

基于改进 YOLO v8n 的田间玉米杂草快速识别方法

齐江涛^{1,2} 吕明阳^{1,3} 王 硕^{2,3} 郭 慧^{1,2} 邹宗峰⁴ 熊悦淞^{1,2}

(1. 吉林大学工程仿生教育部重点实验室, 长春 130022; 2. 吉林大学生物与农业工程学院, 长春 130022;
3. 吉林省智慧农业装备与技术重点实验室, 长春 130000; 4. 烟台市农业技术推广中心, 烟台 265499)

摘要: 玉米是东北黑土区主要粮食作物, 苗期常受伴生杂草威胁, 化学和机械除草作为重要的中耕管理手段, 其实实施效果对黑土地保护意义重大, 杂草防治需以高效精准的杂草识别技术为基础。为实现玉米田间多行作物环境下杂草高效精准识别, 以东北黑土区 2~5 叶期玉米幼苗及其早期伴生杂草为对象, 提出了一种基于改进 YOLO v8n 的玉米杂草高效精准识别算法。通过将 YOLO v8n 模型主干网络替换为 GhostNet 轻量特征提取网络, 简化了模型特征提取流程并缩减了模型参数量; 通过引入优化的加权双向特征金字塔结构 (Bidirectional feature pyramid network, BiFPN), 并在颈部网络最后一层引入轻量注意力机制 (Triplet Attention), 增强了模型信息获取能力, 提高了模型泛化能力; 通过将损失函数替换为 Wise-IoU v3, 进一步提高了模型精度。试验结果表明, 改进 YOLO v8n 平均精度均值达 97.8%, 相较于原始模型, 改进模型参数量降低 37.90%, 检测速度、平均精度均值、精确率和召回率分别提高 32.10%、0.65 个百分点、1.85 个百分点和 1.40 个百分点。与主流检测模型相比, 检测速度相较于 YOLO v5n、YOLO v6n、Faster R-CNN、YOLO v9t 和 YOLO v10n 分别提高 26.38%、33.80%、591.89%、96.58% 和 53.93%。该方法满足除草机器人等移动端部署要求, 为东北黑土地保护性耕作中耕管理环节智能化机械除草和精准对靶施药提供了技术支持。

关键词: 玉米; 杂草; 图像处理; YOLO v8n; 识别

中图分类号: TP391.4

文献标识码: A

文章编号: 1000-1298(2026)10-0275-12

OSID:



Corn and Weeds Faster Identification Method Based on Improved YOLO v8n in Field

QI Jiangtao^{1,2} LÜ Mingyang^{1,3} WANG Shuo^{2,3} GUO Hui^{1,2} ZOU Zongfeng⁴ XIONG Yuesong^{1,2}

(1. Key Laboratory of Bionic Engineering, Ministry of Education, Jilin University, Changchun 130022, China

2. College of Biological and Agricultural Engineering, Jilin University, Changchun 130022, China

3. Smart Agriculture Equipment and Technology Key Laboratory of Jilin Province, Changchun 130000, China

4. Yantai Agricultural Technology Extension Center, Yantai 265499, China)

Abstract: Corn is one of the three major grain crops in China, and precise application of weeds at the seedling stage is crucial to ensure its yield and quality. Weeds in the seedling stage compete with corn for sunlight, water, and nutrients, seriously affecting the normal growth of corn and even leading to yield reduction or death. Therefore, accurate and fast weed identification is the basis for precise weed control. Existing weed recognition in field environments is mostly based on small field-of-view image datasets, and few studies related to corn weed recognition in field multi-row environments are seen. In the field multi-row environment, because a single image data can cover multiple rows of crops at the same time, the number of target objects is dense, and the recognition range of weeds is larger in a single detection. However, because a variety of weeds are common in the seedling stage of corn, and the weeds and crops overlap each other, the image data in the multi-row environment is more complex, and it is more difficult to control the detection accuracy and computational volume of the conventional model. To address the

收稿日期: 2025-02-17 修回日期: 2025-03-18

基金项目: 国家自然科学基金面上项目(32271988)、吉林省重点研发计划项目(20220202028NC)和吉林省中青年科技创新创业卓越人才团队项目(20230508032RC)

作者简介: 齐江涛(1981—),男,教授,博士生导师,主要从事精准农业与仿生智能农机装备研究,E-mail: qijiangtao@jlu.edu.cn

通信作者: 郭慧(1988—),女,高级工程师,博士,主要从事农机触土部件及智能农业机械研究,E-mail: guohui6520@jlu.edu.cn

above problems, northeast seedling corn was taken as the research object. The corn seedling and weed datasets used for model training and containing both single and multi-targets were collected, and data enhancement operations were performed on the datasets. The specific main content was to address the problem of insufficient target detection speed in the process of precision application and weed control, which led to the deviation of target application. A field corn weed identification method with an improved YOLO v8n model was proposed by using a northeastern corn field as the research object. By collecting pictures of corn seedlings and weeds in the field under the range of multiple rows as a training set, which included single weeds, multiple weeds of multiple species, and the coexistence of corn seedlings and weeds, the backbone network of the YOLO v8 model was replaced by the GhostNet lightweight feature extraction network to simplify the feature extraction process and reduce the number of model parameters. The weighted bidirectional feature pyramid network (BiFPN) was introduced to enhance the information acquisition ability of the model. Triplet Attention, a lightweight attention mechanism, was introduced into the neck network of the model, and the loss function was replaced with Wise-IoU v3 to improve the generalization ability and fine reading of the model. The experimental results showed that compared with the original model, the improved model parameter count was reduced by 37.90%, the detection speed was increased by 32.10%, the mean average precision (mAP) was improved by 0.65 percentage points, the precision was improved by 1.85 percentage points, and the recall was improved by 1.40 percentage points. The research results can provide a basis for decision-making in herbicide reduction application.

Key words: corn; weeds; image processing; YOLO v8n; identification

0 引言

东北黑土区地处世界三大黄金玉米带之一,占全国耕地面积的15.4%^[1],在我国粮食安全中占据举足轻重的地位。保护性耕作技术在保持土壤肥力、改善土壤结构、涵养土壤水分等方面具有积极作用^[2],但同时也给杂草生长制造了温床。杂草防治作为保护性耕作实施过程的重要技术环节,应尽量采用机械除草,并尽可能地减少化学防治对土壤污染^[3]。玉米苗期,尤其是2~5叶期,幼苗光合作用逐渐成为主要能量和物质来源,此时伴生杂草争夺光照、水分和养分,更易使幼苗受到侵害,影响植株正常生长和产量,严重时会导致植株死亡和减产^[4]。机械和化学除草是维持该时期植株良好长势必不可少的田间管理作业环节,但机械除草对杂草识别精度要求高,化学除草常存在过量施用、成本高且易造成杂草抗药性和有害物残留的问题。因此,实现田间玉米2~5叶期的杂草精准快速识别,对杂草防控、化肥农药减施、作物保产及黑土地保护均具有重要意义^[5]。

常用的杂草检测方法包括传统图像处理和深度学习技术^[6-8]。早期研究多以传统图像处理技术为主,并在检测目标 and 环境具有较大形态差异的应用领域取得了较好效果。周平等^[9]提出的基于RGB分量运算和色域位屏蔽压缩的实时目标检测方法,可实现收获季节对水稻群体目标图像分割和不同生长期同类单植株图像实时分割。张春龙等^[10]利用超绿像素提取方法识别作物行苗株坐标,使锄刀实

现了避苗除草作业。

由于传统图像处理技术对复杂环境适应性差、泛化能力有限,玉米苗期幼苗和多种杂草并存,幼苗和部分杂草形态结构差异不大,目标交叠、遮挡现象频发,单纯依靠传统图像处理技术很难提升玉米苗期杂草检测速度和精度提升^[11-12]。基于深度学习的计算机视觉方法在目标识别准确性和泛化能力的优秀表现,使其成为当前农田复杂环境下的热门检测方法。王璨等^[13]提出一种基于卷积神经网络提取多尺度分层特征识别玉米杂草的方法,可实现2~5叶期单株玉米幼苗图像中玉米幼苗和杂草识别,有效减少了多个目标交叠问题。孙俊等^[14]提出了一种空洞卷积与全局池化相结合的多尺度特征融合网络,用于识别12种农作物幼苗和杂草,解决了传统 Alex Net 模型参数大、特征尺度单一的问题,但对复杂或光线不佳背景下幼苗识别性能还有待提高,且模型在实时检测速度上也不理想^[15]。

随着轻量级卷积神经的发展,YOLO网络模型成为目标检测领域的主流模型,王秀红等^[16]基于YOLO v5改进模型算法,提出一种适用于 Jetson TX2 移动端部署的秸秆覆盖农田杂草检测方法,检测精度达93.6%,检测速度达28.33 f/s。LI等^[17]基于轻量级YOLO v4-tiny模型提出了一种结合注意力机制和空间金字塔池化结构的玉米杂草检测模型,对自然环境中玉米幼苗及其伴生杂草平均检测精度为86.69%,检测速度为57.33 f/s。SAPKOTA等^[18]基于YOLO v4构建棉花田间杂草检测模型,并评价了该模型对同种杂草跨作物检测能力,玉米

和大豆田间杂草检测结果表明,相同模型对其他作物田间杂草检测精度表现不同,通过添加跨作物田间图像训练模型,可改善模型对交叉作物适用性。YING 等^[19] 将 YOLO v4 骨干网络替换为 MobileNetV3 Small 神经网络,提出了一种 YOLO v4-weeds 的轻量级杂草检测模型,可用于胡萝卜田间 4 种杂草精确检测,检测精度达 89.11%,提高了复杂环境下小杂草检测效率和准确性。

基于图像处理技术的田间小视野范围内作物杂草检测已取得了一定成效,但对于田间多行作物同时存在时杂草检测,因单个图像数据涵盖检测目标数量和识别范围的增加,加之玉米苗期多种类杂草并存,杂草间及杂草和作物交错重叠,使得玉米苗期多行环境下图像数据更为复杂,对玉米苗期大视野环境下杂草识别精度和检测速度相关研究仍有很大提升空间^[20-22]。本文基于 YOLO v8n,以东北黑土区玉米田间 2~5 叶期玉米苗和杂草为研究对象,对田间多行作物环境下杂草目标检测模型进行轻量化改进,以减少模型计算冗余,实现田间多行作物环境下玉米杂草高精度和高效率识别,以期玉米苗期精准/对靶施药和精准除草作业提供辅助性技术支持。

1 材料与方法

1.1 图像采集与预处理

1.1.1 图像采集

数据于 2023 年 5 月 29 日至 6 月 3 日(每 2 d 采集 1 次,共采集 3 次)在吉林大学农业实验基地(125°15'16.348"E,43°57'6.912"N)采集。采集设备包括佳能 EOS M50 型数码相机,海康 MV-CS200-10GC 型工业相机并配置 ZX-SF1224TC 型镜头,如图 1 所示。




图 1 田间图像采集平台
Fig. 1 Image acquisition platform

试验图像数据为 2~5 叶期玉米与早期伴生杂草图像和视频数据,杂草主要包括稗草、苘麻、铁苋菜、菎草等。为了提高目标数据多样性和模型泛化能力,在工业相机距垂直离地高度 1 m 处不同光线条件(12:00 和 16:00)、镜头角度(0°和 45°)下采集单株杂草、玉米苗遮挡杂草、多种杂草和仅有玉米幼苗等图像数据。图像分辨率为 6 000 像素×4 000 像素,共采集图像 600 幅、视频 8 个,其中 600 幅图像数据作为原始图像用于数据增强,8 个视频用于改进模型性能评估,部分图像如图 2 所示;采集的图像数据分为训练集、测试集和验证集,数据集划分如表 1 所示。

1.1.2 图像特征增强

为改善模型训练效果,提高原始数据集多样性,在 Python 编程环境下采用 imgaug 库进行数据增强,对原始 600 幅图像数据集进行随机旋转、添加噪声、亮度增强、裁剪和缩放等操作,如图 3 所示,经数据增强后图像总计 6 340 幅。

1.1.3 数据集标注与划分

对增强后数据利用 LabelImg 工具制作 VOC 格




图 2 部分采集图像
Fig. 2 Part of image collection

表 1 数据集划分
Tab.1 Dataset distribution

类别	图像	图像数量
训练集	单株杂草	870
	仅有玉米苗	230
	玉米遮挡杂草和多种杂草分布	3 972
验证集	玉米遮挡杂草和多种杂草分布	634
测试集	单株杂草、玉米遮挡杂草和多种杂草分布	634




图 3 数据增强示例
Fig.3 Data expansion example

1.2 玉米幼苗和杂草识别方法

1.2.1 YOLO v8n 模型改进

针对 YOLO v8 模型参数量大、检测时间长等问题,通过替换主干网络为 GhostNet,引入优化 BiFPN 为特征融合层,且在颈部网络最后一层引入 Triplet Attention,最后替换损失函数为 Wise-IoU,有效降低模型参数量和体积,提高有效信息特征提取能力,改善模型对大视野环境下小目标检测准确率,总体提升模型检测能力和速度,YOLO v8-GBT 网络结构如图 4 所示。

(1)轻量化 GhostNet 特征提取网络

YOLO v8 采用的 C2f 模块通过卷积操作和 Bottleneck 模块迭代^[23],将输入特征图信息进行提取、融合,从而提高目标检测准确率,但未充分考虑

式数据集,框选玉米幼苗、稗草、苘麻、葎草和铁苋菜,标注标签分别为“maize”“barnyard_grass”“abutilon_theophrasti”“humulus_scandens”“acalypha_australis”,每幅图像生成对应的 xml 文件。将标注完毕的数据集按照训练集、验证集和测试集以比例 8:1:1 进行划分(表 1)。xml 文件包含植物名称和位置信息。

特征冗余情况,导致模型体积增大,运算速度较慢。针对田间环境下玉米杂草数据,为充分提取数据有效特征、降低模型体积,采用 GhostNet 作为主干网络,同时使用 GhostNet 中的模块降低颈部网络参数,具体为替换主干网络和颈部网络中的 CBS 和 C2f 分别为 GhostNet 网络中的 GhostCBS 和 C2fGhost,如图 5、6 所示。其中, GhostCBS 由 GhostConv、BN、SiLU 组成; C2fGhost 由多个 G-bneck 模块组成^[24], G-bneck 模块通过 Ghost 模块堆叠而成, Ghost 模块主体为 GhostConv。 GhostConv 由 Conv、分组卷积(Group convolution)和恒等映射(Identity)3 部分组成, GhostConv 输入特征先经过卷积核为 1×1 的 Conv 进行特征提取,得到一定数量的内在特征图后,经 Group convolution 和 Identity 生




图 4 YOLO v8-GBT 网络结构
Fig.4 YOLO v8-GBT network structure

成多维特征图,最后进行通道维度堆叠,获取输出特征图,如图 7 所示。




图 5 GhostCBS 结构
Fig. 5 GhostCBS structure




图 6 C2fGhost 结构
Fig. 6 C2fGhost structure




图 7 普通卷积和 GhostConv 结构
Fig. 7 Conv and GhostConv structure

由图 7 可知,当输入 n 幅特征图时,GhostConv 具有一个 Identity,即通过 Conv 得到 m 幅特征图和 $m(s-1) = \frac{(s-1)n}{s}$ 个线性运算,其中 $n = ms$,每个线性运算卷积核尺寸为 $d \times d$, s 远小于 c ,推导出相较于普通 Conv 模块 GhostConv 理论加速比为

$$r_s = \frac{nh'\omega'cdd}{\frac{n}{s}h'\omega'cdd + (s-1)\frac{n}{s}h'\omega'dd} \approx \frac{sc}{s+c-1} \approx S \quad (1)$$

其参数压缩比为

$$r_c = \frac{ncdd}{\frac{n}{s}cdd + (s-1)\frac{n}{s}dd} \approx \frac{sc}{s+c-1} \approx S \quad (2)$$

式中 h' ——输出特征图高度
 ω' ——输出特征图宽度
 s, c ——超参数
 S ——输出特征图尺寸

由式(1)、(2)可知,采用 GhostConv 模块在理论上可节约 S 倍训练时间,缩减 S 倍参数量。

(2)加权双向特征金字塔融合网络 BiFPN

YOLO v8n 采用 PANet^[25] 和 FPN^[26] 的方式进行特征融合,通过横向连接和金字塔状层次结构融合各个尺度的特征信息,形成特征金字塔网络。但提取不同尺度特征时存在信息丢失和信息冗余,导致模型检测精度降低。为提升模型检测精度,采用鲁棒性强的加权双向特征金字塔融合网络 (BiFPN),BiFPN 通过引入双向流动特征信息,逐层融合上下特征图,同时引入横向连接和纵向连接 2 种方式,使不同尺度特征有效融合^[24],有效克服在处理尺度变化和苗草遮挡等导致精度降低的问题,结构如图 8a 所示。




图 8 BiFPN 网络模型
Fig. 8 BiFPN network models

原始模型中 BiFPN 采用 5 进 5 出结构,但由于 YOLO v8n 输出通道为 3 个,5 个通道的输出并不适用于 YOLO v8n 模型,因此本文将 BiFPN 层数由 5 进 5 出改为 3 进 3 出,使其更适配 YOLO v8n 模型,增强对图像特征的提取能力。此外,为了更好地提取多目标特征,在 P3、P4 层连接中增加跳跃连接;特征连接方式采用 Concat 拼接,保留各层次特征信息。优化后 BiFPN_Contact2 如图 8b 所示。

(3)轻量化注意力机制

为进一步提高在田间不同环境下模型泛化能力,在特征融合层后引入轻量化注意力机制 (Triplet Attention),解决传统注意力机制在计算通道注意力过程中因将输入张量在空间上通过池化转为像素造成大量空间信息丢失的问题。Triplet Attention 在单像素通道上计算注意力时,增加通道和空间维数之

间的相互依赖性,通过捕捉跨维度交互信息,可有效提高目标检测模型性能^[25]。

Triplet Attention 由 3 个分支组成,结构如图 9 所示。当 3 个分支输入均为 X ,第 1 分支,先沿输入张量 X 的高 H 逆时针旋转 90° ,再经过 Z-Pool 池化操作,通道宽 W 维度缩减为 2,即获取维度上的最大特征值和平均特征值。再将该二维张量通过一个卷积核大小为 $k \times k$ 的标准卷积层 Conv,进行批归一化处理,随后经过一个 Sigmoid 激活层生成注意力权重,并将输出张量沿第 1 步中的高 H 或宽 W 顺

时针旋转 90° ,以保持输出张量与输入张量 X 尺寸相同。第 2 分支,先沿输入张量 X 的宽 W 逆时针旋转 90° ,再经过 Z-Pool 池化操作,通道高 H 的维度缩减为 2,后与第 1 分支处理方法相同。在第 3 个分支中去除了旋转操作,先将输入张量 X 的通道经过 Z-Pool 池化层直接减少到 2,再通过一个卷积核尺寸为 k 的标准卷积层 Conv,进行批量归一化处理,输出张量通过 Sigmoid 激活层生成尺寸为 $1 \times H \times W$ 的注意力权重。最后,将 3 个分支输出张量取平均值,获得张量 Y 。




图 9 Triplet Attention 模型结构
Fig. 9 Triplet Attention model structure

(4) Wise-IoU v3 损失函数

YOLO v8n 模型采用 CIoU 损失函数,主要关注预测框与真实框之间的交并比(IoU),并不能完全捕捉目标之间相对位置和大小差异,导致模型检测性能提升受阻^[27]。将损失函数替换为 Wise-IoU v3 损失函数,检测精度和定位性能超越了传统的 CIoU。

Wise-IoU v3 是基于距离度量构造的两级注意力机制,构造了基于注意力的边界框损失^[28],解决了低质量数据集不可避免地会对模型产生负面影响,为了避免数据集质量过低导致的有害梯度,假设 (x,y) 在目标框的位置 (x_{gt},y_{gt}) ,Wise-IoU v3 计算式为

$$L_{WIoUv3} = rR_{WIoU}L_{IoU} \tag{3}$$

其中
$$r = \frac{\beta}{\delta \alpha^{\beta-\delta}} \tag{4}$$

$$\beta = \frac{L_{IoU}^*}{L_{IoU}} \in [0, +\infty) \tag{5}$$

$$R_{WIoU} = \exp\left(\frac{(x-x_{gt})^2 + (y-y_{gt})^2}{(W_g^2 + H_g^2)^*}\right) \tag{6}$$

$$L_{IoU} = 1 - IoU = 1 - \frac{W_iH_i}{S_u} \tag{7}$$

式中 W_g ——预测框和真实框最小外接矩形宽

H_g ——预测框和真实框最小外接矩形高
 β ——离群度
 R_{WIoU} ——Wise-IoU 损失的核心权重
 L_{IoU} ——Wise-IoU 基础损失
 r ——非单调聚焦系数
 S_u ——预测框与真实框并集面积
 α, δ ——超参数
 L_{IoU}^* ——单调聚焦系数
 $\overline{L_{IoU}}$ ——动量滑动平均值

该损失函数可有效提高收敛效率,并在边界预测框与真实框重合较好的情况下降低对中心点距离的关注,提高模型泛化能力。其动态更新使整体 β 保持较高水平,可有效解决训练后期收敛速度较慢的问题。采用 Wise-IoU v3 损失函数通过权衡低质量示例和高质量示例学习提高检测器整体性能。

1.2.2 试验环境和评价标准

针对多行环境下玉米幼苗和杂草数据集的训练和测试试验硬件环境如表 2 所示,训练过程使用 YOLO v8n 作为基线模型,调整输入图像尺寸至 640 像素×640 像素,训练参数如表 3 所示。

选用精确率(Precision, P)、召回率(Recall, R)和平均精度均值(Mean average precision, mAP)作为

表 2 硬件环境参数

Tab.2 Hardware environment parameters

硬件	配置
CPU	12th Gen Intel Core i5 12500H@ 3.5 GHz
操作系统	64 位 Win11
编译软件	Pycharm 24.2.3
CUDA	11.7 版本
深度学习框架	Pytorch 2.0.0
显卡	NVIDIA GeForce RTX 3050Ti,8 GB

表 3 训练参数

Tab.3 Training parameters

参数	数值
初始学习率	0.000 1
优化器	SGD
优化器动量	0.937
优化器权重衰减系数	0.000 5
线程	4
训练批次	16
迭代周期	400

表 4 消融试验结果

Tab.4 Ablation test

试验	基线网络	GhostNet	BiFPN	Triplet Attention	Wise – IoU	平均精度 均值/%	精确率/ %	召回率/ %	模型内存占 用量/MB	参数量
1	YOLO v8n	×	×	×	×	97.15	95.15	93.00	6.20	3.20×10^6
2	YOLO v8n	✓	×	×	×	96.80	96.20	92.99	4.00	1.80×10^6
3	YOLO v8n	×	✓	×	×	97.40	95.00	94.90	6.40	3.06×10^6
4	YOLO v8n	×	×	✓	×	97.40	95.60	92.90	6.30	3.01×10^6
5	YOLO v8n	×	×	×	✓	97.30	96.20	94.50	6.20	3.20×10^6
6	YOLO v8n	✓	✓	×	×	97.00	95.60	93.00	5.10	2.41×10^6
7	YOLO v8n	✓	×	✓	✓	97.60	96.30	92.70	4.00	1.82×10^6
8	YOLO v8n	✓	✓	×	✓	97.60	96.10	93.90	5.10	1.86×10^6
9	YOLO v8n	✓	✓	✓	✓	97.80	97.00	94.40	4.10	1.87×10^6

注：✓表示使用算法，×表示未使用算法。

由表 4 可知,试验 2 在 YOLO v8n 中将主干网络替换为 GhostNet 后,模型参数量缩小 40.20%,模型内存占用量减少 35.50%,但召回率和平均精度有所下降,其原因在于 GhostNet 中的 Ghost 卷积操作省去了复杂的冗余信息提取过程,有效减小模型内存占用量和计算成本的同时,丢失通道中可能含有少量特征所致;试验 3 在颈部网络引入 BiFPN 后,模型召回率和平均精度均值均有所提升,表明 BiFPN 网络可提高模型的拟合程度和模型识别精度;试验 4 引入 Triplet Attention 后,模型参数量变化不明显,模型召回率下降 0.1 个百分点,但模型平均精度均值和精确率分别提高 0.25、0.45 个百分点,表明轻量级神经网络在不增加模型参数量的前提下能够提高模型检测精度;试验 5 将损失函数替换为 Wise – IoU 后,模型平均精度均值、精确率和召回率分别提高 0.15、1.05、1.5 个百分点,模型内存占用

评价指标,在模型检测性能方面选用参数量、模型内存占用量、检测速度和浮点运算量作为衡量指标。其中 P 、 R 、mAP 越大,模型检测精度、定位和识别效果越好^[29–30]。

2 试验结果与分析

2.1 消融试验

消融试验结果如表 4 所示,利用 GhostNet 作为主干网络后,大大降低了模型参数量和模型内存占用量。采用 BiFPN 特征融合网络增加不同层次间双向跨尺度连接和带权重的特征融合,提高了模型检测平均精度均值,精确率、参数量和模型内存占用量变化不明显。通过轻量化注意力模块 Triplet Attention 丰富模型在特征信息上的关注程度,提升了模型检测精确率、平均精度均值等。利用 Wise – IoU 损失函数提供合理的梯度增益分配策略,提升了模型平均精度均值、精确率、召回率等。

量和参数量不变。

试验 6、7、8 在将主干网络替换为 GhostNet 的基础上,分别加入 BiFPN、Triplet Attention 和 Wise – IoU、BiFPN 和 Wise – IoU,其中试验 6、7 与试验 2 相比,平均精度均值分别提高 0.2、0.8 个百分点,召回率变化不大。试验 6、8 与试验 3 相比,精确率分别提高 0.6、1.1 个百分点。试验 7 与试验 4 相比,精确率增加 0.7 个百分点。试验 7、8 与试验 5 相比参数量分别下降 1.38×10^6 和 1.34×10^6 。结合试验 9 可知,BiFPN 可提高模型召回率和平均精度均值,与试验 7 相比,平均精度均值、精确率和召回率分别上升 0.2、0.7、1.7 个百分点,参数量增加 5×10^4 。Triplet Attention 可提高模型定位框精度,与试验 8 相比,平均精度均值、精确率和召回率分别上升 0.20、0.90、0.50 个百分点,模型内存占用量下降 1 MB,参数量变化不大。

2.2 不同轻量化网络模型性能

以 YOLO v8 目标检测网络为基础网络,分别采用 GhostNet、ShuffleNet、MobileNetV3 和 VanillaNet 轻量级主干网络作为模型的主干结构特征,在保持除主干网络外其他参数一致的基础上,基于不同主干网的 YOLO v8n 杂草检测结果如表 5 所示。

表 5 不同轻量化卷积神经网络性能

Tab.5 Performance of different lightweight convolutional neural networks						
主干网络	参数量	浮点运算量	平均精度均值/%	精确率/%	召回率/%	检测速度/(f·s ⁻¹)
C2f	3.20×10 ⁶	8.20×10 ⁹	97.15	95.15	93.00	36.20
VanillaNet	2.00×10 ⁶	5.50×10 ⁹	95.18	93.82	91.45	27.90
ShuffleNet	1.70×10 ⁶	5.00×10 ⁹	89.52	90.52	80.70	23.00
MobileNetV3	2.30×10 ⁶	5.70×10 ⁹	92.60	88.30	85.50	24.60
GhostNet	1.80×10 ⁶	6.30×10 ⁹	96.80	96.20	92.99	44.26

由表 5 可以看出,使用 GhostNet 作为轻量级主干网络,相较于 C2f (原模型)、VanillaNet、ShuffleNet、MobileNetV3,在模型训练精确率和检测速度方面具有较大优势,而平均精度均值和召回率与训练过程中模型特征提取时间有关,由于参数量降低加快了特征提取时间,进而使模型忽略一些细节特征,但总体来看,平均精度均值和召回率的降低并不影响采用 GhostNet 网络的优势。精确率较上述网络分别提升 1.05、2.38、5.68、7.90 个百分点,检测速度较上述网络分别提升 8.06、16.36、21.26、19.66 f/s。部分轻量化模型改进网络参数量和浮点运算数小于本方法,但模型提取特征能力较差,不能满足边缘计算端部署要求。

2.3 损失函数

YOLO v8n 模型使用 CIoU 损失函数,虽然具有较好的模型拟合能力,但由于预测框高宽比描述是一个相对值,对回归损失不利。为了验证所采用 Wise-IoU 损失函数的有效性,对 YOLO v8n 模型采用 Wise-IoU、GIoU、CIoU、SIoU 和 MPDIoU 损失函数时进行模型检测精度和检测帧率试验。

由表 6 可以看出,采用 Wise-IoU 后,模型检测速度、平均精度均值和召回率均较佳,检测速度分别较 CIoU、MPDIoU、GIoU、SIoU 损失函数提升 22.43%、9.64%、14.37%、18.50%。精确率仅低于 GIoU 损失函数 0.64 个百分点,但较原模型 CIoU 损失函数提升 0.70 百分点。综合评估下,采用 Wise-IoU 损失函数在模型检测精度和检测速度面综合表现较好。

表 6 不同损失函数试验结果

Tab.6 Model effects of different loss functions				
损失函数	检测速度/ (f·s ⁻¹)	平均精度 均值/%	精确 率/%	召回 率/%
YOLO v8n + CIoU	36.20	97.15	95.15	93.00
YOLO v8n + MPDIoU	40.42	97.04	95.81	92.24
YOLO v8n + GIoU	38.75	97.30	96.49	92.96
YOLO v8n + SIoU	37.40	97.16	95.58	93.77
YOLO v8n + Wise-IoU	44.32	97.34	95.85	94.25

同时对 YOLO v8n - GBT 模型采用 GIoU、SIoU、DIoU、MPDIoU、CIoU 和 Wise-IoU 损失函数时收敛情况试验,结果如图 10 所示。由图 10 可知,采用 MPDIoU 时,收敛速度最慢,且收敛后损失值最高;采用 DIoU 和 SIoU 收敛速度略高于 DIoU,收敛后损失值略低于 DIoU;采用 Wise-IoU 后,训练时模型梯度下降速度最快,在前 50 轮迭代周期快速收敛,收敛后损失值远小于另外 5 种损失函数,结合表 6 可知,采用 Wise-IoU 后,准确率、召回率、平均精度均值等均有提升。




图 10 不同损失函数收敛曲线

Fig.10 Comparison of improved loss function

2.4 模型特征可视化

为了更加直观地观察模型在替换特征融合网络为 BiFPN 特征融合层,并在其后引入 Triplet Attention 注意力机制对提升模型识别能力的效果,采用 Grad-CAM 绘制热力图^[31],可较直观地观测模型改进前后检测效果,如图 11 所示。

由图 11 可知,在引入 Triplet Attention 注意力机制和 BiFPN 结构前模型对苘麻叶片的关注并不好,当出现多个目标时,模型仅关注到当前检测到的单个物体,当添加优化的 BiFPN 结构后明显增强了模型图像特征提取能力,使其在检测当前物体的同时关注区域内存在相似物体,当引入 Triplet Attention 注意力机制后模型更加关注全局中所存在的同一目标物体的形状特征,尤其是关注到每一株苘麻叶片特征部位。因此加入 Triplet Attention 注意力机制和 BiFPN 特征融合网络对模型特征感兴趣区域聚焦能力有明显提升。




图 11 添加 BiFPN 和 Triplet Attention 前后的热力图

Fig. 11 Heat map before and after adding BiFPN and Triplet Attention

2.5 检测模型性能试验

为了定量比较改进模型在目标检测方面的性能,将改进的 YOLO v8 - GBT 模型与 YOLO v5n、

YOLO v6n 和 YOLO v8n、Faster R - CNN 等主流目标检测网络模型进行试验,结果如表 7 所示。

由表 7 可知,改进 YOLO v8 模型在浮点运算

表 7 不同模型性能试验结果

Tab. 7 Comparative experiments of different models

模型	浮点运算量	平均精度均值/%	精确率/%	召回率/%	检测速度/(f·s ⁻¹)	模型内存占用量/MB
YOLO v5n	7.10 × 10 ⁹	96.37	94.17	92.71	37.83	5.01
YOLO v6n	1.18 × 10 ¹⁰	86.66	90.42	80.47	35.73	8.27
Faster R - CNN	5.42 × 10 ¹⁰	89.76	72.06	84.91	6.91	108.00
YOLO v9t	7.60 × 10 ⁹	80.50	84.70	74.40	24.32	4.70
YOLO v10n	8.20 × 10 ⁹	78.70	83.60	69.80	31.06	5.80
YOLO v8n	8.20 × 10 ⁹	97.20	95.20	93.00	36.20	6.20
YOLO v8 - GBT	5.60 × 10 ⁹	97.80	97.00	94.40	47.81	4.10

量、平均精度均值、精确率、召回率、检测速度和模型内存占用量表现均优于其他模型,其中平均精度均值比 YOLO v5n、YOLO v6n、Faster R - CNN、YOLO v9t、YOLO v10n、YOLO v8n 分别高 1.43、11.14、8.04、17.30、19.10、0.6 个百分点,模型内存占用量相较于 YOLO v5n、YOLO v6n、Faster R - CNN、YOLO v9t、YOLO v10n、YOLO v8n 分别减少 17.76%、50.42%、96.20%、12.77%、29.31%、33.87%,检测速度相较于 YOLO v5n、YOLO v6n、Faster R - CNN、YOLO v9t、YOLO v10n、YOLO v8n 分别提高 26.38%、33.80%、591.89%、96.58%、53.93%、32.07%。改进 YOLO v8 - GBT 模型具有较好实时检测性能和检测精度,可以较好地实现田间多行范围内玉米幼苗和杂草检测 and 定位。

为了衡量改进模型和原模型检测效果,选定采集的田间玉米幼苗和杂草视频进行逐帧提取,对部分提取的图像分别使用 YOLO v8n 模型和 YOLO v8 - GBT 模型进行检测,部分检测结果如图 12 所示。

对比图 12a 和图 12b,原模型错检 1 个、漏检 0 个,改进后模型无错检和漏检情况;对比图 12c 和图 12d,原模型错检 1 个、漏检 4 个,改进后模型错检 0 个、漏检 1 个;对比图 12e 和图 12f,原模型错检 1 个、漏检 3 个,改进后模型错检 0 个、漏检 1 个。




图 12 改进前后模型检测结果

Fig. 12 Model testing effect before and after improvement

可以看出,由于图像中存在杂草遮挡、多种杂草共存和单株杂草等情况,原模型对图像中杂草和幼苗检测时的错检和漏检情况明显多于改进 YOLO v8n 模型。且在多目标图像中,原模型重复识别情况较为严重,原始模型将图像中部分杂草误识别为玉米幼苗,对多种杂草重叠的识别效果也较差。

3 种条件下改进 YOLO v8n 模型在检测精度上均表现较佳,可满足田间多行环境下玉米杂草实时检测要求。

2.6 田间作业性能验证试验

为了进一步验证 YOLO v8 - GBT 模型田间实际作业效果,2024 年 6 月在吉林大学农业实验基地进行了实时检测性能验证试验。由 YOLO v8 - GBT 模型检测速度可知,实际作业时相机最大帧率需大于等于 47.81 f/s,且移动平台运行速度不宜过快。因此,选用 DELL G15 (NVIDIA GeForce RTX 3050Ti 型显卡)硬件平台搭配 USB 网络摄像机(海康威视 DS - UVC - U178R 型,最大帧率为 60 f/s),并将硬件平台安装在团队自主研发的施药机前方,固定相机离地高度为 1 m,此时相机视野约为 130 cm × 80 cm。检测过程,为保证植株图像连续性和清晰度,设置相机视频帧率为 60 f/s,分辨率为 1 920 像素 × 108 像素,施药机前进速度为 1.2 m/s(图 13)。




图 13 田间实时检测
Fig. 13 Real-time field detection

作业时,植保施药机采用远程遥控控制,相机采集到的视频数据可经 USB 数据线直接传输给硬件平台进行实时检测,由于田间环境的影响,相机实际作业帧率为 49 f/s,因此采取每 49 帧(即 1 s)提取一次视频图像并进行检测和结果保存。通过随机抽取 10 幅检测结果,检测正确率为 88.67%,漏检率为 7.13%,误检率为 4.20%,部分检测结果如图 14 所示。相较于实验室条件下检测结果,田间实时检测结果正确率有所下降,主要是因为田间施药机行走时造成相机画面抖动和用于信息处理的硬件平台在户外作业性能不足。但综合田间作业性能验证试验结果,构建的 YOLO v8 - GBT 模型检测精度和时




图 14 部分检测结果
Fig. 14 Partial test results chart

效依然符合实时检测要求,通过搭配硬件平台基本可以满足田间实际作业需求。

3 结论

(1)提出了一种改进 YOLO v8n 模型的田间玉米杂草快速检测算法,将 YOLO v8n 模型主干网络替换为 GhostNet 结构,在特征融合层部分引入 BiFPN,且在颈部网络最后一层中引入 Triplet Attention,原 CIoU 损失函数替换为 Wise - IoU,在提升模型特征提取能力的同时,提高了模型泛化能力和检测速度。

(2)采用 GhostNet 作为主干网络后,相较于原始模型,其参数量减少 43.75%、浮点运算数降低 23.17%;在特征融合层部分引入 BiFPN,并在颈部网络引入 Triplet Attention,模型平均精度均值提升 0.20 个百分点、精确率提升 0.40 个百分点;替换损失函数为 Wise - IoU 后,模型召回率提升 0.70 个百分点;检测速度提升 22.04%。

(3)在测试集上改进 YOLO v8 - GBT 模型平均精度均值为 97.80%,模型内存占用量 4.1 MB。与原模型相比,改进内存占用量减少 33.87%。平均精度均值提高 0.60 个百分点,精确率提高 1.80 个百分点,召回率提高 1.40 个百分点,模型参数量降低 37.90%。与 YOLO v5n、YOLO v6n、YOLO v10 和 Faster R - CNN 等主流目标检测网络相比,在检测精度、速度和效率上也具有一定的优势。通过搭配 DELL G15 硬件平台的模型田间作业性能验证试验表明,所提出的模型可以满足田间实际作业要求。

参 考 文 献

[1] LI Y, ZHENG S, LIU H, et al. Contour farming suitability of the black soil region in northeast China and its spatial characteristics[J]. Chinese Geographical Science, 2024, 34(6): 1119 - 1133.

[2] 齐智娟, 宋芳, 张忠学, 等. 保护性耕作对寒地黑土土壤水热效应与玉米产量的影响[J]. 农业机械学报, 2022, 53(12): 380 - 389.

QI Zhijuan, SONG Fang, ZHANG Zhongxue, et al. Effects of different conservation tillage methods on soil hydrothermal condition as well as maize yield in cold black soil region[J]. Transactions of the Chinese Society for Agricultural Machinery,

- 2022, 53(12): 380–389. (in Chinese)
- [3] 何进, 李洪文, 陈海涛, 等. 保护性耕作技术与机具研究进展[J]. 农业机械学报, 2018, 49(4): 1–19.
HE Jin, LI Hongwen, CHEN Haitao, et al. Research progress of conservation tillage technology and machine[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(4): 1–19. (in Chinese)
- [4] SCHUMACHER M, WITTY R, GERHARDS R. Reintroduction strategies for rare arable weeds in agricultural practice and their influence on yield[J]. Weed Research, 2024, 64(5): 384–394.
- [5] ZHAO Xueguan, WANG Xiu, LI Cuiling, et al. Cabbage and weed identification based on machine learning and target spraying system design[J]. Frontiers in Plant Science, 2022, 13: 924973.
- [6] 刘莫尘, 高甜甜, 马宗旭, 等. 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 Mochen, GAO Tiantian, MA Zongxu, et al. 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)
- [7] RAM B G, ODUOR P, IGATHINATHANE C, et al. A systematic review of hyperspectral imaging in precision agriculture: analysis of its current state and future prospects[J]. Computers and Electronics in Agriculture, 2024, 222: 109037.
- [8] 卢鹏, 孙天文, 陈明, 等. 基于 YOLO v8 和 CycleGAN 的红掌植株表型参数自动提取方法[J]. 农业机械学报, 2024, 55(11): 154–159, 319.
LU Peng, SUN Tianwen, CHEN Ming, et al. Automatic extraction of phenotypic parameters from *Anthurium andraeanum* linden based on YOLO v8 and CycleGAN[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 154–159, 319. (in Chinese)
- [9] 周平, 汪亚明, 赵匀. 基于颜色分量运算与色域压缩的杂草实时检测方法[J]. 农业机械学报, 2007, 38(1): 116–119.
ZHOU Ping, WANG Yaming, ZHAO Yun. Real-time detection of weeds based on color components and bit-mask operation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2007, 38(1): 116–119. (in Chinese)
- [10] 张春龙, 黄小龙, 刘卫东, 等. 苗间锄草机器人信息获取方法的研究[J]. 农业工程学报, 2012, 28(9): 142–146.
ZHANG Chunlong, HUANG Xiaolong, LIU Weidong, et al. Information acquisition method for mechanical intra-row weeding robot[J]. Transactions of the CSAE, 2012, 28(9): 142–146. (in Chinese)
- [11] YUN Z, YUAN Y, XING X, et al. Precision detection of crop diseases based on improved YOLOv5 model[J]. Frontiers in Plant Science, 2023, 13: 1066835.
- [12] QI J, CONG X, ZHANG W, et al. Impact of canopy opener working height on spraying effect of a high clearance sprayer[J]. Biosystems Engineering, 2024, 240: 19–32.
- [13] 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 Can, WU Xinhui, LI Zhiwei. Recognition of maize and weed based on multi-scale hierarchical features extracted by convolutional neural network[J]. Transactions of the CSAE, 2018, 34(5): 144–151. (in Chinese)
- [14] 孙俊, 何小飞, 谭文军, 等. 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 Jun, HE Xiaofei, TAN Wenjun, et al. Recognition of crop seedling and weed recognition based on dilated convolution and global pooling in CNN[J]. Transactions of the CSAE, 2018, 34(11): 159–165. (in Chinese)
- [15] CHEN Zhaoyi, WU Ruhui, LIN Yiyan, et al. Plant disease recognition model based on improved YOLOv5[J]. Agronomy, 2022, 12(2): 365.
- [16] 王秀红, 王庆杰, 李洪文, 等. 基于 YOLO v5-Jetson TX2 的秸秆覆盖农田杂草检测方法[J]. 农业机械学报, 2023, 54(11): 39–48.
WANG Xiuhong, WANG Qingjie, LI Hongwen, et al. Weed detection method of straw-covered farmland based on YOLO v5 Jetson TX2[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(11): 39–48. (in Chinese)
- [17] LI Siqi, JIN Yishu, RUAN Zheng, et al. Real-time detection of seedling maize weeds in sustainable agriculture[J]. Sustainability, 2022, 14(22): 15088.
- [18] SAPKOTA B B, HU Chengsong, BAGAVATHIANNAN M V. Evaluating cross-applicability of weed detection models across different crops in similar production environments[J]. Frontiers in Plant Science, 2022, 13: 837726.
- [19] YING Boyu, XU Yuancheng, ZHANG Shuai, et al. Weed detection in images of carrot fields based on improved YOLO v4[J]. Traitement du Signal, 2021, 38(2): 341–348.
- [20] RAZFAR N, TRUE J, BASSIOUNY R, et al. Weed detection in soybean crops using custom lightweight deep learning models[J]. Journal of Agriculture and Food Research, 2022, 8: 100308.
- [21] 张馨悦, 王庆杰, 王超, 等. 旱田智能化机械除草技术与装备研究进展[J]. 农业机械学报, 2025, 56(4): 22–41, 71.
ZHANG Xinyue, WANG Qingjie, WANG Chao, et al. Research progress on intelligent mechanical weeding technology and equipment in dry field[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(4): 22–41, 71. (in Chinese)
- [22] YANG Y, WANG Y D, CHEN Y, et al. Detection of weeds growing in alfalfa using convolutional neural networks[J].

Agronomy, 2022, 12(6): 1459.

[23] YANG G L, WANG J X, NIE Z L, et al. A Lightweight YOLOv8 tomato detection algorithm combining feature enhancement and attention[J]. Agronomy-basel, 2023, 13(7): 1824.

[24] HAN K, WANG Y, TIAN Q, et al. GhostNet: more features from cheap operations[C]//Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020.

[25] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation[C]//Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)CVPR, 2018.

[26] PIOTR D, RON A, SERGE B, et al. Fast feature pyramids for object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 36(8): 1532 – 1545.

[27] CHEN J, JI C, ZHANG J, et al. A method for multi-target segmentation of bud-stage apple trees based on improved YOLOv8 [J]. Computers and Electronics in Agriculture, 2024, 220: 108876.

[28] TONG Z, CHEN Y, XU Z, et al. Wise – IoU: bounding box regression loss with dynamic focusing mechanism[J]. ArXiv, 2023, 1:10051.

[29] 罗志聪, 何陈涛, 陈登捷, 等. 基于轻量化 YOLO v8s – GD 的自然环境下百香果快速检测模型[J]. 农业机械学报, 2024, 55(8): 291 – 300.

LUO Zhicong, HE Chentao, CHEN Dengjie, et al. Passion fruit rapid detection model based on lightweight YOLO v8s – GD [J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(8): 291 – 300. (in Chinese)

[30] 翟肇裕, 张梓涵, 徐焕良, 等. YOLO 算法在动植物表型研究中应用综述[J]. 农业机械学报, 2024, 55(11): 1 – 20.

ZHAI Zhaoyu, ZHANG Zihan, XU Huanliang, et al. Review of applying YOLO family algorithms to analyze animal and plant phenotype[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 1 – 20. (in Chinese)

[31] LIU Y, TANG L, LIAO C, et al. Optimized dropkey-based Grad – CAM: toward accurate image feature localization[J]. Sensors, 2023, 23(20): 8351.

(上接第 172 页)

[14] ZHENG Z, WANG P, LIU W, et al. Distance – IoU loss: faster and better learning for bounding box regression[J]. arXiv preprint arXiv:1911.08287, 2019.

[15] SUNKARA R, LUO T. No more strided convolutions or pooling: a new CNN building block for low-resolution images and small objects[C]//Joint European Conference on Machine Learning and Knowledge Discovery in Databases, 2022: 443 – 459.

[16] ZHANG X, SONG Y, SONG T, et al. LDConv: linear deformable convolution for improving convolutional neural networks[J]. Image and Vision Computing, 2024(Sep.):149.

[17] 苑迎春, 耿俊, 许楠, 等. 基于 YOLO v8 – TRP 模型的小麦麦穗识别方法[J]. 农业机械学报, 2025, 56(11): 499 – 508.

YUAN Yingchun, GENG Jun, XU Nan, et al. Wheat ear recognition method using YOLO v8 – TRP model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(11): 499 – 508. (in Chinese)

[18] HU J, SHEN L, SUN G, et al. Squeeze-and-excitation networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132 – 7141.

[19] WOO S, PARK J, LEE J Y, et al. Cbam: convolutional block attention module[C]//Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3 – 19.

[20] 李尚平, 郑创锐, 文春明, 等. 基于无人机 RGB 图像与改进 YOLO v5s 的宿根蔗缺苗定位方法[J]. 农业机械学报, 2024, 55(12): 57 – 70.

LI Shangping, ZHENG Chuangrui, WEN Chunming, et al. Method for locating missing ratoon sugarcane seedlings based on RGB images from unmanned aerial vehicles and improve YOLO v5s[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(12): 57 – 70. (in Chinese)

[21] GEVORGYAN Z. SIoU loss: more powerful learning for bounding box regression[J]. Computer Vision and Pattern Recognition, 2022(5): 1 – 12.

[22] TONG Zanjia, CHEN Yuhang, XU Zewei, et al. Wise – IoU: bounding box regression loss with dynamic focusing mechanism [J]. arXiv preprint arXiv:2301.10051, 2023.

[23] MA S, XU Y. MPDIoU: a loss for efficient and accurate bounding box regression[J]. arXiv preprint arXiv:2307.07662, 2023.

[24] LI C, LI L, JIANG H, et al. YOLO v6: a single-stage object detection framework for industrial applications[J]. arXiv preprint arXiv:2209.02976, 2022.

[25] WANG C Y, BOCHKOVSKJ Y A, LIAO H Y M. YOLO v7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464 – 7475.

[26] WANG C Y, YE H I, MARK L H Y. YOLO v9: learning what you want to learn using programmable gradient information [C]//European Conference on Computer Vision, 2024: 1 – 21.