

自然环境下树上绿色芒果的无人机视觉检测技术

熊俊涛 刘振林 睿 陈淑绵 陈伟杰 杨振刚

(华南农业大学数学与信息学院, 广州 510642)

摘要: 为了快速检测芒果树上的芒果,提出了一种基于无人机的树上绿色芒果视觉检测方法。采用深度学习技术,利用YOLOv2模型对无人机采集的绿色芒果图像进行检测,首先通过无人机采集树上绿色芒果图像,对芒果图像进行人工标记,建立芒果图像的训练集和测试集,通过试验确定训练模型的批处理量和初始学习率,并在训练模型时根据训练次数逐渐降低学习率,最终训练的模型在训练集的平均精度(Mean average precision, MAP)为86.43%。试验分析了包含不同果实数和不同光照条件下绿色芒果图像的识别正确率,并进行了芒果产量估计试验,试验结果表明:本文算法检测一幅图像的平均运行时间为0.08 s,对测试集的识别正确率为90.64%,识别错误率为9.36%;对含不同果实数的图像识别正确率为88.05%~94.55%,顺光条件下识别正确率为93.42%,逆光条件下识别正确率为87.18%;对芒果产量估计的平均误差为12.79%。本文算法对自然环境下树上绿色芒果有较好的检测效果,可为农业智能化生产中果蔬产量的估计提供技术支持。

关键词: 无人机; 绿色芒果; 深度学习技术; 视觉检测

中图分类号: TP391.41 **文献标识码:** A **文章编号:** 1000-1298(2018)11-0023-07

Unmanned Aerial Vehicle Vision Detection Technology of Green Mango on Tree in Natural Environment

XIONG Juntao LIU Zhen LIN Rui CHEN Shumian CHEN Weijie YANG Zhengang
(College of Mathematics and Informatics, South China Agricultural University, Guangzhou 510642, China)

Abstract: In order to detect the mango yield on trees rapidly, a green mango visual detection method based on unmanned aerial vehicle (UAV) was proposed. The deep learning technology and the YOLOv2 model were adopted to detect the mango images captured by UAV. Firstly, totally 471 images of the mango on trees were collected by the UAV. To meet the demand of diversity, totally 360 images included different shooting distances and different lighting situations were selected. Among which, 300 images were selected randomly as the training set, the other 60 images were used as the test set. Also, the shooting plan of the whole tree was designed. By image collecting and image mosaic, the integrated images of five mango trees were worked out for the yield estimating experiment of mango. After image collection, these images were marked manually and used to build the training set and the test set. The batch size and the initial learning rate were determined by experiments. During the model training, the learning rate was reduced gradually as the training times were changed. The mean average precision (MAP) of the trained model on the training set was 86.43%. By designing the experiments, the accuracy of mango recognition with images that containing different fruit numbers and different lighting conditions was worked out. Also, the yield estimation experiment was designed. The experimental results showed that the average running time of an image using the given algorithm was 0.08 s, while the accuracy of the test set was 90.64% and the false recognition rate was 9.36%; the highest recognition accuracy of image with different numbers of fruits was 94.55% and the lowest was 88.05%. The recognition accuracy was 93.42% under the condition of direct sunlight, and the recognition accuracy was 87.18% under the condition of backlight. The average error of the yield estimation of mango tree was

收稿日期: 2018-06-20 修回日期: 2018-07-21

基金项目: 国家自然科学基金项目(31201135, 31571568)、广东省自然科学基金项目(2018A030313330)和广州市科技计划项目(201802020032)

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: 杨振刚(1976—),男,副教授,主要从事机器视觉与虚拟现实的关键技术研究,E-mail: yzg@scau.edu.cn

12.79%。The result demonstrated that the algorithm was effective for mango in natural environment, which can provide technical support for estimating the yield of fruits and vegetables in intelligent agricultural production.

Key words: unmanned aerial vehicle; green mango; deep learning technique; visual detection

0 引言

农业航空技术开始于20世纪20年代,如今已经成为世界各国农业领域的重要技术之一^[1]。由于无人机具有工作适用性、灵活性和机动性等优势,近年来在农业领域得到了诸多应用,并逐渐成为现代农业工程一种新型设备^[2-3]。

国内外关于农用无人机的研究主要集中在病虫害的监控^[4-8]以及农药喷洒^[9-13]方面,因无人机的空中作业机动性和灵活性较好,也逐渐应用于农作物产量估计上。李昂等^[14]利用无人机拍摄从抽穗期到成熟期的水稻冠层影像,根据水稻图像的颜色特征对图像进行分割,提取出水稻穗数量并代入水稻产量估算公式进行估产。赵晓庆等^[15]利用无人机获取大豆多个生育期的高光谱数据,并对采样空间尺度进行优化选择,得到能较准确估计大豆产量的采样空间尺度。HUANG等^[16]使用无人机拍摄高分辨率的彩色图像,利用从棉花田获取的多个彩色图像,提取三维点云数据,计算棉花的高度,从而估计棉花产量。此外,SENTHILNATH等^[17]利用无人机获取的高分辨率图像估计西红柿产量,CARL等^[18]通过无人机获取的图像估计黑槐花和花蜜的产量,YU等^[19]开发了一种基于无人机的高通量表型分析(High throughput phenotyping, HTP)平台,在大豆生长阶段收集高分辨率多光谱图像,并设计了一种大豆产量估计模型。

从国内外研究可知,使用无人机估计农作物产量的研究对象主要集中于地面生长高度较低的水稻、大豆和棉花等农作物上,较少使用无人机进行树上水果产量估计。而对树上水果产量估计的研究,主要集中在使用地面拍摄设备获取图像^[20-23]。对于较高且树冠面积较大的果树,使用地面拍摄设备只能拍摄到离地面较近树冠的水果,而长在高处的水果,只能远距离拍摄或者以仰视的角度拍摄,很难拍摄到树冠顶部的水果。无人机则可以克服这个缺点,实现从空中拍摄到树冠高处和树冠顶部的水果。本文提出一种基于无人机的树上绿色芒果的视觉检测技术,利用无人机获取芒果图像,制作训练集,训练用于识别绿色芒果的YOLOv2模型,实现树上芒果的准确识别,为芒果产量的智能化估计提供视觉技术支持。

1 图像采集及图像拼接

所用无人机为大疆 PHANTOM 3 STANDARD 型四轴飞行器,如图1a所示,其自带的相机拍摄图像的分辨率为4 000像素×3 000像素,影像最大光圈是F2.8,94°广角定焦镜头,等效焦距20 mm,拍摄时手动控制在距离芒果树1.5~2 m处进行拍摄,如图1b所示。图像拍摄时间为08:00—10:00,共拍摄471幅图像用于图像识别算法研究,为满足样本的多样性,挑选出包含不同距离和光照情况的图像,共挑选出360幅图像,如图2所示。随机选取300幅图像作为训练集,剩余60幅图像作为测试集。



图1 图像采集现场

Fig. 1 Image acquisition scene



图2 无人机采集到的芒果图像

Fig. 2 Mango images collected by unmanned aerial vehicle

为得到整棵树的图像,在采集图像时,手动控制无人机在距离芒果树1.5~2 m处拍摄图像,分两次拍摄树的两侧,如图3a所示。在采集单侧图像时,从树的左上角开始拍摄,从上往下,如图3b所示,按数字顺序采集整棵树的图像,其中相邻两幅图像的重叠位置用于图像拼接,本文使用基于SURF的图像拼接算法^[24],按拍摄顺序依次拼接图像,得到整棵树一侧的图像,结合两侧可以得到一棵树完整的图像。本文挑选5棵树进行拍摄,先人工计算没有被遮挡、直接可见的芒果数量,然后再进行图像采

集,用于验证模型的有效性。

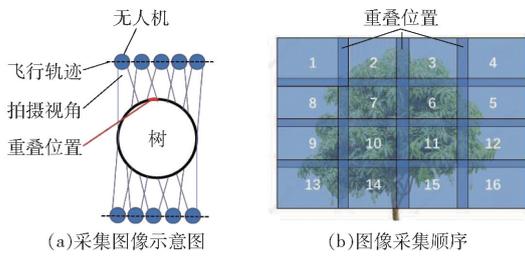


图 3 图像采集

Fig. 3 Image acquisition

2 基于 YOLOv2 的绿色芒果视觉检测方法

近年来深度学习在目标检测领域取得了较大的进展, GIRSHICK 等^[25]提出了区域卷积神经网络(RCNN),在 VOC2012 数据集上平均精度提高了 30%,达到了 53.3%。在 RCNN 的基础上, GIRSHICK^[26]和 REN 等^[27]提出了快速区域卷积神经网络(Fast RCNN)和超快速卷积神经网络(Faster RCNN),在提高检测正确率的同时增加了检测速率,检测速率达 5 f/s。REDMON 等^[28]提出了 YOLO 模型,平均精度达 63.4%,检测速率达到 45 f/s。随后,REDMON 等^[29]在 YOLO 模型的基础提出了 YOLOv2 模型,在 VOC2007 上平均识别精度(MAP)达 76.8%,识别速率达到 67 f/s。

参照文献[30]的思想,将分类和定位整合到同一个网络当中,与之前大部分目标检测框架使用的特征提取网络 VGG-16 相比, YOLO 模型使用类似 goolnet 的网络结构,计算量小于 VGG-16,能在保证正确率的同时拥有较快的检测速率,标准的 YOLO 模型检测速率达到 45 f/s, Fast YOLO 模型检测速率达到了 155 f/s,但正确率略低于 VGG-16。YOLOv2 模型以 Darknet-19 为基础网络模型,包含了 19 个卷积层和 5 个最大池化层,在保持 YOLO 模型检测速率的同时提升了检测精度,使用分辨率为 544 像素 × 544 像素的图像时, YOLOv2 模型在 VOV2007 数据集上可以在正确率比 Faster RCNN 高的情况下,处理速率达到 40 f/s,如表 1 所示。

使用 YOLOv2 模型作为树上芒果的检测方法,先对 300 幅训练集图像进行人工标记,标记图像中的感兴趣区域(Region of interest, ROI),然后用标记好的图像通过预训练,调整 YOLOv2 模型网络参数,最后用调整好的参数训练 YOLOv2 模型网络,如图 4 所示。

2.1 标记训练数据集

YOLOv2 模型需要人工设置标签,根据人工设置的标签进行自我学习,要测试模型检测的精度,也需要对测试集进行人工标记感兴趣区域。所以在训

表 1 目标检测模型性能对比

Tab. 1 Performance comparison of object detection box

检测模型	MAP/%	检测速率/(f·s ⁻¹)
Fast RCNN	70.0	0.5
Faster RCNN VGG-16	73.2	7
Faster RCNN ResNet	76.4	5
YOLO	63.4	45
SSD300	74.3	46
SSD500	76.8	19
YOLOv2(288 像素 × 288 像素)	69.0	91
YOLOv2(352 像素 × 352 像素)	73.7	81
YOLOv2(416 像素 × 416 像素)	76.8	67
YOLOv2(480 像素 × 480 像素)	77.8	59
YOLOv2(544 像素 × 544 像素)	78.6	40



图 4 模型训练流程

Fig. 4 Model training process

练模型之前,需要对训练集和测试集图像进行人工标记感兴趣区域,并记录标记的矩形框的右上角坐标和矩形框的长、宽作为 YOLOv2 的输入。为了使模型有较高的检测效果,标注的样本中包含了不同光照角度和不同拍摄距离的芒果样本,同时适当加入了遮挡的芒果。在 300 幅训练集图像中,共标记出 2 542 个芒果样本,部分芒果样本如图 5 所示,其中顺光样本 1 673 个,占样本总数的 65.81%,逆光样本 869 个,占样本总数的 34.19%,其中有遮挡的样本中,顺光样本 293 个,逆光样本 125 个,共有 418 个样本,占样本总数的 16.44%。

2.2 模型参数选择

训练模型时,输入图像的分辨率、批处理量(batch)、学习率都会影响最终模型的检测效果,因此在训练模型之前,需要选择合适的参数。本文训练使用的操作系统为 Ubuntu 16.04,训练使用框架为 Darknet,CPU 为 i7-8700,主频为 3.2 GHz,六核十二线程,内存 32 GB,显卡为 GeForce GTX 1080,显存为 8 GB,使用 YOLOv2 官方提供的预训练模型对数据集进行训练。因为 40 f/s 的速率可以满足实际应用的要求,而识别精度则越高越好,因此,输入图像分辨率设定为 544 像素 × 544 像素。

2.2.1 批处理量

在训练模型的过程中,为准确计算损失函数对

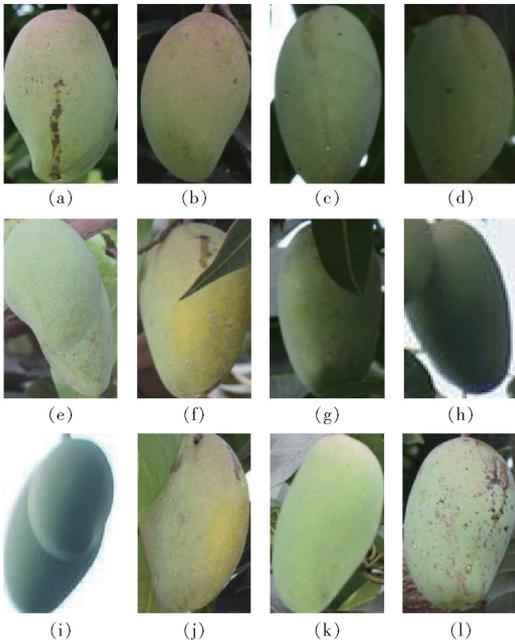


图5 训练样本示例

Fig. 5 Examples of training sample

参数的梯度,需要对数据集上的每一个样本进行计算,对于深度神经网络而言,这样做计算量会非常巨大。所以,一般在训练深度神经网络时,会分批从数据集中抽取少量的图像,然后计算这批图像的平均值,抽取图像的数量即为批处理量(batch),但批处理量太小会造成模型无法收敛的情况,批处理量太大会使收敛速率变慢,因此要选择合适的批处理量。本文分别选取16、32、64、128、256作为批处理量,其他参数使用默认值,其中学习率为0.01,对模型训练500次的平均精度进行比较,如表2所示。

表2 不同批处理量模型的平均精度对比

Tab. 2 Performance comparison of model with different batches

批处理量	16	32	64	128	256
MAP/%	56.29	67.49	74.37	76.16	77.57

从表2可以看出,其他参数不变的情况下,随着批处理量的增大,训练500次模型的检测精度逐渐增大,但MAP并非随着批处理量的增大而线性增大,当批处理量从16增大到64时,MAP增大了18.08个百分点,而批处理量从64增大到256时MAP只增大了3.20个百分点,而批处理量增大会使训练时间明显增加,综合考虑检测精度和训练时间两个因素,本文选择64作为批处理量。

2.2.2 学习率

学习率的大小影响模型的收敛速率,学习率太小,会使模型收敛缓慢,学习率太大,会使代价函数震荡,甚至无法收敛。从表2可以看出,当批处理量为64,学习率为0.01时,模型训练500次MAP为

74.37%,检测精度高于70%,收敛速率较快,而且还未达到收敛,所以本文设置初始学习率为0.01,前500次学习率保持不变,之后每训练100次,学习率变为当前学习率的0.95倍。

2.3 模型训练与测试

基于YOLOv2官方提供的预训练模型,根据预训练得到的参数对测试集进行训练,其中批处理量为64,初始学习率为0.01,在训练次数达到500次以后,每训练100次学习率变为当前学习率的0.95倍,其他参数使用YOLOv2默认的参数,其中动量系数为0.9,网络损失值变化情况如图6所示。

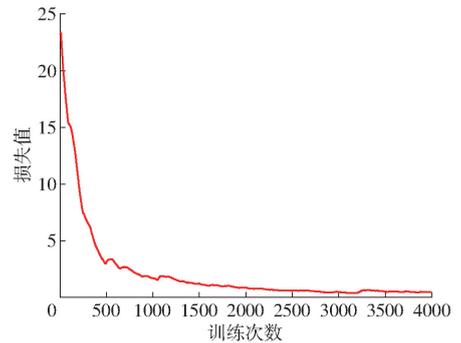


图6 训练阶段损失值变化情况

Fig. 6 Change of loss value in training stage

从图6可以看出,随着训练次数的增加,损失值逐渐减小,前500次训练损失值变化较大,训练次数达到500以后损失变化趋于平缓,当训练次数达到2500以后损失值趋于平稳,从2500次到4000次时,损失值一直稳定在0.1~0.2,因此暂停训练,选择训练2500、3000、3500、4000次的模型,使用60幅测试集图像进行测试,测试结果如表3所示。

表3 不同训练次数的模型检测平均精度对比

Tab. 3 Performance comparison of model with different numbers of training

训练次数	2 500	3 000	3 500	4 000
MAP/%	85.87	86.43	86.21	86.23

从表3可以发现,当训练次数达到2500以后,模型的MAP变化较小,当训练次数为3000时,模型的MAP最高,因此选择训练次数为3000时的模型作为本文的芒果检测模型,经测试使用GeForce GTX 1080显卡运行模型时,检测一幅图像的平均时间为0.08s,其中部分检测结果如图7所示。

3 试验与结果分析

为检测本文算法对果实识别的准确性,本文设计了果实识别试验,对测试集中的60幅图像进行识别测试,部分识别结果如图7所示。因为芒果是单

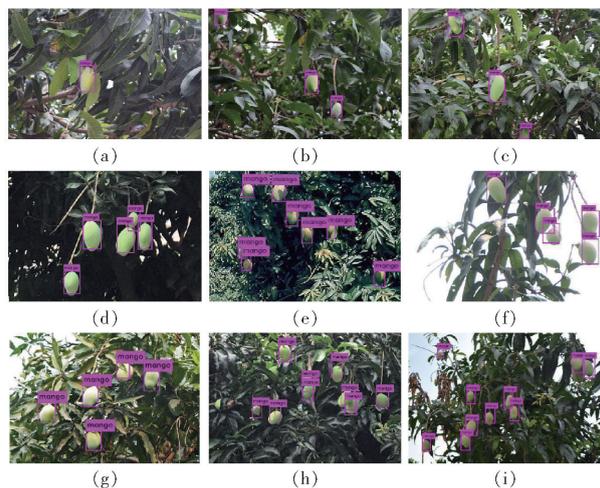


图 7 树上芒果图像的检测结果

Fig. 7 Detection results of mango image on tree

个生长的,所以本文通过计算正确识别芒果的个数和错误识别芒果的个数作为识别正确率的标准,错误识别数为假阴数和假阳数之和,其中假阴包含漏识别和一框多果两种情况,没有被框标记出来的芒果记为漏识别,一框多果,只记为正确识别一个,其余果记为假阴,例如一个框包含两个果,算正确识别一个,假阴一个;假阳包含误识别和一果多框两种情况,矩形框将背景框出来记为误识别,同时一个果包含多个框,只记为正确识别一个,其余框记为假阳。统计 60 幅测试集图像中,共有 438 个芒果,芒果的识别统计结果如表 4 所示。438 个芒果中有 397 个芒果被正确识别,识别正确率为 90.64%,错误识别的芒果数为 41 个,识别错误率为 9.36%,其中假阴(漏识别,一框多果)25 个,假阳(误识别,一果多框)16 个。为测试不同情况下本文算法的识别正确率,本文分别按图像中含果实数和图像光照情况进行进一步统计分析。

表 4 图像检测结果统计

Tab. 4 Statistics of detection results of images

类别	假阴		假阳	
	漏识别	一框多果	误识别	一果多框
芒果数	18	7	5	11
百分比/%	4.11	1.60	1.14	2.51

同时利用 Otsu、K-means、模糊 C 均值聚类(Fuzzy C-means clustering, FCM)算法对 60 幅测试集图像进行识别,与本文算法进行对比,识别结果如表 5 所示。由表 5 可知,因为绿色芒果和背景(树叶)都为绿色,芒果和背景的颜色区别不明显,使用 Otsu、K-means、FCM 3 种算法识别的正确率较低,这 3 种算法中,FCM 算法有较高的识别正确率,识别正确率为 82.42%,Otsu 有较高的运行速率,识别一副图像的平均时间为 0.09 s。本文算法识别正确率为

90.64%,识别一幅图像的平均时间为 0.08 s,与 Otsu、K-means 及 FCM 算法相比,本文算法有较高的识别正确率和运行速率。

表 5 不同识别算法性能对比

Tab. 5 Comparison of segmentation algorithms

算法	正确率/%	时间/s
Otsu	79.68	0.09
K-means	80.82	0.82
FCM	82.42	0.91
本文算法	90.64	0.08

3.1 不同果实数的图像检测结果分析

在自然环境下拍摄的芒果图像,往往一幅图像中所拍摄的芒果数量是不同的,图像中含果实数目的不同会对检测结果造成不同的影响,如果图像中只有一个芒果,所拍摄的芒果一般比较完整清晰,比较容易识别。相对单果图像而言,如果一幅图像中含有多个芒果,可能会出现 2 个或多个果实粘连或者相互遮挡的情况,增加检测难度。因此本文按图像中含果实的数量分 3 个梯度对 60 幅测试集的检测结果进行了统计,3 个梯度分布为图像中果实数小于 5、图像中果实数为 5~10 以及图像中的果实数大于 10,含不同果实数图像检测结果统计如表 6 所示。

表 6 含不同果实数的图像检测结果统计

Tab. 6 Statistics of detection results of images with different quantities of fruits

图像中含果实数	图像总数/幅	果实总数	识别正确		识别错误	
			数量	百分比/%	数量	百分比/%
<5	19	55	52	94.55	3	5.45
5~10	24	157	146	92.99	11	7.01
>10	17	226	199	88.05	27	11.95
总计	60	438	397	90.64	41	9.36

由表 6 可以看出,随着图像中果实数量的增加,识别正确率下降,识别错误率上升。是因为随着果实数量的增加,多个果实粘连和遮挡情况越多,当图像含果实数较多时,几乎每幅图像都有粘连和遮挡情况发生,虽然通过边缘检测分隔了部分粘连的果实,但还是有相互粘连和遮挡的果实会被识别为一个果实,降低识别正确率。除此之外,含果实数量较多的图像,一般拍摄距离较远,因此背景会比较复杂,图像中的芒果也比较小,比较模糊,从而导致识别正确率降低,识别错误率增加。

3.2 不同光照情况下图像检测结果分析

在自然环境下,拍摄时的光照角度不同也会影响检测的效果,在顺光条件下拍摄的图像一般比较明亮清晰,在逆光条件下拍摄的图像会比较阴暗模

糊。因此,本文将60幅测试集图像的检测结果分为顺光和逆光两组进行统计分析,统计结果如表7所示。

表7 不同光照情况下图像检测结果统计

Tab.7 Statistics of image test results of different illumination conditions

光照情况	图像总数/幅	果实总数	识别正确		识别错误	
			数量	百分比/%	数量	百分比/%
顺光	34	243	227	93.42	16	6.58
逆光	26	195	170	87.18	25	12.82
总计	60	438	397	90.64	41	9.36

从表7可以看出,在逆光条件下的检测效果明显比顺光条件下的检测效果差,因为在逆光环境下拍摄的图像比较暗,果实和背景的颜色分量值均降低,各分量值的对比度降低,边缘特征和颜色特征也被弱化,从而增加了逆光条件下的检测难度。

3.3 整棵树芒果数量检测结果分析

为进一步验证模型的有效性,本文选择5棵树,先人工计算没有被遮挡、直接可见的芒果数量,然后再按第1节中的方法进行图像采集和拼接得到整棵树的图像,用本文算法对图像进行检测,用算法检测出来的芒果数量与人工计算的芒果数量进行对比验证。用算法检测树两侧的图像得到整棵树上芒果的数量,统计结果如表8所示。

表8 整棵树芒果数量检测结果统计

Tab.8 Statistics of mango count test results

芒果树序号	人工计算芒果个数	算法检测芒果个数			误差/%	
		识别正确数	正确率/%	假阳总计		
1	251	207	82.47	15	222	11.55
2	274	217	79.20	17	234	14.60
3	286	232	81.12	19	251	12.24
4	313	245	78.27	31	276	11.82
5	354	277	78.25	29	306	13.56
总计	1478	1178		111	1289	
平均			79.70			12.79

其中,总计为正确识别的芒果数量加上假阳(误识别,一果多框)数量,即算法检测出来的芒果

数量,误差计算公式为

$$E = \left| \frac{T_p + F_p - R}{R} \right| \times 100\% \quad (1)$$

式中 E ——误差,% T_p ——正确识别数

R ——人工计算芒果个数

F_p ——假阳数量

由表8可知,总的识别正确率为79.70%,远低于3.1节和3.2节的正确率,这主要是因为采集图像时,只从2个角度获取芒果树图像,有些芒果在这2个角拍摄不到,而人工计数时可以看到。从误差来看,算法统计的芒果数量小于人工统计的芒果数量,而且误差范围集中在11%~15%之间,平均误差为12.79%,在实际应用时,可统计多棵芒果树的误差,再根据多棵果树的平均误差和算法检测的芒果数,估计芒果的实际产量。

4 结论

(1)提出了一种自然环境下树上绿色芒果的无人视觉检测技术,使用无人机采集图像,对图像进行人工标记感兴趣区域,通过预训练确定了YOLOv2模型训练的批处理量和学习率,利用预训练确定的训练参数训练YOLOv2模型,最终训练得到的模型在测试集上的平均精度为86.43%。

(2)本算法对芒果识别具有较高的正确率,60幅测试集图像中共拍摄到438个芒果,正确识别的芒果有397个,识别正确率为90.64%,识别错误率为9.36%。对含不同果实图像识别的正确率如下:含果实数小于5的图像,识别正确率为94.55%;含果实数5~10的图像,识别正确率为92.99%;含果实数大于10的图像,识别正确率为88.05%。不同光照条件下识别正确率如下:顺光条件下识别正确率为93.42%,逆光条件下识别正确率为87.18%。

(3)本算法识别一幅图像的平均时间为0.08s,对于不同情况下的芒果识别正确率较高,使用无人机可以快速准确地估计芒果的产量,为果园自动化管理和收获提供方法支持与参考。

参 考 文 献

- 杨陆强,果霖,朱加繁,等.我国农用无人机发展概况与展望[J].农机化研究,2017,39(8):6-11.
YANG Luqiang, GUO Lin, ZHU Jiafan, et al. The development situation and prospect of agricultural UAV in China[J]. Journal of Agricultural Mechanization Research, 2017, 39(8): 6-11. (in Chinese)
- 周超,向绪友,钟旭,等.无人机在农业中的应用及展望[J].湖南农业科学,2017(11):80-82,86.
ZHOU Chao, XIANG Xuyou, ZHONG Xu, et al. Application and prospect of unmanned aerial vehicle in agriculture[J]. Hunan Agricultural Sciences, 2017(11): 80-82, 86. (in Chinese)
- 张志云,李长贺.无人机技术在现代农业中的应用[J].农业工程,2016,6(4):23-25.
ZHANG Zhiyun, LI Changhe. Application of unmanned aerial vehicle technology in modern agriculture[J]. Agricultural Engineering, 2016, 6(4): 23-25. (in Chinese)
- 李宗南,陈仲新,王利民,等.基于小型无人机遥感的玉米倒伏面积提取[J].农业工程学报,2014,30(19):207-213.
LI Zongnan, CHEN Zhongxin, WANG Limin, et al. Area extraction of maize lodging based on remote sensing by small unmanned

- aerial vehicle[J]. Transactions of the CSAE, 2014, 30(19):207–213. (in Chinese)
- 5 贾鹏宇, 冯江, 于立宝, 等. 小型无人机在农情监测中的应用研究[J]. 农机化研究, 2015, 37(4): 261–264.
JIA Pengyu, FENG Jiang, YU Libao, et al. Small drones in the application of field monitoring research[J]. Journal of Agricultural Mechanization Research, 2015, 37(4): 261–264. (in Chinese)
- 6 杨贵军, 李长春, 于海洋, 等. 农用无人机多传感器遥感辅助小麦育种信息获取[J]. 农业工程学报, 2015, 31(21): 184–190.
YANG Guijun, LI Changchun, YU Haiyang, et al. UAV based multi-load remote sensing technologies for wheat breeding information acquirement[J]. Transactions of the CSAE, 2015, 31(21):184–190. (in Chinese)
- 7 ZHAO T, STARK B, CHEN Y Q, et al. Challenges in water stress quantification using small unmanned aerial system (SUAS): lessons from a growing season of almond[J]. Journal of Intelligent & Robotic Systems, 2017(9): 1–15.
- 8 UTO K, SEKI H, SAITO G, et al. Characterization of rice paddies by a UAV-mounted miniature hyperspectral sensor system[J]. IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing, 2013, 6(2): 851–860.
- 9 张东彦, 兰玉彬, 陈立平, 等. 中国农业航空施药技术研究进展与展望[J/OL]. 农业机械学报, 2014, 45(10):53–59.
http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20141009&flag=1. DOI:10.6041/j.issn.1000-1298.2014.10.009.
- ZHANG Dongyan, LAN Yubin, CHEN Liping, et al. Current status and future trends of agricultural aerial spraying technology in China[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2014, 45(10):53–59. (in Chinese)
- 10 王大帅, 张俊雄, 李伟, 等. 植保无人机动态变量施药系统设计与试验[J/OL]. 农业机械学报, 2017, 48(5):86–93.
http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20170510&flag=1. DOI:10.6041/j.issn.1000-1298.2017.05.010.
- WANG Dashuai, ZHANG Junxiong, LI Wei, et al. Design and test of dynamic variable spraying system of plant protection UAV [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(5):86–93. (in Chinese)
- 11 许童羽, 于丰华, 曹英丽, 等. 粳稻多旋翼植保无人机雾滴沉积垂直分布研究[J/OL]. 农业机械学报, 2017, 48(10): 101–107.
http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20171012&flag=1. DOI:10.6041/j.issn.1000-1298.2017.10.012.
- XU Tongyu, YU Fenghua, CAO Yingli, et al. Vertical distribution of spray droplet deposition of plant protection multi rotor UAV for japonica rice [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(10):101–107. (in Chinese)
- 12 XUE X, LAN Y, SUN Z, et al. Develop an unmanned aerial vehicle based automatic aerial spraying system[J]. Computers & Electronics in Agriculture, 2016, 128: 58–66.
- 13 CHEN Y, ZHU H, OZKAN H E. Development of variable-rate sprayer with laser scanning sensor to synchronize spray outputs to tree structures[J]. Transactions of the ASABE, 2012, 55(3): 773–781.
- 14 李昂, 王洋, 曹英丽, 等. 基于无人机高清数码影像的水稻产量估算[J]. 沈阳农业大学学报, 2017, 48(5): 629–635.
LI Ang, WANG Yang, CAO Yingli, et al. Rice yield estimation based on high-definition digital image of UAV[J]. Journal of Shenyang Agricultural University, 2017, 48(5): 629–635. (in Chinese)
- 15 赵晓庆, 杨贵军, 刘建刚, 等. 基于无人机电载高光谱空间尺度优化的大豆育种产量估算[J]. 农业工程学报, 2017, 33(1): 110–116.
ZHAO Xiaoqing, YANG Guijun, LIU Jian'gang, et al. Estimation of soybean breeding yield based on optimization of spatial scale of UAV hyperspectral image[J]. Transactions of the CSAE, 2017, 33(1): 110–116. (in Chinese)
- 16 HUANG Y, BRAND H J, SUI R, et al. Cotton yield estimation using very high-resolution digital images acquired with a low-cost small unmanned aerial vehicle[J]. Transactions of the ASAE, 2016, 59(6): 1563–1574.
- 17 SENTHILNATH J, DOKANIA A, KANDUKURI M, et al. Detection of tomatoes using spectral-spatial methods in remotely sensed RGB images captured by UAV[J]. Biosystems Engineering, 2016, 146: 16–32.
- 18 CARL C, LANDGRAF D, MAATEN T, et al. *Robinia pseudoacacia* L. flowers analyzed by using an unmanned aerial vehicle (UAV)[J]. Remote Sensing, 2017, 9(11): 1091.
- 19 YU N, LI L, SCHMITZ N, et al. Development of methods to improve soybean yield estimation and predict plant maturity with an unmanned aerial vehicle based platform[J]. Remote Sensing of Environment, 2016, 187:91–101.
- 20 BARGOTI S, UNDERWOOD J P. Image segmentation for fruit detection and yield estimation in apple orchards[J]. Journal of Field Robotics, 2017, 34(6):1039–1060.
- 21 DORJ U O, LEE M, YUN S S. An yield estimation in citrus orchards via fruit detection and counting using image processing[J]. Computers & Electronics in Agriculture, 2017, 140: 103–112.
- 22 LIU X, ZHAO D, JIA W, et al. A method of segmenting apples at night based on color and position information[J]. Computers & Electronics in Agriculture, 2016, 122(C): 118–123.
- 23 ZHAO C, LEE W S, HE D. Immature green citrus detection based on colour feature and sum of absolute transformed difference (SATD) using colour images in the citrus grove[M]. Elsevier Science Publishers B. V., 2016: 243–253.
- 24 GUI Y, SU A, DU J. Point-pattern matching method using SURF and shape context[J]. Optik-International Journal for Light and Electron Optics, 2013, 124(14):1869–1873.
- 25 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.
- 26 GIRSHICK R. Fast R-CNN[C]//IEEE International Conference on Computer Vision, 2015: 1440–1448.
- 27 REN Shaoqing, HE Kaiming, 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.
- 28 REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//Computer Vision and Pattern Recognition. IEEE, 2016:779–788.
- 29 REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]//IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society, 2017:6517–6525.
- 30 LIN Min, CHEN Qiang, YAN Shuicheng. Network in network[J]. Computer Science, 2014:1–10.