

基于改进 YOLO v10 的复杂田间杂草检测模型

李晓菲¹ 赖广华² 张 洋² 陈柯彤² 陶万成² 李慕义² 李 胤^{3,4}
李 权² 张惠敏⁵ 苏 伟⁶

(1. 宿迁学院数理学院, 宿迁 223800; 2. 宿迁学院建筑工程学院, 宿迁 223800;

3. 江苏省自然资源厅卫星遥感应用重点实验室, 南京 210018; 4. 江苏省地质调查研究院, 南京 210018;

5. 宿迁学院生物与材料工程学院, 宿迁 223800; 6. 中国农业大学土地科学与技术学院, 北京 100193)

摘要: 针对复杂农田环境下因遮挡与光照变化导致杂草检测精度低的问题,本文构建并扩充杂草图像数据集,并提出一种基于 YOLO v10 的改进检测模型 SDE - YOLO v10。以 YOLO v10 模型为基准,采用激活函数为 ReLU 的 SimSPPF(Simplified spatial pyramid pooling fast)替换骨干网络原有池化结构,以增强模型对多尺度杂草特征的提取能力;在颈部网络(Neck)C2f 处引入可变形卷积网络 v3(Deformable convolutional networks v3, DCNv3)构建 C2f_DCNv3 模块,提升模型对不规则形态杂草的自适应感知;嵌入具有空间和通道注意力的 EMA(Efficient multi-scale attention)注意力机制,增强模型对图像不同特征维度的关注与加权能力。在自主构建并扩充的杂草数据集(3 126 幅)上进行试验,消融试验与多模型性能试验结果表明,SDE - YOLO v10 模型精确率、召回率、mAP@ 0.5 和 mAP@ 0.5:0.95 最高,分别为 91.3%、80.2%、86.7% 和 73.1%,相比 YOLO v10 基线模型分别提升 5.4、4.7、1.5、2.3 个百分点。在光照变化和遮挡条件下,改进模型检测成功率分别为 86.42% 和 82.72%,较原模型分别提高 13.58、12.35 个百分点,表明在复杂条件下具有良好鲁棒性。SDE - YOLO v10 能实现对复杂形态杂草的准确识别,同时优化了网络结构,为智慧农业场景下实时杂草检测提供了技术参考。

关键词: 杂草检测; YOLO v10; 可变形卷积; 注意力机制

中图分类号: S451 **文献标识码:** A **文章编号:** 1000-1298(2026)20-0154-09

OSID:



Improved YOLO v10-based Detection Model for Weeds in Complex Field Environments

Li Xiaofei¹ Lai Guanghua² Zhang Yang² Chen Ketong² Tao Wancheng² Li Mui²
Li Yin^{3,4} Li Quan² Zhang Huimin⁵ Su Wei⁶

(1. School of Mathematics and Physics, Suqian University, Suqian 223800, China

2. School of Architectural Engineering, Suqian University, Suqian 223800, China

3. Key Laboratory of Satellite Remote Sensing Application, Jiangsu Department of Natural Resources, Nanjing 210018, China

4. Geological Survey of Jiangsu Province, Nanjing 210018, China

5. School of Biological and Materials Engineering, Suqian University, Suqian 223800, China

6. College of Land Science and Technology, China Agricultural University, Beijing 100193, China)

Abstract: Aiming to address the issue of low weed detection accuracy caused by occlusion and varying lighting conditions in complex farmland environments, a weed image dataset was constructed and augmented and an improved detection model, SDE - YOLO v10, was proposed based on YOLO v10. Firstly, the original pooling structure in the backbone network was replaced with the simplified spatial pyramid pooling fast (SimSPPF) module to enhance the extraction of multi-scale weed features. Secondly, the deformable convolutional networks v3 (DCNv3) was introduced into the C2f module in the neck network to improve adaptive perception of irregularly shaped weeds. Meanwhile, the efficient multi-

收稿日期: 2026-01-23 修回日期: 2026-07-08

基金项目: 宿迁市科技计划项目(K202537)、江苏省产学研合作项目(BY20251504)、国家重点研发计划政府间国际科技创新合作项目(2025YFE0102000)、江苏省高等学校基础科学(自然科学)研究重大项目(24KJA220003)和福建省特色生物化工材料重点实验室开放课题(FJKL_FBCM202509)

作者简介: 李晓菲(1994—),女,助理讲师,主要从事机器视觉与人工智能算法研究,E-mail: 854138671@qq.com

通信作者: 陶万成(1993—),男,讲师,博士,主要从事农业定量遥感研究,E-mail: 19164@sq. edu. cn

scale attention (EMA) mechanism was embedded to strengthen the model's focus on key feature dimensions. Experiments were conducted on the self-constructed and augmented weed dataset (3 126 images). Results from ablation experiments and multi-model comparisons indicated that the SDE - YOLO v10 model achieved the highest precision, recall, mAP@0.5, and mAP@0.5:0.95 scores of 91.3%, 80.2%, 86.7% and 73.1%, respectively. These represent improvements of 5.4, 4.7, 1.5 and 2.3 percentage points over the baseline YOLO v10 model. Under conditions of varying lighting and occlusion, the improved model attained detection success rates of 86.42% and 82.72%, corresponding to improvements of 13.58 and 12.35 percentage points compared with that of the original model, demonstrating its strong robustness in complex scenarios. SDE - YOLO v10 enabled accurate identification of weeds with complex morphology while optimizing the network architecture, providing a technical reference for real-time weed detection in smart agriculture scenarios.

Key words: weed detection; YOLO v10; deformable convolution; attention mechanism

0 引言

田间杂草精准识别与定位是实施变量施药与智能除草的关键前提,对推动精准农业与生态可持续发展具有重要意义^[1]。然而,自然农田环境下杂草检测面临诸多挑战,杂草与作物幼苗苗期形态、颜色高度相似;目标尺寸小且分布密集;同时,光照变化、枝叶遮挡和复杂背景噪声进一步增加准确识别的难度^[2],对检测算法的特征分辨能力和模型鲁棒性提出了更高要求。

近年来,基于深度学习的 YOLO 系列模型因在实时目标检测中卓越性能,在农业视觉感知领域得到了广泛应用与持续改进^[3-6]。刘芳等^[7]针对番茄果实在复杂枝叶与光照干扰下识别问题,提出了一种改进型 YOLO 模型,通过优化锚框与增强特征融合,在自建数据集检测准确率为 91.7%,验证了 YOLO 框架在农业复杂场景下适应潜力。王卓等^[8]基于改进 YOLO v4 构建了自然环境下苹果轻量级检测模型,通过优化网络结构在保证精度的同时显著提升了检测速度,为移动端部署提供了可能。杨锋等^[9]针对小麦叶片病虫害,提出了基于改进 YOLO v8 的轻量化模型,通过引入高效的网络模块,在复杂田间背景下实现了对细小病斑的准确检测。在语义分割领域,祝诗平等^[10]基于改进 DeepLabv3+ 模型进行马铃薯幼苗与杂草识别,通过引入多尺度注意力模块和密集连接结构,显著提升了模型对幼苗与杂草边缘的区分能力,平均交并比达到 85.6%,为在检测任务中强化多尺度上下文感知提供了借鉴。Chandra 等^[11]将多层注意力机制与 YOLO v10 结合用于遥感影像滑坡测绘,构建的注意力增强模块显著提升了模型在复杂地形背景下特征聚焦能力,在公开数据集 F1 分数达到 89%,证明了注意力机制在增强 YOLO 模型关键信息捕获能力方面的有效性。上述研究结果共同表明,通过引入轻

量化设计、注意力机制与多尺度融合等策略,能显著提升 YOLO 系列模型在农业复杂场景下检测性能^[12]。尽管上述研究在特定作物或场景中取得了进展,但现有研究多聚焦于单一作物或特定环境下目标识别,面向复杂田间背景的杂草精准实时检测仍面临高精度与鲁棒性平衡的挑战^[13]。

因此,本文提出一种基于改进 YOLO v10 的田间杂草检测模型。首先,在骨干网络引入融合多分支池化与跨层连接的 SimSPPF (Simplified spatial pyramid pooling fast) 模块,通过扩展特征金字塔的感受野层次,增强模型对多尺度杂草特征的捕捉能力。其次,在颈部网络 (Neck) 采用可变形卷积网络 v3 (Deformable convolutional networks v3, DCNv3) 模块,构建 C2f_DCNv3 结构,使卷积采样能根据杂草的不规则轮廓自适应调整空间分布,提升对目标几何形变的建模精度。同时,嵌入具有空间和通道注意力的 EMA (Efficient multi-scale attention) 注意力机制,强化模型对关键判别特征的权重分配,以抑制复杂田间背景干扰。最后,利用田间杂草图像数据集进行模型验证。

1 材料与方法

1.1 田间杂草数据集

1.1.1 图像采集

选取 12 种农田杂草为对象,分别为莠荳菜、钻叶紫菀、酢浆草、牛筋草、飞蓬、马兰、一枝香、叶下珠、小叶冷水花、车前草、凤尾草、苣荬菜。其中,莠荳菜虽属蔬菜物种,但田间自生苗不属于人工栽培作物,一般混杂于玉米和花生等农田中,与栽培作物竞争光照、水肥及生长空间,是常见的农田伴生杂草,符合杂草样本选取要求。其余 11 种均为农田典型杂草,物种代表性强、分布广泛。

图像采集于江西省赣州市与景德镇市,共 142 个采样地块,采集时间为 2025 年 6—9 月,涵盖杂草

主要生长期。采集设备为 vivo Y78 型智能手机,分辨率 3 060 像素 × 4 080 像素,存储格式 JPG,拍摄高

度距冠层约 0.5 m,包括晴天、阴天、顺光、逆光等自然光照条件,部分样例如图 1 所示。



图 1 采集的部分杂草数据集图像

Fig. 1 Partial images of collected weed dataset

1.1.2 数据集构建

利用 LabelImg 标注工具的 YOLO 格式对杂草数据集进行人工标注,标签分别为莴苣菜 (*Lactuca sativa*)、钻叶紫菀 (*Symphyotrichum subulatum*)、酢浆草 (*Oxalis corniculata*)、牛筋草 (*Eleusine indica*)、飞蓬 (*Erigeron annuus*)、马兰 (*Kalimeris indica*)、一枝香 (*Veronica linariifolia*)、叶下珠 (*Phyllanthus urinaria*)、小叶冷水花 (*Pilea microphylla*)、车前草 (*Plantago asiatica*)、凤尾草 (*Pteris multifida*)、苣荬菜 (*Sonchus arvensis*),标注信息以 txt 文件形式保存,构建共计 1 563 幅杂草原始数据集。采用随机翻转和色彩抖动等数据增强策略对原始训练集进行在线扩充,扩增后图像总量为 3 126 幅,各类别图像数量见表 1。

表 1 杂草数据集基本信息

Tab. 1 Basic information of weed dataset 幅				
种类	总数	训练集数量	验证集数量	测试集数量
莴苣菜	314	250	32	32
钻叶紫菀	286	230	28	28
酢浆草	220	176	22	22
牛筋草	242	194	24	24
飞蓬	226	182	22	22
马兰	216	172	22	22
一枝香	220	176	22	22
叶下珠	300	240	30	30
小叶冷水花	320	256	32	32
车前草	284	228	28	28
凤尾草	266	214	26	26
苣荬菜	232	184	24	24
共计	3 126	2 502	312	312

2 模型训练与改进

2.1 YOLO v10 目标检测模型

目标检测模型高效化设计是提升实用性的关

键。MobileNet 系列^[14]、ShuffleNet 系列^[15]通过深度可分离卷积、通道混洗等操作降低模型计算复杂度,GhostNet^[16-17]进一步采用线性变换生成特征冗余,此类主干网络常被用作 YOLO 等检测器的基础架构。YOLO v10 采用无需非极大值抑制设计与精度协同优化的模型架构,在检测精度与计算效率间取得良好平衡,架构设计有利于嵌入式部署。综合考虑杂草检测对实时性与精度的要求,选取 YOLO v10 作为基线模型。然而在复杂农田环境中,该模型直接用于杂草检测时仍面临挑战:①模型空间金字塔池化模块在捕捉极端尺度杂草特征时能力有限。②标准卷积的固定采样方式,难以适配杂草不规则的几何形变。③在田间复杂背景干扰下,模型对杂草关键特征的聚焦能力有待提升。因此,以 YOLO v10 为基础框架进行改进,以期获得适用于真实农田场景的检测模型。

2.2 改进网络模型

改进 YOLO v10 模型整体架构如图 2 所示,通过对骨干网络和颈部网络进行系统性优化实现。首先,在骨干网络末端采用 SimSPPF 模块替代原有的空间金字塔池化层,以增强模型对多尺度杂草特征的表达能力;然后,在颈部网络同步引入可变形卷积 DCNv3 构建 C2f_DCNv3 模块,同时嵌入 EMA 注意力机制,从而协同提升模型对不规则形态杂草的几何适应性与判别性特征的选择性关注。通过以上改进,构成一个面向复杂农田场景的杂草检测模型。

2.2.1 改进金字塔池化层模块

为解决多尺度特征融合过程信息损失问题,在 YOLO v10 原 SPPF 模块^[18]基础上进行改进,引入 SimSPPF 模块^[19]。该模块将原卷积层中使用的 SiLU 激活函数^[20]替换为形式更为简洁高效的 ReLU 函数^[21]。

与 SiLU 函数相比,ReLU 函数通过避免指数运




图 2 改进 YOLO v10 杂草检测模型整体架构

Fig. 2 Overall architecture of improved YOLO v10 weed detection model

算简化了计算流程,同时其线性激活特性有助于维持训练过程梯度的稳定传递,从而提升模型整体计算效率与训练稳定性。SimSPPF 模块结构如图 3 所示,RF:5×5 等表示对应尺寸的特征图经过 ReLU 激活;MaxPool2d 为二维最大池化(k,s,p 分别为对应核、步距、填充);Concat 为通道维度拼接特征;ConvBNReLU 为“卷积+批归一化+激活”组合层(C 为输出通道)。首先通过卷积操作对输入特征图进行通道压缩;随后通过 3 级串联相同 MaxPool2d 池化层,以叠加方式提取具有不同感受野的特征信息;然后将原始输入与 3 级池化输出的 4 组特征图在通道维度进行拼接(Concat);最后再通过 1 次卷积操作完成通道升维与特征融合。




图 3 SimSPPF 模块结构

Fig. 3 Structure of SimSPPF module

2.2.2 可变形卷积 DCNv3

在颈部网络引入可变形卷积 DCNv3 模块,提升模型在复杂自然场景下对不规则杂草几何特征的提取能力。该模块核心机制是动态生成卷积核各采样点的空间偏移量(Offset)与调制系数,使卷积操作能依据输入特征自适应调整采样位置与注意力权重,从而将感受野更精准地聚焦于杂草的关键形态轮廓与判别性局部区域^[22-23]。

DCNv3 结构如图 4 所示,DWConv 为深度可分离卷积,Linear 为线性层,Mask 为掩码(用于特征筛选)、Offset 为偏移量(用于动态卷积的位置调整),DCN op. 为可变形卷积操作,DPCConv 为动态点卷积,Pre-pro 为预处理模块,虚线表示分支连接,圆圈黑点是特征融合操作。图 4a 为标准 DCNv3 单元处理流程,图 4b、4c 分别为 2 种结构等效但实现方式不同的 DCNv3 处理单元。采用图 4b 所示的处理单元。具体而言,对于输入特征图,通过 1 个辅助卷积网络预测每个像素位置对应的卷积核各采样点偏移量($\Delta x, \Delta y$)与调制系数(Δm)。因此,DCNv3 输出特征图在位置 P_0 计算式为

$$y(P_0) = \sum_{k=1}^{K_1} w_k x(P_0 + P_k + \Delta P_k) \Delta m_k \quad (1)$$

式中 K_1 ——卷积核采样点总数
 w_k ——第 k 个采样点权重
 P_k ——第 k 个采样点在标准卷积中的预定义位置




图 4 DCNv3 网络结构

Fig. 4 Structure of DCNv3 network

ΔP_k ——网络学习到的针对位置 P_0 的第 k 个采样点偏移量

Δm_k ——在 $[0, 1]$ 之间的调制标量,用于调整每个采样点特征贡献权重

将 DCNv3 模块嵌入至颈部网络的 C2f 模块,构建 C2f_DCNv3 结构。此结构使模型在多尺度特征融合过程能动态适应杂草目标的形态变化,以提升对不规则边界、交错遮挡等复杂情形的识别能力。

2.2.3 EMA 注意力机制

在颈部网络嵌入的 EMA 注意力机制能聚焦于目标区域,提升模型对小尺寸杂草的识别与定位精度。该模块通过多分支并行结构,协同建模特征图的空间维度与通道维度间的长程依赖关系,提升模型对关键特征的提取与筛选效能^[24]。该注意力机制有 3 个分支。首先,将 1 个输入特征图 $X \in \mathbf{R}^{C \times H \times W}$ 在通道方向上划分为 G 个子特征,即 $X = \{X_0, X_1, \dots, X_{G-1}\}$ 。在分支 1 上将划分的 G 个子特征图与其他分支信息进行融合;分支 2 通过二维平均池化对特征图从高度和宽度 2 个方向进行全局平均池化,计算式为

$$Z_c = \frac{1}{HW} \sum_i^H \sum_j^W X_c(i, j) \tag{2}$$

式中 $H、W$ ——特征图高度和宽度

X_c ——不同通道特征张量

Z_c ——第 c 个通道经过二维全局平均池化后得到的通道全局特征值

分支 3 通过 3×3 卷积捕获跨维度信息并与其余分支交互。该机制融合通道与空间注意力,同步提取全局通道依赖及局部空间特征,实现更全面的特征表达,从而增强对小目标和模糊目标的识别鲁棒性。该模块采用分组并行与跨维度交互策略,融合多尺度空间结构与通道统计特征,增强模型对杂草特征的适应性响应,并抑制复杂背景干扰。

2.3 评价指标

采用平均精度均值 (mean Average Precision, mAP) 作为核心性能评价指标。以交并比 (IoU) 阈值为 0.5 时平均精度均值 (mAP@0.5) 反映模型定位准确性,同时采用 IoU 阈值 0.5 ~ 0.95 的平均结果 (mAP@0.5:0.95) 综合评估模型在不同定位精度要求下分类与定位性能。精确率 (Precision) 与召回率 (Recall)^[13,25] 作为分析指标。此外,检测成功率指标评估模型在光照和遮挡等场景下整图判别能力。对单幅测试图像,若模型能准确检出该图像中所有杂草目标,则判定为正确检测;否则为检测未通过。检测成功率为正确检测图像数占总检测图像数百分比。

3 试验与结果分析

3.1 试验设置

3.1.1 数据集

采用自行构建的杂草数据集,包含 12 类杂草图像。原始数据集共 1 563 幅,经数据增强扩增后总量为 3 126 幅,按比例 8:1:1 划分为训练集、验证集和测试集。通过对照试验验证数据增强策略的有效性;在相同试验环境下,分别基于原始数据集与扩增数据集训练 SDE-YOLO v10 模型,结果如表 2 所示。较原始数据集,扩增数据集模型精确率、召回率、mAP@0.5 和 mAP@0.5:0.95 分别提升 3.0、7.2、3.3、5.0 个百分点,表明数据增强策略有效提升了训练样本的多样性,增强了模型在复杂田间环境下检测性能与泛化能力。基于此,消融试验及对比试验均在扩增数据集完成。

表 2 数据增强策略试验结果

Tab.2 Experimental results of data augmentation

数据集	strategies				%
	精确率	召回率	mAP@0.5	mAP@0.5:0.95	
原始数据集	88.3	73.0	83.4	68.1	
扩增数据集	91.3	80.2	86.7	73.1	

3.1.2 试验环境与参数设置

试验操作系统为 64 位 Windows 11,选取服务器硬件规格为 CPU 为 15 核 Intel (R) Xeon (R) Platinum 8362 CPU @ 2.80 GHz 处理器、NVIDIA RTX 3090 24 GB 独立显卡,内存为 64 GB;模型均基于 Python 3.9 编写,IDE 使用 PyCharm,深度学习框架为 PyTorch,版本 1.12.0 + cu116,torchvision 版本为 0.13.1 + cu116,torchaudio 版本为 0.12.1,CUDA 版本为 CUDA 11.6。模型训练参数设置:图像训练批次大小为 32,迭代次数为 200,输入图像尺寸为 640 像素 $\times$ 640 像素,学习率为 0.01,权重衰减率为 0.000 5。

3.2 消融试验

在扩增数据集设计 8 组消融试验,分别为 YOLO v10 基线模型、S-YOLO v10、D-YOLO v10、E-YOLO v10、SD-YOLO v10、DE-YOLO v10、SE-YOLO v10、SDE-YOLO v10,验证各改进模块引入的有效性,结果如表 3 所示。

由表 3 可知,各改进模块单独引入相较于基线模型均能提升检测性能。其中,D-YOLO v10 精确率提升最为显著,较基线模型提升 4.5 个百分点,达到 90.4%,表明 DCNv3 能有效增强模型对不规则杂草形态的几何适应性;E-YOLO v10 在召回率上提升

表 3 消融试验结果

Tab.3 Ablation experiment results

模型	SimSPPF	DCNv3	EMA	精确率	召回率	mAP@0.5	mAP@0.5:0.95
YOLO v10	-	-	-	85.9	75.5	85.2	70.8
S-YOLO v10	✓	-	-	86.3	77.5	86.1	72.8
D-YOLO v10	-	✓	-	90.4	75.8	85.3	71.8
E-YOLO v10	-	-	✓	87.6	79.0	86.2	71.7
SD-YOLO v10	✓	✓	-	87.8	79.8	85.4	72.4
DE-YOLO v10	-	✓	✓	86.1	76.3	85.6	71.4
SE-YOLO v10	✓	-	✓	86.4	79.4	85.7	72.1
SDE-YOLO v10	✓	✓	✓	91.3	80.2	86.7	73.1

注: - 表示未引入该模块,✓表示引入该模块。

明显,较基线模型提升 3.5 个百分点,达到 79.0%,体现 EMA 注意力机制对目标特征响应的强化作用;较基线模型 S-YOLO v10 精确率和召回率分别提升 0.4、2 个百分点,mAP@0.5:0.95 提升 2 个百分点,表明 SimSPPF 通过多尺度特征融合实现了各指标的均衡提升。

在模块组合方面,SD-YOLO v10 展现了 SimSPPF 与 DCNv3 协同效果,较基线模型精确率和召回率分别提升 1.9、4.3 个百分点,mAP@0.5:0.95 提升 1.6 个百分点。DE-YOLO v10 各指标与基线、基本持平,原因在于 DCNv3 改变特征空间分布后与 EMA 基于原始空间计算的注意力权重不匹配,削弱了改进效果;SE-YOLO v10 召回率较基线模型提升 3.9 个百分点,达到 79.4%,但精确率与 mAP@0.5 提升幅度较小,原因在于 SimSPPF 强化的全局上下文与 EMA 聚焦的局部显著性之间平衡失调,导致注意力权重分散。

SDE-YOLO v10 在所有指标上均取得最优结果,精确率、召回率、mAP@0.5 和 mAP@0.5:0.95 分别达到 91.3%、80.2%、86.7% 和 73.1%,较基线模型分别提升 5.4、4.7、1.5、2.3 个百分点,表明三者通过多尺度特征丰富、几何自适应建模和关键特征强化的有效协同规避了双模块组合的特征冲突问题。

3.3 模型性能试验

3.3.1 不同检测模型性能

将 SDE-YOLO v10 与 YOLO v8、YOLO v10、YOLO 11 进行对比,结果如表 4 所示。SDE-YOLO v10 在各项指标上均优于对比模型,精确率分别高 5.2、5.4、3 个百分点,召回率分别提升 2.3、4.7、0.4 个百分点,mAP@0.5 分别提高 1.4、1.5、0.5 个百分点,mAP@0.5:0.95 分别提高 0.9、2.3、0.7 个百分点,验证了在复杂场景下检测优势。

3.3.2 不同光照条件下模型性能

采用图像级检测成功率,从整图通过率角度分

表 4 不同模型性能

Tab.4 Performance for different models

模型	精确率	召回率	mAP@0.5	mAP@0.5:0.95
YOLO v8	86.1	77.9	85.3	72.2
YOLO v10	85.9	75.5	85.2	70.8
YOLO 11	88.3	79.8	86.2	72.4
SDE-YOLO v10	91.3	80.2	86.7	73.1

析光照和遮挡条件下模型识别性能,作为对象级指标的有效补充。从测试集随机选取 162 幅杂草图像(无阴影与有阴影各 81 幅),利用 YOLO v10 和 SDE-YOLO v10 模型进行识别,结果如表 5 所示。在无阴影条件下,YOLO v10 和 SDE-YOLO v10 检测成功率分别为 82.72% 和 95.06%;在有阴影条件下,分别为 72.84% 和 86.42%。

表 5 不同光照条件下模型性能

Tab.5 Model performance under different lighting conditions

场景	模型	检测数量/幅	正确检测数量/幅	检测未通过数量/幅	检测成功率/%
无阴影	YOLO v10	81	67	14	82.72
	SDE-YOLO v10		77	4	95.06
有阴影	YOLO v10	81	59	22	72.84
	SDE-YOLO v10		70	11	86.42

由表 5 可知,在无阴影条件下,改进模型检测成功率较原模型提升 12.34 个百分点,在有阴影条件下提升 13.58 个百分点,表明 SDE-YOLO v10 对光照变化具有更强的适应性,在复杂光照场景下具备更优的检测稳定性。

3.3.3 不同遮挡条件下模型性能

从测试集随机选取 162 幅不同遮挡条件杂草图像(无遮挡与有遮挡各 81 幅),利用 YOLO v10 和 SDE-YOLO v10 模型进行识别,结果如表 6 所示。在无遮挡条件下,YOLO v10 和 SDE-YOLO v10 模型检测成功率分别为 77.78% 和 90.12%;在有遮挡条件下,分别为 70.37% 和 82.72%。

表 6 不同遮挡条件下模型性能

Tab. 6 Model performance under different occlusion conditions		conditions			
场景	模型	检测数量/幅	正确检测数量/幅	检测未通过数量/幅	检测成功率/%
无遮挡	YOLO v10	81	63	18	77. 78
	SDE - YOLO v10		73	8	90. 12
有遮挡	YOLO v10	81	57	24	70. 37
	SDE - YOLO v10		67	14	82. 72

由表 6 可知,在无遮挡条件下,改进模型检测成功率较原模型提升 12. 34 个百分点;在有遮挡条件下,提升 12. 35 个百分点。SDE - YOLO v10 在不同遮挡条件下表现均优于 YOLO v10,表明改进模型有效增强了对遮挡目标的感知能力,在复杂真实场景中具有更强鲁棒性。

3. 4 定性检测结果

除定量评价指标外,从定性角度分析 SDE - YOLO v10 与 YOLO v10 模型在复杂自然场景下检测效果。如图 5 所示,SDE - YOLO v10 模型在训练和验证过程表现出良好的收敛特性,召回率随迭代

次数稳步提升且未出现明显过拟合,为后续定性分析奠定了基础。




图 5 模型训练和验证迭代曲线

Fig. 5 Training and validation iteration curves of model

基于已训练完成的 SDE - YOLO v10 与 YOLO v10 模型,对自然环境下杂草进行检测验证。图 6 为杂草误检情况,原模型存在杂草类别误判,改进模型则有效避免了此类错误。图 7 为杂草漏检情况,在弱光照场景和复杂背景下,YOLO v10 存在明显漏检,而 SDE - YOLO v10 能准确检出全部目标。结果表明,在复杂场景下 SDE - YOLO v10 漏检和误检均显著少于原模型。




图 6 杂草误检

Fig. 6 Weed false detection




图 7 杂草漏检

Fig. 7 Weed missed detection

4 讨论

针对复杂田间杂草检测难题,对 YOLO v10 模型进行多模块改进优化。消融试验结果表明,SimSPPF 模块可有效增强模型多尺度杂草特征提取能力,DCNv3 模块能自适应拟合杂草不规则形态特征,EMA 注意力机制可有效抑制田间背景与光照干扰。三者协同优化,使 SDE - YOLO v10 模型综合检测性能显著提升。对比试验结果表明,本文模型精确率、召回率、平均精度均值等核心指标均优于 YOLO v8、YOLO v10、YOLO 11 等主流算法,在光照变化、遮挡等复杂田间场景下具备更优的检测稳定性,验证了本文改进方案的有效性与其可行性。

本文模型仍存在一定局限与优化空间,具体体现在数据集、田间复杂环境、设备部署条件 3 方面:①数据集泛化能力受限。数据集采集区域、杂草品类及生长场景相对有限,样本多样性不足,模型训练场景覆盖面较窄。若将模型迁移应用至不同地域、不同作物种植模式及不同田间环境的除草场景中,受地域环境、杂草品类、田间地貌差异影响,模型检测精度会出现一定程度下降,整体泛化性与通用适应性有待进一步提升。②复杂田间环境抗干扰能力有限。实际田间环境极具复杂性与不确定性,田间杂草密集丛生、枝叶交错重叠、杂草与作物粘连遮挡等问题频发,极易造成目标特征残缺、边界模糊^[13]。同时,阴雨强光、沙尘雾霾、昼夜温差等多变天气条件,会进一步弱化杂草有效特征,大幅增加检测难度,导致模型出现漏检、误检等问题,难以完全适配

极端复杂的田间作业场景。③田间设备动态检测稳定性不足。田间智能除草装备多为轻量化移动嵌入式设备,在实际作业过程,设备行进震动、拍摄角度偏移、运动画面模糊、田间光照剧烈变化等动态干扰,均会降低现场图像采集质量,进而影响模型实时检测精度与稳定性,在一定程度上制约了算法的工程化落地与实际应用效果。针对上述问题,后续将致力于扩充样本、优化抗干扰机制及轻量化部署,以支撑智能除草装备的工程化应用。

5 结论

(1)提出了基于改进 YOLO v10 的杂草精准检测模型 SDE - YOLO v10。改进模型精确率、召回率、mAP @ 0.5 和 mAP @ 0.5: 0.95 分别达到 91.3%、80.2%、86.7% 和 73.1%,相较于 YOLO v10 模型,提升 5.4、4.7、1.5、2.3 个百分点。结果表明,融合 SimSPPF 的多尺度特征融合能力、DCNv3 的动态卷积特征提取优势与 EMA 的注意力优化机制,可有效增强模型对杂草目标特征的捕捉能力,提升检测性能,验证了该改进策略的合理性与有效性。

(2)通过不同光照强度与不同遮挡条件下数据集试验,验证了 SDE - YOLO v10 模型在自然环境中的有效性。在无阴影和有阴影条件下,SDE - YOLO v10 模型检测成功率分别为 95.06%、86.42%;在无遮挡和有遮挡条件下,SDE - YOLO v10 模型检测成功率分别为 90.12%、82.72%。相较于 YOLO v10,改进模型在各场景下均具有更高的检测成功率,表现出更优性能。

参 考 文 献

[1] Guo Z, Cai D, Bai J, et al. Intelligent rice field weed control in precision agriculture: from weed recognition to variable rate spraying[J]. Agronomy, 2024, 14(8): 1702.

[2] Tao W, Su W, Zeng Y, et al. Simulating bidirectional reflectance in croplands with various crop residue cover by a geometric optical-radiative transfer model[J]. IEEE Transactions on Geoscience and Remote Sensing, 2025, 63: 4415018.

[3] Zeb F M, Iqbal A, Husnain G, et al. Automated weed monitoring and control: enhancing detection accuracy using a YOLOv7 - AlexNet fusion network[J]. Frontiers in Plant Science, 2025, 16: 1664650.

[4] Ali M L, Zhang Z. The YOLO framework: a comprehensive review of evolution, applications, and benchmarks in object detection[J]. Computers, 2024, 13(12): 336.

[5] Hussain M. YOLO - v1 to YOLO - v8, the rise of YOLO and its complementary nature toward digital manufacturing and industrial defect detection[J]. Machines, 2023, 11(7): 677.

[6] Sharma A, Kumar V, Longchamps L. Comparative performance of YOLOv8, YOLOv9, YOLO v10, YOLOv11 and Faster R - CNN models for detection of multiple weed species[J]. Smart Agricultural Technology, 2024, 9: 100648.

[7] 刘芳, 刘玉坤, 林森, 等. 基于改进型 YOLO 的复杂环境下番茄果实快速识别方法[J]. 农业机械学报, 2020, 51(6): 229 - 237.

Liu Fang, Liu Yukun, Lin Sen, et al. Fast recognition method for tomatoes under complex environments based on improved YOLO[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(6): 229 - 237. (in Chinese)

[8] 王卓, 王健, 王泉雄, 等. 基于改进 YOLO v4 的自然环境苹果轻量级检测方法[J]. 农业机械学报, 2022, 53(8): 294 - 302.

Wang Zhuo, Wang Jian, Wang Xiaoxiong, et al. Lightweight real-time apple detection method based on improved YOLO v4 [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(8): 294 - 302. (in Chinese)

- [9] 杨锋,姚晓通. 基于改进 YOLOv8 的小麦叶片病虫害检测轻量化模型[J]. 智慧农业(中英文),2024,6(1):147–157.
Yang Feng, Yao Xiaotong. Lightweighted wheat leaf diseases and pests detection model based on improved YOLOv8[J]. Smart Agriculture, 2024, 6(1): 147–157. (in Chinese)
- [10] 祝诗平,林曦,冯川,等. 基于改进 DeepLabv3+ 的马铃薯幼苗与杂草识别方法[J]. 农业工程学报,2025,41(10):147–156.
Zhu Shiping, Lin Xi, Feng Chuan, et al. Potato seedling and weed identification based on improved DeepLabv3+ [J]. Transactions of the CSAE, 2025, 41(10): 147–156. (in Chinese)
- [11] Chandra N, Vaidya H, Satyam N, et al. A novel multi-layer attention boosted YOLOv10 network for landslide mapping using remote sensing data[J]. Transactions in GIS,2025,29(2): e70023.
- [12] 田壮壮,张恒伟,王坤,等. 改进 CenterNet 在遥感图像目标检测中的应用[J]. 遥感学报,2023,27(12):2706–2715.
Tian Zhuangzhuang, Zhang Hengwei, Wang Kun, et al. Application of an improved CenterNet in remote sensing images object detection[J]. National Remote Sensing Bulletin, 2023, 27(12): 2706–2715. (in Chinese)
- [13] Ren D, Yang W, Lu Z, et al. Improved weed detection in cotton fields using enhanced YOLOv8s with modified feature extraction modules[J]. Symmetry, 2024, 16(4): 450.
- [14] 李梅,郑浩宇,毛锐,等. 基于改进 MobileNet-V2 的轻量化苹果叶片病害识别[J]. 农业机械学报,2026,57(8):246–255.
Li Mei, Zheng Haoyu, Mao Rui, et al. Lightweight apple leaf disease recognition based on improved MobileNet-V2 [J]. Transactions of the Chinese Society for Agricultural Machinery,2026,57(8):246–255. (in Chinese)
- [15] Zhou Y, Fu C, Zhai Y, et al. Identification of rice leaf disease using improved ShuffleNet V2[J]. Computers, Materials & Continua, 2023, 75(2):4501–4517.
- [16] Du Z, Xu X, Bai Z, et al. Feature fusion strategy and improved GhostNet for accurate recognition of fish feeding behavior[J]. Computers and Electronics in Agriculture, 2023, 214: 108310.
- [17] Sun J, Xu T, Yao Y. An enhanced GhostNet model for emotion recognition: leveraging efficient feature extraction and attention mechanisms[J]. Frontiers in Psychology, 2025, 15: 1459446.
- [18] Liu Y, Zhang J, Shi L, et al. Detection method of the seat belt for workers at height based on UAV image and YOLO algorithm [J]. Array, 2024, 22: 100340.
- [19] Ren F, Fei J, Li H, et al. Steel surface defect detection using improved deep learning algorithm: ECA-SimSPPF-SIoU-Yolov5[J]. IEEE Access, 2024, 12: 32545–32553.
- [20] 李伟豪,詹炜,周婉,等. 轻量型 Yolov7-TSA 网络在茶叶病害检测识别中的研究与应用[J]. 河南农业科学,2023, 52(5):162–169.
Li Weihao, Zhan Wei, Zhou Wan, et al. Research and application of lightweight Yolov7-TSA network in tea disease detection and identification[J]. Journal of Henan Agricultural Sciences, 2023, 52(5): 162–169. (in Chinese)
- [21] 张顺,龚怡宏,王进军. 深度卷积神经网络的发展及其在计算机视觉领域的应用[J]. 计算机学报, 2019, 42(3): 453–482.
Zhang Shun, Gong Yihong, Wang Jinjun. The development of deep convolution neural network and its applications on computer vision[J]. Chinese Journal of Computers,2019, 42(3): 453–482. (in Chinese)
- [22] Li Z, Zhu Y, Sui S, et al. Real-time detection and counting of wheat ears based on improved YOLOv7[J]. Computers and Electronics in Agriculture, 2024, 218: 108670.
- [23] Du X, Xi M, Ding X, et al. Motor imagery EEG signal classification based on deformable convolution v3 and adaptive spatial attention mechanism[J]. Biomedical Signal Processing and Control, 2025, 99: 106905.
- [24] Xu D, Xiong H, Liao Y, et al. EMA-YOLO: a novel target-detection algorithm for immature yellow peach based on YOLOv8 [J]. Sensors, 2024, 24(12): 3783.
- [25] 王汉羊,娄淞,邸佳豪,等. 基于嵌入式 YOLO 的玉米苗与杂草检测轻量化模型 BACD-YOLO 研究[J]. 农业机械学报,2026,57(13):149–159.
Wang Hanyang, Lou Song, Di Jiahao, et al. Research on lightweight BACD-YOLO model for corn seedling and weed detection based on embedded YOLO[J]. Transactions of the Chinese Society for Agricultural Machinery,2026,57(13):149–159. (in Chinese)