

高 泉,刘笠溶,张 洁,等. 基于 ActNN - YOLO v5s - RepFPN 的番茄病害识别及系统设计[J]. 江苏农业科学,2024,52(20):220-227.  
doi:10.15889/j.issn.1002-1302.2024.20.026

# 基于 ActNN - YOLO v5s - RepFPN 的番茄病害识别及系统设计

高 泉<sup>1</sup>,刘笠溶<sup>2</sup>,张 洁<sup>2</sup>,高颜军<sup>1</sup>,叶 荣<sup>3</sup>

(1. 云南省作物生产与智慧农业重点实验室,云南昆明 650201; 2. 云南农业大学大数据学院,云南昆明 650201;  
3. 云南农业大学食品科学技术学院,云南昆明 650201)

**摘要:**作物病害的早期检测可以提高农作物的质量和生产力,为解决番茄病害识别模型在真实复杂场景中的泛化能力弱,易受作物品种、颜色特征、叶斑形状、疾病周期和环境因素干扰,对存储和计算资源依赖性强的问题,提出 1 个轻量化改进模型 ActNN - YOLO v5s - RepFPN 来研究多个区域场景中的番茄疾病,使用 Mosaic 数据增强方法来扩展数据,结合使用模型参数压缩技术 ActNN 来替换 YOLO v5s 网络中的组件模块,保留重要激活参数的同时不影响精确度,然后在 YOLO v5s 颈部网络内构建 RepFPN 特征金字塔,增加特征信息流通,实现计算和内存平衡的硬件神经网络设计。结果表明,改进的 ActNN - YOLO v5s - RepFPN 模型在番茄病害检测精度上达到了 93.6%,检测速率为 29.0 帧/s,满足实时监测的要求,模型整体性能高于 YOLO v5s、YOLO v4、Faster R - CNN 等模型,在训练 1 000 轮后精确率、召回率、mAP 分别较 YOLO v5s 原模型高 10.0、9.8、4.9 百分点。最后,设计并实现了基于 YOLO v5s 模型智能化番茄病害检测系统,为病害智能检测系统提供了可视工具。

**关键词:**病害检测;ActNN;YOLO v5s;RepFPN;

**中图分类号:**TP391.41;S126 **文献标志码:**A **文章编号:**1002-1302(2024)20-0220-08

番茄是全球蔬菜贸易中的重要组成部分之一,具有重要地位。它不仅是日常蔬菜,还被视为新型水果和科研模式作物,拥有多重功能,因此,番茄越来越受到人们的喜爱<sup>[1-2]</sup>。随着对番茄需求的增加,全球的番茄生产总量和种植规模也在不断扩大。截至 2020 年底,我国已成为全球最大的番茄生产国家之一,年产量约为 0.7 亿 t。在我国大规模种植番茄的省份中,云南省的对外销售量位居榜首,约占我国的 37%<sup>[3-4]</sup>。

目前番茄在全球范围内广泛种植,但在生长过程中会遭受各种病虫害的侵害。番茄叶片上的病害同样对番茄产量构成威胁,若不及时防治,可能导致减产或无法收获。以前人们主要根据经验来判断番茄病害类型,但这种方法的判断能力有限且

耗时耗力。图像处理技术已经在各个领域得到广泛应用,包括农业。然而,传统的图像识别方法已无法应对复杂的实际情况,随着计算机硬件性能的提升,将深度学习应用于农业生产已成为未来农业发展的趋势。深度学习通过引入卷积层、池化层、全连接层等操作,能够自动提取图像特征,以实现植物叶片病害的准确识别<sup>[5-10]</sup>。快速、准确地识别番茄叶片病害并采取相应的防治措施对于保障作物生产和提高农民收入至关重要。

## 1 试验方法

### 1.1 YOLO v5s 模型

目标检测算法可以分为 one - stage 和 two - stage 2 种类型。随着 one - stage 检测算法的发展,YOLO 系列模型由于具有良好的检测速度和准确率逐渐应用于目标检测。YOLO v5 能够在 1 次运算中完成目标检测。而 two - stage 算法则是基于候选区域的目标检测,需要根据滑动窗口获取的图像部分进行特征提取,并使用分类器来识别图像。YOLO v5s 是 YOLO v5 目标检测系列中的一个轻量模型,它在速度、准确性和轻量化方面取得了平衡,

收稿日期:2023-11-03

基金项目:云南省重大科技专项(编号:202302AE090020,202002AE090010);  
云南省基础研究计划(编号:202101AU070096)。

作者简介:高 泉(1977—),男,云南华坪人,硕士,副教授,研究方向为智慧农业。E-mail:312441310@qq.com。

通信作者:叶 荣,博士,讲师,研究方向为食品安全信息化与数字农业。E-mail:307176152@qq.com。

适用于各种实时目标检测场景,并能够更好地满足本研发系统的需求<sup>[11-13]</sup>。网络结构主要包括输入端、Backbone 层、Neck 网络和输出端 Head 部分(图

1),图 1 中的(a)~(d)展示了与网络结构相关模块的组成。

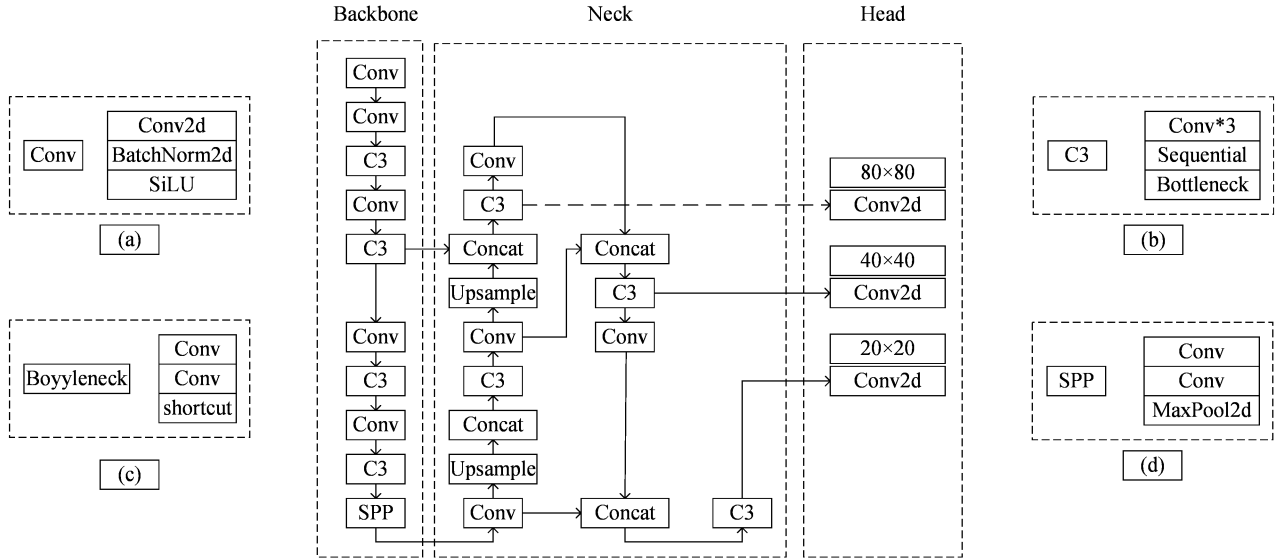


图1 YOLO v5s 网络结构

Backbone 层的 Conv 模块是基本的卷积单元,依次对输入执行 2D 卷积、2D 正则化和 SiLU 激活操作,C3 模块作为特征提取的主要结构,由 3 个卷积和 1 个瓶颈组成,可以通过解决大规模重复梯度信息的问题,整合特征图中的梯度变化,减小模型尺寸,降低模型每秒浮点运算数(FLOPs)和参数,保证推理的准确性和速度。连接不同维度的特征图的 Concat 模块被用于合并特征映射,这样可以让网络获得更多的信息,增强网络对目标的感知能力,上采样模型用于对特征映射进行采样,通过上采样,可以将低分辨率的特征映射变为高分辨率的特征映射,从而提高目标检测的精度。空间金字塔池(SPP)模块位于 YOLO v5s 网络的第 10 层,可将任意大小的特征映射转换为固定大小的特征向量,这样可以增加网络的感知场,从而检测不同尺度的目标。Neck 层通过添加具有自底向上路径增强特性的特征金字塔网络(FPN)来传播底层特征,并利用来自每个特征层的价值信息融合更高级别的特征。这样可以提高目标的定位精度,并增强网络对目标的理解能力;Head 结构的检测网络由 3 个检测层组成。每个检测层都有不同尺寸的像素特征图的输入,用于检测不同大小的目标。检测层将生成原始图像中预测的边界框和目标类别,从而实现目标的检测。

## 1.2 模型参数压缩 ActNN

在模型训练期间,存储模型参数、中间激活结

果和优化器状态会导致模型所需内存呈指数级增长,因此在内存有限的 GPU 上训练大规模模型变得困难。本研究旨在设计解决番茄病害识别系统问题,为此采用了 ActNN 策略,该策略可以在不影响预测精度的情况下快速压缩模型参数,结合 YOLO v5s 网络模型结构,本研究实现了作物病害分类、检测和分割应用<sup>[14-17]</sup>。

在 YOLO v5s 网络中通过使用 ActNN 来聚焦激活参数上下文压缩数值精度,实现动态随机量化激活神经网络,在训练过程中,训练权重、激活参数和优化器被量化后可以降低数值精度,而模型中的梯度方差容易跟随量化影响而改变,使用 ActNN 中组量化和细粒度量化的混合精度量化策略,在最大 2 位量化的情况下,该策略可以近似训练过程中梯度方差的最小化,模型压缩参数公式如下:

$$H^{(l)} = F^{(l)}[H^{(l-1)}; \Theta^{(l)}]; \quad (1)$$

$$\nabla_{H^{(l-1)}}, \nabla_{\Theta^{(l)}} = G^{(l)}\{\nabla_{H^{(l)}}, C[H^{(l-1)}, \Theta^{(l)}]\}; \quad (2)$$

$$\begin{cases} \nabla_{H^{(l-1)}} = \nabla_{H^{(l)}} \Theta^{(l)T}, \nabla_{\Theta^{(l)}} = H^{(l-1)T} \nabla_{H^{(l)}} \\ C[H^{(l-1)}, \Theta^{(l)}] = [H^{(l-1)}, \Theta^{(l)}] \end{cases} \quad (3)$$

式中:假设神经网络为  $l$  层,输入图像  $X$ ,对应标签  $Y$ ,抽取小批量样本  $(X, Y)$ ,输入  $H^{(0)} = X$ ,  $H^{(l)}$  为  $N \times D^{(l)}$ ,其中  $N$  为批量大小,  $D^{(l)}$  为特征个数,  $\Theta^{(l)}$  为参数向量,前向传播  $F^{(l)}$  包含模型参数  $\Theta^{(l)}$  的  $N$  个特征映射  $H^{(l-1)}$ 。给定用于预测  $H^{(l)}$  和标签  $Y$  的

小批量损失函数  $L = l(H^{(l)}, Y)$ , 将梯度  $\nabla$  计算为  $\nabla_{\theta^{(l)}} L$ 。  $H^{(l-1)^T}$  为特征映射的转置, 并使用优化器 SGD 更新模型参数。由于梯度变化总是与损失函数  $L$  一样, 激活参数梯度记为  $\nabla_{\theta^{(l)}} \nabla_{H^{(l)}}$ 。梯度计算过程为式(2), 其中反向传播  $G^{(l)}$  得到  $\nabla_{H^{(l)}}$ , 对于上文特征中的  $C$  需要保存在模型内存中, 用于反向传播。方程(3)作为特殊情况, 当  $H^{(l)} = H^{(l-1)} \Theta^{(l)}$  中的线性层时, 将保留住上文中的量化参数, 为实现 2 位激活压缩, 对  $l$  层神经网络的  $C$ 、 $\Theta^{(l)}$  和  $\nabla_{H^{(l-1)}}$  采用随机量化策略进行量化, 得到原始梯度的无偏估计, 如式(4)所示:

$$\% \hat{\nabla}_{H^{(l-1)}}, \hat{\nabla}_{\theta^{(l)}} = G^{(l)} \{ \hat{\nabla}_{H^{(l)}}, \hat{C} [H^{(l-1)}, \Theta^{(l)}] \}, \hat{\nabla}_{H^{(l)}} = \nabla_{H^{(l)}} \quad (4)$$

ActNN 通过动态调整混合精度量化策略, 在运行时针对不同网络层的异构特性和硬件特性进行优化, 这种优化策略能够减少无关紧要的激活参

数, 并保留重要激活参数以保持模型的准确性。

由图 2 可知, ActNN 为  $L1$  到  $L5$  定义了可选的压缩参数, 其中  $L1$  和  $L2$  可以使用 4 位每组量化, 但  $L1$  可以使用 32 位量化, 并且只处理卷积层;  $L3$  到  $L5$  使用细粒度混合精度量化策略后作用于所有卷积层上的激活参数, 在整个过程中, ActNN 只负责根据原始模型的大小比例来处理训练过程中的激活参数。

$$L1 \not\subseteq L2 \not\subseteq L3 \not\subseteq L4 \not\subseteq L5. \quad (5)$$

此外, 公式(5)中, 从  $L1$  到  $L5$  中, 压缩算法是进行逐级叠加的, 增加压缩级别会增加反向传播过程中解压激活参数所需的时间。即使在硬件条件保持不变的情况下, 训练速度也会降低。在调整参数和数据方面, 增加批处理大小和使用高分辨率图像都会增加压缩激活(CA)参数和解压激活(DCA)参数所需的时间, 导致模型收敛速度减慢。

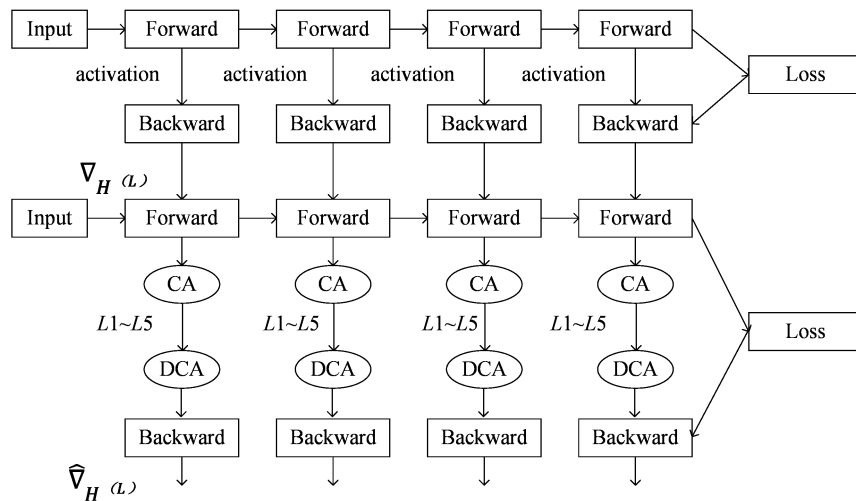


图2 ActNN 压缩参数过程

### 1.3 RepConv 网络构建

FPN 被称特征金字塔网络, 被广泛应用于目标检测等任务中<sup>[18]</sup>。FPN 通过自下而上的方式构建颈部网络中的特征金字塔, 即从底层特征图中提取高分辨率的特征, 并通过逐层上采样、融合等操作得到分辨率较低但信息更丰富的特征图。在本研究中, 使用 FPN 构建 RepFPN 对 YOLO v5s 颈部网络进行改进, RepFPN 则通过自上而下的方式构建特征金字塔, 即从顶层特征图开始进行下采样、融合, 逐层向下传递得到高分辨率的特征图, 最后应用于 YOLO v5s 检测框架中。

RepConv 网络层结构由  $3 \times 3$  Conv 分支、 $1 \times 1$

分支和身份组成, 可以充分利用硬件计算能力。通过重新参数化, 将多分支结构转换为训练状态下的单分支  $3 \times 3$  Conv, 如图 3 所示。

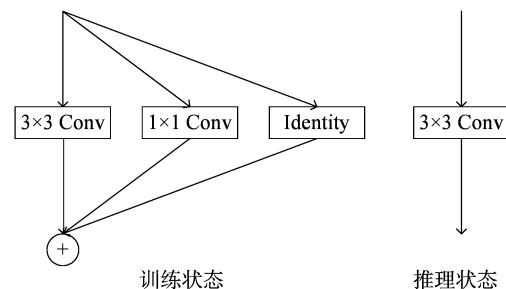


图3 RepConv 网络

RepFPN 网络是由 RepPAN 和 BepC3 (block with exponential padding) 模块组合而成的网络结构。该网络结构见图 4、图 5, 其中, C 表示卷积层, P 表示池化层。

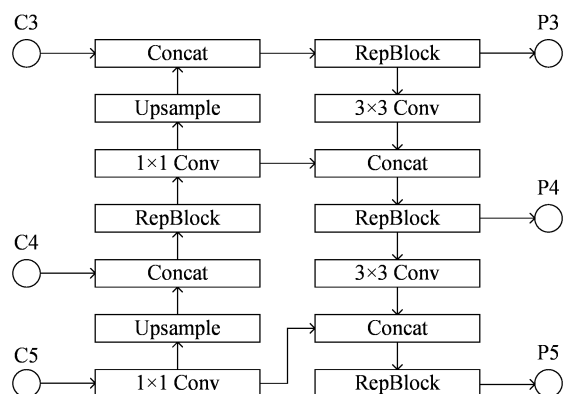


图4 RepPAN 网络

在图 5 中描述了 RepBlock 的结构, 该结构在颈部网络处结合的多尺度特征提取和循环神经网络, 以提高目标检测的性能。

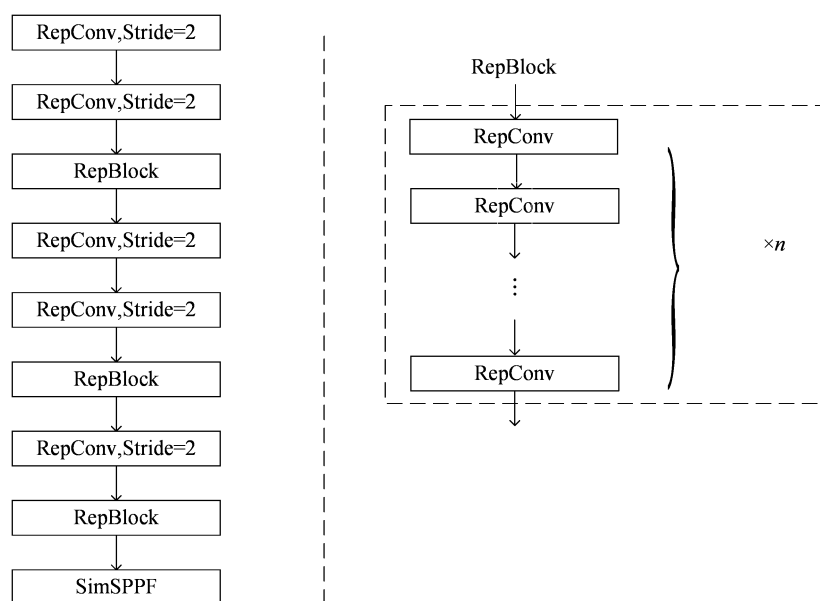


图5 EfficientRep 骨架网络

## 2 试验过程

### 2.1 数据集准备

番茄叶片病害图片取自云南农业大学后山试验基地, 试验时间为 2022 年 4—8 月。拍摄方式为人工拍摄, 考虑到场景变化多端、目标尺度参差不齐等情况, 选择了 Mosaic 数据增强方法来扩展原始数据集样本, 增加模型泛化能力。人工拍摄了 300

### 1.4 损失函数

在目标检测和实例分割中, 边界框回归 (bounding box regression, BBR) 是一个关键的步骤, 用于定位目标的位置。传统的边界框回归损失函数通常假设预测框与实际标注框具有相同的宽高比<sup>[19-23]</sup>。然而, 在宽度和高度值完全不同的情况下, 这些损失函数无法进行优化。在本研究中, 考虑了预测框与真实框之间的位置关系以及框体的尺度关系, 相比 IoU 损失函数, GIoU 损失函数通过考虑目标的非重叠区域来解决这个问题, 弥补了 IoU 边界损失函数无法量化真实框与预测框不相交的缺点。GIoU 计算公式如下:

$$GIoU = 1 - IoU + \frac{|S - A \cup B|}{|S|} \quad (6)$$

GIoU 针对这方面进行优化, 在公式中增加了预测框 A 和真实框 B 的最小凸闭合框面积 S (最小外接矩形面积), 使得在 A 与 B 不相交的时候损失仍能下降。

张图像, 并经过筛选后将数据集扩充为 1 500 张, Mosaic 拼接方法见图 6。进行训练时将其按表 1 所示进行划分。然后通过标签处理成为 YOLO v5s 模型需要数据的格式, 在 images 文件夹中存放图像, 在 label 文件夹中存放相对应的 txt 文件。

### 2.2 试验环境与参数设置

本次试验环境配置见表 2。

本次试验训练模型参数见表 3。




图6 Mosaic 拼接

表 1 叶片数据划分

类型	训练集 (张)	测试集 (张)
番茄叶片	800	200
其他叶片	400	100

表 2 试验环境

类型	环境数据
CPU	Intel Core i7 - 6700HQ
GPU	GTX970M
内存	8 GB
语言	Python
操作系统	Windows 10
深度学习框架	Tensorflow

表 3 模型参数

类型	环境数据
批大小	64 个
训练轮次(迭代次数)	1 000 轮
学习率	0.000 5
动量	0.9
权重衰减	0.000 1

### 2.3 评估指标

本研究采用采用精确率( $P$ )、召回率( $R$ )、平均精度均值( $mAP$ )等 3 个指标对番茄病害检测模型进行评价。

**2.3.1 精确率** 对于目标检测任务精确率就是在所有预测为正样本的结果中,预测正确的比例。其公式为

$$P = \frac{TP}{TP + FP} \quad (6)$$

式中: $TP$  表示预测出的正确的框; $FP$  表示预测出的错误的框; $FP + TP$  就是所有的预测框的个数。

**2.3.2 召回率** 召回率是在所有预测为正样本的结果中,真的是正样本的概率。它与精确率呈负相关。当 1 个类的精确率提高,那么这个类的召回率就会下降。其公式为

$$R = \frac{TP}{TP + FN} \quad (7)$$

式中: $FN$  表示没有被模型识别为正样本的目标数量。

**2.3.3 平均精度均值**  $AP$  是衡量一个类别检测效果好坏的参数,根据不同的置信度和 IoU 阈值,对应有不同的精确率和召回率,通过计算精确率和召回率构成的二维曲线图的面积即为  $AP$  值。而通过不同类别的  $AP$  值求取平均精度均值。 $AP$  和  $mAP$  计算公式为

$$AP = \int_0^1 P(R) dR; \quad (8)$$

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

根据设定好的试验参数,分别使用 ActNN - YOLO v5s - RepFPN 模型与 YOLO v5s、YOLO v4、Faster R - CNN 模型在数据集进行训练,并在验证集进行测试,4 个模型的边界回归损失和目标置信度变化结果见图 7。改进后的 ActNN - YOLO v5s - RepFPN 模型与其他 3 个模型相比,边界框回归损失与目标置信度损失都更小,模型收敛速度更快。在经过大约 800 轮训练后,ActNN - YOLO v5s - RepFPN 模型的边界框回归损失和目标置信度损失都趋于平缓,分别达到了 0.024 1 和 0.029 8。

4 个模型在验证集上的精确率、召回率、IoU 为 0.5 的平均精度均值的变化曲线见图 8。在大约 120 轮训练后,精确率和召回率出现了骤降,这是因为训练不充分导致特征之间的联系被破坏,特征聚

合不足以弥补。此外,ActNN-YOLO v5s-RepFPN 模型在经过 400 轮训练后逐渐趋于平缓,精确率和召回率随着训练轮次的增加而抖动上升,表明网络模型的训练效果较好。表 4 中显示了各模型的性能指标,可以看出 ActNN-YOLO v5s-RepFPN 模型

整体性能优于 YOLO v5s 和 YOLO v4 等模型。在经过 1 000 轮训练后,精确率达到了 93.6%,召回率达到了 90.8%,平均精度均值达到了 93.2%,这些数据比 YOLO v5s 原始模型分别高出了 10.0、9.8、4.9 百分点。病害识别示例见图 9。




图7 损失结果




图8 验证集结果

表 4 模型性能指标

模型	精确率 (%)	召回率 (%)	<i>mAP</i> (%)	检测速率 (帧/s)
Faster R-CNN	86.7	81.6	84.5	19.6
YOLO v4	83.2	79.4	86.5	18.6
YOLO v5s	83.6	81.0	88.3	21.5
ActNN-YOLO v5s-RepFPN	93.6	90.8	93.2	29.0

### 3 番茄叶片病害识别系统设计

#### 3.1 应用开发环境

保存模型有 2 种方法。第 1 种方法是保存整个神经网络的结构和参数信息,加载模型时直接读取模型并设置参数即可。第 2 种方法是只保存参数,读取模型参数前需要先定义 1 个与原模型相同的结构,然后将参数导入到该模型中。

训练好的模型保存后不能直接在 TensorFlow Lite 运行,因此,需要先利用 TensorFlow Lite 将模型

转换为 .tflit 格式的文件。TensorFlow Lite 架构设计见图 10,是 TensorFlow 针对移动和嵌入式设备的轻量级解决方案。以在移动设备上运行机器学习模型,实现分类等功能,无需与服务器交互。

#### 3.2 系统功能测试

整个系统测试流程见图 11。

### 4 结论

本研究算法在 YOLO v5s 算法的基础上通过采集实际实验室番茄病害图片,采用 Mosaic 数据增强





图9 病害识别示例

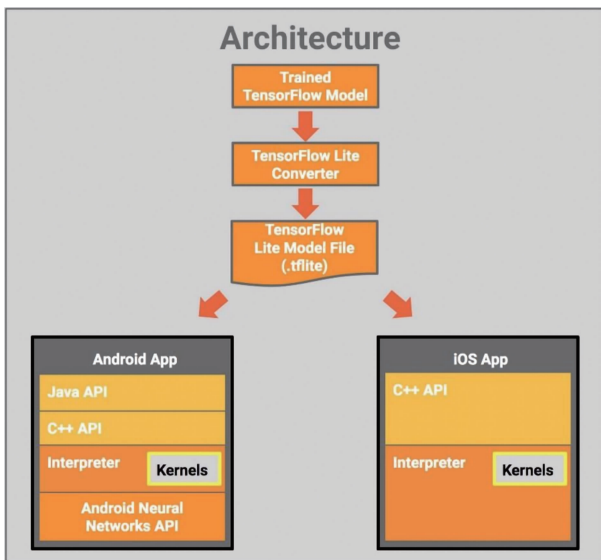


图10 TensorFlow Lite 架构

解决病害数据集不足的问题,测试了番茄在自然场景下病害识别能力。通过使用 ActNN 替换 YOLO v5 的相应模块,实现了激活参数的细粒度压缩,可以在不影响预测精度的情况下快速压缩模型参数,从数据样本和模型推广 2 个方面来考虑,ActNN 在病害检测应用上具有明显优势。

提出基于改进 YOLO v5s 的番茄病害检测模型 ActNN – YOLO v5s – RepFPN,构建 EfficientRep 主干网络来提取病害特征,并使用 EfficientRep 替换 YOLO v5s 颈部结构中的传统卷积,在不失检测精度的同时平衡计算机硬件能力。

ActNN – YOLO v5s – RepFPN 模型需要具备一

定的适应性,能够在不同光照条件下实现稳定的检测结果。在后续研究中通过增加训练数据、模型结构优化和参数处理来进一步轻量化,逐步提升模型在移动嵌入式平台的运行速度。

#### 参考文献:

- [1]米国全,唐艳领,牛莉莉,等. 危害我国番茄的重要病毒病及防控措施[J]. 中国瓜菜,2021,34(10):8–14.
- [2]张瑞花,兰超杰,刘 雯,等. 生物炭对反季节露地樱桃番茄生长及产量品质的影响[J]. 分子植物育种,2019,17(14):4831–4839.
- [3]郭小清,范涛杰,舒 欣. 基于改进 Multi – Scale AlexNet 的番茄叶部病害图像识别[J]. 农业工程学报,2019,35(13):162–169.
- [4]李君明,项朝阳,王孝宣,等. “十三五”我国番茄产业现状及展望[J]. 中国蔬菜,2021(2):13–20.
- [5]牛学德,高丙朋,南新元,等. 基于改进 DenseNet 卷积神经网络的番茄叶片病害检测[J]. 江苏农业学报,2022,38(1):129–134.
- [6]胡志伟,杨 华,黄济民,等. 基于注意力残差机制的细粒度番茄病害识别[J]. 华南农业大学学报,2019,40(6):124–132.
- [7]Amara J, Bouaziz B, Algergawy A. A deep learning based approach for banana leaf diseases classification[M]//Mitschang B. Lecture notes in informatics(LNI). Bonn: Gesellschaft Für Informatik, 2017:79–88.
- [8]Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]//31st Conference on Neural Information Processing Systems (NIPS). Long Beach, 2017:5998–6008.
- [9]Brahimi M, Boukhalfa K, Moussaoui A. Deep learning for tomato diseases: classification and symptoms visualization[J]. Applied Artificial Intelligence, 2017, 31(4):299–315.

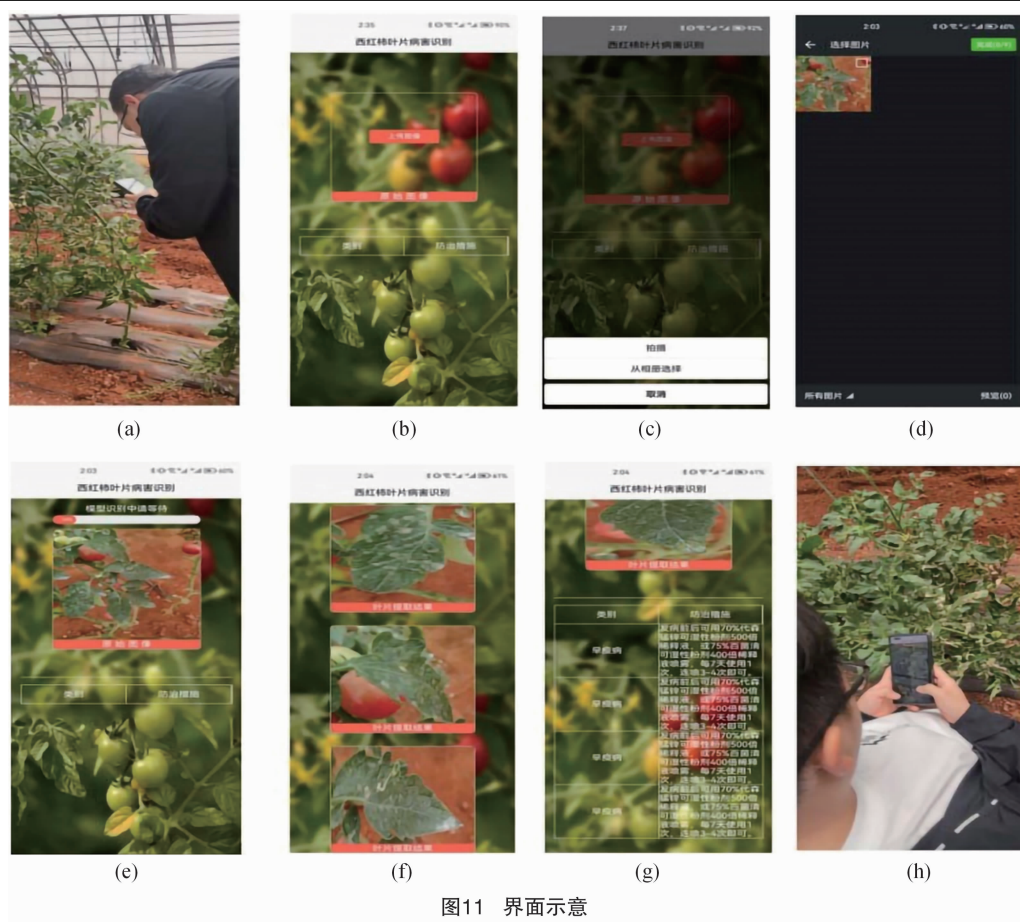


图11 界面示意

- [10] 刘拥民, 刘翰林, 石婷婷, 等. 一种优化的 Swin Transformer 番茄叶片病害识别方法[J]. 中国农业大学学报, 2023, 28(4): 80-90.
- [11] 左昊轩, 黄祺成, 杨佳昊, 等. 基于改进 YOLO v5s 的番茄黄化曲叶病检测方法[J/OL]. 农业机械学报, 2023; 1-11 (2023-09-15) [2023-10-02]. <http://kns.cnki.net/kcms/detail/11.1964.S.20230914.1408.025.html>.
- [12] 王瑜, 毕玉, 石健彤, 等. 基于注意力与多级特征融合的 YOLO v5 算法[J]. 郑州大学学报(工学版), 2024, 45(3): 38-45, 95.
- [13] 范天浩, 顾寄南, 王文波, 等. 基于改进 YOLO v5s 的轻量化金银花识别方法[J]. 农业工程学报, 2023, 39(11): 192-200.
- [14] Dai G W, Hu L, Fan J C. DA-ActNN-YOLO v5: hybrid YOLO v5 model with data augmentation and activation of compression mechanism for potato disease identification[J]. Computational Intelligence and Neuroscience, 2022, 2022: 6114061.
- [15] Chakrabarti A, Moseley B. Backprop with approximate activations for memory-efficient network training[EB/OL]. (2019-10-28) [2023-10-02]. <http://arxiv.org/pdf/1901.07988>.
- [16] Fu F C, Hu Y Z, He Y H, et al. Don't waste your bits! Squeeze activations and gradients for deep neural networks via Tinsynscript[EB/OL]. [2023-10-02]. <http://proceedings.mlr.press/v119/fu20c/fu20c.pdf>.
- [17] 周绍发, 肖小玲, 刘忠意, 等. 改进的基于 YOLO v5s 苹果树叶病害检测[J]. 江苏农业科学, 2023, 51(13): 212-220.
- [18] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu: IEEE, 2017: 936-944.
- [19] 王兵, 李文璟, 唐欢. 改进 YOLO v3 算法及其在安全帽检测中的应用[J]. 计算机工程与应用, 2020, 56(9): 33-40.
- [20] 熊恩杰, 张荣芬, 刘宇红, 等. 面向交通标志的 Ghost-YOLO v8 检测算法[J]. 计算机工程与应用, 2023, 59(20): 200-207.
- [21] 晏朋, 李遇鑫, 李治林, 等. 基于改进 YOLO v7 的高铁异物入侵检测算法[J]. 无线电工程, 2024, 54(5): 1099-1109.
- [22] 郭明镇, 汪威, 申红婷, 等. 改进型 YOLO v4-tiny 的轻量级目标检测算法[J]. 计算机工程与应用, 2023, 59(23): 145-153.
- [23] 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.