

贺洪江,刘毅祥,王双友. 基于改进 YOLO v5s 的叶菜病虫害检测算法研究[J]. 江苏农业科学,2025,53(5):244-250.

doi:10.15889/j.issn.1002-1302.2025.05.028

基于改进 YOLO v5s 的叶菜病虫害检测算法研究

贺洪江¹, 刘毅祥¹, 王双友²

(1. 河北工程大学信息与电气工程学院,河北邯郸 056000; 2. 邯郸学院软件学院,河北邯郸 056005)

摘要:叶菜病虫害的早期识别是提高叶菜产量和质量的重要保障,为提高常见叶菜病虫害的检测精度,针对实际生产中的复杂环境,以 YOLO v5s 为基准模型,提出一种改进的 FV-YOLO v5s 模型。首先,在主干网络中融合 CA 注意力机制模块与 C3 特征提取模块,形成了 C3CA 模块以增强叶菜病虫害的特征提取能力。接着在颈部网络中使用 Slim-neck 范式设计,高效提取图像中小尺寸目标的特征,增强特征融合的效率。最后用 WIoU 损失对原损失函数 CIoU 进行替换,更快地达到收敛状态并提升模型检测性能。结果表明,新模型的精度、召回率和平均精度均值分别达到了 92.2%、91.5%、94.8%。改进后的模型 FV-YOLO v5s 对比原 YOLO v5s 模型算法,精度、召回率、平均精度均值分别提高 2.7、1.4、1.8 百分点,优于现有的识别网络,包括 YOLO v7、YOLO v8、Faster R-CNN 等模型。FV-YOLO v5s 模型适用于现代农业生产环境,有助于快速识别和检测叶菜病虫害,且该研究为智慧农业中的叶菜高品质和高产量提供了依据,从而最大限度地减少经济损失。

关键词:叶菜病虫害;YOLO v5s;CA 注意力机制;Slim-neck;WIoU 损失函数

中图分类号:S126;TP391.41 **文献标志码:**A **文章编号:**1002-1302(2025)05-0244-06

叶菜类蔬菜在我国蔬菜产业中扮演着重要的角色,也是我国北方地区冬季储存量最多的蔬菜,在农业生产中占据重要地位,对我国农业市场的稳定发挥着重要作用。由于叶菜病虫害问题频发,缺乏良好的种植技术及病虫害防治措施,不仅影响叶菜的产量与效益,还给种植户加剧了经济负担^[1-2]。

随着 Faster R-CNN、SSD、YOLO 等目标检测算法不断迭代和进步,其为各种实际应用场景提供了强大的工具和技术支持^[3-6]。王云露等提出了基于改进 Faster R-CNN 的苹果叶部病害检测模型,对 5 类苹果叶部病害检测的平均精度均值达到 86.2%^[7]。Li 等提出了 YOLO-JD 网络模型,结合 Hourglass 特征提取模块、深度 Hourglass 特征提取模块和空间金字塔池化模块,对黄麻病虫害图像的平均识别准确率达到 96.63%^[8]。Wang 等提出 YOLO v3 改进的番茄病虫害算法,采用扩张卷积层替代主干网络中的卷积层,通过引入平衡因子,对损失函数中的小物体权重进行优化,对番茄常见病

虫害的检测结果进行统计分析,平均精度均值(*mAP*)为 91.81%^[9]。Soeb 等基于 YOLO v7 并通过使用数据增广技术,以增加数据集的多样性,进而提高对病虫害的识别准确率^[10]。

基于上述研究结果,在主流的深度学习网络模型中,YOLO 系列在农业领域表现优异。例如农作物目标检测、农业生态系统检测、作物病虫害检测等^[11]。对于常见的球形农产品,如番茄和苹果等的目标检测方法研究较为广泛,然而对叶菜的病虫害检测相关研究较少^[12-14]。本研究针对实际检测过程中叶菜颜色纹理相似、特征差异较小、图像中病虫害多为小尺寸目标且位于非结构化环境中等特性,提出了针对叶菜病虫害识别检测的 FV-YOLO v5s 模型,以期对叶菜的病虫害识别和移动端虫害检测提供技术支持。

1 叶菜图像数据获取与预处理

本研究的叶菜病虫害图像数据来源于邯郸国家现代农业产业园区现场采集和网络抓取,采集时间为 2023 年 8—9 月。采集设备为手机一加 Ace 竞速版,采用后置摄像头于不同位置拍摄采集图像,人工筛选出叶菜类蔬菜常见的 2 种虫害(蚜虫和烟粉虱)、白菜的 5 种病害(缺钙症、缺镁症、缺磷症、缺氮症、缺钾症)、菠菜的 3 种病害(霜霉病、病毒

收稿日期:2024-03-29

基金项目:河北省高等学校科学技术研究项目(编号:ZC2022095)。

作者简介:贺洪江(1964—),男,河北邯郸人,硕士,教授,研究方向为计算机检测与控制。E-mail:1446877734@qq.com。

通信作者:王双友,博士,副教授,研究方向为计算机视觉。E-mail:wsyhdc@163.com。

病、叶黄病),共计 1 974 张试验图像。为避免网络中过拟合现象,并增强所训练模型的鲁棒性和泛化能力,对获得的数据集中的原始图像进行了数据增广。通过随机应用裁剪、旋转、亮度调整和添加噪声等操作,样本数量扩充至 7 630 张图像,具体划分如表 1 所示。

表 1 数据集划分

类别	原始数量	增强后图像数量		
		训练集	验证集	测试集
蚜虫	186	479	63	63
烟粉虱(成虫)	115	471	66	67
烟粉虱(幼虫)	123	474	57	61
缺钙症	177	461	62	55
缺镁症	165	467	55	57
缺氮症	163	461	54	52
缺磷症	192	466	56	51
缺钾症	197	470	61	62
健康白菜	131	472	63	66
健康菠菜	147	485	60	43
霜霉病	157	466	50	66
病毒病	113	461	57	60
叶黄病	108	471	59	60
总计	1 974	6 104	763	763

2 叶菜病虫害识别算法及改进

2.1 YOLO v5 网络模型

YOLO v5 是单阶段目标检测算法中表现优异的模型。本研究以 YOLO v5s 为基础模型,兼顾了检测病虫害精度和对目标的检测速度,能够满足农业病虫害领域中的实际生产环境检测要求。

YOLO v5 的骨干网络采用了 CSPDarkNet 结构作为特征提取网络。它由 5 个卷积模块、4 个 C3 特征提取融合模块和 1 个 SPPF 模块组成。通过应用跨阶段连接等操作使网络能够融合特征、丰富梯度信息。Neck 网络中采用的 SPP 模块和 FPN + PAN 模块位于基准网络和头网络之间,通过自底向上的下采样传递强定位特征,从而生成信息更丰富的特征图,增强特征的多样性和鲁棒性。最终在 Head 网络获得 3 个不同尺度的特征层,利用获得的特征信息对各种尺寸的目标进行分类和定位,以获取病虫害的具体类别信息和位置信息,输出结果。FV - YOLO v5s 算法从 3 个方面对基准模型进行改进,其网络结构如图 1 所示。

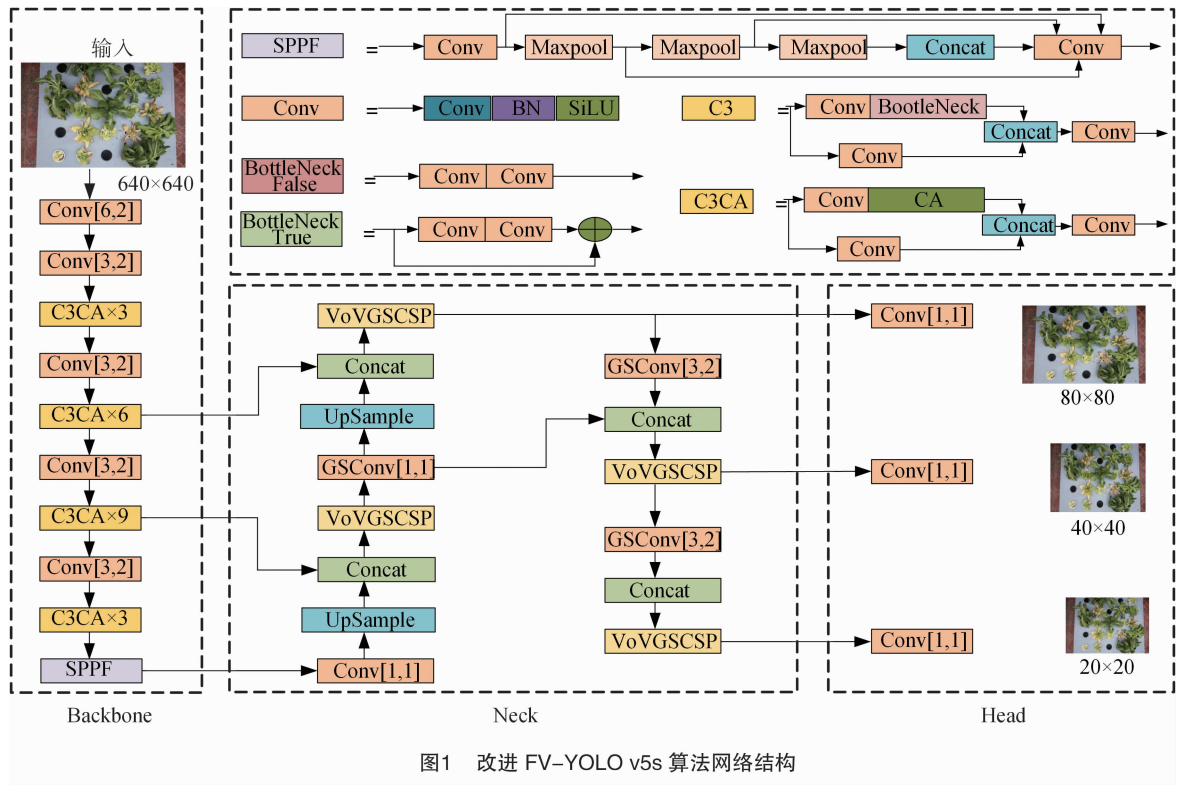


图1 改进 FV-YOLO v5s 算法网络结构

2.2 CA 注意力机制

本研究使用结合位置信息和通道注意力的轻

量级移动网络 CA 注意力模块,以针对性地提取叶菜病虫害特征信息并减弱其他干扰信息的影响^[15]。

CA 注意力模块分为 2 个步骤,分别为坐标信息嵌入和坐标注意力机制生成。

$$Z_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_c(i, j) \quad (1)$$

式中:给定输入特征张量 $X = [x_1, x_2, x_3, \dots, x_c] \in \mathbb{R}^{C \times H \times W}$,全局池化操作与第 c 通道相关的输出 Z_c 为式中 $x_c(i, j)$ 输入 X 的一个分量。

将输入特征图分别在水平和垂直方向上进行全局平均池化。获取图像在宽度和高度方向上的注意力并编码详细的位置信息。得到水平和垂直 2 个方向上的特征图。具体的计算公式如下:

$$z_c^h(h) = \frac{1}{W} \sum_{0 \leq i < W} x_c(h, i); \quad (2)$$

$$z_c^w(w) = \frac{1}{H} \sum_{0 \leq j < H} x_c(j, w) \quad (3)$$

坐标信息嵌入变换后接着将获得全局感受野的水平和垂直方向的特征向量进行融合,并利用卷积变换函数对其进行转换,从而获得更准确的坐标信息。

$$f = \delta \{ F_1([z^h, z^w]) \} \quad (4)$$

式中: $[z^h, z^w]$ 是特征图的拼接操作,函数 δ 是激活函数。将 f 沿着空间维数分解为 2 个单独的张量 $f^h \in \mathbb{R}^{C/r \times H}$ 和 $f^w \in \mathbb{R}^{C/r \times W}$ 。分别使用 2 个 1×1 卷积核 F_h 和 F_w ,将特征图 f^h 和 f^w 转换为与输入 X 同样的通道数的结果,从而得到的结果如下所式。

$$g^h = \sigma[F_h(f^h)]; \quad (5)$$

$$g^w = \sigma[F_w(f^w)] \quad (6)$$

式中: σ 是 Sigmoid 激活函数,在得到输入特征图在高度方向的注意力权重(g^h)、宽度方向的注意力权重(g^w)后,在原始特征图上通过乘法加权计算,最后,CA 注意力模块的输出 $y_c(i, j)$ 可以写成:

$$y_c(i, j) = x_c(i, j) \times g_c^h(i) \times g_c^w(j) \quad (7)$$

在本研究的网络中,采用了一种融合方法,将 CA 模块嵌入到 C3 模块中,用 CA 注意力模块替换传统 C3 模块中的 bottleneck 结构,得到了一种新的网络模块,即 C3CA 网络模块。其结构如图 2 所示。

2.3 Slim-neck 模块

Slim-neck 范式设计是在 GSConv 和 VoV-GSCSP 这 2 种技术的基础上进一步发展和融合而成。它通过将 2 个 GSConv 模块级联在一起,并使用 VoV-GSCSP 来替代颈部网络中的 C3 结构,组成 Slim-neck 结构。这种设计在保持模型性能的前提下,用更少的计算资源达到更高的效率,其核

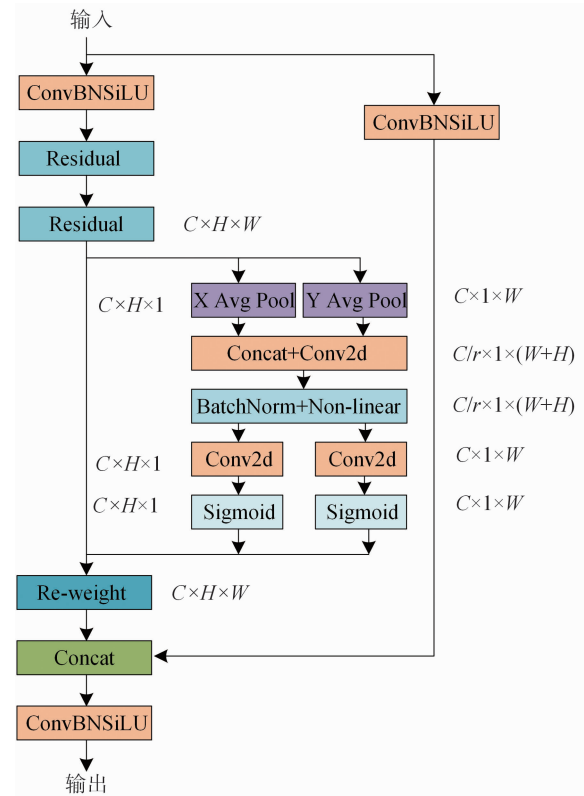


图2 C3CA 融合注意力模块展开图

心思想是将低维特征图与输入特征图相加,以融合不同层次的语义信息。通过一系列的卷积操作对特征进行处理,以提取更丰富的语义信息^[16]。

GSConv 模块是一种用于目标检测任务的卷积模块,能够获取更大范围的上下文信息,并促进对图像或空间数据的语义理解能力。它的核心思想是 GSConv 模块先输入进行一个普通卷积的下采样,然后使用 DWConv 深度卷积,并将 2 个 Conv 的结果拼接起来,最后进 Shuffle 操作,让之前 2 个卷积的对应通道数挨在一起,将全局上下文特征图与输入特征图相加,提取更丰富的语义信息。GSConv 网络结构如图 3 所示。

VoV-GSCSP 是用于构建深度神经网络的网络结构,它在颈部网络中同时引入了 GSConv 和 VoV-GSCSP,跨级部分网络是一种类似于残差块的结构,它允许网络在不同层级之间进行信息的跨级传递。这种结构可以促进特征的重用和信息流动,有助于提高模型的特征表达能力和优化训练过程。VoV-GSCSP 的网络结构如图 4 所示。

2.4 损失函数

原始 YOLO v5s 中使用的损失函数是由 IoU 衍生出现的 CIoU。传统的 IoU 计算方法只考虑了边界框的位置信息,而 CIoU 通过计算 2 个边界框的中

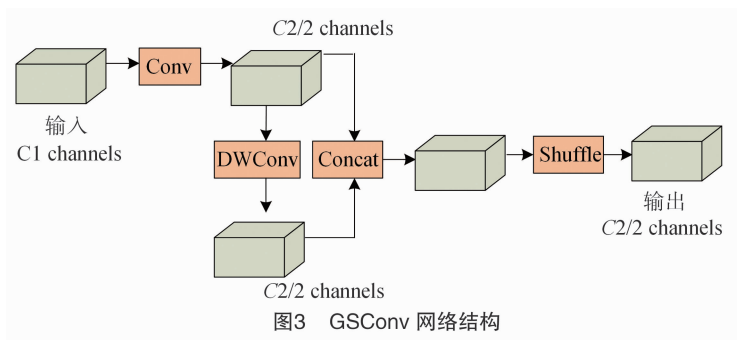


图3 GSCov网络结构




图4 VoV-GSCSP网络结构

心点之间的欧氏距离,并将其归一化,使得较远的边界框在计算中得到惩罚,从而更准确地衡量边界框之间的相似度。但CIoU对于小目标检测和长宽比例差异较大的目标定位等任务存在一定的局限性和不足的问题,且无法确保预测框的宽高同时增减。

WIoU损失函数去除了CIoU中的纵横比惩罚项,使用自适应调整的非单调聚焦机制通过离群度调整对不同锚框的关注度^[17]。同时,它平衡了高质量和低质量锚框对模型回归的影响,并给出了梯度增益分配的合理方案。本研究采用WIoU v3版本,其损失函数、离群度(β)公式如下:

$$L_{\text{WIoU v1}} = R_{\text{WIoU}} L_{\text{IoU}}; \quad (8)$$

$$R_{\text{WIoU}} = \exp \left[\frac{(x - x_{\text{gt}})^2 + (y - y_{\text{gt}})^2}{(W_g^2 + H_g^2)^*} \right]; \quad (9)$$

$$\beta = \frac{L_{\text{IoU}}^*}{L_{\text{IoU}}} \in [0, +\infty), r = \frac{\beta}{\delta \alpha^{\beta-\delta}}; \quad (10)$$

$$L_{\text{WIoU v3}} = r L_{\text{WIoU v1}} \circ \quad (11)$$

式中: x 和 y 为预测锚框的中心坐标; x_{gt} 、 y_{gt} 为目标锚框的中心点坐标; W_g 和 H_g 为预测框和目标框最小外接矩形的宽和高; L_{IoU}^* 为单调聚焦系数; $\overline{L_{\text{IoU}}}$ 为动态滑动平均值; r 为非单调聚焦因子; α 、 δ 为超参数。由于 $\overline{L_{\text{IoU}}}$ 是动态的,锚框的质量划分是一种动态的过程,其中重要的是采用WIoU来进行梯度增益分配策略,以在每个时刻选择最符合当前情况的策略。

3 试验验证与结果分析

3.1 试验设定及训练策略

本试验在Linux操作系统的图像工作站,GPU

为NVIDIA A30,显存24 GB,编程语言为Python 3.10,软件环境包括在Ubuntu 20.04操作系统下运行的PyTorch 2.0.1深度学习框架,以及CUDA 12.2并行计算架构。

优化后的YOLO v5s选择在GPU上进行训练,使用SGD优化器进行优化,图像输入尺寸为640像素×640像素,初始学习率设置成0.01,动量初始值0.92,权重衰减系数为0.000 5,样本批量大小为32,并进行了300个epochs的训练轮次。置信度阈值为0.5。试验时间为2023年10—12月,试验地点为邯郸学院西校区。

3.2 模型评价指标

在本试验中,设置了一系列的参数来评估模型的性能。对于叶菜病虫害目标使用精度(Precision)、召回率(Recall)、平均精度均值(mAP)、网络参数量(Parameters)作为衡量模型预测的性能评价指标,采用检测速度FPS(帧/s)作为模型的识别速度评价指标。

3.3 模型结果分析

在试验中进行了多项对比消融试验。根据前述的改进策略和试验参数设置,在训练了300个轮次后,对引入的注意力机制模块进行评估,将多个主流注意力模块进行比较,包括GAM注意力模块、CBAM注意力模块以及C3CA注意力模块。试验结果表明,C3CA注意力模块能够更好地提取目标特征,对叶菜病虫害的平均精度均值最高(图5)。本试验验证了C3CA注意力模块的优越性能,并为后续讨论提供了试验依据。

基于引入C3CA的模型,通过更换基础模型的损失函数,主要对比了其他主流损失函数(如WIoU v1、 α -IoU、CIoU)后发现,在目标精度和召回率方面,这些损失函数之间没有明显差异。但在边界差回归方面,WIoU v3表现出了更快的收敛速度和更高的精度。相比其他损失函数更为优秀。这对于目




图5 不同注意力机制模块的平均精度均值对比

标检测任务的准确度和稳定性至关重要。对比结果如图 6 所示。

最后网络中引入 Slim - neck 范式设计的模块

对网络进行改进,并对模型的各项性能进行了评估。与原始的 YOLO v5s 模型相比各项参数指标的变化如表 2 所示。




图6 不同损失函数回归 Loss 对比

表 2 不同改进消融试验结果

试验	模型	C3CA	Slim - neck	WIoU	精度 (%)	召回率 (%)	mAP (%)	网络参数量 (M)	检测速度 (帧/s)
1	YOLO v5s	×	×	×	89.5	90.1	93.0	7.02	158
2		√	×	×	90.6	91.1	94.2	6.43	151
3		×	√	×	92.1	87.8	93.9	7.18	166
4		×	×	√	91.5	88.6	93.7	7.02	163
5		√	√	×	93.1	90.1	94.7	6.58	155
6		√	×	√	91.8	88.9	94.0	6.43	153
7		×	√	√	91.4	90.0	94.2	7.18	160
8		√	√	√	92.2	91.5	94.8	6.58	149

由表 2 数据可知,试验 1 采用原 YOLO v5s 模型,该模型对叶菜病虫害识别的 mAP 为 93.0%,参数量为 7.02 M,平均检测速度达到了 158 帧/s;试验 2 在主干网络中将 CA 注意力机制模块与 C3 特征提取模块融合构成 C3CA 模块, mAP 较试验 1 提升了 1.2 百分点,为 94.2%,参数量降低了 8.40%,但检测速度下降了 7 帧/s;试验 3 在试验 1 的基础上将 Slim - neck 模块引入颈部网络,在维持识别准确度的同时减少网络的参数数量和计算负担,与试验 1 相比, mAP 提升了 0.9 百分点,检测速度提高了 8 帧/s。在试验 4 中,通过将原网络损失函数 CIOU 替换为 WIOU v3 损失函数,成功提高了模型对病虫害目标检测的回归效率,从而略微提升了检测精度和检测时间,同时保持了参数数量的不变。试验 5、6、7 分别对 3 个改进模块进行组合,相对于试验 1 中的模型,分别实现了 1.7、1.0、1.2 百分点的 mAP 提升。最后在试验 8 中得到的改进模型表现出最优综合性能,其 mAP 达到了 94.8%,而参数量仅为 6.58 M,尽管检测速度下降了 9 帧/s,但仍足以满足

实际作业过程中对实时检测的需求。

本研究对最终改进后的算法效果在自建数据集中进行了对比试验,图 7 展示了随机选择的多场景下的叶菜病虫害图像,包括小目标、颜色与背景相似的目标、多种病害遮挡目标。选取 2 张虫害图像和 4 张病害图像。可以看出,由于烟粉虱幼虫目标较小,蚜虫颜色与背景色相近,原 YOLO v5s 模型在小目标和背景相似的场景下存在漏检问题。在常见的叶菜病害和复杂遮挡场景中,检测到的目标置信度较低。改进后的模型在检测叶菜病虫害图像时,置信度更高,并且显著减少了病虫害目标的漏检现象。

将本研究提出的 FV - YOLO v5s 算法模型与其他主流的卷积神经网络模型对比试验,包括 YOLO v8、YOLO v5s、Faster R - CNN 和 SSD 等模型。在同样的参数设置条件下,使用自建的叶菜病虫害数据集进行训练和测试,最终得到了如表 3 所示的性能测试结果。

根据表 3 的结果,在自建样本集上与其他模型

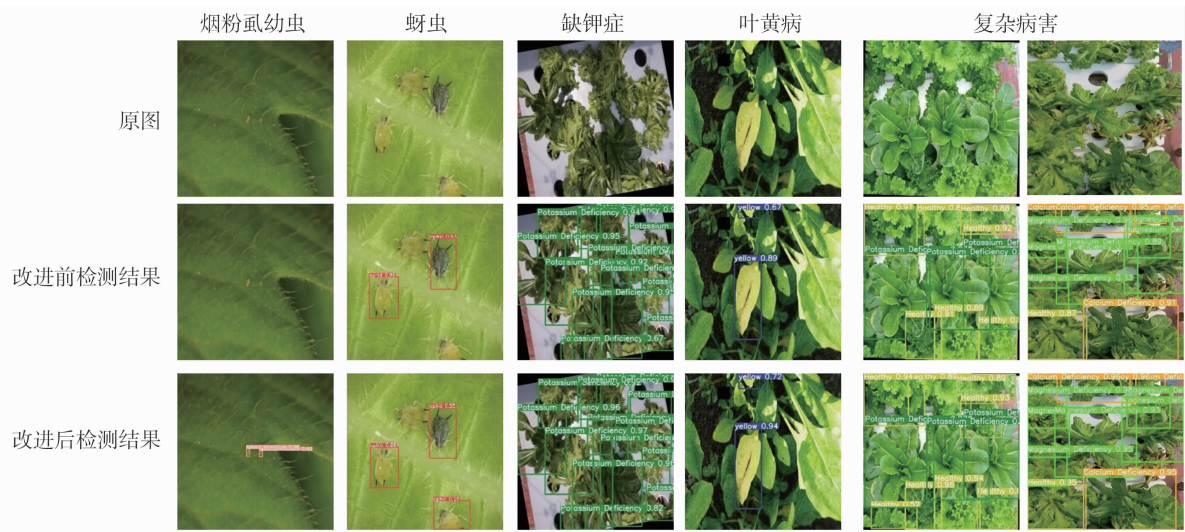


图7 YOLO v5s 改进后部分检测效果对比

表 3 不同模型对比结果

模型	精度 (%)	召回率 (%)	平均精度均值 (%)	检测速度 (帧/s)
Faster R - CNN	75.7	63.8	88.2	23
SSD	65.2	69.3	73.8	41
YOLO v5s	89.5	90.1	93.0	158
YOLO v5m	91.6	91.1	93.2	142
YOLO v7	89.2	89.5	92.1	138
YOLO v8s	90.7	89.1	93.2	151
FV - YOLO v5s	92.2	91.5	94.8	149

相比,本试验中的 FV - YOLO v5s 模型表现出对叶菜病虫害更高的识别精度和召回率,分别达到 92.2% 和 91.5%,模型的 *mAP* 达到了 94.8%,表明在算法性能方面取得了显著的改进效果。模型的检测速度虽然降低,但仍能满足实际生产环境对叶菜病虫害检测与识别的需求,能够在复杂背景情况下识别目标病害。

4 结论

本研究提出的 FV - YOLO v5s 模型提高了实际生产环境中的常见叶菜病虫害识别准确率,为智慧农业中的叶菜高品质和高产量生产提供了参考。首先将 C3 模块融合 CA 注意力机制,提升了对病虫害特征的提取能力,Neck 部分使用 Slim - Neck 范式结构,在保证识别精度的前提下,简化了模型的复杂程度;接着将损失函数替换为 WIoU,加快收敛速度,提高任务的精确度和稳定性。

本研究模型对叶菜共 10 类病虫害的识别平均精度均值为 94.8%,精度为 92.2%,召回率为 91.5%,与原模型和其他优化模型相比均有不同程

度的提升。试验结果表明,该方法在目标颜色与背景相似下识别精度和鲁棒性有了显著提升,尽管模型的检测速度略有降低,但仍能满足实际生产环境对叶菜病虫害检测与识别的需求,具有较高的应用价值,可以为后续其他的叶菜病虫害检测提供参考。

参考文献:

[1]金利容,丛胜波,黄薇,等. 播种后直接覆盖 29 目防虫网防控叶菜害虫[J]. 中南农业科技,2022,43(5):16-19.

[2]岳崇勤,张寒波,堵一鸣. 3 种叶菜播种机适应性研究[J]. 长江蔬菜,2023(13):13-15.

[3]Girshick R. Fast R - CNN[C]//Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV). Washington, DC:IEEE Computer Society,2015:1440-1448.

[4]Ren S Q,He K M,Girshick R,et al. Faster R - CNN:towards real - time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2017,39(6):1137-1149.

[5]Liu W,Anguelov D,Erhan D,et al. SSD:single shot MultiBox detector[M]//Lecture notes in computer science. Cham:Springer International Publishing,2016:21-37.

[6]Redmon J,Divvala S,Girshick R,et al. You only look once:unified, real - time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas,NV, USA:IEEE,2016:779-788.

[7]王云露,吴杰芳,兰鹏,等. 基于改进 Faster R - CNN 的苹果叶部病害识别方法[J]. 林业工程学报,2022,7(1):153-159.

[8]Li D W,Ahmed F,Wu N L,et al. YOLO - JD:a deep learning network for jute diseases and pests detection from images[J]. Plants,2022,11(7):937.

[9]Wang X W,Liu J,Zhu X N. Early real - time detection algorithm of tomato diseases and pests in the natural environment[J]. Plant Methods,2021,17(1):43.

刘 嘉,曾鹏滔,王志胜. 基于改进 YOLO v5s 的复杂环境下棉叶病虫害识别[J]. 江苏农业科学,2025,53(5):250-257.

doi:10.15889/j.issn.1002-1302.2025.05.029

基于改进 YOLO v5s 的复杂环境下棉叶病虫害识别

刘 嘉,曾鹏滔,王志胜,撒金海

(新疆大学软件学院,新疆乌鲁木齐 830000)

摘要:棉叶病虫害是影响棉花产量的关键性因素,为解决传统人工棉叶病虫害识别准确率低的问题,提出一种基于 YOLO v5s 的改进模型来实现真实环境下的棉叶病虫害精确识别,该模型将 YOLO v5 模型的原主干网络改进为一种新的纯轻量级卷积网络架构 RepViT,它与 YOLO v5 原有的主干网络 CSPNet 相比不但参数更少且具有更高的平均精度均值;再使用一种基于 MPDIoU 的边界框回归损失函数 MLPDIoU 来减小背景损失在置信损失中的占比,使得模型收敛更快速,模型训练更加充分,提高本模型在复杂背景下的目标检测精度;最后针对棉叶病虫害检测时存在的叶片背景复杂、病虫害叶片与健康叶片高度相似、同一张图像可能出现数种不同病虫害叶片的问题,在 SPPF 层之前添加 ECA 注意力机制,使本模型能更好的提取病虫害叶片的特征,减少背景的干扰。通过以上改进,该模型在真实环境下对棉叶病虫害检测的准确率达到 91.4%,均值平均精度达到 85.8%,相较于 SSD、YOLO v3、YOLO v4、YOLO v5 等传统模型,准确率分别提高了 6.3、2.7、7.5、3.4 百分点,平均均值精度分别提高了 4.0、5.2、4.6、4.8 百分点,可以有效识别出各种棉叶病虫害,为棉花种植户进行参考。

关键词:目标检测;棉叶病虫害;主干网络;损失函数;注意力机制

中图分类号:TP391.41;S126 **文献标志码:**A **文章编号:**1002-1302(2025)05-0250-08

新疆棉是全球最好的棉花之一,因其品质优良,产量大,常年供不应求。根据国家统计局资料显示,2022 年新疆棉产量为 539.1 万 t,较上年增加 26.2 万 t,占我国棉花总产量的比重持续提升,达到 90.2%,创历史新高^[1]。据统计,新疆是我国最大的棉花产地,也是世界最重要的棉花产地之一,全

新疆大约有一半的农民从事棉花种植或其相关行业,棉已经成为新疆地区的支柱产业之一^[2]。

棉叶病虫害是棉生产的关键性制约因素,一般年份造成的产量损失达 15%~20%,严重年份可达 30%~50%^[3-4]。因新疆地区的气候环境特殊,地广人稀且缺乏病虫害专家的指导,新疆棉病虫害危害总体严重,发生演变规律复杂。因此,提出一种基于改进 YOLO v5s 的棉叶病虫害识别模型,尝试将目标检测技术应用于棉叶病虫害检测,选取新疆棉产区区内常见的棉叶病虫害,包括链格孢叶斑病、卷叶病、红斑病、白叶枯病、叶面病和除草剂的图片作为数据集,以期实现新疆棉叶病虫害的精准识

收稿日期:2024-01-06

基金项目:国家自然科学基金(编号:62266043)。

作者简介:刘 嘉(1999—),男,江苏徐州人,硕士研究生,研究方向为图像处理。E-mail:2505188345@qq.com。

通信作者:撒金海,高级工程师,研究方向为图像处理。E-mail:super_sjh@163.com。

[10] Soeb M J A, Jubayer M F, Tarin T A, et al. Tea leaf disease detection and identification based on YOLO v7 (YOLO-T) [J]. Scientific Reports, 2023, 13(1): 6078.

[11] 黄成龙,柯宇曦,华向东,等. 边缘计算在智慧农业中的应用现状与展望[J]. 农业工程学报, 2022, 38(16): 224-234.

[12] 杨 坚,钱 振,张燕军,等. 采用改进 YOLO v4-tiny 的复杂环境下番茄实时识别[J]. 农业工程学报, 2022, 38(9): 215-221.

[13] 吕志远,张付杰,魏晓明,等. 采用组合增强的 YOLOX-ViT 协同识别温室番茄果实[J]. 农业工程学报, 2023, 39(4): 124-134.

[14] 周桂红,马 帅,梁芳芳. 基于改进 YOLO v4 模型的全景图像

苹果识别[J]. 农业工程学报, 2022, 38(21): 159-168.

[15] Hou Q B, Zhou D Q, Feng J S. Coordinate attention for efficient mobile network design [C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville, TN, USA: IEEE, 2021: 13708-13717.

[16] Li H L, Li J, Wei H B, et al. Slim-neck by GSConv: a better design paradigm of detector architectures for autonomous vehicles [EB/OL]. (2022-06-06) [2024-03-01]. <https://arxiv.org/abs/2206.02424>.

[17] Tong Z, Chen Y, Xu Z, et al. Wise-IoU: Bounding Box Regression loss with dynamic focusing mechanism [EB/OL]. (2023-04-08) [2024-03-10]. <https://arxiv.org/abs/2301.10051>.