning and multi-feature network fusion [D]. Nanjing: Nanjing University of Posts and Telecommunications, 2022. (in Chinese)
- [14] 张茹飞.基于低空遥感的杂草识别及定位方法研究[D].杨凌:西北农林科技大学,2020.
ZHANG Rufei. Weed identification and location based on low altitude remote sensing [D]. Yangling: Northwest A&F University, 2020. (in Chinese)
- [15] 黄华盛.基于无人机遥感图像的稻田杂草识别研究[D].广州:华南农业大学,2019.
HUANG Huasheng. The research on weed recognition in rice fields using UAV remote sensing imagery [D]. Guangzhou: South China Agricultural University, 2019. (in Chinese)
- [16] 朱圣,邓继忠,张亚莉,等.基于无人机低空遥感的水稻田间杂草分布图研究[J].华南农业大学学报,2020,41(6):67-74.
ZHU Sheng, DENG Jizhong, ZHANG Yali, et al. Study on distribution map of weeds in rice field based on UAV remote sensing [J]. Journal of South China Agricultural University, 2020, 41(6):67-74. (in Chinese)
- [17] 邓向武.基于深度学习的稻田杂草种类识别及其位置检测方法研究[D].广州:华南农业大学,2019.
DENG Xiangwu. The research of the categories identification and target detection with weeds based on deep learning in the

- paddy field[D]. Guangzhou: South China Agricultural University, 2019. (in Chinese)
- [18] GENZE N, AJEKWE R, GÜRELI Z, et al. Deep learning-based early weed segmentation using motion blurred UAV images of sorghum fields[J]. Computers and Electronics in Agriculture, 2022, 202: 107388.
- [19] CAI Y, ZENG F, XIAO J, et al. Attention-aided semantic segmentation network for weed identification in pineapple field[J]. Computers and Electronics in Agriculture, 2023, 210: 107881.
- [20] 玄洁, 刘港, 郭国法. 基于多尺度融合模块和特征增强的杂草检测方法[J]. 农业机械学报, 2022, 53(4): 254–260.
KANG Jie, LIU Gang, GUO Guofa. Weed detection based on multi-scale fusion module and feature enhancement [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(4): 254–260. (in Chinese)
- [21] RAZFAR N, TRUE J, BASSIOUNY R, et al. Weed detection in soybean crops using custom lightweight deep learning models [J]. Journal of Agriculture and Food Research, 2022, 8: 100308.
- [22] 孟庆宽, 张漫, 杨晓霞, 等. 基于轻量卷积结合特征信息融合的玉米幼苗与杂草识别[J]. 农业机械学报, 2020, 51(12): 238–245, 303.
MENG Qingkuan, ZHANG Man, YANG Xiaoxia, et al. Recognition of maize seedling and weed based on light weight convolution and feature fusion[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(12): 238–245, 303. (in Chinese)
- [23] 温德圣. 深度学习在复杂特征杂草识别中的研究与应用[D]. 乌鲁木齐: 新疆大学, 2021.
WEN Desheng. Research and application of deep learning in weed recognition of complex features [D]. Urumqi: Xinjiang University, 2021. (in Chinese)
- [24] 张社荣, 欧阳乐颖, 王超, 等. 基于 DeepLabV3+ 的骨料图像自动分割算法[J]. 水利水电科技进展, 2022, 42(6): 28–32, 97.
ZHANG Sherong, OUYANG Leying, WANG Chao, et al. Automatic segmentation algorithm of aggregate image based on DeepLabV3+ [J]. Advances in Science and Technology of Water Resources, 2022, 42(6): 28–32, 97. (in Chinese)
- [25] 刘子文, 刘青山. 通用处方农作嵌入式 GIS 信息处理系统的研制[J]. 农业装备技术, 2019, 45(1): 15–20.
LIU Ziwen, LIU Qingshan. On the development of embedded GIS information processing system for general prescription agriculture[J]. Agricultural Equipment & Technology, 2019, 45(1): 15–20. (in Chinese)

(上接第 233 页)

- [15] LI X B, CHEN Y H, YANG H, et al. Improvement, comparison, and application of field measurement methods for grassland vegetation fractional coverage[J]. Journal of Integrative Plant Biology, 2005, 47(9): 1074–1083.
- [16] MEYER G E, NETO J C. Verification of color vegetation indices for automated crop imaging applications[J]. Computers and Electronics in Agriculture, 2008, 63(2): 282–293.
- [17] GITELSON A A, VINA A, ARKEBAUER T J, et al. Remote estimation of leaf area index and green leaf biomass in maize canopies[J]. Geophysical Research Letters, 2003, 30(5): 1248.
- [18] HOLMAN F H, RICHE A B, MICHALSKI A, et al. Highthroughput field phenotyping of wheat plant height and growth rate in field plot trials using UAV based remote sensing[J]. Remote Sensing, 2016, 8(12): 1031.
- [19] LI W, NIU Z, CHEN H, et al. Remote estimation of canopy height and aboveground biomass of maize using high-resolution stereo images from a low-cost unmanned aerial vehicle system[J]. Ecological Indicators, 2016, 67: 637–648.
- [20] NIU Y, ZHANG L, ZHANG H, et al. Estimating above-ground biomass of maize using features derived from UAV-based RGB imagery[J]. Remote Sensing, 2019, 11(11): 1261.
- [21] LU J, LI W, YU M, et al. Estimation of rice plant potassium accumulation based on non-negative matrix factorization using hyperspectral reflectance[J]. Precision Agriculture, 2021, 22: 51–74.
- [22] BENDIG J, YU K, AASEN H, et al. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley[J]. International Journal of Applied Earth Observation and Geoinformation, 2015, 39: 79–87.
- [23] 马彦鹏, 边明博, 樊意广, 等. 基于无人机 RGB 影像的马铃薯植株钾含量估算[J]. 农业机械学报, 2023, 54(7): 196–203, 233.
MA Yanpeng, BIAN Mingbo, FAN Yiguang, et al. Estimation of potassium content of potato plants based on UAV RGB images [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(7): 196–203, 233. (in Chinese)
- [24] WAN L, CEN H, ZHU J, et al. Grain yield prediction of rice using multi-temporal UAV-based RGB and multispectral images and model transfer—a case study of small farmlands in the South of China[J]. Agricultural and Forest Meteorology, 2020, 291(1): 108096.
- [25] WANG W, YAO X, TIAN Y, et al. Estimating leaf nitrogen concentration with three-band vegetation indices in rice and wheat [J]. Field Crops Research, 2012, 129: 90–98.