

基于 GEB - YOLO v8n 的烟草蚜虫识别与计数方法

罗斌^{1,2} 马乐意^{1,2} 周亚男^{1,3} 黄硕¹ 谢子文¹ 陈栋^{1,3}

(1.北京市农林科学院智能装备技术研究中心,北京 100097; 2.新疆农业大学机电工程学院,乌鲁木齐 830052;
3.农芯(南京)智慧农业研究院有限公司,南京 211800)

摘要: 蚜虫数量是直观表征烟草虫害侵染程度的表型指标之一,针对环境光照动态变化、图像模糊等田间图像采集问题,提出了一种 GEB - YOLO v8n 轻量化的烟草蚜虫检测算法。首先,主干网络引入 GSConv 与有效通道注意力机制(Efficient channel attention, ECA),增强了协同输出烟草蚜虫丰富的图像特征信息和目标导向能力;其次,颈部网络引入加权双向特征金字塔网络(Bidirectional feature pyramid network, BiFPN),增强了模型检测烟草蚜虫特征图的语义表达能力和空间信息质量;最后,引入 WIoU 作为边界框回归损失函数,通过动态聚焦复杂样本,使模型更好地泛化到新的、挑战性强的烟草蚜虫检测场景。经模型结构重参数化与超参数优化后,形成面向田间烟草蚜虫检测的网络架构。结果表明,改进后的模型平均精度均值(Mean average precision, mAP)和 F1 值分别达到了 91.8% 和 90.4%,参数量(Parameters)降低 42.8%,模型内存占用量(Model memory footprint)和浮点运算次数(Floating point operations, FLOPs)分别降低至 3.5 MB 和 4.1×10^9 ,平均推理时间缩短至 3.6 ms。基于 GEB - YOLO v8n 模型开发了一款面向小区田间烟草蚜虫识别与计数系统,系统具备在线式图像检测与视频检测双功能,能够在界面上直观展示烟草蚜虫数量检测结果,满足小区田间烟草蚜虫实时检测以及移动端部署的需求。本研究轻量化 GEB - YOLO v8n 模型为田间环境中烟草植物病虫害识别与表型分析提供了方法参考。

关键词: 烟草蚜虫; 精准识别; 计数; 轻量化; GEB - YOLO v8n

中图分类号: S126 文献标识码: A 文章编号: 1000-1298(2026)01-0159-10

OSID:



Tobacco Aphid Identification and Counting Method Based on GEB - YOLO v8n

LUO Bin^{1,2} MA Leyi^{1,2} ZHOU Ya'nan^{1,3} HUANG Shuo¹ XIE Ziwen¹ CHEN Dong^{1,3}

(1. Research Center of Intelligent Equipment, Beijing Academy of Agriculture and Forestry Sciences, Beijing 100097, China
2. College of Mechanical and Electrical Engineering, Xinjiang Agricultural University, Urumqi 830052, China
3. Nongxin (Nanjing) Smart Agriculture Research Institute Co., Ltd., Nanjing 211800, China)

Abstract: A lightweight tobacco aphid detection algorithm called GEB - YOLO v8n was proposed to address the problems in field image acquisition, such as dynamic changes in ambient light and image blurring. Firstly, GSConv and the efficient channel attention (ECA) mechanism were innovatively introduced into the backbone network, and the rich image feature information and target-oriented ability of tobacco aphids were jointly output. Secondly, the bidirectional feature pyramid network (BiFPN) was introduced into the neck network, and the semantic expression ability and spatial information quality of the model for detecting tobacco aphid feature maps were enhanced. Finally, WIoU was introduced as the bounding-box regression loss function, and the model was enabled to better generalize to new and challenging tobacco aphid detection scenarios by dynamically focusing on complex samples. After the model structure re-parameterization and hyperparameter optimization, a network architecture for field tobacco aphid detection was formed. The results showed that the mean average precision (mAP) and F1 value of the improved model reached 91.8% and 90.4%, respectively, the number of parameters was reduced by 42.8%, the model memory footprint and floating point operations (FLOPs) were reduced to 3.5 MB and 4.1×10^9 , respectively, and the average inference time reached 3.6 ms. A system for tobacco aphid recognition and counting in small-scale fields was developed based on the GEB - YOLO

收稿日期: 2025-08-11 修回日期: 2025-10-10

基金项目: 黔科合重大专项([2024]004)和中国烟草总公司贵州省公司科技项目(2024520000240085)

作者简介: 罗斌(1981—),男,副研究员,博士,主要从事农业智能装备研究,E-mail: luob@necita.org.cn

v8n model. The system had the dual functions of online image detection and video detection, and can intuitively display the detection results of the number of tobacco aphids on the interface, meeting the requirements of real-time detection of tobacco aphids in small-scale fields and mobile-end deployment. The improved lightweight GEB-YOLO v8n model can provide a method reference for the identification and phenotypic analysis of tobacco plant diseases and pests in the field environment.

Key words: tobacco aphid; precise identification; counting; lightweight; GEB-YOLO v8n

0 引言

烟草是我国重要的经济作物,在农业经济结构中占据重要地位。植物病虫害是影响小区田间烟草产量的主要因素之一,在中国各种植区呈现广域分布特征,其中烟蚜属于多代共存、体型微小且高密度聚集性生物,吸食田间烟草汁液并传播多种病毒,造成烟株生长缓慢,严重影响烟草的品质和产量^[1],同时其也为烟草花叶病毒病、烟草黄瓜花叶病毒病等 30 余种病毒的传播媒介^[2]。烟蚜数量的增长是导致烟草品质下降和产量锐减的重要因素,给烟草产业经济发展带来严峻挑战。因此,开展烟草蚜虫(烟蚜)识别与计数是烟草病虫害表型研究的一个重要方向。

传统的植物病虫害表型研究方法,包括黄板诱捕法^[3]、二氧化碳测量法^[4]和 X 射线计算机断层扫描^[5]等,在一定程度上能够观测烟蚜虫害等级和范围,指导种植户及时采取防治措施,对于降低烟蚜危害发挥了很好的效果。但存在时效性差、识别误差率高和人力成本投入高等问题^[6],同时面临着大量数据处理的挑战,无法适应大批量、快速、准确的植物表型测量需求,成为限制植物生物学表型研究的重要因素^[7],难以满足田间烟草种植的需求,检测技术的瓶颈也严重制约了烟草植物表型的研究。

近年来,随着图像传感器和计算机技术的快速发展,基于深度学习的目标识别技术为解决这一难题提供了新的思路和强有力的手段^[8-10]。多种基于深度学习的目标检测方法已被应用于植物病虫害表型的研究,如 Faster region convolutional neural network(Faster R-CNN)^[11]、Single shot multiBox detector(SSD)^[12]和 You only look once(YOLO)系列^[13]。其中 YOLO 系列模型作为一种代表性的目标识别算法,因其卓越的实时识别性能和出色的泛化能力,在农业病虫害检测领域得到了广泛的应用^[14-21]。ODverse33 基准测试揭示了不同 YOLO 版本和专业领域中模型性能的波动情况,强调了较新的 YOLO 版本并不能保证优于其早期版本^[22]。经查阅相关文献,目前对田间烟草植物虫害表型的研究和计数存在目标识别缺陷等技术问题。

针对上述问题,本文在相同硬件配置、参数和数

据集下使用各个系列的 YOLO 模型进行训练和验证,综合考虑模型的平均精度均值(mAP@0.5)、浮点运算次数(FLOPs)和模型内存占用量(Model memory footprint),选择 YOLO v8n 作为基础模型,构建一种轻量化、灵敏的烟蚜检测模型。深度解析植物病虫害的表型特征及图像表征,着重提升改进后的模型在田间环境中对烟蚜的识别和计数性能,解决烟蚜密集分布时出现错检和漏检的问题。在此基础上,探索构建模型的移动端部署方案,以期为田间烟草虫害表型研究提供高效、可靠的技术支持。

1 材料与方法

1.1 数据集获取

本研究数据集采集自贵州省毕节市林泉镇烟草科技园区(27.041 67°N, 105.862 05°E),该地日照强度变化幅度大,9 月平均温度达 29.8℃,月均降雨量 89.7 mm,适于烟蚜成长和繁殖。针对烟叶背面密集分布长度 0.5~1.2 mm 的腺毛特征和植株冠层叶片重叠率达 35%,烟蚜的多代共生及体长 0.9~2.1 mm、体色淡绿至深褐的个体差异,拍摄过程手动调整烟叶空间姿态,确保目标烟蚜的可检测性。数据分 3 个时间段采集^[23]:上午(07:00—09:00, 20~50 klx)、中午(11:00—13:00, 200~250 klx)和下午(16:00—18:00, 100~150 klx)。图像获取使用华为 Mate 30 Pro 型智能手机,距目标物 20 cm 进行拍摄,拍摄过程需调整设备位置消除光线干扰,获得 4 284 像素×5 712 像素 PNG 格式的原始图像。经质量筛选(包括模糊度检测和色度校准)后,得到 1 000 幅图像数据集,其中烟蚜小目标总数 31 358 只。

1.2 图像预处理与数据增强

为了提高网络模型的推理速度,本研究将尺寸 4 284 像素×5 712 像素的图像修改为 640 像素×640 像素^[24],用 LabelImg 对烟蚜进行手动标注,标注类为 Aphid。为提升模型的鲁棒性和面向小区田间环境的检测性能,设计多模态数据增强策略:添加高斯噪声和光照变化,如图 1 所示。将扩增后数据集在 LabelImg 标注软件下检查图像中烟蚜相对应的标签框,调整标签框位置和尺寸,确保在正确目标标签框下训练,进而提高模型的检测精度。图像预

处理后最终获得 3 000 幅图像,增强后的烟草蚜虫数量总数为 94 074 只,通过采用分层随机抽样法将所得的数据集按比例 8:1:1 划分,其中训练集 2 400 幅、验证集 300 幅和测试集 300 幅。



图 1 添加高斯噪声和光照变化数据增强技术

Fig. 1 Incorporating Gaussian noise and illumination variation as data augmentation techniques

1.3 GEB - YOLO v8n 模型构建及检测流程

研究基于 YOLO v8n 架构提出一种 GEB - YOLO v8n 模型,核心模块构成如图 2 所示。为应对田间环境(叶片部分遮挡、光照变化、叶片晃动)检测难题,改进主干网络和颈部网络架构,引入轻量级 GSConv、ECA 模块和 BiFPN 模块。构建多尺度特征融合、通道注意力模块以提升模型在田间环境下的特征选择作用,提高模型识别的精度;重构损失函数 WIoU,对距离敏感和田间环境下的检测进行优化,以满足小目标和密集目标的检测需求。




图 2 GEB - YOLO v8n 检测模型的框架

Fig. 2 GEB - YOLO v8n detection model structure

1.3.1 YOLO v8 模型

YOLO 算法是一种单阶段的目标检测网络框架,模型的网络结构简单且检测速度快,在目标检测领域具有广阔的应用前景^[13]。本研究选取 YOLO v8 作为烟草检测的基础模型,核心点在于解耦头部设计、Detect 检测范式以及采用 CIoU 的边界框损失函数组合,结合对主干网络、特征融合模块 SPPF 的优化以及先进的训练策略,推动了其精度和速度的提升。同时,提供的多样化预训练模型和出色的部署友好性,使其成为高效、高精度目标检测的强有力工具。YOLO v8 提供了多种不同尺寸的模型,如 YOLO v8n、YOLO v8s、YOLO v8m、YOLO v8l 和 YOLO v8x。研究采用 YOLO v8n 作为基准模型,不仅减少了计算量,而且简化了训练过程,同时支持多

种输入尺寸和尺度,适应不同分辨率的图像处理任务。该模型具备自适应锚框和图像缩放等技术,能够根据目标的表型调整锚框位置和尺寸。虽然该模型对检测群密集目标性能较好,但对检测小目标仍存在不足之处。

1.3.2 GEB - YOLO v8n 模型结构

为提高模型对烟蚜的检测性能,基于 YOLO v8n 模型对其主干网络、颈部网络和损失函数进行改进,具体结构改进方案如图 3 所示。在模型的主干网络中引入轻量级 GSConv 和 ECA 注意力模块,GSConv 通过将分组卷积和空间卷积相结合减少模型的计算量和参数量,并保持模型识别能力,ECA 注意力模块显著提升卷积神经网络的性能,同时引入极少的计算开销和参数;颈部网络引入双向特征金字塔网络 BiFPN 模块,实现田间环境下对烟蚜准确识别,丰富特征表达能力。




图 3 改进的 GEB - YOLO v8n 网络结构图

Fig. 3 Improved GEB - YOLO v8n network structure diagram

1.3.3 GSConv 模块

GSConv 模块是一种轻量级卷积技术,实现了精度和速度的平衡^[25],其结构如图 4 所示。GSConv 是通过分组卷积 (Grouped convolution)、通道混洗 (Channel shuffle) 和空间卷积 (Spatial convolution) 的结合来减少计算量。其中分组卷积将输入特征图分成若干组,每组分别进行卷积操作,可减少每组卷积的计算量;通道混洗将上一步得到的特征图 ($G \times H \times W$, 其中 G 为分组数量, H 为特征图高度, W 为特征图宽度) 进行通道维度的重新排列,打破组与组之间的隔离,确保了下一步逐点卷积能够处理来自原始不同输入组的通道信息;空间卷积将每组输出后特征图进行空间卷积操作,以捕捉跨组的特征。总之,GSConv 是一种有效的神经网络优化技术,通

过分组卷积和空间卷积的结合,在主干网络进行优化,达到了降低计算复杂度和参数数量的目的,适用于多种计算资源受限的检测场景。




图 4 GSConv 模块结构
Fig.4 Structure of GSConv module

虽然单步表达能力稍弱,但通过与下文网络模块(BiFPN)配合,可实现提高精度的同时得到更高的检测效率。GSConv 融合标准卷积与深度可分离卷积的优点,能够降低计算量且最大限度保留通道信息,避免小目标特征丢失,使模型在提取小目标特征的同时,捕获周围更广泛的上下文信息,对区分背景和小目标烟蚜具有重要的作用,直接提升了模型对小目标蚜虫的识别能力、检测鲁棒性和实时性,减少训练时间和计算资源的消耗。

1.3.4 ECA 注意力模块

ECA 注意力模块是一种新的卷积神经网络结构,是高效的通道注意力模块,对不同通道特征进行加权,使网络能够更好地捕捉长距离依赖关系,为每个通道生成一个权重,适应不同的输入尺寸^[26],其结构如图 5 所示。




图 5 ECA 模块结构图
Fig.5 Structural diagram of ECA module

图 5 中, X 为输入特征图, $\bar{X}$ 为经过加权后的输出特征图, C 为通道数,GAP 为给定全局平均池化, k 表示卷积核大小。

图 6 展示了 SE 与 ECA 模块结构对比示意图,图 6a 为 SE 模块,经过改进后得到 ECA 模块如图 6b 所示。将 MLP 模块($FC1 \rightarrow ReLU \rightarrow FC2 \rightarrow Sigmoid$)转变为一维卷积的形式(ECA module),有效减少了参数计算量。一维卷积自带的功效是非全连接,每一次卷积与部分通道相互作用,实现跨通道交互。Scale 是加权操作,Pool 是池化操作,FC1 的激活函数是 ReLU,FC2 的激活函数是 Sigmoid,分别降低和增加维度的全连接层,具有良好的性能和高效的计算能力,以极低的代价降低了模型复杂度,对烟蚜实




图 6 SE 与 ECA 模块结构对比示意图
Fig.6 Schematic of structural comparison between SE and ECA modules

时检测部署具有重要的作用。

ECA 注意力模块通过自适应学习通道权重,强化与烟蚜相关的特征通道(如颜色、纹理),抑制无关复杂背景,自动增强烟蚜表面的浅绿色/黄色特征,弱化叶片纤毛纹理的特征通道动态加权,使可见部位特征更显著。精准捕获通道间局部依赖关系(如蚜虫与植物茎的对比度),对处理不同尺寸的目标具有很好的适应性,区分烟蚜与叶片纹理的特征,减少了传统卷积层因感受野单一而发生漏检或误检情况。

1.3.5 BiFPN 模块

BiFPN 在设计上采用了轻量化的结构,通过对特征图进行高效融合和处理,避免了过多的冗余计算^[27],图 7 展示了 FPN 和 BiFPN 的特征网络结构图,FPN 引入了路径至上而下从 3 级到 7 级($P3 \sim P7$)融合的多尺度特征,BiFPN 可以通过自顶向下($P7 \sim P3$)和自底向上($P3 \sim P7$)的双向多尺度特征。与一些复杂的多尺度特征融合方法相比,BiFPN 能够在保证检测精度的前提下,显著减少模型的计算量和参数量,从而提高模型的运行效率。BiFPN 的高效网络结构使得模型能够更快地处理输入图像,对一些高实时性要求的检测具有重要的意义。

为提高模型对田间环境烟蚜的检测精度,引入 BiFPN 模块,通过自顶向下和自底向上的双向信息流,在不同尺度的特征图之间进行多次融合^[28]。这种双向融合机制能够更充分地利用不同尺度的特征信息,提取每个特征图包含的丰富信息,增强了特征表达能力。在烟蚜检测任务中,不同尺寸的烟蚜在不同尺度特征图上具有更好的识别作用,BiFPN 多尺度特征融合机制能够更好地整合不同尺度的特征信息,使模型能够更好地检测不同尺寸的目标,从而




图 7 FPN 和 BiFPN 的特征网络结构

Fig. 7 Feature network architecture of FPN and BiFPN

提高烟蚜检测性能。

1.3.6 损失函数 WIoU

在 YOLO 目标检测中,损失函数是训练的核心驱动力,量化了模型预测结果与真实标注之间的差异,并通过反向传播指导模型参数优化。YOLO 的损失函数通常由多项子损失组成,共同解决目标检测中的定位、分类和置信度任务。不同损失函数的设计直接影响模型的精度、速度和鲁棒性。

损失函数 WIoU 是一种有效且低成本的改进策略。Wiou 分别有 v1、v2、v3 版本,其中 v1 具有基本的动态聚焦,v2 增加了梯度增益控制,v3 实现离群度概念和两层注意力机制^[29]。本研究引入 WIoU v3 版本,通过核心动态样本加权机制,能够有效引导模型学习困难样本,提升田间环境下小目标的检测精度,获得更低的损失和更好的收敛状态,进而提高模型的泛化能力,实现更平衡的训练过程。

损失函数 WIoU v3 利用离群度 β 构造了一个非单调聚焦系数,并将其应用于 WIoU v1,得到了具有动态非单调聚焦的 WIoU v3。利用动态非单调聚焦的梯度增益分配策略,获得了优越的性能。Wiou v1 计算公式为

$$L_{\text{Wiou}v1} = R_{\text{Wiou}} L_{\text{IoU}} \tag{1}$$

其中
$$R_{\text{Wiou}} = \exp \frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)^*} \tag{2}$$

$$L_{\text{IoU}} = 1 - \text{IoU} \tag{3}$$

式中 (x,y) ——预测目标的边界框中心点坐标
 (x_{gt},y_{gt}) ——真实目标的边界框中心点坐标
 $W_g、H_g$ ——同时包含预测框和目标框的最小矩形框的宽度和高度

IoU ——交并比

$*$ ——停止梯度操作

损失函数 WIoU v3 通过 WIoU v1、离群度 β 和平衡系数 $\alpha、\delta$ 构建,其计算公式为

$$L_{\text{Wiou}v3} = r L_{\text{Wiou}v1} \tag{4}$$

其中
$$r = \frac{\beta}{\delta \alpha^{\beta-\delta}} \tag{5}$$

式中 r ——自适应权重,增强对困难样本的惩罚

离群度 β 是一个用来量化并衡量当前预测框与目标框匹配“困难程度”或“离群困难程度”或“离群程度”的指标。 β 越大,表示该样本越可能是离群样本(难样本、质量差的样本)。 β 越小,表示该样本越可能是普通样本。本文

$$\beta = \frac{L_{\text{IoU}}^*}{L_{\text{IoU}}} \tag{6}$$

改进后的损失函数 WIoU v3 在模型训练中自动调整预测框的尺寸,使得目标与锚框更加匹配,在田间环境中模型更易区分背景中烟蚜。

1.4 环境配置

计算机硬件配置为 14th Intel® Core™ i9 – 14900HX (2.20 GHz) 中央处理器 (CPU)、32 GB 运行内存 (RAM) 和 8 GB 显存、NVIDIA® GeForce™ RTX 4060M 图形处理器 (GPU),运行环境为 CUDA (版本 12.6.1)、Anaconda3 (版本 2024.10)、Python (版本 3.11.4) 和 PyTorch (版本 2.5.0),模型权重选用 YOLO v8n.pt。

考虑到模型检测的烟蚜目标尺寸过小,通过调整超参数以提高检测精度的前提下提升训练速度,其中环境配置和试验超参数训练如表 1 所示。

表 1 GEB-YOLO v8n 模型训练超参数
Tab.1 GEB-YOLO v8n model training hyperparameters

超参数	数值
学习率 (Lro)	0.01
衰减率 (Lrf)	0.01
动量 (Momentum)	0.937
权重衰减 (Weight-decay)	0.000 5
训练轮数 (Epochs)	200
批量大小 (Batch-size)	8
图像尺寸 (Image pixel)/(像素 × 像素)	640 × 640

1.5 模型评估指标

采用精确率 (P)、召回率 (R)、平均精度均值 ($\text{mAP}@0.5$) 和 F1 值作为评价模型目标检测性能指标。 $\text{mAP}@0.5$ 能综合反映模型在多个类别上的检测性能;F1 值用于评估模型在检测出所有目标的情况下的精确性和完整性^[30]。

为评估模型轻量化因素,本研究将模型内存占用量、参数量 (Parameters)、浮点运算次数 (FLOPs)、帧速度 (FPS) 和平均推理时间作为评估指标。模型内存占用量表示模型文件存储在磁盘中所占用的量,主要由模型的参数量决定,参数越多模型越大;参数量指模型需要学习的权重和偏置的总数量,参数越多的模型学习能力越强,潜力精度越高;浮点运算次数指模型对每次输入的图像进行一次完整推

理,所需要的浮点运算的总次数,值越大,对硬件的算力要求越高;帧速度指模型在特定硬件和软件环境下,每秒能够处理并输出结果的图像数量,直接决定了移动部署应用是否满足实时性检测需求;平均推理时间指模型处理单幅图像所需的平均时间,是衡量实际运行速度的核心指标。

2 试验与结果分析

2.1 网络模块训练效果比较

在基础 YOLO v8 模型的主干网络与颈部网络分别引入 SE、GSConv、ECA、BiFPN、CA 和 CBAM 模块,对比各模块对模型的关键特征识别能力的影响。以平均精度均值和浮点运算次数为指标评估识别效果,结果如表 2 所示。引入不同模块对模型的检测精度和浮点运算次数均有不同程度的优化,相较于其他模块,BiFPN 模块对提高烟蚜检测的准确性效果较优,相较于 YOLO v8n,mAP@ 0.5 提高 0.5 个百分点;而引入 GSConv 与 ECA 模块在保持平均精度均值同时,降低了浮点运算次数,分别降低 4×10^8 和 2.1×10^9 ,显著降低了模型的轻量化指标。综合

分析表 2 中试验结果,引入 GSConv、ECA、BiFPN 模块对模型检测精度与轻量化方面均有不同程度的提升。

表 2 引入不同模块试验结果对比

Tab.2 Comparison of test results from different modules

模型	平均精度均值/%	浮点运算次数
YOLO v8n	91.2	8.2×10^9
YOLO v8n + SE	91.3	8.2×10^9
YOLO v8n + GSConv	91.3	7.8×10^9
YOLO v8n + ECA	91.0	6.1×10^9
YOLO v8n + BiFPN	91.7	8.2×10^9
YOLO v8n + CA	91.2	8.1×10^9
YOLO v8n + CBAM	91.1	8.2×10^9

2.2 网络模型的参数变化

为深入理解模型在训练和验证过程的表现,图 8 全面展示了 GEB-YOLO v8n 模型各项训练与验证参数的变化情况。如图 8a 所示,在训练过程中,边界框和目标损失函数应尽可能最小化。损失值越低,表明模型越能准确预测边界框和类别标签,提升烟蚜的检测能力。

与之相对,图 8b 反映验证过程中,模型性能的




图 8 GEB-YOLO v8n 模型训练与验证模型参数

Fig. 8 Demonstrating model parameter behavior in training and validation of GEB-YOLO v8n model

优化程度、模型的准确性和整体性能。较高的精确率、召回率和平均精度值表明,该模型能有效区分田间烟蚜小目标,从而提升模型检测水平。通过细致分析这些图表所展示的模型行为,可以确定:用于烟蚜小目标识别的 GEB-YOLO v8n 模型展现出较好的准确率与效率,能精准识别烟蚜。经多种指标验证,该模型具有较高的烟蚜预测性能和实时检测烟蚜小目标的能力。

表 3 消融试验结果对比
Tab.3 Ablation study results comparison

BiFPN	GSConv	ECA	WIoU	平均精度均值/%	F1 值/%	浮点运算次数	模型内存占用量/MB	平均推理时间/ms
×	×	×	×	91.2	88.6	8.2×10^9	5.9	5.5
✓	×	×	×	91.7	89.0	8.2×10^9	6.0	5.5
✓	✓	×	×	91.9	90.5	7.2×10^9	5.3	5.2
✓	✓	✓	×	91.6	89.7	3.9×10^9	4.1	3.5
✓	✓	✓	✓	91.8	90.4	4.1×10^9	3.5	3.6

注:“✓”表示使用该模块,“×”表示不使用该模块。

从表 3 可知,把 BiFPN 模块引入 Neck 架构后,与 YOLO v8n 模型相比,对蚜虫的检测精度有一定提升,这是因为 BiFPN 通过引入高效的双向跨尺度连接和学习的加权特征融合机制,提升了 Neck 网络融合多尺度特征的能力。为使网络模型在实际应用中可以轻松部署至移动端,引入轻量化模块 GSConv 作为主干网络的基本模块,与 YOLO v8n 网络模型相比,平均精度均值与 F1 值均有所提升,浮点运算次数与模型内存占用量分别降低 1×10^9 和 0.6 MB,平均推理时间达 5.2 ms;在此基础上引入 ECA 注意力模块,并将损失函数替换为 WIoU,改进后的 GEB-YOLO v8n 模型与 YOLO v8n 相比,F1 值提高 1.8 个百分点,浮点运算次数、参数量、模型内存占用量均有显著的优化,分别降低 50.0%、42.8%、40.7%,满足模型在轻量化的同时又可以提高其检测精度。

综上,引入相应的模块对模型 GEB-YOLO v8n 在保持原有检测精度的同时,显著降低了浮点运算次数和模型内存占用量,使模型对图像的平均推理时间缩短至 3.6 ms。如表 3 所示,消融试验验证了各模块的有效性,为小目标烟蚜的检测提供了新的技术路径。

2.4 不同深度学习检测算法比较

GEB-YOLO v8n 与 Faster R-CNN、SSD、YOLO-SIP^[19]、YOLOPC^[31] 相比,平均精度均值和帧速度较优,如表 4 所示。其中 Faster R-CNN 和 SSD 分别使用 ResNet-50 和 VGG-16 作为特征提取层,而 ResNet-50 获得的特征图是单层的,分辨率相对较低,无法解决小尺寸目标的特征,导致很多漏检。不能准确检测烟蚜小目标。Faster R-CNN

2.3 消融试验

为评估不同模块对烟蚜的检测性能,以 YOLO v8n 作为基础模型,系统性地改进主干网络、颈部网络和损失函数。通过将 GSConv、ECA、BiFPN 模块引入 YOLO v8n 网络架构中,损失函数 CIoU 替换为 WIoU。为评估引入的模块对烟蚜检测模型的有效性,采用消融试验进行验证,试验在相同数据集和环境配置下进行,结果如表 3 所示。

和 SSD 的检测速度非常低且检测精度过小,模型尺寸很大,尤其是 Faster R-CNN 的参数量高达 43 169 873。YOLO-SIP 与 YOLOPC 作为改进后的模型,与 GEB-YOLO v8n 相比,检测准确率、检测速度和模型尺寸都有所不足,无法满足嵌入式移动终端的实际应用需求。GEB-YOLO v8n 模型显著降低了模型复杂度,平均精度均值达到 91.8%,参数量达到 1 722 626,帧速度高达 341 f/s,可满足移动终端部署应用的需求。

表 4 不同模型训练效果比较
Tab.4 Comparison of training performance across different models

模型	平均精度 均值/%	帧速度/ (f·s ⁻¹)	参数量
Faster R-CNN	14.9	13	43 169 873
SSD	37.4	37	27 262 976
YOLO-SIP	84.2	5	55 574 528
YOLOPC	91.4	59	15 099 494
GEB-YOLO v8n	91.8	341	1 722 626

2.5 多种 YOLO 系列模型之间的比较

为了评估改进后模型的检测性能,将 GEB-YOLO v8n 与 YOLO 多系列模型进行对比,试验均在同一计算机硬件下运行,采用相同的数据集进行训练和验证,试验结果如表 5 所示,各模块的 F1 值和平均精度均值较为接近,其中 YOLO v8m 模型的平均精度均值和 F1 值在各个模型中达到最高,分别为 91.8% 和 90.4%,但其参数量、浮点运算次数和模型内存占用量均达到最高,不适合模型部署于移动端,难以满足实时性检测需求。在评估模型性能

中,参数量直接影响模型训练时占用多少计算资源,模型内存占用量影响存储与内存资源,浮点运算次数直接影响模型的训练和推理速度,改进后的 GEB-YOLO v8n 模型的帧速度、浮点运算次数、参数量、模型内存占用量和平均推理时间与其他系列 YOLO 模型相比均达到最优,分别为 368 f/s、 4.1×10^9 、

1 722 626、3.5 MB 和 3.6 ms,综合性能优于其他系列 YOLO 模型,满足检测烟蚜检测的需求。从表 5 中的对比数据得出,该模型可部署至移动端,且对检测硬件的需求相对较低,在田间环境下对烟蚜检测任务中展现出良好的实时性,符合虫害现场检测的应用需求。

表 5 YOLO 系列模型在相同的数据集下性能对比

Tab.5 Performance comparison of YOLO series models on the same dataset							
模型	平均精度 均值/%	F1 值/%	帧速度/ (f·s ⁻¹)	浮点运算次数	参数量	模型内存占用 量/MB	平均推理 时间/ms
YOLO v5n	90.1	87.2	267	5.20×10^9	1 765 270	3.7	3.6
YOLO v5s	90.4	88.9	221	1.59×10^{10}	7 011 326	13.7	5.2
YOLO v5m	91.0	88.9	121	4.82×10^{10}	20 871 318	40.2	8.0
YOLO v7-tiny	89.5	86.9	227	1.31×10^{10}	6 017 531	11.6	4.7
YOLO v8n	91.2	88.6	200	8.20×10^9	3 011 043	5.9	5.5
YOLO v8s	91.3	88.6	186	2.84×10^{10}	11 135 987	21.4	7.3
YOLO v8m	91.6	89.4	82	7.91×10^{10}	25 856 883	49.6	15.1
YOLO v9t	90.5	87.9	80	1.07×10^{10}	2 659 286	5.8	16.6
YOLO v9s	90.6	88.4	55	3.96×10^{10}	9 743 366	19.3	18.0
YOLO v10n	89.8	86.5	175	8.70×10^9	2 707 430	5.5	5.7
YOLO v10s	90.9	88.1	153	1.64×10^{10}	8 067 110	15.7	8.5
YOLO v10m	91.5	88.4	93	5.91×10^{10}	16 451 542	31.9	21.1
GEB-YOLO v8n	91.8	90.4	341	4.10×10^9	1 722 626	3.5	3.6

GEB-YOLO v8n 与多种模型在不同田间环境中对烟蚜检测性能与效果的对比试验,图 9 展现了 YOLO 不同系列轻量 YOLO v5n、YOLO v7-tiny、YOLO v8n、YOLO v9t、YOLO v10n 以及 GEB-YOLO v8n 在测试集上的表现图,图中黑色圆框为漏检目标,黄色方框为错检目标。叶片表面含有一定的纤毛且颜色与蚜虫相近,干扰 YOLO 模型对烟蚜有效识别,YOLO v5n、YOLO v7-tiny、YOLO v8n、YOLO v9t、YOLO v10n 模型在识别田间环境预测中均出现了错检或漏检现象。针对烟蚜病虫害检测,改进后的 GEB-YOLO v8n 模型识别效果较好,预测图中并无错检与漏检现象,表明对 YOLO v8n 模型的改进效果较显著,能有效解决田间烟蚜虫害检测精度不足的问题。

综合以上结果,改进后的 GEB-YOLO v8n 模型不仅对田间烟蚜识别有一定的优势,而且轻量化改进能满足模型对烟蚜的实时性检测需求,对田间移动端部署的应用有一定的优势。

2.6 模型在烟蚜识别系统中的应用

烟草蚜虫识别系统是基于轻量化 GEB-YOLO v8n 模型检测识别,可应用于机器巡检、无人机监测蚜虫发生动态,替代人工巡查,提高识别效率和范围,快速判断烟蚜的发生情况,如图 10 所示。该系

统可以显著提升烟草蚜虫监测的效率和精准率,是人工智能赋能现代农业的典型示例。可实现人机交互,开发了可视化操作界面,突破了原始 YOLO 模型仅支持命令行操作的局限。该系统包含烟草蚜虫图像检测(支持 JPG/PNG 格式)功能和视频检测功能,可将图像中的烟蚜快速标记并统计出数量,显示于界面正下方,为植物虫害表型的研究提供辅助性支持。系统能有效解决复杂背景下小目标、密集目标的识别难题,满足田间实时检测应用需求。

3 结论

(1)开展田间环境中烟草植物虫害表型的研究,提出了一种轻量化的 GEB-YOLO v8n 检测模型,主干网络中引入了 GSConv 和 ECA 注意力模块,颈部网络引入了 BiFPN 双向特征加权融合网络,采用 WIoU 损失函数,增强卷积核感受野并提升预测框和目标框的匹配度,在降低模型对计算资源需求的同时,保持足够的特征提取能力,提升了烟蚜检测精度。

(2)在烟蚜检测任务中,由试验数据可以得到 GEB-YOLO v8n 模型的 mAP@0.5、F1 值达到了 91.8%、90.4%,与原始 YOLO v8n 模型相比,F1 值提高了 1.8 个百分点,浮点运算次数和模型内存占




图 9 YOLO 系列模型对烟蚜部分验证集检测结果对比

Fig. 9 Comparison of detection results of YOLO series models on a subset of validation set for tobacco aphids




图 10 烟草蚜虫检测系统

Fig. 10 Tobacco aphid detection system

用量分别达到了 4.1×10^9 和 4.2 MB。在保持精度的同时提升了模型的检测速度,并降低了模型对硬件资源的需求。

(3)所提出的 GEB - YOLO v8n 网络模型与基础 YOLO v8n 模型相比,浮点运算次数、参数量和模型内存占用量分别降低 50.0%、42.8% 和 40.7%,提升效果明显,表明改进后的模型能满足田间环境下烟蚜的实时检测需求,同时可为植物病虫害表型研究提供参考。

参 考 文 献

- [1] WANG Q, YUAN E, LING X, et al. An aphid facultative symbiont suppresses plant defence by manipulating aphid gene expression in salivary glands[J]. *Plant, Cell & Environment*, 2020, 43(9): 2311–2322.
- [2] BRAULT V, UZEST M, MONSION B, et al. Aphids as transport devices for plant viruses[J]. *Comptes Rendus. Biologies*, 2010, 333(6–7): 524–538.
- [3] TENGURI P, KRANTHI S, NAIK C B, et al. The comparison of species diversity and abundance of insect natural enemies in the domesticated species of cotton using the yellow pan trap method[J]. *Scientific Reports*, 2024, 14(1): 2787.
- [4] KOESTLER R J, SARDJONO S, KOESTLER D L. Detection of insect infestation in museum objects by carbon dioxide measurement using FTIR[J]. *International Biodeterioration & Biodegradation*, 2000, 46(4): 285–292.
- [5] ARBAT S, FORSCHLER B T, MONDI A M, et al. The case history of an insect infestation revealed using X-ray computed tomography and implications for museum collections management decisions[J]. *Heritage*, 2021, 4(3): 1016–1025.
- [6] 张慧春, 王国苏, 边黎明, 等. 基于光学相机的植物表型测量系统与时序生长模型研究[J]. *农业机械学报*, 2019, 50(10): 197–207.
- ZHANG Huichun, WANG Guosu, BIAN Liming, et al. Visible camera-based 3D phenotype measurement system and time-series visual growth model of plant[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2019, 50(10): 197–207. (in Chinese)
- [7] 黄霞, 郑顺义, 桂力, 等. 基于点云的谷粒高通量表型信息自动提取技术[J]. *农业机械学报*, 2018, 49(4): 257–264, 248.
- HUANG Xia, ZHENG Shunyi, GUI Li, et al. Automatic extraction of high-through put phenotypic information of grain based on point cloud[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2018, 49(4): 257–264, 248. (in Chinese)
- [8] 张振国, 邢振宇, 赵敏义, 等. 改进 YOLOv3 的复杂环境下红花丝检测方法[J]. *农业工程学报*, 2023, 39(3): 162–170.
- ZHANG Zhenguo, XING Zhenyu, ZHAO Minyi, et al. Detecting safflower filaments using an improved YOLOv3 under complex environments[J]. *Transactions of the CSAE*, 2023, 39(3): 162–170. (in Chinese)
- [9] LIU J, WANG X. Plant diseases and pests detection based on deep learning: a review[J]. *Plant Methods*, 2021, 17(1): 22.
- [10] 罗斌, 李家超, 周亚男, 等. 基于改进 YOLO v8 的轻量化稻瘟病孢子检测方法[J]. *农业机械学报*, 2024, 55(11): 32–38.
- LUO Bin, LI Jiachao, ZHOU Yanan, et al. Lightweight rice blast spores detection method based on improved YOLO v8[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(11): 32–38. (in Chinese)
- [11] REN S, HE K, GIRSHICK R, et al. Faster R–CNN: towards real-time object detection with region proposal networks[J]. *arXiv Preprint, arXiv: 1506. 01497*, 2015.
- [12] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multiBox detector[M]//LEIBE B, MATAS J, SEBE N, et al. *Computer Vision-ECCV 2016: Vol. 9905*. Cham: Springer International Publishing, 2016: 21–37.
- [13] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[J]. *arXiv Preprint, arXiv: 1506. 02640*, 2015.
- [14] 林文树, 张金生, 何乃磊. 基于改进 YOLO v4 的落叶松毛虫侵害树木实时检测方法[J]. *农业机械学报*, 2023, 54(4): 304–312, 393.
- LIN Wenshu, ZHANG Jinsheng, HE Nailei, et al. Real-time detection method of *Dendrolimus superans*-infested *Larix gmelinii* trees based on improved YOLO v4[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(4): 304–312, 393. (in Chinese)
- [15] LIU L, XIE C, WANG R, et al. Deep learning based automatic multiclass wild pest monitoring approach using hybrid global and local activated features[J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(11): 7589–7598.
- [16] KASHNATHAN T, SINGARAJU D, UYYALA S R. Insect classification and detection in field crops using modern machine learning techniques[J]. *Information Processing in Agriculture*, 2021, 8(3): 446–457.
- [17] XU W, XU T, ALEX THOMASSON J, et al. A lightweight SSV2–YOLO based model for detection of sugarcane aphids in unstructured natural environments[J]. *Computers and Electronics in Agriculture*, 2023, 211: 107961.
- [18] GUO Q, WANG C, XIAO D, et al. Automatic monitoring of flying vegetable insect pests using an RGB camera and YOLO–SIP detector[J]. *Precision Agriculture*, 2023, 24(2): 436–457.
- [19] 王泰华, 郭亚州, 张家乐, 等. 基于改进 YOLO v5s 的水稻害虫识别研究[J]. *农业机械学报*, 2024, 55(11): 39–48.
- WANG Taihua, GUO Yazhou, ZHANG Jiale, et al. Rice pest identification based on improved YOLO v5s [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(11): 39–48. (in Chinese)
- [20] LI R, WANG R, XIE C, et al. A coarse-to-fine network for aphid recognition and detection in the field[J]. *Biosystems Engineering*, 2019, 187: 39–52.

[30] TIAN X C, JIA X Y, DA Y Z, et al. Evaluating the sensitivity of vegetation indices to leaf area index variability at individual tree level using multispectral drone acquisitions[J]. *Agric. For Meteorol.*, 2025, 364: 110441.

[31] GAO S, RUN Z, YAN K, et al. Evaluating the saturation effect of vegetation indices in forests using 3D radiative transfer simulations and satellite observations[J]. *Remote Sens Environ*, 2023, 295: 113665.

[32] ATTO A M, GALICHET S, PASTOR D, et al. On joint parameterizations of linear and nonlinear functionals in neural networks[J]. *Neural Netw.*, 2023, 160: 12–21.

[33] 张智韬, 陈钦达, 黄小鱼, 等. 基于加权算法的空-天遥感升尺度土壤含盐量监测模型[J]. *农业机械学报*, 2022, 53(9): 226–238, 251.

ZHANG Zhitao, CHEN Qinda, HUANG Xiaoyu, et al. UAV – satellite remote sensing scale-up monitoring model of soil salinity based on dominant class variability-weighted method [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(9): 226–238, 251. (in Chinese)

[34] 王鹏, 严昂, 张弓. 考虑点扩散函数效应的光谱遥感图像超分辨率制图[J]. *信号处理*, 2024, 40(3): 599–608.

WANG Peng, YAN Ang, ZHANG Gong. Considering point spread function effect for spectral remote sensing image super-resolution mapping[J]. *Journal of Signal Processing*, 2024, 40(3): 599–608. (in Chinese)

~~~~~

(上接第 168 页)

[21] LACOTTE V, NGUYEN T, SEMPERE J D, et al. Pesticide-free robotic control of aphids as crop pests[J]. *AgriEngineering*, 2022, 4(4): 903–921.

[22] JIANG T, ZHONG Y. ODverse33: is the new YOLO version always better? A multi domain benchmark from YOLO v5 to v11 [A]. *arXiv Preprint, arXiv: 2502. 14314*, 2025.

[23] XU W, THOMASSON J A, SU Q, et al. A segmentation algorithm incorporating superpixel block and holistically nested edge for sugarcane aphids images under natural light conditions[J]. *Biosystems Engineering*, 2022, 216: 241–255.

[24] XU W, XU T, ALEX THOMASSON J, et al. A lightweight SSV2 – YOLO based model for detection of sugarcane aphids in unstructured natural environments[J]. *Computers and Electronics in Agriculture*, 2023, 211: 107961.

[25] LI H, LI J, WEI H, et al. Slim-neck by GSConv: a lightweight-design for real-time detector architectures[J]. *Journal of Real-Time Image Processing*, 2024, 21(3): 62.

[26] WANG Q, WU B, ZHU P, et al. ECA – Net: efficient channel attention for deep convolutional neural networks[J]. *arXiv Preprint, arXiv: 1109. 01155*, 2020.

[27] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[J]. *arXiv Preprint, arXiv: 1612. 03144*, 2017.

[28] TAN M, PANG R, LE Q V. EfficientDet: scalable and efficient object detection[J]. *arXiv Preprint, arXiv: 1911. 09070*, 2019.

[29] TONG Z, CHEN Y, XU Z, et al. Wise – IoU: bounding box regression loss with dynamic focusing mechanism[J]. *arXiv Preprint, arXiv: 2301. 10051*, 2023.

[30] WANG Z, JIN L, WANG S, et al. Apple stem/calyx real-time recognition using YOLO v5 algorithm for fruit automatic loading system[J]. *Postharvest Biology and Technology*, 2022, 185: 111808.

[31] 郑俊健, 兰玉彬, 熊万杰, 等. 基于 YOLOv5s 改进模型的小白菜虫害识别方法[J]. *农业工程学报*, 2024, 40(13): 124–133.

ZHENG Junjian, LAN Yubin, XIONG Wanjie, et al. Method for identification of Pak choi pests and diseases based on improved YOLOv5s[J]. *Transactions of the CSAE*, 2024, 40(13): 124–133. (in Chinese)