

DOI: 10.13733/j.jcam.issn.2095-5553.2024.12.034

李昱达, 吴正平, 孙水发, 等. 改进 YOLOv5 算法的多类苹果叶片病害检测[J]. 中国农机化学报, 2024, 45(12): 230-237

Li Yuda, Wu Zhengping, Sun Shuifa, et al. Multi-species apple leaf disease detection with improved YOLOv5 algorithm [J]. Journal of Chinese Agricultural Mechanization, 2024, 45(12): 230-237

改进 YOLOv5 算法的多类苹果叶片病害检测^{*}

李昱达¹, 吴正平¹, 孙水发², 林森³, 伍箴燎¹, 沈虹杜¹

(1. 三峡大学电气与新能源学院, 湖北宜昌, 443002; 2. 杭州师范大学信息科学与技术学院, 杭州市, 311121; 3. 山东财经大学工商管理学院, 济南市, 250000)

摘要:针对多类苹果叶片病害准确率差异大、检测精度不高的问题,提出一种改进 YOLOv5 准确判别苹果叶片病害的检测算法(YOLOv5-CSEP)。首先,引入 C3Ghost 模块替换原 YOLOv5 主干网络 C3 模块,减少模型的参数量与计算量;其次,将混合注意力模块 C-SAM 加入主干网络中,提高主干网络的特征提取能力,在颈部网络中加入 CA 注意力模块,抑制复杂背景干扰关注目标信息;最后,引入增强型路径聚合网络(E-PANet)充分融合多尺度特征,提升网络对多类苹果叶片病害检测的准确性与鲁棒性。试验表明,改进后算法的各项性能指标均有提升,精确率达到 93.2%,平均精度均值 $mAP@0.5$ 达到 87.9%,与原 YOLOv5 算法相比分别提高 3.4% 与 1.7%,计算量减少 11%。

关键词:苹果叶片;病害检测;注意力机制;增强型路径聚合网络;YOLOv5

中图分类号:S661.1; TP391.4 **文献标识码:**A **文章编号:**2095-5553 (2024) 12-0230-08

Multi-species apple leaf disease detection with improved YOLOv5 algorithm

Li Yuda¹, Wu Zhengping¹, Sun Shuifa², Lin Miao³, Wu Zhenliao¹, Shen Hongdu¹

(1. College of Electrical Engineering and New Energy, China Three Gorges University, Yichang, 443002, China;
2. College of Information Science and Technology, Hangzhou Normal University, Hangzhou, 311121, China;
3. School of Business Administration, Shandong University of Finance and Economics, Jinan, 250000, China)

Abstract: Aiming at the problems of large difference in accuracy and low detection accuracy of various types of apple leaf diseases, an improved YOLOv5 detection algorithm for accurate identification of apple leaf diseases (YOLOv5-CSEP) was proposed. Firstly, C3Ghost module was introduced to replace the C3 module of YOLOv5 backbone network to reduce the number of parameters and calculation amount of the model. Secondly, the hybrid attention module C-SAM was added to the backbone network to improve the feature extraction capability of the backbone network, and the CA attention module was added to the neck network to suppress the interference of complex background information. Finally, an enhanced path aggregation network (E-PANet) was introduced to fully integrate multi-scale features and improve the accuracy and robustness of the network to detect various types of apple leaf diseases. Experiments showed that all performance indexes of the improved algorithm were improved, the accuracy rate reached 93.2%, and the average accuracy ($mAP@0.5$) reached 87.9%. Compared with the original YOLOv5 algorithm, it was improved by 3.4% and 1.7% respectively, and the calculation amount was reduced by 11%.

Keywords: apple tree leaf; disease detection; attention mechanism; enhanced path aggregation network; YOLOv5

0 引言

中国是世界上最大的苹果生产国,长期保持着最

大消费国地位^[1]。近年来,我国市场对于苹果的需求已超 46 000 kt,苹果的人工培育面积不断扩大。然而,从优质高产方面来讲低于世界平均水平,低品质果

收稿日期:2023 年 8 月 26 日 修回日期:2023 年 10 月 10 日

^{*} 基金项目:国家自然科学基金资助项目(61871258)

第一作者:李昱达,男,2000 年生,山东威海人,硕士研究生;研究方向为目标检测、图像识别。E-mail: 1261007026@qq.com

通讯作者:吴正平,男,1966 年生,湖北宜昌人,博士,教授;研究方向为控制科学与工程。E-mail: wuzp@ctgu.edu.cn

实积压滞销影响着我国苹果产业的经济收益,病害则是导致苹果的生产力与优果率低下主要原因之一^[2]。早期病害检测方法主要由专家目视检测,不仅要求专家精确掌握各类病害特点,还需要对病害的治疗方法了然于胸,实时性差,效率不高^[3]。为提高病害检测效率,除加强专业人才的培养外,通过科技手段提高病害检测效率是另一种有效途径。

随着图像处理技术的不断进步^[4],计算机视觉在苹果病害检测领域的研究与日俱增。国内外相关学者借助传统的图像分割^[5]、标记、增强以及分类^[6]等技术在提取苹果病害特诊等领域开展了大量的研究^[7],Chakraborty 等^[8]使用 Otsu 阈值算法和直方图均衡对图像特征增强以及提取,并使用了基于多类支持向量机(SVM)的方法来识别苹果叶病害类型,试验具有一定成效;Zhang 等^[9]使用基于图像处理和模式识别的方法,利用区域生长算法(RGA)对苹果叶片图像中的病斑进行分割,试验结果表明该方法的可行性与有效性;Khan 等^[10]提出一种基遗传算法的苹果病害图像分割方法,通过预处理、分割、特征提取和分类实现对不同类型苹果病害准确识别与鉴定,准确率提升显著。然而,传统图像识别技术需要手动设计模型和提取特征,对光照、角度和尺度变化敏感,且需大量的标注数据来进行模型训练,不仅工作量大,而且鲁棒性以及泛化能力差。

相比传统的机器视觉技术,基于深度学习的目标检测算法能够在大规模数据集上进行训练,自动提取样本多维特征,泛化能力强,可移植性高,近年来得到迅速发展,在农业等领域中应用愈发成熟,常用的检测算法有:SSD、R-CNN 和 YOLO 等。Jiang 等^[11]对 SSD 算法进行改进,结合 Inception 模块和 Rainbow 级联来对 5 种苹果叶片病害进行实时检测,改进后算法鲁棒性提高但平均精度均值较低。赵嘉威等^[12]使用轻量化网络 MobileNetV3,结合注意力机制对 YOLOv4 算法进行改进,改进后算法检测速度相比于原 YOLOv4 算法有所提升,但算法参数量较大,与主流的 YOLOv5 算法相比检测速度仍较慢。曾晏林等^[13]改进 YOLOv5 算法,使用融合自注意力机制,提高对目标的特征提取能力。通过上述研究可以看出^[14],主流的深度学习模型算法鲁棒性较强,并对苹果叶片病害进行检测,但研究目标主要为提高平均精度均值,而对其中特征不明显的病害类型精度提升小,改进后某类甚至几类病害的检测精度虽有所提升,但仍与平均精度均值差距大,难以保证各类病害均精确识别。

为解决上述问题,在 YOLOv5 算法的基础上进行

改进,提出 YOLOv5-CSEP 的改进算法:使用轻量化主干网络 C3Ghost 和 C-SAM(CS),将通道注意力机制 CA 引入特征金字塔网络抑制无关信息,引入增强型路径聚合网络(E-PANet)代替原 YOLOv5 模型中的路径聚合网络,聚焦重要特征信息。其中,轻量化主干网络由 C3Ghost 和混合注意力模块 C-SAM 组成,使用 C3Ghost 减少模型计算量,提升检测速度,混合注意力模块 C-SAM 提高目标检测精度,弥补 C3Ghost 带来的精度损失。最后,在含有 5 类病害的数据集上进行验证并与其他主流目标检测算法进行对比,评估 YOLOv5-CSEP 算法性能。

1 苹果叶片病害检测算法

1.1 YOLOv5 算法

YOLOv5 算法是 YOLO 系列算法的第 5 个版本,经过多个版本更迭,对算法的特征融合、数据增强和损失函数进行不断改进,使其检测精度与速度得到了提升。该算法易于训练,有着十分出色的检测性能的同时还具有很高的稳定性与可靠性,使得工程部署成为可能^[15]。

YOLOv5 算法结构由 4 个部分组成:输入端(Input)、主干网络(Backbone)、特征融合网络(Neck)和预测网络(Head)。首先,输入端对待输入的图像进行处理后发送到主干网络,通过 Conv 模块、C3 模块和空间金字塔池化模块(Spatial Pyramid Pooling-Fast, SPPF)后得到 3 种尺度特征的输出,其中 SPPF 通过采用卷积核为 5 的最大值池化,对输入串行进行处理,有效地克服了目标大小差异引起的问题,并增强网络特征融合的能力,从而获取更丰富的目标信息。然后通过特征金字塔网络(FPN)和路径聚合网络(PANet)相结合的结构,将高层与低层的特征进行融合,使目标信息更加丰富,增强了对不同尺度物体检测的能力。最后,将生成的 3 个不同尺度的特征图输入到预测网络(Detect)进行目标分类和边界框回归任务,并通过非极大值抑制算法(NMS)来过滤冗余的预测结果,得到最终的目标检测结果。

1.2 改进 YOLOv5 算法(YOLOv5-CSEP)

由于苹果叶片的病害有多种类型,使得检测目标大小不一,而拍摄视角的不同与图像背景复杂多变会使原始 YOLOv5 算法难以聚焦重要特征,对于关键信息提取少,容易在检测苹果叶片的病害时造成漏检错检,并且原 YOLOv5 算法在骨干网络与颈部网络使用了 C3 模块,虽可以有效地从图像中提取特征,但引入了大量不必要的参数导致计算量明显增加。为解决以上问题,本研究在原 YOLOv5 模型算法基础上进行如下改进:(1)将 C3 模块替换为轻量型的 C3Ghost 模

块;(2)引入了混合注意力模块 C-SAM;(3)将原 PANet 网络替换为 E-PANet 网络,增强捕捉不同

尺度的上下文信息的能力。YOLOv5-CSEP 模型的整体结构如图 1 所示。




图 1 YOLOv5-CSEP 算法结构

Fig. 1 Model structure of YOLOv5-CSEP

注:Conv 为卷积,BN 为批量归一化,Silu 为激活函数,Concat 为特征拼接层,SPPF 为池化层,NMS 为非极大抑制算法。

1.3 C3Ghost 模块

为减少 YOLOv5 算法中冗余参数数量的同时保证检测的精度,引入 Han 等^[16]提出的 C3Ghost 模块。C3Ghost 模块继承自 C3 模块,通过将普通卷积替换为 Ghost 卷积,在无较大精度损失的情况下,降低了网络的参数量与计算量。普通卷积过程和 Ghost 卷积过程如图 2 和图 3 所示。




图 2 Conv 卷积过程

Fig. 2 Conv convolution process




图 3 Ghost 卷积过程

Fig. 3 Ghost convolution process

根据图 2 可知,假设输入特征图的宽度、高度和通道数分别为 W 、 H 和 C ,经过 $k \times k$ 与 $d \times d$ 的线性运算后,输出的特征图为 $h \times w \times n$,则在 C3 模块中单个卷积的运算量如式(1)所示。

$$Conv = n \times h \times w \times C \times k \times k \quad (1)$$

而普通卷积输出特征中有大量冗余特征,这将消耗大量参数和计算量生成这些冗余信息。由图 3 可

知,若将 Conv 卷积替换为 Ghost 卷积,则通道数变为 $n = m \times s$,即 Output 的通道数是 Identity 的 s 倍,运算量计算如式(2)所示。

$$G = \frac{n}{s} \times h \times w \times C \times k \times k + (s-1) \times \frac{n}{s} \times h \times w \times d \times d \quad (2)$$

则式(1)与式(2)的运算量之比

$$r_s = \frac{Conv}{G} \approx \frac{sC}{s+C-1} \approx s \quad (3)$$

由式(3)可知,Conv 的计算量是 Ghost 卷积的 s 倍,从理论上证明 Ghost 卷积的计算成本更低,故而将 Ghost 卷积融入 C3 模块形成 C3Ghost 模块可以减少 Conv 带来的参数量,压缩模型规模。C3Ghost 模块结构如图 4 所示。




图 4 C3Ghost 模块

Fig. 4 C3Ghost module

具体实现过程:首先,将输入图像使用标准卷积改变通道数后,多次堆叠 GhostBottleneck 块,生成一部分特征图;其次,对输入图像再使用 3×3 的卷积操作,得到另一部分特征图;最后,将两部分特征图进行拼

接,输出得到最终的特征图^[17]。C3Ghost 在减少计算量与参数量的同时,仍可以保持较高特征表示能力,无较大的精度损失,提高了模型的性能和效率,有利于网络轻量化与部署。

1.4 C-SAM 混合注意力模块

C-SAM 混合注意力模块融合了 CA 注意力模块和 SimAM 无参注意力模块两个部分。将两部分优点与不足互补,以较少的参数量的增加,提升检测的精度,达到其他模块的改进效果。

注意力机制是受到人类大脑信号和视觉的启发而发展起来的一种模块,Hou 等^[18]提出的移动网络注意力机制(Coordinate Attention,CA),这是一种基于坐标信息的注意力模块,能够捕捉输入特征图中不同位置之间的空间结构信息,增强不同通道之间的信息交互与传递,从而使网络更加注重重要特征通道,以达到提高模型的性能和检测效果。为了在众多输入特征中聚焦重要特征,获取对苹果叶片病害检测起到关键作用的信息,使网络模型检测的更加准确高效,本研究引入 CA 注意力机制提高病害叶片检测效率。CA 注意力机制具体实现过程如图 5 所示。




图 5 Coordinate attention block 结构

Fig. 5 Coordinate attention block structure

首先,使用尺寸为 $(1,W)$ 和 $(H,1)$ 的池化核来对输入的特征信息进行编码,以得到高度 h 的第 c 个通道 z_c^h ,计算如式(4)所示。

$$z_c^h(h) = \frac{1}{W} \sum_{0 \leq i \leq W} x_c(h, i) \quad (4)$$

式中: x_c ——输入特征 x 在通道 c 上的值。

同理,可以得到宽度为 w 的第 c 个通道 z_c^w 。

$$z_c^w(w) = \frac{1}{H} \sum_{0 \leq j \leq H} x_c(j, w) \quad (5)$$

依次将式(4)和式(5)输出的具有全局感受野的特征图进行拼接后传入 1×1 卷积模块,批量归一化后,将特征图 F_1 经过非线性激活函数 Sigmoid,得到特征图 f ,如式(6)所示。

$$f = \delta(F_1([z^h, z^w])) \quad (6)$$

式中: f ——空间信息在垂直方向和水平方向的中间特征图, $f \in \mathbb{R}^{C/r \times (H+W)}$;

δ ——非线性激活函数;

r ——下采样率。

根据特征图 $f \in \mathbb{R}^{C/r \times (H+W)}$,将 f 沿空间维度分割成两个部分: $f^h \in \mathbb{R}^{C/r \times H \times 1}$ 和 $f^w \in \mathbb{R}^{C/r \times 1 \times W}$,对分割后的 f^h 和 f^w 分别使用 1×1 的卷积变换,获得的特征图 F_h 和 F_w 与输入具有相同的通道数。然后经过 Sigmoid 激活函数进行计算,得到高度方向与宽度方向的注意力权重 g^h 和 g^w 如式(7)和式(8)所示。

$$g^h = \sigma(F_h(f^h)) \quad (7)$$

$$g^w = \sigma(F_w(f^w)) \quad (8)$$

最后,使用原始输入 $x_c(i, j)$ 的特征图乘以注意力权重,得到最终输出的特征信息如式(9)所示。

$$y_c(i, j) = x_c(i, j) \times g_c^h(i) \times g_c^w(j) \quad (9)$$

通过学习这些坐标信息使模型能够很好地理解特征图的空间布局,聚焦重要特征,抑制无关信息,从而提升模型对空间结构的感知能力。然而,CA 模块对全局信息的捕捉能力较弱。

Yang 等^[19]提出无参注意力模块(Similarity-based Attention Module, SimAM),相比其他注意力模块,SimAM 在不引入额外学习参数前提下,可以更好对特征权重进行评估,减少冗余信息,提高全局感知的能力。通过度量神经元之间的线性可分性,可定义能量函数如式(10)所示。

$$e_t(w_t, b_t, y, x_i) = (y_t - \hat{t})^2 + \frac{1}{M-1} \sum_{i=1}^{M-1} (y_0 - \hat{x}_i)^2 \quad (10)$$

式中: t ——目标神经元, $\hat{t} = w_t t + b_t$ 是 t 的线性变换;

x_i ——相邻神经元, $\hat{x}_i = w_t x_i + b_t$ 是 x_i 的线性变换;

w_t ——神经元变换时的权重;

b_t ——神经元变换时的偏差;

y ——一般神经元的输出;

y_0 ——其他神经元 x_i 的标签;

y_t ——目标神经元 t 的标签;

M ——通道的神经元数量。

但 SimAM 不足之处在于计算复杂度较高可能会导致注意力过于集中,造成特征偏执问题。

针对上述所提问题,考虑到 CA 与 SimAM 的优点与不足可以互补,首先,将 CA 与 SimAM 结合,提出新的混合注意力模块(Mixed Attention Module, C-SAM)。C-SAM 的网络结构如图 6 所示。C-SAM 的设计避免了级联连接的组合方式,将 CA 与 SimAM 以并行的方式进行拼接,弥补了 CA 模块捕捉全局信息较弱缺点的同时也解决了 SimAM 注意力过于集中的问题,使得注意力权重更加平衡,增强了模型对输入特征的感知能力。然后,使用分支融合模块(Branch Convergence Module, BCM),在无额外参数引入的同时,综合了两种注意力机制输出的特征信息,使其互补的应用于输入特征图,并使用 Sigmoid 函数进行归一化处理,注意力权重矩阵中数值较高的位置和通道会得到更高的权重,模型会在前向传播时更加关注重要特征。最后,将得到的特征图经过卷积层 Conv 处理,减少参数量的同时对特征进行精炼并输出。C-SAM 综合了 CA 与 SimAM 的优点,增强了算法对于不同病害的辨识度,弱化了无关背景信息,提高模型的精确性与鲁棒性,是稳定高效的注意力模块。




图 6 混合注意力模块结构图

Fig. 6 Mixed attention module structure diagram

1.5 增强型路径聚合网络(E-PANet)

YOLOv5 的颈部网络采用了自顶向下的特征金字塔结构和自底向上的路径聚合网络结构,对原始特征图进行多次下采样、上采样和特征图的融合操作以得到不同尺度的特征图。但多次使用上下采样会造成一定的特征损失,特征图融合过程也会导致噪声特征信息的多次混叠,最终特征图存在较多噪声信息。为解决上述问题,在 FPN 网络中引入通道注意力机制 CA,将参数量较少的 CA 插入融合操作之后,聚焦重要特征信息的同时抑制不重要的信息从而抑制特征融合过程中的噪声干扰。

为解决多类苹果叶片病害准确率差异大的问题,将 C3Ghost 模块和 C-SAM 模块应用到 PANet 结构中,构成增强型路径聚合网络(E-PANet)。C3Ghost 引入 GhostBottleneck,增强了模型的表征能力,减少了计算量和参数数量,并且使用低秩卷积核保留关键信息,模型性能得以保持的同时获得更高的计算效率。而 C-SAM 引入通道和空间注意力机制,能够自适应地调整特征图中不同位置和通道的重要性。将 C-

SAM 加入 C3Ghost 模块之后不仅可以抑制不相关的背景和噪声,增强模型的鲁棒性,还可以进一步提升特征的重要性和区分度,提高模型对目标的感知能力,使模型在目标检测任务中取得更好的表现,在提高小目标密集病害检测精度的同时,更能够有针对性的关注目标病害的重要特征,提高算法对于各类病害的辨识度,以解决病害特征不明显而造成的漏检问题,因此,将其串联连接后输出到预测网络。增强型路径聚合网络如图 7 所示。




图 7 增强型路径聚合网络

Fig. 7 Structure of an E-PANet

2 数据集准备与模型训练

2.1 数据集制作

试验所用数据集来自公开网络下载和现场拍摄收集的苹果叶片病害图像,在制作数据集前,先对原始数据集进行数据清理,去掉无效的苹果叶片病害图片,留下的有效图片包含的病害类型:叶斑病、褐斑病、灰斑病、锈病和白粉病,并通过裁剪、旋转和模糊处理等操作进行数据增广,最终共获得有 4 670 张图片,使用 LabelImg 工具对图片进行标注,标注标签:叶斑病(ALSpot),褐斑病(BrownSpot),灰斑病(graySpot),白粉病(powderyMildew),锈病(Rust)。最后按 9:1 的比例将数据集划分为训练集和测试集,其中训练集包含 4 203 张图片,测试集包含 467 张图片。数据集中包含的各类病害的图片数量如表 1 所示。

表 1 五类病害图像数量分布

Tab. 1 Five kinds of disease image quantity distribution 张

病害类型	叶斑病	褐斑病	灰斑病	白粉病	锈病
图片数量	1 002	772	888	1 112	896

2.2 试验环境及参数

所有试验操作平台均由单计算机完成,操作系统为 64 位 Windows10,计算机的硬件配置为 Intel Corei5 - 12400F @ 2.50 GHz, GPU 为 GeForce RTX3060,16 GB 运行内存,软件环境为 Python3.9 编程语言,Pytorch 深度学习框架,CUDA12.1GPU 加速库。为使训练图像便于输入模型,输入的图像尺寸全

部处理为 640 像素 × 640 像素, 试验设置的初始学习率设置为 0.01, 动量设置为 0.937, 批量大小为 16, 训练总轮次设置为 300 轮。

2.3 模型评价指标

采用全类平均精度均值($mAP@0.5$), 精确率 P , 召回率 R 、10 亿次浮点运算($GFLOPs$)和参数规模($Parameters$)来对模型的检测效果进行评估。分别以精确率、召回率为横坐标、纵坐标绘制出 Recall-Precision 曲线, 对曲线求积分则为 AP 值。由于本研究为多个病害类别检测, 因此对每个类别的 AP 求和取平均即为 mAP 值, 用于衡量模型对所有病害类别的检测效果, $mAP@0.5$ 指 IOU 为 0.5 时的平均精度均值。在目标检测任务中, 参数规模用于衡量模型空间复杂度的评价指标即模型大小, 这是一个重要的考量因素, 因为较小的模型通常在嵌入式设备或者移动端上更易部署且运行更高效。计算如式(11)~式(14)所示。

$$P = \frac{TP}{TP + FP} \times 100\% \quad (11)$$

$$R = \frac{TP}{TP + FN} \times 100\% \quad (12)$$

$$AP = \int_0^1 P dR \quad (13)$$

$$mAP = \frac{\sum_{i=0}^N AP_i}{N} \quad (14)$$

式中: TP ——检测正确的目标数量;

FP ——检测错误的目标数量;

FN ——漏检的目标数量;

N ——检测类别数;

i ——当前类别的编号。

本次试验类别有叶斑病、褐斑病、灰斑病、锈病和白粉病五类, 因此 $N=5$ 。

3 试验与结果分析

3.1 模型参数调试

使用 YOLOv5-CSEP 算法在数据集上进行训练, 并进行测试, 模型训练过程中的总损失、精确率与召回率和平均精度均值的变化过程如图 8 所示。

由图 8(a)可知, 随着训练轮数的增加, 分类损失、目标损失和定位损失三者之和的总损失在前 30 轮下降较快, 30 轮之后下降速度逐渐减缓。当训练轮数达到 300 轮时, 总损失曲线的波动较小, 表明模型精度达到稳定值, 因此, 将总轮数设置在 300 轮结束模型训练。由图 8(b)、图 8(c)可知, 训练轮数增加的同时, 精确率与召回率也随之不断上升, 在 250~300 轮时, 基本趋于稳定, 最终准确率和召回率达到 93.2% 和 84.3%, 各类型

苹果叶片病害检测的平均精度均值($mAP@0.5$)达到了 87.9%, 训练效果提升明显。试验中模型各类曲线的走势反映出参数设置的合理与训练过程的有效。




图 8 模型评价指标

Fig. 8 Model evaluation indicators

3.2 YOLOv5-CSEP 模型消融试验

提出的 3 种改进方法分别为使用 C3host 轻量化主干网络、混合注意力模块 C-SAM 以及增强型路径聚合网络 E-PANet。为清晰分析所提出改进方法的效果, 设计以下消融试验方法。

1) 在原 YOLOv5 算法基础上, 依次加入上述 3 种所提改进方法, 并评估每种改进方法对原算法的优化效果。

2) 在改进后 YOLOv5-CSEP 算法的基础上, 依次移除所提改进方法, 并评估每种改进方法对最终算法的优化效果。

由表 2 可知, 将原 YOLOv5 算法主干网络中的 C3 模块替换为轻量化模块 C3Ghost 后, 参数量规模减少了 17.5%, 计算量大幅下降, 虽实现了结构的轻量化, 但是平均精度均值有所降低; 而在原 YOLOv5 算法主干网络中单独加入 C-SAM 和 E-PANet, 平均精度均值分别提高 1.1 个百分点和 1.2 个百分点, 但计算量也增加, 模型体积增大。为了弥补精度的损失的同时减少计算量与参数的增加, 将 C3Ghost、C-SAM 以及 E-PANet 三种改进方法进行结合, 结合后算法的检测精度显著提高, 计算量与参数量减少, 试验结果充分证明改进后网络的提升效果, 验证了 YOLOv5-CSEP 算法的可行性。

通过上述试验可知, 提出的改进算法 YOLOv5-CSEP 与原 YOLOv5 算法相比, 准确度提高了 3.4%, 平均精度均值提高了 1.7%, 计算量减少 11%, 能够满足在提高检测精度的同时保证检测的效率。

表 2 YOLOv5—CSEP 模型消融试验					
Tab. 2 Ablation experiment of YOLOv5—CSEP model					
C3Ghost	C—SAM	E—PANet	$mAP@0.5$ /%	参数规模 /MB	$GFLOPs$
—	—	—	86.2	7.03	15.8
✓	—	—	86.0	5.87	12.4
—	✓	—	87.3	7.84	16.4
—	—	✓	87.4	7.20	17.1
✓	✓	—	87.0	6.67	13.2
✓	—	✓	86.7	6.03	13.4
✓	✓	✓	87.9	6.89	14.1

3.3 不同主流检测算法对比试验

为了能够更清晰全面评估 YOLOv5—CSEP 算法的性能,将不同主流的检测算法与本文所提算法进行试验对比,性能检测对比由表 3 所示。

表 3 与主流算法试验对比结果
Tab. 3 Experimental results are compared with the mainstream algorithms

模型	各类病害检测准确率/%					$mAP@0.5$ /%	参数规模 /MB	$GFLOPs$
	叶斑病	褐斑病	灰斑	锈病	白粉病			
YOLOv3	93.9	89.2	87.9	94.2	81.8	84.7	9.31	23.1
YOLOv4	92.5	76.0	86.2	92.9	68.8	79.6	244.24	60.52
SSD	88.9	93.4	97.9	81.6	91.2	68.2	92.6	62.74
Faster R—CNN	42.8	81.4	42.8	50.7	80.8	67.9	108	370.21
YOLOv5	96.9	84.4	89.1	92.9	85.8	86.1	7.03	15.8
YOLOv5—CSEP	97	90.3	90.6	96.8	91.2	87.9	6.89	14.1

3.4 检测结果对比


由于不同苹果叶片出现的病害区域不同,且叶片生长通常较为密集,这使人工检测叶片病害变得困难,容易出现漏检错检的情况。然而,随着算法的不断完善与硬件的不断发展,计算机检测的准确率与检测的速度已经远高于常人,因此,使用计算机可以显著提高检测的精度。分别使用 YOLOv5—CSEP 算法和原 YOLOv5 算法,对随机选取的多张易漏检、错检病害区域的图片进行检测,以更全面地评估计算机检测方法的性能检测结果如图 9 所示。

YOLOv5 受环境的影响较大,设置的对照组 I 为当病害与叶片颜色相近时的对比结果,设置的对照组 II 为病害叶片所处背景较为复杂的对比结果,由图 9 可知,YOLOv5 算法在对照组 I 中出现漏检现象,对照组 II 中出现错检的现象,在图中用红色箭头标出,改进的 YOLOv5—CSEP 算法未出现错检漏检现象;对照组 III 所检测的叶片病害较小且被强光照射,此时原 YOLOv5 算法出现错检现象,与 YOLOv5—CSEP 算法相比置信度较低,可以看出,改进后的算法鲁棒性较强,检测小目标效果好;当检测病害类型为特征不明显的病害白粉病时,在对照组 IV 中,YOLOv5 出现漏

检现象,对于特征不明显的病害检测效果不好,改进的 YOLOv5—CSEP 算法未出现漏检现象。综上所述,YOLOv5—CSEP 算法在苹果叶片病害检测精度高、鲁棒性强,出现错检漏检的现象少,可以满足实时检测的需求。

改进后算法的 $mAP@0.5$ 为 87.9%,与其他主流检测算法的 $mAP@0.5$ 相比提升显著,检测准确率明显提高,算法优势明显。并且 YOLOv5—CSEP 的参数数量最小,仅为 6.89 M,所占用的体积最小,计算量最低,运行时能降低对硬件设备的要求,有利于算法的部署,满足实时监测的需求。

检现象,对于特征不明显的病害检测效果不好,改进的 YOLOv5—CSEP 算法未出现漏检现象。综上所述,YOLOv5—CSEP 算法在苹果叶片病害检测精度高、鲁棒性强,出现错检漏检的现象少,可以满足实时检测的需求。



(a) 组 I (b) 组 II (c) 组 III (d) 组 IV

图 9 YOLOv5 和 YOLOv5—CSEP 检测结果

Fig. 9 YOLOv5 and YOLOv5—CSEP test results

4 结论

使用 YOLOv5 作为基础检测算法,提出 YOLOv5—CSEP 目标检测算法,对改进后的算法在包含 5 类苹果叶片病害的数据集中训练并进行验证,

最后比较改进后的算法与原始算法的检测效果。

1) 使用增强型路径聚合网络 E-PANet 代替原始 YOLOv5s 算法,在保证小目标病害检测精度与算法鲁棒性提高的同时,提高较大目标病害检测的精度,证明 E-PANet 的有效性。

2) 相比原始 YOLOv5 算法,使用 C3Ghost 实现模型的轻量化,以平衡 C-SAM 混合注意力模块带来的参数量的增加。并对叶斑病、褐斑病、灰斑病、锈病和白粉病 5 类病害进行检测,特征不明显病害褐斑病和白粉病的准确率分别提高 5.9% 和 5.4%,其他小目标病害准确率也得到提升,平均准确率提高 3.4%,平均精度均值提升 1.7%,参数量减少 2%,计算量减少 11%,模型性能明显提升,实现多类目标病害检测。

后续工作尝试在保证兼具检测精度与检测速度的同时将算法部署到嵌入式设备,增强实用性,实现自动化病害检测。

参 考 文 献

- [1] 任佳佳, 张朦朦, 李巍. 我国苹果区域分布特征及其供需优化分析[J]. 中国果树, 2023(5): 123—126.
Ren Jiajia, Zhang Mengmeng, Li Wei. Analysis on the regional distribution characteristics and supply and demand optimization of apple in China [J]. China Fruits, 2023(5): 123—126.
- [2] Khan A I, Quadri S M K, Banday S, et al. Deep diagnosis: A real-time apple leaf disease detection system based on deep learning [J]. Computers and Electronics in Agriculture, 2022, 198: 107093.
- [3] 陈聪, 于啸, 宫琪. 基于改进残差网络的苹果叶片病害识别研究[J]. 河南农业科学, 2023, 52(4): 152—161.
Chen Cong, Yu Xiao, Gong Qi. Apple leaf diseases identification based on improved residual network [J]. Journal of Henan Agricultural Sciences, 2023, 52(4): 152—161.
- [4] 夏小雨, 韩成浩. 基于无人机的低空图像处理技术在农业领域的应用[J]. 农业与技术, 2023, 43(1): 38—41.
- [5] 陈超, 齐峰. 卷积神经网络的发展及其在计算机视觉领域中的应用综述[J]. 计算机科学, 2019, 46(3): 63—73.
- [6] 刘颖, 雷研博, 范九伦, 等. 基于小样本学习的图像分类技术综述[J]. 自动化学报, 2021, 47(2): 297—315.
Liu Ying, Lei Yanbo, Fan Jiulun, et al. Survey on image classification technology based on small sample learning [J]. Acta Automatica Sinica, 2021, 47(2): 297—315.
- [7] Dubey S R, Jalal A S. Detection and classification of apple fruit diseases using complete local binary patterns [C]. 2012 Third International Conference on Computer and Communication Technology. IEEE, 2012: 346—351.
- [8] Chakraborty S, Paul S, Rahat-uz-Zaman M. Prediction of apple leaf diseases using multiclass support vector machine [C]. 2021 2nd International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST). IEEE, 2021: 147—151.
- [9] Zhang Chuanlei, Zhang Shanwen, Yang Jucheng, et al. Apple leaf disease identification using genetic algorithm and correlation based feature selection method [J]. International Journal of Agricultural and Biological Engineering, 2017, 10(2): 74—83.
- [10] Khan M A, Lali M I U, Sharif M, et al. An optimized method for segmentation and classification of apple diseases based on strong correlation and genetic algorithm based feature selection [J]. IEEE Access, 2019, 7: 46261—46277.
- [11] Jiang P, Chen Y, Liu B, et al. Real-time detection of apple leaf diseases using deep learning approach based on improved convolutional neural networks [J]. IEEE Access, 2019, 7: 59069—59080.
- [12] 赵嘉威, 田光兆, 邱畅, 等. 基于改进 YOLOv4 算法的苹果叶片病害检测方法[J]. 江苏农业科学, 2023, 51(9): 193—199.
- [13] 曾晏林, 贺壹婷, 蔺瑶, 等. 基于 BCE-YOLOv5 的苹果叶部病害检测方法[J]. 江苏农业科学, 2023, 51(15): 155—163.
- [14] 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.
Wang Yunlu, Wu Jiefang, Lan Peng, et al. Apple disease identification using improved Faster R-CNN [J]. Journal of Forestry Engineering, 2022, 7(1): 153—159.
- [15] 金鑫, 庄建军, 徐子恒. 轻量化 YOLOv5s 网络车底危险物识别算法[J]. 浙江大学学报(工学版), 2023, 57(8): 1516—1526.
Jin Xin, Zhuang Jianjun, Xu Ziheng. Lightweight YOLOv5s network-based algorithm for identifying hazardous objects under vehicles [J]. Journal of Zhejiang University (Engineering Science), 2023, 57(8): 1516—1526.
- [16] Han K, Wang Y, Tian Q, et al. GhostNet: More features from cheap operations [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 1580—1589.
- [17] Liu G, Hu Y, Chen Z, et al. Lightweight object detection algorithm for robots with improved YOLOv5 [J]. Engineering Applications of Artificial Intelligence, 2023, 123: 106217.
- [18] 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.
- [19] Yang L, Zhang R Y, Li L, et al. SimAM: A simple, parameter-free attention module for convolutional neural networks [C]. International Conference on Machine Learning. PMLR, 2021: 11863—11874.

论文精选:改进 YOLOv5 算法的多类苹果叶片病害检测

研究概况

针对多类苹果叶片病害准确率差异大、检测精度不高的问题,提出一种改进 YOLOv5 准确判别苹果叶片病害的检测算法(YOLOv5—CSEP)。首先,引入 C3Ghost 模块替换原 YOLOv5 主干网络 C3 模块,减少模型的参数量与计算量;其次,将混合注意力模块 C—SAM 加入主干网络中,提高主干网络的特征提取能力,在颈部网络中加入 CA 注意力模块,抑制复杂背景干扰关注目标信息;最后,引入增强型路径聚合网络(E—PANet)充分融合多尺度特征,提升网络对多类苹果叶片病害检测的准确性与鲁棒性。试验表明,改进后算法的各项性能指标均有提升,精确率达到 93.2%,平均精度均值 $mAP@0.5$ 达到 87.9%,与原 YOLOv5 算法相比分别提高 3.4%与 1.7%,计算量减少 11%,不同叶片背景与病害类型的漏检错检现象减少,为苹果叶片病害检测问题提供一种有效方法。

该研究由国家自然科学基金资助项目(61871258)等资助,通讯作者为三峡大学的吴正平教授。

主要技术指标

模型	各类病害检测准确率/%					$mAP@0.5/\%$	参数规模/MB	$GFLOPs$
	叶斑病	褐斑病	灰斑	锈病	白粉病			
YOLOv3	93.9	89.2	87.9	94.2	81.8	84.7	9.31	23.1
YOLOv4	92.5	76.0	86.2	92.9	68.8	79.6	244.24	60.52
SSD	88.9	93.4	97.9	81.6	91.2	68.2	92.6	62.74
Faster R—CNN	42.8	81.4	42.8	50.7	80.8	67.9	108.0	370.21
YOLOv5	96.9	84.4	89.1	92.9	85.8	86.1	7.03	15.8
YOLOv5—CSEP	97.0	90.3	90.6	96.8	91.2	87.9	6.89	14.1

