

doi:10.6041/j.issn.1000-1298.2019.05.021

基于深度卷积神经网络的柑橘目标识别方法

毕松 高峰 陈俊文 张潞

(北方工业大学电气与控制工程学院, 北京 100041)

摘要: 针对户外自然环境, 基于深度卷积神经网络设计了对光照变化、亮度不匀、前背景相似、果实及枝叶相互遮挡、阴影覆盖等自然环境下典型干扰因素具有良好鲁棒性的柑橘视觉识别模型。模型包括可稳定提取自然环境下柑橘目标视觉特征的深层卷积网络结构、可提取高层语义特征来获取柑橘特征图的深层池化结构和基于非极大值抑制方法的柑橘目标位置预测结构, 并基于迁移学习完成了柑橘目标识别模型训练。本文运用多重分割的方法提高了柑橘目标识别模型的多尺度图像检测能力和实时性, 利用包含多种干扰因素的自然环境下柑橘目标数据集测试, 结果表明, 柑橘识别模型对自然采摘环境下常见干扰因素及其叠加具有良好的鲁棒性和实时性, 识别平均准确率均值为 86.6%, 平均损失为 7.7, 平均单帧图像检测时间为 80 ms。

关键词: 自然环境; 柑橘; 识别; 深度卷积神经网络

中图分类号: TP391.4 **文献标识码:** A **文章编号:** 1000-1298(2019)05-0181-06

Detection Method of Citrus Based on Deep Convolution Neural Network

BI Song GAO Feng CHEN Junwen ZHANG Lu

(College of Electrical and Control Engineering, North China University of Technology, Beijing 100041, China)

Abstract: Citrus detection and location is the foundation of citrus automated picking systems, in light of the outdoor natural picking environment, a citrus visual feature recognition model was designed based on deep convolution neural network with good robustness for typical interfering factors, such as illumination change, uneven brightness, similar foreground and background, mutual occlusion of fruit, branches and leaves, shadow coverage and so on. The model included a deep convolutional network structure which can steadily extract the visual features of citrus under natural environment, a deep pool structure which can extract high-level semantic features to get citrus feature map, a citrus location prediction model based on non-maximum suppression method. Moreover, the proposed model was trained by transfer learning method. Each raw image was segmented into several sub-images before citrus detection to enhance the ability of multi-scale object detection, and reduce the computing time of citrus detection. A testing dataset, which contained representative interference factors of natural environment, was used to test the citrus detection model, and the proposed detection model had good robustness and real-time performance. The average detection accuracy and the average loss value of the model was 86.6% and 7.7, respectively, meanwhile, the average computing time for detecting citrus from single image was 80 ms. The citrus detecting model constructed by deep convolution neural network was suitable for the citrus harvesting in the natural environment.

Key words: natural environment; citrus; detection; deep convolution neural network

0 引言

我国为世界上重要的水果生产国之一, 自 2012 年以来, 我国柑橘、苹果等主要水果品种的种植面积和产量已居世界第一。2017 年, 我国柑橘产量为

3 816.78 万 t^[1], 占世界柑橘产量的四分之一。采摘是水果生产过程中劳动力投入最大的作业环节, 柑橘采摘劳动量为整个生产过程工作量的 50% ~ 70%, 所处环境的复杂性导致水果采摘仍然以人工作业为主^[2]。水果自动化采摘对于解决劳动力不

收稿日期: 2018-11-23 修回日期: 2019-02-02

基金项目: 国家自然科学基金项目(61573024)、北京市教育委员会科研计划一般项目(KM201610009001)和北方工业大学毓优青年人才培养计划项目

作者简介: 毕松(1983—), 男, 副教授, 博士, 主要从事智能农机装备研究, E-mail: bisongo@163.com

足、保证水果适时采摘、提高采摘品质和市场竞争力等具有重要意义。因此,研究水果自动化采摘技术迫在眉睫^[3]。

柑橘目标识别是自动采摘的基础,众多研究者主要从颜色、纹理、边缘等多个特征综合角度出发,研究了限定环境下或自然环境下果实目标识别方法^[4-17]。利用多种分类和聚类算法设计目标识别模型,获得了较好的目标检测效果。但上述方法的基础是从果实自身特征出发获得图像特征,当存在光线变化、阴影覆盖、着色不均、枝叶遮挡和果实重叠等多种自然采摘环境下常见干扰因素时,果实特征发生明显变化,使得用于描述果实的特征也出现明显的不同,因此基于图像特征的柑橘识别方法在自然环境下检测效果不理想。

自然环境下柑橘图像的特征在不同干扰因素下具有明显的差异。自然环境下干扰因素较多且变化较大,难以获得涵盖上述所有干扰情形的柑橘目标特征,因此基于图像分析的柑橘目标识别方法难以应对自然环境下多种干扰因素同时存在的情况。

针对户外柑橘采摘机器人的目标识别定位问题,本文设计基于深度卷积神经网络的自然环境下柑橘目标识别模型。对实际采收环境下的柑橘目标进行数据测试。

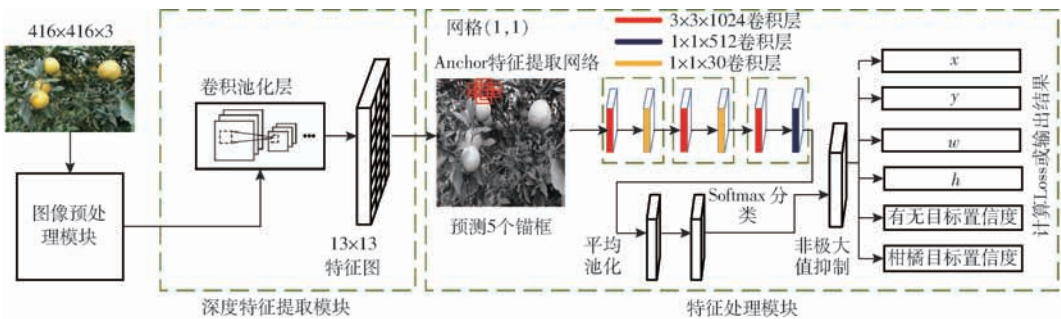


图1 自然环境下的柑橘识别模型网络结构

Fig.1 Network structure diagram of citrus recognition system in natural environment

图像预处理模块对图像进行降噪和数据扩展等操作,调节图像的色调、饱和度和亮度后,图像在输入网络之前进行预处理,尺寸缩放到416像素×416像素。深度特征提取模块实现了基于DARKNET19网络^[20]的卷积池化构建方法,提取完整图像的高阶特征,经过卷积池化层后得到13×13特征图。

特征处理模块分为区域生成网络模块(Region proposal network, RPN)和预测框特征提取分类模块。特征处理模块通过多个交叉的卷积层对特征降维,并利用池化操作提取柑橘图像的高阶特征,进而对特征进行分类。区域生成网络模块利用锚框

1 柑橘目标识别方法

基于图像的柑橘目标识别的基础在于获得可稳定描述自然环境下柑橘目标的图像特征,而大部分传统的目标特征提取方法都是在提取目标物体的浅层特征,如HOG特征、SIFT特征、颜色特征、局部二值特征等。这些人工设计的特征只适用于某些特定场景,复杂场景中表现的并不尽如人意,致使构建的目标识别模型难以满足复杂田间场景的需求,检测效果很不稳定。深度学习模型具有模型层次深、特征表达能力强的特点,能自适应地从大规模数据集中学习当前任务所需要的特征表达^[18],在目标识别领域,卢宏涛等^[19]认为使用深度学习方法提取到的特征具有传统手工特征所不具备的重要特性,其通过逐层训练学习,最终得到蕴涵清晰语义信息的特征表示,从而大大提高识别率。自然采摘环境的干扰因素多是典型的复杂场景,目标随环境干扰因素变化而难以获得完备的目标特征集,基于深度卷积神经网络模型的柑橘目标视觉识别方法,可以克服自然环境下的多种干扰条件影响,获得较高的识别准确性和稳定性。

基于深度卷积神经网络的柑橘识别模型主要分为图像预处理模块、深度特征提取模块、特征处理模块。柑橘识别模型结构如图1所示。

(Anchor boxes)方法在获得的特征图上预测初始预选框。利于K均值聚类(K-means clustering)算法求取锚框参数并预测出锚框尺寸和比例,K是聚类算法将样本集划分成簇的数量,实验测得K=5时锚框预测的正确率最高。深度特征提取模块中,图像经过卷积池化层后,特征图维数为13×13。对特征图的每个网格按照预测出的比例划出5个锚框(以图1中13×13特征图的第1行第1列网格为例,网格(1,1)表示该网格)并将这5个锚框映射回原图得到初始预选框。预测框特征提取分类模块的结构基于DARKNET19网络,在网络训练阶段移除DARKNET19网络最后一个卷积层,增加3个3×3×

1 024 的卷积层,并且在后面与 1 个 $1 \times 1 \times 512$ 的卷积层和 2 个 $1 \times 1 \times 30$ 的卷积层交叉,从而提高模型的特征抽取能力。由于经过多层卷积后特征向量的维度大幅增高,不利于数据分类与训练收敛,加大了网络的训练和预测时间,因此设计 3 层 3×3 卷积层和 3 层 1×1 卷积层交叉结构对特征降维,从而降低其深度以提高系统的训练效率与实时性。

将提取到的图像特征全局平均池化,并将其输入到 Softmax 层进行分类得出预测结果。预测结果包含 6 个元素:对应网格的偏移量 x 和 y 、预测出的柑橘目标边界框的宽度 w 和高度 h 、有无目标置信度(Box confidence score)和柑橘目标置信度。有无目标置信度表示该目标框包含柑橘目标的可能性,柑橘目标置信度表示如果包含柑橘目标,则该目标是柑橘的可能性,因此预测结果维度为 $(13, 13, 5 \times (4 + 1 + C))$,其中 C 是目标类别。由于只需检测柑橘,因此 $C = 1$,预测结果的维度即为 $(13, 13, 30)$ 。本文在训练阶段利用 Softmax 分类器将输出数值与标签数据比较得到其总损失,进而使用随机梯度下降(Stochastic gradient descent, SGD)优化损失函数使其收敛。在检测阶段,每个组合的结果分别是预选框位置相对于标签位置偏移量,有目标的置信度、以及有某个指定目标的置信度,柑橘识别模型只需要柑橘置信度,因此只有一类。

2 基于迁移学习的网络初始化

迁移学习利用预先训练好的具有良好学习能力的网络模型参数初始化某个小型训练集模型参数,这种参数初始化方法可以将已学习的知识能力迁移到另一个网络中,使得新网络具有快速学习能力^[21],从而显著改善因训练数据集不足带来的网络过拟合问题,增加识别模型在复杂自然条件下柑橘目标识别的泛化能力。

ImageNet 数据集是目前图像深度学习领域应用较广的数据集,与图像分类、定位、检测相关的工作大多基于此数据集展开,成为目前深度学习图像领域算法性能检验的“标准”数据集。本文使用标准 ImageNet1000 类数据集预训练柑橘识别模型。对于每个网格 5 个预选框给出的 30 个数值,每个目标只需要一个预选框预测器,根据预测区域与标签区域之间的重叠比例(IOU)最高值确定预测目标,从而使预测器更好地适应柑橘识别任务,从而改善整体召回率。训练期间的损失函数(Loss function)包含位置误差和分类误差。

若目标存在于该网格单元中,则损失函数仅惩罚分类错误;若预测器负责实际边界框,则也惩罚边

界框坐标错误。网络更加重视预测到目标的预测框,加入预测到目标的预测框系数 λ_{coord} 来提高其数值占比。在 VOC2007 数据集下,这一数值为 5,相应的,对于没有检测到目标的预测框,加入未预测到目标的预测框系数 λ_{noobj} 来降低其数值占比,本文取 0.5。在训练过程中,通过优化算法使得 Loss 函数收敛到最小。在预测阶段,由于网格设计强化了边界框预测中的空间多样性,一些较大或靠近多个网格单元边界的目标可能会被多个网格单元定位,因此本文使用非极大值抑制算法^[22]来修正多重检测,从而获得准确的识别结果。

3 迁移学习结果与分析

3.1 实验设计

为保证数据集能够较好地反映自然环境下柑橘目标的真实特点,在广西合浦柑橘种植园拍摄了 1 200 幅柑橘样本图像,拍摄时间包括晴天正午、晴天傍晚以及阴天正午 3 个时段。选用 Basler acA2440-20gc 型工业相机采集图像数据,采用焦距为 8 mm 的定焦镜头。经过人工挑选后制作了包括 1 000 幅柑橘图像的 VOC2007 格式的数据集。为保证训练集的有效性,训练集中包含光照不均图像 241 幅、前背景相似图像 134 幅、果实以及枝叶相互遮挡图像 246 幅、阴影覆盖图像 211 幅、过曝图像 168 幅。将 1 000 幅图像按照训练集、测试集、验证集 7:2:1 的比例配置。以端到端训练方式对上述训练集进行训练,并计算平均损失率和在全体测试集和验证集上的平均准确率(Mean average precision, MAP)。

同时为了验证本文方法的有效性,将可变性部件模型^[23](Deformable part model, DPM)与本文模型进行对比测试。DPM 算法提取目标的 HOG 特征,并使用支持向量机分类器,源码版本选择 voc-release 4.01,训练 50 000 次,数据集依然采用 VOC2007 格式,按照训练集、测试集 7:3 的配置分配训练。

3.2 实验数据性能指标计算方法

本文方法和 DPM 算法均使用 VOC2007 格式数据集和 P-R 曲线测试网络性能。P-R 曲线的数据插值方法使用 VOC2007 规范,即 11 点插值法(Eleven-point interpolation)。对于网络检测出来的目标,定为 Positive 样本,未检测出来的目标定为 Negative 样本。采用 0.5 为 IOU 阈值,大于 0.5 的认定为检测正确,检测结果为 T;反之,则为检测错误,检测结果为 F。故实验结果有 4 种,分别为检测出来的 IOU 值小于等于 0.5 的目标 FP、检测出来的

IOU 值大于 0.5 的目标 TP、未检测出来的真值目标 FN、TN。本文不统计 TN 类样本。准确率 (Precision) 的计算方法为

$$P = \frac{T_p}{T_p + F_p} \times 100\% \quad (1)$$

式中 T_p ——检测出来的 IOU 值大于 0.5 的目标数量

F_p ——检测出来的 IOU 值小于等于 0.5 的目标数量

召回率 (Recall) 为识别出的柑橘数占图像中总目标数的比例,其计算方法为

$$R = \frac{T_p}{T_p + F_N} \times 100\% \quad (2)$$

式中 F_N ——未检测出来的真值目标数量

3.3 结果分析

迁移学习具有良好的泛化能力且具有良好的抑制过拟合能力,本文利用迁移学习和非迁移学习训练柑橘目标识别模型,训练损失如图 2 所示。




图 2 迁移学习与非迁移学习方法训练损失

Fig. 2 Training loss of transfer learning and non-transfer learning methods

从图 2 可知,迁移学习可以使得训练过程更加平滑,在相同训练轮数下,其平均损失远低于未使用迁移学习。训练结束后,迁移学习在召回率大于后者的情况下,依然可以取得更好的平均准确率。两种训练方法的参数如表 1 所示。

表 1 迁移学习与非迁移学习训练参数

Tab. 1 Training parameters of transfer learning and non-transfer learning methods

训练参数	迁移学习	非迁移学习
初始学习率	0.01	0.01
学习动量	0.9	0.9
学习率衰减	0.000 5	0.000 5
每轮图像数	8	8
2 000 轮训练后学习率	0.001	跟随衰减

迁移学习与非迁移学习方法的基本训练参数相同,初始学习率取 0.01,动量为 0.9,学习衰减率为 0.000 5,每轮训练图像数量为 8。2 000 轮训练后,迁移学习的学习率固定,陷入局部最优。未使用迁

移学习的网络在达到局部最优后,即使降低学习率也并不能使得网络平均损失率明显下降。迁移学习和非迁移学习训练方法的平均损失、最大召回率和平均准确率如表 2 所示。

表 2 迁移学习与非迁移学习训练结果

Tab. 2 Training results of transfer learning and non-transfer learning methods

训练结果	迁移学习	非迁移学习
平均损失	7.7	20.5
最大召回率/%	93	82
MAP/%	86.9	78.3

由表 2 可知,非迁移学习训练的柑橘目标识别模型获得的平均损失为 20.5,本文通过降低学习率的方法使得平均损失下降了 12.8,最终平均损失达到了 7.7。训练结束后,在验证、测试数据集上计算平均准确率,分别为 86.9% 和 78.3%。基于迁移学习方法训练的模型平均损失较低,平均准确率较高,有效提高了模型的性能。

使用迁移学习和未使用迁移学习训练模型的柑橘目标检测结果如图 3 所示。



图 3 迁移学习和非迁移学习训练模型检测结果

Fig. 3 Test results of transfer learning and non-transfer learning methods

图 3a 中标号 1 的结果将两个识别条件良好的柑橘识别成了一个,而且还存在目标框重叠问题,标号 2 结果将两个相互重叠的柑橘识别成一个目标。作为对比,图 3b 中标号 1、2 的检测结果都能正确区分并识别柑橘,并且图 3b 识别出了更多的柑橘,可以看出迁移学习的检测系统具有更高的召回率。由图 3 可知,两种训练方法都识别出柑橘目标,但常规训练下的网络识别出的柑橘目标框存在较大的误差与较低的召回率。由此可知迁移学习可以提高网络的目标检测性能。

DPM 算法是目前常用目标检测算法之一。DPM 算法与本文方法在自然采摘环境下柑橘目标识别的 P-R 曲线如图 4 所示。测试集和验证集共包含 300 幅图像,包括光照不均、前背景相似、果实以及枝叶相互遮挡、阴影覆盖、过曝。

图 4a 中 DPM 算法的 P-R 曲线平均准确率为 67.56%,远低于本文方法的 86.91%。本文方法较




图4 两种方法的P-R曲线

Fig. 4 P-R curves of two methods

DPM 算法具有更高的召回率,且 P-R 曲线较 DPM 算法曲线更加平滑稳定,在较高召回率情况下,依旧可以保持较高的准确率。以人工进行柑橘目标识别标注的结果为标准,在不同干扰因素下,DPM 算法与本文方法的识别平均准确率对比如表 3 所示。

表3 DPM 算法与本文方法识别平均准确率对比
Tab. 3 Experimental result of citrus using DPM and proposed method %

干扰因素	样本数量	DPM 算法	本文方法
光照不均	63	64.4	88.1
前背景相似	49	61.2	84.8
果实及枝叶遮挡	67	60.8	83.6
阴影覆盖	67	67.5	89.7
过曝	54	68.1	86.6

从表 3 可知,DPM 算法的准确率远低于本文方法。针对果实与枝叶遮挡条件,评估所用数据集包含 67 幅存在果实与枝叶遮挡的图像,遮挡率的计算方法为 67 幅遮挡图中被遮挡柑橘的遮挡面积占其总面积的比率均值,经统计,平均遮挡率为 48%,DPM 算法检测的准确率只有 60.8%,而本文方法准确率为 83.6%。同时,本文方法在表 3 的多个影响因素下的识别平均准确率的均值为 86.6%。

本文方法的目标识别结果如图 5 所示。图 5a 中,枝叶遮挡面积小于 50% (图中标号 1、2、3),其 IOU 值分别为 0.8、0.95、0.9。但如果遮挡面积过大,则依旧无法成功识别(图中蓝框)。蓝框中的柑橘具有标签值,但未被识别,相当于 IOU 值为 0,分

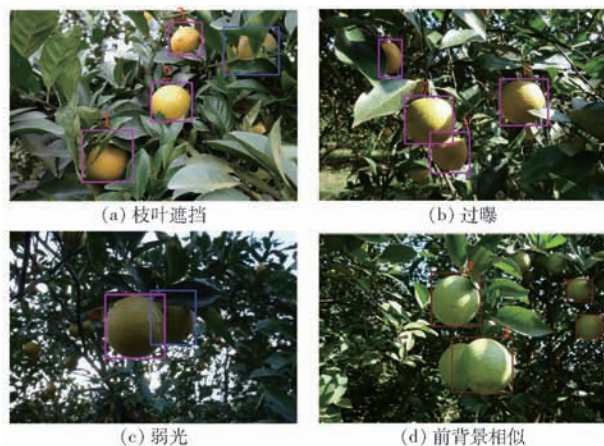


图5 本文方法对自然条件下柑橘目标识别结果

Fig. 5 Detecting results of citrus by proposed method under natural conditions

类结果为 FN。其他情形以此类推。图 5b 中,标号 1、2、3 的样本存在阴影覆盖和过曝,本文方法依然可以识别柑橘目标。图 5c 中,弱光条件下,柑橘纹理不明显,同时颜色也有较大变化,个别位置甚至可能出现柑橘和枝叶颜色混合的现象,这时不管是 SIFT 特征还是 HOG 特征效果较差。但使用本文方法均可准确识别柑橘。蓝框标出的柑橘由于光照条件太差,颜色信息损失太多并未成功识别。图 5d 中,在前背景相似情况下,柑橘颜色几乎和枝叶颜色融为一体,同时还伴有光照变化和阴影覆盖等情况存在。本文所设计的模型取得了较好的效果,其中识别效果较差的 2 号柑橘的 IOU 仍可达到 0.8,分类结果为 TP。由图 5 识别结果可知,本文方法能够有效地应对多种户外采摘条件下的干扰因素。

实地拍摄的图像尺寸为 2 448 像素 × 2 448 像素,由于图像像素较大,柑橘较小,因此将图像分成 4 幅有重叠的子图进行识别,子图尺寸为 1 000 像素 × 1 000 像素。识别模型将子图缩放到 416 像素 × 416 像素,识别完成后将识别结果聚合,以此实现多尺度图像的识别。本文所设计的柑橘目标识别模型的运算平台为 i7-6850K CPU, Nvidia GTX 1080Ti GPU,内存 32 GB。识别时间为从将图像分割成 4 幅子图到将 4 幅子图识别结果聚合在一起输出最后识别结果的总时间。经测试,1 000 幅图像的平均识别速度为 12.5 帧/s,因此该模型具有良好的实时性,能够满足实际自动化采摘的目标识别速度要求。

4 结论

(1)设计的基于深度卷积神经网络的柑橘目标识别模型对光照变化、亮度不均、前背景相似、果实及枝叶相互遮挡、阴影覆盖等实际采摘环境下常见

干扰因素及其叠加情形具有良好的鲁棒性,可为柑橘采摘机器人设计提供参考。

到了86.6%,平均损失为7.7,最大召回率为93%,实验结果表明,该模型能够在自然采摘环境下进行准确和快速的柑橘目标识别及定位。

(2)本文方法对柑橘识别的平均准确率均值达

参 考 文 献

- [1] 中华人民共和国国家统计局. 中国水果产量[R]. 2017.
- [2] 张水波,鲍官军,杨庆华,等. 基于机器人采摘的柑橘机械特性研究[J]. 浙江工业大学学报, 2012, 40(3): 340-344. ZHANG Shuibao, BAO Guanjun, YANG Qinghua, et al. Study on mechanical properties of citrus bases on robotic harvesting[J]. Journal of Zhejiang University of Technology, 2012, 40(3): 340-344. (in Chinese)
- [3] 王丹丹,宋怀波,何东健. 苹果采摘机器人视觉系统研究进展[J]. 农业工程学报, 2017, 33(10): 59-69. WANG Dandan, SONG Huaibo, HE Dongjian. Research advance on vision system of apple picking robot[J]. Transactions of the CSAE, 2017, 33(10): 59-69. (in Chinese)
- [4] 徐越,李盈慧,宋怀波,等. 基于Snake模型与角点检测的双果重叠苹果目标分割方法[J]. 农业工程学报, 2015, 31(1): 196-203. XU Yue, LI Yinghui, SONG Huaibo, et al. Segmentation method of overlapped double apples based on Snake model and corner detectors[J]. Transactions of the CSAE, 2015, 31(1): 196-203. (in Chinese)
- [5] 詹文田,何东健,史世莲. 基于Adaboost算法的田间猕猴桃识别方法[J]. 农业工程学报, 2013, 29(23): 140-146. ZHAN Wentian, HE Dongjian, SHI Shilian. Recognition of kiwifruit in field based on Adaboost algorithm[J]. Transactions of the CSAE, 2013, 29(23): 140-146. (in Chinese)
- [6] ZHOU Rong, DAMEROW L, SUN Yurui, et al. Using colour features of cv. 'Gala' apple fruits in an orchard in image processing to predict yield[J]. Precision Agriculture, 2012, 13(5): 568-580.
- [7] BEHROOZI-KHAZAEI N, MALEKI M R. A robust algorithm based on color features for grape cluster segmentation[J]. Computers and Electronics in Agriculture, 2017, 142: 41-49.
- [8] CHAIVIVATRAKUL S, DAILEY M N. Texture-based fruit detection[J]. Precision Agriculture, 2014, 15(6): 662-683.
- [9] 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(2): 140-149.
- [10] 宋怀波,屈卫锋,王丹丹,等. 基于光照无关图理论的苹果表面阴影去除方法[J]. 农业工程学报, 2014, 30(24): 168-176. SONG Huaibo, QU Weifeng, WANG Dandan, et al. Shadow removal method of apples based on illumination invariant image[J]. Transactions of the CSAE, 2014, 30(24): 168-176. (in Chinese)
- [11] 项荣,应义斌,蒋焕煜,等. 基于边缘曲率分析的重叠番茄识别[J/OL]. 农业机械学报, 2012, 43(3): 157-162. XIANG Rong, YING Yibin, JIANG Huanyu, et al. Recognition of overlapping tomatoes based on edge curvature analysis[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2012, 43(3): 157-162. http://www.jcsam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20120329&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2012.03.029. (in Chinese)
- [12] 王津京,赵德安,姬伟,等. 采摘机器人基于支持向量机苹果识别方法[J]. 农业机械学报, 2009, 40(1): 148-151. WANG Jinjing, ZHAO Dean, JI Wei, et al. Apple fruit recognition based on support vector machine using in harvesting robot[J]. Transactions of the Chinese Society for Agricultural Machinery, 2009, 40(1): 148-151. (in Chinese)
- [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. 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. http://www.jcsam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20160701&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2016.07.001. (in Chinese)
- [14] LU J, SANG N. Detecting citrus fruits and occlusion recovery under natural illumination conditions[J]. Computers and Electronics in Agriculture, 2015, 110: 121-130.
- [15] 李思雯,吕建成,倪胜巧. 集成的卷积神经网络在智能冰箱果蔬识别中的应用[J]. 数据采集与处理, 2016, 31(1): 205-212. LI Siwen, LÜ Jiancheng, NI Shengqiao. Integrated convolutional neural network and its application in fruits and vegetables recognition of intelligent refrigerator[J]. Journal of Data Acquisition and Processing, 2016, 31(1): 205-212. (in Chinese)
- [16] INKYU S, ZONGYUAN G, FERAS D, et al. Deepfruits: a fruit detection system using deep neural networks[J]. Sensors, 2016, 16(8): 1222-1245.
- [17] HOU L, WU Q, SUN Q, et al. Fruit recognition based on convolution neural network[C]//12th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD), Changsha, 2016: 18-22.
- [18] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[C]//Advances in Neural Information Processing Systems, 2012: 1097-1105.
- [19] 卢宏涛,张秦川. 深度卷积神经网络在计算机视觉中的应用研究综述[J]. 数据采集与处理, 2016, 31(1): 1-17. LU Hongtao, ZHANG Qinchuan. Applications of deep convolutional neural network in computer vision[J]. Journal of Data Acquisition and Processing, 2016, 31(1): 1-17. (in Chinese)
- [20] JOSEPH R, ALI F. YOLO9000: better, faster, stronger[J]. arXiv:1612.08242[cs.CV]
- [21] PAN S J, YANG Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge & Data Engineering, 2010, 22(10): 1345-1359.
- [22] NEUBECK A, VAN GOOL L. Efficient non-maximum suppression[C]//18th International Conference on Pattern Recognition (ICP-R'06), Hong Kong, 2006: 850-855.
- [23] FELZENSZWALB P, MCALLESTER D, RAMANAN D. A discriminatively trained, multiscale, deformable part model[C]//IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2008: 1-8.