

自然环境下绿色柑橘视觉检测技术研究

熊俊涛 刘 振 汤林越 林 睿 卜榕彬 彭红星

(华南农业大学数学与信息学院, 广州 510642)

摘要: 绿色柑橘具有与背景相似的颜色特征, 自然环境下绿色柑橘的视觉检测比较困难。提出基于深度学习技术, 利用 Faster RCNN 方法进行树上绿色柑橘的视觉检测研究。首先配置深度学习的试验环境, 同时设计了绿色柑橘图像采集试验, 建立了柑橘图像样本集, 通过试验对批处理大小、学习速率和动量等超参数进行调优, 确定合适的学习速率为 0.01、批处理为 128、动量系数为 0.9, 使用确定的超参数对模型进行了训练, 最终训练模型在测试集上的平均精度 (MAP) 为 85.49%。通过设计自然环境下不同光照条件、图像中不同尺寸柑橘、不同个数柑橘的 Faster RCNN 方法与 Otsu 分割法的柑橘检测对比试验, 并定义 F 值作为对比评价指标, 分析 2 种方法的检测结果, 试验结果表明: Faster RCNN 方法与 Otsu 方法在不同光照条件下检测绿色柑橘的 F 值分别为 77.45% 和 59.53%; 不同个数柑橘果实检测结果的 F 值分别为 82.58% 和 60.34%, 不同尺寸柑橘检测结果的 F 值分别为 73.53% 和 49.44%, 表明所提方法对自然环境下绿色柑橘有较好的检测效果, 为果园自动化生产和机器人采摘的视觉检测提供了技术支持。

关键词: 绿色柑橘; 视觉检测; 深度学习; Faster RCNN

中图分类号: TP391.41 **文献标识码:** A **文章编号:** 1000-1298(2018)04-0045-08

Visual Detection Technology of Green Citrus under Natural Environment

XIONG Juntao LIU Zhen TANG Linyue LIN Rui BU Rongbin PENG Hongxing
(College of Mathematics and Informatics, South China Agricultural University, Guangzhou 510642, China)

Abstract: China is one of the main planting sites of citrus. Since citrus is the economic pillar of farmers from many producing regions and the raw ingredients of many fruit processing facilities, there is a strong connection between citrus output and economic benefits. The output can influence farmers' income and facilities' productivity directly. By estimating the output of citrus, the facilities can analyze the production and marketing situation and adjust the pricing policy in time, which is significant to the macro-control of citrus market. For a long time, the agricultural production in China relies mainly on manual work, which has high labor intensity and low efficiency. A precise visual detection of citrus can estimate the output. Also, it can provide technical support for the citrus picking robot. Therefore, it is of great significance to the study of visual detection of green citrus under natural environment. Green citrus has similar color feature to the background, which makes the visual detection of fruits difficult to be implemented. Based on deep learning technology, the visual detection of green citrus was studied by using faster RCNN. The image acquisition experiment of green citrus was designed firstly. Then 2160 images were acquired and 1500 of them were selected from artificial selection. These 1500 images contained different amounts of fruit, different areas of scale and different illuminating angles. Totally 1200 images were selected randomly as training set. The rest 300 images were left for verification. Then the experimental environment of deep learning was configured, the image acquisition experiment was designed and the sample set of green citrus was set up. Making tuning of hyper-parameters and setting the learning rate as 0.01, batch size as 128 and momentum as 0.9 to train the model. The MAP of test set by using trained model was 85.49%. Comparison experiment of Faster RCNN and Otsu method was

收稿日期: 2017-08-29 修回日期: 2017-11-15
基金项目: 国家自然科学基金项目(31201135、51705365)、广东省自然科学基金项目(2015A030310258)和广州市科技计划项目(201506010081)
作者简介: 熊俊涛(1981—),男,副教授,主要从事农业机器人和智能设计与制造研究,E-mail: xiongjt2340@163.com
通信作者: 彭红星(1976—),男,副教授,主要从事虚拟现实及智能设计与制造研究,E-mail: 77481028@qq.com

conducted under different lighting environments, different sizes of citrus and different amounts of citrus within an image. Defining value F as comparative evaluation index to analyze the detection result of the two methods. The F value of Faster RCNN under different lighting conditions was 77.45%, which was 59.53% when Otsu method was used. The F value of different amounts of citrus were 82.58% and 60.34%. With images of citrus in different sizes, the F values were 73.53% and 49.44%. Results above showed that the given method had better detection result. It can provide technical support for automatic production in orchard and visual detection of picking robot.

Key words: green citrus; visual detection; deep learning; Faster RCNN

0 引言

果蔬采摘是农业生产中劳动强度大、季节性强的一个重要环节,目前国内果蔬采摘作业基本依靠人工完成,其自动化程度仍然很低^[1-2]。机器视觉技术能实现采摘机器人对目标的精确定位,因此开发具有视觉功能的果蔬采摘机器人,对提高农业生产力有较大的应用价值与较强的现实意义。

国内外在水果检测方面的研究取得了一定的进展^[3-9],但研究对象主要偏向于与背景颜色差异明显的水果,而对未成熟或者成熟后为绿色的水果检测的相关研究相对较少,这是由于绿色水果果实与叶子颜色很相近,识别难度较大,识别准确率较低。

目前一些绿色水果的识别研究成果,如 KURTULMUS 等^[10]结合颜色、圆形 Gabor 纹理特征和“特征果”算法来检测绿色柑橘类水果,其检测的柑橘果实在图像中的直径为 130~210 像素,检测准确率为 75.3%,漏检率为 24.7%,错检率为 27.3%。张春龙等^[11]在环形闪光灯条件下采集了夜间苹果树图像,设计了以归一化的 g 分量和 HSV 颜色空间中 H 、 S 分量为特征参数的支持向量机分类器和以超绿算子为特征的阈值分类器的集成方法,实现了绿色苹果在自然环境中的有效识别。ZHAO 等^[12]结合颜色特征和绝对变换差值和 (Sum of absolute transformed difference, SATD) 来检测未成熟的绿色柑橘,其算法检测绿色柑橘的准确率为 83.4%,漏检率为 16.6%,错检率为 10.7%。以上对绿色水果的识别方法主要是基于颜色特征和纹理特征,需结合多种纹理特征对绿色水果进行识别,识别准确率较其他颜色的水果也较低,而且不同品种的绿色水果颜色特征和纹理特征都会有些差异,即使同一品种的绿色水果果实在图像中的尺寸不同或在不同光照强度下其颜色特征和纹理特征也会发生改变,因此绿色水果的视觉检测较为困难。

深度学习作为一种特征学习方法,其通过对样本的学习,可以得到较好的识别模型,如赵源深等^[13]利用结合 Haar-like 特征和 AdaBoost 对番茄进行识别,其对测试集中成熟番茄的识别成功率达

93.3%;高震宇等^[14]通过卷积神经网络对茶叶进行分选,其对各类茶叶的识别准确率都不低于 90%,平均识别准确率为 92.4%。

Faster RCNN^[15]是继 R-CNN^[16]和 Fast R-CNN^[17]后 REN 等提出的最新的目标检测方法,其具有较快的检测速度,同时也具有较高的识别准确率和泛化性能。桑军等^[18]将 Faster RCNN 用于道路监控车辆的车型识别,车型识别率达 91.3%;JIANG 等^[19]将 Faster RCNN 应用于人脸识别,得到较好的识别结果。

本文基于深度学习方法的识别模型准确度高、运算速度快的特点,以绿色柑橘为主要研究对象,利用 Faster RCNN 方法进行不同光照和不同尺寸的绿色柑橘识别,考虑自然环境的多种情况,筛选的训练样本包含不同尺寸和不同光照角度的绿色柑橘图像,设计一种自然环境下树上绿色柑橘的视觉检测方法,为农业生产中绿色水果的视觉检测研究提供技术支持。

1 材料与方法

1.1 图像采集与颜色分析

本文以绿色柑橘为研究对象,进行自然环境下绿色柑橘的识别研究。设计了柑橘图像采集试验,图像采集的时间为 2016 年 11 月 5 日 08:00—16:00,使用尼康 D5300 采集图像,图像分辨率为 2 992 像素×2 000 像素,在晴天环境下从侧光、顺光和逆光多个光照角度进行拍摄,拍摄距离为 50~110 cm,共拍摄 2 126 幅图像,其中以图像中的绿色柑橘区域作为正样本,图像中的枝叶背景作为负样本,根据光照角度和柑橘在图像中的尺寸,以保证图像数据的多样性为原则对图像进行筛选,最终经过人工筛选,所得数据集包含拍摄图像 1 500 幅,数据集包含了不同光照角度和不同拍摄距离的柑橘图像,在本研究中,随机抽取 80% 的数据,即 1 200 幅图像作为训练集,剩余的 300 幅图像作为验证集。

绿色柑橘的果实与叶子颜色非常相近,在不同光照角度下颜色特征会发生改变,很难根据其颜色特征进行识别。本文对自然环境下采集的绿色柑橘

图像进行颜色特征分析,图 1 为顺光条件下绿色柑橘图像的 12 个颜色分量图像。在 12 个颜色分量中,正常光照环境下 H 分量和 Cb 分量的图像中果实和背景具有较大的对比度,可以选择这 2 个分量进一步分析不同光照角度下的柑橘图像。




图 1 不同颜色分量下的顺光柑橘图像

Fig.1 Side lighting citrus images under different color components

图 2 为不同光照角度下柑橘在 H 分量和 Cb 分量的图像,在顺光光照角度下,果实区域与背景对比都较为明显,能看到明显的果实区域,而在侧光环境下, Cb 分量图像只有在光照照射到的一侧果实区域颜色特征才较为明显,而在 H 分量下果实区域与背景对比并不明显,在逆光环境下 Cb 分量和 H 分量都很难区分出果实区域。




图 2 不同光照角度下柑橘的 H 分量和 Cb 分量图像

Fig.2 H and Cb component images of citrus under different illumination angles

综上所述,自然环境下绿色柑橘与叶子颜色相近,其颜色特征在不同的光照角度下也不同,利用传统分割算法很难达到较好的识别效果。因此本文采

用机器学习的方法对自然环境下绿色柑橘进行识别,由于自然环境下采集柑橘图像会存在不同光照角度、不同拍摄距离、柑橘自身大小不同、果实遮挡粘连等情况,采集的图像本身具有比较复杂的结构。为了适用不同的情况,提高 Faster RCNN 网络模型的泛化性能,在数据筛选阶段,通过选择不同类型的训练样本来逼近图像样本的真实分布,使图像数据具有以下多样性特征:首先是光照角度多样性,如侧光、顺光和逆光;其次是面积尺度的多样性,本文以柑橘果实面积的像素半径作为度量标准,基于摄像机标定的最佳拍摄距离为 50 ~ 110 cm 来确定柑橘样本的像素半径和像素面积标准。部分训练样本示例如图 3 所示。




图 3 样本多样性示例

Fig.3 Examples of sample diversity

1.2 算法实现流程

本文以深度学习方法来解决自然环境中绿色柑橘的检测问题,选择 Faster RCNN 作为绿色柑橘识别模型,caffe 作为深度学习框架,首先配置 caffe 的运行环境,并将筛选出来的图像数据按照 PASCAL VOC2007 检测标准进行存储和标注,基于预训练模型进行微调,使预训练模型可用于求解本文的研究问题,算法流程如图 4 所示。




图 4 基于 Faster RCNN 绿色柑橘识别算法流程

Fig.4 Flow chart of green citrus recognition algorithm based on Faster RCNN

1.3 模型训练与优化

在训练模型与优化参数之前,需要先确定预训

练模型以及损失函数。Faster RCNN 提供了 3 个预训练好的模型,分别对应小型、中型和大型网络,每个网络都有与之对应的配置文件,当需要对参数进行修改时,可以通过配置文件快捷实现^[20]。考虑到

试验对象只有绿色柑橘和背景 2 个类别,综合考虑计算资源和检测效果等因素,选择中型网络作为预训练模型。Faster RCNN 结构示意图如图 5 所示。




图 5 Faster RCNN 结构示意图

Fig. 5 Structure diagram of Faster RCNN

1.3.1 批处理大小

一般情况下,为准确计算损失函数对参数的梯度,需要对整个数据集上的每个样本进行计算,对于深度网络而言,这样的计算量十分巨大。因此,在实践中倾向于从数据集中分批随机采样少量的样本,然后计算这些批样本上的平均值。这种采样策略被称为 minibatch 或随机 minibatch,基于 minibatch 的梯度下降方法被称为随机梯度下降。随机梯度下降更新参数的算法如下^[21]。

算法 1:随机梯度下降 (SGD) 在第 k 个训练迭代的更新

设置:学习速率 ϵ_k ; 初始参数 θ

while 没有达到停止准则 do

从训练集中随机采样包含 m 个样本 $\{x^{(1)}, x^{(2)}, \dots, x^{(m)}\}$ 的 minibatch,对应目标为 $y^{(i)}$ 。

计算梯度估计: $g \leftarrow \frac{1}{m} \nabla_{\theta} \sum_i L(f(x^{(i)}, \theta), y^{(i)})$

应用更新: $\theta \leftarrow \theta - \epsilon g$

end while

试验分别测试了 minibatch 为 32、64、128 和 256 时,模型在测试集上的检测精度,结果如表 1 所示。

表 1 不同批处理对应的模型检测精度

Tab.1 Detection accuracy of model with different batch sizes

	batch sizes				%
minibatch	32	64	128	256	
平均精度均值 (MAP)	55.31	61.94	63.71	65.84	

分析 minibatch 大小与 MAP 的变化关系,可以看出,试验选定的范围内,minibatch 取得越大,MAP 也相应随之有所提高,但 MAP 的增量并非是

minibatch 线性增量,而是小于线性的。如 minibatch 从 64 增加到 128 以及从 128 增加到 256 是成倍的增加,但是与之相应的 MAP 两次都只提高了约 2 个百分点。

考虑到增大 minibatch 后,训练时间增加明显,参数的学习也显得更加缓慢,而小的 minibatch 训练时需要较小的学习速率以维持稳定性。综合以上两点,试验在此阶段暂时选择候选 minibatch 大小为 64 和 128。

1.3.2 学习速率和动量

学习速率和动量的选取直接影响检测网络的训练速度和结果,本文选取一些较常用的学习速率和动量作为候选值,通过试验确定较为合适的学习速率和动量。试验选择 0.1、0.01 和 0.001 作为初始学习速率 ϵ 的候选值,以 0.5、0.9 和 0.99 作为动量系数 α 的候选值,以 1.3.1 节中选择的 64 和 128 作为批处理 s 候选值。基于这些候选值设计了多组对比试验,首先确定了学习速率,接着确定批处理大小,最终确定动量的大小。参数的组合情况和测试结果如表 2 所示。

表 2 不同参数组合对应的测试精度

Tab.2 Detection accuracy of different parameter combinations

序号	参数组合	MAP/%
1	$\epsilon = 0.1, s = 64$	
2	$\epsilon = 0.01, s = 64$	67.91
3	$\epsilon = 0.001, s = 64$	65.89
4	$\epsilon = 0.01, s = 128$	68.29
5	$\epsilon = 0.01, s = 128, \alpha = 0.5$	71.46
6	$\epsilon = 0.01, s = 128, \alpha = 0.9$	72.35
7	$\epsilon = 0.01, s = 128, \alpha = 0.99$	66.89

试验首先在不加入动量,批处理大小设置为 64 的基础上,测试了不同学习速率对检测精度的影响,其中当学习速率为 0.1 时,训练出现发散,可能原因为 0.1 作为初始学习速率过大。学习速率为 0.001 时,MAP 略小于 0.01 对应的值,可能原因为 0.001 相对于 0.01 对应的损失函数值迭代到极小值邻域较慢。据此,在第 4 组试验中,确定 0.01 为初始学习速率,对比第 2 组和第 4 组,当批处理取 128 时的 MAP 比批处理取 64 时的 MAP 高。最终,试验在第 4 组参数的条件下加入动量,分别测试了动量系数为 0.5、0.9 和 0.99 时的 MAP,由表 2 可以看出,动量系数为 0.9 时取得的 MAP 最高。因此,试验最终确定初

始学习速率为 0.01,批处理为 128,动量系数为 0.9。

1.4 模型测试

使用上节得到的超参数,基于原始训练集,对模型进行训练以学习模型参数。该阶段使用的训练集为原始数据集,模型参数使用 Xavier 方法初始化,当检测网络和 RPN 网络迭代到 20 000 和 40 000 步时,损失函数值趋于平稳,如图 6 所示为 Faster RCNN 第 2 轮训练时,RPN 网络和检测网络的损失值变化曲线。最终损失函数值稳定在[0.1,0.2]区间的邻域内,模型在验证集上的 MAP 为 85.49%,使用 GeForce GTX 1080 显卡运行检测一幅绿色柑橘图像的平均时间为 0.4 s。




图 6 Faster RCNN 训练阶段损失值变化情况

Fig. 6 Changing conditions of loss value in training stage of Faster RCNN

分析误差出现的原因可能在于:试验数据考虑了多种状态的样本,可能在某些状态下,柑橘的特征不如其他状态明显,比如逆光和阴天等条件下收集到的样本,从而提高了错误识别率。另一个可能原因在于,模型对小尺度的物体检测不敏感,比如远距离拍摄的柑橘图像,图像中的柑橘尺度较小,不容易被检测到。为了直观感受 Faster RCNN 的检测效果,使用该模型在测试图像上进行效果测试,得到的部分检测结果如图 7 所示。

2 试验与讨论

2.1 试验评价指标

为了进一步验证模型的有效性,试验选择基于 Otsu 阈值分割法的传统图像处理方法作为参照,对比 Faster RCNN 和 Otsu 2 种算法的检测效果。分别从图像中果实个数、果实面积半径和拍摄的光照角度 3 个方面进行对比分析,每个分析变量又分别设置了 3 次对比试验。为了对比 2 种算法的检测效果,首先需要对检测效果和评价指标进行约定。

由于正确率和召回率在某些情况下会出现矛盾情况,所以需要综合考虑。Faster RCNN 中使用了 MAP,是基于候选框的类别概率排序,而 Otsu 算法并没有根据概率或其他参考值对包围框进行排序,




图 7 Faster RCNN 部分检测结果示例

Fig. 7 Examples of detection results for Faster RCNN

同时,Otsu 算法每次产生的包围框个数较少,使用少量包围框样本的召回率和正确率来计算 MAP 会存在计算复杂度与计算误差相对较大的问题。因此,本试验定义一个 F 值作为对比评价指标,具体计算公式为

$$F = \frac{2PR}{P + R} \tag{1}$$

其中, P 、 R 分别表示正确率和召回率, P 等于模型检

索到的正确的正样本数除以模型检索到的正样本总数; R 等于模型检索到的正确的正样本数除以所有正样本总数。

在试验中,为每个对比条件收集 100 个样本,同时为所有对比条件收集 30 个背景样本,每次对比试验中,从每个条件的 100 个样本和 30 个背景样本的组合集中随机抽取 100 个样本,组成该次试验的测试集,将测试集中的背景样本作为负样本,其余样本作为正样本。若算法能有效检测出正样本中超过 50% 的柑橘目标,则认为该正样本被检索到,利用被检索到的正样本数、被检索到的所有样本数和正样本总数计算召回率和正确率进而得到 F 值。每个对比条件重复 3 次对比试验,取 3 个 F 值的均值作为评价结果。

2.2 不同果实个数对比试验

在实际柑橘图像中,往往包含不同个数的果实对象,对检测造成不同的影响,如在单果图像中,果实对象一般比较完整清晰,识别难度低,在多果图像中,有可能存在果实粘连甚至相互遮挡等情况,增加了检测的难度。因此本节对比试验共设置了 3 个梯度,分别为图像中具有 1 个果实、2~5 个果实以及 5 个以上果实,目的是对比 2 种算法在图像包含不同果实个数下的检测性能,分析 2 种算法在哪个梯度范围内表现较佳。图 8 为 2 种算法对含不同个数果实图像的检测结果。




图 8 2 种算法对含不同个数果实图像的检测结果
Fig.8 Detection results of two algorithms on images with different amounts of fruits

试验首先从原始测试集中随机抽取若干幅图像,对应 3 个梯度进行分类,再次随机抽取直到 3 个梯度类别中均达到 100 幅图像,在每个梯度的样本中加入 30 幅背景图像组成该梯度的数据集。分 3 次从每个梯度的数据集中抽取出 100 幅作为试验的

测试集,使用 2 种算法对测试集的图像进行检测,检测结果如表 3 所示。

表 3 含不同个数果实的图像对比试验结果
Tab.3 Comparison results of images with different amounts of fruit

果实个数	检测算法	F_1	F_2	F_3	平均值 F
1	Otsu	83.72	82.35	81.66	82.58
	Faster RCNN	91.30	91.89	90.71	91.30
2~5	Otsu	49.62	58.16	52.94	53.57
	Faster RCNN	85.71	84.39	84.52	84.88
>5	Otsu	31.93	38.71	40.00	36.88
	Faster RCNN	73.42	66.67	68.42	69.50
综合结果	Otsu	58.49	62.07	60.47	60.34
	Faster RCNN	83.95	81.89	81.91	82.58

表 3 中的综合结果计算方式为:将每次试验的数据集样本数、正样本总数、被检测到的样本数和被检测到的正样本数分别求和,然后采用与每次试验相同的方法计算总体的召回率、正确率和 F 值。从综合结果来看,Faster RCNN 的检测效果优于 Otsu,Faster RCNN 的 F 值比 Otsu 的 F 值高 22.24 个百分点,特别是对于果实个数大于 5 的图像,Faster RCNN 的 F 值约为 Otsu 的 2 倍,说明相对于 Otsu,Faster RCNN 不仅能提高其对单果的检测精度,而且能够对多果进行较精确的检测。经过分析,使用 Faster RCNN 多果识别效果比单果识别效果差的主要原因是多果靠得太近或存在相互遮挡时,被识别成是一个果实区域,或被遮挡太多的果实没有被识别出来。

2.3 不同果实尺寸对比试验

与不同果实个数的情况类似,如果图像中的果实半径较大,则枝叶背景对识别过程的影响相对较小,如果果实半径较小,则往往出现被枝叶遮挡,难以检测等情况。与 2.2 节试验方法相同,结合摄像机标定的有效拍摄距离 50~110 cm,分别设置了 3 个测试梯度:半径大于 50 像素,半径在 30~50 像素之间,半径在 30 像素以下。图 9 为 2 种算法对不同尺寸果实的检测效果图像。

依照 2.1 节的抽样方法,从原始测试集中分别抽取出 3 个梯度的试验数据。对每个梯度相应的测试样本,使用 2 种算法分别进行 3 次检测试验,得到的统计结果如表 4 所示。

从表 4 可以看出,2 种算法的最佳检测效果均出现在半径大于 50 像素范围,Faster RCNN 的 F 值为 85.76%,比 Otsu 高出约 17 个百分点,同时相对于另外 2 个对比条件,2 种算法在半径小于 30 像素的试验组中均表现较差,Faster RCNN 的 F 值为



图 9 2 种算法对不同尺寸果实的检测效果

Fig. 9 Detection results of two algorithms on fruit with different radii

表 4 不同半径的果实对比试验结果

Tab. 4 Comparison results of fruit with different radii		%			
果实半径/ 像素	检测算法	F_1	F_2	F_3	平均值 F
> 50	Otsu	68. 42	70. 13	65. 75	68. 10
	Faster RCNN	87. 64	82. 63	87. 01	85. 76
30 ~ 50	Otsu	44. 96	46. 15	50. 74	47. 29
	Faster RCNN	75. 00	75. 11	79. 52	76. 54
< 30	Otsu	21. 43	33. 33	27. 59	27. 45
	Faster RCNN	57. 55	52. 94	54. 01	54. 84
综合结果	Otsu	47. 33	51. 49	49. 49	49. 44
	Faster RCNN	74. 63	70. 97	75. 00	73. 53

54. 84%, Otsu 的 F 值为 27. 45%。综上数据可知, Faster RCNN 对果实半径大于 30 像素的图像的检测效果较好,可以用于识别半径大于 30 像素的果实。而 Faster RCNN 在半径小于 30 像素的图像上表现不足的可能原因为样本丰富度不够,采集图像时拍摄的半径较小果实图像较少,导致半径较小果实数据集的样本较少。

2. 4 不同光照角度对比试验

前两组试验主要分析了果实个数和面积因素对检测效果的影响,在试验数据中,除了以上内部因素外,还存在其他外部影响因素,比如拍摄时的光照角度。本节试验选择了侧光、顺光和逆光作为研究变量,设计了 3 个对比试验进行分析。图 10 为 2 种算法对不同光照角度下果实的检测效果。

从图 10 可以看出,侧光时,果实与枝叶的颜色相近,但纹理差异较明显,在顺光条件下,果实和枝叶的局部表面亮度增强,部分遮挡的枝叶会在果实表面留有阴影,在逆光条件下,果实与枝叶的亮度均




图 10 2 种算法对不同光照角度下果实的检测效果

Fig. 10 Detection results of two algorithms on fruit under different illumination angles

变暗,颜色与纹理差异均不明显。试验使用与 2. 2 节相同的方法,针对 3 种光照角度,通过重复随机抽样采集了 3 组测试集,使用 2 种算法对每组测试集分别进行 3 次检测试验,统计结果如表 5 所示。

表 5 不同光照角度果实的对比试验结果

Tab. 5 Comparison result of fruit under different illumination angles		%			
光照角度	检测算法	F_1	F_2	F_3	平均值 F
侧光	Otsu	77. 30	80. 24	75. 00	77. 51
	Faster RCNN	91. 21	90. 00	91. 80	91. 00
顺光	Otsu	60. 14	65. 77	63. 95	63. 29
	Faster RCNN	83. 33	81. 63	81. 08	82. 02
逆光	Otsu	19. 82	38. 71	30. 51	29. 68
	Faster RCNN	57. 14	56. 11	50. 75	54. 67
综合结果	Otsu	56. 12	63. 64	58. 82	59. 53
	Faster RCNN	78. 04	77. 09	77. 22	77. 45

从表 5 可以看出,不同光照下 Otsu 算法的检测效果均低于 Faster RCNN,同时两种检测算法的检测效果在侧光条件下达到最佳,在逆光时两种算法的检测效果最差,经过分析导致逆光条件下检测效果差的原因为:逆光条件下,果实和树叶在图像中显现的灰度均很低,边缘没有明显的梯度,纹理特征也被弱化,大大增加了该条件下的检测难度。

综上所述,3 组对比试验证明了基于 Faster RCNN 算法进行绿色柑橘检测的有效性,试验结果表明,Faster RCNN 算法不仅适用于单果的检测,对于多果的检测精度也较高,可用于果园采摘机器人的定位检测,同时,适用于对中小面积半径的果实的检测,可用于中小型果园的产量预估。

3 结论

(1)提出了一种基于 Faster RCNN 的绿色柑橘

视觉检测方法,基于Faster RCNN深度框架,结合自然环境绿色柑橘的颜色特征,通过多次模型的参数调整,确定了适用于绿色柑橘检测的学习速率、批处理大小和动量系数,最终训练得到的模型在验证集上的MAP为85.49%,检测一幅图像的平均运行时间为0.4 s,满足实时检测的要求。

(2)为了验证该方法的有效性和可行性,设计了3种条件下的对比试验,从图像中柑橘的个数、柑橘的半径和自然环境下拍摄柑橘图像的光照角度3方面进行Faster RCNN检测柑橘的效果分析,与Otsu检测结果进行对比分析,Faster RCNN具有较高的泛化性能以及检测精度。

参 考 文 献

- 1 陈磊,陈帝伊,马孝义. 果蔬采摘机器人的研究[J]. 农机化研究, 2011,33(1): 224-227.
CHEN Lei, CHEN Diyi, MA Xiaoyi. Researching on the fruit and vegetable harvesting robot[J]. Journal of Agricultural Mechanization Research, 2011,33(1): 224-227. (in Chinese)
- 2 徐铭辰,牛媛媛,余永昌. 果蔬采摘机器人研究综述[J]. 安徽农业科学, 2014(31): 11024-11027.
XU Mingchen, NIU Yuanyuan, YU Yongchang. Review of research on picking robots of fruits and vegetables[J]. Journal of Anhui Agricultural Sciences, 2014(31): 11024-11027. (in Chinese)
- 3 ARIVAZHAGAN S, SHEBIAH R N, NIDHYANANDHAN S S, et al. Fruit recognition using color and texture features[J]. Journal of Emerging Trends in Computing and Information Sciences, 2010, 2(1): 90-94.
- 4 XU Y, IMOU K, KAIZU Y, et al. Two-stage approach for detecting slightly overlapping strawberries using HOG descriptor[J]. Biosystems Engineering, 2013, 115(2): 144-153.
- 5 MOGHIMI A, AGHKHANI M H, MAHMOOD R, et al. A robo-vision algorithm for automatic harvesting of green bell pepper[C]//ASABE Annual International Meeting, 2015: 2-10.
- 6 IVORRA E, SÁNCHEZ A J, CAMARASA J G, et al. Assessment of grape cluster yield components based on 3D descriptors using stereo vision[J]. Food Control, 2015, 50: 273-282.
- 7 马晓丹,刘刚,周薇,等. 基于量子遗传模糊神经网络的苹果果实识别[J/OL]. 农业机械学报, 2013, 44(12): 227-232, 251. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20131238&flag=1. DOI:10.6041/j.issn.1000-1298.2013.12.038.
MA Xiaodan, LIU Gang, ZHOU Wei, et al. Apple recognition based on fuzzy neural network and quantum genetic algorithm[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(12): 227-232, 251. (in Chinese)
- 8 宋西平,李国琴,罗陆锋,等. 基于HSI色彩空间与FFCM聚类的葡萄图像分割[J]. 农机化研究, 2015,37(10): 40-44.
SONG Xiping, LI Guoqin, LUO Lufeng, et al. Segmentation of grapes image based on HSI color space and FFCM clustering algorithm[J]. Journal of Agricultural Mechanization Research, 2015,37(10): 40-44. (in Chinese)
- 9 沈甜. 苹果采摘机器人重叠果实快速动态识别及定位研究[D]. 镇江: 江苏大学, 2016.
SHEN Tian. Research on fast dynamic recognition and location of overlapping fruit for apple harvesting robot[D]. Zhenjiang: Jiangsu University, 2016. (in Chinese)
- 10 KURTULMUS F, LEE W S, VARDAR A. Green citrus detection using 'eigenfruit', color and circular Gabor texture features under natural outdoor conditions[J]. Computers and Electronics in Agriculture, 2011, 78:140-149.
- 11 张春龙,张楫,张俊雄,等. 近色背景中树上绿色苹果识别方法[J/OL]. 农业机械学报, 2014, 45(10): 277-281. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20141043&flag=1. DOI:10.6041/j.issn.1000-1298.2014.10.043.
ZHANG Chunlong, ZHANG Ji, ZHANG Junxiong, et al. Recognition of green apple in similar background[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2014, 45(10): 277-281. (in Chinese)
- 12 ZHAO Chuanyuan, LEE Won Suk, HE Dongjian. Immature green citrus detection based on colour feature and sum of absolute transformed difference (SATD) using colour images in the citrus grove[J]. Computers and Electronics in Agriculture, 2016, 124: 243-253.
- 13 赵源深,贡亮,周斌,等. 番茄采摘机器人非颜色编码化目标识别算法研究[J/OL]. 农业机械学报, 2016, 47(7):1-7. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20160701&flag=1. DOI:10.6041/j.issn.1000-1298.2016.07.001.
- 14 ZHAO Yuanshen, GONG Liang, ZHOU Bin, et al. Object recognition algorithm of tomato harvesting robot using non-color coding approach[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(7):1-7. (in Chinese)
- 15 高震宇,王安,刘勇,等. 基于卷积神经网络的鲜茶叶智能分选系统研究[J/OL]. 农业机械学报, 2017,48(7): 53-58. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20170707&flag=1. DOI:10.6041/j.issn.1000-1298.2017.07.007.
- 16 GAO Zhenyu, WANG An, LIU Yong, et al. Intelligent fresh-tea-leaves sorting system research based on convolution neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(7): 53-58. (in Chinese)
- 17 REN Shaoqing, HE Kaiming, GIRSHICK R, et al. Faster RCNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6):1137-1149.
- 18 GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- 19 GIRSHICK R. Fast-RCNN[C]//IEEE International Conference on Computer Vision, 2015: 1440-1448.
- 20 桑军,郭沛,项志立,等. Faster-RCNN的车型识别分析[J]. 重庆大学学报:自然科学版, 2017,40(7): 32-36.
SANG Jun, GUO Pei, XIANG Zhili, et al. Vehicle detection based on Faster-RCNN[J]. Journal of Chongqing University: Natural Science Edition, 2017,40(7): 32-36. (in Chinese)
- 21 JIANG H, LEARNEDMILLER E. Face detection with the Faster RCNN[C]//2017 12th IEEE International Conference on Automatic Face & Gesture Recognition, 2016:650-657.
- 22 SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. Computer Science, 2014, ArXiv Preprint ArXiv: 1409.1556.
- 23 LECUN Y, BOSER B, DENKER J S, et al. Backpropagation applied to handwritten zip code recognition[J]. Neural Computation, 1989, 1(4): 541-551.