doi:10.6041/j.issn.1000-1298.2019.10.003

基于改进 AlexNet 的广域复杂环境下遮挡猕猴桃目标识别

穆龙涛[1]　高宗斌[1]　崔永杰[1,2]　李　凯[1]　刘浩洲[1]　傅隆生[1,3]

(1. 西北农林科技大学机械与电子工程学院, 陕西杨凌 712100; 2. 农业农村部农业物联网重点实验室, 陕西杨凌 712100;
3. 陕西省农业信息感知与智能服务重点实验室, 陕西杨凌 712100)

摘要: 为了提高猕猴桃采摘机器人的工作效率和对猕猴桃复杂生长环境的适应性,识别广域复杂环境下相互遮挡的猕猴桃目标,采用 Im-AlexNet 为特征提取层的 Faster R-CNN 目标检测算法,通过迁移学习微调 AlexNet 网络,修改全连接层 L6、L7 的节点数为 768 和 256,以解决晴天(白天逆光、侧逆光)、阴天及夜间补光条件下的广域复杂环境中猕猴桃因枝叶遮挡或部分果实重叠遮挡所导致的识别精度较低等问题。采集广域复杂环境中晴天逆光、晴天侧逆光、阴天和夜间补光条件下存在遮挡情况的 4 类样本图像共 1 823 幅,建立试验样本数据库进行训练并测试。试验结果表明:该方法对晴天逆光、晴天侧逆光、阴天和夜间补光条件下存在遮挡情况的图像识别精度为 96.00%,单幅图像识别时间约为 1 s。在相同数据集下,Im-AlexNet 网络识别精度比 LeNet、AlexNet 和 VGG16 3 种网络识别精度的平均值高出 5.74 个百分点。说明该算法能够降低猕猴桃果实漏识别率和误识别率,提高了识别精度。该算法能够应用于猕猴桃采摘机器人对广域复杂环境下枝叶遮挡或部分果实重叠遮挡的准确识别。

关键词: 猕猴桃; 多目标识别; 广域目标; 遮挡图像; 深度学习; AlexNet

中图分类号: TP391.41; S126　　**文献标识码**: A　　**文章编号**: 1000-1298(2019)10-0024-11

Kiwifruit Detection of Far-view and Occluded Fruit Based on Improved AlexNet

MU Longtao[1]　GAO Zongbin[1]　CUI Yongjie[1,2]　LI Kai[1]　LIU Haozhou[1]　FU Longsheng[1,3]

(1. *College of Mechanical and Electronic Engineering, Northwest A&F University, Yangling, Shaanxi* 712100, *China*
2. *Key Laboratory of Agricultural Internet of Things, Ministry of Agriculture and Rural Affairs, Yangling, Shaanxi* 712100, *China*
3. *Shaanxi Key Laboratory of Agricultural Information Perception and Intelligent Service, Yangling, Shaanxi* 712100, *China*)

Abstract: To improve the applicability and efficiency of scaffolding cultivation kiwifruit harvesting robot in orchard, an efficient and accurate recognition method for multiple clusters characteristics of kiwifruits under far-view and occlusion environment conditions were researched. Faster R-CNN was proposed for detecting kiwifruit. The Im-AlexNet model was used to recognize the far-view and occluded fruit image, including the sunny backlight, sunny rembrandt light, cloudy, night with illumination condition. In addition, there was more obstructive among fruit clusters and branches and leaves of fruit trees. By modifying the number of nodes in full connection layer of AlexNet model by transfer learning, fine-tuning the number of nodes full connection layer L6, L7 to 768 and 256. The feature extraction of kiwifruit was more accurate, and the recognition result of occluded image of fruit contour was obtained. Through the recognition of 1 823 multi-cluster kiwifruit images trained by Im-AlexNet, the experimental results indicated that the average precision (AP) of far-view and occluded complex condition images was 96.00%, and the recognition speed reached 1 s. By comparing with LeNet、AlexNet、VGG16 models of training the same datasets, the AP of Im-AlexNet was 5.74 percentage points higher than those of Faster R-CNN network, and the rate of false recognition and missing recognition of kiwifruit was reduced by Im-AlexNet. It was proved that deep learning can solve the problem of recognition results of far-view complex weather and occluded fruit, and kiwifruit harvesting robot was suitable for kiwifruit detection in complex environment, it can also be applied to other far-view multi-target and partially occluded target recognition.

Key words: kiwifruit; multi-target recognition; far-view target; occluded image; deep learning; AlexNet

收稿日期: 2019-06-20　修回日期: 2019-08-22

基金项目: 陕西省科技统筹创新工程计划项目(2015KTCQ02-12)

作者简介: 穆龙涛(1988—),男,博士生,主要从事果实采摘自动化研究,E-mail: clever19880817@163.com

通信作者: 崔永杰(1971—),男,教授,博士生导师,主要从事果蔬生产自动化研究,E-mail: cuiyongjie@nwsuaf.edu.cn

0　引言

中国猕猴桃种植面积和总产量位居世界前列[1]，且经济效益高[2]，但目前多采用人工采摘收获，耗时且劳动力成本高[3-5]，亟待实现果实采摘的机械化与自动化。目前，国内外学者对果实采摘机器人进行了研究，但采摘效率较低[6-7]。要提高采摘效率，猕猴桃果实的精准识别定位尤为重要。由于猕猴桃果实在田间受不同天气（晴天、阴天）及不同光照强度变化的影响，且由于果实大小各异并存在枝叶或果实重叠遮挡等情况，对广域复杂环境中多目标果实的准确识别造成很大困难。因此，广域复杂环境下存在遮挡情况的多目标识别对提高机器人采摘效率并实现自动化及智能化具有重要意义。

针对棚架式栽培猕猴桃识别，多采用如 Sobel 边缘提取[8]、Hough 变换[9]、构建颜色网络的识别分类器[10]、果萼特征识别[11]、K-means 多目标识别[12]等传统图像处理方法，上述方法基于像素颜色、形状或纹理特征，主要针对近距离拍摄的小范围少量果实图像进行目标识别，对于单簇果实的识别效果较好。而对于广域复杂环境下所采集的猕猴桃果实图像中果实目标小且密集，其中包括多个果实簇，果实数量达 30 个以上，并且受光照强弱变化及枯枝叶遮挡情况的影响，易对图像成像品质产生较大影响，进而造成目标误识别与漏识别[13]。因此，需要对广域复杂环境下细小而密集型多目标果实的识别方法进行研究。

卷积神经网络（Convolutional neural network，CNN）对于农作物图像具有很好的分类和表征识别能力[14]。文献[15]使用 LeNet 提高了猕猴桃识别精度和速度，却未对枝叶遮挡或果实重叠遮挡所致的误识别或漏识别等问题进行研究。文献[16]提出一种 SSD 网络，对具有复杂特征的 4 种水果进行了目标识别。另外，文献[17]利用深度网络亦对复杂特征的不同种类水果进行了识别，均取得了较好的识别效果，但上述两种方法未能解决复杂环境下小而密集的多目标果实遮挡识别问题。文献[18]通过 ResNet 对疏果前苹果进行识别研究，取得了较高的识别精度，但存在漏识别现象。文献[19]采用 YOLO v3 来定位苹果目标，精度高且速度快，但该网络对密集的小目标检测效果不佳。除将 YOLO 检测网络用于图像识别以外，还有将 Faster R－CNN 应用于存在部分目标被遮挡情况的图像进行分类和识别方面[20]，如对污损指纹[21]和遮挡面部[22-23]等特征缺失图像的识别与分类。此外，CNN 还被应用于作物病虫害检测及识别[24-25]、作物器官[26]和品种识别[27-28]、杂草识别及外形分级[29-30]等农业领域。尽管上述对 CNN 的研究解决了不同领域复杂图像中的目标检测存在耗时费力且精度较低等问题，但对于广域复杂环境下果实受叶片遮挡或果实相互遮挡情况下的小而密集的目标识别研究较少。研究表明，Faster R－CNN 对图像中多个小而密集的目标识别效果较好[31]。另外，对比深度神经网络中 LeNet、AlexNet、VGG16、ResNet18、YOLO 等结构，AlexNet 具有层数相对较少、参数少和所需计算资源低等优势，而简化网络结构对于网络在实际部署和应用中优化网络至关重要[31-32]。因此本文采用改进 AlexNet 为特征提取层的 Faster R－CNN 目标检测算法进行猕猴桃果实识别。

通过对猕猴桃果园实地环境进行调研后发现：猕猴桃果实呈簇生生长，且受枝叶遮挡及果实相互遮挡等情况约占 26.4%。由此可见，对广域复杂环境下猕猴桃受枝叶遮挡或果实相互遮挡情况下的目标精准识别，成为研究的难点与关键。鉴于此，本文提出一种基于改进 AlexNet 的广域复杂环境下猕猴桃受枝叶遮挡或果实相互重叠遮挡的目标识别方法，以期解决此情况下目标漏识别和误识别等多目标识别与定位缺陷问题，为猕猴桃采摘机器人在田间复杂环境下高效精准作业奠定基础。

1　图像采集与识别方法

1.1　猕猴桃生长特点

本文试验样本数据库的图像采集地点选自陕西省秦岭北麓猕猴桃产区（34°7′39″N，107°59′50″E，海拔约 648 m）西北农林科技大学（眉县）猕猴桃试验站，以海沃德猕猴桃作为本研究所需图像采集对象。海沃德猕猴桃以棚架式栽培为主，棚架高 1.8 m，两行间距 4.0 m，果实分布于棚架底部呈簇生且自然下垂式生长（图 1），该地区天气条件复杂多变，由于猕猴桃果实受枝叶遮挡且存在果实相互遮挡等情况，众多复杂因素对猕猴桃果实的精准识别造成较大影响，同时对猕猴桃采摘机器人的实地高效精准作业造成一定影响。

1.2　试验样本图像数据库

图像采集装置如图 2 所示，采用 CCD（型号：Microsoft LifeCam）和 Kinect v2 传感器。将 CCD 和 Kinect v2 分别安装于三角架上，并与计算机相连（试验软件平台为 LifeCam Studio 和 Kinect for windows SDK，硬件平台为 Dell i5－8250U 1.80 GHz 处理器，4 GB 内存），从棚架底部利用图 2 所示图像采集装置竖直向上对广域复杂环境下的多目标簇生猕猴桃果实进行图像采集，其中包括果实受枝叶遮

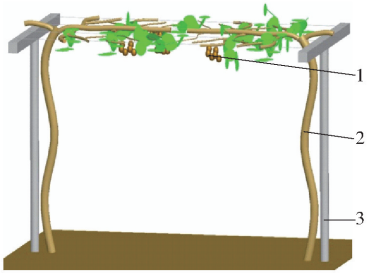

图 1 猕猴桃的棚架栽培模式

Fig. 1 Scaffolding cultivation kiwifruit tree

1. 果实簇 2. 果树 3. 棚架

挡或果实间相互遮挡的情况。另外,因果园地面平整度有差异,并非完全平整的硬质地面,因此为保证所采集图像的成像品质,每次进行图像采集时,均通过调整三脚架来确保相机处于水平位置且镜头距棚架平面下方(0.8 ±0.1) m 处。此外,对于夜间环境下的图像采集均使用 LED 补光灯(CM - LED 1200HS 型,KEMA Co.)提供光源以进行照明。



图 2 猕猴桃图像采集装置

Fig. 2 Device of kiwifruit image acquisition with artificial light

1. LED 补光灯 2. 相机 3. 果实簇 4. 计算机 5. 小车

综合考虑天气及光照因素,于 2018 年 9—10 月对海沃德猕猴桃进行了图像采集。采集工作分别选择在 2 种不同天气(晴天、阴天)条件下进行,其中在晴天条件下采集图像时,重点考虑光照强度和角度变化,采集晴天逆光、晴天侧逆光 2 种条件下的猕猴桃图像。共采集晴天逆光(Sunny backlight, SB)、侧逆光(Sunny rembrandt light, SR)、阴天(Cloudy, CL)和夜间补光(Night with illumination, NI;光照强度为 30 ~ 50 lx[4])4 种类型样本图像共 1 823 幅(图 3),图像总共包含猕猴桃果实样本约为 46 394 个,并且 4 种类型的样本图像中均存在果实被非目标物(如枝叶)所遮挡或果实间相互遮挡等情况。将所采集样本统一设置为 jpg 格式的多尺度 RGB 图像(分辨率为 640 像素 × 360 像素、640 像素 × 480 像素、1 920 像素 × 1 080 像素),以避免因棚架高度不均匀造成的遮挡果实图像多样性的影响。由此建立试验样本数据库。

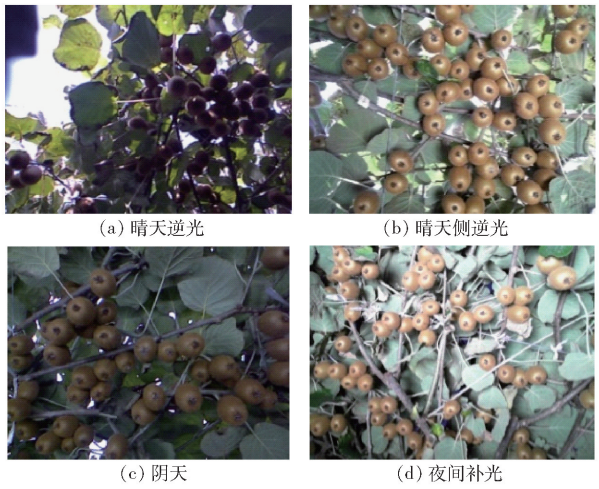

(a) 晴天逆光 (b) 晴天侧逆光

(c) 阴天 (d) 夜间补光

图 3 广域复杂环境下采集的猕猴桃图像

Fig. 3 Complex kiwifruit images under far-view environment

在对 4 类图像进行采集的过程中,均需要考虑遮挡所造成的影响。由于部分果实生长位置所在平面距地面平均高度超过棚架平均高度而被棚架所遮挡,也有部分果实颜色与枯叶、枝干的灰暗色相近,上述 2 种情况均无法分辨果萼及果实轮廓,因此该情况的果实不易被识别。本研究对存在部分遮挡情况的果实目标(即轮廓不全的猕猴桃果实图像)随机选取并进行图像采集,其中包括枝叶遮挡(图 4a)、光照及阴影遮挡(图 4b)、果实重叠遮挡(图 4c)、果实簇密集生长触碰遮挡(图 4d)等情形,均归类为本文所表述的部分遮挡果实图像。

对所采集的 1 823 幅猕猴桃果实样本图像按照 4 种采集条件和 4 种遮挡类型情况分别进行数量统计,如表 1 所示。其中每种采集条件图像中均包含 4 类目标被遮挡情况。

本研究将试验样本数据库中的 1 823 幅猕猴桃样本图像,进行亮度、对比度调整,分别将亮度、对比度设置为 60%、70%、80%、90%、110%、120%、130%、140%,并将高亮度设置为 120% 和 140%。将试验样本进行数据增强(Data augmentation),经扩充后,样本集图像数量增加到 21 147 幅。随机抽选 65% 的样本数据(15 132 幅)作为训练集,剩余 35% 样本数据(6 015 幅)作为测试集。其中训练集所有标签都经过人工标定,标定原则为:对训练集每一幅样本中的果实前景目标以最小外接矩形对其进行画框标定,包括前景目标轮廓不全的果实也将其进行画框标定,以保证果实特征标签训练的可靠性,避免偶然因素对网络训练及后期测试造成的影响。另外,为开展猕猴桃果园实地的果实目标现场识别试验,随机选取现场目标果实进行图像采集,将新采集的 340 幅图像用于实地现场识别验证。在具体识别



(a) 枝叶遮挡(类型1)　(b) 光照及阴影覆盖遮挡(类型2)　(c) 果实重叠遮挡(类型3)　(d) 果实簇密集生长触碰遮挡(类型4)

图 4　不同遮挡类型的猕猴桃图像样本示例

Fig. 4　Examples of kiwifruit images with different occluded conditions

表 1　不同光照条件下的猕猴桃及遮挡图像数量

Tab. 1　Numbers of kiwifruit images and occluded images

采集条件	图像数量/幅	遮挡图像数量/幅				遮挡图像比例/%
		类型 1	类型 2	类型 3	类型 4	
SB	576	49	72	23	8	26.39
SR	368	39	32	15	11	26.36
CL	549	82	18	28	17	26.41
NI	330	56	0	19	12	26.36
合计	1 823	226	122	85	48	

检测试验中,图像数据集的多样性能够促进网络训练学习的有效性及网络泛化能力,提高果实目标的识别精度。

1.3　改进 AlexNet 的猕猴桃目标识别网络

1.3.1　迁移学习

AlexNet 的全连接层的作用是进行分类判别[33-34],利用卷积层对训练集图像提取到的特征来判断所识别测试集图像中的特征区域属于猕猴桃果实区域还是属于背景区域[35]。由于迁移学习可提高网络识别精度,因此,通过迁移学习将 AlexNet 预训练得到的权重用于猕猴桃果实目标的检测,保留原网络的卷积层,同时对全连接层参数进行调整。利用提取的特征,可将猕猴桃识别检测视为区分果实与背景的一个二分类问题(1 属于猕猴桃,0 属于背景)。并通过对 AlexNet 网络的 L6 ~ L8 的全连接层参数、训练参数和防止过拟合(Dropout)的参数进行微调,能够提高果实的识别精度。本研究对 Faster R - CNN 网络中的 AlexNet 特征提取层进行改进,其网络结构如图 5 所示。

神经网络输出层公式为

$$X_j^{(l)} = \int\left(\sum_{i=1}^{d} X_i^{(l-1)}\omega_{ij}^{(l)} + b_j^{(l)}\right) \tag{1}$$

式中　i——输入单元序号

$X_i^{(l-1)}$——上一个卷积层的输出

j——隐含层序号

$\omega_{ij}^{(l)}$——第 i 个输入层与第 j 个隐含层权重

$b_j^{(l)}$——第 j 个隐含层的偏差

d——滤波器个数

$\int(\cdot)$——激活函数

l——网络层序号

由于改进 AlexNet 的输出与原图尺寸相同,因此通过对 L6、L7 进行设置来降低特征维度,使其输出尺寸和原图一致,输出层则采用 ReLU 函数作为激活函数,其函数表达式为

$$\mathrm{ReLU}(x) = \begin{cases} x & (x>0) \\ 0 & (x\leqslant 0) \end{cases} \tag{2}$$

对改进 AlexNet 进行训练,为使训练精确度更高,损失函数采用二次均方误差函数(Mean squared squared error,MSSE),其函数表达式为

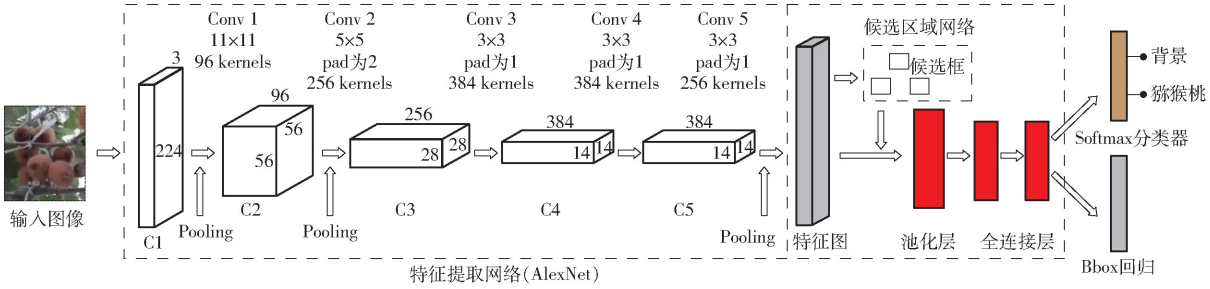

图 5　基于改进 AlexNet 的 Faster R - CNN 网络结构

Fig. 5　Structure of faster R - CNN model with AlexNet

$$MSSE(\omega,b)=\frac{1}{|Y|}\sum_{i=1}^{|Y|}(Y(i)-\hat{Y}(i))^4 \quad (3)$$

式中 ω——权重 $Y(i)$——原始值

$\hat{Y}(i)$——预测值 b——偏差

$|Y|$——样本个数

1.3.2 Im-AlexNet 结构

AlexNet 网络的卷积核尺寸、数量及步长对于网络识别精度影响显著,为避免过拟合和训练速度减慢,仅以检测猕猴桃果实特征为主,并对 AlexNet 网络结构进行改进:保留 AlexNet 前 5 个卷积层,去除所有全连接层。并对网络进行调参,通过将 AlexNet 中 L6、L7 的全连接层参数从 2^4 ~ 2^{14} 依次设置进行多轮训练,并将 L6、L7 全连接层在不同参数设置下的网络识别精度(Average precision, AP) V_{AP} 进行对比,识别精度在不同参数设置下的统计结果,如表 2 所示。经对测试集进行试验得出,当 AlexNet 中的全连接层 L6、L7 的节点数为 768 和 256 时,改进的 AlexNet 对猕猴桃果实识别精度最高。

表 2 全连接层参数微调测试及对应识别精度

Tab. 2 Fine-tuning full connection layer parameters and recognition results

序号	L6 节点数	L7 节点数	V_{AP}/%
1	16	16	65.07
2	32	32	73.19
3	64	64	87.36
4	128	128	91.87
5	256	256	94.75
6	512	512	95.32
7	768	256	96.29
8	1 024	1 024	95.96
9	2 048	2 048	89.31
10	4 096	4 096	82.25

由于卷积层的作用是提取图像特征,从浅层卷积层对边缘、颜色等底层特征的提取到深层卷积层对目标高级特征的提取过程中,通过保留卷积层和预训练权重,可使网络收敛更快,提取目标特征更容易,因此本研究并未对 AlexNet 网络的卷积层参数进行改动设置。其中,所保留的 AlexNet 第 1 层卷积核大小为 11×11×3;第 2 层卷积核大小为 5×5×48,与原网络的卷积层设置一致[35-36]。因此可知,用于猕猴桃识别的改进 AlexNet 包括 5 个卷积层、2 个全连接层和 1 个输出层。由于考虑到猕猴桃果实识别属于二分类问题,将最后一个全连接层参数设置为 2。并将改进的 AlexNet 网络命名为 Im-AlexNet。网络结构修改调整后的具体网络参数配置如表 3 所示。

表 3 Im-AlexNet 网络结构的参数设置

Tab. 3 Parameters of Im-AlexNet model

网络层	卷积核	步长	卷积核数量
Conv1	11×11×3	4	96
Pool1	1×3×3×1	2	
Conv2	5×5×48	1	256
Pool2	1×3×3×1	2	
Conv3	3×3×256	1	384
Conv4	3×64×384	1	384
Conv5	3×3×384	1	256
Pool5	1×3×3×1	2	3×3
Fc6	64×256		256×1
ReLU6			768
Dropout			
Fc7	32×256		2×1
ReLU7			256
Dropout			
Fc8	256×2		2
Prob	Softmax		
Output			

2 猕猴桃识别试验

2.1 训练处理平台

选用艮泰 SP16HDIET 深度学习计算模拟机作为训练处理平台,处理器为 Intel Xeon E5-1650 v4,主频为 3.6 GHz;32 GB 内存;显卡为 Nvidia TITAN XP(GPU),12 GB GDRR5 显存;2TB 7200RPM SATA 硬盘。使用的深度学习软件为 Matlab 2018a, Deep learning toolbox model for AlexNet network,支持 GPU 运算。

2.2 网络训练

根据表 3 所示网络结构进行参数设置后,对候选区域网络(Region proposal network, RPN)进行多轮训练并进行测试试验。具体训练过程中,将起始学习率(Learning rate)设为 0.001,每批图像数量设置为 64,动量(Momentum)设置为 0.9,权值衰减(Decay)设置为 0.000 5,最大迭代次数设置为 60 次;并在 L6、L7 全连接层中加入 Dropout 层,以确保每层提取特征的相互独立,同时将防止过拟合 Dropout 设置为 0.4,此时网络的识别精度较高。Im-AlexNet 最终输出为猕猴桃目标果实的识别结果,为提高猕猴桃目标的识别精度,本研究仅保留置信度大于 0.85 的目标。为验证本研究所提算法的有效性,在与上述参数配置相同情况下,对 LeNet、AlexNet 和 VGG16 网络进行识别测试验证,并对识别结果进行数据统计。

2.3 评价指标

为验证本研究所提识别方法的性能优越性,用

AP 对 Im－AlexNet 网络的识别性能进行评价，AP 是 PR 曲线在准确率基础上对召回率的积分[36]。评价指标为

$$P = \frac{T_P}{T_P + F_P} \times 100\% \tag{4}$$

$$R = \frac{T_P}{T_P + F_N} \times 100\% \tag{5}$$

$$V_{AP} = \int_0^1 P(R)\,\mathrm{d}R \tag{6}$$

式中　P——准确率　　R——召回率

T_P——算法正确识别的猕猴桃数量

F_P——将背景误识别为猕猴桃的数量

F_N——未识别到的猕猴桃数量

3　结果与讨论

3.1　训练误差率

利用 Im－AlexNet 对训练集进行训练，共分为 4 步，损失函数（Loss function）每一步训练采用 60 次迭代运算，4 步训练的损失函数值变化曲线如图 6 所示。

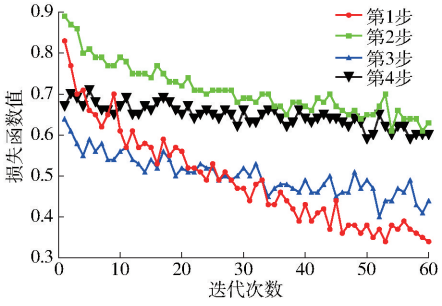

图 6　猕猴桃样本训练损失函数值变化曲线

Fig. 6　Loss changing curves of training using Im－AlexNet

由图 6 可看出，第 1 步使用 ImageNet 网络初始化，独立训练一个 RPN 网络，训练迭代次数（Epochs）由 0 次逐渐增加到 60 次的过程中，损失函数值由 0.85 降至 0.35；第 2 步继续使用 ImageNet，将上一步 RPN 网络产生的候选框（Proposal）作为输入，训练一个 Fast R－CNN 网络，训练迭代由 0 次逐渐增加到 60 次的过程中，损失函数值由 0.90 降至 0.63；第 3 步使用第 2 步的 Fast R－CNN 参数初始化一个新的 RPN 网络，并将其共享卷积层的学习率设置为 0，仅更新 RPN 特有的网络层，重新训练两个网络已共享的所有公共卷积层，训练迭代由 0 次逐渐增加到 60 次的过程中，损失函数值由 0.65 降至 0.41；第 4 步保持共享的卷积层固定，微调 Fast R－CNN 的全连接层，训练迭代由 0 次逐渐增加到 60 次的过程中，损失函数值由 0.72 降至 0.61。此时，网络内部预测 Proposal 并实现猕猴桃果实的目标检测。通过数据分析，从图 6 整体来看，随迭代次数不断增加，训练集和验证集的分类误差基本呈逐渐降低趋势，训练损失基本收敛到稳定值，表明 Im－AlexNet 基本达到了预期的训练效果。

3.2　测试集试验结果

利用 LeNet、AlexNet、VGG16 和 Im－AlexNet 分别对试验样本数据库中筛选出的包含 4 类采集条件的图像训练集进行标记并进行交叉训练，验证测试集中所包含的 4 类采集条件图像测试集的识别精度。其中，4 种网络分别对 4 种不同类型图像的识别精度统计结果如表 4 所示。

表 4　不同网络识别猕猴桃图像试验结果

Tab. 4　Recognition results of kiwifruit used different networks

网络类型	图像类型	V_{AP}/%	平均值/%	识别时间/s
LeNet	SB	87.75	89.05	0.9
	SR	89.72		
	CL	85.90		
	NI	92.82		
AlexNet	SB	90.23	90.48	1.0
	SR	92.36		
	CL	87.10		
	NI	92.23		
VGG16	SB	89.90	91.26	1.1
	SR	93.20		
	CL	87.62		
	NI	94.30		
Im－AlexNet	SB	94.36	96.00	1.0
	SR	96.87		
	CL	94.94		
	NI	97.83		

3.2.1　不同光照条件下的识别结果

由表 4 可知，Im－AlexNet 对 4 种类型的样本图像识别精度明显高于 LeNet、AlexNet 和 VGG16，Im－AlexNet 识别精度比 LeNet、AlexNet 和 VGG16 3 种网络识别精度的平均值高出 5.74 个百分点。其中夜间和晴天侧逆光条件下的图像识别精度较高，对于晴天逆光条件下的图像识别精度较低，由此说明光照变化对于图像成像品质影响较大，当光照强度过大且不均匀时易形成逆光条件，逆光、光照强度对于图像识别精度有较大影响。

使用准确率-召回率曲线来凸显分类器在准确率与召回率间的权衡关系。Im－AlexNet 对猕猴桃目标识别的准确率-召回率曲线如图 7 所示。

由图 7 可得出，所选择网络在召回率增长的同时，准确率保持在一个较高的水平，说明 Im－AlexNet 对于多目标猕猴桃果实的识别精度较高，识别精度为 96.00%。为保证本研究所提出 Im－AlexNet 与 LeNet、AlexNet 和 VGG16 3 种网络对比

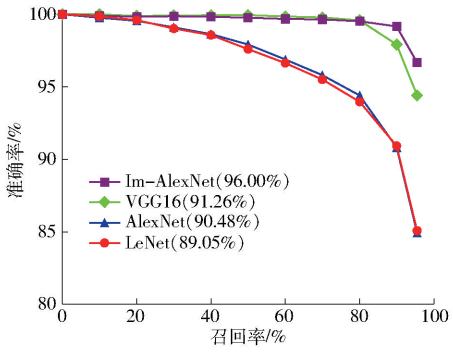

图 7 Im - AlexNet 的准确率-召回率曲线

Fig. 7 Precision-recall curves of Im - AlexNet

论证的科学严谨性,均选用相同采集条件下所获取的遮挡情况相同、背景一致、曝光程度相同的同类型图像进行目标识别检测试验(以 SR 图像为例),其关于 4 种网络对测试集图像的识别结果实例,如图 8 所示。由图 8 可看出,相较于 LeNet、AlexNet 和 VGG16,本研究所提出的 Im - AlexNet 对猕猴桃果实的目标识别精度更高,漏识别和误识别情况较少,而 LeNet、AlexNet 和 VGG16 在对测试集图像进行目标检测的识别过程中,目标漏识别率和误识别率较高(图 8 中红框的标记位置为算法识别的结果,黄色框的标记位置为漏识别和误识别果实)。由此可知,Im - AlexNet 能够克服田间环境变化对图像成像品质的影响,对于猕猴桃目标果实的精准识别性能更加优良。

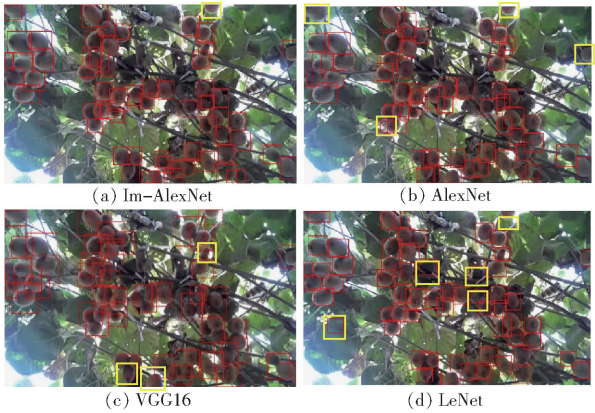

图 8 4 种网络对猕猴桃果实图像的识别结果对比

Fig. 8 Comparison of kiwifruit recognition results used four networks

3.2.2 存在遮挡情况下的识别结果

将试验样本数据库中(表 1)的遮挡样本作为测试集,利用 LeNet、AlexNet、VGG16、Im - AlexNet 网络进行目标识别验证,试验结果表明对广域复杂环境下存在遮挡情况的 4 类猕猴桃果实图像的目标识别精度分别为 83.01%、89.36%、89.52%、94.75%。可明显看出该 Im - AlexNet 网络对于广域复杂环境下果实遮挡情况的识别精度明显优于 LeNet、AlexNet 和 VGG16 3 种网络,由此可证明该算法能够降低对猕猴桃果实遮挡情况下的漏识别率与误识别率,并能够提高对目标果实的识别精度,亦证明本研究所提出的 Im - AlexNet 能够应用于猕猴桃采摘机器人对广域复杂环境下存在遮挡情况的目标果实识别。

3.3 田间识别试验结果

3.3.1 不同光照条件下的识别结果

针对广域复杂环境下生长的猕猴桃,将上述经过样本标记训练后的 Im - AlexNet 应用于采摘机器人视觉识别模块(Kinect v2 和软件 Matlab 2018a)和便携计算机(Dell i5 -8250U),对实地果园环境中的猕猴桃果实进行检测识别与目标验证,并将目标检测所获取的用以验证实地大田环境下采摘机器人视觉识别模块性能的 340 幅(果实数量为 10 177 个)验证图像建立试验集,其中包括晴天逆光(图 9a)、晴天侧逆光(图 9b)、阴天(图 9c)、夜间补光(图 9d)4 类图像。利用采摘机器人的视觉识别模块对验证集进行目标识别验证,具体识别统计结果如表 5 所示。

由表 5 可知,Im - AlexNet 对于猕猴桃果实目标具有较好的识别效果,对 4 类图像的识别精度的平均值为(96.00 ± 0.16)%。经统计,该网络对 4 种类型图像的正确识别果实总数为 9 804 个,漏识别果实总数为 373 个,误识别果实总数为 403 个,其中,对晴天逆光和侧逆光类型图像的果实误识别情况较严重,误识别果实总数达到 335 个,明显高于阴天和夜间补光 2 种类型图像,造成误识别的主要原因是受自然光的影响,因强光照射使得采摘机器人视觉识别模块所获取图像中目标前景特征与背景区分不明显或因异物遮挡果实所致。

本文识别方法对 4 种类型图像的目标识别检测示例如图 9 所示,图中 1、2、3 表示逆光(阴影)、被枝叶遮挡、果实簇重叠遮挡情况,4、5 表示漏识别和误识别的情况。由图 9 可明显看出 Im - AlexNet 网络能够对广域复杂环境下包括晴天逆光、晴天侧逆光、阴天、夜间补光的 4 类猕猴桃果实图像的前景目标进行有效准确识别。另外,将所得图像识别结果中被标定框标记锁定的目标果实位置设为(x_i,y_i,w_i,h_i),其平面坐标中心点则作为机器人末端执行器对该目标果实的采摘抓取位置,并且果实果萼的位置坐标误差,在采摘机器人末端执行器的容差范围内(25 mm)[37]。因此,该网络对目标果实的识别精度和定位精度均满足猕猴桃采摘机器人的要求。试验结果表明,Im - AlexNet 网络泛化性较好,满足猕猴桃采摘机器人在实际生产中对视觉系统识别精

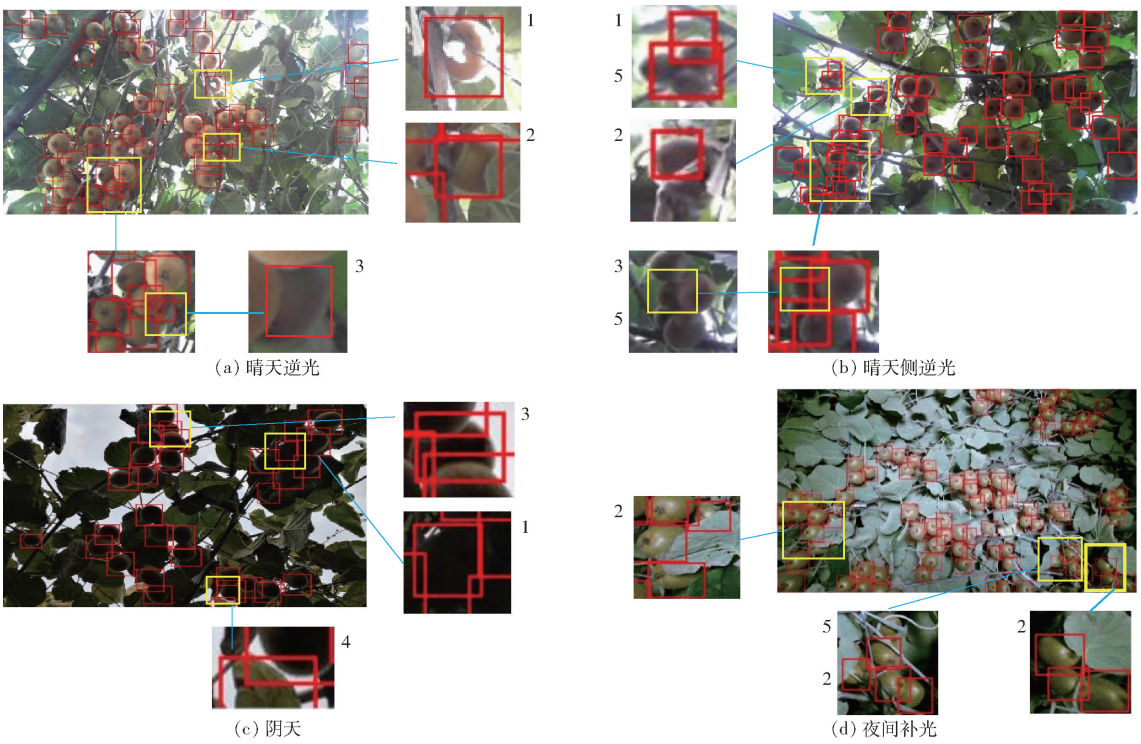

图 9　不同光照条件下猕猴桃果实识别结果示例

Fig. 9　Recognition results examples of kiwifruit under different illuminations

表 5　Im－AlexNet 田间环境猕猴桃识别的试验结果

Tab. 5　Kiwifruit image recognition results of different conditions by Im－AlexNet

序号	图像类型	实际果实数量/个	正确识别果实数	误识别果实数	漏识别果实数	V_{AP}/%	识别时间/s	单幅图像平均果实数量/个
1	SB	1 668	1 574	37	94	94. 39 ± 0. 11	1. 07	42
2	SR	3 125	3 005	298	120	96. 87 ± 0. 21	1. 10	30
3	CL	1 300	1 229	62	71	94. 91 ± 0. 19	1. 02	22
4	NI	4 084	3 996	6	88	97. 83 ± 0. 14	1. 08	54
合计		10 177	9 804	403	373			
平均						96. 00 ± 0. 16	1. 07	37

度与识别速度的要求。

3. 3. 2　存在遮挡情况下的识别结果

本研究重点对验证集图像中的遮挡情况进行分析讨论，并利用 Im－AlexNet 网络对存在遮挡情况（表 1，共 4 种类型）的果实目标进行识别验证。通过分析可知，遮挡情况主要由于逆光拍摄造成光影遮挡（图 9a），致使目标果实与背景不易区分，导致识别率降低；另外，由于猕猴桃呈现簇生密集生长（图 9b、9c），使得在对广域范围内的猕猴桃果实进行图像采集时，获取到的目标前景特征多为小而密集目标，而所采集图像中仅存在单个或稀疏少量果实前景目标的情况占极少数，因此，易导致对目标果实的识别精度有所降低。通过 Im－AlexNet 对存在上述遮挡情况的图像进行目标检测识别，识别结果表明，Im－AlexNet 网络能够克服因果实部分遮挡对识别所造成的影响（图 9a、9c），但亦存在因果实簇间相互重叠遮挡所致的被遮挡果实漏识别情况的发生（图 9b、9d），同时也存在果实被枯枝叶所遮挡而导致果实误识别的情况（图 9c）。

4　讨论

较其他识别方法而言，本文所提出的识别方法性能优越。在有关目标识别的研究当中，文献[15]用LeNet 网络对猕猴桃的识别精度为 89. 29%，而本研究采用的 Im－AlexNet 识别精度达到 96. 00%，比 LeNet 网络识别率高出 6. 71 个百分点；文献[16]所提出 4 种果实的 SSD 网络识别方法对无遮挡情况下单簇果实图像识别精度较高，但对于多簇果实图像的识别精度并未做研究说明。同时，在识别精度相同的情况下，本文所提出的基于 Im－AlexNet 网络的多目标果实识别方法，在对单幅图像进行目标识别时，识别率远高于文献[16]所提方法，而对图像中单果识别时间远快于文献[16]所提方法。文献[18]R_FCN 网络

对疏果前苹果与绿叶背景相近的目标特征检测识别进行了研究,取得了一定成效,但存在漏识别的现象。与文献[19]所采用的 YOLO v3 网络相比,该网络对于密集且小的猕猴桃目标检测效果不佳。本文采用的 Im - AlexNet 识别率较高,能够克服光照变化、枝叶遮挡对图像识别精度造成的影响,减少了误识别、漏识别果实的数量。该方法具有较好的可操控性和实用性,且对网络进行了精简,便于植入到移动端,能够满足猕猴桃采摘机器人果园移动式作业的需求。本研究通过对 AlexNet 网络进行改进,通过迁移学习对 AlexNet 网络当中的全连接层节点数量进行微调,有效解决了晴天逆光、晴天侧逆光、阴天和夜间补光 4 种条件下有遮挡情况存在的猕猴桃果实目标识别精度较低的问题。且将 Im - AlexNet 、LeNet、AlexNet 和 VGG16 网络的识别精度进行对比,Im - AlexNet 的识别精度较高(表 4)。此外,文中并未选择使用如 Faster R - CNN(VGG19,ResNet)、YOLO v3 等类型的深层网络,其主要原因是该网络较大,无法被植入移动端控制器当中,降低了 CNN 在猕猴桃采摘机器人视觉系统实际应用中的性价比。

5 结论

(1)针对猕猴桃采摘机器人信息感知单元对存在遮挡情况下的目标果实识别精度较低等问题,提出一种基于 Im - AlexNet 网络的广域复杂环境遮挡情况下的多目标果实识别方法。利用 Im - AlexNet 网络实现对 4 类猕猴桃果实的图像识别,识别精度为 96.00%,单幅图像识别时间约为 1 s。满足猕猴桃采摘机器人在实际生产中对视觉系统识别精度及识别速度的要求。

(2)提出的 Im - AlexNet 降低了网络复杂程度,通过减少全连接层参数而压缩了网络,减少了计算量,对于广域复杂环境下存在遮挡情况的猕猴桃果实图像的目标识别精度有较大提高。

(3)利用搭建的猕猴桃采摘机器人试验平台,对实地田间生长的猕猴桃果实进行了识别测试,结果表明,本文提出的以 Im - AlexNet 为特征提取层的 Faster R - CNN 网络,相比其他网络具有更高的识别精度。本研究为多机械手采摘机器人协同作业任务分配方法的研究奠定了基础,同时也促进了猕猴桃采摘机器人工作效率的提高。

参 考 文 献

[1] FAOSTAT. Kiwifruit production in 2017[M]. Paris: OECD Publishing, 2018.

[2] 傅隆生,张发年,槐岛芳德,等. 猕猴桃采摘机器人末端执行器设计与试验[J/OL]. 农业机械学报, 2015, 46(3):1 - 8.
FU Longsheng, ZHANG Fanian, YOSHINORI G, et al. Development and experiment of end-effector for kiwifruit harvesting robot[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(3):1 - 8. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 20150301&journal_id = jcsam. DOI:10.6041/j.issn.1000-1298.2015.03.001. (in Chinese)

[3] MU Longtao, LIU Haozhou, CUI Yongjie, et al. Mechanized technologies for scaffolding cultivation in the kiwifruit industry: a review[J]. Information Processing in Agriculture, 2018, 5(4):401 - 410.

[4] FU Longsheng, WANG Bin, CUI Yongjie, et al. Kiwifruit recognition at nighttime using artificial lighting based on machine vision[J]. International Journal of Agricultural and Biological Engineering, 2015, 8(4):52 - 59.

[5] 陈军,王虎,蒋浩然,等. 猕猴桃采摘机器人末端执行器设计[J/OL]. 农业机械学报, 2012, 43(10):151 - 154, 199.
CHEN Jun, WANG Hu, JIANG Haoran, et al. Design of end-effector for kiwifruit harvesting robot[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2012, 43(10):151 - 154, 199. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 20121027&journal_id = jcsam. DOI:10.6041/j.issn.1000-1298.2012.10.027. (in Chinese)

[6] BECHAR A, VIGNEAULT C. Agricultural robots for field operations: concepts and components[J]. Biosystems Engineering, 2016, 149:94 - 111.

[7] FENG Qingchun, ZOU Wei, FAN Pengfei, et al. Design and test of robotic harvesting system for cherry tomato[J]. International Journal of Agricultural and Biological Engineering, 2018, 11(1):96 - 100.

[8] SCARFE A J. Development of an autonomous kiwifruit harvester[D]. Manawatu: Massey University, 2012.

[9] 崔永杰,苏帅,王霞霞,等. 基于机器视觉的自然环境中猕猴桃识别与特征提取[J/OL]. 农业机械学报, 2013, 44(5):247 - 252.
CUI Yongjie, SU Shuai, WANG Xiaxia, et al. Recognition and feature extraction of kiwifruit in natural environment based on machine vision[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(5):247 - 252. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 20130543&journal_id = jcsam. DOI:10.6041/j.issn.1000-1298.2013.05.043. (in Chinese)

[10] 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)

[11] 傅隆生,孙世鹏,MANUEL V A,等. 基于果萼图像的猕猴桃果实夜间识别方法[J]. 农业工程学报, 2017, 33(2):199 - 204.
FU Longsheng, SUN Shipeng, MANUEL V A, et al. Kiwifruit recognition method at night based on fruit calyx image[J]. Transactions of the CSAE, 2017, 33(2): 199 - 204. (in Chinese)

[12] 陈礼鹏,穆龙涛,刘浩洲,等. 基于猕猴桃果萼图像的多目标果实识别方法[J]. 计算机工程与设计, 2018, 39(6):1738 - 1744.
CHEN Lipeng, MU Longtao, LIU Haozhou, et al. Multi-target fruit recognition method based on kiwifruit calyx image [J]. Computer Engineering and Design, 2018, 39(6):1738 - 1744. (in Chinese)

[13] 黄继鹏,史颖欢,高阳. 面向小目标的多尺度 Faster - RCNN 检测算法[J]. 计算机研究与发展, 2019, 56(2):319 - 327.
HUANG Jipeng, SHI Yinghuan, GAO Yang. Multi-scale Faster - RCNN algorithm for small object dectection[J]. Journal of Computer Research and Development, 2019, 56(2):319 - 327. (in Chinese)

[14] WIATOWSKI T, BOLCSKEI H. A mathematical theory of deep convolutional neural networks for feature extraction[J]. IEEE Transactions on Information Theory, 2018, 64(3):1845 - 1866.

[15] 傅隆生,冯亚利,ELKAMIL Tola E,等. 基于卷积神经网络的田间多簇猕猴桃图像识别方法[J]. 农业工程学报, 2018, 34(2):205 - 211.
FU Longsheng, FENG Yali, ELKAMIL Tola E, et al. Image recognition method of multi-cluster kiwifruit in field based on convolutional neural networks[J]. Transactions of the CSAE, 2018, 34(2): 205 - 211. (in Chinese)

[16] 彭红星,黄博,邵园园,等. 自然环境下多类水果采摘目标识别的通用改进 SSD 网络[J]. 农业工程学报, 2018, 34(16):155 - 162.
PENG Hongxing, HUANG Bo, SHAO Yuanyuan, et al. General improved SSD model for picking object recognition of multiple fruits in natural environment[J]. Transactions of the CSAE, 2018, 34(16): 155 - 162. (in Chinese)

[17] SA I, GE Z, DAYOUB F, et al. Deep fruits: a fruit detection system using deep neural networks[J]. Sensors, 2016, 16(8):1222 - 1244.

[18] 王丹丹,何东健. 基于 R - FCN 深度卷积神经网络的机器人疏果前苹果目标的识别[J]. 农业工程学报, 2019, 35(3): 156 - 163.
WANG Dandan, HE Dongjian. Recognition of apple targets before fruits thinning by robot based on R - FCN deep convolution neural network[J]. Transactions of the CSAE, 2019, 35(3): 156 - 163. (in Chinese)

[19] 赵德安,吴任迪,刘晓洋,等. 基于 YOLO 深度卷积神经网络的复杂背景下机器人采摘苹果定位[J]. 农业工程学报, 2019,35(3):164 - 173.
ZHAO Dean, WU Rendi, LIU Xiaoyang, et al. Apple positioning based on YOLO deep convolutional neural network for picking robot in complex background[J]. Transactions of the CSAE, 2019, 35(3): 164 - 173. (in Chinese)

[20] YANG Qinghua, CHANG Chun, BAO Guanjun, et al. Recognition and localization system of the robot for harvesting Hangzhou white chrysanthemums[J]. International Journal of Agricultural and Biological Engineering, 2018, 11(1):88 - 95.

[21] 吴震东,王雅妮,章坚武. 基于深度学习的污损指纹识别研究[J]. 电子与信息学报, 2017, 39(7):1585 - 1591.
WU Zhendong, WANG Yani, ZHANG Jianwu. Fouling and damaged fingerprint recognition based on deep learning[J]. Journal of Electronics & Information Technology, 2017, 39(7):1585 - 1591. (in Chinese)

[22] LOPES A T, AGUIAR E, DE SOUZA A F, et al. Facial expression recognition with convolutional neural networks: coping with few data and the training sample order[J]. Pattern Recognition, 2017, 61:610 - 628.

[23] 李小薪,梁荣华. 有遮挡人脸识别综述:从子空间回归到深度学习[J]. 计算机学报, 2018, 41(1):177 - 207.
LI Xiaoxin, LIANG Ronghua. A review for face recognition with occlusion: from subspace regression to deep learning[J]. Chinese Journal of Computers, 2018, 41(1):177 - 207. (in Chinese)

[24] 孙俊,谭文军,毛罕平,等. 基于改进卷积神经网络的多种植物叶片病害识别[J]. 农业工程学报, 2017, 33(19):209 - 215.
SUN Jun, TAN Wenjun, MAO Hanping, et al. Recognition of multiple plant leaf diseases based on improved convolutional neural network[J]. Transactions of the CSAE, 2017, 33(19): 209 - 215. (in Chinese)

[25] 龙满生,欧阳春娟,刘欢,等. 基于卷积神经网络与迁移学习的油茶病害图像识别[J]. 农业工程学报, 2018, 34(18): 194 - 201.
LONG Mansheng, OUYANG Chunjuan, LIU Huan, et al. Image recognition of camellia oleifera diseases based on convolutional neural network & transfer learning[J]. Transactions of the CSAE, 2018, 34(18): 194 - 201 (in Chinese)

[26] 周云成,许童羽,郑伟,等. 基于深度卷积神经网络的番茄主要器官分类识别方法[J]. 农业工程学报, 2017, 33(15): 219 - 226.
ZHOU Yuncheng, XU Tongyu, ZHENG Wei, et al. Classification and recognition approaches of tomato main organs based on DCNN[J]. Transactions of the CSAE, 2017, 33(15): 219 - 226. (in Chinese)

[27] 尼加提·卡斯木,师庆东,刘素红,等. 基于卷积网络的沙漠腹地绿洲植物群落自动分类方法[J/OL]. 农业机械学报, 2019, 50(1):217 - 225.
NIJAT Kasim, SHI Qingdong, LIU Suhong, et al. Automatic classification method of oasis plant community in desert hinterland based on VGGNet and ResNet models[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(1): 217 - 225. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag=1&file_no=20190124&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2019.01.024. (in Chinese)

[28] 袁培森,黎薇,任守纲,等. 基于卷积神经网络的菊花花型和品种识别[J]. 农业工程学报, 2018, 34(5):152 - 158.
YUAN Peisen, LI Wei, REN Shougang, et al. Recognition for flower type and variety of chrysanthemum with convolutional

neural network[J]. Transactions of the CSAE, 2018, 34(5): 152 - 158. (in Chinese)
[29] 姜红花,王鹏飞,张昭,等. 基于卷积网络和哈希码的玉米田间杂草快速识别方法[J/OL]. 农业机械学报, 2018, 49(11):30 - 38.
JIANG Honghua, WANG Pengfei, ZHANG Zhao, et al. Fast identification of field weeds based on deep convolutional network and binary hash code[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(11):30 - 38. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag=1&file_no=20181104&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2018.11.004. (in Chinese)
[30] 孙俊,何小飞,谭文军,等. 空洞卷积结合全局池化的卷积神经网络识别作物幼苗与杂草[J]. 农业工程学报, 2018, 34(11):159 - 165.
SUN Jun, HE Xiaofei, TAN Wenjun, et al. Recognition of crop seedling and weed recognition based on dilated convolution and global pooling in CNN[J]. Transactions of the CSAE, 2018, 34(11): 159 - 165. (in Chinese)
[31] REDMON J, FARHADI A. YOLOv3: an incremental improvement[J/OL]. arXiv:1804.02767v1. 2018. https://arxiv.org/abs/1804.02767.
[32] CANZIANI A, PASZKE A, CULURCIELLO E. An analysis of deep neural network models for practical applications[J/OL]. arXiv:1605.07678v4. 2017. https://arxiv.org/abs/1605.07678.
[33] WANG Shuaihua, XIE Shipeng, CHEN Xiangqing, et al. Alcoholism identification based on an AlexNet transfer learning model[J]. Frontiers in Psychiatry, 2019, 10:1 - 13.
[34] SHIN H C, ROTH H R, GAO M, et al. Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning[J]. IEEE Transactions on Medical Imaging, 2016, 35(5):1285 - 1298.
[35] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553):436 - 444.
[36] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6):84 - 90.
[37] MU Longtao, CUI Gongpei, LIU Yadong, et al. Design and simulation of an integrated end-effector for picking kiwifruit by robot [J/OL]. Information Processing in Agriculture 2019. https://www.sciencedirect.com/science/article/pii/S2214317318304372? via%3Dihub. DOI: https://doi.org/10.1016/j.inpa.2019.05.004.

(上接第 23 页)

[17] 高兰. 基于 PLC 的高空作业平台调平控制系统研究[D]. 石家庄: 石家庄铁道大学, 2016.
GAO Lan. Design of leveling control system for a high lift platform based on PLC[D]. Shijiazhuang: Shijiazhuang Tiedao University, 2016. (in Chinese)
[18] 秦敬贤. 基于模糊的高空作业平台自动调平系统[D]. 沈阳: 沈阳建筑大学, 2012.
QIN Jingxian. Research of suspend access platform automatic leveling system based of fuzzy PID[D]. Shenyang: Shenyang Jianzhu University, 2012. (in Chinese)
[19] 孙江宏, 何世风. 一种新型自动调平平台结构与控制系统设计[J]. 机械设计与制造, 2015(7): 11 - 15.
SUN Jianghong, HE Shifeng. Structure and control system design of a new automatic leveling platform[J]. Machinery Design & Manufacture, 2015(7): 11 - 15. (in Chinese)
[20] 王涛, 杨福增, 王元杰, 等. 山地拖拉机车身自动调平控制系统的设计[J]. 农机化研究, 2014, 36(7): 232 - 235.
WANG Tao, YANG Fuzeng, WANG Yuanjie, et al. Design of body automatic leveling control system of hillside tractor[J]. Journal of Agricultural Mechanization Research, 2014, 36(7): 232 - 235. (in Chinese)
[21] 何金伊,杨福增,徐秀栋. 山地履带式遥控微耕机控制系统设计[J]. 拖拉机与农用运输车, 2011, 38(2): 19 - 22.
HE Jinyi, YANG Fuzeng, XU Xiudong. Design of control system for mountain tracked remote control microgrid[J]. Tractors and Farming Vehicles, 2011, 38(2): 19 - 22. (in Chinese)
[22] 张战文. 微型履带山地拖拉机稳定性能研究[D]. 杨凌: 西北农林科技大学, 2011.
ZHANG Zhanwen. Research on stability of micro-hillside caterpillar tractor[D]. Yangling: Northwest A&F University, 2011. (in Chinese)
[23] 彭贺, 马文星, 王忠山, 等. 丘陵山地拖拉机车身调平控制仿真分析与试验[J]. 吉林大学学报(工学版), 2019, 49(1): 157 - 165.
PENG He, MA Wenxing, WANG Zhongshan, et al. Control system of self-leveling in hilly tractor body through simulation and experiment[J]. Journal of Jilin University(Engineering and Technology Edition), 2019,49(1): 157 - 165. (in Chinese)
[24] 彭贺, 马文星, 赵恩鹏, 等. 丘陵山地轮式拖拉机车身调平系统设计与物理模型实验[J]. 农业工程学报, 2018, 34(14): 36 - 44.
PENG He, MA Wenxing, ZHAO Enpeng, et al. Design and physical model experiment of body leveling system for roller tractor in hilly and mountainous region[J]. Transactions of the CSAE, 2018, 34(14): 36 - 44. (in Chinese)