doi:10.6041/j.issn.1000-1298.2026.13.011

基于嵌入式 YOLO 的玉米苗与杂草检测轻量化模型 BACD－YOLO 研究

王汉羊[1]　娄　淞[1]　邸佳豪[1]　马永财[1]　刘　丹[2]

（1.黑龙江八一农垦大学工程学院，大庆 163319；2.黑龙江八一农垦大学土木水利学院，大庆 163319）

摘要：针对玉米 2～5 叶除草关键窗口期存在的田间复杂环境、杂草识别精度与检测效率难以兼顾的难题，以东北 2～5 叶期玉米幼苗及其早期伴生杂草为对象，提出了基于一种改进 YOLO v8n 的玉米苗及杂草轻量化检测模型 BACD－YOLO（BiFPN－Adown－CA－DualConv－YOLO）。该方法采用 Adamax 优化器增强模型在复杂田间环境下的鲁棒性；引入加权双向特征金字塔网络（Bidirectional feature pyramid network，BiFPN）至特征融合网络作为连接层，改善模型对长势各异杂草的检测效果；采用轻量化下采样模块（Adown）替换网络中常规卷积，降低模型冗余的参数计算量；在 SPPF 层前及特征融合网络中嵌入坐标注意力机制（Coordinate attention，CA），提高模型对小目标及密集分布杂草的定位能力；采用 DualConv 轻量化双卷积替换原模型中普通卷积结构，进一步实现模型轻量化及模型对相似特征杂草的检测能力。试验结果表明，改进模型的精确率、召回率及平均精度均值分别为 86.6%、86.2%和 91.2%，较初始模型分别提高了 2.2、1.5、1.6 个百分点，且浮点计算量和参数量仅为 6.2×10^9 和 2.3×10^6，较初始模型分别降低了 23.5%和 23.3%。通过主流检测模型对比、公开数据集验证和边缘设备部署应用试验，结果表明，改进模型（BACD－YOLO）凭借较高的检测精度、较强的泛化能力和较优异的轻量化性能适宜边缘设备部署应用，帧率达到 19.4 f/s，检测正确率为 86.6%，能够满足田间实时检测要求。本研究可为玉米苗及杂草精准识别与机器人除草作业提供有效的轻量化解决方案。

关键词：玉米；杂草识别；深度学习；YOLO v8n；轻量化

中图分类号：TP391　　**文献标识码**：A　　**文章编号**：1000-1298(2026)13-0149-11　　**OSID**：

Research on Lightweight BACD－YOLO Model for Corn Seedling and Weed Detection Based on Embedded YOLO

Wang Hanyang[1]　Lou Song[1]　Di Jiahao[1]　Ma Yongcai[1]　Liu Dan[2]

(1. *College of Engineering*, *Heilongjiang Bayi Agricultural University*, *Daqing* 163319, *China*
2. *College of Civil Engineering and Water Conservancy*, *Heilongjiang Bayi Agricultural University*, *Daqing* 163319, *China*)

Abstract: Aiming at the problems of complex field environment and difficulty in taking into account the accuracy of weed identification and detection efficiency in the critical window period of 2～5 leaf weeding of maize, a lightweight detection model BACD－YOLO for maize seedlings and weeds based on improved YOLO v8n was proposed. Using Adamax optimizer to enhance the robustness of model in field environment; the weighted bidirectional feature pyramid network (BiFPN) was introduced to the feature fusion network as the connection layer to improve the detection effect of the model on weeds with different growth. Adopting lightweight down sampling module (Adown) replaced the conventional convolution in the network to reduce the amount of parameter calculation of model redundancy; the coordinate attention (CA) mechanism was embedded in the SPPF layer and the feature fusion network to improve the positioning ability of the model for small targets and densely distributed weeds; DualConv lightweight double convolution was used to replace the ordinary convolution structure in original model to further realize the lightweight of the model and the detection ability of the model for weeds with similar characteristics. The experimental results showed the accuracy, recall and average accuracy of improved

收稿日期：2025－12－17　修回日期：2026－02－02

基金项目：黑龙江省“揭榜挂帅”科技攻关项目（2023ZXJ07B02）、黑龙江省重点研发计划项目（2024ZXDXB45）和黑龙江省“双一流”学科协同创新成果建设项目（LJGXCG2022－107）

作者简介：王汉羊（1982—），男，副教授，博士，主要从事智能农机装备设计研究，E-mail：michaelyang198217@163.com

model were 86.6%, 86.2% and 91.2%, respectively, which were 2.2, 1.5 and 1.6 percentage points higher than that of the original model, and floating-point calculation and parameter quantity were only 6.2×10^9 and 2.3×10^6, which were 23.5% and 23.3% lower than that of original model, respectively. According to the verification test results, the improved model was more suitable for edge device deployment application with high detection accuracy, strong generalization ability and excellent lightweight performance. The frame rate was 19.4 f/s, and the detection accuracy was 86.6%, which can meet requirements of field real-time detection. The research result can provide an effective lightweight solution for accurate identification of corn seedlings and weeds and robot weeding.

Key words: corn; weed recognition; deep learning; YOLO v8n; lightweight

0 引言

玉米作为我国三大粮食作物之首,在日常食用、家禽饲料和工业原材料制造等领域中都发挥着巨大作用。数据显示,2024 年全国玉米播种面积占到了所有农作物的 30% 以上,且总产量达到 2.95 亿吨,已成为全球玉米生产第二大国[1]。玉米 2 ~ 5 叶生长周期是杂草防控的关键窗口期,此时玉米苗生长较缓慢,对养分需求大,杂草形态较小且对除草剂敏感性强,在此阶段进行杂草清除可有效避免其对水分、养分和光照的争夺,保障玉米产量。但由于此阶段田间的杂草种类繁多、形态复杂且存在一定的相互遮挡,这对杂草的识别和去除提出了更高要求。传统的机械除草方式效率低下且易造成伤苗现象,化学和生物除草方式存在污染严重和环境适应性差等缺点[2]。因此,探索出高效、精准且环境友好型的新型除草方式,已成为提升我国玉米生产效益和农业可持续发展中急需解决的重要问题之一。

随着智能化技术的迅速发展,融合信息化技术和传统除草技术的智能除草方式被广泛研究和应用于农业除草领域,有效改善了传统除草方式的局限性,实现了高效除草的目的。在智能化除草作业中,对杂草及作物精准检测是关键环节,影响最终除草效果。一些学者实地采集了复杂环境下的玉米苗及杂草数据,通过融合轻量化模块并结合精度提升策略构建了玉米苗及杂草高效检测模型[3-7]。随着智慧农业的迅速发展,研究者在基于前人研究基础上将构建的轻量化模型部署至边缘设备以探究模型实际应用效果,为玉米苗期除草机器人的发展做出了重大贡献[8-9]。

上述研究针对农作物及杂草检测领域提出了较多考虑轻量化和精度的改进方案,但在田间较复杂的环境下,上述模型在玉米苗及杂草的检测精度与轻量化性能平衡方面仍有优化空间,且缺乏不同数据集的泛化性验证和边缘端设备部署实时性试验验证。因此,本文设计一种基于 YOLO v8n 模型改进后的模型嵌入至边缘设备进行检测效果验证,以满足实际环境对模型精度高、计算复杂度低和部署应用效果好的需求,为玉米 2 ~ 5 叶期机械化智能除草作业提供技术支持。

1 材料与方法

1.1 数据构建

本研究数据采集于黑龙江省安达市万宝山镇、省建五公司农场及大庆市龙凤区白家窑,种植玉米品种主要为先玉 335 和郑单 958。采用垄上单行种植,垄距 65 cm,采集时间为 2025 年 5 月 25 日至 6 月 15 日,此时为玉米 2 ~ 5 叶幼苗期。采用手机拍摄,距地面高度 40 ~ 70 cm,拍摄角度包括俯角 60° ~ 90°(相机光轴与水平面夹角)和水平方向 0° ~ 360°的视角。为构建一个能够充分反映玉米 2 ~ 5 叶期田间复杂环境的代表性数据集,图像采集紧密围绕田间实际挑战,保证数据集中包含不同光照条件(不同天气和时段)、杂草生长期(包含玉米 2 ~ 5 叶期下杂草初生真叶期、生长初期和快速生长期等多生长期)、背景复杂度(不同土壤湿度、土壤板结、碎石等)、空间分布复杂性(不同密度及相互遮挡等)及杂草种类[10]等多样化场景,为鲁棒性提升奠定数据基础。

剔除采集图像中曝光、模糊及其他低质量图像,统一将图像转换为 jpg 格式,分辨率设置为 640 像素 × 640 像素,共得到 4 000 幅图像。数据集划分为玉米(corn)和杂草(weed)2 大类,杂草类别中包含藜、苘麻、地肤,此 3 类杂草为玉米田中数量较多且分布较广的主要杂草类型。对玉米 2 ~ 5 叶期下各类杂草的不同生长时期进行采样,保证模型学习到丰富的特征信息。采用 LabelImg 软件进行数据标注,保存为 xml 格式文件,并转换为 txt 格式文件用于模型训练。采用旋转、裁切尺寸、高斯及椒盐噪声注入、亮度调节、模糊处理、背景分割等数据增强方式对数据集进行预处理,得到包含 7 000 幅图像的数据集。将数据集按复杂程度分为 3 类:包含较少目标或单一类别的简单场景、玉米苗与杂草相互遮挡或存在少量聚集目标的中等复杂场景和多种杂草

密集分布或严重遮挡的复杂场景，在每个场景类别子集内按比例 7∶2∶1 随机抽取图像分别放入训练集、验证集和测试集，保证每个数据集中都包含不同复杂度场景下的图像[11]。数据集情况如图 1 所示。

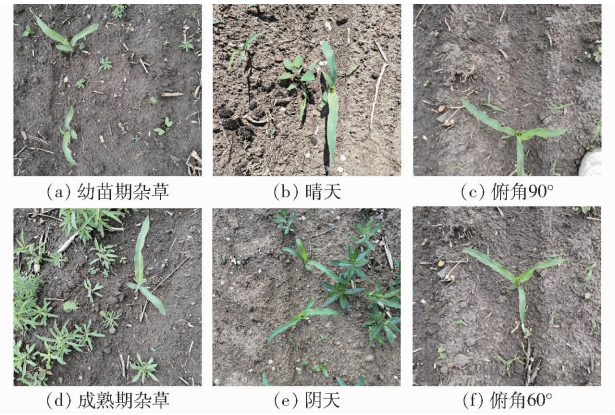

图 1　数据集中玉米苗及杂草生长情况

Fig. 1　Growth of maize seedlings and weeds in dataset

1.2　改进模型 BACD－YOLO 构建

本研究选用 2023 年 Ultralytics 公司发布的高效检测模型 YOLO v8n 为基线模型进行研究。YOLO v8n 模型为 YOLO v8 系列模型中参数量最少、实时性最好、计算复杂度最低的高效检测模型，相较于同系列的 s、m、l、x 模型，具备较快的推理速度和较低的参数计算量；相较于早期发布的 YOLO v3 和 YOLO v5 等系列的模型，YOLO v8n 模型拥有更先进的网络架构，在复杂环境下的杂草检测任务中具有更强的精度及计算效率兼顾能力；较近年来发布的 YOLO v9 及 YOLO 11 等模型，YOLO v8n 模型具有成熟的部署能力和二次创新潜力[12]。考虑到复杂的田间环境对模型轻量化、高精度与高速推理能力需求，故选用 YOLO v8n 模型作为基础模型。

为优化模型对玉米 2～5 叶期作物及杂草的检测性能，采用 Adamax 优化器[13]替换初始优化器，将 BiFPN 网络[14]作为特征融合网络的连接层，引用 YOLO v9 模型中的 Adown 轻量化下采样模块[15－16]至网络中提高模型轻量化和精度平衡性能，在 SPPF 层前及特征融合网络中加入 CA[17]，并采用 DualConv 轻量化双卷积[18]替换网络中的普通卷积，上述协同优化方案有效改善了模型的轻量化性能，实现对复杂环境下玉米苗及杂草的高精度检测。改进模型结构如图 2 所示。图中，BiFPN_Concat2 和 BiFPN_Concat3 为 BiFPN 结构中的双输入融合节点和三输入融合节点；Adown 为改进的轻量化下采样模块；CoordAtt 为改进的 CA；C2f_Dual 为改进的 DualConv 轻量化双卷积。

1.3　Adamax 优化器

YOLO v8 模型中默认的优化器为随机梯度下降优化器[19]（Stochastic gradient descent，SGD），此优化器在深度学习领域应用较广泛且泛化性较强，但其

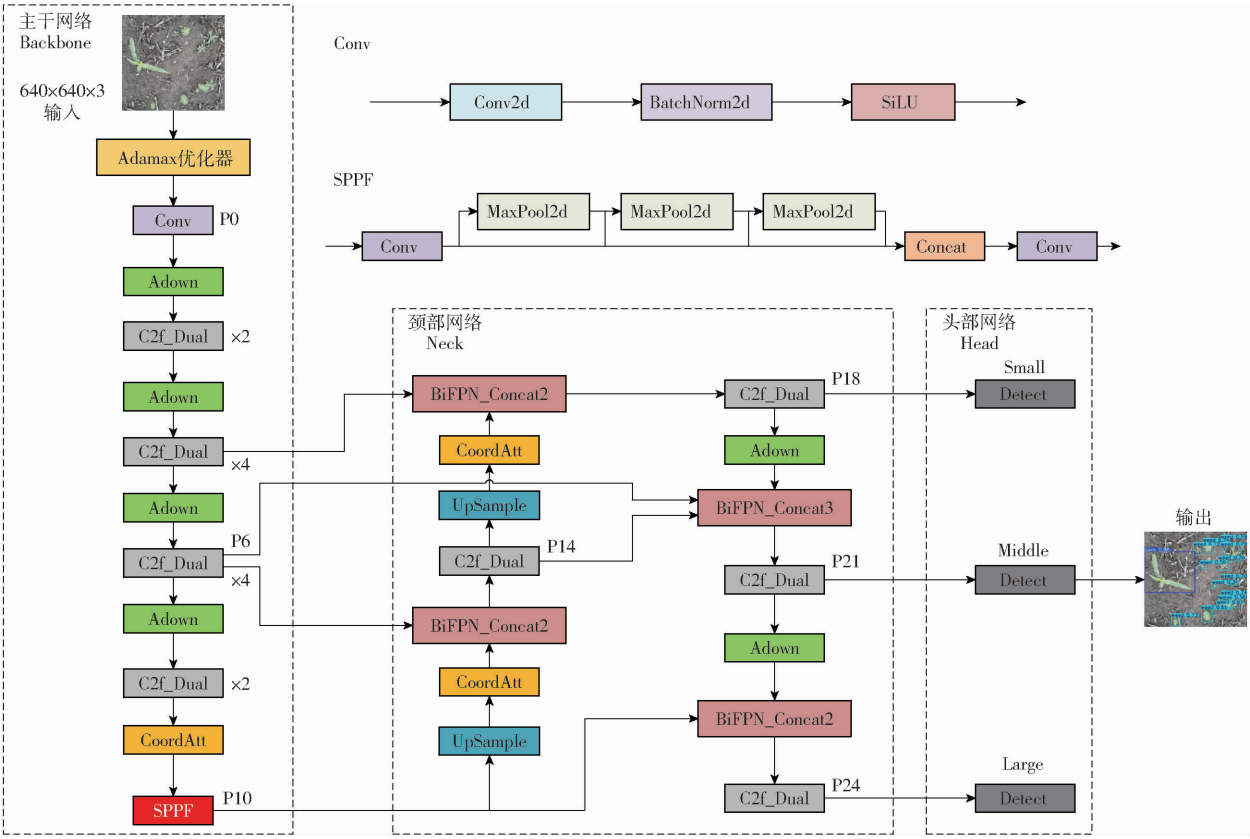

图 2　BACD－YOLO 模型网络结构

Fig. 2　BACD－YOLO model network structure

固定的学习率可能使模型对噪声较为敏感,在处理玉米 2 ~ 5 叶期杂草特征信息时,收敛速度和模型损失值易受影响,制约了模型性能的充分挖掘。Adamax 优化器是自适应动量估计优化器[20](Adaptive moment estimation,Adam)的变体,采用了 L_∞ 范数自适应平衡机制,能够抑制一定的噪声干扰因素,且对学习率敏感性不高,在较复杂的深度学习模型训练方面更加平滑。因此采用 Adamax 优化器,以缓解由于玉米 2 ~ 5 叶期作物与杂草目标尺寸不一、分布不均造成的稀疏梯度问题,确保优化过程在复杂损失曲面上平稳推进。Adamax 的参数更新方式与 Adam 类似,表达式为

$$m_t = \beta_1 m_{t-1} + g_t(1-\beta_1) \tag{1}$$

$$u_t = \max(\beta_2 u_{t-1}, |g_t|) \tag{2}$$

$$\hat{m}_t = \frac{m_t}{1-\beta_1^t} \tag{3}$$

$$\theta_{t+1} = \theta_t - \frac{\eta}{u_t}\hat{m}_t \tag{4}$$

式中 m_t——动量梯度均值

u_t——加权无穷范数

g_t——当前时间步梯度

β_1、β_2——衰减系数,取 0.9 和 0.999

$\hat{m}_t$——偏差修正后动量梯度均值

η——学习率,默认值为 0.002

θ_{t+1}——经历 t 次迭代后模型的参数值

β_1^t——对指数衰减率做 t 次幂运算函数

$\max(\beta_2 u_{t-1}, |g_t|)$——取两者中较大者函数

1.4 BiFPN 网络

YOLO v8 网络在颈部网络中融合了 FPN 和 PANet 结构,结构简单且具有轻量化特性,但易导致特征权重均等化,使模型在复杂环境下无法精准聚焦杂草关键特征,且特征信息逐级传递的方式易对不同尺度的杂草目标漏检[21]。BiFPN 网络是基于传统特征金字塔创新之后的网络,它继承并优化了特征金字塔网络(Feature pyramid network,FPN)、实例分割网络(Path aggregation network,PANet)、基于神经架构搜索技术自动优化网络(Neural architecture search-feature pyramid network,NAS - FPN)的优势,并通过加权操作和简化网络实现对目标的高效检测。它在相邻级别之间引入了双向连接,实现不同尺度间特征的相互流通,增强了模型对上下文特征信息的感知能力;BiFPN 网络可为每个特征信息进行加权融合,提高有利特征信息对模型的影响能力;轻量化方面,BiFPN 网络减少了网络节点数,并重新定义网络特征层,实现特征信息高效融合。将 BiFPN 网络替换特征融合网络中的连接层,提高模型对长势各异杂草的检测准确性,弱化了土壤等其他干扰因素的影响。YOLO v8n 中双向特征融合路径结构及 BiFPN 网络结构如图 3、4 所示。其中,BiFPN_Concat2 和 BiFPN_Concat3 均属于 BiFPN 网络,两者协同作用以提升模型对小目标和中大目标的检测性能。

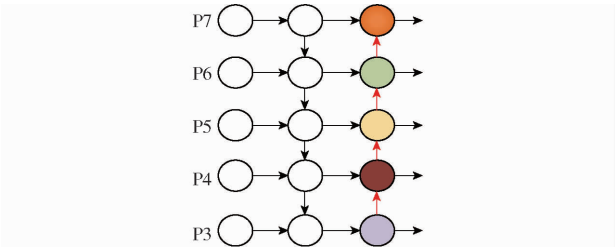

图 3 YOLO v8n 中双向特征融合路径结构

Fig. 3 Bidirectional feature fusion path structure in YOLO v8n

在每个特征融合节点处,BiFPN 网络对所有输入特征按可学习权重进行归一化加权求和,让模型学习每个输入特征的重要性,表达式为

$$O_{\text{output}}(i,j) = \sum_{i=1}^{n} \frac{W_i}{\varepsilon + \sum_{j=1}^{n} W_j} I_i \tag{5}$$

式中 $O_{\text{output}}(i,j)$——融合后的特征输出

W_i、W_j——可学习权重,初始值为 1

I_i——不同层级特征图的第 i 个输入特征

ε——极小常数,作用为避免分母为零

1.5 Adown 轻量化下采样模块

YOLO v8n 网络中采用的普通卷积能够承担通道数降维和特征信息学习的功能,但在田间复杂环境下易出现局部信息丢失的问题,导致模型对小目标杂草检测精度不够理想。优化方案中采用的

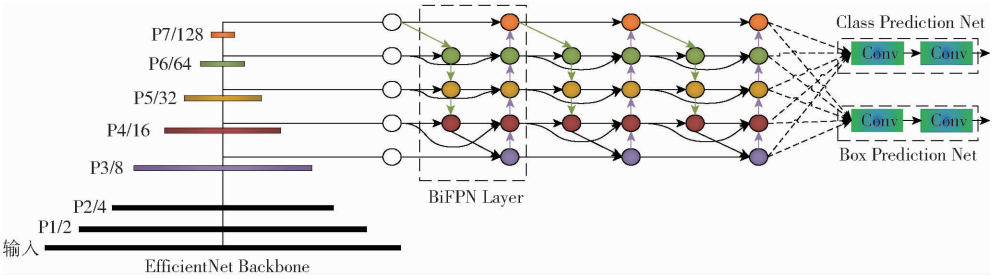

图 4 BiFPN 网络

Fig. 4 BiFPN network structure

Adown 轻量化下采样模块为 YOLO v9 模型中的结构，它采用自适应采样和轻量化设计的方法，优化模型对小目标和外观相似杂草的检测精度，并显著降低了模型内存占用量。Adown 轻量化下采样模块结构如图 5 所示，图中，AvgPool2d 表示对输入特征图采取二维平均池化操作；Chunk 表示沿通道维度将特征图均匀地分割成两部分；MaxPool2d 表示采取二维最大池化操作。

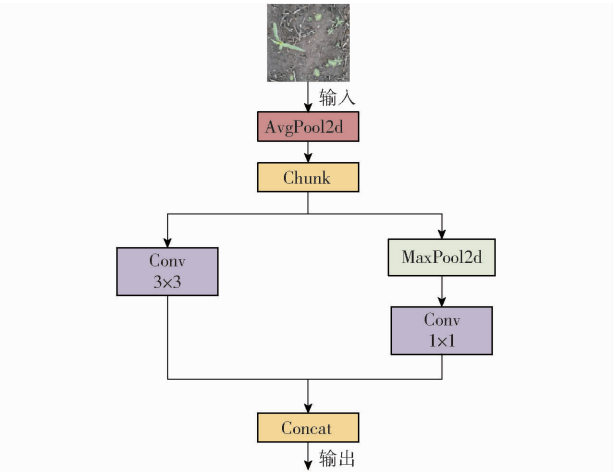

图 5　Adown 轻量化下采样模块

Fig. 5　Adown lightweight downsampling module

首先对特征图进行二维平均池化，弱化卷积计算误差，捕捉稳定的特征信息。接着采用 Chunk 操作将特征图划分为两部分，分别表示为X_{Avg1}和X_{Avg2}。其中一个分支上采用步长为 2 的 3×3 卷积进行处理，保留关键特征信息，此分支上得到的特征图表示为X_{Conv1}。表达式为

$$X_{\text{Conv1}} = \text{Conv}_{3\times3}(X_{\text{Avg1}}) \tag{6}$$

式中　$\text{Conv}_{3\times3}(X_{\text{Avg1}})$——对特征图$X_{\text{Avg1}}$进行局部特征提取和下采样操作

另一个分支采用二维最大池化精准捕获局部最大特征，避免信息丢失，且通过步长为 1 的 1×1 卷积处理，经此分支处理后的特征图表示为$X_{\text{Max+Conv2}}$。最后，两个并行分支处理后的结果通过拼接(Concat)操作融合输出。表达式为

$$X_{\text{Max+Conv2}} = \text{Conv}_{1\times1}(\text{MaxPool}(X_{\text{Avg2}})) \tag{7}$$

式中　$\text{MaxPool}(X_{\text{Avg2}})$——对特征图$X_{\text{Avg2}}$采取最大池化操作

1.6　坐标注意力机制

坐标注意力机制(Coordinate attention，CA)是一种轻量级注意力，它聚焦于重点检测区域，通过分解检测目标的空间编码，精准地向模型传达三维定位信息。CA 通过一维池化建立长距离依赖关系，对全局特征具有优秀的捕获能力。将 CA 融入网络的 SPPF 层前和上采样层之后，让模型快速区分目标的位置关系，提高对密集分布和小目标杂草的检测效果。CA 结构如图 6 所示，图中，Residual 表示残差连接；BatchNorm 表示归一化处理；Non－linear 表示非线性激活操作；Re－weight 表示将注意力权重图与原始输入特征图进行逐元素相乘。

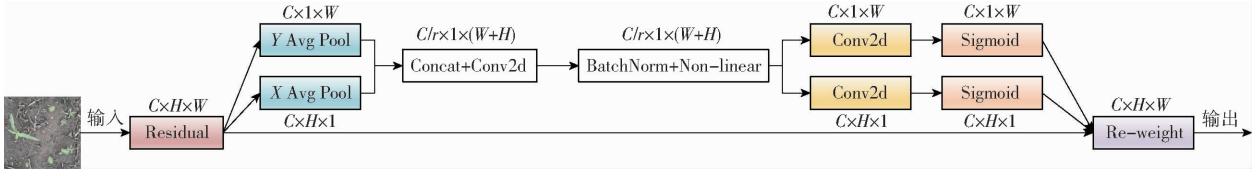

图 6　CA 结构

Fig. 6　Coordinate attention structure

首先，对输入特征图进行宽度(W)和高度(H) 2 个方向上的全局平均池化，为后续处理编码提供基础条件。接着，将 2 个方向上得到的一维特征进行拼接，得到$(H+W)\times1\times C$的融合特征。随后，该特征通过 1×1 卷积进行降维和非线性激活函数处理，以捕获跨方向的交互信息，提高模型学习复杂特征的能力。之后将激活后的特征沿宽度和高度方向拆分为 2 个独立的一维特征张量，并分别使用 1×1 卷积处理，再通过 Sigmoid 函数生成宽度和高度两方向上的注意力权重图，最终采取 Re－weight 操作将注意力权重图与初始图像进行逐元素相乘，并实现特征重加权和输出。

1.7　DualConv 轻量化双卷积

YOLO v8n 模型中的 C2f 模块采用“分支并行＋残差融合”的方式，平衡了模型的特征提取能力和参数量，但固定的卷积核串行处理方式导致模型在特征学习时灵活性欠佳。DualConv 轻量化双卷积的异构卷积并行方式能够在通道上实行差异化处理，最大限度保留关键特征。将 DualConv 轻量化双卷积融入主干和颈部网络中替换 C2f 结构，提高模型对外观相似杂草的检测能力，抑制土壤等无关因素对检测的影响，并进一步优化模型的轻量化及实际部署能力。DualConv 轻量化双卷积如图 7 所示，图中，Split 代表特征分流操作，Bottleneck 代表深度特征提取操作，3×3 代表分组卷积，1×1 代表逐点卷积，M 代表输入特征图的总通道数，M/G 代表分配给混合卷积分支处理的通道数，N/G 代表每组需要输出的通道数，⊕代表逐元素相加操作。

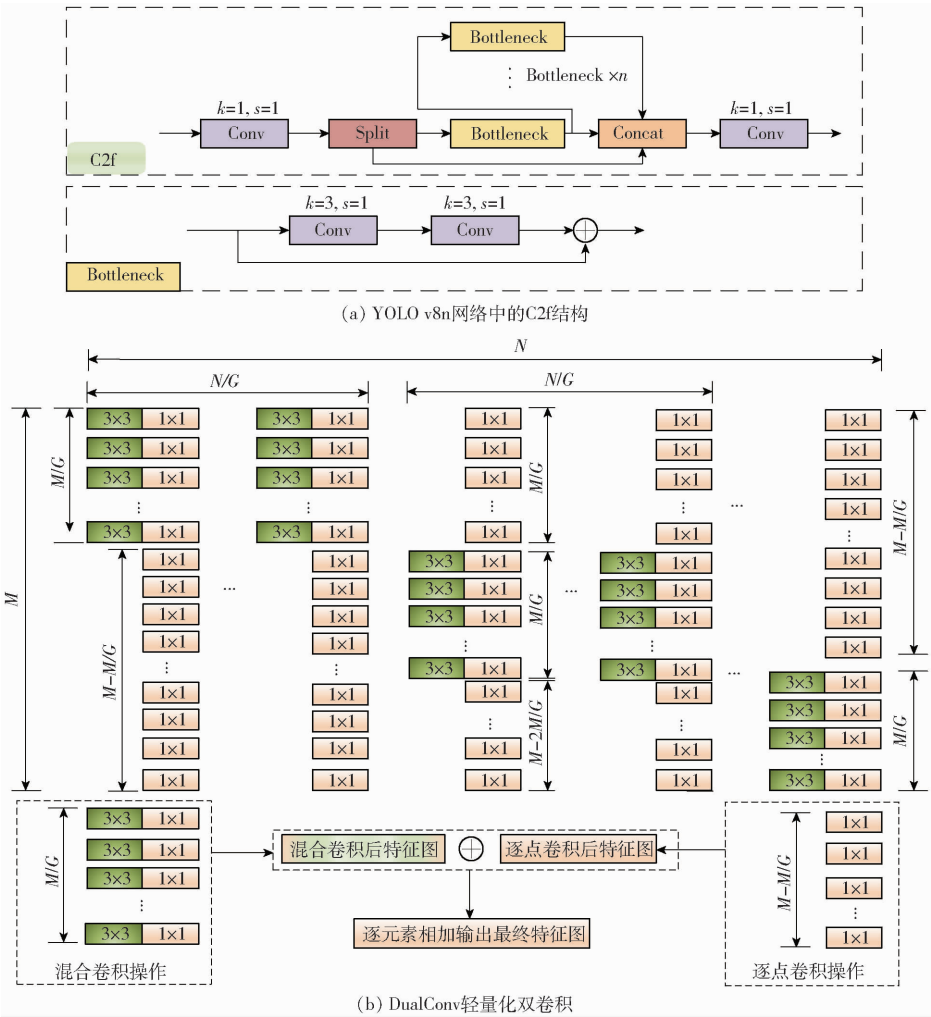

(a) YOLO v8n网络中的C2f结构

(b) DualConv轻量化双卷积

图 7 YOLO v8n 网络中的 C2f 结构和 DualConv 轻量化双卷积

Fig. 7 C2f structure in YOLO v8n network and DualConv lightweight double convolution

首先,将输入的特征图划分为 G 组并对每一组输入通道进一步分割为两部分,送入并行处理路径:其中一路经采用混合卷积(首先采用 3×3 组卷积,随后采用 1×1 逐点卷积)处理 M/G 个通道,使模型掌握丰富的局部特征信息,在这一路径上,模型学习到局部细节特征和跨通道交互特征。另一路经则仅采用逐点卷积的方式处理组内剩余的 $M-M/G$ 个通道,保留输入特征的全局信息。最后,2 个路径上输出的特征图进行逐元素相加操作得到最终特征图。

2 结果与分析

2.1 评价指标与参数设置

为科学评估模型优化前后的性能,选取精确率(P)、召回率(R)、平均精度均值(mAP@0.5)分析模型的精度性能,选取参数量、帧率(FPS)以及浮点运算次数分析模型轻量化性能,通过以上指标综合评价模型的各项性能[22]。评价指标中,精确率、召回率和平均精度均值越大,模型检测精度、定位和识别效果越好;参数量越大,模型潜在学习能力越强,但模型运行时间越长,模型部署越困难;帧率越大,模型运行时的检测速度越快;浮点运算次数越大,计算开销越大[23]。试验平台为 Windows 11 系统,处理器为 AMD Radeon 780M Graphics,显卡为 NVIDIA GeForce RTX 4060。Pycharm 为 2022.1 版本,Pytorch 为 1.12 版本,Python 为 3.9 版本。基线模型的训练采用 SGD 优化器,输入图像尺寸为 640 像素×640 像素,迭代次数为 300,批次大小为 16。

2.2 消融试验

为验证改进方案的有效性,在统一的试验环境下,进行模块化消融试验,试验结果如表 1 所示。其中,YOLO v8n 为基线模型,YOLO v8n-E 为替换初始优化器为 Adamax 的模型,YOLO v8n-B、YOLO v8n-A、YOLO v8n-C、YOLO v8n-D 模型为在 YOLO v8n-E 模型上分别仅引入 BiFPN 网络、Adown 轻量化下采样模块、CA、DualConv 轻量化双卷积后的模型,YOLO v8n-BA 为在 YOLO v8n-B 模型基础上引入 Adown 轻量化下采样模块的模型,YOLO v8n-BAC 为在 YOLO v8n-BA 模型基础上引入 CA 的模型,BACD-YOLO 模型为在基线模型

表 1　消融试验结果

Tab. 1　Ablation test results

模型	精确率/%	召回率/%	平均精度均值/%	参数量	帧率(GPU)/(f·s^{-1})	浮点运算次数
YOLO v8n	84.4	84.7	89.6	3.0×10^{6}	178.6	8.1×10^{9}
YOLO v8n－E	84.5	85.4	90.1	3.0×10^{6}	181.8	8.1×10^{9}
YOLO v8n－B	86.7	84.0	90.2	3.0×10^{6}	149.3	8.1×10^{9}
YOLO v8n－A	86.1	83.2	90.0	2.6×10^{6}	147.1	7.2×10^{9}
YOLO v8n－C	84.6	85.4	90.3	3.0×10^{6}	169.5	8.1×10^{9}
YOLO v8n－D	84.7	85.7	90.1	2.6×10^{6}	181.8	7.0×10^{9}
YOLO v8n－BA	85.7	83.7	90.1	2.6×10^{6}	133.3	7.3×10^{9}
YOLO v8n－BAC	85.7	85.4	90.8	2.6×10^{6}	151.5	7.3×10^{9}
BACD－YOLO	86.6	86.2	91.2	2.3×10^{6}	153.8	6.2×10^{9}

基础上同时采用所有优化方案的最终模型。

由消融试验结果可知，随着各改进方案的依次采用，模型的精度和轻量化性能都有了一定程度的提高。首先，采用了 Adamax 优化器模型的平均精度均值较初始模型提高了 0.5 个百分点，帧率基本不变，证明 Adamax 优化器的采用优化了模型的检测性能。在 YOLO v8n－E 模型中引入 BiFPN 网络后，模型的精确率和平均精度均值分别提高了 2.2 个百分点和 0.1 个百分点，证明 BiFPN 网络增强了模型对不同尺度的玉米及杂草目标的学习能力。在 YOLO v8n－E 模型中仅引入 Adown 轻量化下采样模块后，模型的参数量和浮点运算次数降低了 13.3% 和 11.1%，平均精度均值仅降低了 0.1 个百分点。在 YOLO v8n－E 模型中引入坐标注意力机制后，模型的轻量化指标未发生显著变化，模型的精确率和平均精度均值分别提高了 0.1 个百分点和 0.2 个百分点。将 DualConv 轻量化双卷积引入 YOLO v8n－E 模型后，模型的精度性能未发生降低，但参数量及浮点运算次数降低了 13.3% 和 13.6%，表明 DualConv 轻量化双卷积优化了特征信息的流动，对模型的轻量化性能改善具有较大的综合贡献价值。YOLO v8n－BA 模型较 YOLO v8n－B 模型平均精度均值下降了 0.1 个百分点，但参数量及浮点运算次数降低了 13.3% 和 9.9%，模型轻量化性能得到了较大提升。引入 CA 后的 YOLO v8n－BAC 模型的召回率较引入前提升了 1.7 个百分点，证明嵌入了检测目标的坐标信息后，模型更能精准地检测到小目标杂草的位置。采用所有优化方案的 BACD－YOLO 模型的召回率和平均精度均值高于其他模型，较 YOLO v8n 模型分别提升了 1.5 个百分点和 1.6 个百分点，且参数量及浮点运算次数分别降低了 23.3% 和 23.5%。综合分析，优化方案改善了模型检测精度并降低了模型计算复杂度，促进了模型的部署和应用。

2.3　主流模型对比试验

为探究当前主流检测模型与改进模型的性能差异，以进一步验证改进模型的优势，采用统一的试验环境和相同的数据集，对 YOLO v3tiny、YOLO v5n、YOLO v5s、YOLO v8n、YOLO v8s、YOLO v9s、YOLO 11s 模型[24－25]进行训练对比和结果分析，主流模型对比试验结果如表 2 所示。

表 2　主流模型对比试验结果

Tab. 2　Comparison test results of mainstream models

模型	精确率/%	召回率/%	平均精度均值/%	参数量	浮点运算次数
YOLO v3tiny	81.0	85.8	88.3	8.7×10^{6}	1.29×10^{10}
YOLO v5n	83.5	84.6	88.7	1.8×10^{6}	4.30×10^{9}
YOLO v5s	82.4	87.1	89.2	7.1×10^{6}	1.63×10^{10}
YOLO v8n	84.4	84.7	89.6	3.0×10^{6}	8.10×10^{9}
YOLO v8s	86.0	84.2	89.9	1.1×10^{7}	2.84×10^{10}
YOLO v9s	85.6	84.9	90.5	7.2×10^{6}	2.67×10^{10}
YOLO 11s	86.7	84.9	90.6	9.4×10^{6}	2.13×10^{10}
BACD－YOLO	86.6	86.2	91.2	2.3×10^{6}	6.20×10^{9}

由表 2 对比结果可知，YOLO v8n 模型较 YOLO v3tiny、YOLO v5n、YOLO v5s 等主流模型具有更高的精确率和平均精度均值，其平均精度均值比浮点运算次数最小的 YOLO v5n 模型高了 0.9 个百分点；相较于 YOLO v8s、YOLO v9s、YOLO 11s 模型，YOLO v8n 模型的精确率及平均精度均值略低，但参数量仅为 YOLO v8s、YOLO v9s、YOLO 11s 模型的 27.3%、41.7% 和 31.9%，浮点运算次数仅为 YOLO v8s、YOLO v9s、YOLO 11s 模型的 28.5%、30.3% 和 38.0%，证明 YOLO v8n 模型兼具精度和轻量化性能，最适宜进一步优化改进。改进模型相较于 YOLO v8n 模型，平均精度均值提高了 1.6 个百分点，为主流模型中平均精度均值最高的模型，且参数量和浮点运算次数仅为 YOLO v8n 模型的 76.7% 和 76.5%。综合来看，改进模型凭借较高的检测精度和较低的计算复

杂度,更适宜于玉米 2 ~ 5 叶期的杂草检测任务应用。

2.4 检测效果分析

为验证改进模型的实际检测效果,选取测试集中不同场景下的数据进行检测对比,试验结果如图 8 所示。图中,预测框代表预测目标所在位置,置信度代表对目标检测结果的确定程度,介于 0 到 1 之间,置信度越高,代表目标被预测到的程度越大。图中红色圆圈代表漏检目标。

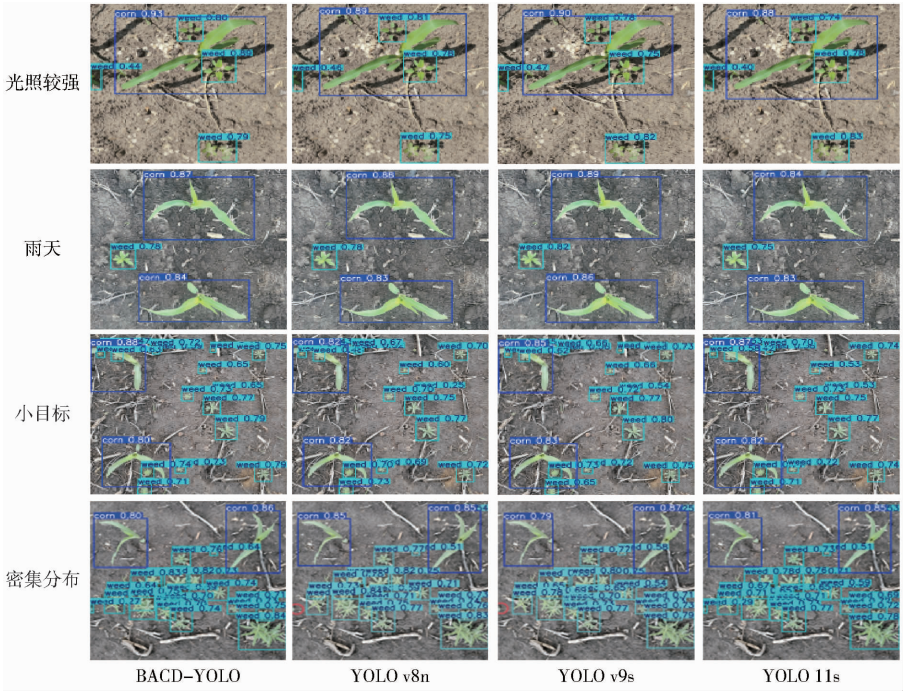

图 8 不同模型检测效果

Fig. 8 Detection effects of different models

在光线较强条件下,改进模型对玉米苗的置信度达到了 93%,在对比模型中达到了最高,证明改进模型在光照较强的条件下对较大目标的玉米苗检测效果较好,但在该条件下,4 个模型对图中左部小目标杂草检测精确率都较低,可能是阴影遮挡条件降低了模型对该区域的细节特征的辨认能力,结合小目标本身较少的像素值,进一步降低检测效果,未来可扩充小目标及阴影条件的数据优化检测效果。在雨天条件下,改进模型检测结果优于 YOLO 11s,稍逊于 YOLO v9s,可能是由于 YOLO v9s 模型采用独特的可编程梯度信息设计学习到更丰富的特征,在该条件下有更好的检测优势。在小目标检测条件下,改进模型的整体置信度普遍高于其他 3 个模型。在密集分布的条件下,YOLO v8n 和 YOLO v9s 模型出现了漏检,改进模型对杂草的检测效果较优,可能是改进方案中的 BiFPN 网络及 DualConv 轻量化双卷积优化了模型对密集区域的特征相似对象及不同尺寸目标的检测能力。综合上述场景可知,改进模型凭借泛化性较好、检测精确率较高、漏检率较低的优势,更适宜于进一步地部署应用。

2.5 不同数据集泛化性验证试验

为验证改进模型的泛化性,采用 Kaggle 平台提供的 weed-classification 公开数据集进行验证试验,数据集中包含 1 815 幅玉米苗图像和 985 幅杂草图像,共计 2 800 幅图像。其中包含多类杂草,且包含不同亮度和不同采集视角的条件。数据集中包含的玉米 2 ~ 5 叶期和玉米非 2 ~ 5 叶期下的图像数量比例为 8∶2。试验结果如表 3 所示。

表 3 不同数据集泛化性验证试验结果

Tab. 3 Generalization verification test results on different datasets

模型	生长时期	精确率/%	召回率/%	平均精度均值/%			参数量	浮点运算次数
				玉米	杂草	总体		
YOLO v8n	2 ~ 5 叶	93.5	91.0	98.1	92.3	95.2	3.0×10^6	8.1×10^9
	非 2 ~ 5 叶	85.2	85.8		88.6	88.6	3.0×10^6	8.1×10^9
	所有时期	91.2	92.3	98.8	92.4	95.6	3.0×10^6	8.1×10^9
BACD - YOLO	2 ~ 5 叶	92.3	93.5	97.8	93.8	95.8	2.3×10^6	6.2×10^9
	非 2 ~ 5 叶	86.5	86.5		89.1	89.1	2.3×10^6	6.2×10^9
	所有时期	91.7	93.5	98.8	93.4	96.1	2.3×10^6	6.2×10^9

由表 3 知，改进模型在公开数据集上全时期的精确率、召回率及平均精度均值分别比 YOLO v8n 模型高 0.5、1.2、0.5 个百分点，参数量及浮点运算次数也相较于初始模型更少。与陈雪等[3]及褚云等[6]提出的模型相比，本研究的改进模型较初始模型的精度提升比例较大，且在公开数据集上的高精度值证明本研究的改进模型具有较为优异的表征能力和泛化性能；同时本研究的改进模型在公开数据集上的召回率高于以上两位学者提出的模型，证明改进模型在复杂条件下对杂草的捕捉能力较强，漏检率较低。与本研究中自建数据集上的结果相比，改进模型在 weed-classification 公开数据集上的精确率和平均精度均值分别提高了 5.1 个百分点和 4.9 个百分点，原因主要是自建和公开数据集的数据复杂度及样本分布方面存在较大差异。自建数据集中包含实地采集的大量的具有挑战性的多样化样本以构建满足复杂条件下的高效检测模型，公开数据集中则存在复杂度偏低的较理想样本以验证模型在常规条件下的泛化能力。为进一步验证上述分析，将公开数据集划分为玉米 2～5 叶期和非 2～5 叶期。由表 3 知，改进模型在玉米 2～5 叶期的召回率和平均精度均值较改进前提高了 2.5 个百分点和 0.6 个百分点，分别达到了 93.5% 和 95.8%；而改进模型在玉米非 2～5 叶期的平均精度均值较改进前提高了 0.5 个百分点，为 89.1%，证明改进模型在玉米 2～5 叶期具有优异的检测性能及鲁棒性，且对非 2～5 叶期的杂草具有较好的检测能力。取公开数据集中不同场景下的图像验证模型检测效果，利用 Grad－CAM（Gradient-weighted class activation mapping）类梯度热力图[26－27]突出模型重点聚集区域，红色区域代表对检测结果贡献较大的区域，蓝色区域代表对检测结果贡献较小的区域。检测效果如图 9 所示。由检测效果知，改进模型在不同光照、不同长势、不同类别条件下的检测精度普遍高于 YOLO v8n 模型，且由热力图知，红色区域与检测目标所在区域重叠，表明模型理论关注重点区域与检测目标所在区域一致，证明改进模型具备较强的泛化能力。

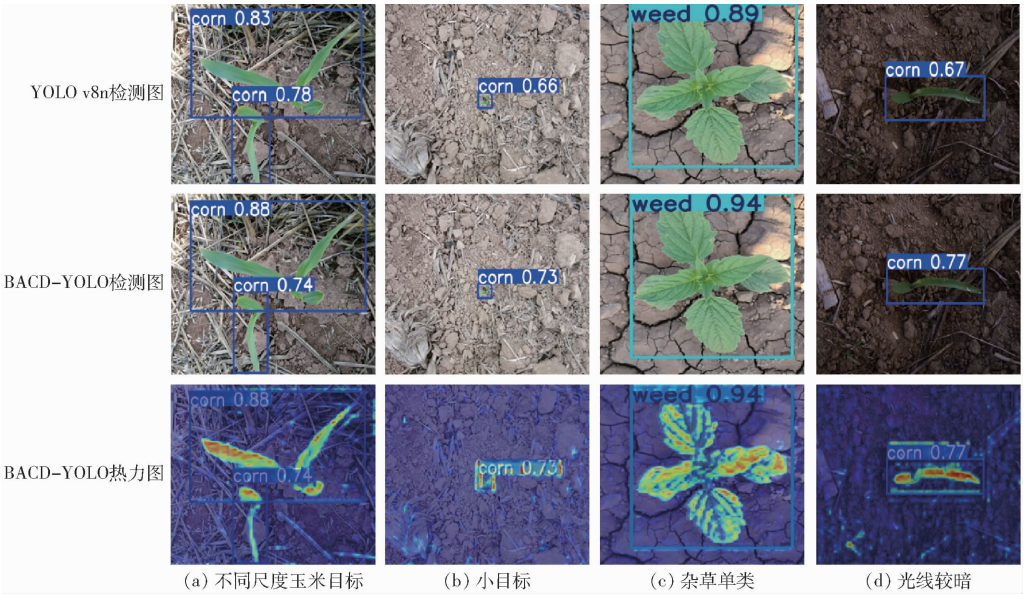

图 9　模型改进前后不同数据集检测效果对比

Fig. 9　Comparison of detection effects on different datasets before and after model improvement

2.6　模型部署及试验结果

本研究采用 Jetson Orin Nano Super 开发板进行模型部署试验，将改进后的模型和基线模型进行嵌入式部署试验[28]。试验在室内实施，采用实时视频检测方式对玉米苗及杂草进行检测试验，以 6 f/s 的速度从视频流中等间隔提取图像帧处理。玉米及杂草采用盆栽方式，每盆中包含 1～3 株玉米及杂草，杂草随机分布于玉米苗周围，盆栽间距 30 cm，共计 15 盆，盆栽位于同一水平线上，试验车沿预设直线轨迹匀速行进，轨迹平行于盆栽所在水平线，速度为 1.1 m/s。开发板内存为 8 GB，GPU 为 1024 核 NVIDIA Ampere 架构，摄像头为 30 万像素的 USB 摄像头，相机镜头中心距地面 60 cm，相机光轴与水平面呈 60°俯角，确保视野覆盖盆栽全区域。进行 5 次重复试验求平均值降低误差，部署试验环境如图 10 所示，实时检测效果如图 11 所示，试验结果如表 4 所示。

由部署结果可知，在检测精度方面，改进模型拥有更低的漏检率及误检率，在室内实时性检测任务中，改进模型检测精确率达到了 86.6%，较

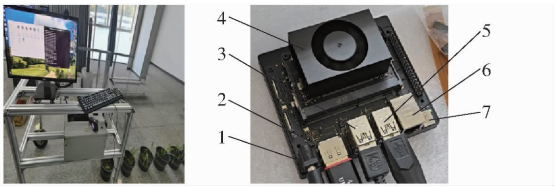

图 10 模型部署试验

Fig. 10 Model deployment experiment

1. 电源接口 2. 显示屏接口 3. 键盘接口 4. 散热风扇 5. 鼠标接口 6. RJ45 千兆网口 7. Type－C 接口

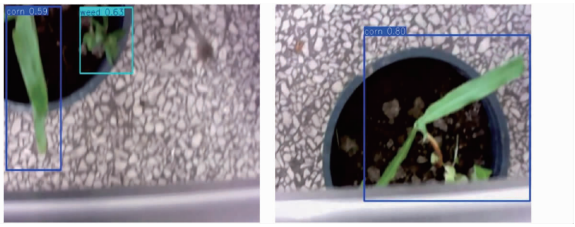

图 11 实时检测效果

Fig. 11 Real time detection effect

表 4 模型部署试验结果

Tab. 4 Model deployment test results

模型	漏检及误检数/个	目标总数/个	检测正确率/%	帧率/(f·s^{-1}) 计算机 GPU	帧率/(f·s^{-1}) 边缘设备
YOLO v8n	6	30	80.0	178.6	24.3
BACD－YOLO	4	30	86.6	153.8	19.4

YOLO v8n 模型提高了 6.6 个百分点。在计算机 GPU 和边缘设备上的帧率分别为 153.8 f/s 和 19.4 f/s，稍低于 YOLO v8n，但改进模型拥有更低的参数量及浮点运算次数，意味着改进模型在实际应用中适宜于更多常规资源受限的边缘端设备，该模型对部署设备性能需求较低。与王宁等[8]提出的模型相比，本研究提出的模型在精度和轻量化性能上均存在较大的优势；与刘莫尘等[9]提出的模型相比，本研究提出的模型具有更高的精确率及帧率和更低的参数量及内存占用量。结合研究文献及具体情况分析，造成改进模型帧率稍低的可能原因有：硬件与软件栈的优化差异导致改进模型无法享受 YOLO v8n 等主流模型级别的加速处理，且改进模型中采用的分组卷积等优化方案导致内存访问无序，影响了一定的硬件并行处理性能等[29]。但总体来看，改进模型拥有较高的检测精确率和较低的计算复杂度，在帧率方面基本满足实际田间杂草检测任务，应用前景较广阔。

3 结论

(1)为解决复杂环境下玉米 2～5 叶期作物及杂草检测精度和效率不均衡的问题，以适宜移动端部署应用为前提，通过在 YOLO v8n 模型中采用 Adamax 优化器、引入 BiFPN 网络、采用 Adown 轻量化下采样模块、加入 CA 及利用 DualConv 轻量化双卷积的方法得到高效检测模型 BACD－YOLO，实现对玉米苗及杂草的高效精准检测。

(2)改进模型相比于初始模型拥有更为优异的综合性能。精度方面，改进后的模型在自建数据集上的精确率、召回率及平均精度均值分别为 86.6%、86.2% 和 91.2%，较初始模型分别提升了 2.2、1.5、1.6 个百分点；轻量化方面，浮点运算次数和参数量分别为 6.2×10^9 和 2.3×10^6，较初始模型降低了 23.5% 和 23.3%。

(3)相较于当前主流杂草检测模型，本研究提出的改进模型兼具精度和轻量化的综合优势。在主流模型性能对比试验中，改进模型的平均精度均值达到最高，召回率仅次于 YOLO v5s 模型。轻量化性能仅次于 YOLO v5n，但精确率和平均精度均值比 YOLO v5n 高 3.1 个百分点和 2.5 个百分点。相较于同研究领域其他学者提出的模型，本研究提出的改进模型在玉米 2～5 叶期的复杂条件下具有更好的精度及轻量化均衡性、较大的综合性能提升比例和较强的泛化能力。由不同场景下的检测效果可知，改进模型在复杂条件下的检测精确率较高且漏检率较低。公开数据集的验证试验表明，改进模型较初始模型能更好地适应不同场景下的玉米 2～5 叶期作物及杂草检测任务。

(4)将改进模型部署至 Jetson Orin Nano Super 开发板进行实时性检测试验，试验结果表明，改进模型在嵌入式设备上的检测正确率较高，达到了 86.6%，且帧率达到 19.4 f/s，能够满足玉米 2～5 叶期作物及杂草的检测任务。未来可以通过剪枝蒸馏及优化网络结构的方式提高模型综合性能，通过启用 TensorRT 加速推理和调节量化配置等方式进一步优化模型的检测帧率，实现模型在农田杂草检测领域的深度应用。

参 考 文 献

[1] 梁晋欣. 除草机器人田间玉米幼苗识别方法研究[D]. 合肥：安徽农业大学，2023.
Liang Jinxin. Research on identification method of weeding robot field maize seedlings[D]. Hefei: Anhui Agricultural University, 2023. (in Chinese)

[2] 张景禹. 垄作玉米智能株间机械除草装置设计与试验[D]. 哈尔滨：东北农业大学，2021.
Zhang Jingyu. Design and experiment of intelligent mechanical weeding device for ridge corn[D]. Harbin: Northeast Agricultural University, 2021. (in Chinese)

[3] 陈雪，谭峰，宁韶瞳，等. 基于轻量级网络的玉米田间杂草识别方法[J]. 江苏农业科学，2025，53(20)：194－202.
Chen Xue, Tan Feng, Ning Shaotong, et al. Weed identification method in maize field based on lightweight network[J]. Jiangsu Agricultural Science, 2025, 53(20): 194－202. (in Chinese)
[4] Li L, Sun R, Xu Y F. Design and optimization of a new corn-weed detection model with YOLOv8－GAS based on artificial intelligence[J]. Journal of Real-time Image Processing, 2025, 22(8): 167.
[5] Guo L T, Wang X D, Zhang Y F, et al. RT－DETR－ME: a lightweight corn and weed detection algorithm based on improved RT－DETR[J]. Biosystems Engineering, 2025, 50(9): 410－423.
[6] 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 weed detection algorithm[J]. Journal of North China University (Natural Science Edition), 2025, 46(4): 489－498. (in Chinese)
[7] Wang Y, Xu S F, Cheng K H, et al. Optimized DINO model for accurate object detection of sesame seedlings and weeds[J]. Scientific Reports, 2025, 15(4): 11854.
[8] 王宁，尚忠，陈康，等. 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(2)：192－204.
Wang Ning, Shang Zhong, Chen Kang, et al Weed detection method in corn field based on improved YOLOv5s[J]. Journal of China Agricultural University, 2026, 31(2): 192－204. (in Chinese)
[9] 刘莫尘，高甜甜，马宗旭，等. 基于 MSRCR－YOLO v4－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. Field weed detection model for maize based on MSRCR－YOLO v4－tiny[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53 (2): 246－255, 335. (in Chinese)
[10] Le V N T, Truong G, Alameh K. Detecting weeds from crops under complex field environments based on Faster RCNN[C]// IEEE Eighth International Conference on Communications and Electronics (ICCE), 2021: 350－355.
[11] Li H S, Shi L, Fang S, et al. Real-time detection of apple leaf diseases in natural scenes based on YOLOv5[J]. Agriculture, 2023, 13(4): 878.
[12] Bagherpour H, Peyruo N F. Enhanced YOLO-based framework for accurate detection and identification of common wheat impurities with distinct objects[J]. Scientific Reports, 2025, 15(11): 40436.
[13] Güçlü S F. Modelling of pome fruit pollen performance using machine learning[J]. Scientific Reports, 2025, 15(2): 6913.
[14] Birla L, Bharadwaj A, Jain R, et al. Deep learning model BiFPN－YOLOv8m for tree counting in mango orchards using satellite remote sensing data[J]. Scientific Reports, 2025, 15(9): 33791.
[15] Du C F, Ma Z Z, Almodfer R, et al. A faster and lighter weight robotic ready model YOLO Punica for detecting pomegranate fruit development[J]. Scientific Reports, 2025, 15(11): 39274.
[16] Cai S B, Zhou X, Cai W C, et al. Lightweight underwater object detection method based on multi-scale edge information selection[J]. Scientific Reports, 2025, 15(7): 27681.
[17] Xiao J S, Zhang J, Li Z L. Global grouped coordinate attention for transformer in pedestrian trajectory prediction[J]. Signal Image and Video Processing, 2025, 19(6): 714.
[18] Yang G M, Wang Y B, Li X Y, et al. YOLOv9t－DM: a lightweight multi-target detection method for walnut shell kernel materials[J]. Signal Image and Video Processing, 2025, 19(5): 591.
[19] Duchi J, Hazan E, Singer Y. Adaptive subgradient methods for online learning and stochastic optimization[J]. Journal of Machine Learning Research, 2011, 12(7): 257－269.
[20] Song H Y, Huang X Y, Wang Z Q, et al. ADAM－DETR: an intelligent rice disease detection method based on adaptive multi-scale feature fusion[J]. Plant Methods, 2025, 21(8): 108.
[21] Chen Z W, Ma Y H, Gong Z A, et al. R－AFPN: a residual asymptotic feature pyramid network for UAV aerial photography of small targets[J]. Scientific Reports, 2025, 15(5): 16233.
[22] Pan Y, Zhao Y Q. Research on grape disease identification method based on improved YOLOv7[C]// International Symposium on Computer Technology and Information Science (ISCTIS), 2024: 781－786.
[23] Pan Y, Zhang H N, Hou Z Y, et al. Weed recognition method based on a lightweight YOLOv5[C]// International Conference on Neuromorphic Computing (ICNC), 2024: 1－5.
[24] Zhang H F, Wang B Y, Tang Z G, et al. A rapid field crop data collection method for complexity cropping patterns using UAV and YOLOv3[J]. Frontiers of Earth Science, 2024, 18: 242－255.
[25] Li G X, Li S, Fang X, et al. An improved YOLOv3 model for detection of invasive saccharomyces cerevisiae infections[J]. Multimedia Tools And Applications, 2025, 84: 14605－14622.
[26] 吕石磊，陈洁瑜，高鹏，等. 基于 YOLO－DRR 与实时处理 FPGA 边缘计算平台的低空视角下柑橘冠层分割[J]. 农业机械学报，2026，57(3)：67－76.
Lü Shilei, Chen Jieyu, Gao Peng, et al. Citrus canopy segmentation from low altitude perspective based on YOLO－DRR and real-time processing FPGA edge computing platform[J]. Transactions of the Chinese Society for Agricultural Machinery, 2026, 57(3): 67－76. (in Chinese)
[27] 张稳，张鑫哲，张在莹，等. 基于 EL－YOLO v8n 的轻量化群养猪只姿态识别与跟踪方法[J/OL]. 农业机械学报，2026－03－04. https://link.cnki.net/urlid/11.1964.s.20260304.1128.002.
[28] 段盛茂，章翔峰，姜宏，等. CEDL_YOLO：多尺度轻量化棉田杂草检测方法[J]. 计算机工程与应用，2025，61(24)：261－272.
Duan Shengmao, Zhang Xiangfeng, Jiang Hong, et al. CEDL_YOLO: multi scale lightweight weed detection method in cotton field[J]. Computer Engineering and Applications, 2025, 61(24): 261－272. (in Chinese)
[29] 陈胜宝，施隆照. YOLO－PD：轻量级实时行人检测算法[J]. 计算机工程与应用，2026，62(6)：122－133.
Chen Shengbao, Shi Longzhao. YOLO－PD: lightweight real-time pedestrian detection algorithm[J]. Computer Engineering and Applications, 2026, 62(6): 122－133. (in Chinese)