

DOI: 10.13733/j.jcam.issn.2095-5553.2025.03.038

许毓超, 吴茜, 张兵团, 等. 轻量级深度学习网络在农作物目标检测的应用进展[J]. 中国农机化学报, 2025, 46(3): 261—270

Xu Yuchao, Wu Qian, Zhang Bingyuan, et al. Review on lightweight deep learning networks for object detection in crops [J]. Journal of Chinese Agricultural Mechanization, 2025, 46(3): 261—270

轻量级深度学习网络在农作物目标检测的应用进展^{*}

许毓超^{1, 2}, 吴茜^{2, 3}, 张兵团^{1, 2, 3}, 周玲莉^{2, 3}, 任妮^{1, 2, 3}, 张美娜^{1, 2, 3}

(1. 江苏大学农业工程学院, 江苏镇江, 212013; 2. 江苏省农业科学院农业信息研究所/农业农村部长三角智慧农业技术重点实验室, 南京市, 210014; 3. 生物育种钟山实验室, 南京市, 210014)

摘要: 随着计算机视觉领域中深度学习网络模型应用的发展, 各类农业场景中的目标检测性能得到极大的推动。与部署在云端服务器的大规模深度学习网络不同, 轻量级深度学习网络因其较小的参数量和运算量, 在硬件资源有限且实时性要求更高的农业场景中展现出潜力, 完成果蔬采摘机器人的目标检测、作物病虫草害目标检测以及作物表型检测等任务。概述当前主流轻量级深度学习网络的模型结构、关键技术模块与模型性能, 进行对比分析。归纳总结轻量级深度学习网络在果实目标检测、谷物穗部检测、作物病虫害检测 3 大类应用场景的研究进展。指出轻量级深度学习网络在农作物目标检测应用上还存在普适性数据集稀缺、模型泛化能力弱、模型检测精度与检测效率的平衡难以把握等问题, 并展望通过农业数据集数量、质量与多样性提升, 轻量级深度学习网络结构优化, 迁移学习应用以及边缘设备硬件加速技术等进一步提升目标检测性能。

关键词: 农作物; 目标检测; 深度学习; 轻量级网络; 边缘计算

中图分类号:S5; TP391.4 文献标识码:A 文章编号:2095-5553 (2025) 03-0261-10

Review on lightweight deep learning networks for object detection in crops

Xu Yuchao^{1, 2}, Wu Qian^{2, 3}, Zhang Bingyuan^{1, 2, 3}, Zhou Lingli^{2, 3}, Ren Ni^{1, 2, 3}, Zhang Meina^{1, 2, 3}

(1. School of Agricultural Engineering, Jiangsu University, Zhenjiang, 212013, China; 2. Institute of Agricultural Information, Jiangsu Academy of Agricultural Sciences / Key Laboratory of Intelligent Agricultural Technology (Yangtze River Delta), Ministry of Agriculture and Rural Affairs, Nanjing, 210014, China;
3. Zhongshan Biological Breeding Laboratory, ZSBB, Nanjing, 210014, China)

Abstract: With the development of deep learning network model applications in the field of computer vision, the performance of object detection in various agricultural scenarios has been greatly boosted. Unlike large-scale deep learning networks deployed in cloud servers, lightweight deep learning networks, due to their smaller number of parameters and computing power, show potential in agricultural scenarios with limited hardware resources and higher real-time requirements, such as the object detection of fruit and vegetable picking robots, object detection of crop pests and weeds, and crop phenotyping, among other tasks. We provide an overview of the model structure, key technology modules and model performance of the current mainstream lightweight deep learning networks, and conduct a comparative analysis; summarize the research progress of lightweight deep learning networks in three major application scenarios, namely, fruit object detection, grain spike detection, and crop pest and disease detection; and analyze the scarcity of universal datasets, the weakness of the model generalization ability, the accuracy and efficiency of model detection, and the lack of model generalization ability in the application of lightweight deep learning networks in the detection of crop targets. It also analyses the scarcity of universal datasets, weak model generalization ability, and difficulty in balancing model detection accuracy and detection efficiency in crop object detection applications, and looks forward to further improving the object detection performance through the enhancement of agricultural datasets in terms of

收稿日期:2023 年 12 月 18 日 修回日期:2024 年 2 月 6 日

* 基金项目: 国家自然科学基金项目(32201664); 江苏省重点研发计划(BE2022363); 江苏省农业科技自主创新资金项目(CX(22)5009); 江苏省创新能力设计计划(BM2022008—01)

第一作者: 许毓超, 男, 2000 年生, 福建漳州人, 硕士研究生; 研究方向为计算机视觉技术。E-mail: yanx_super@qq.com

通讯作者: 张美娜, 女, 1986 年生, 内蒙古通辽人, 博士, 副研究员; 研究方向为农业机器人控制系统。E-mail: zmnl22@163.com

quantity, quality, and diversity, the optimization of the structure of the lightweight deep learning network, the application of migration learning, and the hardware acceleration technology of edge devices.

Keywords: crops; object detection; deep learning; lightweight networks; edge computing

0 引言

机器视觉技术用机器代替人眼做测量和判断,在农业自动化领域被广泛应用,如农作物分类、作物长势监测、病虫草害检测、产量预测、品质评估以及智能农业装备的精准作业^[1]。基于机器视觉的农作物目标检测方法经历了从人工提取图像颜色、形态等特征参数,到基于机器学习算法的浅层特征提取,再到基于深度学习网络的深层、高级特征提取的过程,目标检测的种类、尺度以及精度有了飞跃式发展^[2]。

目标检测算法在应用过程中,为达到更高的精度,卷积神经网络的层数越来越深,这种具有大量参数和复杂结构的庞大模型对硬件计算资源的要求更高,通常部署在大型高性能服务器上,时效性有限。在硬件资源有限且实时性需求高的农业场景中,复杂的深度学习网络模型难以实现边缘端的实时推理^[2],因此,模型的轻量化成为发展趋势之一。轻量级深度学习网络^[3]通过简化的网络结构、参数共享和特征融合等优化策略,显著减少计算资源的消耗,有效平衡精准性与实时性指标,可部署在 FPGA(现场可编程逻辑门阵列)、DSP(数字信号处理器)、SOC(片上系统)、RaspberryPi、NVIDIA Jetson 系列设备以及物联网网关、智能手机等边缘设备上^[4],为在资源受限的环境下进行农作物目标检测提供有效途径。

本文检索近 5 年来轻量级深度学习网络算法在农作物目标检测中的国内外相关研究,首先,介绍主流轻量级深度学习网络的核心关键技术与性能水平;然后,详细阐述轻量级深度学习网络算法在果实、谷物穗部以及作物病虫害等目标检测中的应用实例;最后,针对面临的问题展望未来发展方向。

1 轻量级深度学习网络

1.1 MobileNet 系列

MobileNet v1^[5] 在 2017 年被提出,其核心特点是将传统卷积方式替换成深度可分离卷积。MobileNet v1 在准确率没有大幅下降的情况下,参数量和计算量降低了大约 1/8。2018 年,MobileNet v2^[6] 被提出,该模型在 MobileNet v1 的基础上引入 IR(倒残差)结构和 LB(线性瓶颈)结构。IR 操作扩充了通道数以提取更多信息;LB 结构将输出通道数从输入通道数的低维度映射到高维度,减少信息损失。2019 年,MobileNet v3^[7]

被提出,它在前两代网络基础上采用非线性激活函数 H-Swish、可变形卷积和神经网络架构搜索 3 项新技术,分别用于降低模型计算复杂度、提高模型感受野和准确率以及提高模型性能。

1.2 ShuffleNet 系列

ShuffleNet v1^[8] 在 2017 年被提出,主要采用 PGC(逐点分组卷积)和 CS(通道重排)两个关键技术,分别用于降低模型计算复杂度以及增强特征图不同通道之间的信息流动性和跨层特征融合能力。ShuffleNet v2^[9] 是基于 4 条轻量级网络设计原则对 ShuffleNet v1 进行改进得到,它采用更加精细的分组策略和更高效的通道重排方式,并引入“残差单元+通道分离”结构来进一步提高模型的性能。

1.3 EfficientNet 系列

EfficientNet v1^[10] 在 2019 年被提出,该系列架构使用 MobileNet 中的移动翻转瓶颈卷积(MBConv)作为主干网络,包含深度可分离卷积、倒残差和线性瓶颈等模块。为设计 1 个标准化卷积网络方法来平衡分辨率、深度和宽度 3 个维度,采用模型复合缩放、神经架构搜索和网络参数优化等技术,以达到较高的准确率和更高的计算效率。2021 年,Google 提出 EfficientNet v2^[11],在 EfficientNet v1 的基础上,引入 Fused—MBConv 算子到搜索空间中,移除不重要的搜索选项;为避免不平衡的正则化因子导致精度下降,在渐进式学习方式中引入自适应正则强度调整机制。

1.4 GhostNet 系列

GhostNet v1^[12] 于 2020 年被提出,核心模块为即插即用的 Ghost 模块,以代价较低的线性操作来获取冗余的特性映射,实现在保证精度的同时压缩网络。2022 年,提出了 GhostNet v2^[13],其主要创新点在于引入 DFC(解耦全连接)注意力机制,其对长距离空间信息的建模能力强,对硬件友好且计算效率高,不会拖慢推理速度。

1.5 YOLO 系列轻量化模型

YOLO^[14] 于 2016 年被提出,是首个 one-stage 目标检测器,发展至今,YOLO 系列已更新至 YOLOv8。YOLO 系列轻量化模型是采用网络剪枝、注意力迁移、权值量化和知识蒸馏^[15] 等轻量化方法减少网络的复杂性、优化网络结构和减小参数量,其中,Tiny YOLO 系列和 YOLO—LITE 是目前轻量化领域较为常用的方法。Tiny YOLO 是 YOLO 的一种变体,参

数量只有标准 YOLO 网络的 6% 左右,计算速度更快^[16]。在 Tiny YOLO 中,每个像素点使用两个锚框进行预测,可以同时检测不同尺度和长宽比的目标,提高检测精度,Tiny YOLO 随着 YOLO 版本的更新而不断更迭。对于无 GPU 的设备来讲,Tiny YOLO 依然很难达到实时性的要求,因此,Huang 等^[17]针对无 GPU 的情况下,提出了 YOLO—LITE 网络,去除 BN 层(批量归一化),仅由 7 个卷积层组成,实现将目标检测引入无 GPU 计算机的目标。

1.6 轻量级模型的性能比较

模型结构设计和模型压缩是当前移动端神经网络模型轻量化设计的两个方向。MobileNet、EfficientNet、ShuffleNet、GhostNet 系列模型的设计思路属于模型结构设计,即通过设计更高效的网络结构来实现模型变小和变快,上述模型在 ImageNet 数据集上的性能比较如表 1 所示。MobileNet、ShuffleNet 和 GhostNet 系列模型的参数量均小于 10 M,模型的空间复杂度均较低;EfficientNet 系列模型的 Top—1 准确率较高。

表 1 模型结构设计类网络模型性能比较(ImageNet 数据集)

Tab. 1 Performance comparison of modelling algorithms based on model structure design (ImageNet Dataset)

模型	参数量/M	Top—1 准确率/%	FLOPs
MobileNet v1	4.2	70.6	569 M
MobileNet v2	3.4	72.0	300 M
MobileNet v3—Large	5.4	75.2	219 M
ShuffleNet v1 2X	5.4	73.7	524 M
ShuffleNet v2 2X	2.3	74.9	591 M
EfficientNet—B7	66	84.7	38 B
EfficientNet v2—M	55	85.1	24 B
GhostNet v1 1.3X	7.3	75.7	226 M
GhostNet v2 1.0X	6.1	75.3	167 M

注:参数量是指模型的总参数数量,M;Top—1 准确率是指模型在 ImageNet 数据集上的 Top—1 分类准确率;FLOPs 是指模型浮点运算次数,用来衡量模型计算复杂度,M(Million),B(Billion)。

表 2 给出了典型 YOLO 系列模型算法在 COCO 数据集上的性能参数。

表 2 模型压缩类网络模型性能比较(COCO 数据集)

Tab. 2 Performance comparison of model algorithms based on model compression (COCO Dataset)

GPU	模型	平均精确率 mAP /%	检测速度/fps
有	YOLOv2	48.1	40
	YOLOv3	57.9	20
	YOLOv2—Tiny	23.6	244
	YOLOv3—Tiny	33.2	220
无	YOLOv2—Tiny	23.7	2.4
	YOLO—LITE	12.3	21

注:mAP 表示所有类标签的平均精确率;检测速度表示每秒处理的图像帧数,单位 fps。

由表 2 可知,在有 GPU 条件下,YOLO Tiny 版本算法的推理速度均达到了 200 fps 以上;在无 GPU 条件下,YOLO—LITE 算法的推理速度达 21 fps。

2 农作物目标检测应用

通过检索轻量级深度学习网络在农作物目标检测任务中的应用可以发现,国内外相关研究在 2019 年之后呈现数量上的大幅增长,得益于上述主流轻量型网络架构的不断涌现,加速了其在农业场景中的应用。筛选、引用近 5 年国内外相关研究文献,通过文献分类归纳,主要集中在果实目标检测、谷物穗部识别和作物病虫害检测三大类农作任务。

2.1 果实目标检测

基于深度学习网络的果实目标识别涵盖 20 余种类别,其中番茄、苹果和柑橘的占比比较大,为此,主要介绍以上 3 大类别果实检测任务中的轻量级深度学习网络应用进展,并简要介绍其他果实检测的应用案例。

2.1.1 番茄

针对密集圣女果遮挡、粘连等情况下的果实快速识别问题,张伏等^[18]提出一种以 MobileNet v3 为骨干网的 YOLOv4—LITE 轻量化网络,改进了 FPN(特征金字塔网络)和 PANet(路径聚合网络)结构。针对传统目标识别算法速度慢、对遮挡番茄和小番茄识别准确率低的问题,杨坚等^[19]提出一种改进 YOLOv4—tiny 模型,通过在头部网络增加检测头来提高小目标识别准确率,并增加 CBAM(卷积注意力)模块以提高被遮挡番茄的识别准确率。为实现番茄果实的实时定位与成熟度检测,Zeng 等^[20]提出一种改进的 YOLOv5 轻量化网络,使用 MobileNetv3 的 bneck 结构代替 YOLOv5 的 Conv 和 C3 结构,进行了模型颈部层的通道修剪与基于遗传算法的超参优化操作。为实现植物工厂栽培模式下的小番茄目标的轻量化、高精度检测,Wang 等^[21]提出了一种轻量级 SM—YOLOv5 检测算法,将原 CSPDarknet53 骨干网替换为 MobileNetv3—Large,并增加了小目标检测层。Li 等^[22]提出了一种基于改进 YOLOv5s 的番茄目标识别与定位算法,采用内容特征感知重组(CARAFE)模块对 YOLOv5s 的上采样算法进行优化,增加网络的接受场,引入有效交并比(EIoU)和质量焦点损失(QFL)对网络的损失函数进行优化,解决样本不均匀导致的精度下降问题。

2.1.2 苹果

为解决复杂环境下苹果识别的问题,Ji 等^[23]提出一种基于 MobileNetv3—Small 的轻量级网络,利用鲸鱼优化算法^[24]对苹果数据集中的复合缩放系数进行优化。针对果园非结构环境中的苹果检测任务,王卓

等^[25]提出一种 YOLOv4—CA 轻量级网络, 使用 MobileNet v3 改进网络主干, 引入 CA(坐标注意力)机制增加对苹果特征的敏感程度以避免检测精度损失。针对苹果树叶遮挡、光照环境复杂、识别目标小而密集等问题,Zhang 等^[26]提出一种轻量级苹果检测模型 Improved YOLOv4, 该模型通过 GhostNet 特征提取网络和 CA 机制来提高检测精度, 引入深度可分离卷积重构颈部和 YOLO 头结构。为快速检测果园中苹果数量并用于产量估计,Sun 等^[27]提出一种轻量级苹果检测模型 YOLOv5—PRE, 引入 ShuffleNet 和 GhostNet 轻量级结构, 使用 CA 机制和 CBAM 机制提高算法的检测精度。

为提升自然环境下苹果检测的准确性,Li 等^[28]将 YOLOv5 特征提取部分的标准卷积替换为深度可分离卷积, 增加了一种视觉注意力机制解决提取特征时的非注意力偏好和参数冗余问题。为平衡苹果识别中的检测精度、速度和轻量化 3 个方面, 张震等^[29]提出一种改进 YOLOv7 的轻量化模型, 引入 PConv(部分卷积)替换部分常规卷积, 添加 ECA(有效通道注意力)机制提高特征提取能力, 采用了基于 SSA(麻雀搜索算法)的学习率优化策略。

2.1.3 柑橘

针对田间实时场景应用中边缘设备算力有限的问题,Zhang 等^[30]提出一种轻量级的柑橘检测算法, 算法以 Light—CSPNet 作为骨干网络, 改进了特征提取模块、下采样方法和特征融合模块。为在自然环境中准确检测青柑橘,Zheng^[31]等提出一种 YOLO BP 模型, 以 YOLOv4 为基础, 对骨干网络 CSPDarknet53 进行裁剪, 提出了一种双向 PANet 网络以有效地融合多层特征。为解决自然环境中绿色柑橘的目标检测和准确计数问题,Lü 等^[32]提出一种轻量级的目标检测 YOLOv5—CS(Citrus Sort)模型, 以 YOLOv5 为基础, 添加 CBAM 机制以获取柑橘的更多细节信息, 减少叶片和复杂背景的干扰, 使用 CIoU(完全并交比)损失函数和余弦退火算法控制学习率。针对柑橘检测准确度与模型大小的平衡问题, Chen 等^[33]提出一种轻量化的 YOLOv7 模型, 引入小目标检测层、CBAM 机制, 实现了多尺度特征提取与融合。针对果实成熟度分类问题, Huang 等^[34]提出 GCS—YOLOv4—Tiny 模型, 在 YOLOv4—Tiny 的基础上, 增加了 SE(压缩激励)模块和 SPP(空间金字塔池化)模块来提高模型精度, 并使用组卷积来减小模型尺寸。为提高复杂场景下柑橘水果识别的准确性和实时性,Xu 等^[35]提出一种 HPL—YOLOv4 轻量化模型, 采用 GhostNet 作为主干网增强柑橘的特征提取, 在颈部网络中引入深

度可分离卷积和 Mish 激活函数来减小模型的参数, 利用 ECA 机制获得多尺度特征权重。

2.1.4 其他果实

王金鹏等^[36]提出一种改进型 YOLOv4—LITE 轻量化火龙果检测方法, 将 YOLOv4 的骨干网络替换为 MobileNetv3, 并在网络的特定层进行上采样特征融合。针对草莓收获机器人的草莓实时检测,Zhang 等^[37]提出基于 YOLOv4—tiny 的轻量级神经网络 RTSD—Net, 对原 CSPNet 进行裁剪、参数缩减与替换。针对草莓果实堆叠、叶片遮挡和小目标等问题, 汤泽政等^[38]提出了改进 YOLOv7—Tiny 的成熟草莓识别模型, 将激活函数替换为 SiLU, 引入轻量化 RepGhost 网络, 在小目标层加入了 C3 模块, 模型具有识别速度快、识别精度高和轻量化的特点。针对葡萄果实生长密集、遮挡等问题,Liu 等^[39]提出一种基于 YOLOX—Tiny 的葡萄检测模型 YOLOX—RA, 采用 3×3 卷积层代替焦点层以减小计算负担, 进行了骨干网裁剪, 用 ResBlock—M 模块代替 CSPLayer 模块以提高检测速度, 采用深度可分离卷积代替常规卷积。为提高密集和遮挡葡萄目标的检测精度和速度, Chen 等^[40]提出一种轻量级 GA—YOLO 模型, 在 YOLOv4 的基础上, 设计一种新的骨干网 SE—CSPGhostNet, 采用自适应空间特征融合机制, 解决密集和闭塞葡萄难以检测的问题。为实现自然环境下的板栗果实目标快速识别, 李茂等^[41]提出一种改进 YOLOv8 的轻量化模型, 将 PConv 引入 C2f 模块中, 引入 BiFPN(加权双向特征金字塔网络), 损失函数改为 WIoU(Wise—IoU)。

2.1.5 小结

综合分析上述应用案例, 各类果实目标识别检测模型在轻量简化方面主要采用了 YOLO 系列和 Tiny YOLO 系列为基本算法, 引入 MobileNet、ShuffleNet、GhostNet 等轻量级模型的部分骨干结构作为主干网络, 或对主干网进行裁剪或者关键模块替换, 以提高检测效率; 而在目标检测精度提升方面, 则采取改进特征金字塔、改进检测头、改进损失函数、增加注意力机制、优化学习率、增加鲸鱼算法等不同方法, 其中注意力机制模块的应用有效提升了小目标以及枝叶遮挡情况的果实目标检测精度。上述基于轻量级深度学习方法的果实目标识别应用与主要性能指标如表 3 所示。在模型检测精度方面, 最高达 99.15%, 平均值为 94.47%; 模型规模最小为 2.70 MB, 50 MB 以下的模型占 87.5%, 10 MB 以下的占 25%; 模型的推理时间为 3.01 ms, 平均推理时间为 43.12 ms。

表3 基于轻量级深度学习方法的果实与植株目标识别应用成果

Tab. 3 Fruit and plant target recognition application results based on lightweight deep learning method

对象	参考文献	硬件(训练与边缘部署)	主干网	精度/%	模型大小/MB	参数量/M	推理时间/ms
番茄	文献[18]	训练: Intel(R) Xeon(R) Silver 4210R+NVIDIA Quadro P2200 16 G	MobileNetv3	99.15	45.30	—	3.01
	文献[19]	训练: Intel i5-10600KF + Nvidia GTX 2060	YOLOv4-tiny	97.9	81.30	—	9.00
	文献[20]	训练: Hygon 7185 + NVIDIA V100 16 GB	MobileNetv3	96.9	3.01	—	42.50
	文献[21]	训练: NVIDIA GeForce RTX 3090	MobileNetv3—Large	97.8	6.33	—	42.50
苹果	文献[22]	训练: Intel i9-9900 k+GeForce RTX 2080 SUPER	YOLOv5s	95.33	14.60	—	9.00
	文献[25]	训练: Intel (R) Core(TM) i7 8700 + NVIDIA TITAN V 边缘部署: Jetson AGX Xavier	MobileNetv3	92.23	54.10	—	66.18
	文献[26]	训练: AMD Ryzen 5 3600X + NVIDIA RTX 3060Ti	GhostNet	95.72	37.90	—	22.12
	文献[27]	训练: Intel (R) Xeon (R) Silver 4214+NVIDIA Quadro P620	ShuffleNet+GhostNet	94.03	4.80	—	27.00
	文献[28]	训练: AMD Ryzen7 4800H + NVIDIA GeForce GTX 1660Ti	YOLOv5	95.03	—	—	290.31
	文献[29]	训练: Intel (R) Xeon (R) Platinum 8255C +Nvidia GeForce RTX 3090	YOLOv7	97.00	—	28.99	13.18
柑橘	文献[30]	训练: Intel i7 8th+GeForce GTX 1080Ti 边缘部署: Jetson Xavier NX	CSPNet	93.00	48.00	—	46.95
	文献[31]	训练: Intel i7-10700+NVIDIA GeForceGTX 3090	YOLOv4	91.55	—	—	55.56
	文献[32]	训练: Intel(R) Core (TM) i9-11900+NVIDIA GeForce RTX 3080 边缘部署: Jetson Xavier NX	YOLOv5	98.23	—	—	35.71
	文献[33]	训练: NVIDIA GeForce RTX A4000	YOLOv7	97.29	—	24.26	69.38
	文献[34]	训练: Intel(R) Core (TM) i7-8700+NVIDIA GeForce RTX 2080	YOLOv4-tiny	93.42	20.70	—	—
	文献[35]	—	GhostNet	93.45	43.50	—	18.20
其他 果实	火龙果 ^[36]	训练: Intel (R) Core (TM) i5-9600KF + GeForce GTX 1660Ti	MobileNetv3	96.48	2.70	—	2.28
	草莓 ^[37]	训练: AMD Ryzen 5 3600 6-Core + AMD RTX 3070 边缘部署: Jetson Nano	YOLOv4-tiny	83.06	—	—	49.50
	草莓 ^[38]	训练: AMD Ryzen5 3600 + NVIDIA GeForce RTX 3060	YOLOv7-tiny	93.2	—	11.7	2.8
	葡萄 ^[39]	训练: Intel (R) Core (TM) i9-11900 K + NVIDIA GeForce RTX 3080	YOLOX-tiny	88.75	17.53	—	11.78
	葡萄 ^[40]	训练: Intel (R) Xeon (R) E5-2680 + Tesla M40 24 G×4	GhostNet	96.87	32.50	—	17.89
	板栗 ^[41]	训练: I9 9900K+NVIDIA A4000 边缘部署: Jetson Nano	YOLOv8	89.4	12.1	—	23.25

注: 推理时间指算法模型最终在每张图片上进行的推理时间, 单位为 ms, 文献[19]、[27]、[28]、[29]、[30]、[31]、[37]、[39]、[40]、[41]进行了帧率(每秒处理的图像帧数, 单位 fps)向推理时间的换算。

2.2 谷物穗部检测

水稻、小麦、玉米等谷物的穗部识别在作物产量估算、病害检测和数字化育种等方面具有广泛应用价值^[42]。为提高复杂农田场景下小麦麦穗检测的准确性,

Bhagat 等^[43]提出一种轻量级的 WheatNet-Lite 模型, 采用带反向残差块的混合深度可分离卷积技术构建主干网, 改进的 SPP 模块用于提取多尺度特征。针对复杂背景下密集遮挡的麦穗小目标检测任务, Dong 等^[44]提

出一种轻量级 Shuffle Polarized Self—Attention (SPSA)麦穗检测模型,使用具有不对称卷积的轻量级 AsymmNet^[45]骨干网络进行有效的特征提取,引入 PSA(极化自注意机制),并采用 CIoU 损失函数和 TanhExp 激活函数。为准确、快速地统计单位面积内有效水稻穗数,Sun 等^[46]提出基于 YOLOv4 的水稻弯曲穗部检测模型,以 MobileNet v2 作为主干网,结合 FL(焦点损失)和 CBAM,采用非最大值软抑制方法解决数据集中水稻穗部遮挡问题。Khaki 等^[47]提出 WheatNet 模型计算小麦穗数,使用截短的 MobileNet v2 作为轻量级的主干特征提取器,合并不同尺度的特征图来对抗图像尺度变化。为提高巡检机器人检测玉米花丝的精度和速度,朱德利等^[48]研究一种轻量级目标检测模型 YOLOX—CA,将 CA 模块嵌入到 YOLOX—s 主干网部分,并将特征金字塔结构中的普通卷积更改为深度可分离卷积以

及在预测头部分引入 GIoU(广义并交比)改进定位损失函数计算。Ma 等^[49]提出一种轻量级网络模型 CornNet 来对玉米穗进行分类,通过减少卷积层和通道数改进主干网 VGG16 的结构,使用全局平均池化层代替全连接层实现模型轻量化,并使用了 SE 和 BN 来提高特征提取能力和防止梯度消失。

综上所述,在谷物穗部目标检测分类算法轻量化方面,模型主干网主要采用 MobileNet v2、MobileNet v3、YOLOX、AsymmNet 以及 VGG16 等网络,通过骨干网络改进、网络剪裁实现算法的轻量化;利用 PSA、CBAM、CA、SE 等注意力机制或改进 SPP 结构提高特征提取能力。上述基于轻量级深度学习方法的谷物穗部目标识别应用与主要性能指标如表 4 所示,其中模型检测精度最高达 98.56%,模型最小仅 0.42 MB,在相应硬件设备上运行的最短推理时间为 15 ms。

表 4 基于轻量级深度学习方法的谷物穗部目标识别应用成果

Tab. 4 Application results of grain ear target recognition based on lightweight deep learning method

对象	硬件	主干网	精度/%	模型大小/MB	参数量/M	推理时间/ms
麦穗 ^[43]	NVIDIA GPU Tesla P100	MobileNet v3	91.32	—	8.20	15.00
麦穗 ^[44]	NVIDIA GTX 1080Ti—12G	AsymmNet	94.40	9.00	—	40.00
麦穗 ^[46]	AMD 5900X CPU + NVIDIA GeForce RTX 3060 G	MobileNet v2	90.32	—	—	22.49
稻穗 ^[47]	NVIDIA Tesla V100 GPU	MobileNet v2	93.07	—	4.04	137.00
玉米花丝 ^[48]	AMD 5600X 6—Core CPU + NXIDIA GeForce RTX 3060 GPU	YOLOX—s	97.69	—	8.35	17.00
玉米穗 ^[49]	AMD Ryzen 7 5800H CPU + NVIDIA GeForce RTX 3060 GPU	VGG16	98.56	0.42	—	—

注:文献[44]、文献[47]进行了帧率(每秒处理的图像帧数,单位 fps)向推理时间的换算。

2.3 作物病虫害检测

农作物病虫害严重影响农作物的产量和品质,农作物病虫害识别由传统的人工识别、仪器辨识、基于机器学习的识别,已发展至基于深度学习技术的识别^[50]。为实现手机端检测植物病害,刘洋等^[51]采用了两种轻量级卷积神经网络 MobileNet 和 Inception v3 构建植物病害分类模型,采用迁移学习方法,MobileNet 更适合在手机端使用。Khan 等^[52]对柑橘 6 种不同疾病进行识别分类,基于增强后的数据集对 SqueezeNet^[53]和 MobileNetv2 两个轻量级模型进行训练,使用鲸鱼优化算法进行优化,SqueezeNet 模型优于 MobileNetv2。为实现水稻病害的快速、准确识别,卫雅娜等^[54]提出一种轻量化水稻病害识别方法,将 CBAM 引入 EfficientNet—B0 主干网中的 MBConv 模块,利用 Ghost 模块优化网络中的卷积层,降低网络的参数量和计算量,并使用 Adam 优化算法提高网络的收敛速度。Wang 等^[55]提出一种优化的轻量级 YOLOv5 模型用于检测和分类植物病害,主干网引入 GhostNet 结构

来减少计算量,加入 IASM(改进注意力子模块),并使用 WBF(加权边界框融合)进行后处理。谢家兴等^[56]针对荔枝病虫害图像的病斑分布区域广、面积大小不一等特点,在原 ShuffleNet v2 模型结构的基础上,采用 HDC(混合空洞卷积)、嵌入 ECA 模块并进行模型裁剪。为自动快速识别香蕉叶片疾病,Bhuiyan 等^[57]提出一种轻量级模型 BannaSqueezeNet,该模型以 SqueezeNet 为核心,采用贝叶斯优化技术确定最优超参。

综上所述,在农作物叶片病害实时检测算法的轻量化方面,主要使用了 MobileNet、ShuffleNet、EfficientNet、SqueezeNet、GhostNet 等轻量级网络,并在此基础上加入 CBAM、ECA 机制、GhostNet 结构模块、鲸鱼优化算法或贝叶斯算法等优化方法,从而提升病虫害识别的速度和准确性。上述基于轻量级深度学习方法的作物病虫害目标识别应用与主要性能指标如表 5 所示,模型检测精度最高达 99.04%,模型最小为 4.78 MB,参数量最小为 0.059 M,在相应硬件设备上运行的最短推理时间为 15 ms。

表5 基于轻量级深度学习方法的作物病虫害目标识别应用成果

Tab. 5 Application results of crop pest target recognition based on lightweight deep learning method

对象	硬件(训练+边缘部署)	主干网	精度/%	模型大小/MB	参数量/M	推理时间/ms
葡萄叶片 ^[51]	训练:NVIDIA TESLA K20 边缘部署:手机端	MobileNet	95.02	17.1	—	134
柑橘叶片与果实 ^[52]	训练:Intel Core i5, 4GB RAM, and 1 GB	SqueezeNet	96.00	—	—	—
水稻叶片与稻穗 ^[54]	训练:Intel i7-11700K + NVIDIA GeForce RTX 3080Ti	EfficientNet	95.63	—	4.4	—
多种植株叶片 ^[55]	训练:Intel Core i5-7200 + NVIDIA GeForce RTX 2070	GhostNet	92.57	17.8	—	15
荔枝叶片 ^[56]	训练:Intel(R)Core(TM)i7-6800K+GeForce GTX 1080Ti	ShuffleNet v2	99.04	—	0.059	—
香蕉叶片 ^[57]	—	SqueezeNet	96.25	4.78	—	1 784

3 存在问题与展望

3.1 存在问题

农作物目标检测模型轻量化的主要目的是期望在计算资源有限的农业场景边缘端实现实时推理计算,以提升果实采摘、病虫害识别分类以及作物表型检测等任务的效率和性能,研究重点主要集中在田间复杂光环境下目标检测、成簇聚集的小目标检测、遮挡情况下的目标监测、颜色与背景相近的目标检测、多尺度目标检测以及更微观的细粒度分类检测等方面。目前,轻量级深度学习网络在农作物目标检测应用上还存在数据集有限、数据集标注费工费时、模型泛化能力弱、模型检测精度与检测效率的平衡不均、模型的边缘部署应用不足等问题,亟需通过数据集优化、模型结构优化、迁移学习应用、边缘设备硬件加速等途径提升轻量级深度学习网络对农作物目标的检测性能。

3.2 展望

3.2.1 农业数据集扩增

数据集的数量、质量和多样性对目标检测模型的精度和泛化能力至关重要。农业领域的大型公共数据集数量相对较少,特别是标注信息丰富的数据集仍较为稀缺。农业场景环境复杂,针对数据集中包含噪声、失真、缺失等问题,国内外相关研究主要采取数据预处理操作以提高数据集质量,包括图像去噪、图像增强、图像配准、图像融合等。同时,数据扩增方法常用于增加数据的多样性和数量,即通过对原始数据进行旋转、缩放、翻转、平移等数据增强操作生成新的样本,从而提升模型的泛化能力和鲁棒性。近些年,有关农业方面目标检测的数据集也在不断发展,当前可用于目标识别的高质量公开农业数据集包括 Fruits360、plantVillage、CropDeep 和 DeepWeeds 等。另一方面,监督学习模型的训练需要标注后的高质量图像数据,

人工数据标注存在耗时长、成本高、标注精度受人为主观因素影响等问题,自监督学习方法可以通过从数据中自动生成目标标签来进行训练,消除了对数据标记的需求,是未来的发展方向。

3.2.2 模型结构优化

轻量级深度学习网络结构模块化搭建十分灵活,尤其是在特征提取的主干网络部分,充分吸取 MobileNet、ShuffleNet、EfficientNet、GhostNet 以及轻量化 YOLO 等系列的核心技术模块;同时,在模型结构简化易带来精准性损失方面采取多种措施,如增加 CBAM、SE、CA、ECA、PSA 等注意力机制优化算法,选择 CIoU、EIoU、GIoU、mIoU 等不同损失函数方法,以及特征融合网络层、检测头结构的优化改良,进一步平衡实时性与精准性。未来,在模型结构优化方面,按农业场景的特定需求自由搭建轻量级深度学习网络是基础,还可以应用模型剪枝、网络量化、低秩分解等方法,进一步减小轻量级深度学习网络算法的模型大小和计算复杂度,增加新的注意力机制以及各种网络结构优化算法,提高模型在农业场景中的实时性和资源利用率。

3.2.3 迁移学习应用

农业数据集质量不均衡,使许多目标检测算法的性能受到限制,采用迁移学习方法能够提高目标检测算法的效率和准确性,减少对大量标注数据的依赖。迁移学习方法的核心思想是将源领域的知识迁移到目标领域,利用源领域丰富的数据来提升目标领域数据较为稀缺情况下的模型性能,或将已有的模型参数迁移到新任务中提高模型的泛化能力和效率。因此,可以利用大量公开的高质量图像数据来训练一个通用的目标检测模型,将该模型迁移到农业数据集上进行微调,以适应农业场景下的特殊需求。迁移学习方法有望为轻量级深度学习网络算法的性能提升提供新的思

路和方法。

3.2.4 边缘硬件加速

农业场景中边缘端的目标检测需求不断增加,这对边缘设备在性能、内存和功率 3 方面的平衡上提出更高的要求,既要实时性高又要检测精度高。随着边缘设备硬件技术的不断进步,嵌入式设备的计算能力和存储容量的提升更便于轻量级深度学习模型的边缘部署应用。例如,可以利用图形处理单元(GPU)、张量处理单元(TPU)、专用集成电路(ASIC)等专用硬件加速器来加速卷积、池化等操作,从而提高目标检测的速度和效率。此外,还可以利用 FPGA 等可编程逻辑器件来实现定制化的硬件加速方案,并且根据硬件平台的特点和限制,对轻量级深度学习网络结构进行优化和适应。最终,硬件加速优化还需要与算法设计相结合,共同推动边缘端的轻量化发展。

参 考 文 献

- [1] Tian H, Wang T, Liu Y, et al. Computer vision technology in agricultural automation: A review [J]. *Information Processing in Agriculture*, 2020, 7(1): 1–19.
- [2] 宋怀波, 尚钰莹, 何东健. 果实目标深度学习识别技术研究进展[J]. 农业机械学报, 2023, 54(1): 1–19.
Song Huaibo, Shang Yuying, He Dongjian. Review on deep learning technology for fruit target recognition [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(1): 1–19.
- [3] Zaidi S S A, Ansari M S, Aslam A, et al. A survey of modern deep learning based object detection models [J]. *Digital Signal Processing*, 2022, 126: 103514.
- [4] Cao K, Liu Y, Meng G, et al. An overview on edge computing research [J]. *IEEE Access*, 2020, 8: 85714–85728.
- [5] Howard A G, Zhu M, Chen B, et al. MobileNets: Efficient convolutional neural networks for mobile vision applications [J]. *arXiv preprint arXiv*: 1704. 04861, 2017.
- [6] Sandler M, Howard A, Zhu M, et al. MobileNetv2: Inverted residuals and linear bottlenecks [C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 4510–4520.
- [7] Howard A, Sandler M, Chu G, et al. Searching for MobileNetv3 [C]. *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2019: 1314–1324.
- [8] Zhang X, Zhou X, Lin M, et al. ShuffleNet: An extremely efficient convolutional neural network for mobile devices [C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 6848–6856.
- [9] Ma N, Zhang X, Zheng H T, et al. ShuffleNet V2: Practical guidelines for efficient CNN architecture design [C]. *Proceedings of the European Conference on Computer Vision (ECCV)*, 2018: 116–131.
- [10] Tan M, Le Q. EfficientNet: Rethinking model scaling for convolutional neural networks [C]. *International Conference on Machine Learning*, 2019: 6105–6114.
- [11] Tan M, Le Q. EfficientNetv2: Smaller models and faster training [C]. *International Conference on Machine Learning*, 2021: 10096–10106.
- [12] 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.
- [13] Tang Y, Han K, Guo J, et al. GhostNetv2: Enhance cheap operation with long-range attention [J]. *Advances in Neural Information Processing Systems*, 2022, 35: 9969–9982.
- [14] 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.
- [15] Gou J, Yu B, Maybank S J, et al. Knowledge distillation: A survey [J]. *International Journal of Computer Vision*, 2021, 129: 1789–1819.
- [16] Adarsh P, Rathi P, Kumar M. YOLOv3—Tiny: Object detection and recognition using one stage improved model [C]. *2020 6th International Conference on Advanced Computing and Communication Systems (ICACCS)*. IEEE, 2020: 687–694.
- [17] Huang R, Pedoeem J, Chen C. YOLO—LITE: A real-time object detection algorithm optimized for non-GPU computers [C]. *2018 IEEE International Conference on Big Data (big data)*. IEEE, 2018: 2503–2510.
- [18] 张伏, 陈自均, 鲍若飞, 等. 基于改进型 YOLOv4—LITE 轻量级神经网络的密集圣女果识别[J]. 农业工程学报, 2021, 37(16): 270–278.
Zhang Fu, Chen Zijun, Bao Ruofei, et al. Recognition of dense cherry tomatoes based on improved YOLOv4—LITE lightweight neural network [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2021, 37(16): 270–278.
- [19] 杨坚, 钱振, 张燕军, 等. 采用改进 YOLOv4—tiny 的复杂环境下番茄实时识别[J]. 农业工程学报, 2022, 38(9): 215–221.
Yang Jian, Qian Zhen, Zhang Yanjun, et al. Real-time recognition of tomatoes in complex environments based on improved YOLOv4—tiny [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2022, 38(9): 215–221.
- [20] 曾特, 李思, 宋倩, 等. 轻量级番茄实时检测方法研究 [J]. 农业工程学报, 2022, 38(9): 215–221.

- and mobile deployment [J]. Computers and Electronics in Agriculture, 2023, 205: 107625.
- [21] Wang X, Wu Z, Jia M, et al. Lightweight SM—YOLOv5 tomato fruit detection algorithm for plant factory [J]. Sensors, 2023, 23(6): 3336.
- [22] Li T, Sun M, He Q, et al. Tomato recognition and location algorithm based on improved YOLOv5 [J]. Computers and Electronics in Agriculture, 2023, 208: 107759.
- [23] Ji J, Zhu X, Ma H, et al. Apple fruit recognition based on a deep learning algorithm using an improved lightweight network [J]. Applied Engineering in Agriculture, 2021, 37(1): 123–134.
- [24] Mirjalili S, Lewis A. The whale optimization algorithm [J]. Advances in Engineering Software, 2016, 95: 51–67.
- [25] 王卓, 王健, 王枭雄, 等. 基于改进 YOLOv4 的自然环境苹果轻量级检测方法[J]. 农业机械学报, 2022, 53(8): 294–302.
Wang Zhuo, Wang Jian, Wang Xiaoxiong, et al. Lightweight real-time apple detection method based on improved YOLOv4 [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53 (8): 294–302.
- [26] Zhang C, Kang F, Wang Y. An improved apple object detection method based on lightweight YOLOv4 in complex backgrounds [J]. Remote Sensing, 2022, 14(17): 4150.
- [27] Sun L, Hu G, Chen C, et al. Lightweight apple detection in complex orchards using YOLOV5—PRE [J]. Horticulturae, 2022, 8(12): 1169.
- [28] Li Z, Zhang X, Feng X, et al. Detection method of apple based on improved lightweight YOLOv5 [C]. Cognitive Systems and Information Processing: 6th International Conference, ICCSIP 2021.
- [29] 张震, 周俊, 江自真, 等. 基于改进 YOLOv7 轻量化模型的自然果园环境下苹果识别方法[J]. 农业机械学报, 2024, 55(3): 231–242, 262.
Zhang Zhen, Zhou Jun, Jiang Zizhen, et al. Lightweight apple recognition method in natural orchard environment based on improved YOLOv7 model [J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(3): 231–242, 262.
- [30] Zhang W, Liu Y, Chen K, et al. Lightweight fruit-detection algorithm for edge computing applications [J]. Frontiers in Plant Science, 2021, 12: 740936.
- [31] Zheng Z, Xiong J, Lin H, et al. A method of green citrus detection in natural environments using a deep convolutional neural network [J]. Frontiers in Plant Science, 2021, 12: 705737.
- [32] Lü S, Li R, Zhao Y, et al. Green citrus detection and counting in orchards based on YOLOv5—CS and AI edge system [J]. Sensors, 2022, 22(2): 576.
- [33] Chen J, Liu H, Zhang Y, et al. A multiscale lightweight and efficient model based on YOLOv7: Applied to citrus orchard [J]. Plants, 2022, 11 (23): 3260.
- [34] Huang M L, Wu Y S. GCS—YOLOV4—Tiny: A lightweight group convolution network for multi-stage fruit detection [J]. Mathematical Biosciences and Engineering, 2023, 20(1): 241–268.
- [35] Xu L, Wang Y, Shi X, et al. Real-time and accurate detection of citrus in complex scenes based on HPL—YOLOv4 [J]. Computers and Electronics in Agriculture, 2023, 205: 107590.
- [36] 王金鹏, 高凯, 姜洪喆, 等. 基于改进的轻量化卷积神经网络火龙果检测方法(英文)[J]. 农业工程学报, 2020, 36(20): 218–225.
Wang Jinpeng, Gao Kai, Jiang Hongzhe, et al. Method for detecting dragon fruit based on improved lightweight convolutional neural network [J]. Transactions of the Chinese Society of Agricultural Engineering, 2020, 36(20): 218–225.
- [37] Zhang Y, Yu J, Chen Y, et al. Real-time strawberry detection using deep neural networks on embedded system (RTSD-Net): An edge AI application [J]. Computers and Electronics in Agriculture, 2022, 192.
- [38] 汤泽政, 伍奕桦, 徐新明, 等. 基于改进 YOLOv7—Tiny 的成熟草莓识别模型研究[J]. 江西农业大学学报, 2023, 45(6): 1528–1542.
- [39] Liu B, Zhang Y, Wang J, et al. An improved lightweight network based on deep learning for grape recognition in unstructured environments [J]. Information Processing in Agriculture, 2024, 11 (2): 202–216.
- [40] Chen J, Ma A, Huang L, et al. GA-YOLO: A lightweight YOLO model for dense and occluded grape target detection [J]. Horticulturae, 2023, 9(4): 443.
- [41] 李茂, 肖洋轶, 宗望远, 等. 基于改进 YOLOv8 模型的轻量化板栗果实识别方法[J]. 农业工程学报, 2024, 40 (1): 209–217.
Li Mao, Xiao Yangyi, Zong Wangyuan, et al. Detecting chestnuts using improved lightweight YOLOv8 [J]. Transactions of the Chinese Society of Agricultural Engineering, 2024, 40(1): 209–217.
- [42] Sanaifar A, Guindo M L, Bakhshipour A, et al. Advancing precision agriculture: The potential of deep learning for cereal plant head detection [J]. Computers and Electronics in Agriculture, 2023, 209: 107875.
- [43] Bhagat S, Kokare M, Haswani V, et al. WheatNet-lite: A novel light weight network for wheat head detection [C]. Proceedings of the IEEE/CVF

- International Conference on Computer Vision, 2021: 1332—1341.
- [44] Dong Y, Liu Y, Kang H, et al. Lightweight and efficient neural network with SPSA attention for wheat ear detection [J]. PeerJ Computer Science, 2022, 8: e931.
- [45] Yang H, Shen Z, Zhao Y. AsymmNet: Towards ultralight convolution neural networks using asymmetrical bottlenecks [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 2339—2348.
- [46] Sun B, Zhou W, Zhu S, et al. Universal detection of curved rice panicles in complex environments using aerial images and improved YOLOv4 model [J]. Frontiers in Plant Science, 2022, 13: 1021398.
- [47] Khaki S, Safaei N, Pham H, et al. WheatNet: A lightweight convolutional neural network for high-throughput image-based wheat head detection and counting [J]. Neurocomputing, 2022, 489: 78—89.
- [48] 朱德利, 文瑞, 熊俊逸. 融合坐标注意力机制的轻量级玉米花丝检测[J]. 农业工程学报, 2023, 39(3): 145—153.
Zhu Deli, Wen Rui, Xiong Junyi. Lightweight corn silk detection network incorporating with coordinate attention mechanism [J]. Transactions of the Chinese Society of Agricultural Engineering, 2023, 39 (3): 145—153.
- [49] Ma X, Li Y, Wan L, et al. Classification of seed corn ears based on custom lightweight convolutional neural network and improved training strategies [J]. Engineering Applications of Artificial Intelligence, 2023, 120: 105936.
- [50] 翟肇裕, 曹益飞, 徐焕良, 等. 农作物病虫害识别关键技术研究综述[J]. 农业机械学报, 2021, 52(7): 1—18.
Zhai Zhaoyu, Cao Yifei, Xu Huanliang, et al. Review of key techniques for crop disease and pest detection [J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(7): 1—18.
- [51] 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.
- [52] Khan E, Rehman M Z U, Ahmed F, et al. Classification of diseases in citrus fruits using SqueezeNet [C]. 2021 International Conference on Applied and Engineering Mathematics (ICAEM). IEEE, 2021: 67—72.
- [53] Iandola F N, Han S, Moskewicz M W, et al. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0. 5 MB model size [J]. arXiv preprint arXiv: 1602. 07360, 2016.
- [54] 卫雅娜, 王志彬, 乔晓军, 等. 基于注意力机制与 EfficientNet 的轻量化水稻病害识别方法[J]. 中国农机化学报, 2022, 43(11): 172—181.
Wei Yana, Wang Zhibin, Qiao Xiaojun, et al. Lightweight rice disease identification method based on attention mechanism and EfficientNet [J]. Journal of Chinese Agricultural Mechanization, 2022, 43 (11): 172—181.
- [55] Wang H, Shang S, Wang D, et al. Plant disease detection and classification method based on the optimized lightweight YOLOv5 model [J]. Agriculture, 2022, 12(7): 931.
- [56] 谢家兴, 陈斌瀚, 彭家骏, 等. 基于改进 ShuffleNet V2 的荔枝叶片病虫害图像识别[J]. 果树学报, 2023, 40(5): 1024—1035.
- [57] Bhuiyan M A B, Abdullah H M, Arman S E, et al. BananaSqueezeNet: A very fast, lightweight convolutional neural network for diagnosis of three prominent banana leaf diseases [J]. Smart Agricultural Technology, 2023: 100214.

(上接第 252 页)

- [14] 彭书博, 陈兵旗, 李景彬, 等. 基于改进 YOLOv7 的果园行间导航线检测[J]. 农业工程学报, 2023, 39(16): 131—138.
Peng Shubo, Chen Bingqi, Li Jingbin, et al. Detection of the navigation line between lines in orchard using improved YOLOv7 [J]. Transactions of the Chinese Society of Agricultural Engineering, 2023, 39(16): 131—138.
- [15] Li X, Wang W, Wu L, et al. Generalized focal loss: Learning qualified and distributed bounding boxes for dense object detection [J]. Advances in Neural Information Processing Systems, 2020, 33: 21002—12.
- [16] Mehta S, Rastegari M. MobileViT: Light-weight, general-purpose, and mobile-friendly vision transformer [J]. arXiv preprint arXiv: 2110. 02178, 2021.
- [17] Sandler M, Howard A, Zhu M, et al. MobileNetV2: Inverted residuals and linear bottlenecks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510—4520.
- [18] Zheng Z, Wang P, Liu W, et al. Distance-IoU loss: Faster and better learning for bounding box regression [C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 12993—13000.
- [19] Zhang Y F, Ren W, Zhang Z, et al. Focal and efficient IoU loss for accurate bounding box regression [J]. Neurocomputing, 2022, 506: 146—157.
- [20] Gevorgyan Z. SIoU loss: More powerful learning for bounding box regression [J]. arXiv preprint arXiv: 2205. 12740, 2022.
- [21] Tong Z, Chen Y, Xu Z, et al. Wise-IoU: Bounding box regression loss with dynamic focusing mechanism [J]. arXiv preprint arXiv: 2301. 10051, 2023.