doi:10.6041/j.issn.1000-1298.2026.07.030

基于改进 YOLO 11n 的轻量化大豆田间杂草识别研究

宁　姗[1]　赵伟龙[2]　乔金友[3]　陈海涛[3,4]　崔家健[2]

(1.黑龙江科技大学创新创业学院，哈尔滨 150022；2.黑龙江科技大学电子与信息工程学院，哈尔滨 150022；
3.东北农业大学工程学院，哈尔滨 150030；4.黑龙江东方学院机电工程学院，哈尔滨 150066)

摘要：针对大豆田间杂草识别中传统模型参数量大、实时性差及轻量化不足等问题，提出了一种改进 YOLO 11n 的轻量化杂草检测模型 YOLO 11n－ADS。该模型通过引入可切换空洞卷积(Switchable atrous convolution，SAConv)模块和自适应下采样(Adaptive downsampling，ADown)模块，增强多尺度特征提取能力和抗干扰能力，提升了复杂环境下杂草的检测精度。YOLO 11n－ADS 模型的检测精度、mAP_{50}、mAP_{50-95}及召回率分别为 90.6%、92.0%、86.0%、92.6%，较基准模型 YOLO 11n 分别提升了 1.1、2.6、5.0、3.6 个百分点，参数量由 2.6×10^6降至 2.2×10^6，浮点数运算量由 6.3×10^9降至 4.6×10^9。采用 TensorRT 框架将模型部署到 Jetson Nano 边缘平台，静态推理速度可达 35 f/s。田间验证试验结果为：端到端检测平均帧率为 28 f/s，检测精度、mAP_{50}、mAP_{50-95}及召回率分别为 89.5%、91.0%、84.0%、91.4%。与 YOLO 11n 相比，在光照不均、目标遮挡等复杂场景下展现出更强的鲁棒性和实时性。本研究为大豆田间的实时杂草检测提供了高效轻量化的解决方案，适用于边缘计算设备部署，助力精准农业智能化管理。

关键词：大豆田杂草检测；轻量化；YOLO 11n；多尺度特征融合；自适应下采样

中图分类号：TP391.41　　**文献标识码**：A　　**文章编号**：1000-1298(2026)07-0326-11　　**OSID**：

Lightweight Weed Detection Method in Soybean Field Based on Improved YOLO 11n

NING Shan[1]　ZHAO Weilong[2]　QIAO Jinyou[3]　CHEN Haitao[3,4]　CUI Jiajian[2]

(1. *Innovation and Entrepreneurship*, *Heilongjiang University of Science and Technology*, *Harbin* 150022, *China*
2. *School of Electronics and Information Engineering*, *Heilongjiang University of Science and Technology*, *Harbin* 150022, *China*
3. *College of Engineering*, *Northeast Agricultural University*, *Harbin* 150030, *China*
4. *College of Mechanical and Electrical Engineering*, *East University of Heilongjiang*, *Harbin* 150066, *China*)

Abstract: Aiming to address the issues of excessive parameters, poor real-time performance, and insufficient lightweight design in traditional models for soybean field weed recognition, an improved lightweight weed detection model named YOLO 11n－ADS was proposed based on YOLO 11n. By replacing the original C3K2 module with a switchable atrous convolution (SAConv) module and integrating a global context mechanism with multi-dilation-rate feature fusion, the enhanced model strengthened multi-scale feature extraction capability and improved weed detection accuracy in complex environments. Meanwhile, the backbone network was optimized by using the adaptive downsampling module (ADown), which fused the average pooling and maximum pooling strategies to reduce the feature loss caused by target occlusion and light interference. The YOLO 11n－ADS model achieved detection accuracy, mAP_{50}, mAP_{50-95}, and recall rates of 90.6%, 92.0%, 86.0%, and 92.6%, respectively, representing improvements of 1.1 percentage points, 2.6 percentage points, 5.0 percentage points, and 3.6 percentage points over the baseline YOLO 11n model. Additionally, the parameter count was reduced from 2.6×10^6 to 2.2×10^6, while the floating point operations (FLOPs) was decreased from 6.3×10^9 to 4.6×10^9. Deployed on the Jetson Nano edge computing platform by using the TensorRT framework, the optimized model achieved efficient real-time inference with minimal resource

收稿日期：2025－07－18　修回日期：2025－11－05

基金项目：国家重点研发计划项目(2021YFD2000401)

作者简介：宁姗(1978—)，女，副教授，博士，主要从事机器视觉及农业机械化研究，E-mail：4127756@qq.com

通信作者：陈海涛(1962—)，男，教授，博士生导师，主要从事农业机械化装备及生物质材料研究，E-mail：htchen@neau.edu.cn

consumption. The memory usage was only 1.6 GB, and the detection speed reached 35 f/s. In field dynamic validation tests, the end-to-end detection average frame rate reached 28 f/s, with detection accuracy, mAP_{50}, mAP_{50-95}, and recall rates of 89.5%, 91.0%, 84.0%, and 91.4%, respectively. Compared with YOLO 11n, the proposed model demonstrated stronger robustness and real-time performance under challenging scenarios such as uneven lighting and target occlusion. The research result can provide an efficient and lightweight solution for real-time weed detection in complex farmland environments, which was suitable for deployment on edge computing devices and contributed to the intelligent management of precision agriculture.

Key words: soybean field weed detection; lightweight; YOLO 11n; multi-scale feature fusion; adaptive downsampling

0　引言

大豆是全球重要的粮食与经济作物，对保障粮食安全、推动农业可持续发展意义重大[1]。田间杂草竞争性强，严重威胁大豆生长，影响大豆产量最高可达 80%[2-3]。而大面积喷洒农药会出现杂草抗药性增强、农药残留引发严重生态污染等问题[4]。因此，靶向精准除草成为推动农业实现绿色生产转型的关键，而高效精准的杂草识别则是靶向精准除草研究的重要突破口。

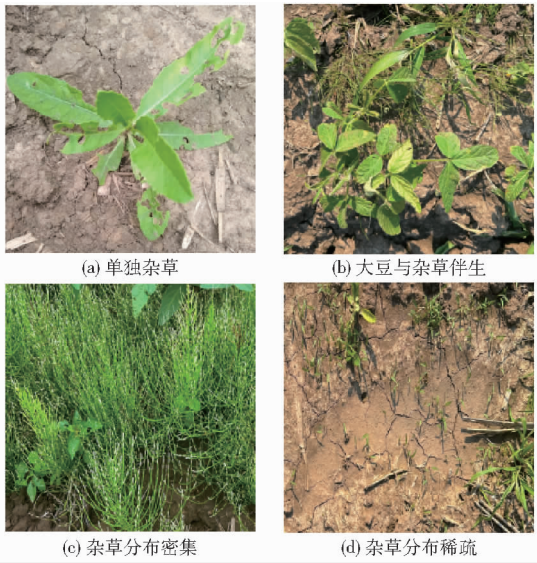
早期的杂草识别研究主要依赖于颜色、纹理和形状等特征，结合支持向量机、随机森林等传统机器学习算法[5-6]，但其特征表达能力有限，难以适应田间复杂多变的真实环境。相比传统机器学习，卷积神经网络具有更强的特征提取与实时反馈能力，Faster R-CNN、YOLO 等算法[7-11]成为研究热点，多个团队通过 U-Net[12]、MSFCA-Net[13]、DarkNet53[14]等网络在不同作物场景中验证了其识别潜力。然而，这些模型普遍存在参数量大、计算复杂度高的问题，在资源有限的边缘设备上难以高效部署。为解决资源受限等问题，模型轻量化已成为推动算法在终端落地的必然选择[15-16]。通过模型量化[17]、轻量模块设计[18]和动态剪枝[19]等策略，OLGUIN-ROJAS 等[20]构建了苹果检测轻量 YOLO v8s 模型，ZHOU 等[21]提出了快速连接件缺陷检测的 QCF-YOLO 轻量化模型。然而，现有轻量化模型并不适合大豆田间的杂草检测，这是由于大豆植株与杂草形态相似，加之环境光照条件复杂多变且存在相互遮挡的情况，模型难以兼顾检测精度与处理效率。与此同时，边缘设备部署面临计算资源限制与实时性要求的问题。

针对以上问题，本文以 YOLO 11n 为基础网络，引入感受野增强 SAConv 模块[22]与 ADown 自适应下采样[23]，构建轻量化 YOLO 11n-ADS 模型。SAConv 通过动态调整空洞率，有效捕捉多尺度杂草特征，其全局上下文模块整合宏观信息以消除局部歧义，结合权重共享机制在扩大感受野的同时控制运算量。通过 TensorRT 框架，将 YOLO 11n-ADS 部署到 Jetson Nano 上，实现端到端的实时检测，以验证改进模型的实际性能。

1　材料与方法

1.1　田间数据构建

图像数据分别于 2023、2024、2025 年的 5—7 月在东北农业大学向阳基地采集，数据采集时间选择为大豆幼苗期至分枝期，杂草种类有问荆草、刺儿菜、马唐草、铁苋菜等。采集图像如图 1 所示，其中杂草的生长状态包括：单独杂草、大豆与杂草伴生、杂草分布密集、杂草分布稀疏等多种情况。图像分辨率为 1 920 像素 × 1 080 像素，共采集有效图像 11 343 幅，各类数据分布数量如表 1 所示。采用 LabelImg 标注工具对采集图像中的大豆植株和不同种类的杂草进行手动标注，并将标注好的数据信息保存为 TXT 标签文件。



(a) 单独杂草　(b) 大豆与杂草伴生　(c) 杂草分布密集　(d) 杂草分布稀疏

图 1　田间杂草样本

Fig. 1　Field weed samples

为保证标注一致性，避免因主观臆断分割边界而引入的标注错误，遵循以下原则处理独立、重叠的

杂草。对于独立实例标注,尽可能为每个可分辨的独立植株绘出与其尺寸一致的边界框。对于重叠实例标注,当杂草密集到一定程度时,多个植株完全交织在一起,若为同类别杂草,则将整个重叠杂草作为一个单独的实例,绘出的边界框将其整体包围,并标记为对应的类别,若为不同类别杂草,则仅框出并标注未完全遮挡的部分。

表 1 大豆田间杂草数据集

Tab. 1 Composition of soybean field weed dataset

类别	名称	图像数量	标注数量
Soybean	大豆	7 150	9 850
Weeds	问荆草	5 080	6 820
Cier	刺儿菜	4 650	5 860
mang	马唐草	4 020	4 810
xian	铁苋菜	3 510	5 230
huang	黄花蒿	2 950	3 111
qing	苘麻	2 830	3 090
zihua	紫花地丁	2 540	2 760
ju	苣荬菜	2 210	2 430

为增加数据集样本的多样性和模型的鲁棒性,防止数据量不足而导致的模型过拟合,采用旋转、平移、镜像、水平翻转、改变亮度和添加高斯噪声对采集图像数据进行数据增强,保留有效样本,样本扩充至 67 810 幅,将扩充后的数据集按照比例 7∶2∶1 划分为训练集、验证集和测试集。

1.2 YOLO 11 模型

YOLO 系列算法是单阶段目标检测算法的代表,相比于 Faster R-CNN[24]、Mask R-CNN、SSD 等两阶段目标检测算法具有更快的推理速度和更多的版本选择。YOLO 11[25] 网络模型主要包括输入(Input)、主干网络(Backbone)、颈部网络(Neck)、头部网络(Head)。YOLO 11 在 YOLO v8 中的具体改进为使用可变卷积 C3K2 模块代替主干网络的 C2f 模块;通过在 C2 结构中嵌入金字塔空间注意力(PSA)形成新模块 C2PSA 模块;头部网络则是在原有的分类检测头中增加了 2 个深度卷积(DWConv),并删除了之前的 objectness 分支;回归损失函数在原来 CIoU 的基础上加入了分布焦点损失函数(Distribution focal loss)。

1.3 YOLO 11n-ADS 模型

为了实现大豆田间杂草的快速识别,精准获取杂草的位置和数量,有效解决堆叠、枝叶遮挡等问题,并满足轻量化部署需求,YOLO 11n-ADS 以 YOLO 11n 为基础模型进行优化改进,如图 2 所示。为减小模型和体积以及降低模型计算复杂度,保证较高的检测精度及速度:首先,引入 SAConv 感受野增强模块,替代 C3K2 模块,通过扩大感受野增强多尺度特征提取能力,提升不同尺度杂草的检测能力;其次,采用 ADown 自适应下采样模块,融合平均池化与最大池化[26],保留关键特征信息,改善光照不均和目标遮挡情况下的检测稳定性,平衡检测精度与速度。

1.3.1 SAConv 感受野增强模块

在网络的中间层最影响模型性能的部分是

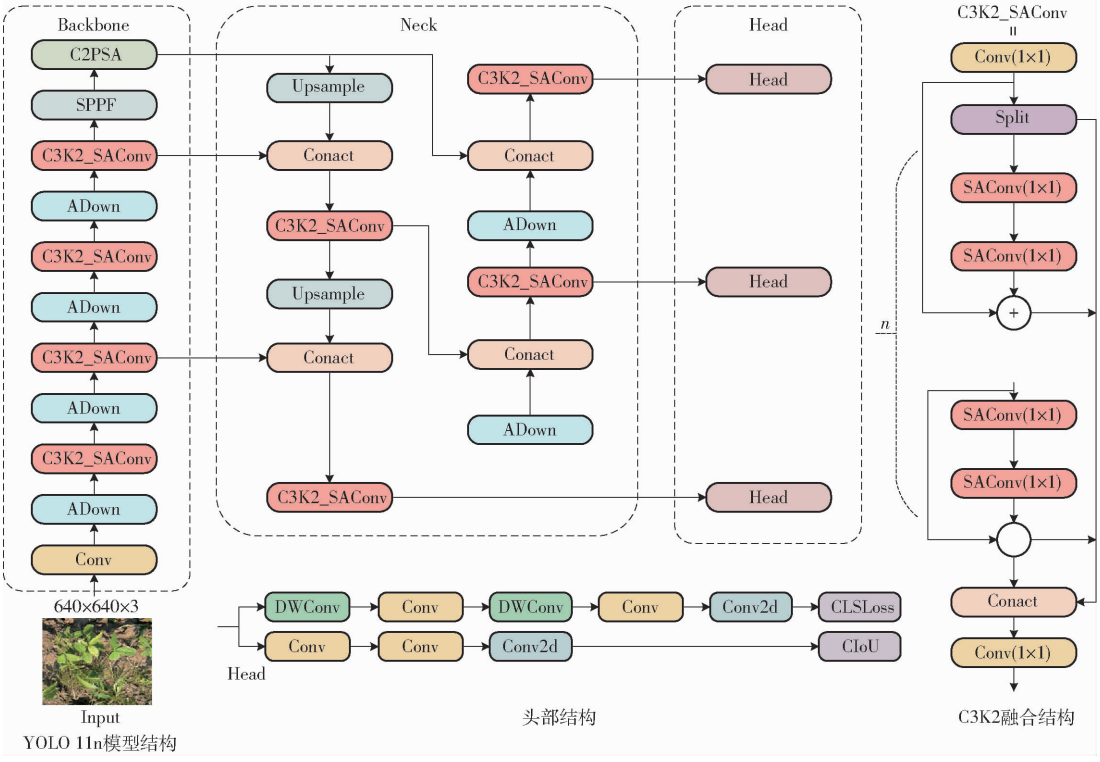


图 2 YOLO 11n-ADS 模型结构图

Fig. 2 Architecture of YOLO 11n-ADS

C3K2 跨阶段部分网络融合模块，C3K2 模块瓶颈结构是由 n 个可变卷积核 C3K 模块组成，其中 k 为可调整的卷积核大小，每个模块是由 2 个 3×3 的卷积构成，如图 3a 所示。

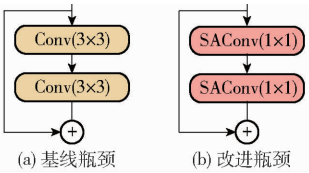


图 3　C3K2 改进前后结构对比

Fig. 3　Comparison of C3K2 structure before and after improvement

常规卷积运算是通过卷积核对输入的数据进行滑动窗口操作来提取图像中的局部特征，虽然这样能够快速地提取图像的主要特征，但因固定的感受野限制了模型对不同尺度信息的获取能力。因此，将 SAConv 模块替换 C3K2 模块的瓶颈结构，如图 3b 所示。

SAConv 架构如图 4 所示，由 SAC 模块及前后 2 个全局上下文模块 3 部分组成。在处理相同输入特征时，SAC 采用可变空洞率进行卷积运算。空洞卷积通过在卷积核中引入额外空洞，配合切换函数融合不同卷积核结果，有效扩大了感受野，使网络对不同特征的尺寸和尺度更具灵活性[27-28]。而前后 2 个全局上下文模块则会帮助网络根据图像中目标的尺度和位置变化自适应调整感受野，捕捉整幅图像的全局信息，使 SAC 模块能够在更广泛的上下文环境中高效工作。

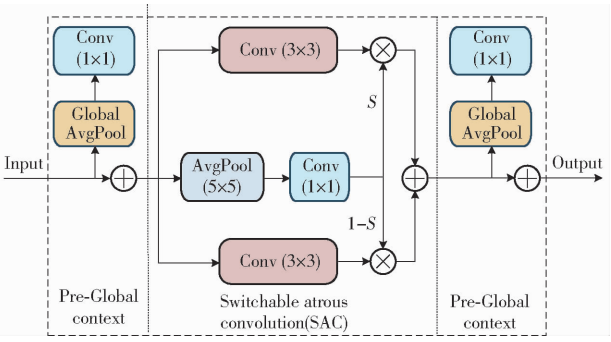


图 4　SAConv 模块结构图

Fig. 4　Architecture of SAConv module

SAC 模块还融合了双重观测机制与切换函数。双重观测机制能够对输入特征进行 2 次观测，每次采用不同的空洞率，使同一组输入特征经过 2 种不同卷积核，而每种配置对应特定空洞率。切换函数具有空间位置依赖性，能对不同位置的特征图实施差异性切换控制，实现调谐特征与特征整合。通过切换函数融合不同空洞率的卷积结果，即切换函数决定如何选择或组合 2 次卷积运算以生成最终输出的特征。

在训练阶段，模型采用双路径并行处理机制，输入特征图通过空洞率分别为 3 和 1 的卷积核进行多尺度特征提取，生成 2 种不同感受野的输出特征图。同时，输入特征经平均池化层压缩空间信息后，通过 1×1 卷积层学习动态权重参数，构成自适应切换函数 S。在推理阶段，系统将 2 种空洞卷积特征分别与 S 及其补数 $1-S$ 进行加权融合，最终通过特征叠加实现多尺度信息的自适应整合，显著增强模型对复杂场景中多尺度目标的表征能力。SAConv 的转换公式为

$$y = S(x) * \mathrm{Conv}(x, w, 1) + (1 - S(x)) * \mathrm{Conv}(x, w + \Delta w, r) \tag{1}$$

式中　x、y——SAConv 的输入与输出

w、r——SAC 空洞率超参数

Δw——可训练权重

$S(\cdot)$——自适应切换函数

$\mathrm{Conv}(x, w, r)$——卷积运算

SAConv 通过应用不同的空洞率、切换函数和转换机制，提升网络模型在处理多尺度及复杂特征时的适应性与准确性，使模型能更好地捕捉目标的多尺度信息。

因此，对 SAConv 与 YOLO 11 的瓶颈结构进行了融合改进，得到 C3K2_SAConv 模块。该模块能够在不同的空洞率间灵活切换，同时通过全局上下文模块和权重共享策略有效地增强特征提取与处理能力，提升特征表示质量，提高检测精度与鲁棒性。此外，借助 SAConv 的空洞卷积机制，C3K2_SAConv 能在不增加计算量的情况下扩大感受野，增强多尺度特征提取能力，更适合于复杂的田间杂草环境。

1.3.2　ADown 自适应下采样模块

在大豆田间场景中，光照、遮挡及背景等因素影响检测精度。传统卷积在骨干网络特征提取过程中采用大步长下采样，当目标特征微弱或被遮挡时易导致目标特征丢失。为提升复杂环境下杂草检测能力和目标检测精度，将 YOLO 11 骨干网络中的传统卷积替换为 ADown 下采样模块，如图 5 所示。

ADown 融合了平均池化与最大池化，平均池化保留全局信息，最大池化捕捉关键局部特征，二者结合实现多尺度特征提取。相较于传统卷积运算，ADown 通过调整卷积层步长来降低特征图空间维度，既能保留更多图像信息又可降低空间分辨率。

该模块还具备根据检测场景自适应调整的学习能力，根据光照、背景复杂度和杂草形态等不同

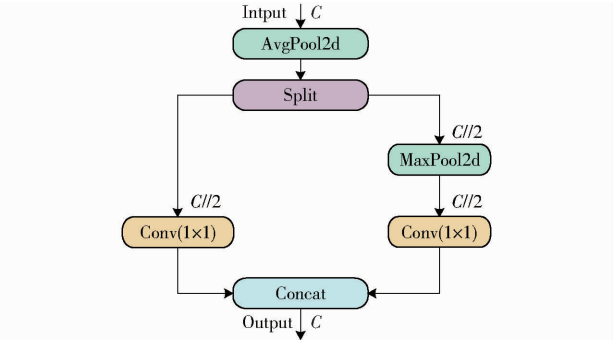


图 5 ADown 模块结构图

Fig. 5 Architecture of ADown module

环境条件自动调整参数。这种适应性有助于在多样化场景中保持较高的检测精度,同时使模型更好地防止复杂背景等的干扰,降低误检率并提升系统的可靠性。

ADown 模块首先对输入特征图进行平均池化,沿通道维度,将特征图划分为 2 部分子特征图。随后一部分执行卷积运算,另一部分先进行最大池化操作再进行卷积处理,再将 2 个子特征图拼接后输出。这种多分支结构的引入提供了更丰富的特征组合与信息交互,保留了更多上下文信息,并有效防止小尺度特征的丢失。

2 结果与分析

2.1 试验环境及评价指标

试验环境为 Windows 11 操作系统,CPU 为主频 5.20 GHz 的 Intel core i7 - 14600,杂草识别模型的搭建使用 Python 3.10 开发环境,深度学习框架选用 Pytorch。GPU 使用 NVIDIA GeForce RTX 4060Ti 进行运算加速,GPU 运行内存为 16 GB,CUDA 版本为 11.8。模型训练采用 GPU 运算,初始学习率设置为 0.01,批量大小设置为 8,动量设置为 0.937,迭代次数为 500,采用随机梯度下降(Stochastic gradient descent,SGD)作为优化器对训练过程进行优化。

为了验证模型性能,采用精确率(Precision,P)、召回率(Recall,R)、平均精度均值(Mean average precision,mAP)、浮点数运算量(Floating-point operations,FLOPs)和模型参数量(Params)[29-31]作为模型性能评价指标。

2.2 消融试验

为了验证改进模型 YOLO 11n - ADS 性能的有效性,以 YOLO 11n 为基准模型在大豆田间杂草数据集上进行消融试验,评估各个改进方法对基准模型性能的影响。

由表 2 可知,基准模型 YOLO 11n 的精确率、mAP_{50}和 mAP_{50-95}分别为 89.5%、89.4% 和 81.0%,参数量为 2.6×10^6。通过 SAConv 模块对瓶颈结构 C3K2 模块的替换,增强了模型的感受野和多尺度特征提取能力,与基准模型相比,虽检测精确率和 mAP_{50}分别仅提升 0.6、0.2 个百分点,但 mAP_{50-95}提升 2.5 个百分点,说明 SAConv 模块有效降低了模型的误检率和漏检率。在基准模型中引入 ADown 下采样模块方案中,通过融合平均池化与最大池化的双路径策略,虽精确率没有变化,但模型的浮点数运算量和参数量明显降低,mAP_{50}和 mAP_{50-95}分别提升 1.3、1.5 个百分点。单独融合的 ADown 模块比单独融合 SAConv 模块的参数量低 27.6%。

表 2 YOLO 11n - ADS 模型消融试验结果

Tab. 2 YOLO 11n - ADS model ablation experiment results

SAConv	ADown	P/%	R/%	mAP_{50}/%	mAP_{50-95}/%	参数量	浮点数运算量
×	×	89.5	89.0	89.4	81.0	2.6×10^6	6.3×10^9
√	×	90.1	89.8	89.6	83.5	2.9×10^6	6.1×10^9
×	√	89.5	90.2	90.7	82.5	2.1×10^6	5.3×10^9
√	√	90.6	92.6	92.0	86.0	2.2×10^6	4.6×10^9

注:"√"表示加入此方法,"×"表示不加入此方法。

YOLO 11n - ADS 模型集成上述 2 种改进方法能有效地提升检测精度与鲁棒性,并显著降低模型的计算复杂度,能够适应复杂环境下的实时杂草检测需求,相比基准模型精确率提升 1.1 个百分点,mAP_{50}提升 2.6 个百分点,mAP_{50-95}提升 5.0 个百分点,召回率提升 3.6 个百分点,参数量降低 15.4%,浮点数运算量降低 27.0%。

模型改进前后训练指标如图 6a 所示,YOLO 11n 模型在训练初期损失值较高且波动较大。而 YOLO 11n - ADS 的损失曲线下降更快且更平稳,最终达到更低的稳定值。表明通过引入 SAConv 和 ADown 模块,增强了特征提取的鲁棒性,加速收敛,优化了学习效率。如图 6b 所示,YOLO 11n - ADS 模型的召回率曲线和平均精度曲线优于 YOLO 11n 模型,表明改进模型在复杂环境下有更高的检测精度和更好的泛化能力。

为了清晰地展示 SAConv 感受野增强模块和 ADown 自适应下采样模块的实际优化效果,采用 Grad - CAM 可视化技术分别对改进前后模型进行可视化,通过热力图展示网络模型对被预测图像的

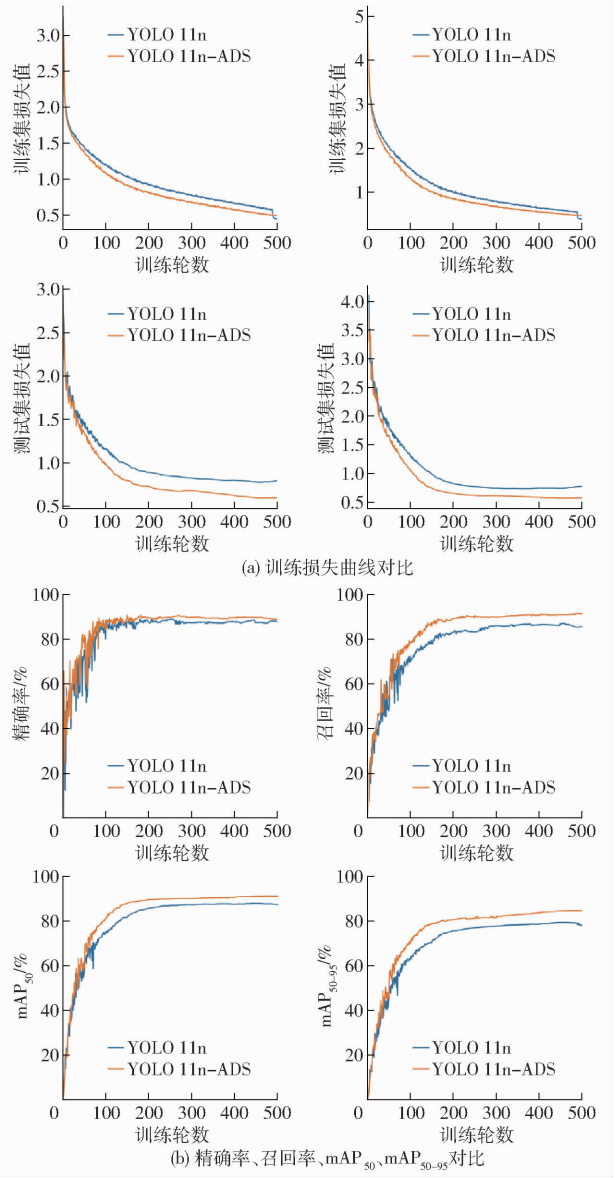


图 6　模型改进前后训练指标对比

Fig. 6　Comparison of training metrics before and after model improvement

关注区域[32]。如图 7b 所示，YOLO 11n 模型对杂草的识别存在漏检、误检等情况，聚焦的部位包含较多的背景信息，受到无关信息的影响较大。如图 7c 所示，增加 SAConv 模块可以拓展感受野，增强大尺度上下文捕捉能力。如图 7d 所示，增加 ADown 模块降低了特征图空间维度，保留了更多图像信息，有较好的识别能力。同时融入 2 个模块的 YOLO 11n－ADS 模型，其激活区域（高亮部分）更精确地聚焦于杂草目标本身，无论是前景中较大的杂草，还是背景中尺寸较小与大豆叶片发生部分遮挡的杂草都得到了关注。综上，从基准 YOLO 11n 模型的热力图可以看出，大部分目标未受到关注，即使受到关注，其目标的聚焦能力也不足，主要表现在激活区域延伸到了无关的土壤背景和作物叶片上，表明其特征提取的专一性和鲁棒性不足。

2.3　模型对比试验

为验证 YOLO 11n－ADS 模型的检测性能优势，选择 YOLO v5n、YOLO v8n、YOLO v9-tiny、基准模型 YOLO 11n 以及经典的双阶段检测算法 Fast R－CNN 进行对比试验。为确保试验结果的公平性和可信度，所有模型均在相同的硬件环境、训练参数和数据集配置下运行。

不同模型的对比试验结果如表 3 所示。传统的双阶段检测算法 Fast R－CNN 在杂草检测任务中表现相对较差，其平均精度均值 mAP_{50} 仅为 72.8%，同时该模型的参数量和浮点数运算量显著高于单阶段检测算法，推理速度较慢，在测试中帧率仅为 5 f/s，难以满足田间实时检测的应用需求。

在轻量级模型中，YOLO v5n 虽具有较高的推理速度和较小的参数量，但召回率为 84.0%，存在较多漏检现象；YOLO v9-tiny 的参数量控制方面表现最优，为 1.8×10^6，但推理速度仅为 90 f/s，难以满足高效检测需求。YOLO v8n 作为较新的模型版本，在检测性能上有所提升，mAP_{50} 达到 88.5%，但其参数量为 3.2×10^6，浮点数运算量相对较高，为 8.1×10^9，不利于轻量化部署。

改进模型 YOLO 11n－ADS 在检测精度与计算效率的平衡上表现最为突出，其 mAP_{50} 和 mAP_{50-95} 分别达到 92.0% 和 86.0%，相比 YOLO v5n、YOLO v8n、YOLO v9-tiny 和基准模型 YOLO 11n 分别提升 4.0、3.5、3.0、2.6 个百分点和 8.0、6.5、5.5、5.0 个百分点。同时，YOLO 11n－ADS 的召回率和精确率分别为 92.6% 和 90.6%，均保持在较高水平，表明该模型在减少漏检的同时有效保证了检测的准确性，具备良好的检测稳定性。

在计算效率方面，YOLO 11n－ADS 的浮点数运算量为 4.6×10^9，显著低于同类型的 YOLO 系列模型，相比 YOLO v8n 降低 43.2%，体现了其优异的轻量化特性。该模型的推理帧率可达 137 f/s，不仅满足了田间实时检测的速度要求，更在 YOLO 系列模型中表现出色。参数量为 2.2×10^6，相比基准模型 YOLO 11n 减少 15.4%，内存占用量为 1.6 GB，较低的计算复杂度和较小的模型规模使其更适合在资源受限的边缘计算设备上部署。

从整体性能综合评估来看，各模型在精度、速度和轻量化 3 个维度上呈现不同的权衡策略。YOLO v5n 在推理速度上具有优势，但漏检率较高。YOLO v9-tiny 在参数量控制上表现突出，但速度和召回率均有不足。YOLO v8n 参数量和计算成本均较高。基准模型 YOLO 11n 在各项指标上相对均衡，但仍有优化空间。YOLO 11n－ADS 模型不仅在检测性

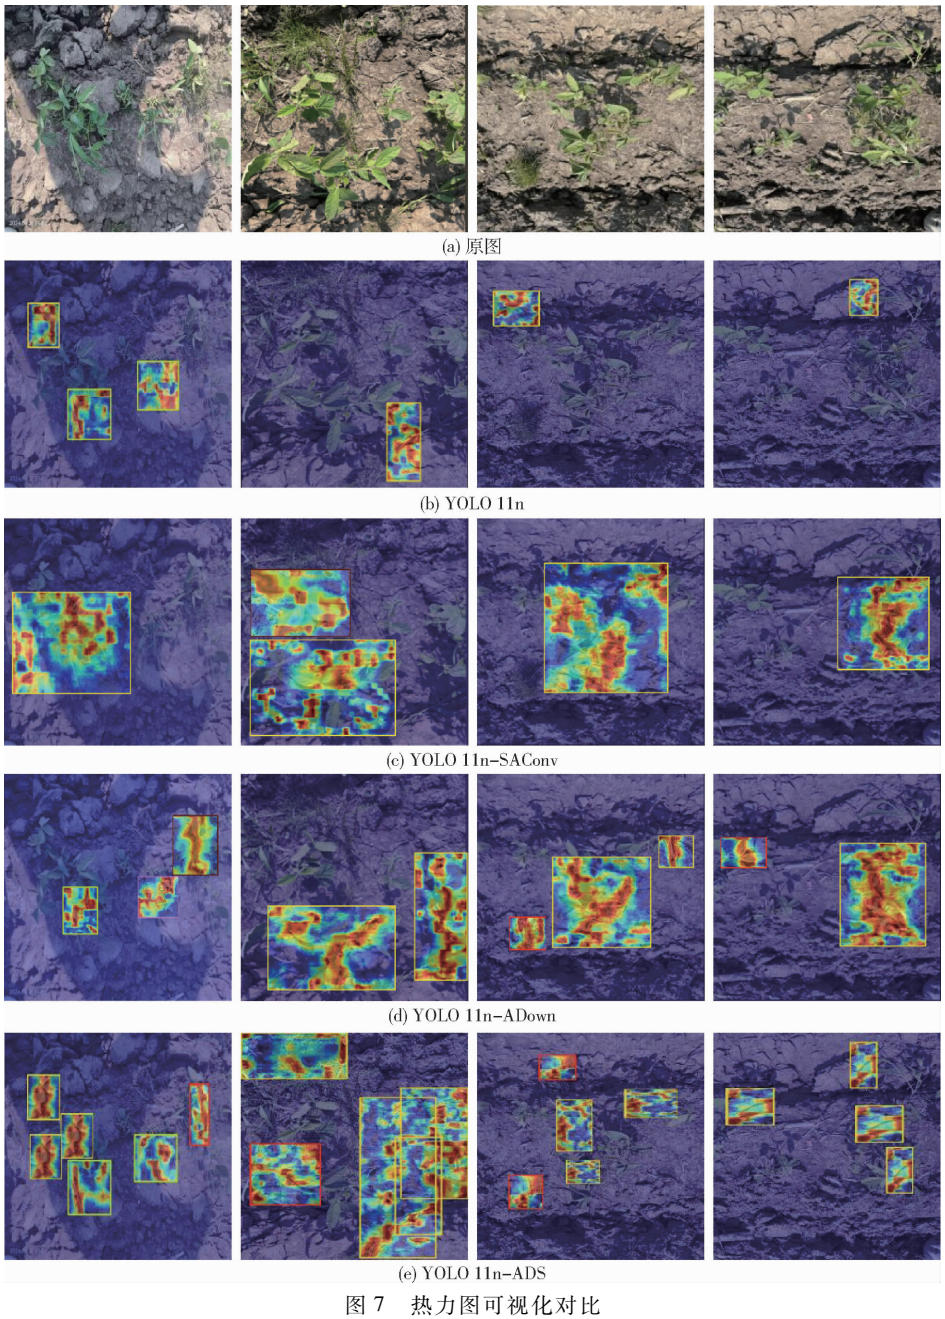


图 7 热力图可视化对比

Fig. 7 Heat map visualization comparison

表 3 6 种模型对比结果

Tab. 3 Comparative results of six models

模型	P/%	R/%	mAP_{50}/%	mAP_{50-95}/%	参数量	浮点数运算量	帧率/(f·s^{-1})
Fast R-CNN	66.1	71.1	72.8	59.0	1.4×10^{9}	3.7×10^{11}	5
YOLO v5n	90.2	84.0	88.0	78.0	2.5×10^{6}	5.8×10^{9}	139
YOLO v8n	89.5	89.0	88.5	79.5	3.2×10^{6}	8.1×10^{9}	120
YOLO v9-tiny	90.1	87.5	89.0	80.5	1.8×10^{6}	6.7×10^{9}	90
YOLO 11n	89.5	89.0	89.4	81.0	2.6×10^{6}	6.3×10^{9}	117
YOLO 11n-ADS	90.6	92.6	92.0	86.0	2.2×10^{6}	4.6×10^{9}	137

能上全面超越了其他对比模型,同时有效降低了网络模型的整体参数量和计算复杂度,在复杂的田间环境下展现出更强的实时性和环境适应性。特别是在光照变化、目标遮挡等复杂场景下,它具有更好的鲁棒性,为农业机器人和精准除草设备的智能化应用提供了高效可靠的技术支撑。

3 田间验证试验

3.1 田间测试平台

为了验证 YOLO 11n-ADS 模型在大豆田间的

实际运行效果，田间试验采用自制的自行走杂草识别平台进行测试，平台共由 8 部分组成，如图 8 所示。



图 8　自行走杂草识别平台

Fig. 8　Self-propelled weed identification platform

1. 药液箱　2. 供电模块　3. 显示屏　4. 驱动轮　5. 控制组件
6. 高清摄像头　7. 并联机械臂　8. Jetson Nano

靶向精准除草部件采用并联机械臂，核心参数包括工作直径 550 mm、Z 轴行程 200 mm 及负载能力 500 g。机械系统采用三支链对称结构：静平台与动平台通过碳纤维主动臂和高强度 PLA 材料 3D 打印的水滴形从动臂连接，其中十字万向节与轴承构成的关键铰链系统保障了动平台三自由度灵活运动。以 Arduino 为主控制器，配合 3 个 TMC2209 步进驱动器对 57 步进电机进行精密控制，整套系统由 24 V/5 A 电源统一供电。控制软件通过实时解算逆运动学方程，将末端目标坐标转换为 3 个电机的转动角度，实现轨迹规划。药液流控制采用泵阀协同闭环控制，通过微型隔膜泵在耐腐蚀管路中建立稳定恒压环境，高速常闭电磁阀接收来自主控系统的脉宽调制信号，实现药液流的启闭控制。

视频流采集系统采用 USB 工业摄像头，摄像头支持 1 920 像素 ×1 080 像素全高清分辨率，可清晰捕捉作物纹理与杂草形态细节，为深度学习模型提供更丰富的特征信息。视频流支持 120 f/s 输出，能满足机械臂高速作业时的实时性需求，通过 USB 3.0 接口实现高效数据传输，为后续的视觉识别构建了稳定可靠的数据采集通道。

3.2　边缘设备部署

为验证 YOLO 11n－ADS 田间杂草检测模型在边缘计算设备上的实际应用效果，选择 NVIDIA TensorRT 推理部署框架，将改进模型部署到 Jetson Nano 边缘计算平台。

先将训练完成的模型权重文件 Best. pt 导出为 . onnx 格式的中间表示文件，该格式提供了跨平台的模型表示标准，便于后续优化处理。随后，进行节点优化和图结构简化，消除冗余操作并合并可融合的层。接着，将优化后的文件传输至 Jetson Nano 设备，利用 TensorRT 推理加速框架解析网络结构，通过 trtexec 工具生成针对目标硬件优化的 engine 推理引擎。该引擎文件经过了针对性的算子优化和内存布局调整，能够充分利用设备的 GPU 计算资源，实现高效的模型推理部署。整个部署流程如图 9 所示。

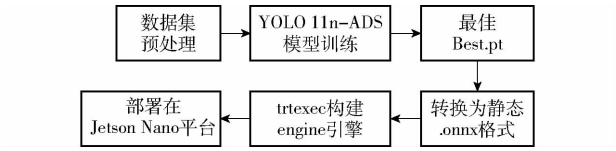


图 9　模型部署流程图

Fig. 9　Model deployment flowchart

部署后的 YOLO 11n－ADS 模型通过设置检测置信度阈值为 0. 88，采用非极大值抑制（NMS）算法消除重复检测框。同时，利用 TensorRT 框架的 FP16 精度优化，在保持检测精度的前提下提升推理速度。在静态测试环境下，模型的理论检测速度可达到 35 f/s。在实际田间动态环境中，受图像采集、数据传输和环境干扰等影响，平均检测帧率为 28 f/s。不同模型在 Jetson Nano 端的对比试验结果如表 4 所示，YOLO 11n－ADS 模型的精确率、mAP_{50} 和 mAP_{50-95} 分别为 89. 5%、91. 0% 和 84. 0%，所有指标均优于其它模型。

表 4　Jetson Nano 端的模型对比结果

Tab. 4　Model comparison results on Jetson Nano

模型	P/%	R/%	mAP_{50}/%	mAP_{50-95}/%	帧率/(f·s^{-1})
YOLO v5n	89. 1	81. 0	85. 0	74. 0	20
YOLO v8n	89. 0	84. 0	86. 0	75. 0	15
YOLO v9-tiny	88. 9	86. 2	86. 4	78. 9	18
YOLO 11n	87. 4	87. 0	86. 8	79. 2	22
YOLO 11n－ADS	89. 5	91. 4	91. 0	84. 0	28

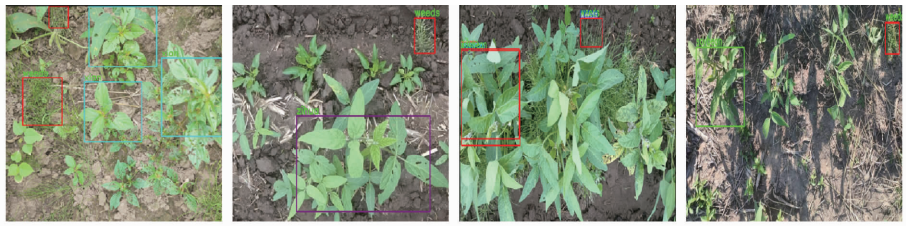
3.3　田间性能测试

在东北农业大学向阳基地的大豆田间进行动态检测，移动平台的检测帧率（R_{FPS}）与前进速度（v）之间存在一个为确保无遗漏检测的根本制约关系。为了保证对田块的完全覆盖，摄像头处理完 1 帧图像的时间 $1/R_{FPS}$ 必须小于或等于移动平台前进 1 个相机视场地面覆盖高度（H_{fov}）所需的时间（H_{fov}/v），即 $R_{FPS} \geqslant v/H_{fov}$。平台摄像头安装高度使其地面垂直视场覆盖高度 H_{fov} 为 0. 5 m。当平台以速度 0. 8 m/s 前进时，为实现无缝覆盖，理论上要求的最低帧率为 0. 8/0. 5 = 1. 6 f/s。然而，这只是一个理论下限。在

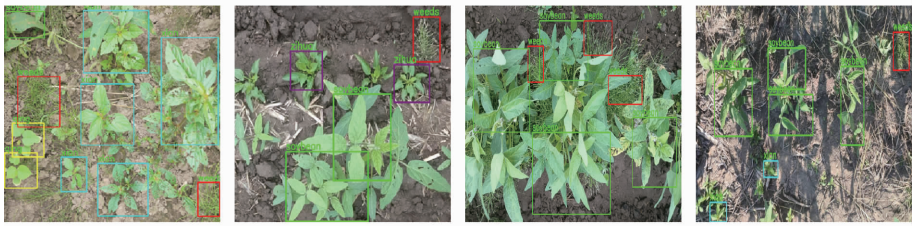
实际应用中,为了应对运动模糊、保证帧间有足够的重叠区域以便进行目标跟踪或确认,以及为控制系统的反应留出时间裕度,实际运行的帧率需要远高于此理论值。平台在速度 0.8 m/s 下平均帧率为 28 f/s,远超理论最低要求,提供了超过 17 倍的安全冗余,充分保证了在动态作业过程中的检测可靠性和完整性。

YOLO 系列算法的理论检测上限虽高,但在实际应用中,尤其是在目标密集的复杂场景下,其有效检测数量常受到后处理算法的限制。一个核心挑战在于非极大值抑制(NMS)环节:当多个独立目标(如紧密生长的杂草)的边界框高度重叠时,NMS 可能将其错误地合并为一个,从而造成目标漏检。在田间实地测试中,YOLO 11n - ADS 模型表现出强大的目标分辨能力,在包含大豆和各类杂草的最密集场景下,单帧能够最多识别 18 个独立目标。这一结果说明,该模型在农业环境中具有高度的鲁棒性与优越的实例分割性能。这主要归因于 SAConv 模块的空洞卷积与全局上下文机制,增强了网络对多尺度特征的提取与整合能力,从而为邻近但不同的目标生成了更具区分度的特征表示,有效缓解了 NMS 的合并问题。另外,在实际应用中,单帧能够有效识别的目标数量主要受目标密度与尺寸及后处理阶段的 NMS 算法等因素制约。因此,单帧识别 18 个目标的能力,证明了 YOLO 11n - ADS 模型在密集杂草场景中,具有出色的分辨能力和鲁棒性,这得益于 SAConv 模块增强的多尺度特征提取能力。

在杂草分布密集田间验证的场景中,如图 10 左起 1、2 列的图,YOLO 11n 可能会因为目标之间的遮挡和重叠而导致误检或漏检。而 YOLO 11n - ADS 通过 SAConv 模块的多尺度特征融合,有效地增强了对重叠目标的识别能力。如图 10 左起第 3 列的图,展示在阴影环境中,YOLO 11n 模型容易出现误检或漏检。改进模型通过引入 SAConv 模块,增强了对不同尺度特征的提取能力,在阴影环境下依然能够较为准确地识别出杂草,减少了由于光照不足或背景杂乱造成的误差,表现出较强的鲁棒性。在图 10 左起第 4 列图中,光照不均匀的环境通常会导致图像亮度分布差异,从而影响目标检测的准确性。YOLO 11n - ADS 在这种条件下的表现优于 YOLO 11n,因为 ADown 模块的自适应下采样策略能够有效平衡不同亮度区域的特征提取,避免了由于光照变化造成的特征丢失。此外,SAConv 模块的空洞卷积机制有助于在光照变化的情况下保持多尺度的特征提取能力,从而保证了在光照干扰下的高准确度。



(a) YOLO 11n



(b) YOLO 11n-ADS

图 10 阴影、光照、密集场景下检测效果对比

Fig. 10 Detection performance comparison under shadow, illumination, and dense clutter conditions

通过田间试验,验证了 YOLO 11n - ADS 模型的有效性和实用性,能够满足实际农业生产的基本需求,为智能除草装备的产业化应用提供了重要的技术支撑和可行性验证。

4 结论

(1)提出了一种基于改进 YOLO 11n 的轻量级杂草检测 YOLO 11n - ADS 模型。通过引入 SAConv 模块,增强多尺度特征提取能力,提升复杂环境下不同尺寸杂草的检测精度;采用 ADown 融合平均池化与最大池化策略,减少目标遮挡与光照干扰导致的特征丢失。模型的改进在保证检测性能的同时,有效降低了参数量与浮点数运算量,为边缘计算设备部署提供了可行性基础。

(2)通过消融试验验证了各改进模块的有效性。试验结果表明,SAConv 模块单独引入使 mAP_{50-95} 提升 2.5 个百分点,增强了感受野和多尺度特征提取能力;ADown 模块则有效降低了模型复

杂度，且 mAP_{50-95} 提升了 1.5 个百分点。与基准模型 YOLO 11n 相比，综合改进后的 YOLO 11n－ADS 的浮点数运算量和参数量分别下降了 27.0% 和 15.4%，其检测精度、mAP_{50} 和 mAP_{50-95} 分别提升了 1.1、2.6、5.0 个百分点。训练损失曲线与 Grad－CAM 热力图分析表明，改进模型收敛更快、关注区域更精准，有效减少了复杂环境下的漏检与误检现象。

(3)试验结果表明，YOLO 11n－ADS 在检测精度、检测速度和轻量化部署方面均表现出色。相比 YOLO v8n，mAP_{50} 提升 3.5 个百分点，浮点数运算量降低 43.2%，推理帧率达到 137 f/s。相比其他对比模型，YOLO 11n－ADS 在多样化田间环境中表现出良好的检测稳定性，为复杂环境下高精度、高效率的实时检测提供了技术支撑。

(4)将 YOLO 11n－ADS 模型在 NVIDIA Jetson Nano 边缘计算上轻量化部署。采用 TensorRT 推理优化框架，模型在边缘设备上的内存占用量仅为 1.6 GB，在静态环境下模型推理速度可达 35 f/s，实际田间动态端到端平均检测帧率 28 f/s。在后处理环节，通过设置 0.88 的置信度阈值，确保较高可信度的检测结果被输出至下游决策系统，从而抑制潜在的虚警(False positives)。田间验证试验表明，移动平台以速度 0.8 m/s 作业时 mAP_{50} 可达 91.0%，验证了模型在真实农业环境下的有效性和实用性。

参　考　文　献

[1] 王禹，李干琼，喻闻，等. 中国大豆生产现状与前景展望[J]. 湖北农业科学，2020，59(21)：201－207.
WANG Yu, LI Ganqiong, YU Wen, et al. Current situation and prospect of soybean production in China[J]. Hubei Agricultural Science, 2020, 59(21): 201－207. (in Chinese)

[2] FANG H M, NIU M M, XUE X Y, et al. Effects of mechanical-chemical synergistic weeding on weed control in maize field [J]. Trans. Chin. Soc. Agric. Eng., 2022, 38: 44－51.

[3] 郭相平，高爽，吴梦洋，等. 中国农作物水足迹时空分布与影响因素分析[J]. 农业机械学报，2018，49(5)：295－302.
GUO Xiangping, GAO Shuang, WU Mengyang, et al. Analysis of temporal-spatial distribution and influencing factors of water footprint in crop production system of China[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(5): 295－302. (in Chinese)

[4] 丁伟，赵慧凝. 乙草胺不同时期施用对大豆安全性和杂草防效影响[J]. 东北农业大学学报，2019，50(5)：35－42.
DING Wei, ZHAO Huining. Weed control and soybean response to application of acetochlor in different periods[J]. Journal of Northeast Agricultural University, 2019, 50(5): 35－42. (in Chinese)

[5] 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(2)：323－334.
YUAN Hongbo, ZHAO Nudong, CHENG Man. Review of weeds recognition based on image proeessing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(2): 323－334. (in Chinese)

[6] WU Zhangnan, CHEN Yajun, ZHAO Bo, et al. Review of weed detection methods based on computer vision[J]. Sensors, 2021, 21(11): 3647.

[7] 张俊宁，毕泽洋，闫英，等. 基于注意力机制与改进 YOLO 的温室番茄快速识别[J]. 农业机械学报，2023，54(5)：236－243.
ZHANG Junning, BI Zeyang, YAN Ying, et al. Rapid recognition of greenhouse tomato based on attention mechanism and improved YOLO[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(5): 236－243. (in Chinese)

[8] 宋怀波，马宝玲，尚钰莹，等，基于 YOLO v7－ECA 模型的苹果幼果检测[J]. 农业机械学报，2023，54(6)：233－242.
SONG Huaibo, MA Baoling, SHANG Yuying, et al. Detection of young apple fruits based on YOLO v7－ECA model[J] Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(6): 233－242. (in Chinese)

[9] 闫泽禹. 番茄穴盘自动播种装置与漏播检测系统设计及关键技术研究[D]. 杨凌：西北农林科技大学，2024.
YAN Zeyu. Design and key technology research of tomato plug tray automatic planting device and missing seeding detection system[D]. Yangling: Northwest A&F University, 2024. (in Chinese)

[10] 黄家才，唐安，陈光明，等. 基于 Compact－YOLO v4 的茶叶嫩芽移动端识别方法[J]. 农业机械学报，2023，54(3)：282－290.
HUANG Jiacai, TANG An, CHEN Guangming, et al. Mobile end identification method of tea buds based on Compact－YOLO v4[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(3): 282－290. (in Chinese)

[11] 罗斌，李家超，周亚男，等. 基于改进 YOLO v8 的轻量化稻瘟病孢子检测方法[J]. 农业机械学报，2024，55(11)：32－38.
LUO Bin, LI Jiachao, ZHOU Ya'nan, et al. Lightweight rice blast spores detection method based on improved YOLO v8[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 32－38. (in Chinese)

[12] GUPTA S K, YADAV S K, SONI S K, et al. Multiclass weed identification using semantic segmentation: an automated approach for precision agriculture[J]. Ecol. Informatics, 2023, 78: 102366.

[13] YANG Q L, YE Y, GU L H, et al. MSFCA－net: a multi-scale feature convolutional attention network for segmenting crops and weeds in the field[J]. Agriculture, 2023, 13(6): 1176.

[14] MODI R U, KANCHETI M, SUBEESH A, et al. An automated weed identification framework for sugarcane crop: a deep learning approach[J]. Crop Protect, 2023, 173:106360.
[15] 罗志聪,李鹏博,宋飞宇,等.嵌入式设备的轻量化百香果检测模型[J].农业机械学报,2022,53(11):262-269,322.
LUO Zhicong, LI Pengbo, SONG Feiyu, et al. Lightweight passion fruit detection model based on embedded device[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022,53(11):262-269,322. (in Chinese)
[16] 苗荣慧,李志伟,武锦龙.基于改进 YOLO v7 的轻量化樱桃番茄成熟度检测方法[J]. 农业机械学报, 2023,54(10):225-233.
MIAO Ronghui, LI Zhiwei, WU Jinlong. Lightweight maturity detection of cherry tomato based on improved YOLO v7[J]. Transactions of the Chinese Society for Agricultural Machinery,2023,54(10):225-233. (in Chinese)
[17] NAGEL M, BAALEN M V, BLANKEVOORT T, et al. Data-free quantization through weight equalization and bias correction [C]// ICCV, 2019:1325-1334.
[18] HOWARD A, SANDLER M, CHU G, et al. Searching for MobileNetV3[C]// ICCV, 2019:1314-1324.
[19] 亢洁,刘港,王勃,等.基于动态剪枝神经网络的杂草检测算法研究[J].农业机械学报,2023,54(4):269-277.
KANG Jie, LIU Gang, WANG Qing, et al. Weed detection algorithm based on dynamic pruning neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023,54(4):269-277. (in Chinese)
[20] OLGUIN-ROJAS J C, VASQUEZ J I, LOPEZ-CANTENS G J, et al. A lightweight YOLO-based architecture for apple detection on embedded systems[J]. Agriculture, 2025, 15(8):838.
[21] ZHOU L, YANG S, WANG C, et al. QCF-YOLO: a lightweight model of surface defect detection for quick-connect fittings [J]. IEEE Sensors Journal, 2024, 25:10752899.
[22] QIAO S Y, CHEN L C, YUILLE A. Detectors: detecting objects with recursive feature pyramid and switchable atrous convolution[C]// Proceedings of the IEEE CVF Conference on Computer Vision and Pattern Recognition, Nashville, 2021: 10213-10224.
[23] ZHAO Z, KANG J, SUN Z, et al. A real-time and high-accuracy railway obstacle detection method using lightweight CNN and improved transformer[J]. Measurement, 2024, 238:16.
[24] GIRSHICK R. Fast R-CNN[C]// Proceedings of the IEEE, International Conference on Computer Vision, 2015:1440-1448.
[25] KHANAM R, HUSSAIN M. YOLOv11: an overview of the key architectural enhancements[J]. arXiv Preprint, arXiv:2410.17725, 2024.
[26] 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)
[27] PAPANDREOU G, KOKKINOS I, SAVALLE P A. Modeling local and global deformations in deep learning: epitomic convolution, multiple instance learning, and sliding window detection[C]// CVPR, 2015:390-399.
[28] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Semantic image segmentation with deep convolutional nets and fully connected CRFs[J]. Computer Science, 2014(4):357-361.
[29] LIN T Y, MAIRE M, BELONGIE S, et al. Microsoft COCO: common objects in context[J/OL]. Springer International Publishing, 2014. DOI:10.1007/978-3-319-10602-1_48.
[30] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017(99):2999-3007.
[31] YU Y, LEE S, CHOI Y, et al. CurlingNet: compositional learning between images and text for fashion IQ data[J]. arXiv Preprint, arXiv:2003.12299, 2020.
[32] SELVARAJU R R, DAS A, VEDANTAM R, et al. Grad-CAM: why did you say that? [J]. arXiv Preprint, arXiv:1611.07450, 2016.