

doi:10.6041/j.issn.1000-1298.2022.08.035

基于 PSA – YOLO 网络的苹果叶片病斑检测

晁晓菲¹ 池敬柯² 张继伟³ 王孟杰³ 陈尧¹ 刘斌¹

(1. 西北农林科技大学信息工程学院, 陕西杨凌 712100;

2. 西北农林科技大学水利与建筑工程学院, 陕西杨凌 712100;

3. 西北农林科技大学机械与电子工程学院, 陕西杨凌 712100)

摘要: 为提高 YOLOv4 目标检测算法对苹果叶片小型病斑的检测性能, 提出了一种 PSA (金字塔压缩注意力) – YOLO 算法。在 CSPDarknet53 的基础上融合了 Focus 结构和 PSA 机制, 并采用网络深度减小策略, 构建了参数量小、精确度高的 PSA – CSPDarknet – 1 轻量化主干网络。其次在网络颈部, 搭建了空间金字塔卷积池化模块, 用极小的计算代价增强了对深层特征图的空间信息提取能力, 并采用 α -CIoU 损失函数作为边界框损失函数, 提高网络对高 IoU 阈值下目标的检测精度。根据实验结果, PSA – YOLO 网络在苹果叶片病斑识别任务中的 AP₅₀ 达到 88.2%。COCO AP@ [0.5:0.05:0.95] 达到 49.8%, 比 YOLOv4 提升 3.5 个百分点。网络对于小型病斑的特征提取能力提升幅度更大, 小型病斑检测 AP 比 YOLOv4 提升 3.9 个百分点。在单张 NVIDIA GTX TITAN V 显卡上的实时检测速度达到 69 帧/s, 相较于 YOLOv4 网络提升 13 帧/s。

关键词: 苹果叶片病斑; 目标检测; YOLOv4 网络; PSA – YOLO 网络

中图分类号: TP391.4 文献标识码: A 文章编号: 1000-1298(2022)08-0329-08 OSID: 

Apple Leaf Lesion Detection Based on PSA – YOLO Network

CHAO Xiaofei¹ CHI Jingke² ZHANG Jiwei³ WANG Mengjie³ CHEN Yao¹ LIU Bin¹

(1. College of Information Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China

2. College of Water Resources and Architectural Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China

3. College of Mechanical and Electronic Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China)

Abstract: In order to improve the detection performance of YOLOv4 object detection algorithm for small apple leaf lesions, a PSA – YOLO network with low computational cost and high accuracy was proposed, which integrated a Focus layer and the pyramid squeeze attention block in the CSPDarknet, and the strategy of network depth reduction was adopted. Finally, the PSA – CSPDarknet – 1 was built on the basis of CSPDarknet53. The experimental results showed that the computational complexity of PSA – CSPDarknet – 1 was reduced by 30.4% compared with the CSPDarknet53 and the detection accuracy of the network for small lesions (covering area less than 32 × 32 pixels) was improved by 2.9 percentage points. In the neck, a spatial pyramid convolution and pooling module was built to enhance multi-scale information extraction in spatial dimensions with a small computational cost, and α -CIoU loss function for the bounding box was used to improve the detection accuracy of bounding boxes for improving the detection accuracy of lesions under the high IoU threshold. According to the experimental results, the proposed PSA – YOLO network achieved 88.2% AP₅₀ and it achieved 49.8% COCO AP@ [0.5:0.05:0.95] in the apple leaf lesion dataset, which was 3.5 percentage points higher than that of YOLOv4. At the same time, the feature extraction ability of the network for small lesions was more improved, and AP_s was 3.9 percentage points higher than that of YOLOv4, respectively. The detection speed on a single NVIDIA GTX TITAN V reached 69 frames per second, which was 13 frames per second faster than that of YOLOv4.

Key words: apple leaf lesion; object detection; YOLOv4 network; PSA – YOLO network

0 引言

在农业自动化生产的最新进展中,深度学习常与物联网技术和无人驾驶飞行器相结合用于开发智能农业系统^[1]。深度卷积神经网络(Deep convolutional neural network, DCNN)^[2]与自动化机械等设备相结合,实现自动、高效的作物病害识别和检测,为作物病害的预防和识别提供更为高效且准确的技术支持^[3]。目前,国内外对 DCNN 在农业上的应用研究包括但不限于作物病害分类^[4-6]、作物与病斑分割^[7-8]、作物及其病害识别与检测^[9-10]等。

基于深度学习的植物病害目标检测算法主要以 YOLO(You only look once)系列为核心的单阶段算法以及以 RCNN(Region - CNN)为核心的双阶段算法为主^[11-21]。文献[15-18]中的研究主要是替换或改良 YOLO 网络中的主干网络从而提高算法的检测性能,但改进后的网络仍存在对病斑区域关注程度不足、对深层特征中所包含语义信息的利用不足等缺点,影响病斑检测性能。因此在对作物病斑检测中,需要充分考虑并利用这些因素来提升 YOLO 网络的性能。此外,还应对 YOLO 网络做必要的轻量化处理以满足检测的实时性及在移动端部署时的

要求。

为解决上述问题,本文以 YOLOv4 目标检测网络为基础,针对苹果叶片的病斑检测任务,以提升网络对苹果叶片病斑检测的精确度和速度为目标,搭建具有检测准确率高、检测速度快、小目标检出率高等特点的 PSA(金字塔压缩注意力)-YOLO 目标检测网络。

1 数据集构建

1.1 苹果病害叶片图像采集

实验所用苹果叶片病害数据集由人工采集,包含斑点落叶病、褐斑病、灰斑病和锈病等 4 种苹果叶片病害图像,其中苹果叶片斑点落叶病的图像为 556 幅,褐斑病图像为 493 幅,灰斑病图像为 404 幅,锈病图像为 429 幅,共 1 892 幅原始图像(JPEG 格式)。图像均采用智能手机拍摄,如图 1 所示。大多数为自然光下田间直接采集的具有复杂背景的图像,少部分为单纯实验室背景的图像,通过缩放、填充、裁剪等操作将原始图像尺寸统一规整为 256 像素×256 像素。从图 1 中可以看出苹果叶片病害图像有叶片病斑小、病斑相似度高等特点,这给病斑特征的提取及病斑的精准检测带来了一定难度。



图 1 苹果患病叶片数据集图例

Fig. 1 Examples of apple diseased leaves dataset

1.2 数据增强与数据集划分

本文在训练前将获取的全部图像按照 8:1:1 的比例随机划分训练集、验证集与测试集。采用 Mosaic 方法^[14]对训练集进行数据增强,如图 2 所示。这种数据增强方法的主要过程为,在训练集中随机选取 4 幅图像,并对所选的图像进行随机翻转,最终将这 4 幅图像拼接成 1 幅图像。在叶片训练数

据有限且没有增加训练集图像数量的前提下,使每幅图像包含 4 幅不同图像的信息,能提高目标检测网络的泛化能力。

2 PSA - YOLO 检测算法

2.1 PSA - YOLO 网络结构

本文基于 YOLOv4 目标检测网络进行改进,提出 PSA - YOLO 网络,如图 3(图中 CBM 表示卷积-批归一化-Mish 激活函数模块,BN 表示批归一化)所示。首先,在 CSPDarknet53 主干网络中添加了 Focus 结构^[22]和 PSA 机制^[23],并按照“1-1-4-4-2”的型式堆叠残差块,精简网络层数。其次,将压



图 2 Mosaic 数据增强后的部分训练集图像

Fig. 2 Images with Mosaic augmentation in training set




图 3 PSA - YOLO 结构
Fig. 3 Structure of PSA - YOLO

缩合并 (Squeeze and concat, SPC) 模块与空间金字塔池化 (Spatial pyramid pooling, SPP)^[24] 模块融合为空间金字塔卷积池化模块 (Spatial pyramid convolution and pooling, SPCP) 替代了原有的 SPP 模块。最后,采取 K-means 聚类方法和 α -CIoU 损失函数对训练图像进行维度分析和边界框回归,检测头部分保持不变。这些部分共同构成了 PSA - YOLO 网络的基本结构。

2.2 PSA - CSPDarknet 特征提取网络

为使含有重要信息的通道在网络前向传播初期获得更大程度的关注,充分提取苹果叶片病斑边缘纹理底层特征提升检测的精确度,PSA - CSPDarknet 网络只保留 CSPDarknet53 网络 CSP1 - 1 层中的残差块并在残差块前增加 Focus 结构和 PSA 模块,PSA - CSPDarknet 网络结构如图 4b 所示。




图 4 原 CSP 1 - 1 结构和改进后的结构
Fig. 4 Structure of original CSP 1 - 1 and improved structure

Focus 结构在 YOLOv5^[22] 目标检测网络中已经得到运用,代替了主干网络第一次下采样,在 COCO 数据集中展示了良好的检测性能。其通过张量切片

操作将输入图像切分为 4 个相似的特征图,然后将 4 个特征图在通道维度上融合使空间特征在无信息损失的情况下转化为通道特征,以此来代替原网络中的第一次下采样。

PSA 模块分为 4 部分,如图 5 (图中 k 表示卷积核尺寸, G 为卷积核分组大小, FC 表示全连接层) 所示。首先,通过 SPC 模块有效地提取并整合输入特征图不同尺度的空间信息。SPC 模块对输入特征图的空间维度用 3、5、7、9 共 4 种尺寸的卷积核进行分组卷积,每种尺寸卷积核所分组大小分别为 2、4、8、16,来实现对特征图的分组卷积与通道压缩。然后将用 SPC 模块处理后的特征图使用 SEWeight 模块^[25]学习权重,统筹局部和全局注意力,根据特征通道对分类任务的重要程度分配不同权重。Softmax 将包含通道的权重归一化。通过将归一化的权重与 SPC 模块处理后的特征图相乘实现了注意力权重与通道之间的交互,使得特征图中对病斑检测更重要的通道分配到更高权重。

为了均衡主干网络的速度和精度,以融合 Focus 结构和 PSA 模块后的 CSPDarknet53 为基础,重新调整残差块的数量排布,以精简网络层数,降低网络参数和计算量。分别构建了 3 个模型,PSA - CSPDarknet - 1、PSA - CSPDarknet - 2、PSA - CSPDarknet - 3。其中,PSA - CSPDarknet - 1 将 CSPDarknet53 网络 CSP 层中残差块的数量减半,设置为“1 - 1 - 4 - 4 - 2”,受文献[26]中 ResNet - 18、ResNet - 34 网络结构启发,将 PSA - CSPDarknet - 2、PSA - CSPDarknet - 3 残差排列分别设置为“1 - 2 - 2 - 2”和“1 - 3 - 4 - 6 - 3”。




图5 金字塔压缩注意力机制结构
Fig.5 Structure of PSA mechanism

2.3 空间金字塔卷积池化模块

为进一步提取深层主干网络中空间维度的多尺度语义信息,搭建了空间金字塔卷积池化模块以替代原有空间金字塔池化模块。YOLOv4 中颈部主要包含两部分,即空间金字塔池化和路径聚合网络(Path aggregation network, PANet)^[27]。空间金字塔池化是一种特殊池化方法,采用步长为 1、卷积核尺寸为 5×5 、 9×9 和 13×13 的最大池化,其与主干网络最深一层的特征图紧集成,扩大感受野并整合多尺度空间信息。PSA-YOLO 目标检测网络中,主干网络提取局部纹理和图案信息,以构建后续层所需的语义信息。然而,随着网络深度的增加,层之间的互连变得更加复杂,网络的宽度也会变得更加庞大,尤其在通过 SPP 模块后卷积核数量达到 2 048,增加了网络的参数量和计算量。在 SPP 模块之前插入了 SPC 模块,用分组多尺度卷积后再压缩的方法使进入 SPP 模块的卷积核数减少一半,在加强对多尺度空间信息提取的同时,对网络计算量进行了进一步平衡。如图 6 所示,将 SPC 模块添加到 SPP 模块之前,将通过 SPP 模块后的通道数压缩为 1 024,搭建起 SPCP 模块。在基本不影响网络中数据传播速度的前提下,提高了网络对局部特征与全局特征信息的利用效率。路径聚合网络中使用了自下而上的路径增强,缩短了多尺度特征金字塔图的高低融合路径,融合来自 PSA-CSPDarknet-1 中 CSP4 层、CSP2 层和经 SPCP 模块输出的 3 种尺度的特征图信息,使较浅网络(CSP4 层、CSP2 层)的特征信息得到有效利用。

2.4 边界框损失函数

在目标检测算法的边界框回归中,很多常用的边界框损失函数都基于 IoU 损失演化而来,例如 Generalized IoU (GIoU)^[28]、Distance IoU (DIoU) 和




图6 空间金字塔卷积池化模块结构
Fig.6 Structure of SPCP module

Complete IoU (CIoU)^[29]。 α -IoU 系列损失^[30]应用幂变换来概括上述基于 IoU 的损失。当出现 IoU 值低的噪声框时, α -IoU 损失会自适应地提高边界框回归损失值,使在训练带有争议的预测框时,边界框损失的降低得到抑制,避免过拟合现象发生。相反,当出现 IoU 值高的预测框时, α -IoU 损失会相对噪声框获得更低的边界框损失,进而使得网络能预测更多高 IoU 对象,实现在高 IoU 阈值的目标检测平均精度上升。在以上两种因素同时作用下,会最终使网络针对高 IoU 阈值的目标检测性能得到提高。

3 实验与结果分析

3.1 实验环境和评价指标

3.1.1 硬件条件和超参数设置

实验环境配置参数如下:操作系统为 Ubuntu 16.04 LTS,中央处理器为 Intel Xeon E5-2620 v4,图形处理器为 NVIDIA GTX TITAN V,显存为 12 GB。训练使用 PyTorch 1.2 深度学习框架。

3.1.2 评价指标

机器视觉国际会议中常用 COCO AP (Average precise) 或 AR (Average recall) 作为目标识别的评价标准。本文采用 COCO AP@ [0.5:0.05:0.95] 作为苹果叶片病害检测准确率评价指标来综合评估模型的检测性能,即分别在 IoU 阈值设置以 0.05 的步距从 0.5 开始遍历至 0.95,取这些阈值条件下评估所得到的平均准确率的均值。

根据检测器的 IoU 阈值不同,则对应召回率所对应的检测精度不同,得到不同阈值下的 AP,例如当 IoU 阈值等于 0.5 时对应的 AP 值为 AP_{s0} 。当被检测的物体覆盖面积小于 $32 \text{ 像素} \times 32 \text{ 像素}$ 时,其被视作小目标,对应的指标被称为 AP_s 。当被检测的物体覆盖面积大于 $96 \text{ 像素} \times 96 \text{ 像素}$ 时,其被视作大目标,对应的指标被称为 AP_L 。被检测的物体面积介于两者之间,则为中等大小,其指标被称为 AP_M 。

3.2 网络训练

在训练过程中为了扩充数据集和保证损失值

的稳定下降,PSA - YOLO 使用了学习率的余弦退火衰减策略、边界框的非极大值抑制等 YOLOv4 原有的训练策略,并使用二元交叉熵损失作为类别置信度损失函数。还将数学特征更加平滑的 Mish 激活函数应用在整个网络中以增强目标检测器的准确性和泛化性能。批大小 (Batch size) 采用 16,采用余弦退火衰减策略更新学习率,学习率初始值为 1.0×10^{-4} ,最小值为 1.0×10^{-5} ,每 20 轮为一个衰减周期。 α -CIoU 损失中 α 的取值为 3。总训练轮数为 200。

3.3 主干网络的对比实验

为实现主干网络目标检测精度和检测速度的均衡提升,以获得更高性能的目标检测网络,在原主干网络 CSPDarknet53 的基础上进行了模块添加实验和网络轻量化实验,以此证明不同的改进对

网络性能的影响,最终比较得出最优的主干网络。实验按照 2.2 节所描述的方法分别在 CSPDarknet53 网络 CSP1 - 1 层中加入 Focus 结构、PSA 模块,以及将主干网络的残差块分别按照“1 - 2 - 2 - 2 - 2”、“1 - 1 - 4 - 4 - 2”、“1 - 3 - 4 - 6 - 3”型式进行堆叠。最后,将不同结构的主干网络结构带入 YOLOv4 网络中代替原有的 CSPDarknet53 主干网络进行性能比较。

如表 1 所示,Focus 结构和 PSA 模块的加入,使 CSPDarknet53 网络在无参数量提升的情况下,AP 提升 2.4 个百分点。同时注意到,Focus 结构和 PSA 模块的加入使网络 AP_s提升 2.9 个百分点,这说明 Focus 结构和 PSA 模块的加入有利于主干网络对苹果叶片病斑特征的提取,尤其是小型病斑特征的提取。

表 1 基于 CSPDarknet53 对主干网络的改进实验结果

Tab.1 Result of improved backbone network experiment based on CSPDarknet53

主干网络	残差块排布	Focus + PSA	AP/%	AP _s /%	参数量/MB	浮点运算数/次
CSPDarknet53	1 - 2 - 8 - 8 - 4	不添加	46.3	35.8	26.62	6.57×10^9
PSA - CSPDarknet - 0	1 - 2 - 8 - 8 - 4	添加	48.7	38.7	26.61	6.42×10^9
PSA - CSPDarknet - 1	1 - 1 - 4 - 4 - 2	添加	48.1	38.2	18.04	4.57×10^9
PSA - CSPDarknet - 2	1 - 2 - 2 - 2 - 2	添加	47.0	37.0	16.44	4.06×10^9
PSA - CSPDarknet - 3	1 - 3 - 4 - 6 - 3	添加	47.8	38.1	22.10	5.40×10^9

PSA - CSPDarknet - 1、PSA - CSPDarknet - 2、PSA - CSPDarknet - 3 网络比加入 Focus 结构和 PSA 模块未轻量化的 PSA - CSPDarknet - 0 网络精度都有所下降,说明网络深度的减小会对病斑检测的精确度产生不利影响。但三者的精确度都比最初的 CSPDarknet53 网络有所提高,这表明 Focus 结构和 PSA 模块的加入抵消了因网络深度减小而导致的精确度降低,使网络的性能得到均衡提升。同时PSA - CSPDarknet - 1 网络与 PSA - CSPDarknet - 3 网络相比,有更小的参数量和更高的检测精度。PSA - CSPDarknet - 2 网络虽然参数量得到了明显的减小,但检测精确度受网络深度缩减影响较大,检测精确度与 PSA - CSPDarknet - 1 网络相比仍有不足。

综合以上结果,为了使主干网络的检测精确度和速度达到均衡,最终选择 PSA - CSPDarknet - 1 网络作为病斑检测网络的主干网络。相比 CSPDarknet53,PSA - CSPDarknet - 1 的参数量小、浮点运算数少、运算速度快、精度高,其计算量与 CSPDarknet53 网络相比减少了 30.4%、AP 提升了 1.8 个百分点,具有更好的移动端部署的特点,相比表 1 中所对比的其他主干网络,PSA - CSPDarknet - 1 能更好地实现对苹果叶片病斑的实时检测。

3.4 主干网络与颈部的组合实验

为探讨 SPCP 模块的加入对目标检测网络训练精确度和速度的影响,设计以下消融实验。分别采用 PSA - CSPDarknet - 1 与 CSPDarknet53 两种主干网络与 SPP 模块及 SPCP 模块进行组合实验,选出最优组合方式。

由表 2 可见,PSA - CSPDarknet - 1 网络与 SPP 模块及 SPCP 模块组合的结果都比 CSPDarknet53 与这两个模块组合的实验结果更为理想,网络参数量和运算量有所下降的同时,使网络的准确率与检测速度得到提升。其中,以 PSA - CSPDarknet - 1 为主干网络,添加 SPCP 模块后,使网络在计算量没有明显提升的前提下,病斑检测的平均精确度达到 48.5%。实验结果表明,当采用 PSA - CSPDarknet - 1 主干网络且颈部中加入 SPCP 模块时,网络获得最

表 2 网络颈部对比

Tab.2 Ablation study of neck of network

主干网络	颈部	参数量/ MB	浮点运算数/ 次	AP/ %	检测速度/ (帧·s ⁻¹)
CSPDarknet53	SPP	63.96	1.132×10^{10}	46.3	56
	SPCP	64.30	1.134×10^{10}	47.0	56
PSA - CSPDarknet - 1	SPP	55.38	9.32×10^9	48.1	70
	SPCP	55.72	9.34×10^9	48.5	69

优检测性能,相比于YOLOv4,AP提升2.2个百分点,速度提升13帧/s。

3.5 损失函数对比实验

不同的边界框损失函数能够对网络的检测精度带来不同程度的影响。为了对比 α -DIoU、DIoU、 α -CIoU等3种边界框损失函数与YOLOv4所采用的CIoU边界框损失函数的性能,分别将这4种边界框损失函数与LeakyReLU及Mish激活函数进行组合实验,选出最好的激活函数与边界框损失函数的组合方案。组合实验结果如表3所示。

表3 边界框损失函数对比

Tab.3 Comparisons of bounding box loss functions				
激活函数	损失函数	AP/%	AP ₅₀ /%	AP ₇₅ /%
LeakyReLU	DIoU	48.2	86.9	45.7
	α -DIoU	49.1	87.2	45.7
	CIoU	48.5	87.1	46.5
	α -CIoU	49.8	88.2	47.0
Mish	DIoU	48.4	86.4	46.7
	α -DIoU	49.5	88.0	47.2
	CIoU	48.3	87.3	44.9
	α -CIoU	49.3	86.8	47.5

实验结果表明,LeakyReLU激活函数与 α -CIoU损失相配合获得了最好的检测性能,网络的AP、AP₅₀、AP₇₅指标比原有的CIoU边界框损失都高,这证明了 α -IoU系列损失在苹果叶片病斑数据集上能够与改进后的PSA-YOLO网络相互配合提高不同IoU阈值目标的检测精确度。由于Mish激活函数无法有效提升网络的检测精确度,因此本文选用

LeakyReLU的激活函数与 α -CIoU边界框损失函数以获得更高的病斑检测性能。

3.6 PSA-YOLO网络综合性能对比

根据3.3~3.5节的实验结果,确定了PSA-YOLO的基本结构,主干网络:PSA-CSPDarknet-1网络,颈部:SPCP模块、PAN模块,边界框损失: α -CIoU损失。

为了验证本文所构建的PSA-YOLO网络在目标检测任务中的有效性,选取YOLOv3、YOLOv3-SPP、YOLOv4、YOLOv4-CSP网络,在其他条件和参数设置均保持一致的前提下进行对比实验。模型性能比较结果见表4。测试结果显示,当IoU阈值为0.5时,PSA-YOLO网络检测精确度(AP₅₀)达到88.2%,同时PSA-YOLO网络对病斑检测的COCO AP@[0.5:0.05:0.95]为49.8%,两者与其他网络相比都为最高。从网络对于小、中、大型目标的检测平均精确度来看,PSA-YOLO网络的AP_s、AP_m、AP_L相比于其他网络都有明显提高,其中,对于小目标的检测精确度提升最大,AP_s比YOLOv4网络提升了3.9个百分点。综上所述,本文所构建的PSA-YOLO目标检测网络具有比YOLOv4更高的检测准确率和更快的检测速度。尤其在小目标的检测方面,能够胜任具有较多小目标的苹果叶片病斑检测任务。同时,从模型对单个图像的平均处理时长来看,PSA-YOLO检测速度最快,在单张NVIDIA TITAN V显卡的算力支持下,对于单幅图像的预测时间仅为0.015 s,满足病斑检测过程中对实时性的要求。

表4 苹果叶片病斑检测任务网络综合性能对比

Tab.4 Comprehensive performance comparison for apple leaf lesion detection networks								
网络	主干网络	检测速度/(帧·s ⁻¹)	AP/%	AP ₅₀ /%	AP ₇₅ /%	AP _s /%	AP _m /%	AP _L /%
YOLOv3	Darknet53	50	21.6	45.5	18.3	8.5	22.2	63.0
YOLOv3-SPP	Darknet53	43	25.3	47.2	22.8	16.2	26.3	69.5
YOLOv4	CSPDarknet53	56	46.3	85.7	41.9	35.8	66.0	81.6
YOLOv4-CSP	CSPDarknet53s	58	48.2	85.7	44.4	37.2	67.6	83.8
PSA-YOLO	PSA-CSPDarknet-1	69	49.8	88.2	47.0	39.7	67.9	84.0

图7(图中紫框为叶片,绿框为斑点落叶病,黄框为灰斑病,红框为褐斑病,蓝框为锈病)展示了PSA-YOLO网络与YOLOv4网络对苹果叶片病斑的预测结果,其中第1列和第2列图像展示了PSA-YOLO网络对苹果叶片锈病和褐斑病病斑的检测结果,由第1列图像可见,PSA-YOLO网络相对于YOLOv4减少了病斑的漏检。第2列所示图像中病斑数真实值为6个,YOLOv4网络检测出4个,PSA-YOLO检测出5个病斑,而中间偏下位置相邻的两个病斑的距离较近,两种网络都未能准

确检测,这说明PSA-YOLO网络在对距离较近的目标检测方面仍有待改进。第3列图像说明PSA-YOLO网络能够较好识别在大田复杂背景下对于斑点落叶病的检测,相对于YOLOv4网络减少了对斑点落叶病病斑的漏检和误检,但由于数据集中自然损害的斑点以及非病斑噪声等因素的干扰,PSA-YOLO网络对于极小的病斑依然无法准确检测。第4列和第5列图像展示了两种网络在大田复杂背景和实验室背景下单叶片多病害病斑的识别,结果表明PSA-YOLO网络能够有效减少小型




图 7 4 种不同苹果病害检测结果对比

Fig. 7 Comparison of four different apple diseases' detection results

病斑的漏检率,相比于 YOLOv4 网络预测结果更加准确。

4 结束语

为提升 YOLOv4 网络的检测精确度和速度,尤其针对小型目标较多的苹果叶片病斑检测任务,本文以 YOLOv4 网络为基础,在主干网络、颈部、边界框损失函数等方面进行了对比实验。在 CSPDarknet53 的基础上添加了 Focus 结构和金字塔压缩注意力机制,并进行了轻量化处理,构建了 PSA - CSPDarknet - 1 主干网络。其次,在颈部中使

用了空间金字塔卷积池化模块,同时优选了 α -CIoU 损失作为目标检测网络的边界框损失函数。最终,搭建出 PSA - YOLO 网络。在本文构建的苹果叶片病害数据集的病斑检测任务中,当 IoU 阈值为 0.5 时,PSA - YOLO 网络检测精确度 (AP_{50}) 达到 88.2%,检测平均精确度 ($COCO AP@[0.5:0.05:0.95]$) 达到 49.8%,检测速度达到 69 帧/s,尤其是对于小型病斑的检测性能相对 YOLOv4 有较为明显提升。因此,本文所提出的 PSA - YOLO 模型的检测速度快、精度高,能满足在复杂自然环境情况下对苹果树叶片病斑实时检测任务的需要。

参 考 文 献

[1] VOUGIOUKAS S G. Agricultural robotics[J]. Annual Review of Control Robotics & Autonomous Systems, 2019, 2(1): 365 - 392.

[2] SMIRNOV E A, TIMOSHENKO D M, ANDRIANOV S N. Comparison of regularization methods for ImageNet classification with deep convolutional neural networks[J]. AASRI Procedia, 2014, 6: 89 - 94.

[3] ROY A M, BOSE R, BHADURI J. A fast accurate fine-grain object detection model based on YOLOv4 deep neural network [J]. Neural Computing and Applications, 2022, 34(5): 3895 - 3921.

[4] 吴华瑞. 基于深度残差网络的番茄叶片病害识别方法[J]. 智慧农业, 2019, 1(4): 42 - 49.

WU Huarui. Method of tomato leaf diseases recognition method based on deep residual network[J]. Smart Agriculture, 2019, 1(4): 42 - 49. (in Chinese)

[5] 黄林生, 罗耀武, 杨小冬, 等. 基于注意力机制和多尺度残差网络的农作物病害识别[J]. 农业机械学报, 2021, 52(10): 264 - 271.

HUANG Linsheng, LUO Yaowu, YANG Xiaodong, et al. Crop disease recognition based on attention mechanism and multi-scale residual network [J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(10): 264 - 271. (in Chinese)

[6] 雷雨, 周晋兵, 何东健, 等. 基于改进 CenterNet 的小麦条锈病菌夏孢子自动检测方法[J]. 农业机械学报, 2021, 52(12): 233 - 241.

LEI Yu, ZHOU Jinbing, HE Dongjian, et al. Automatic detection method for urediniospores of wheat stripe rust based on improved CenterNet model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(12): 233 - 241. (in Chinese)

- [7] ENTUNI C J, MOHD T, ZULCAFFLE A, et al. Severity estimation of plant leaf diseases using segmentation method[J]. Applied Science and Engineering Progress, 2020, 14(1): 108–119.
- [8] ADAMS J, QIU Y, XU Y, et al. Plant segmentation by supervised machine learning methods[J]. The Plant Phenome Journal, 2020, 3(1): 1–11.
- [9] 刘莫尘,高甜甜,马宗旭,等. 基于 MSRCR-YOLOv4-tiny 的田间玉米杂草检测模型[J]. 农业机械学报, 2022, 53(2): 246–255.
- LIU Mochen, GAO Tiantian, MA Zongxu, et al. Target detection model of corn weeds in field environment based on MSRCR algorithm and YOLOv4-tiny[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(2): 246–255. (in Chinese)
- [10] MATHEW M P, MAHESH T Y. Leaf-based disease detection in bell pepper plant using YOLO v5[J]. Signal, Image and Video Processing, 2022, 16(3): 841–847.
- [11] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//Conference on Computer Vision and Pattern Recognition, 2016: 779–788.
- [12] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]//Conference on Computer Vision and Pattern Recognition, 2017: 7263–7271.
- [13] REDMON J, FARHADI A. YOLOv3: an incremental improvement[J/OL]. ArXiv E-prints, 2018-04-08, <https://doi.org/10.48550/arXiv.1804.02767>.
- [14] BOCHKOVSKIY A, WANG C Y, LIAO H. YOLOv4: optimal speed and accuracy of object detection[J/OL]. ArXiv E-prints, 2020-04-23, <https://doi.org/10.48550/arXiv.2004.10934>.
- [15] SON C. Leaf spot attention networks based on spot feature encoding for leaf disease identification and detection[J]. Applied Sciences, 2021, 11(17): 7960–7960.
- [16] LIU J, WANG X. Early recognition of tomato gray leaf spot disease based on MobileNetv2-YOLOv3 model[J]. Plant Methods, 2020, 16(1): 83–99.
- [17] 岳有军,刘杰琼,王红君,等. 基于改进 YOLOv3 模型的苹果树叶片病斑检测[J]. 中国科技论文, 2021, 16(11): 1202–1208.
- YUE Youjun, LIU Jieqiong, WANG Hongjun, et al. Detection of apple leaf diseased spots based on improved YOLOv3 model[J]. China Sciencepaper, 2021, 16(11): 1202–1208. (in Chinese)
- [18] WU L, MA J, ZHAO Y, et al. Apple detection in complex scene using the improved YOLOv4 model[J]. Agronomy, 2021, 11(3): 476–491.
- [19] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//IEEE Computer Society, 2013.
- [20] GIRSHICK R. Fast R-CNN[C]//International Conference on Computer Vision. IEEE Computer Society, 2015.
- [21] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137–1149.
- [22] GLENN J. Yolov5[Z/OL]. <https://github.com/ultralytics/yolov5>, 2021.
- [23] ZHANG H, ZU K, LU J, et al. EPSANet: an efficient pyramid squeeze attention block on convolutional neural network[J/OL]. ArXiv E-prints, 2021-07-22, <https://doi.org/10.48550/arXiv.2105.14447>.
- [24] HE K, XIANG Y, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2014, 37(9): 1904–1916.
- [25] 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.
- [26] HE K, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Conference on Computer Vision and Pattern Recognition, 2016: 770–778.
- [27] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation[C]//Conference on Computer Vision and Pattern Recognition, 2018: 8759–8768.
- [28] REZATOFIGHI H, TSOI N, GWAK J Y, et al. Generalized intersection over union: a metric and a loss for bounding box regression[C]//Conference on Computer Vision and Pattern Recognition, 2019: 658–666.
- [29] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: faster and better learning for bounding box regression[C]//Conference on Association for the Advancement of Artificial Intelligence, 2020: 12993–13000.
- [30] HE J, ERFANI S, MA X, et al. Alpha-IoU: a family of power intersection over union losses for bounding box regression[C]//Conference and Workshop on Neural Information Processing Systems, 2021.