

李 恒, 南新元, 高丙朋, 等. 一种基于 GhostNet 的绿色类圆果实识别方法[J]. 江苏农业学报, 2023, 39(3): 724-731.
doi: 10.3969/j.issn.1000-4440.2023.03.013

一种基于 GhostNet 的绿色类圆果实识别方法

李 恒, 南新元, 高丙朋, 马志钢

(新疆大学电气工程学院/西门子实验室, 新疆 乌鲁木齐 830017)

摘要: 为实现果园实际环境中绿色类圆果实的识别, 研究了基于单阶段目标检测网络的绿色类圆果实识别方法。本研究对比 4 种不同轻量化卷积网络模型, 以 GhostNet 作为本研究网络的主干特征提取网络, 将提取到的特征信息利用复杂双向多尺度融合网络进行融合, 最后以改进后的 YOLO_Head 作为预测头, 建立适合本研究的目标检测网络。结果表明, 在果园背景下本研究构建的目标检测网络对绿色类圆果实的均值平均精度达到 96.8%, 每张图片检测所用的时间为 37 ms, 网络内存占用大小为 11.8 M, 实现了对绿色类圆果实的快速、准确识别, 能够为早期果树的产量预估、病虫害识别提供技术支撑。

关键词: 目标检测; 轻量化卷积网络; 特征融合; 绿色类圆果实

中图分类号: TP391.41 **文献标识码:** A **文章编号:** 1000-4440(2023)03-0724-08

A green round-like fruits identification method based on GhostNet

LI Heng, NAN Xin-yuan, GAO Bing-peng, MA Zhi-gang

(School of Electrical Engineering, Xinjiang University/Siemens Laboratories, Urumqi 830017, China)

Abstract: In order to realize the recognition of green round-like fruits in the actual environment of orchards, the recognition method of green round-like fruits based on one-stage object detection network was studied. In this study, four different lightweight convolutional network models were compared. GhostNet was used as the backbone feature extraction network of this research network. The extracted feature information was fused by bidirectional feature pyramid network (BiFPN). Finally, the improved YOLO_Head was used as the prediction head to establish a target detection network suitable for this study. The experimental results showed that the final detection accuracy of the green round-like fruits in the object detection network constructed in the context of orchard reached 96.8%, the detection speed of a single image reached 37 ms, and the memory occupancy size of the network was 11.8 M, which realized the rapid and accurate identification of green round-like fruits, and could provide technical support for the yield estimation and disease and pest identification of early fruit trees.

Key words: object detection; lightweight convolutional networks; feature fusion; green round-like fruits

中国是传统农业大国, 水果种植面积、产量、消费量早已位居世界第一, 然而中国的水果种植业仍以人力为主, 自动化、机械化水平与发达国家相比存在一定差距。近年来为了应对中国人口红利的衰

减, 顺应国家提出的数字农业战略, 将机器视觉与农业相结合成为国内学者研究的关注点。利用机器视觉可以更好地实现早期果树的产量预估、果树病虫害的早期识别并及时进行防治、实现成熟果实的精准采摘等^[1-3]。此外, 多数果树果实在生长阶段会具备绿色、类圆特征, 因此对绿色类圆果实精准识别是非常有研究价值的。

然而在实际环境中, 绿色类圆果实与果园背景相近, 且叶片、枝干遮挡果实、果实相互重叠遮挡, 给绿

收稿日期: 2022-07-12

基金项目: 国家自然科学基金项目 (61863033)

作者简介: 李 恒 (1997-), 男, 新疆喀什人, 硕士研究生, 主要从事计算机视觉研究。(E-mail) 1344166355@qq.com

通讯作者: 南新元, (E-mail) xynan@xju.edu.cn

色类圆果实的识别造成一定的影响^[4-6]。目前国内外相关研究为上述识别过程中存在的难点提供了部分解决办法。在传统机器学习目标检测算法方面,Bansal 等^[7]应用快速傅里叶变换(FFT)对正常环境下的绿色柑橘进行识别,在构建的数据集上达到 82.2% 的识别准确率。卢军等^[8]利用类圆果实在自然光下图像具有环形光照分布的轮廓特征,将 Hough 变换与该轮廓特征及局部二值模式(LBP)纹理特征进行结合,最终进行圆拟合,该方法的果实识别召回率达到 82.3%,然而该方法只适用于正常光照条件下,不能对复杂环境中的果树果实进行精准识别。马翠花等^[9]利用无监督的显著性检测方法密集稀疏重构(DSR),完成未成熟的绿色番茄的检测任务,最终识别率达到 77.6%,然而该研究存在强光下漏检率高、误检率高的缺陷。谢忠红等^[10]改进 Hough 变换,提出类圆果实检测方法,但精度低且存在误检漏检。Liu 等^[11]利用颜色与形状特征检测苹果,网络召回率达到 85.0%,但存在鲁棒性较差问题。与传统方法相比,现阶段深度卷积神经网络不局限于表面特征,以更高维的视角对特征进行全面学习,充分挖掘检测目标的特征信息,从而更好地满足更精准的识别要求。李硕等^[12]在 ResNet50 网络中引入金字塔结构及遮挡补偿机制,最终实现了果粒排列密集相互遮挡的葡萄果实检测。刘芳等^[13]以 Darknet-20 网络为基础,引入融合多尺度检测模块,重构检测网络,最终利用采摘试验实现了对番茄果实的识别。岳有军等^[14]利用级联卷积神经网络研究番茄果实的检测问题,实现番茄的快速检测。贾伟宽等^[15]对 Transformer 结构进行优化,并结合前馈神经网络(FFN)结构构建目标检测网络,对绿色苹果、柿子进行识别,最终识别精度分别达到 93.27%、91.35%。上述方法仅针对某种特定果实构建网络进行检测,并没有某个网络可以对不同的绿色类圆果实进行识别,网络的泛化性、普适性还有待提升。

综上所述,本研究拟构建目标检测网络对多类绿色类圆果实进行检测,在提升网络检测精度及速度的同时,提高网络的泛化性、适用性。本研究拟借助 GhostNet 网络,通过引入复杂多向特征融合网络及改进后的 YOLO_Head,提出基于 GhostNet 的绿色类圆果实检测网络,实现对自然环境下绿色类圆果实的快速精确检测,以期为早期果实计数、果实病虫害识别、绿色类圆果实采摘等提供参考。

1 材料与方法

1.1 目标检测网络

现阶段国内外学者用来构建检测网络的方法总体上可分为两类(图 1):一类是基于区域进行提名的两阶段检测网络,如 RCNN^[16-17]系列网络,这类网络先生成区域候选框,再通过卷积神经网络进行分类、回归修正以达到预测目的;另一类是直接端到端的单阶段目标检测网络,如 YOLO^[18-19]系列、SDD^[20]系列网络,此类网络不需要生成候选框,而是直接利用网络提取到的检测对象特征直接进行预测。2 类方法各有优劣,两阶段检测网络因为要生成候选框所以检测速度较慢,却能更好地保证检测精度,而单阶段目标检测网络恰恰相反,有着更快的检测速度,但检测精度低于两阶段网络。

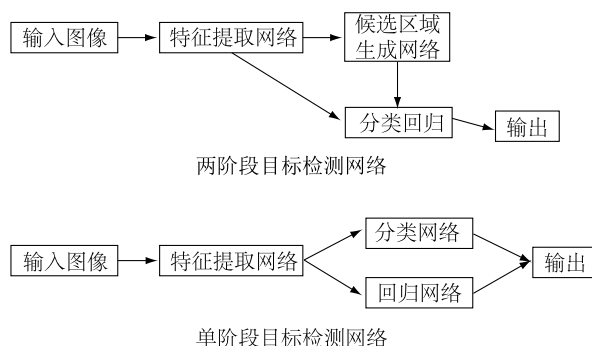


图 1 目标检测网络构建方法

Fig.1 Construction method of object detection network

因此,为了快速、准确地实现绿色类圆果实的检测,本研究构建端到端的单阶段目标检测网络,在网络中添加加权特征融合网络并利用改进后的 YOLO_Head 同时进行分类和回归,在实现快速检测的同时保证网络的检测精度。

1.2 本研究网络构建

1.2.1 轻量化卷积网络 卷积神经网络一经提出就引起各国研究者的广泛关注,目标检测网络方面的学者将其引入检测识别任务,然而大多数学者都在考虑如何提升网络性能,提高网络的识别准确性,这就导致卷积神经网络的深度越来越深、参数越来越多,然而却忽视了现实环境中普通计算机的算力、空间存储有限,很难在一般的硬件及嵌入式设备上进行检测任务,不利于目标检测在现实生活中的应用。基于此谷歌实验室提出 InceptionNet,首次提及卷积网络轻量化概念,后续学者参考 InceptionNet 提出并构建了基

于不同方法的轻量化卷积网络模型^[21],如 SqueezeNet,利用剪枝、量化、张量分解、知识蒸馏等方法压缩重构模型;MobileNet、ShuffleNet 使用较小卷积核,使网络结构更加紧凑,达到轻量化目的。

GhostNet 的构建方式则不同于上述轻量化卷积网络,相较于其他网络轻量化方法,GhostNet 将关注点放在了卷积之后生成的大量冗余特征图上,这些冗余特征图的作用是对检测目标主要特征图进行补充,保证网络对检测对象有更全面、充分的认识,然而在实际检测任务中,此类冗余特征图却仅能发挥很小的作用,但生成这些冗余图却需要消耗计算机大量算力,如此一来,既浪费计算机的算力,也不能更好地帮助网络提升检测任务精度。基于此,

GhostNet 构建了 Ghost 模块,利用 Ghost 模块以更快、更节省计算机算力的方式来生成冗余图。

Ghost 模块提取检测目标特征过程如图 2 显示,其操作过程可以分为 2 部分,第一部分操作与多数卷积神经网络相似,利用给定大小的卷积核(卷积核大小可随意设置,而不是仅局限于大小为 1 的卷积核)对输入图像进行操作,获取检测对象各个通道的特征图;第二部分操作时 Ghost 模块并没有直接继续利用卷积核对已有多通道特征图直接进行卷积,而是利用深度卷积(图 3)分别对每个单一通道进行卷积来获取大量冗余的特征图;最后通过拼接 2 部分获得的特征图并不断堆叠 Ghost 模块,即可搭建任意层数的轻量级 GhostNet,更便捷、高效地提取待检测目标的特征。

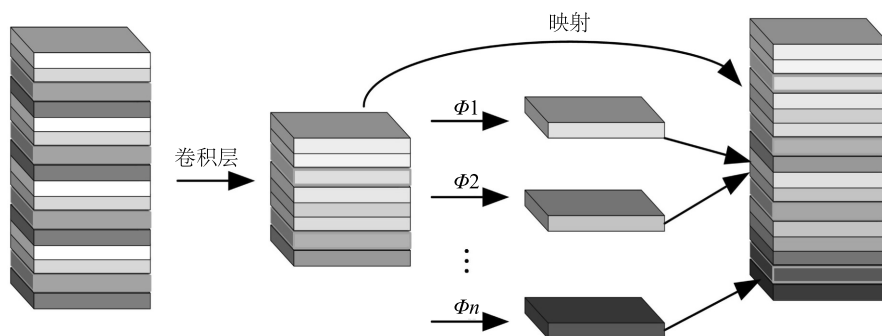


图 2 Ghost 模块

Fig.2 Ghost module

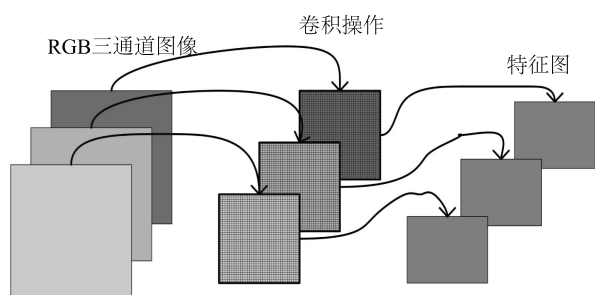


图 3 深度卷积

Fig.3 Deep convolution


1.2.2 特征融合网络 为了更好地利用特征提取网络提取出的特征图,对检测目标特征进行更全面的学习,需要对从不同尺度图像中提取的目标对象特征图进行融合。

早期的目标检测网络并没有特征融合的概念,无论是单阶段还是双阶段目标检测网络都只是在最后一次卷积操作提取特征图后直接接检测头进行预测,可想而知,这种用单一的特征图直接表示检测对

象的方式并不能高效、全面地帮助网络学习,也不利于网络的检测精度。因此,后期的学者在构建目标检测网络时开始关注每次特征提取后的特征图(图 4),利用不同尺度的特征图直接组成或进行融合后组成特征金字塔,从而更好地完成目标检测任务,获得更准确的检测结果。

图 5 显示,复杂双向多尺度融合网络(BiFPN)是在特征金字塔的基础上既添加了自顶向下通道传递高层特征进行融合,又加入自底向上通道融合底层特征信息,此外在进行融合时并不是像传统特征融合一样简单地对特征图进行叠加、相加、拼接操作,而是通过计算不同尺度特征图在检测任务中占据的权重完成特征信息的融合。

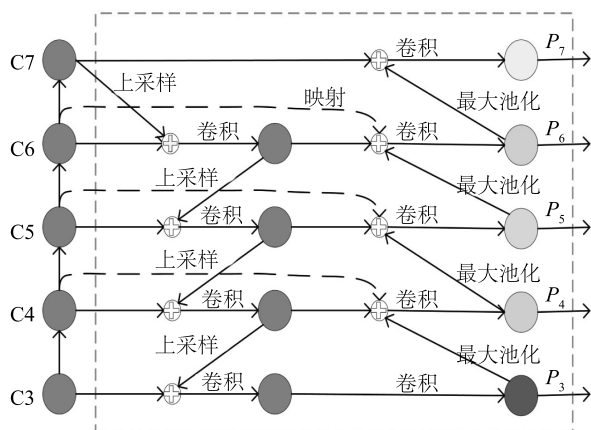
计算权重是因为来自不同层卷积操作后的特征图分辨率不同,需要上采样或卷积操作保持相同分辨率后进行融合,而上采样或卷积操作的特征图及原分辨率特征图对融合后特征图的贡献并不一样,因此需要通过权重对不同重要程度的特征有重点地



C 代表来自不同卷积层的特征图;P 代表最终各卷积层对应的输出。

图4 特征金字塔发展历程

Fig.4 The development process of feature pyramid



C 代表来自不同卷积层的特征图;P 代表最终各卷积层对应的输出。

图5 复杂双向多尺度融合网络 (BiFPN) 结构图

Fig.5 Structure diagram of bidirectional feature pyramid network (BiFPN)

进行学习,对特征图中的信息进行有区别地融合。此外,BiFPN 的加权特征融合采用快速归一化融合方式,具体融合方式以图 5 的 C6 层进行融合输出结果 P_6 举例说明。

融合过程具体分为 2 步,首先对 C6 和 C7 层的输入特征图进行融合,融合过程如公式 1:

$$P_1 = \text{Conv} \left(\frac{\omega_1 \times C_6 + \omega_2 \times \text{UpSample}(C_7)}{\omega_1 + \omega_2 + \varepsilon} \right) \quad (1)$$

其次将公式 1 结果与 C6 层输入及 C5 层输出 P_5 进行融合操作,融合过程如公式 2:

$$P_6 = \text{Conv} \left[\frac{\omega'_1 \times C_6 + \omega'_2 \times P_1 + \omega'_3 \times \text{Conv}(P_5)}{\omega'_1 + \omega'_2 + \varepsilon} \right] \quad (2)$$

公式 1、公式 2 中的 ε 是避免数值不稳定的小数值,一般取 0.000 1; C_6 、 C_7 分别指代原始图像经第

6、第 7 次卷积之后的结果; P_6 表示第 6 次卷积后的最终输出; P_5 表示第 5 次卷积后的最终输出; P_1 表示第 1 次卷积后的最终输出; UpSample 表示上采样操作; Conv 为下采样操作; ω 是学习到的各输入对于融合结果重要程度所占权重参数,这些权重参数类似于注意力机制中的权重,可以区分特征融合结果对不同特征的依赖程度,此外利用 Relu 函数保证权重参数的稳定性 $\omega_i \geq 0$, 并对其进行归一化操作,使其范围限定在 $[0, 1]$ 。

1.2.3 改进的 YOLO_Head YOLO_Head 是目标检测网络 YOLO 系列网络提出的检测头,在各公开数据集的检测中都有较好的表现,可以实现检测目标的精准定位,然而由于本研究检测对象为绿色果实,绿色果实相较于其他数据集中的动物、人、车等目标相对较小,因此需要对 YOLO 检测头进行改进,使其更好地进行小目标识别。

原始 YOLO_Head 在大、中、小 3 个不同尺度的特征图上进行检测,为了更好地检测小目标,本研究在原始 3 个检测层的基础上添加一个对小目标进行检测的检测层,从而提升改进后 YOLO_Head 的小目标检测精度。此外,由于对预测头进行改进,因此需要重新对本研究数据集中的真实目标检测锚框聚类,从而使预测头能够更有效地匹配检测对象的预测框,减小预测框与实际目标位置的偏离程度,并提高被遮挡物体的识别精度。

本研究采用 K-means++ 算法对绿色果实数据集中 29 085 个检测对象的标记锚框聚类,因为本研究改进后的 YOLO_Head 需要在 4 个不同尺度,且每个尺度有 3 个检测框的基础上进行锚框预测,因此人

为设定聚类中心个数 $K=12$ 。此外,由于本研究不再是对坐标点进行聚类,而是对真实锚框聚类,因此在聚类时不再使用欧式距离作为度量值,改为使用其他真实框与聚类中心框的面积交并比(IoU)作为度量真实框与聚类中心的距离, IoU 越小,表明真实框与聚类中心重叠面积越小,其越远离聚类中心。新的距离计算公式:

$$d(B, C) = IoU(B, C) \quad (3)$$

式中, B 表示数据集中真实框集合; C 表示聚类初始选取的锚框集合; d 表示距离; IoU 表示真实框与聚类中心框的面积交并比。最终通过不断进行 IoU 计算及迭代调整聚类中心框的尺度,获取了适合本研究采取的锚框尺度(表 1)。

表 1 预测头检测框尺寸分配

Table 1 Prediction head detection box size assignment


特征图 尺度	感受野 大小	先验框大小		
20×20	大	(165,166)	(215,218)	(281,279)
40×40	中	(87,87)	(108,109)	(132,133)
80×80	小	(45,47)	(56,59)	(71,72)
160×160	微小	(16,17)	(25,26)	(35,36)

1.2.4 Ghost_BY 目标检测网络 本研究单阶段目标检测网络主要包含 3 大部分:主干特征提取网络、

特征加权融合网络及增加一个检测层的 YOLO_Head 预测头,其网络框图如图 6 所示。输入层接受图像并经过图像预处理,将输入图像按网络输入要求进行缩放或扩充,使其满足网络输入要求,接着进行归一化、Mosaic 数据增强等操作,对数据集进行数据增强处理,随后将处理后的图像送入 GhostNet,经过特征提取操作后将全部特征图送入特征融合网络 BiFPN 进行复杂双向多尺度特征融合,最后利用改进后的 YOLO_Head 进行预测,对预测出的锚框本研究采用非极大值抑制回归算法(NMS)来获取最佳预测框,实现检测目标的标记及定位。

1.3 试验准备

1.3.1 数据集的获取与预处理 本研究选取青核桃、青桃子、青桔、青李子、青梅、青苹果、青番茄、青枣 8 种绿色果实为研究对象(图 7),使用红米 k40pro 手机作为拍摄设备,分辨率 2 400×1 080,在 2021 年 5 月、7 月、8 月进入新疆地区的不同果园分时分地进行图片拍摄,并且人为对拍摄的图像进行筛选,经人为初步筛选后共采集复杂背景下各类绿色果实图像 4 392 张,其中包括青核桃 578 张、青桔 491 张、青李子 494 张、青梅 556 张、青苹果 546 张、青桃子 608 张、青番茄 518 张、青枣 601 张,数据集中果实目标共 29 085 个,最终使用 LabelImg 软件对全部果实目标进行标注。



GhostNet:本研究使用的特征提取网络;BiFPN:复杂双向多尺度融合网络;NMS:非极大值抑制回归算法。

图 6 Ghost_BY 目标检测网络

Fig.6 Ghost_BY target detection network

1.3.2 评价指标 本研究在训练和测试中使用的计算机硬件环境配置是:处理器为 3 块 Intel(R) Xeon(R) CPU E5-2678 v3@2.5 GHz 型号 CPU,CPU 内存为 8 GB,GPU 型号为 NVIDIA Tesla K80,显卡内存为 12 GB,操作系统及软件环境为:Windows10 操作系统、CUDA 11.1 版本的并行计算机框架、Cudnn 8.05 版本的深度学习加速库、Pytorch 1.9.1 深度学习框架、YOLOv5 目标检测网络框架,编程语言为 Python 3.8。

本研究用来评价目标检测网络的具体指标主要包括:以均值平均精度(mAP)评价网络预测结果的

准确率(综合考虑精确率(P)和召回率(R),利于评价网络准确性);以参数量及最终权重文件占用内存大小评价网络大小;以每张图片检测所用的时间(FPS)评价网络检测的检测速度,最终各评价指标的计算公式如下:

$$P = \frac{TP}{TP + FP} \quad (4)$$

$$R = \frac{TP}{TP + FN} \quad (5)$$

$$AP = \int_0^1 P(R) dR \quad (6)$$




图7 数据集中不同的绿色果实

Fig.7 Different green fruits in the dataset

$$mAP = \frac{1}{n} \sum AP \quad (7)$$

$$FPS = \frac{TotalTime}{FigureNumber} \quad (8)$$

式中, TP 表示 IoU 满足设定阈值的检测框数目; FP 表示 IoU 没有满足设定阈值的检测框数目; FN 表示漏检的目标数; P 表示精确率; R 表示召回率; mAP 表示均值平均精度; FPS 表示每张图片检测所用的时间; AP 表示平均精度; n 表示检测到待检目标的检测框个数; $TotalTime$ 指检测全部验证图像所用时间; $FigureNumber$ 表示验证图像总数。

2 结果与分析

2.1 不同特征提取网络对目标检测网络性能的影响

为了验证特征提取网络对本研究网络检测性能的影响,本研究在保证网络使用超参数、迭代次数、训练技巧不发生改变的条件下,分别使用 SqueezeNet、MobileNet、ShuffNet 这 3 种特征提取网络与 GhostNet 相比较,它们的网络大小、均值平均精度、每张图片检测所用的时间见表 2。GhostNet 特征提取网络在保证检测速度的同时,相较于其他提取网络拥有最高的均值平均精度,达到 93.5%,虽然网络大小比 MobileNet 多 0.3 M,但综合精度、速度、大小 3 方面考虑, GhostNet 提取网络是 4 种提取网络中的最优选择,因此本研究选用 GhostNet 作为特征提取网络。

2.2 不同特征融合网络对目标检测网络性能的影响

为了探究不同特征融合网络对本研究构建网络的影响,分别使用特征金字塔网络(FPN)、路径聚合网络(PANet)、BiFPN 对 GhostNet 所提取到的特征图进行融合。表 3 显示,使用 BiFPN 对特征

图进行融合的确可以提升模型的检测精度,最终均值平均精度达到 94.9%,高于 FPN(93.5%)、PANet(94.0%)特征融合后的均值平均精度,但由于进行多次融合,网络在内存占用及检测速度方面稍逊于 PANet,内存占用增加 0.7 M,检测速度增加 4 ms。

表 2 不同特征提取网络性能对比

Table 2 Performance comparison of different feature extraction networks

轻量化网络	大小(M)	mAP (%)	FPS (ms)
SqueezeNet	12.6	92.7	49
MobileNet	7.5	92.6	25
ShuffNet	8.0	92.7	28
GhostNet	7.8	93.5	21

mAP : 均值平均精度; FPS : 每张图片检测所用的时间。

2.3 改进后的预测头对网络性能的影响

为了检验改进后 YOLO_Head 的有效性,将改进后 YOLO_Head 与原始 YOLO_Head 分别作为检测网络的预测头进行性能对比,除改变预测头外,检测网络其余部分不变,均采用 GhostNet 作为特征提取网络,使用 BiFPN 进行特征融合,数据增强手段、训练参数均相同。结合图 8 和表 4 可以得出,使用改进后的 YOLO_Head 作为预测头本研究目标检测网络的均值平均精度达到 96.8%,相较于改进前预测头,提升 1.9 个百分点,且训练损失值最终收敛为 0.02。

表 3 不同特征融合网络性能对比

Table 3 Performance comparison of different feature fusion networks

特征融合	大小(M)	mAP (%)	FPS (ms)
FPN	14.1	93.5	35
PANet	7.8	94.0	21
BiFPN	8.5	94.9	25

FPN: 特征金字塔网络; PANet: 路径聚合网络; BiFPN: 复杂双向多尺度融合网络。 mAP : 均值平均精度; FPS : 每张图片检测所用的时间。

表 4 改进预测头性能对比

Table 4 Performance comparison of networks with different prediction head

预测头	大小(M)	mAP (%)	FPS (ms)
YOLO	8.5	94.9	29
改进 YOLO	11.8	96.8	37

mAP : 均值平均精度; FPS : 每张图片检测所用的时间。




图 8 均值平均精度、损失函数曲线对比图

Fig.8 Comparison of mean average precision curves and loss function curves

为进一步探究添加微小感受野对目标检测网络的影响,按照所拍摄果实的实际大小,对图片进行人为筛选,重新构建数据集,将数据集果实分为大、中、小 3 类,其中青枣、青梅为小果实;青核桃、青李子为中等果实;青苹果、青桃子为大果实。重新构建数据集,然而从头开始训练网络不仅需要足够大的数据集,还需要消耗大量时间再次训练网络,因此为了节省训练时间,加速训练网络的收敛,本研究使用此前训练结束的绿色类圆果实检测网络模型作为新网络的预测训练模型,使用迁移学习方法训练新的网络,分别使用改进前后预测头进行预测。表 5 显示,改进前后预测头对中等果实、大果实检测精度的影响并不明显,然而对小果实的检测精度影响较大,改进预测头后检测网络的均值平均精度提升 2.1 个百分点,最终使检测网络的均值平均精度提升 0.9 个百分点。

表 5 不同检测层网络性能对比

Table 5 Performance comparison of networks with different detection layers

预测头	大小 (M)	mAP (%)				FPS (ms)
		大果实	中等果实	小果实	全部	
YOLO	8.5	95.5	94.4	93.0	94.3	32
改进 YOLO	11.8	95.8	94.2	95.1	95.2	43

mAP: 均值平均精度; FPS: 每张图片检测所用的时间。

2.4 与其他网络的比较

为了进一步证明本研究构建单阶段目标检测网络的性能,将本研究构建的检测网络与现阶段较流行的 YOLO 系列网络、Faster RCNN 网络、SDD 网络在数据集不改变、硬件条件不变更的前提下进行对比验证试验。结果(表 6)表明,对比现阶段较流行

的网络,本研究构建的检测网络在检测精度、检测速度方面均优于 Faster RCNN 网络、SDD 网络,网络模型内存占用大小也有明显下降;YOLO 系列 v3、v4 网络虽然在检测速度方面优于 Faster RCNN、SDD 网络,但仍落后于本研究网络的检测速度;YOLO 系列 v5 网络虽然检测速度稍快于本研究构建网络,但对绿色类圆果实的检测精度低于本研究构建网络,本研究所构建网络的均值平均精度为 96.8%,相较于 YOLOv3、YOLOv4、YOLOv5 分别提升 9.3 个百分点、5.3 个百分点、2.6 个百分点。通过对检测结果的综合比较,本研究构建的单阶段目标检测网络综合性能更优,更适合绿色类圆果实的检测。

表 6 不同检测网络性能对比

Table 6 Performance comparison of different detection methods

网络	大小 (M)	mAP (%)	FPS (ms)
Faster R-CNN	25.0	91.5	356
SDD	28.0	92.8	245
YOLOv3	26.0	87.5	78
YOLOv4	35.0	91.5	56
YOLOv5	14.3	94.2	31
本研究构建网络	11.8	96.8	37

mAP: 均值平均精度; FPS: 每张图片检测所用的时间。

此外,分析本研究构建网络对绿色类圆果实的部分检测结果(图 9),发现本研究构建网络对暗光环境、正常环境和夜间环境下的图片均有较好的检测结果;对密集果实、果实遮挡果实、叶片遮挡果实的检测也都具备良好的检测效果。

3 结论

本研究构建的网络能够对自然环境复杂果园背



图9 本研究构建网络检测结果

Fig.9 Detection results of the network constructed in this study

景中的绿色类圆果实实现快速、准确识别,与目前主流检测网络相比,本研究构建网络检测精度优于其他网络,能够在背景与检测目标相近的情况下实现同色系果实的检测。使用 GhostNet 作为特征提取网络可以降低目标检测网络占用大小,提高检测速度,有利于在嵌入式设备及移动端的应用;使用 BiFPN 作为特征融合网络可以提升检测网络的检测精度,更好地实现检测对象的识别预定位;添加检测层,改进预测头可以提升网络对小目标的检测精度,继而提升网络的整体检测精度。最终,本研究构建的检测网络在试验数据集中的均值平均精度达到 96.8%、每张图片检测所用的时间为 37 ms、网络大小 11.8 M,满足了绿色类圆果实快速、准确的识别要求,也利于后续移动端 APP 或嵌入式设备的开发工作。

参考文献:

- [1] HE Z L, XIONG J T, LIN R, et al. A method of green litchi recognition in natural environment based on improved LDA classifier [J]. Computers and Electronics in Agriculture, 2017, 140: 159-167.
- [2] LINKER R, COHEN O, NAOR A. Determination of the number of green apples in RGB images recorded in orchards [J]. Computers and Electronics in Agriculture, 2012, 81: 45-57.
- [3] LI H, LEE W S, WANG K. Identifying blueberry fruit of different growth stages using natural outdoor color images [J]. Computers and Electronics in Agriculture, 2014, 106: 91-101.
- [4] LU J, SANG N. Detecting citrus fruits and occlusion recovery under natural illumination conditions [J]. Computers and Electronics in Agriculture, 2015, 110: 121-130.

- [5] 王丹丹,徐 越,宋怀波,等. 融合 K-means 与 Neut 算法的无遮挡双重苹果目标分割与重建 [J]. 农业工程学报, 2015, 31 (10): 227-234.
- [6] LI H, LEE W S, WANG K. Immature green citrus fruit detection and counting based on fast normalized cross correlation (FNCC) using natural outdoor colour images [J]. Precision Agriculture, 2016, 17(6): 678-697.
- [7] BANSAL R, LEE W S, SATISH S. Green citrus detection using fast Fourier transform (FFT) leakage [J]. Precision Agriculture, 2013, 14: 59-70.
- [8] 卢 军,胡秀文. 弱光复杂背景下基于 MSER 和 HCA 的树上绿色柑橘检测 [J]. 农业工程学报, 2017, 33 (19): 196-201.
- [9] 马翠花,张学平,李育涛,等. 基于显著性检测与改进 Hough 变换方法识别未成熟番茄 [J]. 农业工程学报, 2016, 32 (14): 219-226.
- [10] 谢忠红,姬长英,郭小清,等. 基于改进 Hough 变换的类圆果实目标检测 [J]. 农业工程学报, 2010, 26 (7): 157-162.
- [11] LIU X, ZHAO D, JIA W, et al. A detection method for apple fruits based on color and shape features [J]. IEEE Access, 2019, 7: 67923-67933.
- [12] 李 颀,杨 军. 基于多分辨率特征融合的葡萄尺寸检测 [J]. 江苏农业学报, 2022, 38 (2): 394-402.
- [13] 刘 芳,刘玉坤,林 森,等. 基于改进型 YOLO 的复杂环境下番茄果实快速识别方法 [J]. 农业机械学报, 2020, 51 (6): 229-237.
- [14] 岳有军,孙碧玉,王红君,等. 基于级联卷积神经网络的番茄果实目标检测 [J]. 科学技术与工程, 2021, 21 (6): 2387-2391.
- [15] 贾伟宽,孟 虎,马晓慧,等. 基于优化 Transformer 网络的绿色果实高效检测模型 [J]. 农业工程学报, 2021, 37 (14): 163-170.
- [16] GIRSHICK R. Fast R-CNN [C]. Santiago: IEEE, 2015.
- [17] REN S, HE K, 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.
- [18] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection [C]. Las Vegas: IEEE, 2016.
- [19] REDMON J, FARHADI A. YOLOv3: an incremental improvement [C]. Salt Lake City: IEEE, 2018.
- [20] LIU W, ANGUELOV D, ERHAD D, et al. SSD: single shot multi box detector [C]. Amsterdam: Springer, 2016.
- [21] 包志龙. 卷积神经网络轻量化技术研究 [J]. 无线通信技术, 2022 (1): 36-41, 47.

(责任编辑:王 妮)