

# 基于改进 YOLOv8n 的轻量化柑橘成熟度检测<sup>①</sup>



肖 阳<sup>1</sup>, 项明宇<sup>1</sup>, 李 熹<sup>2</sup>

<sup>1</sup>(广西民族大学 电子信息学院, 南宁 530006)

<sup>2</sup>(广西民族大学 人工智能学院, 南宁 530006)

通信作者: 李 熹, E-mail: lixi@gxmzu.edu.cn

**摘 要:** 为了实现柑橘采摘的智能化, 果园环境中对柑橘快速而精准的识别成为关键. 针对现有目标检测算法对环境的适应缺陷和效率低下的问题, 提出一种基于 YOLOv8n 模型的轻量化柑橘成熟度检测算法 YOLOv8n-CMD (YOLOv8n citrus maturity detection). 首先, 优化 backbone 网络结构, 提高小目标检测能力; 其次, 添加 CBAM 注意力机制, 改善模型分类效果; 然后, 引入 Ghost 卷积, 将 YOLOv8 原模型中的颈部 C2f 模块与 Ghost 结合, 减少计算量和参数量; 最后使用 SimSPPF 模块代替原网络金字塔池化层, 提高模型检测效率. 实验结果表明: YOLOv8n-CMD 算法相较于原模型的模型参数量和计算量分别减少了 31.8% 和 7.4%, 精准度提高了 3.0%, 更适合果园环境下的柑橘检测研究.

**关键词:** 柑橘; 果园环境; 目标检测; 小目标; CBAM; Ghost; SimSPPF

引用格式: 肖阳, 项明宇, 李熹. 基于改进 YOLOv8n 的轻量化柑橘成熟度检测. 计算机系统应用, 2024, 33(11): 202-208. <http://www.c-s-a.org.cn/1003-3254/9693.html>

## Lightweight Citrus Maturity Detection Based on Improved YOLOv8n

XIAO Yang<sup>1</sup>, XIANG Ming-Yu<sup>1</sup>, LI Xi<sup>2</sup>

<sup>1</sup>(College of Electronic Information, Guangxi Minzu University, Nanning 530006, China)

<sup>2</sup>(School of Artificial Intelligence, Guangxi Minzu University, Nanning 530006, China)

**Abstract:** To achieve intelligent citrus picking, fast and accurate identification of citrus in the orchard environment becomes critical. Aiming at the defective adaptation of existing target detection algorithms to the environment and low efficiency, this study proposes a lightweight citrus maturity detection algorithm based on the YOLOv8n model, YOLOv8n-CMD (YOLOv8n citrus maturity detection). Firstly, the backbone network structure is optimized to improve the detection of small targets. Secondly, the CBAM attention mechanism is added to improve the classification effect of the model. Then, Ghost convolution is introduced, and the neck C2f module in the original YOLOv8 model is combined with Ghost to reduce the amount of computation and that of parameters. Finally, the SimSPPF module is used in place of the original pyramidal pooling layer to improve model detection efficiency. Experimental results show that the YOLOv8n-CMD algorithm reduces the number of parameters and computation by 31.8% and 7.4%, respectively, and improves the accuracy by 3.0%, which is more suitable for citrus detection research in the orchard environment.

**Key words:** citrus; orchard environment; target detection; small target; CBAM; Ghost; SimSPPF

柑橘是全球最重要的经济产物之一, 是世界第一  
大类水果, 也是我国南方栽培面积最广、经济地位最  
重要的果树<sup>[1]</sup>. 随着计算机硬件设备和人工智能技术的

快速发展, 柑橘的识别和采摘也走向了机械化、智能  
化的道路, 基于深度学习的目标检测算法在这一领域  
成为研究热点.

① 收稿时间: 2024-04-01; 修改时间: 2024-05-06, 2024-05-14; 采用时间: 2024-06-28; csa 在线出版时间: 2024-09-27  
CNKI 网络首发时间: 2024-09-30

目前目标检测方法大致分为两种,一种是基于卷积神经网络(CNN)的两阶段法,如R-CNN<sup>[2]</sup>、Fast R-CNN<sup>[3]</sup>、Faster R-CNN<sup>[4]</sup>等.另一种是通过单个网络直接预测目标类别和边界框的单阶段法,如SSD<sup>[5]</sup>和YOLO系列<sup>[6-9]</sup>.相较于两阶段法,单阶段法具备更简单的网络结构,检测速度快,更适合对速度要求较高的应用场景.

近年来,针对农产品检测方法的研究仍在持续,而单阶段法以其较强的实时性优势,受到更多研究者的关注.顾伟等<sup>[10]</sup>使用ResNet50替换SSD中的VGG16模型,提高对群体棉花籽的感知能力.薛月菊等<sup>[11]</sup>提出基于改进YOLOv2的未成熟芒果识别,提高模型对环境的抗干扰能力.Tian等<sup>[12]</sup>为了在复杂环境下实现不同生长阶段的苹果检测,将YOLOv3中的Darknet替换成DenseNet网络,极大提升了模型的检测效率.熊俊涛等<sup>[13]</sup>提出了Des-YOLOv3网络模型,实现柑橘采摘机器人的夜间工作.王晨等<sup>[14]</sup>基于YOLOv4网络,引入MobileNetV3并添加CBAM注意力机制,使模型能够更好地满足对仓储货物的检测.王梦妮等<sup>[15]</sup>基于YOLOv5s网络,替换金字塔池化层为ASPP,采用双向流动机制的BiFPN<sup>[16]</sup>,解决模型对茶叶嫩芽特征提取不足的缺点.张瑶等<sup>[17]</sup>基于YOLOv8网络,结合BiFormer双层路由注意力机制,降低图片噪声的影响,并且增加第4个检测头,最终实现水面小目标的高精度检测.

目前,在柑橘成熟度检测的研究中仍然存在果实遮挡、环境噪声干扰以及模型较大等问题,这可能导致模型对目标定位和分类困难,检测效率低下.针对上述问题,本文借助YOLOv8网络结构,充分利用模型浅层特征信息,并引入注意力机制,提高模型对目标感知力及检测效率,最后替换更加高效的特征提取模块,实现模型轻量化.

## 1 果园环境下柑橘数据集的搭建

### 1.1 柑橘图像的采集

为了更好地实现自然环境下对柑橘的检测,实验所需的数据集采集于南宁市西乡塘区双定镇.使用手机作为拍摄设备,拍摄时间为2023年的10月至2024年1月之间,包含柑橘的未成熟期、着色期和成熟期,并在阴天和晴天两种不同光照条件下进行拍摄,以帮助模型适应不同的光照和成熟度条件.采集的数据效果如图1.



图1 数据采集效果

### 1.2 柑橘图像标注与预处理

在图像采集后,对其进行筛选和清理,删掉一些重复、过度模糊等不符合要求的样本,保证训练数据的质量和有效性,最终确定图像2113张,果实数量约35000个.使用开源工具Labelimg对图像中的柑橘绘制最小外接矩阵进行标注,图像类别属性为未成熟(unrip)、已成熟(ripe).为了避免标注不准确和模糊的目标影响到模型的质量和性能,对于遮挡程度超过70%和边缘裸露少于30%的柑橘不予标注.

将柑橘数据集以8:2比例划分为训练集和验证集.训练时,采用Mosaic数据增强方法,随机选取4张图片进行翻转、缩放、色域变化等操作,再将4张图片拼接成一张,新的图片依然包含标注的所有信息,有效地提高模型的性能和鲁棒性.需要注意的是,YOLOv8在对最后10个epoch训练时自动关闭Mosaic数据增强.

## 2 YOLOv8n-CMD模型建立

YOLOv8的网络结构主要由3部分组成:主干网络(backbone)、颈部(neck)和头部(head).

Backbone部分主要是对图像的特征提取.该部分使用Darknet-53网络结构,由CBS模块、C2f模块和SPPF模块组成.相比于YOLOv5模型,YOLOv8引入梯度流信息更丰富的C2f模块替换C3模块,C2f含有更多的跳层连接和额外的split操作,能够更好地传递特征信息.

颈部结构 neck 也称为特征融合层. 通过融合来自主干网络的多层特征图, 捕捉不同层次的语义信息. YOLOv8 采用 PANet<sup>[18]</sup>双向通路网络思想, 引入自下而上的路径并结合下采样操作, 融合邻层的特征图信息, 保留图像的空间信息.

头部是网络结构中负责预测目标类别和位置的部分. YOLOv8 采用解耦头 (decoupled head) 将分类和定位任务解耦, 引入无锚框 (anchor-free) 方法, 简化了目标检测流程.

本文以 YOLOv8n 为基础模型做出以下改进. 通过调整主干网络结构, 充分利用浅层信息, 提高小目标检测能力; 添加 CBAM 注意力机制, 减轻复杂光照影响, 提高模型准确率; 使用 C2fGhost 替换颈部的 C2f 模块, 减少模型参数数量和计算量; 最后引入金字塔池化层 SimSPPF, 提高模型检测效率, 最终得到适应果园环境下的柑橘成熟度检测模型 YOLOv8n-CMD. 模型网络结构如图 2 所示.

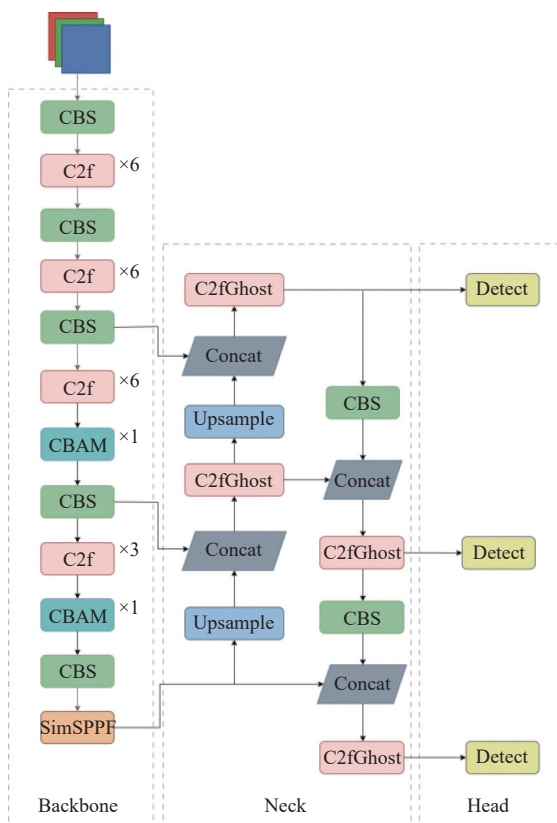


图 2 YOLOv8n-CMD 网络结构

### 2.1 主干网络的改进

在自然果园环境下, 柑橘果实重叠、枝叶遮挡的

情况十分常见, 此外果实初期较小且颜色与背景极度相似, 使得模型漏检错检测的几率增大. YOLOv8 模型通过多尺度融合技术将不同尺度的特征信息进行融合的方法, 提高目标检测任务的性能和鲁棒性. 然而随着模型深度的增加, 特征图数量增多, 大感受野的特征图在提供上下文信息的同时也引入了更多的环境噪声, 而对模型性能提升甚微, 造成计算资源的大量浪费. 针对此问题, 本文对主干网络 backbone 部分进行了优化.

首先在第 1 个 CBS 模块后添加了 C2f 层, 加强局部上下文信息的提取; 其次删除了最后一个 C2f 模块, 在降低背景噪声影响的同时, 缩小了模型大小; 最后, 将 C2f 的 block 数从 3-6-6-3 改为 6-6-6-3, 以更低的计算代价提高小目标检测能力.

在柑橘目标检测任务中对于低级特征的判别对小目标检测至关重要<sup>[19]</sup>. 低级特征为模型提供柑橘目标的边缘轮廓、表面纹理和颜色分布等细节信息, 模型可以更好地识别目标, 并从背景中区分出来. 因此, 本文在特征融合阶段, 将 1/16 和 1/32 原图的尺度特征选择于 CBS 之后, 充分利用低级特征的边缘信息, 提高目标的定位和分类效果. 改进前后对比如图 3 所示. 实验证明, 优化后的网络模型对柑橘目标检测的性能提升明显.

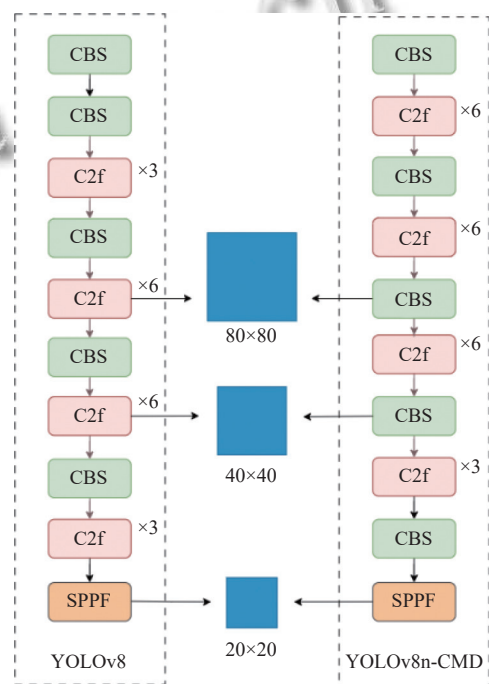


图 3 Backbone 改进前后对比

### 2.2 C2fGhost 模块

在自然果园环境中,地形复杂性对柑橘检测带来了一定挑战.同时,较大的模型会对移动设备的性能造成负担,导致检测不够灵活.为了解决此问题,本文引入 Ghost<sup>[20]</sup>模块,有效减少模型参数量,降低模型复杂度.

Ghost 卷积原理如图 4 所示.传统的卷积神经网络在对图片进行特征提取时,会产生大量的冗余信息,但这些信息又是目标检测不可缺少的部分.为了减少模型参数量和计算量, Ghost 模块先使用普通卷积获得部分特征图,然后采用更廉价的线性变换 cheap operation 生成更多的特征图信息,最后将全部特征图在通道维度上进行拼接,得到最终的输出特征图.

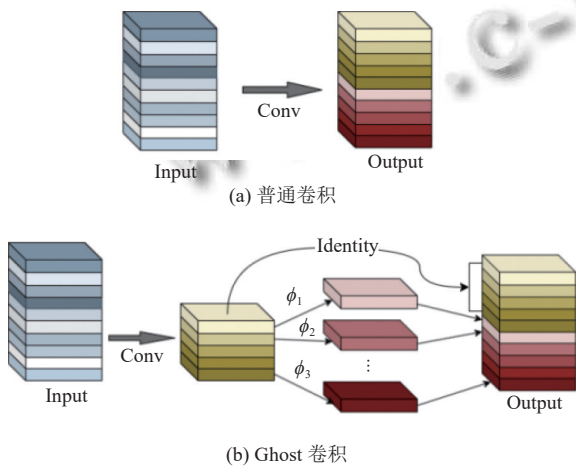


图 4 Ghost 卷积原理

假设输入的特征图尺寸为  $h \times w \times c$ , 输出特征图尺寸为  $h' \times w' \times n$ , 卷积核大小为  $k$ , 线性变换卷积核大小为  $d$ , 经过  $s$  次线性变换, 则加速比  $r_s$  和压缩比  $r_c$  如式 (1)、式 (2). 其中  $n/s$  是 Ghost 模块中卷积部分的输出通道数,  $s-1$  是除去恒等映射后的线性变换.

$$r_s = \frac{n \cdot h' \cdot w' \cdot c \cdot k \cdot k}{\frac{n}{s} \cdot h' \cdot w' \cdot c \cdot k \cdot k + (s-1) \cdot \frac{n}{s} \cdot h' \cdot w' \cdot d \cdot d} = \frac{c \cdot k \cdot k}{\frac{n}{s} \cdot c \cdot k \cdot k + (s-1) \cdot \frac{n}{s} \cdot d \cdot d} \approx \frac{s \cdot c}{s+c-1} \approx s \quad (1)$$

$$r_c = \frac{n \cdot c \cdot k \cdot k}{\frac{n}{s} \cdot c \cdot k \cdot k + (s-1) \cdot \frac{n}{s} \cdot d \cdot d} \approx \frac{s \cdot c}{s+c-1} \approx s \quad (2)$$

由于在网络设计中,  $k$  和  $d$  的取值相对接近, 且  $s$  会远大于  $c$ , 因此可知 Ghost 卷积的计算量和参数量约为普通卷积的  $1/s$ .

GhostBottleneck 模块是将 Ghost 融入 Bottleneck 模块形成. 如图 5, 当卷积步长  $stride=1$  时, 先经过两层 Ghost 卷积处理, 然后与输入特征图进行 Add 融合操作. 当卷积步长  $stride=2$  时, 在两个 Ghost 模块中间多加了一层  $stride=2$  的深度可分离卷积. 最后将 C2f 模块中所有的 Bottleneck 模块替换成 GhostBottleneck, 得到全新的模块 C2fGhost. C2fGhost 模块结构如图 6 所示.

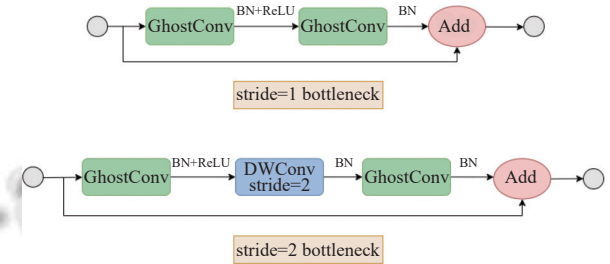


图 5 GhostBottleneck 模块




图 6 C2fGhost 模块

### 2.3 注意力机制 CBAM

由于光照强度的不同使得果实的颜色产生一定的差异, 从而导致模型在果实的定位偏差和分类误判而影响精度. 因此, 本文引入双通道注意力 CBAM 模块, 模块结构如图 7 所示.




图 7 CBAM 模块

该模块由通道注意力模块 (CAM) 和空间注意力模块 (SAM) 串联构成. CAM 通过对不同通道进行池化和全连接网络操作, 得到通道间的相关权重, 帮助网络更好地利用色彩信息, 提高分类判断能力. 而 SAM 通过在维度上应用卷积层学习特征图每个空间位置的权重, 使模型更加关注感兴趣的区域, 提高目标框的准确性和精度.

通过引入 CBAM 模块, 模型可以更好地适应光照强度变化引起的颜色差异, 从而减小果实定位偏差和

分类误判的影响,提高模型的整体精度。

### 2.4 金字塔池化层 SimSPPF

SPP (spatial pyramid pooling)<sup>[21]</sup>是一种将局部特征映射到不同维度空间并融合的池化方法,避免多尺度特征融合阶段出现信息丢失等问题。YOLOv5中使用的SPPF是将SPP中并行连接的池化操作改为串行连接,保持性能不变的情况下,提高了运算效率。

本文引入的SimSPPF是将SPPF中CBS模块的激活函数SiLU替换成函数形式更简单的ReLU而得,效率更为高效。SimSPPF模块结构如图8。该模块首先进行卷积模块操作对输入特征图进行压缩,然后经过3个相同的MaxPool2D池化,以串联叠加的方式从中得到不同感受野信息的特征图,然后将4个维度的特征图进行Concat融合,最后再进行一次卷积升维。

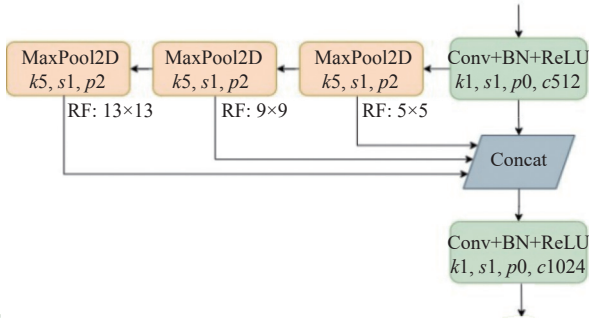


图8 SimSPPF 模块结构

## 3 实验结果与分析

### 3.1 实验环境和评价标准

本文实验模型训练于系统 Ubuntu 20.04 云服务器。平台配置为: 12v CPU Intel(R) Xeon(R) Platinum 8255C CPU@2.50 GHz, 43 GB 运行内存; RTX 3080 显卡, 10 GB 显存。Python 版本为 Python 3.8, 深度学习框架 PyTorch 1.11.0, 配备 CUDA 11.3 加速模型训练。

模型训练过程中,输入图片大小为 640×640, 优化器选用 AdamW, 学习率 (learning rate) 设置为 0.001667,

动量因子 (momentum) 设置为 0.9, 批量大小 (batch size) 设置为 16, 迭代次数 (epoch) 设置为 250。

为了更好地评估模型性能了解模型优劣, 本文使用精确率 (P)、召回率 (R)、平均精度均值 (mAP)、检测速度 (FPS)、参数量 (Params)、每秒浮点运算次数 (GFLOPs) 作为性能指标。

P 表示被分类器正确预测为正例的样本数占有被分类器预测为正例的样本数的比例。R 表示被分类器正确预测为正例的样本数占有真正正例的样本数的比例。精确率和召回率表达式如下。

$$P = \frac{TP}{TP + FP} \tag{3}$$

$$R = \frac{TP}{TP + FN} \tag{4}$$

其中, TP (true positive) 表示被分类器正确预测为正例的样本数, FP (false positive) 表示被分类器错误地预测为正例的样本数。FN (false negative) 表示被分类器错误地预测为负例的样本数。

将计算后的 P 和 R 分别当作纵坐标和横坐标画图, 绘制出 P-R 曲线, 而 mAP 是将各类别的 P-R 曲线进行积分后取平均所得。

$$mAP = \frac{1}{M} \sum_{k=1}^M \int_0^1 PRdR \tag{5}$$

FPS 值反映模型在处理图像时每秒能够完成的推理次数, 是衡量模型的推理速度和实时性能的指标。Params 和 GFLOPs 分别表示模型参数量和计算量大小, 是衡量模型复杂度和计算资源需求的重要指标。

### 3.2 消融实验

为了验证改进后各模块对模型性能的提升, 本文进行了一系列的实验, 如表 1 所示。其中“√”表示使用改进, “—”表示不使用改进, mAP50 是模型在置信度阈值为 50% 时的平均精度, mAP50-90 是置信度阈值在 50%–90% 之间的平均精度。

表 1 消融实验结果

Backbone改进	C2fGhost	SimSPPF	CBAM	参数量	GFLOPs	召回率R	mAP50	mAP50-90	FPS
—	—	—	—	3006038	8.1	0.735	0.814	0.599	91.62
√	—	—	—	2472758	8.3	0.741	0.826	0.617	89.78
√	√	—	—	2030014	7.4	0.736	0.829	0.62	88.52
√	√	√	—	2030398	7.4	0.743	0.835	0.621	103.09
√	√	√	√	2051266	7.5	0.759	0.844	0.628	90.12

分析实验结果可知, 改进 backbone 后的网络模型其计算量略微增加, 但参数量大量减少, 召回率、mAP50

和 mAP50-90 分别增长 1.5%、1.2%、1.8%。说明浅层的特征提取对柑橘的检测影响较大, 而 backbone 中增

加的 C2f 模块和加强低级特征的提取, 极大地提升了目标的定位和分类效果. 在 C2fGhost 加入后, 模型参数量和计算量均有所下降, 然而  $mAP$  并没降低, 证实了使用 cheap operation 操作代替普通卷积的 Ghost 模块的高效性. 而添加 SimSPPF 后, 参数量几乎不变的情况下, FPS 明显提升,  $mAP50$  增加了 0.6%, 召回率提升了 0.7%, 增强了模型的检测效率. 最后在 CBAM

引入后,  $mAP50$  和  $mAP50-90$  分别提高 0.9%、0.7%, 模型精度显著提升.

### 3.3 不同模型的对比实验

为了进一步验证 YOLOv8n-CMD 模型的优越性, 本文分别于 YOLOv3-tiny、YOLOv5、YOLOv6、YOLOv7 和原模型 YOLOv8 进行对比. 实验数据均使用自制的果园柑橘数据集, 实验结果如表 2 所示.

表 2 不同模型的检测结果对比

模型	参数量	GFLOPs	精准率 $P$	召回率 $R$	$mAP50$	$mAP50-90$	FPS
YOLOv3-tiny	12128692	18.9	0.81	0.702	0.78	0.562	107.53
YOLOv5	2503334	7.1	0.829	0.721	0.821	0.604	84.75
YOLOv6	4233942	11.8	0.812	0.74	0.823	0.608	<b>111.11</b>
YOLOv7	8106134	21.1	0.826	0.742	0.827	0.621	87.68
YOLOv8	3006038	8.1	0.806	0.735	0.814	0.599	92.72
YOLOv8n-CMD	<b>2051266</b>	7.5	<b>0.829</b>	<b>0.759</b>	<b>0.844</b>	<b>0.628</b>	90.12

改进后的 YOLOv8n-CMD 模型相较于原模型,  $mAP50$ 、 $mAP50-90$ 、精准率和召回率分别提升了 3.0%、2.9%、2.3%、2.4%, 参数量和计算量分别减少

了 31.8% 和 7.4%, FPS 提高了 10. YOLOv8 与 YOLOv8n-CMD 的检测效果对比如图 9, 改进后的模型对小目标精度提升明显, 漏检错检的情况也有了一定的改善.




图 9 YOLOv8n-CMD 与 YOLOv8 检测效果对比

与 YOLOv3-tiny、YOLOv5、YOLOv6、YOLOv7 相比, 在  $mAP50$  上分别提升了 6.4%、2.3%、2.1%、

1.7%, 参数量分别减少了 83.1%、18.1%、51.6%、74.7%. YOLOv8n-CMD 模型除在计算量上比 YOLOv5

略高, FPS 略低于 YOLOv6 以外, 其参数量、精准度、召回率、*mAP50* 性能参数均为最佳. 综上所述, 本文提出的模型与目前主流模型相比, 具备更高的准确率的同时模型更加地轻量化, 验证了算法的有效性.

#### 4 结论

本文提出一种基于改进 YOLOv8n 的轻量化柑橘成熟度检测算法, 通过优化 backbone 部分提高模型对柑橘的感知能力, 引入 Ghost 技术并与 C2f 模块融合以减小模型大小, 添加 CBAM 注意力机制降低环境噪声干扰, 并采用 SimSPPF 算法来加速模型检测效率. 在柑橘成熟度检测任务上进行实验验证, 结果显示该算法相比原模型 *mAP* 提高了 3.0%, 同时参数量和计算量分别减少了 31.8% 和 7.4%, 模型检测速度达 90.12 f/s 完全满足柑橘的实时性检测任务, 为果园管理和优化提供有力支持.

#### 参考文献

- 郭文武, 叶俊丽, 邓秀新. 新中国果树科学研究 70 年——柑橘. 果树学报, 2019, 36(10): 1264–1272.
- Girshick R, Donahue J, Darrell T, *et al.* Rich feature hierarchies for accurate object detection and semantic segmentation. Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition. Columbus: IEEE, 2014. 580–587. [doi: 10.1109/cvpr.2014.81]
- Girshick R. Fast R-CNN. Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV). Santiago: IEEE, 2015. 1440–1448.
- Ren SQ, He KM, Girshick R, *et al.* Faster R-CNN: Towards real-time object detection with region proposal networks. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137–1149.
- Liu W, Anguelov D, Erhan D, *et al.* SSD: Single shot multibox detector. Proceedings of the 14th European Conference on Computer Vision (ECCV 2016). Amsterdam: Springer, 2016. 21–37. [doi: 10.1007/978-3-319-46448-0\_2]
- Redmon J, Divvala S, Girshick R, *et al.* You only look once: Unified, real-time object detection. Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016. 779–788. [doi: 10.1109/cvpr.2016.91]
- Redmon J, Farhadi A. YOLO9000: Better, faster, stronger. Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu: IEEE, 2017. 6517–6525. [doi: 10.1109/cvpr.2017.690]
- Redmon J, Farhadi A. YOLOv3: An incremental improvement. arXiv:1804.02767, 2018.
- Wang CY, Bochkovskiy A, Liao HYM. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. arXiv:2207.02696, 2022.
- 顾伟, 王巧华, 李庆旭, 等. 基于改进 SSD 的棉种破损检测. 华中农业大学报, 2021, 40(3): 278–285.
- 薛月菊, 黄宁, 涂淑琴, 等. 未成熟芒果的改进 YOLOv2 识别方法. 农业工程学报, 2018, 34(7): 173–179.
- Tian YN, Yang GD, Wang Z, *et al.* Apple detection during different growth stages in orchards using the improved YOLO-V3 model. Computers and Electronics in Agriculture, 2019, 157: 417–426. [doi: 10.1016/j.compag.2019.01.012]
- 熊俊涛, 郑镇辉, 梁嘉恩, 等. 基于改进 YOLOv3 网络的夜间环境柑橘识别方法. 农业机械学报, 2020, 51(4): 199–206.
- 王晨, 袁庆霓, 白欢, 等. 面向仓储货物的轻量化目标检测算法. 激光与光电子学进展, 2022, 59(24): 2410007.
- 王梦妮, 顾寄南, 王化佳, 等. 基于改进 YOLOv5s 模型的茶叶嫩芽识别方法. 农业工程学报, 2023, 39(12): 150–157.
- Tan MX, Pang RM, Le QV. EfficientDet: Scalable and efficient object detection. Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 2020. 10778–10787. [doi: 10.1109/cvpr42600.2020.01079]
- 张瑶, 陈姚节. 改进 YOLOv8 的水面小目标检测算法. 计算机系统应用, 2024, 33(4): 152–161. [doi: 10.15888/j.cnki.csa.009445]
- Liu S, Qi L, Qin H, *et al.* Path aggregation network for instance segmentation. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 8759–8768. [doi: 10.1109/cvpr.2018.00913]
- 刘建政, 梁鸿, 崔学荣, 等. 融入特征融合与特征增强的 SSD 目标检测. 计算机工程与应用, 2022, 58(11): 150–159.
- Han K, Wang YH, Tian Q, *et al.* GhostNet: More features from cheap operations. Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020. 1577–1586.
- He KM, Zhang XY, Ren SQ, *et al.* Spatial pyramid pooling in deep convolutional networks for visual recognition. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904–1916. [doi: 10.1109/TPAMI.2015.2389824]

(校对责编: 张重毅)