

doi:10.6041/j. issn. 1000-1298. 2023. S1. 024

基于改进 YOLO v5s 的作物黄化曲叶病检测方法

左昊轩¹ 黄祺成¹ 杨佳昊² 孙 泉² 李思恩³ 李 莉¹

(1. 中国农业大学农业农村部农业信息获取技术重点实验室, 北京 100083;

2. 中国农业大学智慧农业系统集成研究教育部重点实验室, 北京 100083;

3. 中国农业大学水利与土木工程学院, 北京 100083)

摘要: 作物病害的初期快速准确识别是减小作物经济损失的重要保障。针对实际生产环境中,作物叶片黄化曲叶病毒病(Yellow leaf curl virus, YLCV)患病初期无法应用传统图像处理算法通过颜色或纹理特征进行准确和快速识别,并且 YOLO v5s 通用模型在复杂环境下识别效果差和效率低的问题,本文提出一种集成改进的叶片病害检测识别方法。该方法通过对 Plant Village 公开数据集中单一患病叶片图像以及实际生产中手机拍摄获取的患病作物冠层图像两种来源制作数据集,并对图像中的患病叶片进行手动标注等操作,以实现在复杂地物背景和叶片遮挡等情况下正确识别目标,即在健康叶片、患病叶片、枯萎叶片、杂草和土壤中准确识别出所有的患病叶片。此外,用智能手机在生产现场拍摄图像,会存在手机分辨率、光线、拍摄角度等多种因素,会导致识别正确率降低等问题,需要对采集到的图像进行预处理和数据增强以提高模型识别率,通过对 YOLO v5s 原始模型骨干网络重复多次增加 CA 注意力机制模块(Coordinate attention),增强 YOLO 算法对关键信息的提取能力,利用加权双向特征金字塔网络(Bidirectional feature pyramid network, BiFPN),增强模型不同特征层的融合能力,从而提高模型的泛化能力,替换损失函数 EIoU(Efficient IoU loss),进一步优化算法模型,实现多方法叠加优化后系统对目标识别性能的综合提升。在相同试验条件下,对比 YOLO v5 原模型、YOLO v8、Faster R-CNN、SSD 等模型,本方法的精确率 P、召回率 R、平均识别准确率 mAP_{0.5}、mAP_{0.5,0.95} 分别达到 97.40%、94.20%、97.20%、79.10%,本文所提出的算法在提高了精确率与平均精度的同时,保持了较高的运算速度,满足对作物黄化曲叶病毒病检测的准确性与时效性的要求,并为移动端智能识别作物叶片病害提供了理论基础。

关键词: 病害识别; YOLO v5s; 注意力机制; BiFPN; EIoU

中图分类号: TP18 文献标识码: A 文章编号: 1000-1298(2023)S1-0230-09

Improved YOLO v5s-based Detection Method for Crop Yellow Leaf Curl Virus Disease

ZUO Haoxuan¹ HUANG Qicheng¹ YANG Jiahao² SUN Quan² LI Sien³ LI Li¹

(1. Key Laboratory of Agricultural Information Acquisition Technology, Ministry of Agriculture and Rural Affairs, China Agricultural University, Beijing 100083, China

2. Key Laboratory of Smart Agriculture System Integration, Ministry of Education, China Agricultural University, Beijing 100083, China

3. College of Water Resources and Civil Engineering, China Agricultural University, Beijing 100083, China)

Abstract: Rapid and accurate identification of crop diseases in the early stage is an important guarantee to reduce crop economic losses. In view of the actual production environment, crop yellow leaf curl virus (YLCV) cannot be accurately and quickly identified by color or texture features by traditional image processing algorithms in the early stage of disease, and the YOLO v5s general model has poor recognition effect and low efficiency in complex environments. The dataset was made from two sources: the images of single diseased leaves in the public dataset of Plant Village and the canopy images of diseased crop taken by mobile phones in the actual production, and manually labeled the diseased leaves in the images to

收稿日期: 2023-06-30 修回日期: 2023-09-08

基金项目: 国家重点研发计划项目(2022YFD1900801)

作者简介: 左昊轩(1999—),男,硕士生,主要从事精细农业系统集成研究,E-mail: 1226604034@qq.com

通信作者: 李莉(1978—),女,副教授,博士生导师,主要从事智慧农业系统集成和农业信息获取技术研究,E-mail: lily@cau.edu.cn

achieve the correct identification of targets in complex terrain background and leaf occlusion, that was, to accurately identify all diseased leaves in healthy leaves, diseased leaves, withered leaves, weeds and soil. In addition, a smartphone was used to shoot images at the production site, there would be a variety of factors such as mobile phone resolution, light, shooting angle, etc., which would lead to problems such as reduced recognition accuracy, and it was necessary to preprocess data and enhance the collected images to improve the model recognition rate, and enhance the extraction ability of YOLO algorithm to key information by repeatedly increasing the CA attention mechanism module (coordinate attention) for many times on the YOLO v5s original model backbone network. The weighted bidirectional feature pyramid network (BiFPN) was used to enhance the fusion ability of different feature layers of the model, thereby improving the generalization ability of the model, replacing the loss function EIoU (Efficient IoU loss), further optimizing the algorithm model, and realizing the comprehensive improvement of the target recognition performance of the system after multi-method superposition optimization. Under the same experimental conditions, compared with the original YOLO v5, YOLO v8, Faster R - CNN, SSD and other models, the precision rate P , recall rate R , average recognition accuracy $mAP_{0.5}$, $mAP_{0.5:0.95}$ reached 97.40%, 94.20%, 97.20% and 79.10%, respectively, and the proposed algorithm maintained a high operation speed while improving the accuracy and average accuracy. It met the requirements of accuracy and timeliness of the detection of crop yellowing leaf curvature virus disease, and provided a theoretical basis for the intelligent identification of crop leaf diseases on mobile terminals.

Key words: disease identification; YOLO v5s; attention mechanism; BiFPN; EIoU

0 引言

黄化曲叶病毒 (Tomato yellow leaf curl virus, TYLCV)^[1] 是作物病毒病的主要病毒病原体之一, 可以发生在作物生长的各个时期, 发病后不及时处理往往会造成大规模传播, 对产量和品质造成严重影响, 给生产者带来巨大经济损失^[2]。近年来传统图像分析的速度与精度已经不能满足农业生产的需求, 深度学习逐渐成为植物病害识别的主要研究手段^[3], 通过端到端的网络模型进行计算机的大数据学习, 不需要过多的人为参与, 就可以实现高效的农作物病害识别^[4], 从而提高农作物生产的管理效率^[5]。TURKOGLU 等^[6] 采用 CNN 对包含 14 种作物、26 种病害、38 个类别的共 54 306 幅健康和患病叶片图像的 PlantVillage^[7] 公开数据集进行了试验, 准确率达 99.35%, 证明了这种方法的可行性。WANG 等^[8] 结合 Inception 模块与扩展卷积模块, 提取不同尺度的病害特征, 设定不同参数, 最终在 14 种不同农作物的 26 种病害上达到 99.37% 的平均识别准确率。XIA 等^[9] 通过融合 SeNet + ResNet 在农作物开源数据集上进行训练验证, 识别准确率达到 90%。张领先等^[10] 对比传统显微图像与目前主流的高光谱图像、机器学习和机器视觉对植物病害的检测效果, 得出几种处理方法的优缺点。机器视觉可实现目标的持续监测, 但目前机器视觉识别精度低, 数据集单一是一需要解决的问题。李森等^[11] 将 InceptionV3 和 Mobilenet 模型作为特征提取器, 进行黄瓜和水稻病害特征提取, 在改进的网络模型

AlexNet 和 VGG 模型上用 AMS - IMAGE 对预训练模型进行调参, 识别作物病害, 识别准确率可达 96.8%。李好等^[12] 在 ShuffleNetV2 的基础上引入 ECA (Efficient channel attention) 注意力模块, 对常见的 5 种农作物的 26 种病害进行识别, 病害平均识别率达 99.24%。杜甜甜等^[13] 通过在线增强的方式增加样本多样性, 在 RegNet 的基础上增加注意力机制和改进多尺度融合策略, 对农作物病害程度进行了评估, 识别准确率达 94.5%。李辉等^[14] 提出了一种基于改进 SSD 的苹果叶片病害检测系统, 通过引入注意力机制, 改进损失函数, 采用轻量级特征融合结构对 SSD 进行改进, 改进后的模型对病害识别的精度提高, mAP 达 81.95%。

高伟锋^[15] 提出了一种基于 YOLO v8 的柑橘病虫害识别系统, 在实际环境中的柑橘病虫害识别准确率为 94.9%, 可以应用到实际生产中。龙洁花等^[16] 提出了一种改进 YOLO v4 - CBAM 的检测算法模型, 通过融合注意力机制, 对目标特征加以更重要的特征权重, 对草莓开花期、果实膨大期、绿果期和成熟期的识别准确率分别达到 92.38%、82.45%、68.01%、92.31%。YOLO v5s 通过提高检测算法的精度, 使得检测到的目标更准确。YOLO v5s 的速度更快, 可以在短时间内处理大量的图像^[17]。YOLO v5s 支持处理高分辨率图像, 因此可以用于更高精度的目标检测。YOLO v5s 可以适应不同环境中的目标检测需求, 因此可以在多种场景中使用^[18]。

本文以设施番茄叶片黄化曲叶病毒病为例, 基

于 YOLO v5s 模型提出一种改进的番茄病害识别检测模型,通过引入注意力机制,增强算法的特征提取能力,利用加权特征金字塔网络,进一步增强模型的泛化能力和鲁棒性,替换损失函数优化模型,保证番茄病害识别的精度和时效性,以期为番茄的病害识别和移动端病害检测^[19]提供理论基础。

1 材料与方法

1.1 样本采集及预处理

1.1.1 样本采集

本试验数据集先随机选取 Plant Village 公开数据集中番茄黄化曲叶病毒病图像 200 幅。数据集图像示例如图 1a 所示。Plant Village 公开数据集中的患病番茄图像都为单叶片,对单患病叶片识别率较高,但对多叶片混杂场景下识别率较低。因此本试验在 2022 年 3—5 月于北京市平谷区夏各庄镇谷新农业日光温室 E 区 4 号棚(117°21'E, 40°14'N)采集温室中实际患病番茄植株冠层图像作为追加原始数据集。番茄品种为普罗旺斯,分别在晴天、阴雨天等不同天气状况,不同时间使用小米 8 SE 智能手机后置摄像头于不同位置拍摄采集番茄患黄花曲叶病毒病植株图像,如图 1b 所示。共收集数据图像 445 幅,图像分辨率为 3 024 像素 × 4 032 像素。实际温室中采集的图像既包含患病叶片,也包含健康叶片,在训练前需要对患病叶片进行标注。



图 1 数据集图像

Fig. 1 Dataset images

1.1.2 样本预处理

为了提高所训练模型的泛化能力,同时尽量避免网络发生过拟合现象,对所获得的图像进行数据增强,通过随机添加噪声、裁剪、旋转、调整亮度和镜像等操作,扩充至 2 580 幅图像。考虑到温室内环境复杂,噪声点多,添加高斯噪声以更好适配实际温室环境。将原始图像采用随机角度旋转、33% 的概率水平翻转、33% 的概率垂直翻转、33% 的概率对角翻转等方式,进一步增强数据的稳定性,增强后的数据图像如图 2 所示。

将增强数据集按照比例 8:1:1 划分为训练集、验证集和测试集。番茄患黄化曲叶病毒病初期,会

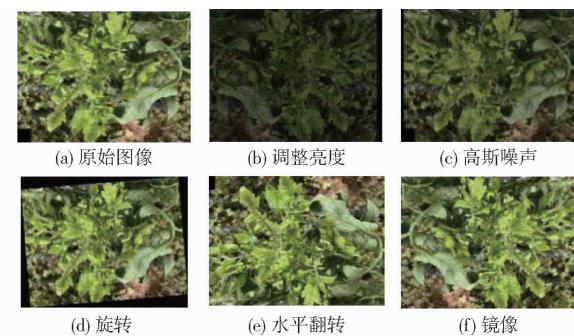


图 2 数据增强后的数据集图像

Fig. 2 Images of dataset after data enhancement

发生叶片变小、变厚、有明显皱褶、向上卷曲变形、叶片边缘至叶脉区域会黄化的现象。为了更有效地对番茄患黄化曲叶病毒病的检测识别,首先人为对番茄患病区域进行标注以提高识别效率,然后使用软件 LabelImg 对患病叶片进行标注,添加识别矩形框,同时 LabelImg 会生成对应的标签文件,图像标注结果如图 3 所示。



图 3 LabelImg 标注结果

Fig. 3 Result of LabelImg labeling

标注后的 XML 文件并不能直接被 YOLO v5 算法识别,通过脚本代码将 XML 文件转换为 TXT 文件,TXT 文件中包含目标类别、归一化后标注框中心点的坐标信息以及归一化后标注框的长和宽信息。

1.2 识别模型构建

1.2.1 YOLO v5 算法模型

YOLO v5 属于单阶段目标检测网络^[20],根据算法模型的深度和宽度不同,分为 5 个版本,分别为 YOLO v5n、YOLO v5s、YOLO v5m、YOLO v5l、YOLO v5x,这 5 个版本所含残差结构的个数依次增多,网络的特征提取、融合能力不断加强,检测精度得到提高,但相应的时间花费也在增加。YOLO v5n 的检测时间虽然最少,但是其残差结构个数较少导致检测精度较低,而 YOLO v5m、YOLO v5l、YOLO v5x 残差结构过多又会增加检测时间,检测时间的增加并不利于应用于农业的实时监测。结合农业生产实践,选用 YOLO v5s,既保证了检测精度,又保证了检测时间,可以满足农作物病害领域的实时性检测要求。本文选择模型复杂度较低的 YOLO v5s 模型,来最大程度地保证识别速度,降低计算机内存占

用量。

YOLO v5s 算法主要包括输入端、骨干网络(Backbone)、颈部网络(Neck)和预测头部(Head)4部分。在输入端采用 Mosaic 数据增强^[21]对原始数据进行随机缩放、随机裁剪、随机排列拼接,一定程度上增强了对小目标的检测效果。同时采用自适应锚框计算,针对不同的数据集,在网络训练中,在初始锚框的基础上输出预测框,进而与真实框 groundtruth 进行比对,计算两者差距,再反向更新,迭代网络参数。通过 Backbone 的卷积操作提取特征后输入到 Neck 进行多层次的特征融合,最终在 Head 端生成检测目标的类别及位置信息,输出结果。

1.2.2 注意力机制

注意力机制^[22]最近几年在深度学习的各个领域被广泛使用,其核心思想是在计算能力有限的前提下,合理分配计算资源,使得神经网络能够利用有限的注意力资源从海量的输入信息中快速筛选出高价值的信息。

当前构建轻量级神经网络多采用挤压注意力 SE(Squeeze-and-Excitation)^[23]模块,属于通道注意力模型,仅考虑了通道间的信息,而忽略了位置信息。后续提出的 CBAM(Convolutional block attention module)^[24]注意力模块旨在降低通道数后通过卷积来获取位置注意力信息,但由于卷积的局限性,仅能提取局部的位置注意力信息,缺乏长距离关系提取的能力。所以本文采用新的高效注意力机制 CA(Coordinate attention)^[25],将位置信息嵌入到通道信息中去。这样不仅获取了通道间的信息,同时还考虑了方向相关的位置信息,使得移动网络能够在大区域上进行特征提取。同时又能避免显著的计算开销,有助于模型更好地定位和识别目标。

CA 注意力模块足够灵活和轻量,能够简单地插入移动网络的核心结构中去,可以看作一个增强移动网络表达能力的计算单元。为了改善由二维全局池化引起的位置信息损失,CA 注意力模块将通道注意分解为 2 个并行的一维特征编码操作过程,分别沿垂直和水平方向将输入特征聚合到 2 个独立的方向感知特征图中。对比全局池化的压缩方式,可以使注意块捕捉单方向上的长距离关系的同时保留另一个方向上的空间信息。这样位置信息就可以保存在生成的注意力图中,来关注感兴趣的区域,帮助网络更好更准确地定位目标。

本文网络设计中,将 CA 模块与原始 Backbone 中的 C3 模块融合,利用 CA 注意力模块替换原始 C3 模块中的 Bottleneck,重新设计后的 C3CA 网络

模块如图 4 所示,其中 C3、C3CA 模块的展开图如图 5 所示。

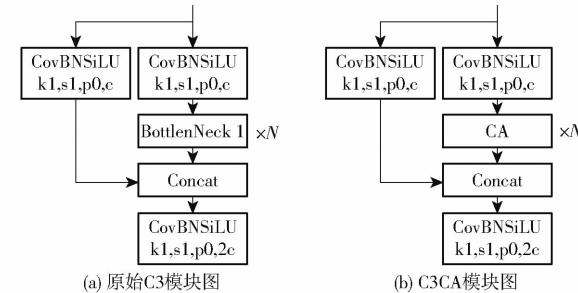


Fig. 4 C3CA module design diagram

1.2.3 加权双向特征金字塔网络

YOLO v5s 的 Neck 部分采用的路径聚合网络(PANet),相比之前的特征金字塔网络(FPN)提出了一个自顶向下和自底向上的双向融合骨干网络。此外在最底层和最高层之间增加了一条“short cut”用于缩短层之间的路径。为了恢复每个建议区域和所有特征层级之间的联系,提出了自适应特征池化操作,增加了一个全连接融合层。本文采用的加权特征金字塔网络(Bidirectional feature pyramid network, BiFPN)^[26]是在 PANet(Path aggregation network)的基础上进行改进的。替换原 YOLO v5s 中的 PANet,通过简单的残差操作,增强特征的表示能力。此外移除了 PANet 中的单输入边节点,因为此单输入边节点没有进行特征融合,所包含的信息相对较少,对后续的特征融合贡献较小,将该节点删除可以简化网络,减少计算量。与 PANet 中只有一个自顶向下和一个自底向上的路径不同,BiFPN 将每个双向路径作为一个特征路径层,并且多次重复同一层次,从而实现更高层次的特征融合。最重要的是提出了一种简单高效的加权特征融合机制,为不同输入特征添加额外的权重,使网络能够学习了解不同输入特征的重要性,从而使融合后的特征网络具有更高的识别效率及准确率,BiFPN 网络结构如图 6 所示。

BiFPN 的带权特征融合公式为

$$O = \sum_i \frac{W_i}{e + \sum_i W_j} I_i \quad (1)$$

式中 O ——输出 I_i ——输入
 e ——用于约束数值振荡的极小值学习率
 W_i, W_j ——权重

以 P6 层为例,对应的计算方法描述了如图 6 所示的 2 个融合特征在第 6 层的具体情况

$$P_6^{\text{id}} = \text{Conv} \left(\frac{w_1 P_6^{\text{in}} + w_2 \text{Resize}(P_7^{\text{in}})}{w_1 + w_2 + e} \right) \quad (2)$$

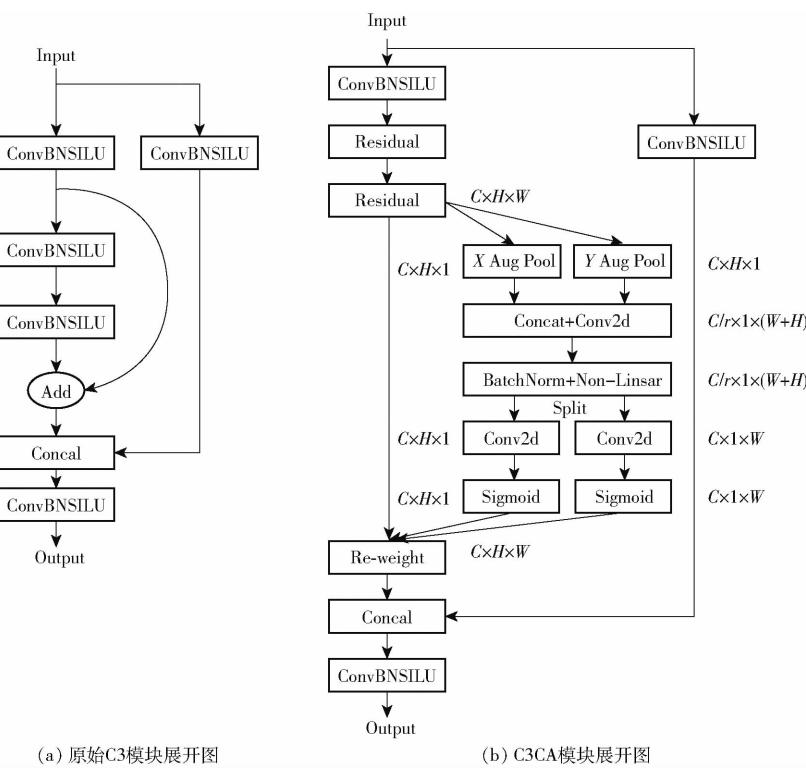


图 5 C3CA 模块展开图

Fig. 5 C3CA module expansion diagram

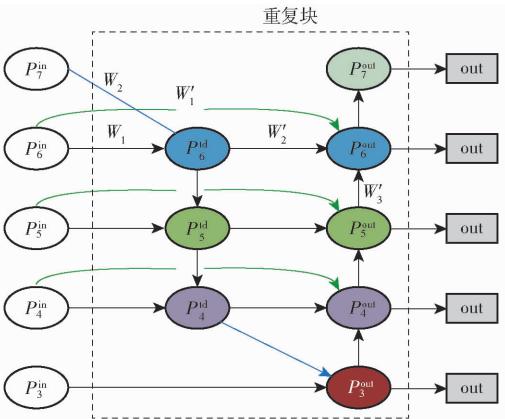


图 6 BiFPN 网络结构图

Fig. 6 BiFPN network structure diagram

$$P_6^{\text{out}} = \text{Conv} \left(\frac{w_1' P_6^{\text{in}} + w_2' P_6^{\text{id}} + w_3' \text{Resize}(P_5^{\text{out}})}{w_1' + w_2' + w_3' + \varepsilon} \right) \quad (3)$$

式中 Conv——对应的卷积操作

Resize——上采样或者下采样操作

$w_1, w_2, w_1', w_2', w_3'$ ——各层对应的权重, 用于描述特征融合过程中各个特征的重要程度

ε ——防止分母为零设置的极小非零常数

1.2.4 损失函数

为了更好地提高识别准确率, 本文考虑改进损失函数^[27], 目标检测中的一项重要工作就是要确定目标边界框的位置, YOLO v5s 原模型在训练中采用的是 ClIoU(Complete IoU loss) 损失函数, 一个好的

回归 Loss 应该包含覆盖面积、中心点距离和长宽比, ClIoU 就是在 DIoU(Distance IoU loss) 的基础上加入了宽高比, 计算公式为

$$\text{ClIoU} = \text{IoU} - \frac{\rho^2(b, b^{\text{gt}})}{c^2} - \alpha\nu \quad (4)$$

其中

$$\alpha = \frac{\nu}{1 - \text{IoU} + \nu} \quad (5)$$

$$\nu = \frac{4}{\pi^2} \left(\arctan \frac{w^{\text{gt}}}{h^{\text{gt}}} - \arctan \frac{w}{h} \right)^2 \quad (6)$$

式中 IoU——预测框与真实框的交并比

b, b^{gt} ——预测框与真实框的中心点

ρ ——中心点之间的欧氏距离

c ——能够同时包含预测框与真实框的最小外接矩形的对角线长度

α ——权重系数

ν ——用来衡量预测框和真实框之间宽高比的一致性系数

$w^{\text{gt}}, h^{\text{gt}}$ ——真实框的宽和高

w, h ——预测框的宽和高

最终 ClIoU Loss 的计算公式为

$$L_{\text{ClIoU}} = 1 - \text{IoU} + \frac{\rho^2(b, b^{\text{gt}})}{c^2} + \alpha\nu \quad (7)$$

但是 ClIoU 只是在 DIoU 的基础上增加了长宽比, 仅能反映长宽比的差异, 并不是长宽分别与其置信度的真实差异, 所以有时候会存在一定的模糊。针对这一问题, 有学者提出了 EIoU(Efficient IoU

loss), 在 CIoU 的基础上将宽高比拆开, 分别计算宽高的差异值, 可以加快预测框的回归速度, 使回归过程专注于高质量锚框, 提高预测框的回归精度。其计算公式为

$$L_{\text{EIoU}} = 1 - \text{IoU} + \frac{\rho^2(b, b^{\text{gt}})}{c_w^2} + \frac{\rho^2(w, w^{\text{gt}})}{c_w^2} + \frac{\rho^2(h, h^{\text{gt}})}{c_h^2} \quad (8)$$

式中 c_w 、 c_h ——预测框和真实框最小外接矩形的宽度和高度

α -IoU 将现有的 IoU 进行了推广, 很好地解决了当预测框与真实框没有重叠时存在的梯度消失问题, 通过自适应提高 High IoU 对象的损失和梯度的加权来提高回归精度, 为小数据集和噪声提供更强的鲁棒性。

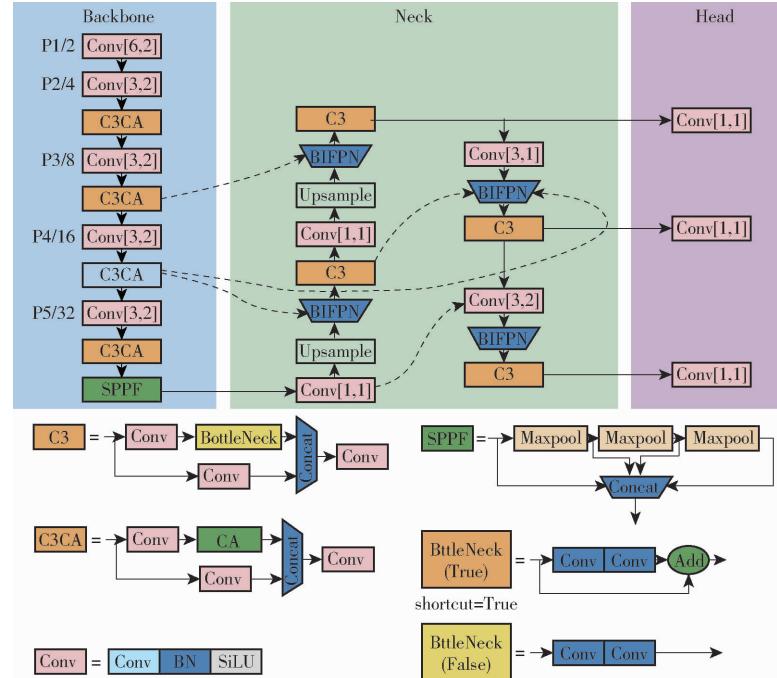


图 7 改进后的 YOLO v5s 网络结构图

Fig. 7 Structure of improved YOLO v5s network

2 试验与结果分析

2.1 试验环境及参数设置

该试验在 Windows 10 系统上运行, 搭载的 Intel Core i5 – 10400F CPU, 主频 2.9 GHz, 最高睿频 4.3 GHz, 32 GB 机带 RAM, Nvidia Geforce RTX 3070 显卡, 统一计算设备架构(CUDA)版本为 11.3, GPU 加速 CUDNN 版本为 8.2.0, Python 3.8, 深度学习框架为 Pytorch 1.10.0。

初始学习率设为 0.01, 动量初始值 0.937, 权重衰减系数为 0.0005, 图像输入尺寸为 640 像素 \times 640 像素, batch-size 为 32, 训练轮次为 500, IoU 阈值为 0.5。

1.2.5 改进后网络

以 YOLO v5s 为基础模型加以改进, 以适应复杂环境背景下温室大棚内的番茄黄化曲叶病毒病的识别检测, 基于以上叙述及试验论证, 针对 YOLO v5s 的改进如下: 将 Backbone 的 C3 模块中的 BottleNeck 换成 CA 注意力, 增强网络特征提取能力, 更有效定位目标, 同时避免了增加大规模的计算开销。将 Neck 端的 PANet 换成 BiFPN, 通过加权双向特征金字塔网络提升特征融合能力, 从而提高识别效率和识别准确率, 最后更换损失函数, 用以获得更准确的边界框回归和目标检测, 在实际番茄种植的复杂背景下, 不会引入额外的参数, 也不会增加训练的时间, 进一步提高收敛速度从而优化网络。改进后的网络结构图如图 7 所示。

2.2 试验评价指标

主要采用精确率(Precision, P)、召回率(Recall, R)、mAP_{0.5} 以及 mAP_{0.5:0.95} 作为评价标准, 将提出的改进模型与其他模型进行了对比。其中 mAP_{0.5} 是指当 IoU 为 0.5 时的 mAP; mAP_{0.5:0.95} 是指不同 IoU 阈值(从 0.5 到 0.95, 步长为 0.05)上的平均 mAP。

2.3 性能结果分析

为进一步验证本试验提出的改进算法性能, 在试验过程中进行了多项对比消融试验, 首先在注意力机制的选择上, 对比了多项常见注意力模块, 如 SE 注意力模块、CBAM 注意力模块和本文使用的 C3CA 注意力模块, 按照如上所述的改进策略及试验参数设置, 训练 500 个轮次后, 在同一个测试集上

进行推理验证,最终实际效果表明,在本试验中,C3CA 注意力模块的识别效果最优,验证集上的识别精确率如图 8 所示。

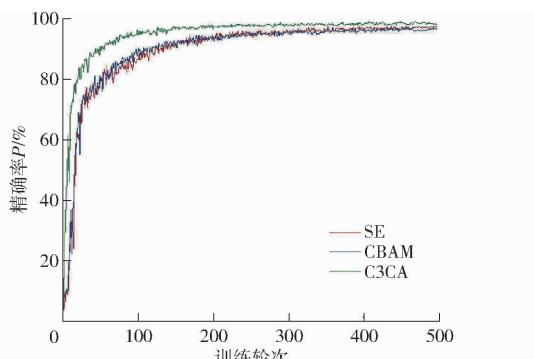


图 8 不同注意力识别精确率对比

Fig. 8 Comparison of precision of different attention recognitions

在 C3CA 模型的基础上,更换 YOLO v5s 的损失函数,分别对比了 EIoU 与 α -IoU 的各项评估指标,

在精确率和召回率上二者并无明显区别,但在预测框与真实框之间的误差回归中,EIoU 的收敛速度和精度比 α -IoU 表现优秀。二者对比如图 9 所示。

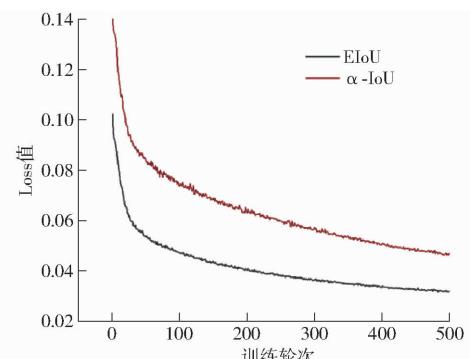


图 9 EIoU 与 α -IoU 回归 Loss 对比

Fig. 9 EIoU vs α -IoU regression Loss

最后更换了 Neck 端的 PANet 为 BiFPN,并进行了一系列消融试验,相较于原始 YOLO v5s,各项参数指标如表 1 所示。

表 1 不同改进消融试验结果

Tab. 1 Results of different improved ablation tests

模型	模块			$P/\%$	$R/\%$	$mAP_{0.5}/\%$	$mAP_{0.5;0.95}/\%$	模型内存占用量/MB	帧率/(f·s ⁻¹)
	CA	BiFPN	EIoU						
YOLO v5s	×	×	×	95.0	92.0	95.4	61.2	14.0	69.0
	√	×	×	96.1	93.3	96.4	70.7	13.2	57.0
	×	√	×	94.6	91.2	95.0	58.8	14.4	58.0
	×	×	√	95.5	92.3	95.9	71.2	14.1	58.0
	√	√	×	96.5	93.8	96.5	76.5	13.9	56.0
	√	×	√	96.8	94.1	96.6	77.0	13.8	56.0
	×	√	√	96.7	93.9	96.3	76.1	13.7	56.0
	√	√	√	97.4	94.2	97.2	79.1	14.1	55.0

注:“√”表示在 YOLO v5s 中采取该模块改进;“×”表示在 YOLO v5s 中未采取该模块改进。

由表 1 可知,对比 YOLO v5s 算法,改进 YOLO v5s 算法的 P 提升 2.4 个百分点, R 提升 2.2 个百分点, $mAP_{0.5}$ 提升 1.8 个百分点, $mAP_{0.5;0.95}$ 提升 17.9 个百分点,模型内存占用量仅增加 0.1 MB。试验结果表明,增加 CA 注意力机制,更换 PANet 网络为 BiFPN,更换损失函数可以在少量增加模型内存占用量的前提下,提高整个检测网络的识别精度,帧率大于等于 24 f/s 即可满足实时检测的需求,将模型部署到手机 APP 中后,其实时检测的帧率比原始的 YOLO v5s 算法在检测番茄黄化曲叶病毒病上表现更为突出,在保证识别精度的同时拥有较高的检测速度。

2.4 不同模型的对比试验分析

为了进一步验证本文提出的改进 YOLO v5s 算法的性能,对比其他当前主流的卷积神经网络模型,试验采用 YOLO v8、YOLO v5s、Faster R-CNN、SSD 模型,在上述同一参数设置条件下,使用 2.1.2 节自

建番茄黄化曲叶病毒病数据集中的训练集 2 064 幅图像和验证集中的 258 幅图像,进行训练和测试,使用自建数据集中的训练集和验证集是为了确保多样本量下的检验结果更具有代表性,最终得到的性能测试结果如表 2 所示。

表 2 不同模型对比结果

Tab. 2 Comparison results of different models %

模型	P	R	$mAP_{0.5}$	$mAP_{0.5;0.95}$
本文模型	97.4	94.2	97.2	79.1
YOLO v8	96.7	93.5	96.8	76.4
YOLO v5s	95.0	92.0	95.4	61.2
Faster R-CNN	65.7	53.8	50.4	39.4
SSD	76.2	70.3	75.7	56.9

由表 2 可看出,本文提出的改进 YOLO v5s 模型在番茄黄化曲叶病毒病验证数据集上对比其他几种主流卷积神经网络模型,识别精确率和召回率可达到 97.4% 和 94.2%, $mAP_{0.5}$ 和 $mAP_{0.5;0.95}$ 达

97.2% 和 79.1%，较原始 YOLO v5s 模型分别提高 2.4、2.2、1.8、17.9 个百分点。在算法性能上有着更好的效果，说明改进 YOLO v5s 模型能够更加专注地提取关键信息，充分利用低层次信息，融合更为丰富全面的特征图，同时可以减少无用信息对识别效果的干扰，从而提高识别精确率和识别速度，能够在温室内复杂背景情况下快速识别目标病害。

为了进一步验证改进 YOLO v5s 模型在实际复杂温室环境下的检测效果，采用改进 YOLO v5s 模型在训练过程中生成的最佳权重文件对验证集中的数据集图像进行了推理验证，验证结果如图 10 所示。



图 10 推理验证结果

Fig. 10 Graph of inference verification results

从图 10 可看出，改进 YOLO v5 模型能够在温

室复杂环境下，准确地识别番茄患黄化曲叶病毒病的目标叶片，并且没有出现错误检测、漏检等问题。因此，结合以上试验结果，本文提出的基于改进 YOLO v5s 的番茄患黄化曲叶病毒病识别方法可以满足实际生产需要。

3 结束语

在 YOLO v5s 算法模型的基础上提出了一种融合 CA 注意力机制，引导网络关注感兴趣区域，降低农业环境下复杂背景对识别效果的影响。更换 PANet 为 BiFPN 网络，减少多余的计算机算力消耗，更好地学习重要特征，保证识别精度。替换损失函数为 EIoU，加快收敛速度，提高模型的回归精度和鲁棒性的改进算法模型。通过建立番茄黄化曲叶病毒病数据集，利用改进的 YOLO v5s 算法进行训练后对番茄黄化曲叶病毒病进行识别，最终得出识别精确率和召回率分别为 97.4% 和 94.2%， $mAP_{0.5}$ 、 $mAP_{0.5:0.95}$ 分别达到 97.2% 和 79.1%，相比原始 YOLO v5s 分别提高 2.4、2.2、1.8、17.9 个百分点，同时帧率高达 55 f/s。试验结果表明，该方法在提升模型的检测精确率以及效率的同时，并未增加检测时间，能够满足实际生产中对番茄黄化曲叶病害初期快速检测与识别的需求。

参 考 文 献

- [1] 高敏丽, 张华. 番茄黄化曲叶病毒病的研究进展分析[J]. 粮食科技与经济, 2019, 44(3): 73–74, 93.
- [2] 胡文艺, 王洪坤, 杜育佳. 基于 SE 模块和 ResNet 的番茄病虫害识别方法[J]. 农业工程, 2022, 12(9): 33–40.
HU Wenyi, WANG Hongkun, DU Yujia. Tomato pest identification method based on SE module and ResNet[J]. Agricultural Engineering, 2022, 12(9): 33–40. (in Chinese)
- [3] 李大湘, 滑翠云, 刘颖. 面向苹果叶部病害识别的细粒度蒸馏模型[J]. 农业工程学报, 2023, 39(7): 185–194.
LI Daxiang, HUA Cuiyun, LIU Ying. A fine-grained distillation model for apple leaf disease identification[J]. Transactions of the CSAE, 2023, 39(7): 185–194. (in Chinese)
- [4] 张文景, 蒋泽中, 秦立峰. 基于弱监督下改进的 CBAM–ResNet18 模型识别苹果多种叶部病害[J]. 智慧农业(中英文), 2023, 5(1): 111–121.
ZHANG Wenjing, JIANG Zehong, QIN Lifeng. A modified CBAM–ResNet18 model based on weak supervision identifies multiple leaf diseases of apple[J]. Smart Agriculture, 2023, 5(1): 111–121. (in Chinese)
- [5] 王大庆, 禄琳, 于兴龙, 等. 基于深度迁移学习的 EfficientNet 玉米叶部病害识别[J]. 东北农业大学学报, 2023, 54(5): 66–76.
WANG Daqing, LU Lin, YU Xinglong, et al. EfficientNet maize leaf disease identification based on deep transfer learning[J]. Journal of Northeast Agricultural University, 2023, 54(5): 66–76. (in Chinese)
- [6] TURKOGLU M, HANBAY D. Plant disease and pest detection using deep learning-based features[J]. Turkish Journal of Electrical Engineering and Computer Sciences, 2019, 27(3): 1636–1651.
- [7] MOHAMETH F, BINGCAI C, SADA K A. Plant disease detection with deep learning and feature extraction using plant village[J]. Journal of Computer and Communications, 2020, 8(6): 10–22.
- [8] WANG L, SUN J, WU X, et al. Identification of crop diseases using improved convolutional neural networks[J]. IET Computer Vision, 2020, 14(7): 538–545.
- [9] XIA X, WU Y, LU Q, et al. Experimental study on crop disease detection based on deep learning[J]. IOP Conference Series: Materials Science and Engineering, 2019, 569(5): 052034.
- [10] 张领先, 韩梦瑶, 丁琦俊, 等. 作物病害智能诊断与处方推荐技术研究进展[J]. 农业机械学报, 2023, 54(6): 1–18.
ZHANG Lingxian, HAN Mengyao, DING Qijun, et al. Research progress of intelligent diagnosis and prescription

- recommendation technology of crop diseases[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(6): 1–18. (in Chinese)
- [11] 李森, 王敬贤, 李华龙, 等. 基于 CNN 和迁移学习的农作物病害识别方法研究[J]. 智慧农业, 2019, 1(3): 46–55. LI Miao, WANG Jingxian, LI Hualong, et al. Research on crop disease identification methods based on CNN and transfer learning[J]. Smart Agriculture, 2019, 1(3): 46–55. (in Chinese)
- [12] 李好, 邱卫根, 张立臣. 改进 ShuffleNet V2 的轻量级农作物病害识别方法[J]. 计算机工程与应用, 2022, 58(12): 260–268. LI Hao, QIU Weigen, ZHANG Lichen. Improved lightweight crop disease identification method for ShuffleNet V2 [J]. Computer Engineering and Applications, 2022, 58(12): 260–268. (in Chinese)
- [13] 杜甜甜, 南新元, 黄家兴, 等. 改进 RegNet 识别多种农作物病害受害程度[J]. 农业工程学报, 2022, 38(15): 150–158. DU Tiantian, NAN Xinyuan, HUANG Jiayu, et al. Improve RegNet's identification of multiple crop disease damages [J]. Transactions of the CSAE, 2022, 38(15): 150–158. (in Chinese)
- [14] 李辉, 严康华, 景浩, 等. 基于改进 SSD 的苹果叶部病理检测识别[J]. 传感器与微系统, 2022, 41(10): 134–137. LI Hui, YAN Kanghua, JING Hao, et al. Pathological detection and identification of apple leaves based on improved SSD [J]. Sensors and Microsystems, 2022, 41(10): 134–137. (in Chinese)
- [15] 高伟峰. 基于 YOLO v8 的柑橘病虫害识别系统研究与设计[J]. 智慧农业导刊, 2023, 3(15): 27–30. GAO Weifeng. Research and design of citrus pest identification system based on YOLO v8 [J]. Smart Agriculture Guide, 2023, 3(15): 27–30. (in Chinese)
- [16] 龙洁花, 郭文忠, 林森, 等. 改进 YOLO v4 的温室环境下草莓生育期识别方法[J]. 智慧农业(中英文), 2021, 3(4): 99–110. LONG Jiehua, GUO Wenzhong, LIN Sen, et al. Improved identification method of strawberry growth period in greenhouse environment of YOLO v4 [J]. Smart Agriculture, 2021, 3(4): 99–110. (in Chinese)
- [17] 马宏兴, 董凯兵, 王英菲, 等. 基于改进 YOLO v5s 的轻量化植物识别模型研究[J]. 农业机械学报, 2023, 54(8): 267–276. MA Hongxing, DONG Kaibing, WANG Yingfei, et al. Research on lightweight plant recognition model based on improved YOLO v5s [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(8): 267–276. (in Chinese)
- [18] 李明, 丁智欢, 赵婧暄, 等. 基于改进 YOLO v5s 的日光温室黄瓜霜霉病孢子囊检测计数方法[J]. 中国农机化学报, 2023, 44(5): 63–70. LI Ming, DING Zhihuan, ZHAO Jingxuan, et al. Detection and counting method of downy mildew sporangia in cucumbers in solar greenhouse based on improved YOLO v5s [J]. Chinese Journal of Agricultural Mechanization, 2023, 44(5): 63–70. (in Chinese)
- [19] 刘洋, 冯全, 王书志. 基于轻量级 CNN 的植物病害识别方法及移动端应用[J]. 农业工程学报, 2019, 35(17): 194–204. LIU Yang, FENG Quan, WANG Shuzhi. Plant disease identification method based on lightweight CNN and mobile application [J]. Transactions of the CSAE, 2019, 35(17): 194–204. (in Chinese)
- [20] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779–788.
- [21] FAN J, CUI L, FEI S. Waste detection system based on data augmentation and YOLO_EC[J]. Sensors, 2023, 23(7): 3646.
- [22] LOUREIRO C, FILIPE V, GONCALVES L. Attention mechanism for classification of melanomas [C] // International Conference on Optimization, Learning Algorithms and Applications, 2022: 65–77.
- [23] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132–7141.
- [24] 孙丰刚, 王云露, 兰鹏, 等. 基于改进 YOLO v5s 和迁移学习的苹果果实病害识别方法[J]. 农业工程学报, 2022, 38(11): 171–179. SUN Fenggang, WANG Yunlu, LAN Peng, et al. Apple fruit disease identification method based on improved YOLO v5s and transfer learning[J]. Transactions of the CSAE, 2022, 38(11): 171–179. (in Chinese)
- [25] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13713–13722.
- [26] RUIZ-PONCE P, ORTIZ-PEREZ D, GARCIA-RODRIGUEZ J, et al. Poseidon: a data augmentation tool for small object detection datasets in maritime environments[J]. Sensors, 2023, 23(7): 3691.
- [27] 晁晓菲, 池敬柯, 张继伟, 等. 基于 PSA – YOLO 网络的苹果叶片病斑检测[J]. 农业机械学报, 2022, 53(8): 329–336. CHAO Xiaofei, CHI Jingke, ZHANG Jiwei, et al. Detection of apple leaf disease spots based on PSA – YOLO network [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(8): 329–336. (in Chinese)