



王宁,尚忠,陈康,吕昊曦,贾麟,姚渝. 基于改进YOLOv5s的玉米田间杂草检测方法[J]. 中国农业大学学报, 2026,31(02):192-204.

WANG Ning, SHANG Zhong, CHEN Kang, LYU Haotun, JIA Lin, YAO Yu. Corn field weed detection method based on improved YOLOv5s[J]. *Journal of China Agricultural University*, 2026,31(02):192-204.

DOI: 10.11841/j.issn.1007-4333.2026.02.17

基于改进YOLOv5s的玉米田间杂草检测方法

王宁¹ 尚忠¹ 陈康¹ 吕昊曦^{1*} 贾麟² 姚渝²

(1. 中国农业大学 工学院, 北京 100083;

2. 烟台市农业技术推广中心, 山东 烟台 264001)

摘要 针对玉米田间环境下幼苗与杂草检测实时性不足、识别模型结构复杂、识别精度欠佳及移动端部署困难等问题,提出一种基于改进YOLOv5s的玉米田间杂草检测方法。通过嵌入轻量化的GhostNetV3模块减少模型的计算量和参数量,提升运行速率以适配移动端部署要求;在主干特征提取网络中引入CA(Coordinate attention)注意力机制,通过空间维度特征强化提升有效特征表达能力,在强化特征提取能力的同时,抑制无关信息干扰,进而提升模型的检测精度;引入高效交并比损失函数EIoU(Efficient intersection over union)替代模型传统的GIoU(Generalized intersection over union),通过改进边界框回归策略提升目标定位精度、收敛效率和回归精度;采用数据增强技术拓展训练样本的多样性,有效解决样本数据不足和复杂背景干扰问题,进一步提升模型的鲁棒性。试验结果表明,该方法在玉米田杂草检测任务中性能显著提升,相比基准模型,精确率、召回率和平均精度分别提高3.7%、7.7%和3.4%,达到95.9%、85.8%、88.6%,浮点运算量、参数量和模型大小分别减少了54.3%、53.9%、50%,在保证检测精度的前提下实现了模型的轻量化与高效性。

关键词 杂草检测;轻量化;注意力机制;损失函数;图像识别

中图分类号 TP391.4

文章编号 1007-4333(2026)02-0192-13

文献标志码 A

Corn field weed detection method based on improved YOLOv5s

WANG Ning¹, SHANG Zhong¹, CHEN Kang¹, LYU Haotun^{1*}, JIA Lin², YAO Yu²

(1. College of Engineering, China Agricultural University, Beijing 100083, China;

2. Yantai Agricultural Technology Extension Center, Yantai 264001, China)

Abstract To address the challenges of insufficient real-time performance, complex model structures, low detection accuracy, and difficulties in mobile deployment for seedling and weed detection in maize fields, this study proposes an improved YOLOv5s-based weed detection method. A lightweight GhostNetV3 module was embedded to reduce computational cost and parameter size to accelerate inference speed and meet mobile deployment requirements. A coordinate attention (CA) mechanism was introduced into the backbone feature extraction network to enhance the representation of effective features by strengthening spatial information while suppressing irrelevant interference, thus improving detection accuracy. Furthermore, the efficient intersection over union (EIoU) loss was adopted to replace the traditional generalized intersection over union (GIoU) loss, improving bounding box regression precision, convergence efficiency, and localization accuracy. Data augmentation techniques were also applied to increase the diversity of training samples, effectively alleviating

收稿日期: 2025-07-03;接受日期: 2025-10-10

基金项目: 保护性耕作与沃土耕层构建新装备研制与应用(2024YFD1500405);京郊农业生产规模化作业配套智能化管控关键技术研究(2025年度)(NY2502290125)

第一作者: 王宁(ORCID:0009-0003-3586-6170),硕士研究生,E-mail:wangning1639@163.com

通讯作者: 吕昊曦(ORCID:0000-0003-4307-1004),副教授,主要从事智能农业装备与技术研究,E-mail:lvhaotun@cau.edu.cn

the problems of insufficient data and complex background interference, and enhancing model robustness. Experimental results demonstrate that the proposed method significantly improves the performance in maize field weed detection. Compared with the baseline YOLOv5s model, the precision, recall, and mean average precision of the proposed method increased by 3.7%, 7.7%, and 3.4%, and reached 95.9%, 85.8%, and 88.6%, respectively. Its floating-point operations, parameter size, and model size were reduced by 54.3%, 53.9%, and 50%. These results indicate that the proposed method achieves both lightweight and high efficiency while maintaining detection accuracy.

Keywords weed detection; lightweight; attention mechanism; loss function; image recognition

玉米田间杂草通过与幼苗期植株争夺光照资源、土壤养分及水分,严重影响玉米正常生长发育,进而导致籽粒产量降低和品质下降^[1]。杂草危害可使玉米产量降低10%~30%,在极端情况下减产幅度可能进一步加大^[2-3]。因此,杂草防控始终是玉米种植过程中的关键问题^[4-7]。

传统除草方式主要包括人工、化学和机械除草^[8-9],但均存在一定局限性。人工除草不仅耗费大量人力,而且劳动强度大、效率低下^[10-12];化学除草依赖除草剂喷洒,容易造成环境污染和土壤退化^[13-15];机械除草作业适应性差、操作难度大、设备购置和维护成本较高^[16-19]。在此背景下,激光除草技术凭借其非接触、高精度的特点,逐渐成为一种具有较大应用潜力的替代方案^[20-21]。在激光除草作业中,对玉米幼苗与杂草的精准识别及快速检测是实现高效除草的核心环节。这一过程不仅需要通过视觉感知系统准确区分作物与杂草的形态特征,还需结合实时计算能力实现目标的快速定位,从而为激光除草装置提供可靠的执行依据。其有效性直接决定了除草效率和作物保护水平,精准识别可避免激光误判造成的幼苗损伤,而快速检测能够满足农田场景下的实时作业需求。

在作物定位与杂草识别研究中,传统机器学习方法多依赖颜色、几何形态和纹理等低层特征进行建模与检测。基于颜色空间分割的算法能够在一定程度上区分作物与杂草,并结合质心提取实现激光靶向等应用。此外,通过引入分类模型实现对特定作物与多类杂草的识别与分类^[22-24]。然而,由于田间环境存在光照不均、土壤背景复杂及植株间相互遮挡等因素,这类方法对外部条件较为敏感,鲁棒性和泛化能力有限,在复杂场景下往往难以获得稳定的识别效果。

随着深度学习的兴起,卷积神经网络在图像特征提取和语义表达方面展现出显著优势,为杂草检

测提供了新的思路。基于Faster R-CNN的多尺度特征建模方法能够在不同尺度目标识别中取得较高的准确性;结合空洞卷积与全局池化的改进网络在提升模型感受野与表达能力方面具有良好效果;而通过特征金字塔网络进行跨层特征融合,能够显著增强特征表达,在棉花田间杂草识别中准确率可达到95.5%^[25-27]。在检测速度优化方面,改进的SSD模型通过多尺度特征融合与结构优化,不仅将甜菜杂草识别精度提升至88.84%,还将单张图像检测耗时缩短至261 ms。此外,面向玉米杂草识别的改进YOLO模型在性能测试中精确率与召回率的调和平均数(F1值)为0.828,在检测精度与实时性之间取得较好平衡^[28-29]。研究表明,深度学习方法在复杂田间环境下具有较高的鲁棒性和适应性,能够在不同作物和任务场景中取得理想的识别效果,尽管已有研究在玉米田间幼苗与杂草检测方面取得了一定进展,但在复杂环境下仍面临诸多挑战。一方面,玉米幼苗与杂草在颜色与形态等特征上高度相似,给准确识别带来困难另一方面,田间环境的多样性,如光照变化、植株遮挡和土壤背景干扰等,也显著增加了检测的复杂性。现有方法普遍存在实时性不足、模型结构复杂和检测精度不足等问题,难以满足农业生产对杂草快速、准确识别与定位的实际需求。

为此,本研究拟在YOLOv5s架构的基础上构建增强型目标检测框架:在特征提取阶段引入深度可分离卷积以降低计算量;在特征融合层集成坐标注意力模块以增强空间特征表征;在边界框回归中采用基于EIoU的改进损失函数以提升定位精度。同时,结合Mosaic数据增强与自适应光照补偿构建训练样本集,提升模型在复杂农田环境下的鲁棒性与泛化能力,为玉米田间杂草精准检测及激光除草装备的研发应用提供智能检测系统与多维度技术支撑。

1 材料与方法

1.1 数据集采集

数据集采集时间为2024年5月15日和9月20日,采集地点位于北京市怀柔区玉米种植试验田。为降低光照变化对图像采集质量的影响、兼顾不同光照强度场景的覆盖性,进一步选择08:00—10:00、13:00—15:00、17:00—19:00这3个具有不同光照特征的时间段开展玉米苗田图像样本的采集工作。原因如下:08:00—10:00时段光照柔和且光线角度稳定,可减少强光反光与阴影过度问题;13:00—15:00时段光照强度高,可模拟强光环境以测试模型对高光场景的适应性;17:00—19:00时段光照逐渐减弱,可覆盖弱光向暮光过渡的场景需求。通过覆盖“柔和光—强光—弱光”过渡的多样光照场景,使数据集更全面地反映自然环境中光照变化对玉米、杂草等目标成像的影响,进而提升后续模型在复杂光照条件下的识别鲁棒性。

数据集图像采集使用Xiaomi 13,处理器为骁龙8Gen2,感光元件为索尼IMX800 1/1.49英寸5400万像素传感器,F/1.8光圈,拍摄照片大小约为3.5~7.5 MB,分辨率为4096像素×3072像素。采用垂直对地拍摄姿势,通过镜头与地面保持垂直,最大限度减少太阳光直射产生的镜面反射干扰,确保目标作物与杂草的色彩、纹理特征真实呈现。拍摄高度控制在40~60 cm,此高度贴近田间实际观测视角,既避免过高导致目标在画面中占比过小、细节模糊,也防止过低易被作物枝叶遮挡,影响画面完整性。同时,统一设置所有拍摄参数:启用原相机模式,关闭闪光灯,放大倍数固定为1倍,对焦模式设为自动,且在单一样本采集批次内保持参数稳定,避免因参数波动导致不同图像的色彩、亮度出现明显差异,影响数据集一致性。

原始图像采集完成后,为保障数据集的随机性与样本质量,采用随机抽样方法从不同日期、不同光照时间段的采集数据中筛选样本,筛选过程中同步剔除模糊、遮挡、曝光过度或不足等质量不合格的图像,最终确定1000张有效样本图像,构建本试验所用的数据集。

本试验的硬件环境配置如下:处理器采用第13代Intel® Core™ i9-13900HX(主频2200 MHz),显卡为Nvidia GeForce RTX 4060,内存容量32 GB。

软件环境方面:操作系统为Windows 11,开发平台为PyCharm,Python版本为3.11.7,深度学习框架为PyTorch 1.7.1,CUDA版本为10.1,CUDNN版本为8.7。

1.2 图像预处理

采用矩形区域标注工具Labelimg软件对杂草图像数据集进行人工标注,标注结果默认保存为YOLO格式文件,每张图像的标签信息以 (n, x, y, w, h) 形式存储于txt文件中。其中: n 为对应类别编号; x 和 y 分别表示标注框中心点横、纵坐标; w 和 h 分别表示标注框的相对宽度和高度。一共手动标注杂草图像3600张,标注完成后对生成的标签文件进行归一化处理,以提高模型在训练阶段的数据读取效率。

为满足深度学习对训练数据规模的需求并提升样本多样性,本研究对数据集进行了划分与增强。首先将3600张原始图像按6:2:2比例划分为训练集(2160张)、验证集(720张)和测试集(720张)。随后仅对训练集样本进行数据增强处理,包括高斯模糊、随机旋转、色彩抖动、随机加噪等操作(图1)。此外采用多图融合技术将四幅训练集原始图像随机组合生成新样本,有效增加小目标特征的学习样本数量,提升模型的鲁棒性。经过数据增强后,训练集图像总量扩展至6048张,而验证集与测试集保持原始规模未做增强处理。最后,通过原始图像编号溯源验证,确保测试集与训练集样本无重复来源。

1.3 YOLOv5模型概述

YOLOv5是一种基于卷积神经网络(Convolutional neural network, CNN)的端到端目标检测模型,可通过统一的神经网络架构同步完成目标分类与定位任务。该模型采用单阶段检测(One-stage detection)架构,在保证检测精度的前提下,大幅降低计算复杂度与推理开销,因此具备较强的实时性优势,适用于农业场景如玉米田间杂草识别等对检测速度有要求的任务。

从检测流程看,输入图像首先经YOLOv5的骨干网络进行特征提取,生成包含目标候选区域的预测框;随后模型对候选框的类别概率与位置信息开展联合判断;最终,通过非极大值抑制(Non-maximum suppression, NMS)算法过滤冗余预测框,输出最优检测结果。




图1 玉米田杂草图像的不同数据增强方法

Fig. 1 Different data augmentation methods for cornfield weed images

YOLOv5作为YOLO系列的典型迭代版本,在识别精度与推理速度间实现了较好平衡。依据控制网络层数的深度与控制通道数的宽度2类参数配置,该模型分为n、s、m、l、x这5个版本,各版本在参数量、计算开销与检测性能上存在差异。本研究针对玉米田间杂草检测任务,综合实时检测需求与后续移动端部署的轻量化要求,最终选用网络参数精简且检测性能均衡的YOLOv5s架构作为基础检测框架。

2 结果与分析

2.1 YOLOv5s模型改进

在复杂的玉米田间环境中,由于杂草与玉米植株在形态上高度相似,杂草分布密集且常伴随植株遮挡,传统YOLOv5s模型在检测精度方面难以满足实际应用需求。针对上述问题,本研究在YOLOv5s架构的基础上进行了多项优化与改进,以提升模型在复杂农田场景下的检测性能。

首先,在网络轻量化方面,引入GhostNetV3模块对主干特征提取网络进行重构。该模块能够在显著减少模型参数量与计算复杂度的同时,有效保留关键特征信息,使得改进后的模型具备更高的运行效率,并能够在嵌入式或资源受限设备上实现实时推理。其次,在特征表达方面,融入坐标注意力机制。该机制通过在通道与空间维度上的自适应

加权,有效突出杂草的显著特征,抑制背景噪声干扰,从而增强模型对杂草与玉米植株细微差异的敏感性,提升杂草特征表征能力,进而提高检测准确率。最后,在目标检测的边界框回归策略中,采用改进的EIoU损失函数替代传统方法。EIoU损失函数在保持交并比对重叠区域敏感性的基础上,引入归一化中心点距离以量化位置偏移,并将目标框的宽度与高度进行解耦优化,避免了梯度方向冲突问题。该策略能够有效引导模型在训练过程中生成更为精确的边界框预测,从而显著降低定位误差,提升模型在复杂场景下的检测精度。

改进后的YOLOv5s网络整体结构见图2。

2.1.1 GhostNetV3轻量化模块

针对YOLOv5网络在计算与存储方面存在的问题,通过引入GhostNetV3模块来进行优化。GhostNetV3是一种高性能的轻量化卷积神经网络模块,其设计目标是在显著降低计算复杂度的同时保持优异的模型性能。该模块遵循Ghost结构的设计原则,将传统卷积操作分解为2个阶段:标准卷积(Conv)和轻量级Ghost卷积(GhostConv)。通过对特征提取与特征映射过程的解耦,此设计在保障特征表达能力的前提下,大幅减少了运算量,为移动端视觉任务提供了高效的模型解决方案。其中,Ghost卷积通过生成计算成本较低的“ghost”特征图,替代部分高计算开销的操作,从而显著降低对

显著降低计算开销。经过深度卷积处理后,特征图维度被初步压缩,为后续轻量化操作奠定基础。

在深度可分离卷积降维的基础上,GhostNetv3通过Ghost卷积生成低成本特征图,进一步扩展特征表达维度。生成的Ghost特征图 Y_{ghost} 为:

$$Y_{ghost} = G(X) \times W_{ghost} + b_{ghost} \quad (2)$$

式中: $G(X)$ 为通过简单操作得到的基础特征图; W_{ghost} 为Ghost卷积核; b_{ghost} 为偏置项。Ghost卷积是通过廉价操作生成基础特征和少量卷积核映射扩展的方式,替代传统卷积中大量卷积核直接生成所有特征图的高开销过程。这种机制通过生成廉价Ghost特征图替代部分高计算量的卷积操作,在保持特征表达能力的前提下,大幅减少了参数数量与计算复杂度,提升了模型的轻量化水平与运行效率。

在Ghost卷积阶段,GhostNetv3进一步采用多通道卷积策略,降低特征计算的冗余性并增强信息聚合能力。多通道卷积通过设计跨通道共享且带权重的卷积核,让不同Ghost特征图在卷积过程中实现信息交互:一方面避免了单一通道卷积的信息孤立问题,使特征图能更充分地聚合空间与通道维度的语义信息;另一方面,通过共享卷积核的设计,减少了卷积核的总数量,进一步压缩了计算成本,最终实现轻量化与特征表达能力的平衡。


2.1.2 CA注意力机制

坐标注意力机制是一种轻量级神经网络组件,在保证较低计算开销的前提下能够显著增强特征表征能力。该机制采用双维度编码策略对空间位置信息进行建模,通过坐标分解方法沿水平与垂直方向对特征进行聚合,生成具有方向感知能力的空间注意力掩码,从而在保持低复杂度的同时捕获长程依赖信息。同时,CA模块还能建立跨通道的特征关联映射,动态建模通道间的相互作用关系,实现通道信息与空间信息的联合优化,使得模型既能突出显著目标区域又能抑制背景噪声,进一步提升特征表达的判别性。

与传统的注意力方法相比,CA机制在设计上引入了空间维度解耦策略,不再依赖单一的全局池化,而是通过方向感知的编码方式实现更加精细的空间表征,该机制不仅能够动态调整通道间的权重分布,还能精确捕捉目标在二维空间中的位置信息敏感性,从而在特征交互效率与精度表现之间取得

良好平衡。其轻量化特性也使其成为提升网络性能而不显著增加计算量的有效方案。

将CA模块集成至YOLOv5s的主干特征提取层,有效增强了模型对植物细微结构特征的捕捉能力,使模型能够更充分地提取特征图中的位置信息。通过这一改进,模型在目标的定位与识别精度方面均得到了提升,尤其在玉米幼苗与杂草形态高度相似的复杂场景下,表现出更强的特征辨别能力与鲁棒性。CA模块的实现主要包含坐标编码和注意力生成2个阶段,其基本架构见图4。



C 为通道维度; H 为空间高度; W 为空间宽度。Residual为残差连接;X Avg Pool为沿X方向的平均池化;Y Avg Pool为沿Y方向的平均池化;Conv2d为二维卷积;BatchNorm为批量归一化;Non-linear为非线性激活;Re-weight为重加权。

C is the channel dimension; H is the spatial height; W is the spatial width. Residual is the residual connection; X Avg Pool is average pooling along the X-direction; Y Avg Pool is average pooling along the Y-direction; Conv2d is two-dimensional convolution; BatchNorm is batch normalization; Non-linear is the non-linear activation function; Re-weight is reweighting.

图4 CA模块网络结构

Fig. 4 Network Structure of CA Module

CA机制通过空间维度解耦策略,将传统全局池化操作重构为空间坐标的特征编码流程。其核心在于建立空间坐标与通道特征间的关联性,具体实现分为2个正交方向的特征聚合阶段。设输入特征量 $X \in \mathbb{R}^{C \times H \times W}$,该机制通过沿水平轴 x 和垂直轴 y 分别执行自适应池化,构建具有方向感知的特征描述符。水平方向池化对特征图第 w 列进行通道维压缩,生成宽度感知向量,垂直方向池化则对第 h 行执行相似操作,输出高度敏感向量,此双路编码

过程可表示为:

$$z_h^c = \frac{1}{W} \sum_{i=1}^W X_c(h, i) \quad (3)$$

$$z_w^c = \frac{1}{H} \sum_{j=1}^H X_c(j, w) \quad (4)$$

式中: z_h^c 为第 c 个通道在第 h 行的水平池化结果; z_w^c 为第 c 个通道在第 w 列的垂直池化结果; $X_c(h, i)$ 表示第 c 个通道、第 h 行、第 i 列的特征值; $X_c(j, w)$ 表示第 c 个通道、第 j 行、第 w 列的特征值。 $c = 1, 2, \dots, C$; $h = 1, 2, \dots, H$; $w = 1, 2, \dots, W$ 。随后, 将这 2 个一维特征向量拼接起来, 并通过一个卷积层进行降维, 得到特征向量 $f \in \mathbb{R}^{C/r \times (H+W)}$, 其中 r 为降维因子。将特征向量 f 沿着水平和垂直方向拆分为 2 个特征向量 $f_h \in \mathbb{R}^{C/r \times H}$ 和 $f_w \in \mathbb{R}^{C/r \times W}$, 分别通过 2 个卷积层进行升维, 得到 $g_h \in \mathbb{R}^{C \times H}$ 和 $g_w \in \mathbb{R}^{C \times W}$, 然后对 g_h 和 g_w 应用 sigmoid 函数得到注意力权重图 $a_h \in \mathbb{R}^{C \times H}$ 和 $a_w \in \mathbb{R}^{C \times W}$:

$$a_h^c = \sigma(g_h^c) \quad (5)$$

$$a_w^c = \sigma(g_w^c) \quad (6)$$

最后, 将 a_h 和 a_w 分别与输入特征图 X 进行逐元素相乘, 得到输出特征图 $Y \in \mathbb{R}^{C \times H \times W}$:

$$Y_c(h, w) = X_c(h, w) \times a_h^c \times a_w^c \quad (7)$$

该设计突破传统通道注意力仅建模通道间关系的局限, 通过建立空间位置与通道响应的动态映射, 有效提升网络对目标几何变换的鲁棒性。

2.1.3 损失函数优化

YOLOv5 凭借其在实时处理性能与检测精度之间的良好平衡, 广泛应用于各类目标检测任务。然而, 其原始的边界框回归损失函数 GIoU 在 IoU 的基础上引入了最小外接矩形的概念, 通过几何约束改善了非重叠目标场景下的梯度反向传播问题。

尽管 GIoU 损失函数可改善非重叠场景的梯度问题, 但在玉米田杂草检测这类复杂任务中仍存在局限: 其核心聚焦于目标框的重叠区域与最小外接矩形, 对目标框的尺度差异如不同生长阶段的玉米幼苗与杂草、长宽比信息如细长茎秆类杂草与宽叶类杂草考量不足。这导致模型在处理目标尺度变化大、密集目标如丛生杂草等场景时, 易出现检测精度偏低、训练收敛速度缓慢的问题, 难以满足田间杂草精准识别的需求。

为解决上述不足, 本研究引入 EIou 损失函数

对 YOLOv5 的边界框回归损失进行优化。EIou 损失函数在 GIoU 的基础上, 进一步将边界框回归损失拆解为重叠损失、中心点距离损失与宽高损失 3 部分。具体计算公式为:

$$\text{EIou} = \text{IoU} - \frac{\rho^2(b_A, b_B)}{c^2} - \frac{\rho^2(w_A, w_B)}{w_C^2} - \frac{\rho^2(h_A, h_B)}{h_C^2} \quad (8)$$

$$\text{Loss}_{\text{EIou}} = 1 - \text{IoU} + \frac{\rho^2(b_A, b_B)}{c^2} + \frac{\rho^2(w_A, w_B)}{w_C^2} + \frac{\rho^2(h_A, h_B)}{h_C^2} \quad (9)$$

式中: $\rho^2(b_A, b_B)$ 为预测框中心点 b_A 与真实框中心点 b_B 的欧氏距离的平方; c 为包含预测框和真实框的最小外接矩形的对角线长度; $\rho^2(w_A, w_B)$ 为预测框宽度 w_A 与真实框宽度 w_B 差值的平方; w_C 为包含预测框和真实框的最小外接矩形在宽度方向上的最大距离; h_C 为包含预测框和真实框的最小外接矩形在高度方向上的最大距离。

通过同时约束重叠程度、中心点位置、宽高尺度, 实现更精准的边界框回归。从优化效果看, EIou 损失函数通过对边界框尺度信息的加权约束, 使模型在面对尺度差异大的目标如低矮杂草与高大玉米苗时, 能更精准地回归目标位置; 同时, 其对长宽比的专项约束, 可减少细长茎秆杂草与宽叶杂草这类长宽比差异显著目标的检测误差, 进一步提升定位精度。将 EIou 损失函数集成至 YOLOv5 后, 模型在玉米田密集杂草、复杂背景、目标尺度波动等场景下的检测稳定性显著提升, 为后续田间杂草精准识别提供了更可靠的损失计算方案。

2.2 评估指标

在计算机视觉的目标检测研究中, 模型的性能评估指标体系主要涵盖精确率、召回率、平均精度、模型复杂度等核心指标。

精确率 (Precision, P) 用于衡量模型预测结果的可信度, 其定义为预测为正类的样本中真实正类所占的比例, 能够反映模型排除负类干扰的能力。召回率 (Recall, R) 则用于评价模型的查全能力, 即在所有真实正类样本中被正确检出的比例。具体计算公式为:

$$P = \frac{\text{TP}}{\text{TP} + \text{FP}} \times 100\% \quad (10)$$

$$R = \frac{TP}{TP + FN} \times 100\% \quad (11)$$

式中:TP(True positive)为被模型预测为正的正样本;FN(False negative)为被模型预测为正的负样本;FP(False positive)为被模型预测为负的正样本。

平均精度(Average precision, AP)定义为精确率-召回率曲线下面积的积分计算值,该指标通过动态调整分类置信度阈值生成离散采样点进行近似求解。其量化值域严格限定在[0,1]区间,AP值趋近于1时表征模型对特定类别的判别能力越强。具体计算公式为:

$$AP_c = \int_0^1 P(R) dR \times 100\% \quad (12)$$

式中, c 为类别数。

模型复杂度通常指模型在磁盘存储中所占据的空间规模,其常见的主要评估指标包括:模型参数量、浮点运算量和模型体积大小。其中,模型参数量表示模型中可训练参数的总数,反映模型结构的复杂程度,一般而言,参数量越大,模型的表达能力越强,但训练和部署成本也更高;浮点运算量则

指模型在推理过程中需执行的浮点运算总量,是衡量计算负载和推理速度的重要指标;模型大小表示模型在磁盘存储中占用的空间规模,直接关系到模型在嵌入式设备或边缘计算平台上的部署可行性。

2.3 结果分析

为评估优化后YOLOv5s架构的性能优势,本研究在统一试验条件下进行了对比性测试。所有试验均在相同硬件环境、训练参数和验证数据集下开展,确保试验结果具有可比性,从而有效验证所提出改进方案的性能提升效果。

2.3.1 不同轻量化方法对比

YOLOv5s在复杂农田场景中虽具有较好的检测性能,但其在特征表征过程中容易累积冗余信息,导致计算量大、参数规模庞大,从而限制了其在资源受限设备Jetson Nano上的高效部署。为解决该问题,本研究分别在YOLOv5s框架中引入MobileNetV3、shuffleNetV2和GhostNetV3这3种轻量化模块,构建对比组模型,探索不同轻量化策略对模型压缩与检测性能的影响,试验结果见表1。

表1 不同轻量化方法对比试验

Table 1 Comparison experiment of different lightweight method

模型 Model	精确率/% Precision	召回率/% Recall	平均精度值/% Average precision	浮点运算量/ 10^9 Floating point operations	参数量/ 10^6 Number of parameters	模型大小/MB Model size
YOLOv5s	92.2	78.1	85.2	15.8	7.0	14.4
YOLOv5s-MobileNetV3	85.5	74.2	79.4	10.5	5.2	10.3
YOLOv5s-ShuffleNetV2	87.6	74.5	80.5	8.4	4.1	8.6
YOLOv5s-GhostNetv3	88.9	76.7	82.6	7.2	3.2	7.0

试验结果表明,不同轻量化策略在降低计算量、参数量和模型体积方面均取得成效。其中YOLOv5s-M分别减少33.4%、25.7%和28.5%,YOLOv5s-S分别减少46.8%、41.2%和40.3%,YOLOv5s-G分别减少54.4%、54.3%和51.4%。YOLOv5s-G在轻量化方面表现最好,但结构剪枝与通道压缩引发的网络层级缩减、卷积核数量削减及特征表征能力弱化,导致关键检测指标呈现系统性衰减,精确率、召回率和平均精度都有所下降。这种性能折中现象源于感受野缩减与多尺度特征融合能力退化,在复杂背景场景下表现为检测置信度波动和遮挡目标漏检率上升。总体看,YOLOv5s-G

在检测精度和轻量化性能之间实现了最佳平衡。虽然其AP值相较基准模型略有下降,但仍显著优于其他2种轻量化结构,且在参数规模和计算复杂度方面具备明显优势,因此,本研究最终选择YOLOv5s-G作为轻量化基础架构,并在此基础上进一步引入空间-通道混合注意力机制与多尺度特征融合模块,以在保持轻量化优势的同时,进一步提升模型在复杂玉米田场景下的检测精度和鲁棒性。

2.3.2 不同注意力机制对比

为验证提出的注意力机制替换方案在目标检测任务中的有效性,在完成主干网络结构优化的基

础上构建以YOLOv5s-G为基本架构的改进型检测模型。在此模型中,分别嵌入了3种主流注意力机制模块SE、CBAM和CA,并围绕玉米田杂草目标检测任务,对不同机制在实际应用中的性能表现进行了系统的对比试验。各注意力机制的试验结果见表2。

表2 不同注意力机制对比试验

Table 2 Comparison experiment of different attention mechanisms

模型 Model	精确率/% Precision	召回率/% Recall	平均精度值/% Average precision	浮点运算量/ 10^9 Floating point operations	参数量/ 10^6 Number of parameters	模型大小/MB Model size
YOLOv5s-G	88.9	76.7	82.6	7.2	3.2	7.0
YOLOv5s-G+SE	92.3	81.6	85.6	7.25	3.32	7.4
YOLOv5s-G+CBAM	93.1	80.8	86.3	7.27	3.39	8.1
YOLOv5s-G+CA	94.6	82.9	86.9	7.22	3.23	7.2

试验结果表明,引入注意力机制整体上有助于提升模型的检测性能,不同机制对精度的影响程度存在差异。其中,基于CA注意力机制构建的YOLOv5s-G模型表现最为突出。在模型参数数量、计算量及模型大小几乎保持不变的情况下,该模型的检测精确率提高了5.7%,召回率提高了6.2%,平均精度值提高了4.3%,显著优于其他注意力机制。与SE和CBAM相比,CA机制通过引入坐标编码策略将空间信息与通道注意力相结合,使模型能够在复杂田间环境中更有效地捕捉杂草与玉米植株的细微差异,尤其在小目标检测和密集场景下表现更加稳定和可靠。综上,CA注意力机制在保持较低计算开销的同时,显著提升了模型的检测精度与鲁棒性,是轻量化YOLOv5s-G模型在资源受限平台上实现高效部署的理想选择。

2.3.3 不同损失函数对比

在目标检测任务中,网络的损失函数通常由边界框回归损失、置信度预测损失和分类损失3部分构成。者相互协同,构成模型训练与优化的整体目标。其中,边界框回归损失是目标检测算法的核心环节,其性能直接影响预测框与真实框在几何位置上的拟合效果。为评估不同损失函数的优化效果,本研究在统一试验条件下,分别采用GIoU、DIoU、CIoU、EIoU和SiIoU 5种损失函数进行对比试验,结果见表3。相较于基准的GIoU损失函数,4类改进型损失函数均展现出更优的回归效果。其中,采用EIoU函数的模型表现最为突出,其目标检测精确率提升至95.9%,召回率增长到85.8%,平均精度值达到88.6%,同时该损失函数的梯度下降速率较其他方法有所提升,在迭代训练中率先达到稳定状态有效提升了目标检测模型的收敛效率与预测精度。

表3 不同损失函数对比试验

Table 3 Comparison experiment of different loss functions %

模型 Model	精确率 Precision	召回率 Recall	平均精度 Average precision
GIoU	94.6	82.9	86.9
DIoU	94.9	83.5	87.5
CIoU	95.3	84.6	87.9
EIoU	95.9	85.8	88.6
SiIoU	95.6	85.1	88.1

2.3.4 不同改进模块及其组合的消融试验

为验证所提出改进模块在YOLOv5s框架中的

有效性及其协同作用,本研究设计并开展了消融试验。试验通过逐步在基准模型YOLOv5s中引入

GhostNetV3 模块、CA 注意力机制与 EIoU 损失函数,并依次考察单模块优化、双模块组合优化以及三者联合优化的效果,以量化不同模块对模型轻量化和检测精度的贡献。消融试验结果见表 4。GhostNetV3 模块在轻量化方面表现显著,相较于原始 YOLOv5s,参数量和 FLOPs 均大幅下降,而检测精度仅有轻微波动。这表明该模块能够在维持性能的同时有效降低计算复杂度,非常适合部署于资源受限的移动端和边缘计算设备中。CA 注意力机制在几乎不增加计算量和参数规模的前提下,显著提升了模型的特征表达能力和目标检测精度,尤其在复杂背景和密集目标场景下效果突出。EIoU 损失函数通过优化边界框回归过程,提升了模型对目

标定位的精度,特别是在小目标检测任务中优势明显。同时,其优化过程收敛更快,进一步提高了训练效率,在模块组合试验中,双模块叠加能够实现精度与轻量化的协同提升,而三者联合引入时效果最为显著。改进后的最终模型在保持轻量化优势的同时,显著改善了检测精度。与原始 YOLOv5s 相比,参数量降低 53.9%,FLOPs 减少 54.3%;精确率提升 3.7%,召回率提升 7.7%,平均精度提升 3.4%。消融试验不仅验证了各模块的独立有效性,还揭示了其在联合应用时的协同增益效果,充分证明了所提出改进方案的合理性与必要性,为 YOLOv5s 在复杂农田杂草检测中的轻量化应用提供了坚实支撑。

表 4 不同改进模块及其组合的消融试验结果
Table 4 Results of ablation experiments for different modules and their combinations

模型 Model	精确率/% Precision	召回率/% Recall	平均精度值/% Average precision	浮点运算量/ 10^9 Floating point operations	参数量/ 10^6 Number of parameters	模型大小/MB Model size
YOLOv5s	92.2	78.1	85.2	15.80	7.00	14.4
YOLOv5s+GhostNetv3	88.9	76.7	82.6	7.20	3.20	7.0
YOLOv5s+CA	93.6	81.2	86.8	15.90	7.20	14.8
YOLOv5s+EIoU	93.2	80.7	87.0	15.85	7.10	14.6
YOLOv5s+ GhostNetV3+CA	94.3	82.9	86.9	7.22	3.23	7.2
YOLOv5s+ GhostNetV3+EIoU	93.7	82.2	86.3	7.26	3.21	7.1
YOLOv5s+CA+EIoU	94.6	84.5	88.1	15.92	7.26	14.9
YOLOv5s+ GhostNetV3+ CA+EIoU	95.9	85.8	88.6	7.22	3.23	7.2

2.3.5 不同目标检测模型对比

为全面评估优化后 YOLOv5s 模型的综合性能,将其与多个主流 YOLO 系列模型进行对比试验,包括 YOLOv5S、YOLOv7、YOLOv8s、YOLOv11s、YOLOv12s 及 YOLOv13s。对比结果见表 5。试验结果表明,改进模型在多项关键指标上展现了卓越的性能。在检测精度方面,改进模型的精确率、召回率、平均精度值分别达到了 95.9%、85.8% 和 88.6%。其精确率和召回率均为所有对比模型中的最高值,平均精度值仅次于表现最优的 YOLOv13s,显著优于原 YOLOv5s 基准模型及其他同类轻量化版本。改进模型在轻量化

方面表现出了一定优势,其浮点运算量仅为 7.22 G,参数量低至 3.23 M,模型体积压缩至 7.2 MB,均低于 YOLOv7、YOLOv8s、YOLOv11s、YOLOv12s 和 YOLOv13s,与原始 YOLOv5s 相比,改进模型在浮点运算量、参数量和模型大小上分别降低 54.3%、53.9% 和 50%,实现了显著的模型压缩。通过对比试验数据结果表明,本研究针对 YOLOv5s 算法从模型架构到参数优化的全方位改进成效显著,在有效实现模型轻量化设计的同时,成功维持了较高水平的杂草目标检测与识别精度,经测试可以满足移动端设备的实际部署应用需求。

表 5 不同目标检测模型对比试验

Table 5 Comparative experiments of different object detection models

模型 Model	精确率/% Precision	召回率/% Recall	平均精度值/% Average precision	浮点运算量/10 ⁹ Floating point operations	参数量/10 ⁶ Number of parameters	模型大小/MB Model size
YOLOv5s	92.2	78.1	85.2	15.8	7.0	14.4
YOLOv7	92.6	79.8	86.3	104.7	37.4	72.35
YOLOv8s	94.5	82.2	88.1	11.3	5.1	10.2
aYOLOv11s	93.3	80.5	87.7	8.6	3.8	7.6
YOLOv12s	94.7	81.8	88.0	12.1	5.5	11.0
YOLOv13s	95.2	83.5	89.0	10.8	4.9	9.8
YOLOv5s-G+ CA+EIoU	95.9	85.8	88.6	7.22	3.23	7.2

2.3.6 Jetson Orin Nano super 实测性能验证

为验证改进 YOLOv5s 模型在农业激光除草装备实际场景中的部署适用性,本研究选取该领域常用的嵌入式硬件英伟达 Jetson Orin Nano super (8 GB 版)作为测试平台,其硬件配置如下:CPU 为 6 核 ARM Cortex-A78AE, GPU 为 1 024 核 NVIDIA Ampere 架构,内存为 8 GB LPDDR5,存储为 32 GB Emmc。软件环境为操作系统 Ubuntu 22.04 LTS,搭载 JetPack 6.0 (CUDA 12.2, TensorRT 8.6.1),模型推理采用 TensorRTFP16

量化加速。测试数据集选取测试集中 100 张玉米田间杂草图像,分辨率为 4 096 像素×3 072 像素,与实际采集分辨率一致。测试指标与方法为:推理速度方面,单张图像连续推理 100 次,记录总耗时并计算平均速度,同时测试批量推理批次=8 的推理速度,模拟激光除草场景中连续帧实时检测的实际需求;内存占用方面,通过 nvidia-smi 工具监控推理过程中 GPU 峰值内存占用,通过 free -h 监控系统内存 (RAM)峰值占用,取 3 次测试平均值。实测性能对比结果见表 6。

表 6 不同模型在 Jetson orin nano super 的实测性能对比

Table 6 Comparison of measured performance of different models on Jetson orin nano super

模型 Model	单张推理速度/(帧/s) Single-image inference speed	批量推理速度 (批次=8)/(帧/s) Batch inference speed (batch=8)	GPU 峰值内存/MB GPU peak memory	系统 RAM 峰值/MB System RAM peak
YOLOv5s	31.3	38.8	1 240	1 560
YOLOv7	24.5	39.2	2 860	2 150
YOLOv8s	37.5	46.6	956	1 280
aYOLOv11s	38.2	48.1	892	1 150
YOLOv12s	36.8	45.5	988	1 320
YOLOv13s	39.1	49.7	1 023	1 410
YOLOv5s-G+ CA+EIoU	43.6	54.2	682	924

改进后的 YOLOv5s 模型在嵌入式硬件上展现出显著的部署优势,推理速度上,单张推理场景下帧率达 43.6,批量推理(批次=8)场景下帧率进一

步提升至 54.2,远高于激光除草实时作业的最低需求,可满足田间的连续检测需求;内存占用上,GPU 峰值内存占用仅为 682 MB,系统内存(RAM)占用

为 924 MB, 分别较原始 YOLOv5S 降低 45.0%、40.8%, 且改进模型在精度、速度、内存三维度实现最优平衡, 在保持高检测精度的同时, 推理速度与内存占用均更优, 为激光除草机器的硬件集成提供了轻量化且高效的算法方案。

3 结 论

本研究围绕玉米田间杂草智能检测的精度、实时性与轻量化需求, 提出了一种基于改进 YOLOv5s 模型的优化方法。通过在网络结构、注意力机制及损失函数等方面的改进, 该方法兼顾了模型的高效性与准确性, 在实验室和真实农田环境中均取得了良好表现。主要结论如下:

1) 针对现有杂草识别模型计算量大、参数冗余的问题, 在 YOLOv5s 主干网络引入 GhostNetV3 模块, 有效降低了模型参数规模和运算量, 同时保持较强的特征提取能力, 为资源受限设备的部署提供了可行方案。

2) 为解决轻量化主干网络引发的特征表征能力弱化及识别精度降低问题, 采用坐标注意力机制强化多维特征建模能力。该机制通过同步构建空间坐标与通道维度间的关联性, 使网络在维持计算效率的前提下, 显著提升目标定位精度与模型泛化性能。试验结果表明, 该改进方案在保持推理速度的同时, 使平均检测精度得到提升, 尤其在复杂场景下表现出更强的特征区分能力。

3) 采用 EIoU 替代传统边界框回归方法, 通过引入几何约束与中心点距离优化机制, 该方案显著提升了目标定位的准确性, 同时加快了模型训练收敛速度, 改进后的损失函数通过动态调整长宽比权重, 有效缓解了多尺度目标的检测偏差问题, 尤其在复杂背景和小目标场景下表现出更强的鲁棒性。该优化方案不仅增强了模型在实际检测任务中的表现, 实现了检测精度与推理效率的协同提升, 还兼顾了模型的轻量化设计, 使其更适用于资源受限的移动端设备 Jetson Orin Nano super 部署, 满足了对高效性与精确性的双重要求。

参考文献 References

[1] 刘莫尘, 高甜甜, 马宗旭, 宋占华, 李法德, 闫银发. 基于 MSRCR-YOLOv4-tiny 的田间玉米杂草检测模型[J]. 农业机械学报, 2022, 53(2): 246-255, 335
Liu M C, Gao T T, Ma Z X, Song Z H, Li F D, Yan Y F. Target detection model of corn weeds in field environment based on MSRCR algorithm and

YOLOv4-tiny[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(2): 246-255, 335 (in Chinese)

[2] Mhlanga B, Chauhan B S, Thierfelder C. Weed management in maize using crop competition: A review[J]. *Crop Protection*, 2016, 88: 28-36

[3] Kumar P, Rawal S, Poonia T M, Punia R, Choudhary K, Anu, Monika. Effect of weed management on growth and yield of maize grown under different tillage systems [J]. *Journal of Experimental Agriculture International*, 2025, 47(2): 296-301

[4] 刘胜男, 朱建义, 郑仕军, 王东风, 王彬, 张建军, 周小刚. 不同种植密度对玉米田杂草发生及玉米产量的影响[J]. 杂草学报, 2016, 34(2): 53-57
Liu S N, Zhu J Y, Zheng S J, Wang D F, Wang B, Zhang J J, Zhou X G. Effects of different cultivation density on occurrence of weeds and yield of maize[J]. *Journal of Weed Science*, 2016, 34(2): 53-57 (in Chinese)

[5] 杨继芝, 龚国淑, 张敏, 陈华保, 王学贵, 杨春平. 密度和品种对玉米田杂草及玉米产量的影响[J]. 生态环境学报, 2011, 20(S1): 1037-1041
Yang J Z, Gong G S, Zhang M, Chen H B, Wang X G, Yang C P. Effects of different planting cultivation density and cultivars of maize on occurrence of weed and yield[J]. *Ecology and Environmental Sciences*, 2011, 20(S1): 1037-1041 (in Chinese)

[6] Mishchenko Y, Butenko A, Hotvianska A, Tsyuk O, Sologub I, Bondarenko O, Pryshedko N, Mikulina M, Ryzhenko A, Sevydov O. The impact of organic farming methods on weed infestation in corn crops and soil improvement[J]. *Journal of Ecological Engineering*, 2025, 26(3): 77-85

[7] Ali A, Ahmed S, Laghari G M, Laghari A H, Soomro A A, Jabeen N. Effect of maize (*Zea mays*) and soybean (*Glycine max*) cropping systems on weed infestation and resource use efficiency[J]. *Agronomy*, 2024, 14(12): 2801

[8] 张莹, 朱奕庚, 吴林峰, 古冬冬, 杨彩虹. 国内外苗间除草装置研究现状与展望[J]. 农机使用与维修, 2024(4): 62-65
Zhang Y, Zhu Y G, Wu L F, Gu D D, Yang C H. Research status and prospect of weeding devices between seedlings at home and abroad [J]. *Agricultural Machinery Using & Maintenance*, 2024(4): 62-65 (in Chinese)

[9] 阙立民, 赵胜雪, 高帅男, 郭洋, 周轶楠. 玉米除草机研究现状与展望[J]. 农机使用与维修, 2024(4): 73-76
Kan L M, Zhao S X, Gao S N, Guo Y, Zhou Y N. Research status and prospect of corn weeder[J]. *Agricultural Machinery Using & Maintenance*, 2024(4): 73-76 (in Chinese)

[10] 伍同, 曾山, 赵润茂, 唐灵茂, 杜攀, 姚腊梅. 智能化作物株间机械除草技术分析与研究[J]. 农机化研究, 2019, 41(6): 1-6, 12
Wu T, Zeng S, Zhao R M, Tang L M, Du P, Yao L M. Analysis and study on intelligentized technologies of intra-row weeding mechanical control[J]. *Journal of Agricultural Mechanization Research*, 2019, 41(6): 1-6, 12 (in Chinese)

[11] 李香菊. 近年我国农田杂草防控中的突出问题与治理对策[J]. 植物保护, 2018, 44(5): 77-84
Li X J. Main problems and management strategies of weeds in agricultural fields in China in recent years[J]. *Plant Protection*, 2018, 44(5): 77-84 (in Chinese)

[12] 赵辉, 曹宇航, 岳有军, 王红君. 基于改进DenseNet的田间杂草识别[J]. 农业工程学报, 2021, 37(18): 136-142
Zhao H, Cao Y H, Yue Y J, Wang H J. Field weed recognition based on improved DenseNet[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2021, 37(18): 136-142 (in Chinese)

[13] Wang A C, Zhang W, Wei X H. A review on weed detection using ground-based machine vision and image processing techniques[J]. *Computers and Electronics in Agriculture*, 2019, 158: 226-240

[14] 王璨, 武新慧, 李志伟. 基于卷积神经网络提取多尺度分层特征识别玉米杂草[J]. 农业工程学报, 2018, 34(5): 144-151
Wang C, Wu X H, Li Z W. Recognition of maize and weed based on multi-scale hierarchical features extracted by convolutional neural network[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2018, 34(5): 144-151 (in Chinese)

- [15] 刘文, 徐丽明, 邢洁洁, 史丽娜, 高振铭, 袁全春. 作物行间机械除草技术的研究现状[J]. 农机化研究, 2017, 39(1): 243-250
Liu W, Xu L M, Xing J J, Shi L N, Gao Z M, Yuan Q C. Research status of mechanical intra-row weed control in row crops [J]. *Journal of Agricultural Mechanization Research*, 2017, 39(1): 243-250 (in Chinese)
- [16] 方会敏, 牛萌萌, 薛新宇, 姬长英. 玉米田间机械-化学协同除草的杂草防除效果[J]. 农业工程学报, 2022, 38(6): 44-51
Fang H M, Niu M M, Xue X Y, Ji C Y. Effects of mechanical-chemical synergistic weeding on weed control in maize field[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2022, 38(6): 44-51 (in Chinese)
- [17] 张宋超, 薛新宇, 孙涛, 田志伟, 武静雯, 周晴晴. 植保无人机油菜杂草防治与效果评估研究[J]. 中国农机化学报, 2019, 40(9): 48-53, 59
Zhang S C, Xue X Y, Sun T, Tian Z W, Wu J W, Zhou Q Q. Study on weed control of plant protection UAV and effect evaluation in rape filed [J]. *Journal of Chinese Agricultural Mechanization*, 2019, 40(9): 48-53, 59 (in Chinese)
- [18] 齐龙, 刘闯, 蒋郁. 水稻机械除草技术装备研究现状及智能化发展趋势[J]. 华南农业大学学报, 2020, 41(6): 29-36
Qi L, Liu C, Jiang Y. Present status and intelligent development prospects of mechanical weeding technology and equipment for rice[J]. *Journal of South China Agricultural University*, 2020, 41(6): 29-36 (in Chinese)
- [19] 张良安, 唐锴, 赵永杰, 王孝义, 余大壮, 卢新建, 王祥. 四足激光除草机器人腿部结构参数优化[J]. 农业工程学报, 2020, 36(2): 7-15
Zhang L A, Tang K, Zhao Y J, Wang X Y, Yu D Z, Lu X J, Wang X. Optimization of leg structure parameter of quadruped laser weeding robot[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2020, 36(2): 7-15 (in Chinese)
- [20] Bauer M V, Marx C, Bauer F V, Flury D M, Ripken T, Streit B. Thermal weed control technologies for conservation agriculture: A review[J]. *Weed Research*, 2020, 60(4): 241-250
- [21] 张帅. 我国主要农作物田杂草防控技术[J]. 杂草学报, 2020, 38(2): 50-55
Zhang S. Weed control techniques in farmland of China[J]. *Journal of Weed Science*, 2020, 38(2): 50-55 (in Chinese)
- [22] Hamuda E, Mc Ginley B, Glavin M, Jones E. Automatic crop detection under field conditions using the HSV colour space and morphological operations[J]. *Computers and Electronics in Agriculture*, 2017, 133: 97-107
- [23] Xiong Y, Ge Y Y, Liang Y L, Blackmore S. Development of a prototype robot and fast path-planning algorithm for static laser weeding[J]. *Computers and Electronics in Agriculture*, 2017, 142: 494-503
- [24] Sabzi S, Abbaspour-Gilandeh Y, Arribas J I. An automatic visible-range video weed detection, segmentation and classification prototype in potato field [J]. *Heliyon*, 2020, 6(5): e03685
- [25] Punithavathi R, Delphin Carolina Rani A, Sughashini K R, Kurangi C, Nirmala M, Farhana Thariq Ahmed H, Balamurugan S P. Computer vision and deep learning-enabled weed detection model for precision agriculture[J]. *Computer Systems Science and Engineering*, 2023, 44(3): 2759-2774
- [26] 孙俊, 何小飞, 谭文军, 武小红, 沈继锋, 陆虎. 空洞卷积结合全局池化的卷积神经网络识别作物幼苗与杂草[J]. 农业工程学报, 2018, 34(11): 159-165
Sun J, He X F, Tan W J, Wu X H, Shen J F, Lu H. Recognition of crop seedling and weed recognition based on dilated convolution and global pooling in CNN[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2018, 34(11): 159-165 (in Chinese)
- [27] 彭明霞, 夏俊芳, 彭辉. 融合FPN的Faster R-CNN复杂背景下棉田杂草高效识别方法[J]. 农业工程学报, 2019, 35(20): 202-209
Peng M X, Xia J F, Peng H. Efficient recognition of cotton and weed in field based on Faster R-CNN by integrating FPN[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2019, 35(20): 202-209 (in Chinese)
- [28] 亢洁, 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 J, Liu G, Guo G F. 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)
- [29] 权龙哲, 夏福霖, 姜伟, 李海龙, 李恒达, 姜朝霞, 李传文. 基于YOLO v4卷积神经网络的农田苗草识别研究[J]. 东北农业大学学报, 2021, 52(7): 89-98
Quan L Z, Xia F L, Jiang W, Li H L, Li H D, Lou Z X, Li C W. Research on recognition of maize seedlings and weeds in maize mield based on YOLO v4 convolutional neural network [J]. *Journal of Northeast Agricultural University*, 2021, 52(7): 89-98 (in Chinese)

责任编辑: 刘迎春



第一作者简介: 王宁, 硕士研究生, 2023年9月至今就读于中国农业大学工学院机械电子工程专业。曾获中国农业大学研究生学习优秀二等奖学金、中国农业大学三好学生等荣誉。



通讯作者简介: 吕昊瞰, 中国农业大学副教授、硕士生导师, 主要从事农机装备抗扰容错控制、精密仪器测量与智能控制系统等方向的研究工作, 致力于农机装备在复杂田间环境下稳定运行与智能控制方法的研究。近年来, 参与多项国家及省部级科研项目, 聚焦装备系统的鲁棒性与可靠性设计。在科研教学中注重学科交叉融合, 倡导以精密仪器理论为基础, 结合机械系统建模与信号处理方法, 提出具有实用价值的控制策略。