

轻量化的YOLOv8杂草目标检测算法

褚云¹, 魏艳龙¹, 梁海坚², 王钰涵¹

(1. 太原师范学院 计算机科学与技术学院, 山西 晋中 030619; 2. 中北大学 软件学院, 山西 太原 030051)

摘要: 智能除草装置在农田实际应用中面临杂草检测模型如何部署至移动设备, 并实现对复杂背景下不同形状和特征的杂草快速精确识别的问题。针对农业移动除草设备的部署需求, 本文以玉米苗期的杂草数据为检测目标, 对YOLOv8(You Only Look Once)检测算法进行改进, 提出了一种轻量化杂草目标检测算法。为了缩减模型规模, 并提高模型在移动设备上的运行效率, 将主干网络替换为改进后的MobileViT(Mobile Vision Transformer)轻量级模型主干。与此同时, 设计了颈部网络纳入轻量级卷积GSConv(Group-Steerable Convolution)和VoVGSCSP(Voting-based Vision Guided Superpixel Co-Segmentation with Pooling)模块, 以增强模型的特征提取能力和目标检测的精确度, 提高模型检测的准确性和速度。通过将Distance-IoU(DIoU)与柔性非极大抑制(Soft-NMS)相结合的算法, 改善了模型的收敛速度, 并在多个目标重叠下达到了更高的平均准确率。通过自建的玉米田杂草数据集进行了实验验证, 结果表明: 轻量化的杂草识别模型参数量仅为1 083 025, 相较于YOLOv8n减少了64%; 模型的精确率和召回率分别达到了93%和92.6%, mAP50和mAP50-95指标分别为97.4%和88.1%; 此外, 单幅图像的检测速度达到了92.5帧/s, 为该模型在农业边缘设备上的应用提供了条件。该算法在准确性、速度和模型规模方面取得了显著的改进, 可以为智能除草装置在农田中的实际应用提供技术支持。

关键词: 目标检测; YOLOv8; MobileViT; 轻量化; Soft-NMS

中图分类号: TP181 **文献标识码:** A **doi:** 10.62756/jnuc.issn.1673-3193.2024.04.0020

引用格式: 褚云, 魏艳龙, 梁海坚, 等. 轻量化的YOLOv8杂草目标检测算法[J]. 中北大学学报(自然科学版), 2025, 46(4): 489-498.

CHU Yun, WEI Yanlong, LIANG Haijian, et al. Lightweight YOLOv8 algorithm for weed target detection [J]. Journal of North University of China(Natural Science Edition), 2025, 46(4): 489-498.

Lightweight YOLOv8 Algorithm for Weed Target Detection

CHU Yun¹, WEI Yanlong¹, LIANG Haijian², WANG Yuhuan¹

(1. School of Computer Science and Technology, Taiyuan Normal University, Jinzhong 030619, China;

2. School of Software, North University of China, Taiyuan 030051, China)

Abstract: In the practical application of intelligent weed control devices in agricultural fields, the key issue is how to deploy the detection model to mobile devices and achieve rapid and accurate identification of weeds with different shapes and features in complex backgrounds. In response to the deployment requirements of agricultural mobile weeding equipment, this study focused on weed data during the corn seedling stage and made improvements to the YOLOv8 (You Only Look Once) detection algorithm, proposing a lightweight weed object detection algorithm. To reduce the model size and improve the operational efficiency of the model on mobile devices, the study replaced the backbone network with an

收稿日期: 2024-04-22

基金项目: 山西省青年科学研究基金项目(202203021212185); 航空科学基金项目(202300340U0002)

作者简介: 褚云(1997-), 女, 硕士生, 主要从事机器学习、图像处理的研究。

通信作者: 魏艳龙(1989-), 男, 副教授, 博士, 主要从事测试、智能信息处理的研究。E-mail: 774208057@qq.com。

improved MobileViT (Mobile Vision Transformer) lightweight model backbone. Simultaneously, the study designed a neck network that incorporated lightweight convolution modules such as GSConv (Group-Steerable Convolution) and VoVGSCSP (Voting-based Vision Guided Superpixel Co-Segmentation with Pooling) to enhance the model's feature extraction capability and the accuracy of object detection, thereby improving the accuracy and speed of model detection. By combining the Distance-IoU (DIoU) algorithm with Soft-NMS (soft non-maximum suppression), the convergence speed of the model was improved, and higher average accuracy was achieved even with multiple overlapping targets. Experimentally verifying by the self-constructed cornfield weed dataset, the number of parameters of the lightweight weed recognition model is only 1 083 025, which is 64% less compared to YOLOv8n. The precision and recall of the model reach 93% and 92.6%, the mAP50 and mAP50-95 metrics are 97.4% and 88.1%, respectively, and the detection speed of a single image reaches 92.5 frames/second, which supplies the conditions for deploying it to agricultural edge devices. The experimental results indicate that the algorithm achieves significant improvements in accuracy, speed, and model size, providing technical support for the practical application of the intelligent weeding device in agricultural fields.

Key words: target detection; YOLOv8; MobileViT; lightweight; Soft-NMS

0 引言

为了应对农业生产规模化发展趋势及避免大范围喷洒除草剂造成环境污染,田间自动化除草设备逐渐被应用于现代化农业生产^[1-3]。在实际农田应用场景中,实现自动化精准除草所使用的检测模型需满足快速准确地识别杂草,参数量和计算复杂度适合部署至可移动设备的要求。

近年来,深度学习因其在目标检测、分类和特征提取方面的显著优势而受到广泛关注,基于深度学习的目标检测算法分为两类:双阶段和单阶段目标检测算法^[4]。双阶段检测算法先生成候选框再对每个候选框进行目标分类和位置精细化,因此具有较高的识别准确率,但相对来说图像数据处理的时间较长。Thanh等^[5]通过对具有不同特征提取器的Faster RCNN模型进行实验,证实Inception-ResNet-V2网络的平均精度高于其他双阶段检测算法。Neha Shekhawat等^[6]提出了结合RCNN模型和改进的RCNN-LSTM的RCNN-GRU模型,并将其应用于无人机的杂草识别系统,其精确度为97.88%,优于其他RCNN模型。Mu等^[7]提出了一种基于Faster RCNN网络模型的双阶段算法,但检测速度不够快,导致无法实时检测。

单阶段检测算法将过程进行了简化并且通常直接利用深度学习模型对图像进行了预测,不需要显式生成候选框。王宇^[8]为了提升检测模型的性能,以YOLOv5s为基准模型引入CA注意力机制模块,

并在Neck端添加了FPN特征融合模块,但是这样造成了模型运算量的增加。Zhang等^[9]提出结合了多尺度检测和注意力机制的杂草识别模型EM-YOLOv4-Tiny,在特征金字塔网络中添加了高效通道注意模块来提高识别能力,然而此举增加了模型的复杂性和计算负担。冀汶莉等^[10]采用PP-LCNet重置特征提取网络以减少模型参数,并使用Ghost卷积模块轻量化特征融合网络以降低计算量,在保持识别精度的同时牺牲了一定的识别速度。Hua等^[11]提出了一种用于花生田间机械智能除草的名为BEM-YOLOv7-microt的目标检测模型,该研究引入ECA和MHSA模块来增强目标特征提取和预测目标的聚焦,利用BiFPN模块来增强网络层间的特征传递,此举提高了现场检测的性能,但是模型的参数量没有显著降低。Hu等^[12]对基于深度学习的杂草目标检测进行了总结,指出神经网络的精度和参数规模在一定程度上与深度成正比例,意味着算法难以部署至移动应用。

由此可见,许多基于深度学习的检测模型因占用内存较大影响了其在可移动农业设备上的应用,而占用内存较小的检测模型往往无法满足准确、快速的检测要求。在此背景下,YOLOv8^[13]作为一种新型的单阶段检测算法,凭借其较高的检测精度、较快的检测速度以及相对较小的模型尺寸,成为研究轻量化设计的理想选择。YOLOv8采用梯度流更丰富的C2f结构作为骨干网络和Neck的部分,通过调整通道数以适应不同尺度的模型,实现了进一步的模型轻量化和高性

能。同时, YOLOv8还引入了正样本分配策略来提高模型的训练效率和检测性能。然而, 尽管YOLOv8在多个方面进行了优化, 其内部仍包含较多的卷积块和C2f块, 导致其在实时检测和边缘部署时面临计算量大和参数量大的挑战。

本文提出一种基于YOLOv8的轻量级农田杂草检测算法, 以满足现代农业自动化除草设备对检测模型的实际需求。主要工作如下:

- 1) 算法采用了轻量级的MobileViT作为主干提取网络以减少参数量和计算复杂度;
- 2) 为了在保持模型准确性的同时提高特征提取效果, 在模型颈部引入GSConv轻量级卷积模块和VoVGSCSP模块来平衡模型的各项指标;
- 3) 为了提高目标定位的鲁棒性和准确性, 将后处理技术Soft-NMS与DIoU loss结合为Soft-NMS-DIoU来减少误检和漏检的发生。

1 基于YOLOv8的轻量化杂草检测模型

应用到农田中的检测算法需要满足高精度、实时性以及可部署的要求, 故而利用轻量级主干网络

MobileViT^[14]取代了YOLOv8原有的由卷积层和C2f模块组成的主干, 用以解决参数量较大难以部署的问题。为了平衡轻量化造成的精确度缺失与实时性的要求, 利用VoVGSCSP模块取代了颈部原有的C2F模块并将颈部的卷积更换为两个GSConv模块, 使其能够更高效地学习图像的局部和全局特征。最后将Soft-NMS与DIoU loss结合为Soft-NMS-DIoU来提升目标检测算法在目标定位、检测结果鲁棒性和回归框精度等方面的性能。

结构图1为改进后的轻量级检测模型结构。模型结构的骨干部分(Backbone)由1个卷积(Conv)层及10个穿插的IRB和MobileViTBlock模块来进行特征提取, 用于从图像中提取有用的特征; 颈部(Neak)由12个模块构成, 主要完成上采样(Upsample)、特征图拼接(Concat)、C2F模块和VoVGSCSP模块图像处理以及GSConv层对特征图进行下采样。头部(Head)将不同尺度的特征图转换为最终的目标检测输出, 主要利用了轻量化的卷积模块(CBS)和二维卷积函数(Conv2d)、边界框回归的损失函数(bbox. loss)和优化目标分类的损失函数(cls. loss)。下面将详细介绍各个模块。

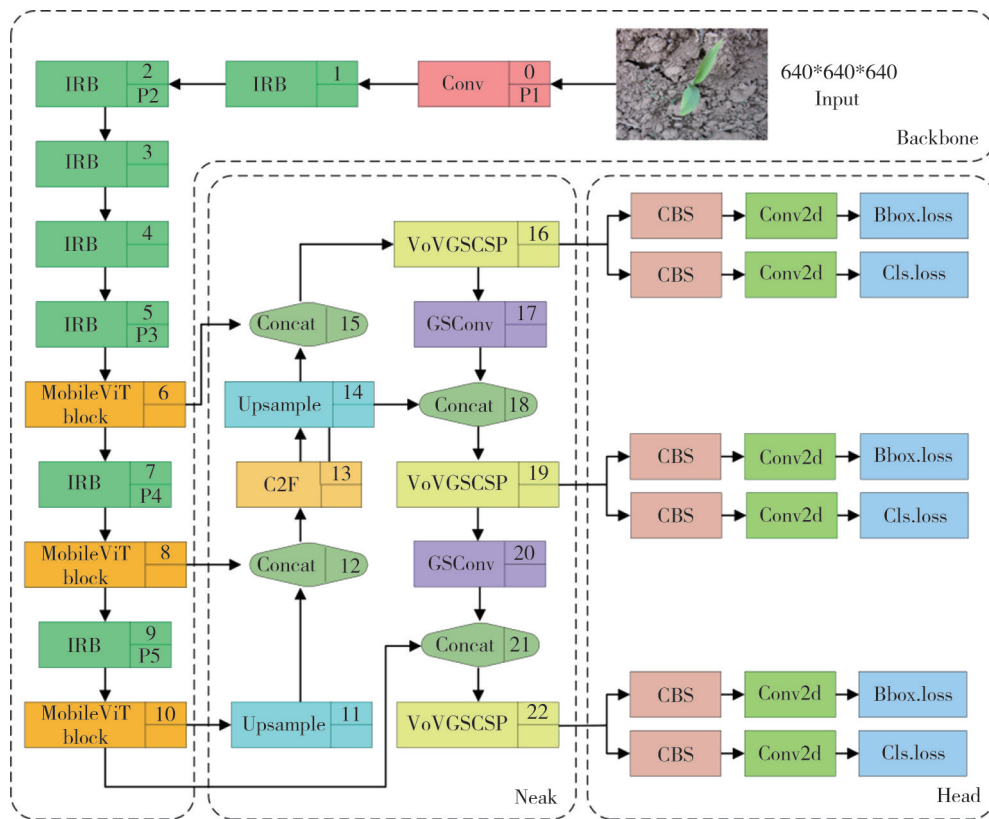


图1 改进的YOLOv8结构图
Fig. 1 Improved structure of YOLOv8

1.1 MobileViT轻量级主干网络

MobileViT网络将轻量级卷积神经网络CNN模型的空间归纳偏差、局部表征能力和重量级ViT视觉转换器的全局感受能力结合在一起,通过更好地捕获全局特征、整合多尺度信息以及采用轻量级设计策略,实现了网络结构的轻量化、检测精度的提升以及强大的泛化能力,使模型更适用应用于农田杂草检测等资源受限的移动设备环境。

MobileViT模型结构如图2所示,主要由Conv标准卷积、IRB模块、MobileViT block,全局池化以及全连接层组成。此结构在输入图像后

经由标准卷积层将原始图像缩小至原来的一半,通过6个IRB模块和3个MobileViT block的交替应用来充分利用局部和全局特征,在进行全局池化和全连接层后输出最终结果。网络中的IRB模块为MobileNetV2^[15]模型中的一种和普通残差结构不同的倒残差(Inverted Residual Block, IRB)结构。此结构首先用 1×1 卷积核进行升维操作使通道变深,再通过 3×3 卷积核Depthwise操作进行卷积,最后经过 1×1 卷积核进行降维操作。结构中采用非线性激活函数ReLU6以及批标准化(Batch Normalization, BN)来改善模型的拟合能力,提高梯度传播和泛化能力,加速训练过程。

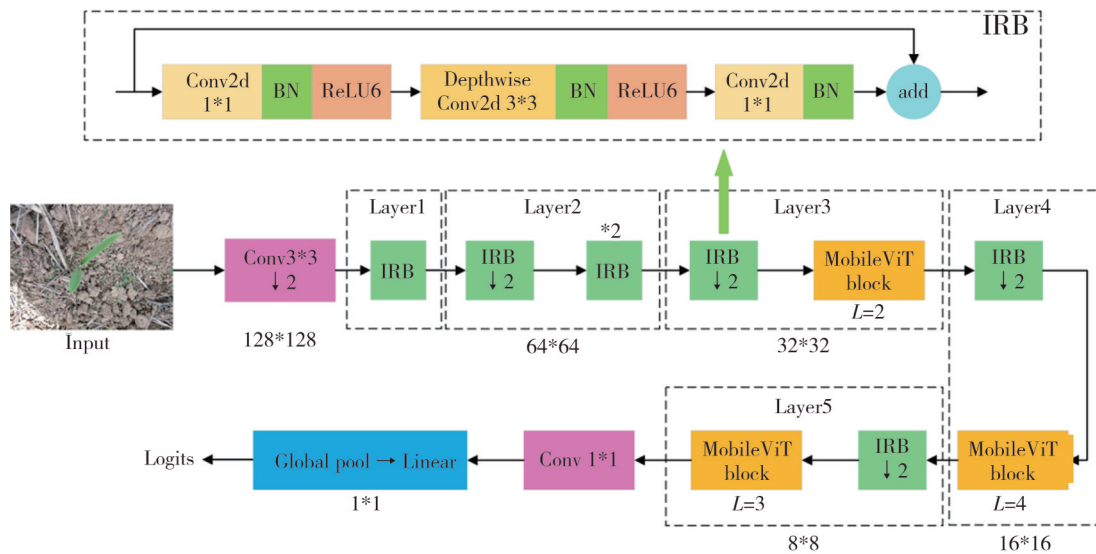


图2 MobileViT网络

Fig.2 MobileViT network

MobileViT block核心模块采用标准卷积相同的构建块,用更深层次的全局处理代替标准卷积中的局部处理,包含Local representation(局部表征模块)、Local representation(全局表征模块)、Fusion(融合模块),如图3所示。首先对输入特征图做 3×3 标准卷积进行图像的局部特征建模,再经由 1×1 标准卷

积调整通道数后展开得到 N 个扁平矩阵以获取像素之间的空间关系,再由Transformer^[16]利用自注意力机制学习像素之间的关系进行全局特征建模,然后通过折叠变为原始特征图,又由 1×1 标准卷积变为原始输入大小与原始输入特征图进行通道方向的拼接,最后使用 3×3 标准卷积进行特征融合输出。

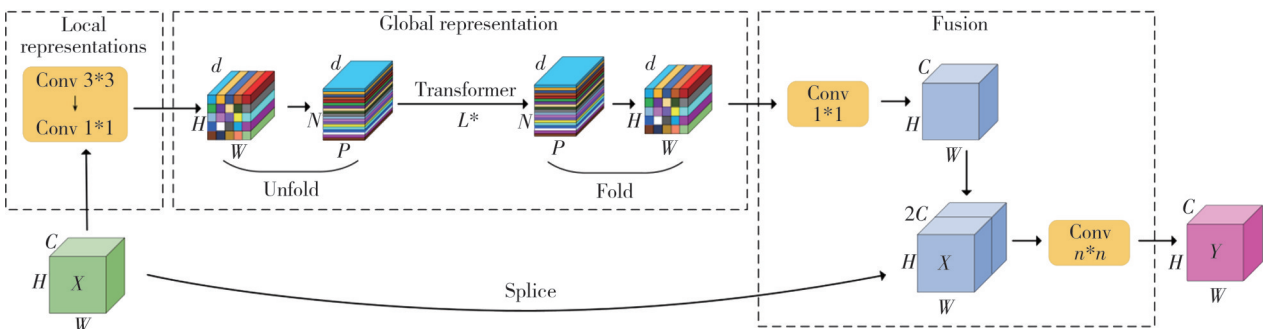


图3 MobileViT block模块

Fig.3 MobileViT block Module

1.2 GSConv 和 VoVGSCSP 模块

主干轻量化设计可以显著降低模型的参数量和计算量,但同时会造成一些精度缺失。为解决这一问题,针对农田杂草检测数据集杂草多样、背景复杂的特点,在模型的颈部引入了GSConv^[17]模块以替代原有的卷积操作,这一改动降低了模型的参数量和计算量,同时保持了较高特征提取能力。此外,利用VoVGSCSP模块取代原有的C2F模块,通过其跨阶段的信息融合机制,进一步提升了模型对复杂场景的适应能力。

GSConv的可定向滤波器特性使得模型能够

捕捉不同方向和尺度的特征,从而可以提供更丰富的特征表达能力。针对农田环境中杂草的形态、大小及生长方向各异特征,GSConv的这一特性使得模型能够更准确地识别这些细微差异,提高检测的精确度。而VoVGSCSP采用一次性聚合的方式设计跨阶段部分的网络模块,在不同阶段之间进行了高效的信息融合,能够有效解决主干轻量化可能带来的信息丢失问题。在农田杂草检测任务中,该模块的设计有助于模型更好地理解杂草与背景以及杂草之间的复杂关系,进一步提高检测的召回率和稳定性。GSConv和VoVGSCSP模块的设计如图4所示。

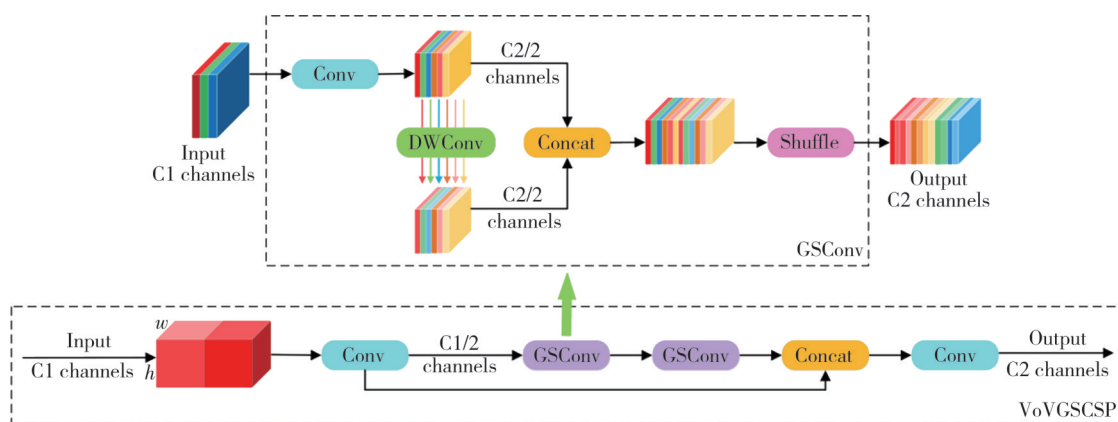


图4 GSConv 和 VoVGSCSP 模块

Fig. 4 GSConv and VoVGSCSP modules

VoVGSCSP模块将特征图进行一次普通卷积(conv),再经过两次GSConv模块卷积后与第一次普通卷积结果进行拼接(concat),然后再卷积(conv)一次输出结果。其中,GSConv模块会将输入特征图经过一个普通卷积层(Conv)进行下采样,然后使用深度可分离卷积层(DWConv)对每个通道进行独立卷积。卷积完成后,将Conv层和DWConv层的输出进行拼接。拼接(concat)后的特征图经过一个随机排列(Shuffle)操作以重新排列特征通道,从而提高特征间的信息流动,最后输出特征图。在模型颈部引入GSConv轻量级卷积模块和VoVGSCSP模块后,模型在农田杂草检测任务中可以保持高召回率并提高算法的鲁棒性和稳定性,从而为农业自动化和精准农业提供更精确的检测结果。

1.3 Soft-NMS-DIoU

传统非最大值抑制(Non-Maximum Suppression, NMS)算法用于获取局部最大值并抑制非最大值,但在处理如杂草图像这类密集且高度重叠的场景时,NMS算法会导致预选框之间重叠,进

而导致许多有效框被直接丢弃,因此降低了目标检测的精度。为了克服这一局限性并更好地适应杂草图像数据集特性,引入了Soft-NMS算法。Soft-NMS^[18]在检测框和得分最高的检测框之间的交并比(IoU)^[19]超过设定阈值时,会用较低的分数量替换原始分数,以更平滑的方式调整其得分,因而保留一些有用的重叠框,这使模型更加关注可靠的检测结果。Soft-NMS函数为

$$s_i = \begin{cases} s_i, & IoU(M, b_i) < N_t, \\ s_i(1 - IoU(M, b_i)), & IoU(M, b_i) \geq N_t, \end{cases} \quad (1)$$

式中: s_i 为处理中检测框的当前分数; IoU 为两框的交并比; M 为得分最高的检测框; b_i 为当前检测框; N_t 为设置的IoU阈值。

为了提高模型的定位精度,YOLOv8使用了CIoU(Complete IoU)^[20]边界框损失函数,它在回归过程中综合考虑了重叠面积、中心点距离和长宽比等因素。然而,CIoU无法有效地反映宽度和高度置信度的差异,可能会影响回归样本质量好的相似性优化。为此,针对杂草图像数据集的特

点,进一步提出了Soft-NMS-DIoU方法,该方法将DIoU^[21]损失函数与Soft-NMS相结合,旨在更精确地衡量预测框与真实框之间的相似度。DIoU不仅考虑了重叠面积,还引入了中心点距离和尺度信息,这使得它在处理杂草图像中形状各异、大小不一的目标时更具优势。通过将DIoU融入Soft-NMS流程,能够在保留有用重叠框的同时,进一步提升边界框的定位精度。

$$DIoU = IoU - \frac{\rho^2(b, b^{gt})}{c^2}, \quad (2)$$

式中: ρ 为两个中心点间的欧式距离; b 为预测框的中心点; b^{gt} 为真实框的中心点; c^2 为能够包含预测框和真实框最小闭包区域的对角线距离。

针对杂草图像数据集的特定属性,对Soft-NMS-DIoU算法中的训练参数进行了细致的优化调整,以确保其能够更准确地反映预测框与真实框之间的相似程度。通过这一创新性的结合,不仅有效解决了杂草图像中检测框重叠的问题,还显著提升了目标检测的整体性能。

2 实验结果与分析

2.1 杂草实验数据集

实验中使用的农田杂草数据集包含两个部分:第一部分是从互联网上找到的玉米幼苗图片以及玉米苗期的两种伴生杂草图片,共计2749张;第二部分是在山西省临汾市玉米田中使用华为nova8手机拍摄的三种杂草图片,共计1756张。为了增加数据集的数量以及防止模型过拟合,使用数据增强技术将其扩充至4141张。杂草种类如图5所示。




图5 杂草数据集
Fig. 5 Weed dataset

数据集中六类标注类别分别标注为:corn—玉米苗、huang—黄蒿、pu—芥菜、xia—夏至草、chenopodium album—灰条和cirsium setosum—刺

儿草,数据集详情如图6所示。最终将数据集按照7:1.5:1.5的比例分为train、val和test^[22]。

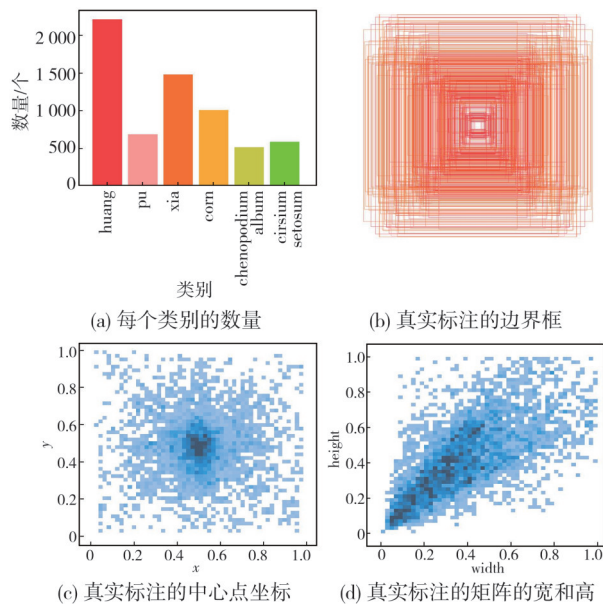


图6 数据集详情

Fig. 6 Dataset details

2.2 实验环境

操作系统为Windows 11, GPU为NVIDIA GeForce RTX 3060 Laptop GPU, 显存大小为16 GB, CPU为AMD Ryzen 7 6800H with Radeon Graphics。使用Python 3.8.18作为开发语言, torch 2.1.1作为模型开发框架。实验中,统一将输入图像的尺寸设置为640像素×640像素。初始学习率(LR)为0.01, 批处理样本大小(batch)设为8, 优化器选用Adam^[23]。根据多轮实验后趋于稳定的结果,选择将迭代次数统一设置为100轮。

2.3 模型评估指标

针对检测玉米幼苗杂草任务,使用精确率(Precision, P)、召回率(Recall, R)、平均准确率(Mean Average Precision, mAP)、参数量(Params)、每秒帧率(FPS)、浮点运算量(FLOPs)等指标^[24-25]来检验方法的有效性。P、R和mAP用来评估模型在数据集上各个类别以及整体的检测性能; Params用来衡量模型的运算规模; FPS用来衡量检测速度; FLOPs用来评估模型的计算复杂度和推理效率。

2.4 实验结果分析

通过对基准模型和改进后的模型训练100轮后,各项数据的变化曲线如图7所示。由图7的

训练曲线对比图可以看出：精确率、召回率的精度指标与基准模型的训练结果基本保持持平状态，mAP50、mAP50-95精度指标与基准模型相比有小幅提升。改进后的模型在训练集上的精确率为91.6%，召回率为92.2%，mAP50为97.0%，mAP50-95为87.9%。相对于基准模型来说，本文模型能够在保持精确率和召回率基本稳定在较高精确度的情况下，其mAP50和mAP50-95指标均有所提高。




图7 改进前后的数据对比图

Fig. 7 Comparison of data before and after improvement

图8为YOLOv8n和改进模型对随机抽取图像的部分检测结果对比。图中，灰条(chenopodium

album)、刺儿草(cirsium setosum)和玉米苗(corn)的检测可视化结果由置信度0.96, 0.57, 0.78提高到0.99, 0.73, 0.95也印证了数据指标的改善,可以看出改进模型的单张图像检测结果准确可靠,验证了改进模型能够在实现轻量化的基础上保持较高的精度指标,体现其在实际应用中的优势。




图8 YOLOv8n和改进模型的部分检测结果对比

Fig. 8 Comparison of some detection results between YOLOv8n and the improved model

3 对比实验分析

3.1 消融实验

为了验证改进模型的有效性进行了消融实验,为了便于描述轻量级主干设计、颈部轻量化设计、后处理技术优化三种改进技术,将其分别简称为M、VoV和SND。实验结果如表1所示。

表1 消融实验

Tab. 1 Ablation experiment

Network	P/%	R/%	mAP50/%	mAP50-95/%	参数量	浮点运算量/(次·s ⁻¹)	速度/(帧·s ⁻¹)
YOLOv8n	94.1	92.6	97.2	86.4	3.00×10 ⁶	8.2×10 ⁹	48.6
YOLOv8n+M	84.9	81.9	88.9	67.4	1.18×10 ⁶	5.4×10 ⁹	92.5
YOLOv8n+VoV	94.5	95.1	97.0	88.4	2.70×10 ⁶	7.4×10 ⁹	37.0
YOLOv8n+SND	91.8	91.9	96.2	84.8	3.00×10 ⁶	8.2×10 ⁹	40.0
YOLOv8n+M+VoV	91.6	89.7	95.3	83.5	1.07×10 ⁶	5.2×10 ⁹	87.4
YOLOv8n+VoV+SND	94.9	93.0	97.1	86.7	2.70×10 ⁶	7.4×10 ⁹	37.3
YOLOv8n+M+SND	85.0	84.5	89.3	72.8	1.18×10 ⁶	5.3×10 ⁹	65.3
Ours	93.0	92.6	97.4	88.1	1.08×10 ⁶	5.2×10 ⁹	92.5

结果显示：M能够有效减少模型的参数量从而提高模型的检测速度,但是降低了模型的检测精度；VoV和SND的组合使用能够稳定模型的检测精度；当三种技术同时使用时,参数量较YOLOv8n降低了64%，同时mAP50-95指标略有提升,mAP50指标与基准模型不相上下。因此,同时运用三种技术不仅可以降低模型的计算量及提高检测效率,还可以维持模型的识别准确率。总体而言,改进的YOLOv8模型相比基准模型更

适用于田间实际应用。

3.2 模型对比实验

为了验证实际场景中改进模型在轻量级和检测精度上的优势,将其在自建杂草数据集上分别与单阶段和双阶段部分检测模型进行了对比实验,结果如表2所示。

由表2中可以看出：改进模型相对于其他比较模型的参数量和浮点计算量大幅下降,相较于

YOLOv8n模型的参数量下降64%，浮点运算量下降36%；改进模型的各项评价指标相对于其他算法来说能够保持较高水平。由此可见，本文模型能够在识别精度各项指标与基准模型相持平的基

础上达到轻量化的要求，在设备内存占用和计算资源的消耗方面占有优势。单幅图像的检测速度为92.5帧/s，可以达到除草设备作业时的实时识别。

表2 不同算法的实验对比

Tab. 2 Experimental comparison of different algorithms

Network	P/%	R/%	mAP50/%	mAP50-95/%	参数量	浮点运算量/(次·s ⁻¹)	速度/(帧·s ⁻¹)
Faster-RCNN	94.9	90.4	96.7	86.0	1.284×10 ⁸	7.810×10 ¹⁰	25.16
SSD	84.9	81.9	88.9	67.4	9.260×10 ⁷	6.400×10 ⁹	47.8
YOLOv5s	93.2	89.6	96.2	85.6	7.000×10 ⁹	1.650×10 ¹⁰	132.0
YOLOv6n	81.0	77.4	82.4	63.8	4.200×10 ⁹	1.190×10 ¹⁰	133.8
YOLOv7	87.6	85.1	97.7	73.4	3.710×10 ⁷	1.043×10 ¹¹	96.0
YOLOv8n	94.1	92.6	97.2	86.4	3.000×10 ⁶	8.200×10 ⁹	48.6
Ours	93.0	92.6	97.4	88.1	1.080×10 ⁶	5.200×10 ⁹	92.5

3.3 模型泛化验证

为了进一步验证改进模型的泛化能力，以近年来新兴的公开数据集ImageWeeds^[26]中的Individual_Weed数据集作为评估对象。Individual_Weed数据集包含4种常见杂草的3422张

图像，将Individual_Weed数据集按照7:1.5:1.5的比例划分为训练集、验证集和测试集，并在测试集上评估轻量化YOLOv8模型的性能。测试结果如表3所示。

表3 不同数据集的实验对比

Tab. 3 Experimental comparison of different datasets

Datasets	Network	P/%	R/%	mAP50/%	mAP50-95/%	参数量	浮点运算量/(次·s ⁻¹)	速度/(帧·s ⁻¹)
Individual_Weed	YOLOv8n	83.0	82.4	88.4	56.8	2.87×10 ⁶	8.2×10 ⁹	34.91
Individual_Weed	Ours	82.8	81.3	89.2	57.8	1.03×10 ⁶	5.2×10 ⁹	68.61
Our datasets	YOLOv8n	94.1	92.6	97.2	86.4	3.00×10 ⁶	8.2×10 ⁹	48.60
Our datasets	Ours	93.0	92.6	97.4	88.1	1.08×10 ⁶	5.2×10 ⁹	92.50

由表3的实验结果可以看出，改进模型在Individual_Weed数据集上的精确率为82.8%，召回率为81.3%，与基准模型的检测结果不相上下，并且在mAP50-95指标和mAP50指标上略有提升。这表明，通过模型压缩和优化，在保证一定检测精度的同时提升模型的推理速度和减少模型的参数量。虽然与建数据集上的表现相比，改进模型在Individual_Weed数据集上的指标结果有所下降，但这可能与两个数据集在杂草类别和图像特点上的差异有关。即使在Individual_Weed数据集上的性能略有下降，改进模型的表现仍然较为出色，取得了较好的检测性能，体现了其在不同场景下的泛化能力。

总体来说，改进模型在Individual_Weed数据集上表现良好，也验证了本文的轻量化方法能够保持一定的泛化能力，为其适于在农田移动设备中应用提供了依据。

4 结论

针对现有检测算法模型参数量较大以及因杂草形态各异、互相遮挡等情况导致的目标检测精

度低的问题，本文提出了一种基于YOLOv8n的轻量级杂草检测算法，将主干网络替换为MobileViT网络解决了轻量化的问题。为了确保模型检测的准确性和速度设计了新的颈部，融合了轻量级卷积模块GSCConv和VoVGSCSP模块，并将后处理技术Soft-NMS与DIoU结合为Soft-NMS-DIoU作为边框回归损失函数。实验结果表明，改进算法在玉米苗期杂草数据集上的mAP50和mAP50-95分别达到97.4%和88.1%。计算复杂度的FLOPs指标和Params降低至5.2和1.08，分别比原模型少36%和64%。改进后的YOLOv8模型大幅降低了模型复杂度且能够保持较高检测精度和速度，满足将其部署到农业设备等边缘设备上的快速准确的目标检测要求，可以实现高效的杂草检测。

尽管本文的实验主要在标准计算平台上进行，尚未在移动设备上进行测试，但已明确了将这一模型无缝迁移至农业边缘设备的必要性。在未来的研究中，可以将农业边缘设备——智能除草机器人作为测试平台，评估模型在移动设备上的性能表现。同时，对模型进行优化，跨越不同计算能力阈值与

内存限制的移动设备界限,确保模型在保持卓越检测精度与响应速度的同时,尝试采用参数共享、模型剪枝等技术进一步削减冗余参数,压缩模型大小以实现模型体积的大幅缩减,从而将该模型成功部署到农业设备的边缘计算场景。

参考文献:

- [1] 李兆旭, 蒋红海, 杨肖, 等. 基于轻量化深度学习模型的豆角苗-杂草检测方法[J]. 农业装备与车辆工程, 2022, 60(9): 98-102.
LI Zhaoxu, JIANG Honghai, YANG Xiao, et al. Bean seedling-weed detection method based on lightweight deep learning model [J]. Agricultural Equipment and Vehicle Engineering, 2022, 60(9): 98-102. (in Chinese)
- [2] 袁涛, 胡冬, 马超, 等. 基于 YOLOv4 的稻田杂草目标检测算法[J]. 上海农业学报, 2023, 39(6): 109-117.
YUAN Tao, HU Dong, MA Chao, et al. An algorithm for weed target detection in rice fields based on YOLOv4[J]. Shanghai Journal of Agriculture, 2023, 39(6): 109-117. (in Chinese)
- [3] 刘斯琦. 基于机器视觉的苗期玉米作物行与行间杂草检测方法研究[D]. 哈尔滨: 东北农业大学, 2023.
- [4] RAKHMATULIN I, KAMILARIS A, ANDREASEN C. Deep neural networks to detect weeds from crops in agricultural environments in real-time: A review [J]. Remote Sensing, 2021, 13(21): 4486.
- [5] THANHLE V N, TRUONG G, ALAMEH K. Detecting weeds from crops under complex field environments based on Faster RCNN [C]//2020 IEEE Eighth International Conference on Communications and Electronics (ICCE). IEEE, 2021: 350-355.
- [6] SHEKHAWAT N, VERMA S, AGARWAL M, et al. Weed and crop detection in rice field using r-cnn and its hybrid models [C]//International Conference on Intelligent Human Computer Interaction. Cham: Springer Nature Switzerland, 2024: 37-49.
- [7] MU Y, FENG R, NI R, et al. A faster R-CNN-based model for the identification of weed seedling [J]. Agronomy, 2024, 12(11): 2867.
- [8] 王宇. 基于改进 yolov5s 模型的小麦田杂草检测研究[D]. 合肥: 安徽农业大学, 2022.
- [9] ZHANG H, WANG Z, GUO Y, et al. Weed detection in peanut fields based on machine vision [J]. Agriculture, 2022, 12(10): 1541.
- [10] 冀汶莉, 刘洲, 邢海花. 基于 YOLO v5 的农田杂草识别轻量化方法研究 [J]. 农业机械学报, 2024, 55(1): 212-222.
- JI Wenli, LIU Zhou, XING Haihua. Lightweight method for identifying farmland weeds based on YOLO v5 [J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(1): 212-222. (in Chinese)
- [11] HUA Y, XU H, LIU J, et al. A peanut and weed detection model used in fields based on BEM-YOLOv7-tiny [J]. Mathematical Biosciences and Engineering: MBE, 2023, 20(11): 19341-19359.
- [12] HU W, WANE S O, ZHU J, et al. Review of deep learning-based weed identification in crop fields [J]. International Journal of Agricultural and Biological Engineering, 2023, 16(4): 1-10.
- [13] ROMERO-GONZÁLEZ J. A comprehensive review of YOLO architectures in computer vision: from YOLOv1 to YOLOv8 and YOLO-NAS [J]. Machine Learning & Knowledge Extractio, 2023, 5(4): 1680-1716.
- [14] MEHTA S, RASTEGARI M. Mobilevit: lightweight, general-purpose, and mobile-friendly vision transformer [DB/OL]. (2022-03-04) [2024-04-22]. <https://arxiv.org/abs/2110.02178v2>.
- [15] SANDLER M, HOWARD A, ZHU M, et al. Mobilenetv2: Inverted residuals and linear bottlenecks [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510-4520.
- [16] 杨晶, 靳雁霞, 刘亚变, 等. 基于改进 Transformer 的布料材质识别方法研究 [J]. 中北大学学报(自然科学版), 2023, 44(2): 138-145.
YANG Jing, JIN Yanxia, LIU Yabian, et al. Research on fabric material recognition method based on improved Transformer [J]. Journal of North University of China (Natural Science Edition), 2023, 44(2): 138-145. (in Chinese)
- [17] LI H, LI J, WEI H, et al. Slim-neck by GSConv: A lightweight-design for real-time detector architectures [DB/OL]. (2022-06-06) [2024-04-22]. <https://arxiv.org/abs/2206.02424v3>.
- [18] BODLA N, SINGH B, CHELLAPPA R, et al. Soft-NMS-improving object detection with one line of code [C]//Proceedings of the IEEE International Conference on Computer Vision, 2017: 5562-5570.
- [19] SHEPLEY A J, FALZON G, KWAN P, et al. Confluence: A robust non-IoU alternative to non-maxima suppression in object detection [J]. IEEE Transactions

- on Pattern Analysis and Machine Intelligence, 2023, 45(10): 11561-11574.
- [20] YANG G, WANG J, NIE Z, et al. A lightweight YOLOv8 tomato detection algorithm combining feature enhancement and attention[J]. Agronomy, 2023, 13(7): 1824.
- [21] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression[J]. Proceedings of the AAAI conference on artificial intelligence, 2020, 34(7): 12993-13000.
- [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.
- 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. (in Chinese)
- [23] 韩强. 面向小目标检测的改进 YOLOv8 算法研究 [D]. 长春: 吉林大学, 2023.
- [24] 刘子洋, 徐慧英, 朱信忠, 等. Bi-YOLO: 一种基于 YOLOv8 改进的轻量化目标检测算法[J/OL]. 计算机工程与科学, 2024, 46(8): 1444-1454.
- LIU Ziyang, XU Huiying, ZHU Xinzhong, et al. Bi-YOLO: An improved lightweight object detection algorithm based on YOLOv8n [J]. Computer Engineering and Science, 2024, 46(8): 1444-1454. (in Chinese)
- [25] 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. A lightweight model for wheat leaf pest and disease detection based on improved YOLOv8 [J]. Smart Agriculture, 2024, 6(1): 147-157. (in Chinese)
- [26] RAI N, MAHECHA M V, CHRISTENSEN A, et al. Multi-format open-source weed image dataset for real-time weed identification in precision agriculture [J]. Data in Brief, 2023, 51: 109691.