

DOI:10.19651/j.cnki.emt.2314962

注意力特征融合的番茄叶部早期病斑诊断算法*

金婷婷^{1,2,3} 房建东^{1,2,3} 赵于东^{2,3}(1.内蒙古工业大学信息工程学院 呼和浩特 010080; 2.内蒙古自治区感知技术与智能系统重点实验室 呼和浩特 010080;
3.内蒙古自治区智慧农牧业感知技术协同创新中心 呼和浩特 010080)

摘要: 番茄产量受到病害、天气等因素的影响,其中番茄生长过程中叶片的病害问题是影响番茄产量的最关键因素。然而,在叶片病害检测领域,现有模型普遍存在泛化能力不足以及小病斑漏检率高等问题。提出一种改进的番茄病害早期检测算法,通过对YOLOv5s网络进行多方面的优化来改善这些问题,同时保持模型轻量化。首先,采用Mosaic 9数据增强技术,强化了模型对小病斑的检测能力,增加了图像背景的复杂度,提高了模型的泛化能力;其次,使用GSConv和Slim-Neck网络,在保持模型准确性的前提下轻量化模型,降低计算负担;同时,使用SimAM注意力机制更准确地捕捉叶片上的小病斑特征,从而降低漏检率;此外,为了进一步增强多尺度目标的检测能力,引入自适应空间特征融合,有效地整合不同尺度的特征,提升了多尺度目标,特别是小目标的检测准确性。实验结果表明:该模型在叶片病害早期检测方面表现出色,对叶霉、早疫、晚疫以及健康叶片四种番茄病害的早期平均识别准确率、召回率、F1分数及mAP分别达到了0.951%、0.918%、0.934%、0.948%。可见该方法对于小病斑具有较好的检测性能,改善了模型泛化能力不足及小病斑检测过程中的漏检问题,进一步提高了检测效果。

关键词: YOLOv5s; 番茄早期病斑; GSConv和slim-neck; 注意力机制; 特征融合
中图分类号: TP391.41 文献标识码: A 国家标准学科分类代码: 510.4050

Early lesion diagnosis algorithm of tomato leaf based on attention
feature fusionJin Tingting^{1,2,3} Fang Jiandong^{1,2,3} Zhao Yudong^{2,3}

(1. College of Information Engineering, Inner Mongolia University of Technology, Hohhot 010080, China;

2. Key Laboratory of Perception Technology and Intelligent System, Inner Mongolia Autonomous Region, Hohhot 010080, China;

3. Collaborative Innovation Center of Perception Technology in Intelligent Agriculture and Animal Husbandry, Inner Mongolia Autonomous Region, Hohhot 010080, China)

Abstract: Tomato yield is affected by diseases, weather and other factors, among which leaf disease is the most critical factor affecting tomato yield. However, in the field of leaf disease detection, the existing models generally have the problem of insufficient generalization ability and high detection rate of small lesions. In this paper, an improved tomato disease early detection algorithm is proposed to improve these problems by optimizing the YOLOv5s network in various aspects, while keeping the model lightweight. Firstly, Mosaic9 data enhancement technology is used to strengthen the detection ability of the model for minor lesions, increase the complexity of the image background, and improve the generalization ability of the model. Secondly, GSConv and Slim-Neck networks are used to lightweight the model and reduce the computational burden while maintaining the accuracy of the model. At the same time, the SimAM attention mechanism was used to capture the features of small lesions on the leaves more accurately, thus reducing the missed detection rate. In addition, in order to further enhance the detection ability of multi-scale targets, adaptive spatial feature fusion is introduced to effectively integrate features of different scales, and improve the detection accuracy of multi-scale targets, especially small targets. The experimental results showed that the model had excellent performance in early detection of leaf diseases, and the average recognition accuracy, recall rate, F1 score and mAP of leaf mold, early disease, late disease and healthy leaf disease reached 0.951%, 0.918%, 0.934% and 0.948%, respectively. It can be seen that this method has a good detection performance for minor lesions, and improves the problem of insufficient generalization ability of the model and missing detection in the detection process of minor lesions, and further improves the detection effect.

Keywords: YOLOv5s; early disease spots in tomato; GSConv and slim-neck; attention mechanism; feature fusion

0 引 言

番茄作为一种富含维生素和矿物质、具有特殊药理作

用的蔬菜,已经被世界粮农组织列为第六大蔬菜^[1]。然而,番茄在生长过程中容易受到多种疾病的感染,其中包括病毒、真菌、细菌和霉菌等。这些感染可能会造成严重的经济

收稿日期:2023-11-09

* 基金项目:内蒙古自治区直属高校基本科研业务费资助项目(JY20220012)、内蒙古自治区科技计划项目(2023YFJM0002, 2022YFSJ0034) 资助

损失,对农民的生计产生负面影响。早期发现番茄叶片的病害情况对于及时的诊断和治疗具有重要意义,可以有效挽救作物损失。因此,高效准确地识别和诊断番茄叶部早期病斑、识别番茄病害类型,并及时进行干预,对于提高番茄种植的质量和效益非常重要,可以大大降低农作物损失的风险。

目前病虫害防治主要采用传统的农业防治法、化学防治法、生物防治法和物理防治法等方法,但这些方法消耗大量人力物力,防治效率不高,且容易导致环境污染。随着人工智能技术的发展,以卷积神经网络(convolutional neural networks, CNN)为代表的深度学习技术,已经广泛应用于图像识别和目标检测任务中。其典型算法主要有 Faster R-CNN(region-based convolutional neural network)^[2]、SSD(single shot multiBox detector)^[3]、YOLO(you only look once)^[4]系列,随着机器学习和深度学习在计算机视觉领域的兴起,越来越多的研究人员开始将人工智能算法应用于植物病害识别领域。例如,Wang等^[5]针对传统的植物病害诊断方法多以专家诊断为主,容易导致作物病害防治滞后的问题,利用轻量化的YOLOv5模型进行植物病害的识别和检测,提升了检测效率,但是由于部分分类特征不明显,导致其识别率较低,小目标检测误检率较高;Wang等^[6]针对植物叶片病害检测和分类困难的问题,在SSD目标检测框架中引入了注意力机制,用于植物病害检测,但其算法的实时性能仍有待提高;Gong等^[7]针对苹果叶病害背景环境复杂、特征密集小等局限性,引入了Res2Net和特征金字塔网络架构来改进Faster R-CNN,用于苹果叶病害检测,具有较高的检测精度,但在实时检测速度方面仍需提升;Lin等^[8]提出了一种改进的茶病检测模型TSBA-YOLO,满足了实时检测的需求,增强了模型抵抗复杂背景干扰的能力,但还存在误检和漏检的问题,其检测的准确性还需提高。

可以看出,基于深度学习的目标检测方法在农作物病害诊断领域取得了显著的进展,在大、中目标的检测方面取得了不错的成效^[9-10],然而,现有的模型仍然存在小目标病斑误检和漏检率高、泛化能力弱等问题,因此,对于小病斑这种尺寸较小、特征不全的目标,仍需要更加敏感的模型来捕捉细微的特征。

因此,基于改进YOLOv5s算法的番茄叶部早期病斑诊断算法对于发展农业领域的智能化和可持续性具有积极的影响。通过优化YOLOv5s模型结构,改进Mosaic数据增强,引入GSConv和Slim-Neck网络、SimAM(similarity-based attention mechanism)注意力机制和自适应空间特征融合(adaptively spatial feature fusion, ASFF),从而提高模型对小病斑的检测能力,实现早期、快速、精准地识别番茄叶部早期病斑,为农户提供更有有效的防治方案,从而提高番茄种植的质量和效益。

1 YOLOv5 算法基本结构

YOLOv5s的结构如图1所示,主要由输入端(Input)、主干网络(Backbone)、检测颈(Neck)和预测层(Prediction)4部分组成。

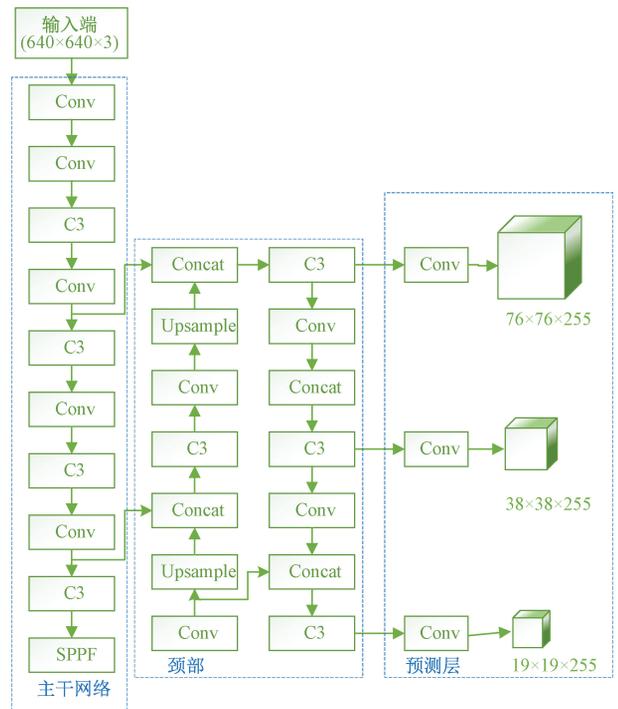


图1 YOLOv5s模型结构图

Input采用Mosaic 4数据增强方法,通过随机裁剪、随机缩放和随机合并等方式拼接4幅图像,以提高输入图像的复杂度,提高模型的泛化能力和鲁棒性。同时,YOLOv5采用自适应图像缩放模块,可以根据原始图像的长宽比自适应地添加最少的黑边,从而将原始图像变换为固定大小为 $640 \times 640 \times 3$ 的输入图像,最佳初始锚点,提高模型精度^[11]。

Backbone使用Focus结构作为基准结构,并采用CSPDarknet53^[12]结构作为骨干特征提取网络。相较于YOLOv3算法的Darknet53^[13]网络结构,CSPDarknet53结构增强了网络的学习能力,减少了计算量和内存,保持了网络特征提取的准确性。

Neck采用了PANet结构,在FPN的基础上引入了自下而上的PAN结构。主要用于生成特征金字塔,以增强模型对不同比例尺度物体的检测能力^[14]。其中FPN层用于提取强语义特征,PAN层用于提取强定位特征。通过这两者的特征融合,可以预测3个不同尺度的目标,实现多尺度特征的融合。

Prediction采用3个检测器来检测不同尺度的特征图上的物体,使用CIoU_Loss作为边界框的损失函数,以提高回归预测框的速度和准确性。

2 改进的 YOLOv5s 网络结构

本文在 YOLOv5s 网络的基础上进行改进以更好地适应番茄生长过程中叶片早期病害的特征,如图 2 所示,为改进后的整体模型结构。

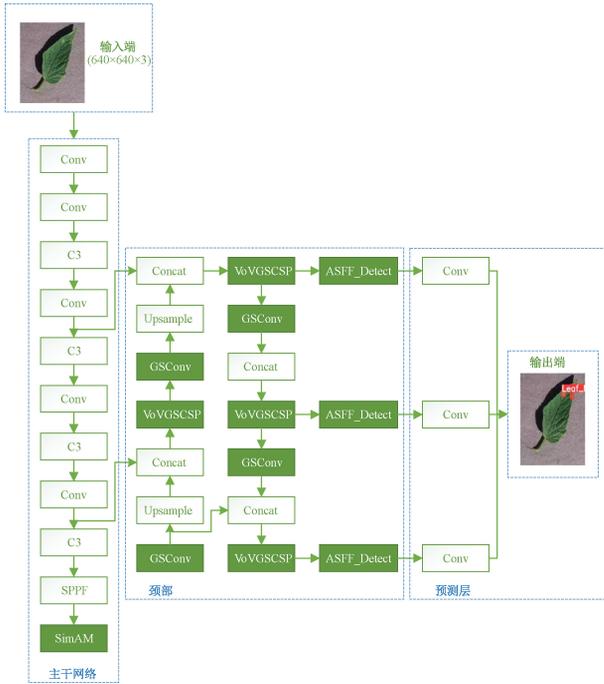


图 2 改进后 YOLOv5s 模型结构图

叶片早期病害通常表现为相对小尺寸、不规则形状的斑点,因此需要提高模型对小目标的检测能力。为此,采用 Mosaic 9 数据增强技术,随机裁剪、缩放和合并 9 张图像,以增加数据的数量和多样性,提高对小目标的检测准确性,降低漏检率。在实际应用中,模型的轻量化对资源和计算效率至关重要,因此,使用 GSCov 和 Slim-Neck 网络替代 YOLOv5s 的 Neck 部分,以轻量化模型,降低计算负担的同时保持精度。为了更准确地识别叶片病害,特别是小病斑特征,在 Backbone 主干网络中加入 SimAM 注意力机制,使网络能够更聚焦于病斑区域,从而增强病斑特征并抑制不相关特征,提高小病斑的提取准确性。叶片上的病斑具有不同的尺度,因此多尺度目标检测至关重要,引入 ASFF 特征融合,通过自适应融合不同尺度的特征,提升多尺度目标,特别是小目标的检测精度,有助于识别不同大小的病害斑点。

通过改进,模型对于番茄叶片早期病斑的识别具有较好的检测性能,更好的泛化能力,更高的准确率和更低的漏检率,对番茄产量的维护和提高起到积极作用。

2.1 Mosaic 9 数据增强

扩充后的番茄病害数据集(3.1 节)仅为单张叶片图片,场景较为单一,且部分数据仅存在一种病害,较为单调。Mosaic 9 数据增强是一种用于增加图像训练数据多样性和

提高模型性能的有效方法。采用 Mosaic 9 数据增强技术可以丰富样本的场景和目标,增加数据的多样性,从而提高模型对小病斑的检测能力^[15]。该技术通过以下步骤对图像进行处理:

1) 随机选择图像:首先,从数据集中随机选择 9 张不同的图像,每张图像都包含了不同的叶片病害或其他目标。

2) 随机裁剪:对这 9 张图像进行随机裁剪,然后将它们合并在一起,形成一个新的合成图像。这有助于集中关注图像中的不同部分,包括潜在的病害区域。

3) 随机缩放和平移:这些裁剪后的小图像块会被随机缩放和平移,以模拟不同观测角度和距离,从而增加样本的多样性。

4) 随机合并:将这些小图像块随机合并成一个新的合成图像,合成图像中的每个目标都会被标记,包括其类别和边界框位置。这个合成图像包含来自不同原始图像的信息,包含了多个场景和目标,为模型提供了更多丰富的背景和上下文信息,增加了数据的多样性。

在 Mosaic9 数据增强的拼接处理细节如图 3 所示。

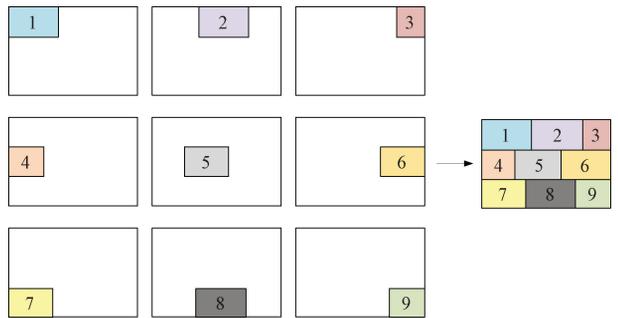


图 3 Mosaic 9 数据增强处理

这一过程增加了数据样本的多样性,使模型能够更好地适应不同尺度、位置和角度的目标,从而提高模型对小病斑的检测能力,同时增加了数据样本的多样性,有助于提高模型的泛化能力和鲁棒性,降低漏检率。

图 4 为经过 Mosaic 9 数据增强方法处理后的图像,其中的识别框标记了检测目标的位置,并且每个识别框都标记了对应目标的种类,用于识别分类。

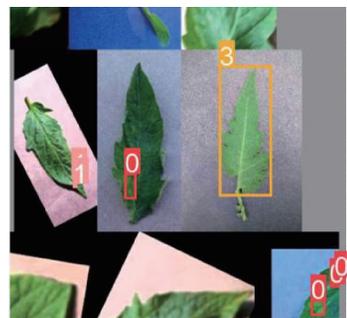


图 4 Mosaic 9 数据增强示例图

2.2 轻量级卷积技术 GSConv 和 Slim-Neck

GSConv 和 Slim-Neck^[16]是一种新的轻量级卷积技术,以减轻模型的重量,同时保持精度。采用标准卷积(standard convolution, SC)、深度可分离卷积(depth-wise separable convolution, DSC)和 shuffle 混合卷积进行组合构建为一个新的卷积层:GSConv。GSConv 可以很好地平衡模型的准确性和速度,使 DSC 的输出尽可能接近 SC,降低了计算量。

GSConv 结构如图 5 所示,使用 shuffle 将 SC 生成的信息渗透到 DSC 生成的信息的每个部分中。该方法通过在不同信道上统一交换局部特征信息,使来自 SC 的信息完全混合到 DSC 的输出中,而不需要附加信息。GSConv 具有直接替换原始卷积层的特点,无需额外的复杂操作即可显著提升模型精度。

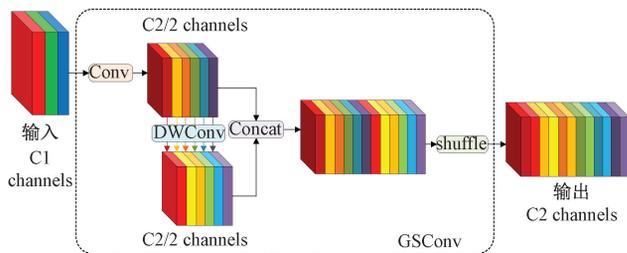


图 5 GSConv 结构图

VoV-GSCSP 模块结构如图 6 所示,图 6 (a)给出了 GS bottleneck 模块的结构,GS bottleneck 由两个 GSConv 模块和一个 DWConv 模块组成。如图 6 (b)所示,VoV-GSCSP 模块则是在 GS bottleneck 基础上采用了一种一次性聚合方法得到的。

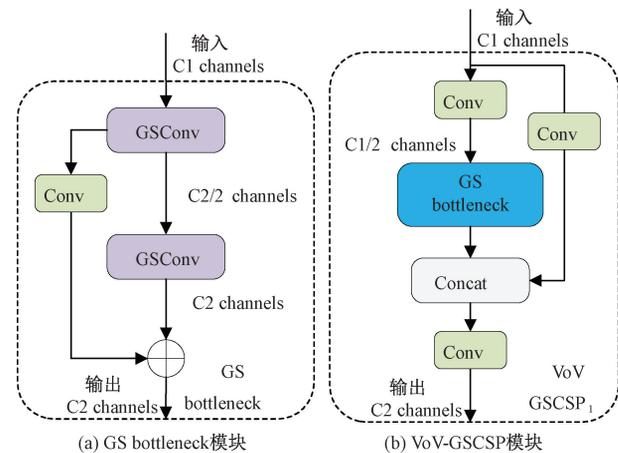


图 6 VoV-GSCSP 模块结构图

2.3 SimAM 注意力机制

在已有的研究中,CBAM(convolutional block attention module)分别估计 1-D 和 2-D 权重,然后将它们组合在一起。这种方法不能直接生成真正的三维权重。为了解决这一问题,SimAM^[17]被提出,使每个神经元被分配一个唯一

的权重。

SimAM 的优点是可以直接为特征图导出三个权重,而无需添加额外的参数,允许网络学习更多的判别神经元,具备即插即用的特性,能够方便地应用于不同模型中,从而增强模型在特征提取方面的能力,提高目标检测的准确性。SimAM 能使网络更精确地聚焦于病斑区域,有助于增强对番茄叶部病斑的特征提取,可以更准确地提取小病斑的特征,使其更加显著,更多的病斑能够被正确检测和识别,降低漏检率,提高整体的检测性能。图 7 展示了分配 3D 注意力权值的示意图。

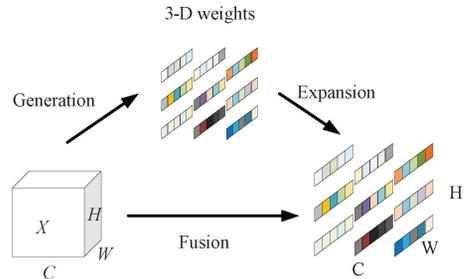


图 7 分配 3D 注意力权值示意图

为了成功地实现注意力,SimAM 模块需要估计单个神经元的重要性。在神经科学中,信息量最大的神经元通常表现出与周围神经元不同的放电模式。此外,一个活跃的神经元经常抑制周围的神经元,即空间抑制。换句话说,具有空间抑制作用的神经元应该被赋予更高的重要性。找到重要神经元的最简单方法是测量神经元之间的线性可分离性。因此,定义 SimAM 能量函数:

$$e_i(\omega_i, b_i, y, x_i) = \frac{1}{M-1} \sum_{i=1}^{M-1} (-1 - (\omega_i x_i + b_i))^2 + (1 - (\omega_i t + b_i))^2 + \lambda \omega_i^2 \quad (1)$$

其中, t 和 x_i 是输入特征 $X \in R^{C \times H \times W}$ 的单个通道中的目标神经元和其他神经元。 i 是空间维度上的索引, $M = H \times W$ 是该通道上的神经元数量。 ω_i 和 b_i 是变换的权重和偏置, λ 是正则化系数。通过对 ω_i 和 b_i 求偏导代入原能量函数,获得最小能量公式为:

$$e_i^* = \frac{4(\hat{\sigma}^2 + \lambda)}{(t - \hat{\mu})^2 + 2\hat{\sigma}^2 + 2\lambda} \quad (2)$$

$\hat{\mu}$ 和 $\hat{\sigma}^2$ 是单个通道上所有神经元的均值和方差。从最小能量的公式中可以清楚地看出,神经元 t 的能量越低,它与周围神经元的区别就越大,因此,它对视觉处理的贡献就越大。

2.4 ASFF 特征融合

本研究引入 ASFF^[18-19], ASFF 是一种新颖有效的特征融合算法,它不同于基于单元或级联的多层次特征融合方法,其核心思想是自适应地学习不同尺度下特征映射融合的空间权重,并通过学习权重参数将不同层的特征集成在一起。ASFF 通过自适应调整各要素层的权重,可以有效

增强对小目标的检测,防止小目标的语义和位置信息被忽略。ASFF 算法结构如图 8 所示,它包括两个步骤:特征缩放和自适应融合。

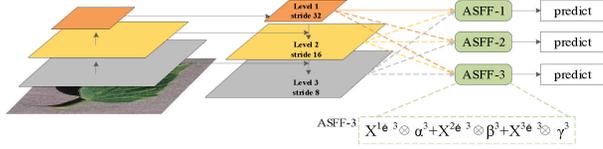


图 8 ASFF 算法结构图

设 $x_{ij}^{n \rightarrow l}$ 为特征向量 (i, j) 从 n 层特征层映射到 l 层的特征,对应 l 层的特征融合公式如下:

$$y_{ij}^l = \alpha_{ij}^l \cdot x_{ij}^{1 \rightarrow l} + \beta_{ij}^l \cdot x_{ij}^{2 \rightarrow l} + \gamma_{ij}^l \cdot x_{ij}^{3 \rightarrow l} \quad (3)$$

其中, y_{ij}^l 表示 ASFF 获取的新特征图。 α_{ij}^l 、 β_{ij}^l 和 γ_{ij}^l 分别表示 3 个不同层次的特征映射的权重参数。 α_{ij}^l 、 β_{ij}^l 和 γ_{ij}^l 可以是简单的标量变量,它们在所有通道上共享。同时满足 $\alpha_{ij}^l + \beta_{ij}^l + \gamma_{ij}^l = 1$, $\alpha_{ij}^l, \beta_{ij}^l, \gamma_{ij}^l \in [0, 1]$, 并定义:

$$\alpha_{ij}^l = \frac{e^{\lambda_{\alpha_{ij}}^l}}{e^{\lambda_{\alpha_{ij}}^l} + e^{\lambda_{\beta_{ij}}^l} + e^{\lambda_{\gamma_{ij}}^l}} \quad (4)$$

其中,用 softmax 函数分别以 $\lambda_{\alpha_{ij}}^l$ 、 $\lambda_{\beta_{ij}}^l$ 和 $\lambda_{\gamma_{ij}}^l$ 为控制参数定义 α_{ij}^l 、 β_{ij}^l 和 γ_{ij}^l 。使用 1×1 卷积层来计算标量图的权重,这样,网络模型通过标准反向传播,可以自适应地学习这些参数。

3 实验与分析

3.1 实验数据集

1) 番茄病害发病特征

(1) 叶霉病

叶霉病是由霉菌类病原体引起的,主要发病部位是植物的叶片。叶霉病的发病通常由中下部叶片开始,最初在叶片正面出现不规则淡黄色褪绿斑。随着病情的发展,叶背面上出现灰色绒状霉层,严重时甚至出现黑色霉层^[20]。

(2) 早疫病

早疫病主要影响番茄等作物的叶片、茎秆和果实等器官。该病通常由真菌病原体引起,其发病过程多从下部叶片发生,然后逐渐蔓延至上部叶片和茎秆。早疫病发病初期的典型症状是在叶片上出现黑褐色的斑点,这些斑点逐渐扩大成为不规则圆形,斑点上有清晰的轮纹。随着病情的发展,叶片上的病斑逐渐增多,最后造成整片叶片干枯^[21]。

(3) 晚疫病

晚疫病通常由真菌病原体引起,其典型症状是发病初期叶片先端或边缘出现水浸状病斑,然后叶片褪绿黄化,病斑逐步变为黄褐色的“V”形大病斑,最终,整片叶片枯黄而死^[22]。

以上 3 种番茄病害发病初期及健康叶片图像如图 9 所示。



图 9 番茄病害图

2) 番茄病害数据集的构建及增强

本研究采用的数据集来自大型公开数据库 Plant Village 及其他公开数据集。从公开数据集中选取符合番茄叶霉病、早疫病及晚疫病早期发病特征的图片来作为番茄叶部早期病斑诊断的数据集。3 种番茄病害图片以及健康图片共 480 张,其中番茄叶霉病、番茄早疫病、番茄晚疫病以及健康叶片各 120 张。

对原始图片随机进行翻转、旋转、不等比例缩放、亮度、运动模糊来扩充数据集,增加样本的数量,避免过拟合,提升模型的鲁棒性。通过对数据集进行数据增强处理,将数据量扩增为原数据集的 4 倍,增强后的数据集共 1 920 张图片,图 10(a)~(h)为不同数据增强方式的示例图。将数据增强前后进行实验对比,对比结果如表 1 所示。

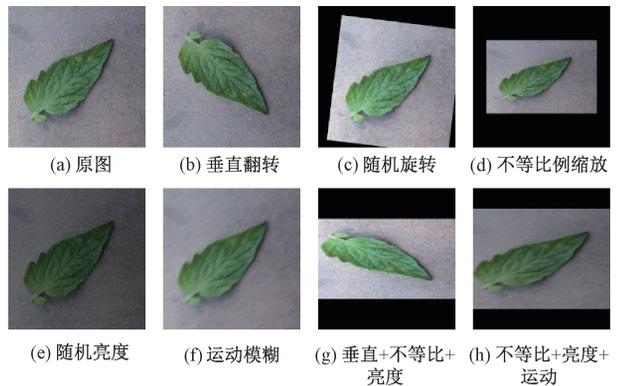


图 10 数据增强示例图

表 1 数据增强前后在 YOLOv5s 下的实验对比

	增强前	增强后
训练集	336	1344
验证集	96	384
测试集	48	192
P	0.833	0.92
R	0.814	0.902
F1	0.823	0.911
mAP@0.5	0.843	0.933

从表 1 中可以看出,在数据增强之后,样本更丰富,有助于提高模型的泛化能力和评估性能。数据增强对模型的性能有明显的积极影响,准确率、召回率、F1 分数和

mAP@0.5 分别提升了 8.7%、8.8%、8.8% 和 9%，模型在各项指标上都取得了显著的提升。由此可以证明数据增强能够较大的提高模型的识别能力。

3.2 实验条件与参数

以番茄叶片病斑数据集为例进行实验与分析,如表 2 所示为实验条件,表 3 为实验训练参数。

表 2 实验条件

名称	环境参数
操作系统	Window10
CPU	Intel(R) Core(TM) i9-10900 CPU@3.70 GHz
GPU	NVIDIA RTX A5000
编译环境	python3.8、pytorch1.12.1

表 3 训练参数设置

参数名称	配置参数
训练次数	100
学习率	0.01
批次大小	16
优化器	SGD
训练集	1344
验证集	384
测试集	192
检测类别	4

3.3 评价指标

1) 准确率(Precision): 为正确检测到的番茄病害数占

所有检测到的番茄病害数的比例,如式(5),其中 TP 表示正确识别的正样本数,FP 表示错误识别的负样本数。

$$P = TP / (TP + FP) \quad (5)$$

2) 召回率(Recall): 为正确检测到的番茄病害数占应该被正确检测到的番茄病害数的比例,如式(6),FN 表示错误识别的正样本数。

$$R = TP / (TP + FN) \quad (6)$$

3) F1 分数(F1-Score): 为准确率和召回率的调和平均,如式(7)。

$$F1 = (2 \times P \times R) / (P + R) \quad (7)$$

4) mAP@0.5: 平均精度(AP)表示模型在每个类别上的好坏,mAP@0.5 表示将 IoU 设为 0.5 时多个类别 AP 值的平均值,体现目标检测网络在数据集上的综合性能,如式(8)(9), N_c 是类别的总数。

$$AP = \int_0^1 PRdR \quad (8)$$

$$mAP = \frac{\sum AP}{N_c} \quad (9)$$

5) Param: 参数量,衡量模型参数大小。

6) FLOPs: 浮点运算次数,衡量模型的复杂度。

7) FPS: 模型在推理过程中的帧率,表示每秒处理的帧数。

3.4 消融实验

为了证明本文提出的各个模块的优越性、算法的充分性以及改进策略对模型带来的影响,进行了消融实验,消融实验的结果如表 4 所示。通过消融实验来评估不同的模块相互组合给最终目标检测性能带来的影响。

表 4 消融实验结果对比

序号	模型				P	R	F1	mAP@0.5	参数量 (parameters/M)	浮点运算数 (GFLOPs)
	mosaic 9	GSCov-slim neck	SimAM	ASFF						
1					0.92	0.902	0.911	0.933	7.02	15.8
2	√				0.939	0.905	0.922	0.94	7.02	15.8
3		√			0.937	0.91	0.923	0.944	5.84	12.6
4			√		0.94	0.909	0.924	0.939	7.02	15.8
5				√	0.941	0.904	0.922	0.942	12.5	24.2
6	√	√			0.942	0.909	0.925	0.944	5.84	12.6
7	√		√		0.94	0.913	0.926	0.943	7.02	15.8
8	√			√	0.945	0.908	0.926	0.941	12.5	24.2
9		√	√		0.945	0.906	0.925	0.94	5.84	12.6
10	√	√	√		0.947	0.916	0.931	0.946	5.84	12.6
11	√	√		√	0.947	0.914	0.93	0.948	11.3	21.1
12		√	√	√	0.948	0.917	0.932	0.947	11.3	21.1
13	√	√	√	√	0.951	0.918	0.934	0.948	11.3	21.1

表 4 中,序号 1 模型为原始 YOLOv5 模型,序号 2 到序号 5 模型为改进一种算法的模型,其相对于序号 1 模型

在 P、R、F1 和 mAP@0.5 上均有所提高。序号 6 到序号 9 模型为改进两种算法的模型,序号 10 到序号 12 模型为改

进 3 种算法的模型,其精度分别相对改进一种、两种算法的模型有了不同程度的提升。改进了 4 种算法的序号 13 模型为本文模型,其模型的识别精度最高。

由表 4 可以看出,与 YOLOv5 模型相比,随着技术改进和增强,模型的性能有了逐步的提升,在 P、R、F1 和 mAP@0.5 上都有了明显的提高,各种病害的识别效果更加平衡。序号 2 模型使用 Mosaic 9 来改善输入端,P、R、F1 和 mAP@0.5 分别提高了 1.9%、0.3%、1.1%和 0.7%,其参数量和浮点数保持不变,可以证明 Mosaic 9 数据增强对于该番茄数据集能够进一步提高模型的识别能力。采用 Mosaic 9 和 GSConv-slim neck 的序号 6 模型,P、R、F1 和 mAP@0.5 比序号 2 模型分别提高了 0.3%、0.4%、0.3%和 0.4%,其参数量和浮点数降低了 1.18 M 和 3.2 GFLOPs,说明其在轻量化的同时提高了模型的识别效果。随着 SimAM 注意力机制的引入,序号 10 模型的 P、R、F1 和 mAP@0.5 比序号 6 模型分别提高了 0.5%、0.7%、0.6%和 0.2%,其参数量和

浮点数不变,在不引入额外参数的情况下,更准确地提取小病斑特征,最终的序号 13 模型在所有指标中表现得最好,参数量和浮点运算数增加了部分的前提下,同时为 P、R、F1、mAP@0.5 四个指标带来了增益,相对于原始 YOLOv5s 分别提升了 3.1%、1.6%、2.3%、1.5%。

3.5 对比实验

1) 增加 GSConv-slim neck 实验对比

为了验证 GSConv-slim neck 的有效性,将改进前后进行了实验对比,对比结果如表 5 所示。结合表 4、5 可以看出,在引入 GSConv-slim neck 之后,模型的大小减小了 2.3 MB,参数量减少了 1.18 M,使得模型更加轻量;同时模型的 P、R、F1 分数和 mAP 均有不同程度的提升,这表明模型对番茄病害的检测准确性有所提高;浮点运算数减少了 3.2 G,FPS 增加了 13 frame/s,这意味着模型在计算效率和推理速度方面取得了显著的改进,对于实际应用中的实时或高效率需求非常有益。

表 5 增加 GSConv-slim neck 和数据增强后的实验对比

序号	模型	模型大小/ MB	参数量 (parameters/M)	mAP	浮点运算数 (GFLOPs)	FPS/ (frame/s)
1	YOLOv5s+m9	14.4	7.02	0.94	15.8	344
2	1+GSConv-slim neck	12.1	5.84	0.944	12.6	357

因此,在引入 GSConv-slim neck 后,减轻模型重量的同时保持精度,提高了模型的效率和推理速度。

2) 注意力模块对比实验

为了进一步验证 SimAM 的有效性,分别将其与其他注意力机制 SE(squeeze-and-excitation)、CBAM、ECA(efficient channel attention)、CA(coordinate attention)进行横向比较,实验结果如表 6 所示。由表可以看出,不同的注意力机制对

模型的性能产生了不同的影响,SimAM 模型在大多数指标上都取得了最佳结果,且没有引入额外参数。而 SE 注意力机制在 P、R、F1、mAP 四个指标上都略有下降,CBAM 仅在准确率上有所提升,ECA 注意力机制在 mAP 分数上有所下降,且 SE 和 CBAM 模型大小均增加了 1 MB,CA 注意力机制在召回率和 mAP 分数上表现良好,但其模型最大,且在准确率上相比于 SimAM 低了 1.6%。

表 6 增加不同注意力机制的消融实验

序号	模型	P	R	F1	mAP	模型大小/MB
1	YOLOv5s+m9+GSConv-slim neck	0.942	0.909	0.925	0.944	12.1
2	1+SE	0.941	0.907	0.924	0.938	13.1
3	1+CBAM	0.943	0.9	0.921	0.936	13.1
4	1+ECA	0.944	0.912	0.928	0.936	12.1
5	1+CA	0.931	0.929	0.93	0.949	13.7
6	1+SimAM	0.947	0.916	0.931	0.946	12.1

因此,SimAM 注意力模块在番茄病害检测中表现出色,提供了最佳的性能,同时保持了模型的轻量化。

3) 特征融合模块对比实验

为了进一步验证 ASFF 模块的有效性,分别将 ASFF 和加权双向特征金字塔网络(bidirectional feature pyramid network,BiFPN)模块加入到模型中进行横向比较,实验结果如表 7 所示。由表可以看出,ASFF 的引入能够使模型

的 P、R、F1、mAP 四个指标分别带来 0.4%、0.2%、0.3%、0.2%的增益,但同时也增加了部分参数量与计算量。BiFPN 的引入在准确率上仅提升了 0.1%,在其他 3 个指标上均有所下降。

综上所述,ASFF 特征融合模块在番茄病害检测中相比于 BiFPN 效果更好,进一步验证了 ASFF 在提高模型性能方面的有效性。

表7 两种融合方法的消融实验

序号	模型	P	R	F1	mAP
1	YOLOv5s+m9+GSConv-slim neck+SimAM	0.947	0.916	0.931	0.946
2	1+BIFPN	0.948	0.904	0.925	0.939
3	1+ASFF	0.951	0.918	0.934	0.948

4) 检测效果对比

为了更直观地验证改进后的网络性能,本文在不同类型的番茄叶片病害测试集上进行验证,并将检测结果与原模型的检测结果进行了可视化对比,结果如图11所示。从图中可以看出,原始的YOLOv5s难以在低光条件下有效检测目标,从而导致误报和漏报。

相对于原始YOLOv5s模型,改进后的模型减少了漏检和误检的情况,提高了病斑目标的定位精度,从而在保持高精度的同时,能够识别小目标病斑,其中图11(a)为漏检的情况,图11(b)为误检的情况。这充分表明了该算法在各种尺度的目标上拥有更出色的特征感知和提取能力。

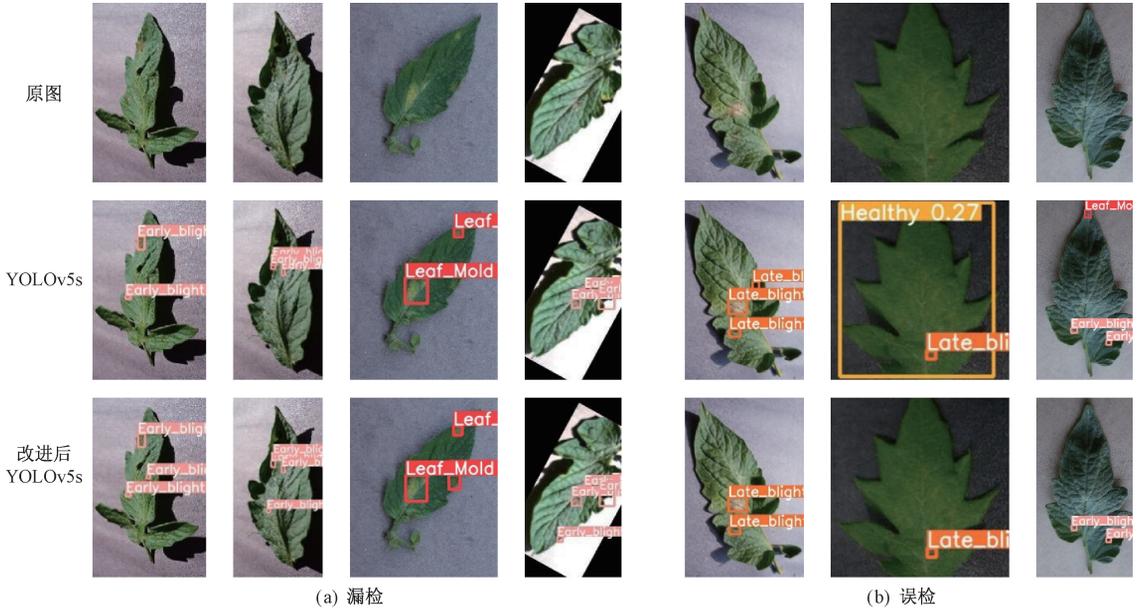


图11 改进前后检测效果对比示意图

5) 不同模型的对比实验

为了验证本研究提出的方法具有更好的效果,选择YOLOv3-tiny、YOLOv7、YOLOv7-tiny、YOLOv8n、SSD五种不同模型,在同一测试设备、相同的配置环境下,利用同一训练和验证数据(即离线数据增强后的番茄病害数据集)进行对比试验,以对比检验不同模型的性能,均进行

100次训练,实验结果如表8所示。

从表8可看出,相较于其他目标检测算法,改进算法具有最优的P、R、F1和mAP。相较于原始YOLOv5模型,改进模型的P、R、F1和mAP分别提升了3.1%、1.6%、2.3%、1.5%;相较于YOLOv3-tiny、YOLOv7、YOLOv7-tiny、YOLOv8n,改进模型的P、R、F1和mAP

表8 不同模型结果对比

序号	模型	P	R	F1	mAP@0.5
1	YOLOv5s	0.92	0.902	0.911	0.933
2	YOLOv3-tiny	0.831	0.875	0.852	0.902
3	YOLOv7	0.915	0.894	0.904	0.926
4	YOLOv7-tiny	0.877	0.894	0.885	0.904
5	YOLOv8n	0.927	0.898	0.912	0.939
6	SSD	0.901	0.504	0.646	0.696
7	改进后 YOLOv5s	0.951	0.918	0.934	0.948

均最优,其中准确率比以上 4 种模型分别高 12%、3.6%、7.4%、2.4%;SSD 模型的召回率、F1 分数及精度在所有模型中最低。总的来说,改进算法在番茄叶部早期病斑诊断中更具优势。

4 结 论

本文采取 Mosaic 9 数据增强技术,增强了模型对小病斑的检测能力,并有效地降低了漏检率,从而提高了模型的泛化能力。通过引入 GSConv 和 Slim-Neck 网络,旨在轻量化的同时保持精度,提高计算效率和推理速度。同时,在 Backbone 主干网络中引入 SimAM 注意力机制,有效地提取了更为显著的病斑特征,从而在目标检测任务中取得了更好的效果。最后,ASFF 的融入进一步提高了多尺度目标的检测精度,特别是对小目标的识别能力。

本文通过对 YOLOv5s 目标检测网络进行了一系列的优化和改进,有效提升了番茄叶部早期病斑的检测性能。通过广泛的实验和对比,验证了所提出改进策略的有效性,在性能指标上取得了显著的提升。然而,本研究仍然存在一些潜在的拓展空间,未来的工作可以考虑其他病害特征,以获得更全面的番茄病害检测模型,可以进一步探索更加轻量化同时保持精度的结构,降低其参数量和复杂度,以进一步提升目标检测模型的性能。

参考文献

- [1] MIMI T T, SHEIKH M H, SHAMPA R A, et al. Leaves diseases detection of tomato using image processing[C]. 8th International Conference on System Modeling and Advancement in Research Trends (SMART), 2019:244-249.
- [2] 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.
- [3] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. 14th European Conference on Computer Vision(ECCV), 2016, 9905: 21-37.
- [4] 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), 2016, 2016-December:779-788.
- [5] WANG H Q, SHANG S Q, WANG D W, et al. Plant disease detection and classification method based on the optimized lightweight YOLOv5 model [J]. Agriculture, 2022, 12(7): 931.
- [6] WANG J, YU L Y, YANG J, et al. DBA_SSD: A novel end-to-end object detection algorithm applied to plant disease detection [J]. Information, 2021, 12(11):474.
- [7] GONG X L, ZHANG S J. A high-precision detection

method of apple leaf diseases using improved faster R-CNN[J]. Agriculture, 2023, 13(2):240.

- [8] LIN J, BAI D, XU R J, et al. TSBA-YOLO: An improved tea diseases detection model based on attention mechanisms and feature fusion[J]. Forests, 2023, 14(3):619.
- [9] 石晨宇,周春,靳鸿,等.基于卷积神经网络的农作物病害识别研究[J].国外电子测量技术,2021,40(9):93-99.
- [10] 潘仁勇,张欣,陈孝玉龙,等.基于 DTS-ResNet 的苹果叶片病害识别方法[J].国外电子测量技术,2022, 41(9):142-148.
- [11] LI S, WANG X Q. YOLOv5-based defect detection model for hot rolled strip steel[J]. Journal of Physics: Conference Series, 2022, 2171(1).
- [12] WANG C Y, LIAO H Y, WU Y H, et al. CSPNet: A new backbone that can enhance learning capability of CNN[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR), 2020:1571-1580.
- [13] 赵德安,吴任迪,刘晓洋,等.基于 YOLO 深度卷积神经网络的复杂背景下机器人采摘苹果定位[J].农业工程学报,2019,35(3):164-173.
- [14] 徐印赞,江明,李云飞,等.基于改进 YOLO 及 NMS 的水果目标检测[J].电子测量与仪器学报,2022,36(4): 114-123.
- [15] 韩泽山,杨红柳,赵建光,等.基于改进 YOLOv5s 的口罩佩戴检测算法研究[J].信息技术与信息化,2023(2): 22-25.
- [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 [J]. ArXiv Preprint, 2022, ArXiv:2206.02424.
- [17] YANG L X, ZHANG R Y, LI L D, et al. SimAM: A simple, parameter-free attention module for convolutional neural networks [C]. International Conference on Machine Learning (ICML), 2021, 139: 11863-11874.
- [18] LIU S T, HUANG D, WANG Y H. Learning Spatial Fusion for Single-Shot Object Detection [J]. ArXiv Preprint, 2019, ArXiv:1911.09516.
- [19] 肖黎俊,潘睿志,李超,等.基于改进 YOLOv5s 绝缘子缺陷检测技术研究[J].电子测量技术,2022,45(24): 137-144.
- [20] 胡晓林.番茄常见病害的发生及防治[J].现代农村科技,2022(2):34.
- [21] 李军安.保护地番茄早疫病防治新技术[J].河南农业, 2022(4):27.
- [22] 何毅.番茄主要病虫害防治技术[J].现代农业科技, 2020(23):96-98.

作者简介

金婷婷,硕士研究生,主要研究方向为感知技术与智能系统。

房建东,博士,教授,主要研究方向为信息处理与智能控制。

E-mail:fangjd@imut.edu.cn

赵于东,学士,研究员,主要研究方向为智能感知与分析决策。