

基于 Faster R – CNN 的田间西兰花幼苗图像检测方法

孙哲 张春龙 葛鲁镇 张铭 李伟 谭豫之

(中国农业大学工学院, 北京 100083)

摘要: 为解决自然环境下作物识别率不高、鲁棒性不强等问题,以西兰花幼苗为研究对象,提出了一种基于 Faster R – CNN 模型的作物检测方法。根据田间环境特点,采集不同光照强度、不同地面含水率和不同杂草密度下的西兰花幼苗图像,以确保样本多样性,并通过数据增强手段扩大样本量,制作 PASCAL VOC 格式数据集。针对此数据集训练 Faster R – CNN 模型,通过设计 ResNet101、ResNet50 与 VGG16 网络的对比试验,确定 ResNet101 网络为最优特征提取网络,其平均精度为 90.89%,平均检测时间 249 ms。在此基础上优化网络超参数,确定 Dropout 值为 0.6 时,模型识别效果最佳,其平均精度达到 91.73%。结果表明,本文方法能够对自然环境下的西兰花幼苗进行有效检测,可为农业智能除草作业中的作物识别提供借鉴。

关键词: 西兰花幼苗; 作物识别; 深度学习; 卷积神经网络; Faster R – CNN

中图分类号: TP391.4 **文献标识码:** A **文章编号:** 1000-1298(2019)07-0216-06

Image Detection Method for Broccoli Seedlings in Field Based on Faster R – CNN

SUN Zhe ZHANG Chunlong GE Luzhen ZHANG Ming LI Wei TAN Yuzhi

(College of Engineering, China Agricultural University, Beijing 100083, China)

Abstract: Traditional methods of image processing for crop detection under agricultural natural environment are easily affected by small samples and subjective judgment, so they have many disadvantages such as low recognition rate and low robustness. Deep learning can self-study according to data set, and has a strong ability to express feature. Therefore, a new broccoli seedlings detection approach based on Faster R – CNN model was proposed. Data acquisition was the first step to build deep learning model, and the diversity of data can improve the generalization ability of the model. According to the characteristics of field environment, broccoli seedlings images with different light intensities, different ground moisture contents and different weed densities were collected. The sample size was expanded by images rotation and noise enhancement, and data set was transformed as PASCAL VOC format. And then the Faster R – CNN model was trained by using data set. Contrast experiment was designed on ResNet101, ResNet50 and VGG16 networks. The results showed that ResNet101 network with the deepest network layer and smaller parameter space was the best feature extraction network. The average detection accuracy was 90.89%, and the average time-consuming was 249 ms. Based on that, the network super-parameters were optimized and the average accuracy of model detection reached 91.73%, when Dropout value was 0.6. The results showed that this approach can effectively detect broccoli seedlings in agricultural natural environment, and provided a hopeful solution for crop detection in the field of agriculture.

Key words: broccoli seedlings; crop recognition; deep learning; convolutional neural network; Faster R – CNN

收稿日期: 2019-01-06 修回日期: 2019-01-30

基金项目: 国家重点研发计划项目(2017YFD0701300)

作者简介: 孙哲(1990—),男,博士生,主要从事农业机器人研究,E-mail: sunzhe0109@foxmail.com

通信作者: 谭豫之(1964—),男,教授,博士生导师,主要从事农业机器人和智能化农业装备研究,E-mail: yztan@cau.edu.cn

0 引言

中国是西兰花生产大国,总产量约 150 万 t,占全球 7% 左右,随着种植面积不断扩大,西兰花除草工作量逐年增大^[1-2]。目前,我国除草作业主要采用化学除草与人工除草,在食品安全意识与劳动力成本提高的背景下^[3],发展智能除草装备具有广阔的应用前景^[4-6]。作为智能除草装备的核心技术之一^[7],快速精准的作物识别是影响除草质量的关键因素。

近年来,科研工作者对自然环境下作物识别进行了深入研究^[8-13]。陈树人等^[14]提出基于颜色特征的棉花与杂草识别技术,采用 R 分量与 B 分量的标准差小于 5 作为判断苗草的阈值,对棉花识别的总体准确率为 82.1%。HERRMANN 等^[15]利用高光谱成像技术获取麦田图像,并设计基于最小二乘法的分类器,分割小麦与杂草,对田间作物的分类准确率为 72%。GARCIA 等^[16]在分割植物与土壤背景后,利用 Otsu 自动阈值分割法区分作物和杂草,该方法对作物的正确识别率为 86.3%。张志斌等^[17]研究了基于快速 SURF 特征的提取算法,该方法中立体视觉系统的左、右目作物图像正确匹配率分别为 94.8% 和 92.4%。NIEUWENHUIZEN 等^[18]结合颜色与纹理特征,采用自适应贝叶斯分类器进行分类,该方法对固定光照和变化光照条件下甜菜的正确分类率分别为 89.8% 和 67.7%。

上述传统识别方法主要根据经验,易受小样本和人为主观因素影响^[19],无法找到通用特征模型,鲁棒性不强,很难用一种方法对复杂田间环境下的作物进行有效识别。相比传统方法,深度学习采用数据本身特征进行自我学习,对图像具有极强的表征能力,可以克服传统方法的不足。彭红星等^[20]利用改进 SSD 模型,对自然环境下的荔枝、皇帝柑、脐橙和苹果进行检测,平均检测精度为 89.53%。周云成等^[21]提出一种基于深度卷积神经网络的番茄器官分类识别方法,分类错误率低于 6.39%。

基于深度学习准确度高、普适性强的特点,本文采用 Faster R - CNN^[22]模型对自然环境下的西兰花幼苗进行识别。依据田间环境下西兰花幼苗图像特点,优化特征提取网络与超参数,建立一种基于深度卷积神经网络的西兰花幼苗图像识别模型。

1 数据材料

1.1 数据采集

试验图像于 2018 年 4—5 月采集自北京国际都

市农业科技园,采集设备为 Canon SX730 HS 型相机,图像分辨率为 1 600 像素 × 1 200 像素,共采集图像样本 6 230 幅。为保证图像样本的多样性,针对 3 块不同播种时间的试验田,分别采集西兰花幼苗除草期的作物图像。图像样本包含不同光照强度、不同地面含水率和不同杂草密度等情况,部分样本示例如图 1 所示。




图 1 部分样本示例

Fig. 1 Examples of sample diversity

1.2 数据集建立

图像采集过程中虽然已考虑样本所处环境的多样性,但西兰花幼苗叶和茎的生长以及成像角度具有随机性,因此本文采用图像旋转 0°、90°、180°和 270°的方法进行数据增强,将总样本数扩大至 4 倍,提高训练模型的泛化能力。受样本集规模与训练次数的影响,深度卷积神经网络会对图像样本的高频特征进行学习,导致过拟合的出现。本文在图像样本上添加零均值特性的高斯噪声,使图像样本在所有频率上都产生数据点,可有效抑制高频特征,减小其对模型的影响。

将整体样本按照 PASCAL VOC 数据集格式进行划分,试验样本数据集包括训练集图像 17 440 幅,测试集图像 7 480 幅,总样本数为 24 920。训练集从整体样本中随机选出,且与测试集互斥。为保证所得模型的可靠与稳定,训练过程中将训练集平均划分为 n 份,每次选取 $n - 1$ 份作为训练集,另外 1 份作为验证集,验证集上 n 次误差的平均值作为该模型的误差,最后采用测试集评估模型的泛化能力。

2 检测方法

2.1 Faster R-CNN 模型框架

Faster R-CNN 模型是对 R-CNN^[23] 和 Fast R-CNN^[24] 的改进,通过卷积神经网络提取候选框,同时加入多任务学习,使得网络训练过程中能够同时获得物体所属类别和位置。基于 Faster R-CNN 的西兰花幼苗检测步骤如下:

(1)利用特征提取网络提取图像的特征图,该特征图被后续候选区域(RPN)网络与 Fast R-CNN

网络共享。

(2)RPN 网络通过 Softmax 分类器执行二分类任务,判断锚点(anchors)属于前景还是背景,并通过锚点回归得到候选框位置。

(3)Fast R-CNN 综合特征图与候选框信息,判别前景所属类别,并生成最终检测框的精确位置。

Faster R-CNN 模型结构如图 2 所示,Faster R-CNN 用 RPN 网络代替 Fast R-CNN 中 Selective Search 方法实现候选框的提取,提高了检测的精度与速度。




图 2 Faster R-CNN 模型结构

Fig.2 Faster R-CNN architecture

2.2 RPN 网络

使用 RPN 网络提取候选框,使 Faster R-CNN 实现了端到端的物体检测。RPN 网络是一个全卷积网络,在特征图传入 RPN 后,使用 3×3 的滑窗生成一个 n 维长度的特征向量,然后将此特征向量分别传入分类层与回归层。在分类层中,使用 Softmax 分类器对锚点进行前景与背景的判断。在回归层中,通过调整锚点边框的中心坐标与长宽,拟合出候选框位置。在训练过程中,RPN 网络的损失函数^[22]、分类层损失函数^[22]与回归层损失函数^[24]如下

$$L(p_i, \mathbf{t}_i) = \frac{1}{N_{\text{cls}}} \sum_i L_{\text{cls}}(p_i, p_i^*) + \lambda \frac{1}{N_{\text{reg}}} \sum_i p_i^* L_{\text{reg}}(\mathbf{t}_i, \mathbf{t}_i^*) \quad (1)$$

其中 $L_{\text{cls}}(p_i, p_i^*) = -\lg(p_i p_i^* + (1 - p_i^*)(1 - p_i))$ (2)

$$L_{\text{reg}}(\mathbf{t}_i, \mathbf{t}_i^*) = \sum_i \text{smooth}_{L_1}(\mathbf{t}_i - \mathbf{t}_i^*) \quad (3)$$

$$\text{smooth}_{L_1}(\mathbf{t}_i - \mathbf{t}_i^*) = \begin{cases} 0.5(\mathbf{t}_i - \mathbf{t}_i^*)^2 & (|\mathbf{t}_i - \mathbf{t}_i^*| < 1) \\ |\mathbf{t}_i - \mathbf{t}_i^*| - 0.5 & (|\mathbf{t}_i - \mathbf{t}_i^*| \geq 1) \end{cases} \quad (4)$$

$$p_i^* = \begin{cases} 1 & (\text{锚点为正样本}) \\ 0 & (\text{锚点为负样本}) \end{cases} \quad (5)$$

- 式中 L ——RPN 网络损失
 L_{cls} ——分类层损失
 L_{reg} ——回归层损失
 i ——锚点索引
 $\mathbf{t}_i$ ——预测边界框坐标向量
 $\mathbf{t}_i^*$ ——真实边界框坐标向量
 N_{cls} ——分类样本数
 N_{reg} ——回归样本数
 p_i ——目标的预测概率
 p_i^* ——锚点判别值
 λ ——权重参数
 smooth_{L_1} ——平滑函数

2.3 特征共享

RPN 与 Fast R-CNN 为两个独立的网络,分别进行单独训练无法获得收敛结果。本文采用交替训练方法对网络进行训练。首先采用 ImageNet 的预训练模型对 RPN 网络中的卷积层进行参数初始化,获得图像通用特征,并生成候选区域框。其次,利用 RPN 网络输出的候选框对 Fast R-CNN 进行训练。

然后,用 Fast R - CNN 卷积层参数训练 RPN 网络,仅更新 RPN 中特有网络层参数。最后固定共享卷积层,微调 Fast R - CNN 的全连接层,将 RPN 与 Fast R - CNN 统一起来,实现两个网络共享相同的卷积层。

3 试验设计与结果分析

3.1 试验平台

试验处理平台为台式计算机,处理器为 Intel Core i7 - 8700k,主频 3.7 GHz, 16 GB 内存,500 GB 固态硬盘, GPU 采用 NVIDIA 1080Ti,运行环境为 Windows 10 (64 位) 系统, Python 3.5.4, Tensorflow 1.8.0, CUDA 9.0.176 版并行计算架构与 cuDNN 9.0 版深层神经网络库。

3.2 试验评价指标

采用平均精度 (Average precision) 作为目标检测的评价指标。平均精度与精确率、召回率有关,精确率和召回率的计算方法为

$$P_{re} = \frac{T_p}{T_p + F_p} \times 100\%$$

(6)

$$R_{ec} = \frac{T_p}{T_p + F_N} \times 100\%$$

(7)

式中 P_{re} ——精确率 R_{ec} ——召回率
 T_p ——被正确划分为正样本的数量
 F_p ——被错误划分为正样本的数量
 F_N ——被错误划分为负样本的数量

绘制精确率-召回率曲线,曲线的横轴召回率反映了分类器对正样本的覆盖能力,纵轴精确率反映了分类器预测正样本的精准度。平均精度是对精确率-召回率曲线进行积分,积分公式为

$$A_p = \int_0^1 P_{re} R_{ec} dR_{ec}$$

(8)

式中 A_p ——平均精度
平均精度体现模型识别效果,其值越大效果越好,反之越差。

3.3 试验设计

在模型训练中,特征提取器的选择可影响模型的检测精度与速度,随着特征提取器层数的增加,网络能够提取更高维度的样本特征,检测准确度应该同步增加,但是网络深度的增加会对各层更新信号造成影响,由于采用误差反向传播的方式,网络深度增加后,前层网络梯度变化非常缓慢,产生梯度消失问题。并且在网络层数增加的同时,模型的参数空间也随之扩张,巨大的参数量使得优化问题变得更加复杂,单纯地堆叠网络深度反而会出现更高的训练误差。

在训练一个深层网络时,假设存在一个性能最佳网络 N ,整体网络与网络 N 相比会存在多余层,训练结果希望这些多余层是恒等变换,即让一些层拟合恒等映射函数 $H(x) = x$,其中 x 为输入变量,此时整体网络为最优网络。HE 等^[25]根据恒等变换的映射关系,提出残差网络 (ResNet) 结构。此模型使用残差块,如图 3 所示,通过加入残差通路,学习残差函数 $F(x) = H(x) - x$ 。求解 $F(x) = 0$ 时,网络多余层实现恒等映射, $H(x) - x$ 过程可以去掉相同的主干部分,从而突出微小的权重变化。




图 3 残差块
Fig. 3 ResNet block

这种改进能够有效解决梯度消失与训练退化问题,因此本试验采用 ResNet50 网络、ResNet101 网络与经典的 VGG16 网络进行对比试验,结果如表 1 所示。

表 1 特征提取器对比试验结果
Tab.1 Comparison test result of feature extractor

测试指标	特征提取器		
	VGG16	ResNet50	ResNet101
平均精度/%	89.34	90.72	90.89
平均检测时间/ms	263	243	249

为了降低模型的泛化误差,通常采用训练几个不同模型,然后让所有模型表决测试样例的输出,但当模型是一个庞大的神经网络时,会消耗大量的运行时间与内存。因此本文采用 Dropout 方式,在每个训练批次中,通过随机忽略一定比例的隐含层节点,来降低运行时间。由于被忽略隐含层节点是随机选取的,因此每个批次都在训练不同的网络参数,最后通过参数共享使模型的泛化误差降低。并且 Dropout 在网络训练过程中,可有效减少神经元之间的相互依赖,从而提取出独立的重要特征,抑制网络过拟合。

在网络训练过程中,通常随机忽略一半的神经元^[26],即 Dropout 设置为 0.5。但 Dropout 对平均精度的影响与数据集规模和训练次数有关,在本试验中,通过设置间隔的 Dropout 值来寻找最高的平均精度,如表 2 所示。

3.4 结果与分析

由表 1 可知,基于本文所用试验平台,使用网络层数最深、参数空间较小的 ResNet101 网络作为特征提取器时,可以保证在较快的检测速度下获得最

表 2 参数优化试验

Tab.2 Parameters optimization test

测试指标	Dropout 值			
	0.4	0.5	0.6	0.7
平均精度/%	90.02	90.89	91.73	89.86
平均检测时间/ms	251	249	248	248

佳的检测效果,其平均精度为 90.89%,平均耗时 249 ms。由表 2 可知,在使用 ResNet101 网络作为特征提取网络的基础上,设置 Dropout 值为 0.6 时,可以取得最佳的西兰花幼苗识别效果,其平均精度为 91.73%,平均耗时 248 ms。

为更好地显示卷积神经网络的运作流程,将特征提取的部分中间过程进行可视化操作,并将图像统一尺寸以便观察。如图 4 所示,随着网络深度的增加,特征图颗粒度增强,高维特征逐步凸显。可以看出浅层网络的特征,图 4b~4e 包括边缘和线条等细节,凸显局部信息。网络深层的特征是一种全局信息,图 4g~4i 具有更强的语义特征。经过卷积网络的多层特征表达,能够有效提取西兰花幼苗特征,降低噪声干扰,强化目标学习。




图 4 卷积层特征图

Fig.4 Feature maps of convolution layer

使用训练好的网络模型对复杂自然环境下的西兰花幼苗进行识别,结果如图 5 所示。针对叶片完

整的西兰花幼苗具有良好的检测效果,但在检测虫蚀作物样本时,出现定位不准的情况,如图 5i 所示,降低了整体的平均检测精度。原因是图像采集过程中,田间的虫蚀作物较少,虫蚀样本占总样本的比例低,因此训练模型对其识别敏感度不足,可通过增加此类图像数量,提高本方法对虫蚀类型的包容性。




图 5 测试结果

Fig.5 Test results

综上可知,本文采用的 Faster R - CNN 模型具有较高的检测精度,对光照强度、地面含水率和杂草密度变化具有较好的鲁棒性,能够有效识别自然环境下的西兰花幼苗,且耗时较短,可满足智能除草装备对作物识别的要求。

4 结论

(1)提出了一种基于 Faster R - CNN 的自然环境下西兰花幼苗检测方法,通过卷积神经网络对数据本身特征进行非线性表达,能够从复杂数据中学习西兰花幼苗的特征,增强了模型的鲁棒性。

(2)以ResNet50 网络、ResNet101 网络和 VGG16 网络作为特征提取器进行对比试验,确定了 ResNet101 网络为最佳特征提取器,并在该网络下,设 Dropout 值为 0.6,使西兰花幼苗检测的平均精度达到 91.73%,平均耗时为 248 ms。

参 考 文 献

[1] 刘伟明,汪恩国,蔡建军,等. 西兰花早中熟品种不同苗龄高密度栽培技术研究[J]. 农学学报,2018,8(11): 49 - 53.
LIU Weiming, WANG Enguo, CAI Jianjun, et al. High density cultivation techniques of early-middle maturing broccoli at different seedling ages[J]. Journal of Agriculture,2018,8(11):49 - 53. (in Chinese)

[2] 马爱民,刘宗陈,陆亚琴,等. 秋播西兰花大面积生产 667 m²产量超 1 000 kg 高产栽培技术[J]. 长江蔬菜,2018(23):20 - 21.

[3] 赵国庆. 农业机械自动化的现状与推进模式[J]. 湖南农机,2014,41(12):6 - 7.

[4] PIRON A. Selection of the most efficient wavelength bands for discriminating weeds from crop[J]. Computers and Electronics in Agriculture,2008,62(2):141 - 148.

[5] 李先鋒,朱伟兴,纪滨,等. 基于特征优化和 LS - SVM 的棉田杂草识别[J]. 农业机械学报,2010,41(11):168 - 172.
LI Xianfeng, ZHU Weixing, JI Bin, et al. Weed identification based on features optimization and LS - SVM in the cotton field [J]. Transactions of the Chinese Society for Agricultural Machinery,2010,41(11):168 - 172. (in Chinese)

- [6] 胡炼,罗锡文,曾山,等. 基于机器视觉的株间机械除草装置的作物识别与定位方法[J]. 农业工程学报,2013,29(10): 12-18.
HU Lian,LUO Xiwen,ZENG Shan,et al. Plant recognition and localization for intra-row mechanical weeding device based on machine vision[J]. Transactions of the CSAE,2013,29(10):12-18. (in Chinese)
- [7] LI N,GRIFT T E,YUAN T,et al. Image processing for crop/weed discrimination in fields with high weed pressure[C]//Michigan:American Society of Agricultural and Biological Engineers,2016.
- [8] CHRISTINE M,ONYANGO J A. Segmentation of row crop plants from weeds using colour and morphology[J]. Computers and Electronics in Agriculture,2003,39(3):141-155.
- [9] SI C. Weed-plant discrimination by machine vision and artificial neural network[J]. Biosystems Engineering,2002,83(3):275-280.
- [10] 刘洪臣,陈建忠,冯勇. 结合颜色和形态特征的杂草实时识别方法[J]. 光电工程,2006,33(7):96-100.
LIU Hongchen,CHEN Zhongjian,FENG Yong. Real-time weed recognition method based on color and morphological features [J]. Opto-Electronic Engineering,2006,33(7):96-100. (in Chinese)
- [11] 李颖,张立福,严薇,等. 地面成像光谱数据的田间杂草识别[J]. 遥感学报,2013,17(4):855-871.
LI Ying,ZHANG Lifu,YAN Wei,et al. Weed identification using imaging spectrometer data[J]. Journal of Remote Sensing, 2013,17(4):855-871. (in Chinese)
- [12] 乔永亮,何东健,赵川源,等. 基于多光谱图像和 SVM 的玉米田间杂草识别[J]. 农机化研究,2013,35(8):30-34.
- [13] CHEN Y,JIN X,TANG L,et al. Intra-row weed recognition using plant spacing information in stereo images[C]//Michigan: American Society of Agricultural and Biological Engineers,2013.
- [14] 陈树人,沈宝国,毛罕平,等. 基于颜色特征的棉田中铁苋菜识别技术[J]. 农业机械学报,2009,40(5):149-152.
CHEN Shuren,SHEN Baoguo,MAO Hanping,et al. Herb detection from cotton field based on color feature[J]. Transactions of the Chinese Society for Agricultural Machinery,2009,40(5):149-152. (in Chinese)
- [15] HERRMANN I,SHAPIRA U,KINAST S,et al. Ground-level hyperspectral imagery for detecting weeds in wheat fields[J]. Precision Agriculture,2013,14(6):637-659.
- [16] GARCIA I D,MONTALVO M,GUERRERO J M,et al. Automatic detection of curved and straight crop rows from images in maize fields[J]. Biosystems Engineering,2017,156:61-79.
- [17] 张志斌,赵帅领,罗锡文,等. 基于 SURF 算法的绿色作物特征提取与图像匹配方法[J]. 农业工程学报,2015,31(14): 172-178.
ZHANG Zhibin,ZHAO Shuailing,LUO Xiwen,et al. Matching method of green crops based on SURF feature extraction[J]. Transactions of the CSAE,2015,31(14):172-178. (in Chinese)
- [18] NIEUWENHUIZEN A T,HOFSTEE J W,HENTEN E J. Adaptive detection of volunteer potato plants in sugar beet fields[J]. Precision Agriculture,2010,11(5):433-447.
- [19] 傅隆生,冯亚利,ELKAMIL T,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 T,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)
- [20] 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 模型[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)
- [21] 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)
- [22] REN S,HE K,GIRSHICK R,et al. Faster R-CNN: towards real-time object detection with region proposal networks[C]// Montréal:International Conference on Neural Information Processing Systems,2015.
- [23] GIRSHICK R,DONAHUE J,DARRELL T,et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//Ohio:Conference on Computer Vision and Pattern Recognition,2014.
- [24] GIRSHICK R. Fast R-CNN[C]//Santiago:International Conference on Computer Vision,2015.
- [25] HE K,ZHANG X,REN S,et al. Identity mappings in deep residual networks[C]//European Conference on Computer Vision,2016:630-645.
- [26] SRIVASTAVA N,HINTON G,KRIZHEVSKY A,et al. Dropout: a simple way to prevent neural networks from overfitting[J]. Journal of Machine Learning Research,2014,15(1):1929-1958.