

基于深度学习与图像处理的蔬菜苗期 杂草识别方法

金小俊¹, 孙艳霞², 于佳琳³, 陈勇¹

(1. 南京林业大学机械电子工程学院, 南京 210037; 2. 南京交通职业技术学院轨道交通学院, 南京 211188;
3. 北京大学现代农业研究院, 山东 潍坊 261325)

摘要:对苗期青菜及其伴生杂草进行识别试验,提出了一种基于识别蔬菜进而间接识别杂草的独特方法,该方法结合深度学习和图像处理技术,可以有效降低杂草识别的复杂度,同时提高识别的精度和鲁棒性。首先,采用神经网络模型对青菜进行识别,并标记边框;然后,将青菜边框之外的绿色目标视为杂草,利用颜色特征将其分割,并通过面积滤波得到滤除噪点后的杂草区域;为探究不同深度学习模型对青菜识别的效果,选取SSD模型、RetinaNet模型和FCOS模型,以 F_1 值、平均精度和检测速度3个评价指标进行对比分析。结果表明,SSD模型为青菜识别最优模型,拥有最高的检测速度和较优的识别率,其在测试集的 F_1 值、平均精度和检测速度分别为95.4%、98.1%和31.0 f/s;改进后的MExG因子能有效识别杂草,分割后的杂草形态完整且轮廓清晰。本文提出的蔬菜田杂草识别方法具有高度的可行性和极佳的应用效果,可为相似作物田杂草识别提供技术参考。

关键词:农业工程;蔬菜识别;杂草识别;深度学习;图像处理;颜色特征

中图分类号:TP391.41 **文献标志码:**A **文章编号:**1671-5497(2023)08-2421-09

DOI:10.13229/j.cnki.jdxbgxb.20211070

Weed recognition in vegetable at seedling stage based on deep learning and image processing

JIN Xiao-jun¹, SUN Yan-xia², YU Jia-lin³, CHEN Yong¹

(1. College of Mechanical and Electronic Engineering, Nanjing Forestry University, Nanjing 210037, China; 2. School of Rail Transportation, Nanjing Vocational Institute of Transport Technology, Nanjing 211188, China; 3. Institute of Advanced Agricultural Sciences, Peking University, Weifang 261325, China)

Abstract: In this study, the recognition test of bok choy and its associated weeds at the seedling stage was carried out, and a novel method based on recognizing vegetables and then indirectly recognizing weeds was proposed. By combining deep learning and image processing technology, this method can effectively reduce

收稿日期:2021-10-18.

基金项目:国家自然科学基金项目(32072498);江苏省重点研发计划项目(BE2021016);江苏省农业科技自主创新项目(CX(21)3184).

作者简介:金小俊(1987-),男,工程师,博士研究生.研究方向:机器视觉与人工智能技术.

E-mail:xiaojun.jin@outlook.com

通信作者:陈勇(1965-),男,教授,博士.研究方向:机电一体化. E-mail:chenyongsj@163.com

the complexity of weed recognition, and at the same time improving the accuracy and robustness of weed recognition. First, a neural network model was used for detecting the bok choy and drawing bounding boxes. The green targets outside the bok choy bounding boxes were marked as weeds, and color features were used to segment them. Besides, an area filter was used for eliminating the noises and extracting weed regions. In order to explore the effects of different deep learning models on bok choy recognition, SSD model, RetinaNet model and FCOS model were selected, and three evaluation metrics of F_1 value, average accuracy and detection speed were used for comparative analysis. The SSD model was the best model for bok choy recognition, with the highest detection speed and excellent recognition rate. Its F_1 value, average accuracy and detection speed in the test set were 95.4%, 98.1% and 31.0 f/s, respectively. The improved MExG index can effectively recognize weeds, and the segmented weeds have complete shapes and clear outlines. Experiment results show that the proposed method for recognizing weeds in vegetable fields is highly feasible and has excellent application effects, which can also provide technical reference for weed recognition in similar crop fields.

Key words: agricultural engineering; vegetable recognition; weed recognition; deep learning; image processing; color feature

0 引言

蔬菜产业是农业的重要组成部分。我国既是蔬菜生产大国,又是蔬菜消费大国^[1]。蔬菜是除粮食作物外栽培面积最广、经济地位最重要的作物^[2]。目前我国蔬菜种植面积已突破3亿亩,产量超过7亿吨,是世界第一大蔬菜生产国^[3,4]。杂草不仅与蔬菜争夺水分和养料,而且促进病虫害的滋生^[5]。蔬菜田杂草有140多种,杂草防除方法有人工除草、化学除草、生物除草和机械除草等^[6-8]。人工除草劳动强度大且效率低,化学除草见效快,但不适宜出苗后的蔬菜杂草防治。生物除草虽然环保,但不适用于突发性的草害。机械除草作为一种绿色无公害除草方式在有机蔬菜种植中已经得到广泛重视。目前,出苗后的蔬菜田里主要还是采用人工除草^[1,7]。但是,农村用工紧缺、劳动力成本的提高不仅提高了蔬菜种植成本,也限制了蔬菜产业的发展^[9]。因此,研发高效智能除草装备势在必行。要想实现智能化除草,首先需要实现对杂草的精准识别^[10,11]。

传统杂草识别方法^[12-15]需要人工设计特征、操作复杂,存在着识别速度慢、精准度不足等缺陷^[10,16-18]。随着人工智能技术的发展,深度学习卷积神经网络得到了广泛的应用^[19-23]。目前国内外研究者也在陆续开展基于深度学习的杂草识别研究^[24-27]。董亮等^[28]基于改进型人工神经网络对温室大棚中培育的花椰菜杂草进行识别。试验表明,对于空心莲子草、马唐草、小画眉草、马齿苋、

婆婆纳5种杂草的识别率可达94%;孙俊等^[29]将甜菜及杂草的近红外与可见光图像融合为4通道图像,利用深度可分离卷积以及残差块构成分割识别模型的卷积层,可有效实现杂草的分割;Osorio等^[30]利用基于支持向量机(SVM)的机器学习技术和基于YOLO-v3、Mask R-CNN的深度学习方法对生菜田中的杂草进行识别,其 F_1 指数分别为88%、94%和94%;Elstone等^[31]同样以生菜田杂草为研究对象,采用多光谱特征对生菜和杂草进行区分,并通过立体相机进一步获取深度信息,田间试验中杂草识别率为81%。

相对于条播作物的规律性种植,蔬菜田中作物和杂草通常都是随机分布的。因此,蔬菜田中的杂草识别更具复杂性和挑战性。目前国内外相关研究尚少,仍处于探索阶段。在菜地里,蔬菜之外的植物都是杂草或者可以被看作杂草,识别出蔬菜即等价于识别出杂草。杂草种类繁多,对杂草进行逐一识别不仅复杂而且精度较低,极易出现误识别。通过识别蔬菜进而间接识别杂草,可有效降低杂草识别的复杂度,同时提高识别精度。本文拟基于这一独特思路进行验证分析,以期解决蔬菜田杂草识别这一制约精确除草的瓶颈问题,同时,为相似作物田杂草识别提供技术参考。

1 材料与方法

1.1 图像采集

本文以苗期青菜(*brassica rapa* spp. *chinensis*)及

其伴生杂草为研究对象进行识别试验。青菜秧苗图像于 2020 年 7 月和 9 月分两批采集于江苏省南京市八卦洲的蔬菜园中。图像采集设备为佳能 EOS 600D 相机,拍摄角度与地面垂直。图像原始分辨率为 3024×4032 像素,共采集图像样本 1150 幅。为保证深度学习训练样本的多样性,图像采集在不同播种时间的试验田,以及晴天、阴天不同光线状态下进行。对于采集的样本图像,使用 LabelImg 软件进行图像标注,标注信息为目标物(青菜秧苗)的矩形区域,标注完成后生成与图像对应的 XML 标签文件,随后作为输入供深度学习模型进行训练。标注图像按照 8:1:1 的比例随机分为训练集,验证集和测试集。

1.2 深度学习框架

为探究不同深度学习模型对青菜识别的效果,本研究拟选取不同目标检测模型进行评价分析。试验深度学习平台为 MMDetection 框架^[32]。MMDetection 是一款基于 PyTorch 的目标检测开源工具箱,支持众多主流的目标检测算法。本文所用模型均取自 MMDetection 框架,以使不同模型的对比处于标准、公平的环境之下。深度学习训练

和运行的硬件系统为台式计算机,搭载 Inter(R) core(TM) i9-9900K CPU @3.60 GHz 处理器,图形处理单元为 NVIDIA GeForce RTX 2080Ti,运行内存为 64 GB,操作系统为 Ubuntu 20.04。

1.3 杂草识别方法

本文拟结合深度学习和图像处理技术实现蔬菜杂草识别。如图 1 所示,首先通过深度学习中的目标检测模型识别蔬菜。蔬菜之外的绿色目标则视为杂草,继而采用图像处理技术对蔬菜目标之外的像素(杂草)进行分割以识别杂草。具体步骤如下:采集自然环境下的蔬菜图像,建立蔬菜样本数据库训练神经网络模型;利用训练完成的神经网络模型对蔬菜进行识别,并标记边框(bounding box);遍历图像中的像素点,若处于蔬菜边框内,则抛弃该像素点,反之,应用颜色因子进行像素值计算,如此,得到只包含杂草目标的二值化图像;图像分割过程中,由于背景干扰物及颜色因子本身误差影响,会产生若干噪点,需要通过面积滤波对这些噪点进行滤除,以最终实现图像背景分割,即仅保留图像中的杂草区域实现杂草识别。

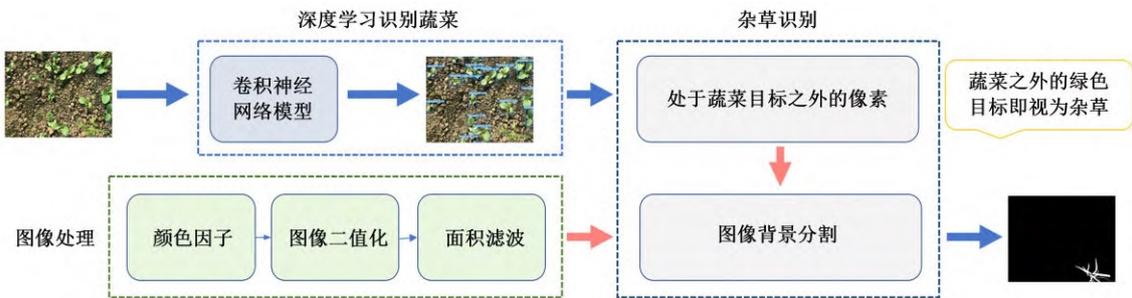


图 1 杂草识别流程示意图

Fig. 1 Flow chart of weed recognition

2 基于深度学习的青菜识别

2.1 检测模型

当前目标检测模型主要分为基于锚框(anchor-based)和无锚框(anchor-free)两类,前者又可分为基于区域提议(Region proposal network, RPN)的二阶(two-stage)检测器和基于回归的单阶(one-stage)检测器^[24,33]。二阶检测器可以提供更高的精度,但性能逊于单阶检测器^[20]。无锚框检测器避免了锚框相关的计算,通过端到端处理,提高了检测效率^[27]。智能除草装备依赖于高性能的实时杂草识别^[34]。基于识别速度考虑,本文分别选取单阶检测器中的 SSD 模型^[35]和 Reti-

naNet 模型^[36]以及无锚框检测器中的 FCOS 模型^[37],从识别率和识别速度两个方面进行综合对比,并根据评价结果选取最优模型进行青菜杂草识别试验。表 1 为不同模型的超参设置。

2.2 评价指标

本文采用精度(precision)、召回率(recall)、 F_1

表 1 不同模型超参设置

Table 1 Hyperparameters of each model

模型	批尺寸	动量	初始学习率/ 10^{-3}	优化器	衰减值/ 10^{-4}	训练周期
SSD	4	0.9	2	SGD	5	24
RetinaNet	4	0.9	10	SGD	1	24
FCOS	4	0.9	10	SGD	1	24

值,以及平均精度(average precision)作为目标检测评价指标。在本研究场景下,精度表示样本中模型正确检测出的青菜目标与预测为青菜目标的比值。召回率表示样本中所有青菜目标被正确预测的比例。精度和召回率的定义如下:

$$\text{precision} = \frac{tp}{tp + fp} \quad (1)$$

$$\text{recall} = \frac{tp}{tp + fn} \quad (2)$$

式中: tp 为被正确划分为正样本的数量; fp 为被错误划分为正样本的数量; fn 为被错误划分为负样本的数量。

F_1 值是目标检测中常用的综合评价指标,其结合了精度与召回率。计算方式为取精度与召回率的调和平均数:

$$F_1 = \frac{2 \times \text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \quad (3)$$

平均精度体现模型的总体检测效果,值越高表明模型的检测效果越佳。通过对精度和召回率曲线进行积分,得到精度-召回率曲线(PR-Curve)与坐标轴构成的面积值即为平均精度。其计算公式为:

$$AP = \int_0^1 \text{precision}(\text{recall}) dR \quad (4)$$

3 基于图像处理的杂草识别

杂草与青菜颜色相近,但与土壤背景等差异较大。首先,利用深度学习识别出青菜,青菜之外的植物则认为是杂草。如此,只需识别出青菜边框之外的绿色目标即可实现杂草识别。本文基于颜色特征,采用 Burgos-Artiztu 等^[38]提出的 MExG 因子对杂草进行分割。杂草在 RGB 图像中呈现为绿色,因而对于每个杂草像素,其 G 分量值大于 R 分量值和 B 分量值。根据此特征,对 MExG 因子进行条件改进,以进一步提高分割效果及效率。改进后的 MExG 因子如下所示:

$$\text{MExG} = \begin{cases} 0, & \text{if}(G < R \parallel G < B) \\ 1.262G - 0.884R - 0.311B, & \text{otherwise} \end{cases} \quad (5)$$

对于图像中的每个像素点,首先判断其是否处于青菜边框内:若是,则直接将其像素值置为 0,反之,应用 MExG 进行像素值计算。如此,得到只包含杂草目标的二值图像。图像分割过程中,由于背景及颜色因子本身误差影响,会产生一

些噪点。这些噪点往往面积较小,且孤立分散于图像内。本文利用面积滤波法进行噪点滤除,具体为标记图像中的像素连通区域,计算区域内像素个数,该数值即为区域面积值。若面积值小于预设阈值,则认为是噪点并滤除。

4 结果与分析

4.1 青菜识别

深度学习训练集包含 920 张图像,验证集和测试集各包含 115 张图像。其中,训练集、验证集和测试集分别包含 11 339、1552 和 1580 个青菜目标。深度学习模型在识别过程中会根据置信度判定当前预测目标是否是正样本。因而,置信度的选取决定了模型的评价数据。不同置信度阈值(0.9、0.8、0.7、0.6、0.5、0.4、0.3、0.2 和 0.1)对应的评价数据如表 2 所示。基于验证集不同置信

表 2 验证集不同置信度阈值的评价数据

Table 2 Evaluation matrix with different confidence score in val dataset

模型	置信度	精度	召回率	F_1 值
SSD	0.9	0.980	0.84	0.904
	0.8	0.971	0.89	0.929
	0.7	0.966	0.91	0.937
	0.6	0.964	0.94	0.952
	0.5	0.960	0.95	0.955
	0.4	0.959	0.96	0.960
	0.3	0.941	0.97	0.955
	0.2	0.922	0.98	0.950
	0.1	0.895	0.99	0.940
	RetinaNet	0.9	0.967	0.95
0.8		0.958	0.96	0.959
0.7		0.958	0.96	0.959
0.6		0.940	0.97	0.955
0.5		0.924	0.98	0.951
0.4		0.924	0.98	0.951
0.3		0.924	0.98	0.951
0.2		0.887	0.99	0.936
0.1		0.887	0.99	0.936
FCOS		0.9	0.000	0.00
	0.8	1.000	0.06	0.113
	0.7	1.000	0.28	0.438
	0.6	0.998	0.51	0.675
	0.5	0.991	0.74	0.847
	0.4	0.982	0.87	0.922
	0.3	0.970	0.93	0.949
	0.2	0.911	0.96	0.935
	0.1	0.850	0.97	0.906

度阈值的评价数据,选取最优置信度阈值,用于对比测试集下各模型的识别效果。

由表 2 可知,当置信度阈值为 0.9 时,SSD 模型的精度值最高,为 0.980,但对应的召回率只有 0.84。相反,当置信度阈值为 0.1 时,SSD 模型的召回率达到了最高的 0.99。通过观察 F_1 值可知,SSD 模型的最优置信度阈值为 0.4,该置信度下精度值和召回率取得了最佳平衡。同理,RetinaNet 模型的最优置信度阈值为 0.7/0.8、FCOS 模型的最优置信度阈值为 0.3,分别对应最佳 F_1 值 0.959 和 0.949。

将通过验证集获取的最优置信度阈值应用于测试集,得到表 3 所示的评价数据,可知,FCOS 模型的精度最高,为 0.970,但是其召回率只有 0.94。

表 3 测试集最优置信度阈值的评价数据

Table 3 Evaluation matrix with best confidence score in test dataset

模型	置信度	精度	召回率	F_1 值	平均精度	检测速度/($f \cdot s^{-1}$)
SSD	0.4	0.938	0.97	0.954	0.981	31.0
RetinaNet	0.7/0.8	0.943/0.947	0.98/0.97	0.961/0.959	0.984	17.5
FCOS	0.3	0.970	0.94	0.955	0.966	17.9

表 3 同样列出了 SSD 模型、RetinaNet 模型和 FCOS 模型的检测速度(以帧率的形式表示)。观察可知,RetinaNet 模型和 FCOS 模型的检测速度相近,分别为 17.5、17.9 f/s,远远低于 SSD 模型的 31.0 f/s。SSD 模型拥有最快的检测速度,几乎是 RetinaNet 模型和 FCOS 模型的两倍。综合识别率和检测速度,SSD 模型为本文所选模型中的最优模型,其拥有最高的检测速度和较优的识别率。此结果与 SSD 模型兼顾精度和性能的特征^[35]相符。

图 2 为本文所得最优模型 SSD 模型的检测效果图。分别选取图 2(a)包含禾本科杂草的图像、图 2(b)包含阔叶草的图像、图 2(c)包含枯叶和秸秆等干扰物的复杂背景图像以及图 2(d)青菜目标分布聚集的高密度青菜图像,从效果图可看出,SSD 模型在不同杂草类型、不同背景复杂度以及不同青菜密度场景下,均能正确识别青菜目标,展示了其良好的鲁棒性。

进一步分析识别效果,图 3(a)右上角虚线框所示,当青菜互相重叠时,模型会将两颗青菜识别成一颗,该场景降低了识别的召回率。但此漏检情况并不会对应用产生实质影响,因为两颗青菜所在的整体区域是被成功识别并标记边框的。图 3(b)显示了杂草形状与青菜高度相似导致误检的场

召回率过低会导致青菜被误识别为杂草。因而,召回率亦表征了杂草的误识率。SSD 模型和 RetinaNet 模型的召回率相近,分别为 0.97 和 0.98(置信度阈值取 0.7),即杂草误识率分别为 0.03 和 0.02。而在精度指标上,RetinaNet 模型(置信度阈值取 0.8)比 SSD 模型略高 0.9%。RetinaNet 模型拥有最高的 F_1 值,为 0.961(置信度阈值取 0.7),SSD 模型和 FCOS 模型的 F_1 值相近,分别为 0.954 和 0.959。对于平均精度,所有模型都超过了 96%,表明,本文所选 3 个模型对于青菜都有较好的识别率。其中,SSD 模型和 RetinaNet 模型的平均精度高于 98%,相较于 FCOS 模型识别效果更优。根据 F_1 值、平均精度以及误识率指标可知,SSD 模型和 RetinaNet 模型对于青菜有更好的识别效果。

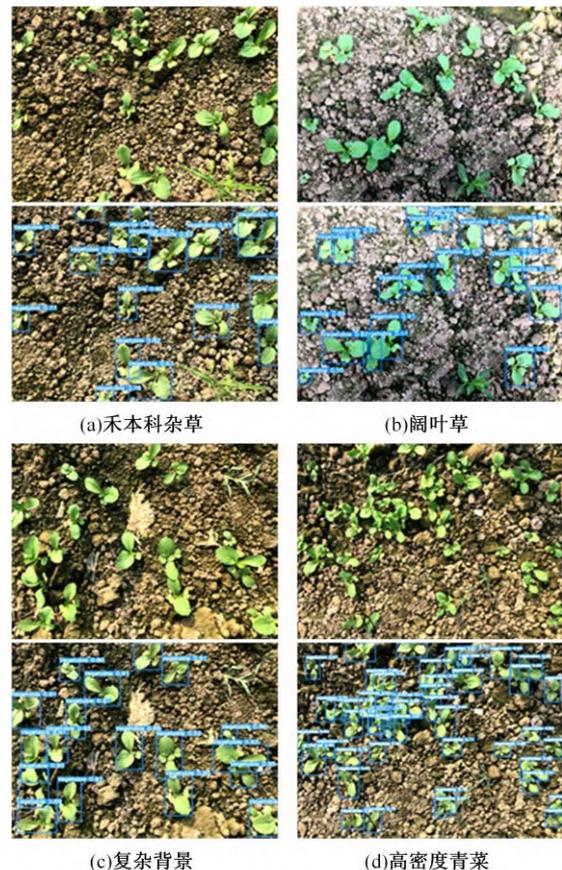
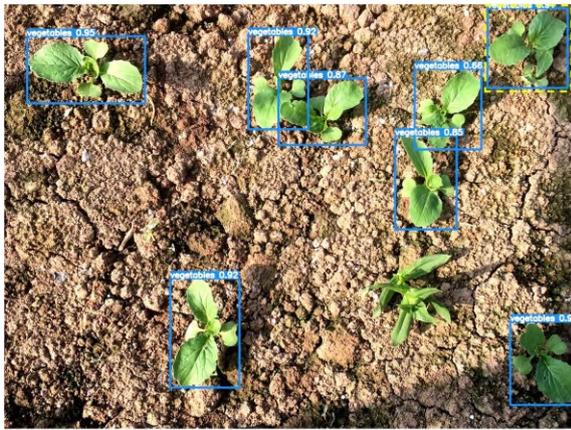
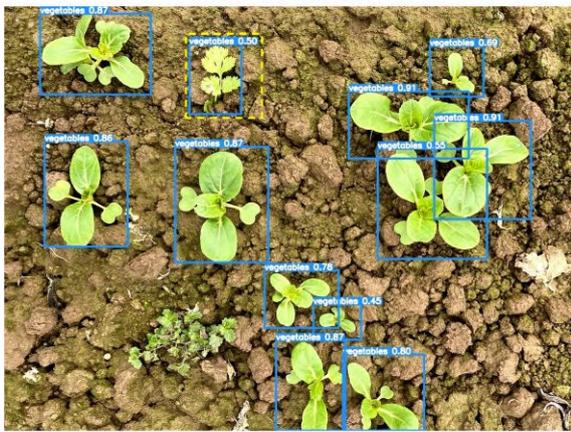


图 2 不同场景下的原图及 SSD 模型青菜检测效果图
Fig. 2 Original images under various conditions and result images of SSD model



(a) 青菜重叠导致漏检



(b) 形状相似导致误检

图 3 漏检和误检场景图

Fig. 3 Missed detection and erroneous detection

景。该场景降低了识别的精度,后续可通过增加该类杂草的训练样本改善此误检情况。

4.2 杂草识别

识别并标记出青菜目标后,剩余的绿色植物皆视为杂草。此时,只需从土壤背景中将青菜边框之外的绿色像素分割出来即可实现杂草识别。如图 4 所示,改进后的 MExG 因子成功分割出杂草,但是分割后的效果图中仍然存在若干随机分布的噪点。

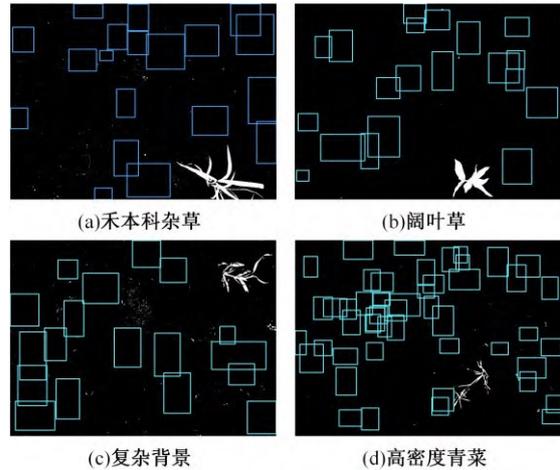
图 5 为应用面积滤波之后的效果图。对比图 4、图 5 可看出,图中的噪点被完全滤除,分割后的杂草形态完整且轮廓清晰。图像处理后的杂草识别效果表明,本文提出的杂草识别方法具有高度的可行性和优异的应用效果。

4.3 方法讨论

相较于传统的直接识别杂草的方式,本文方法具有如下优势:

(1) 降低复杂度

杂草种类繁多,对杂草进行逐一识别不仅复



(a) 禾本科杂草

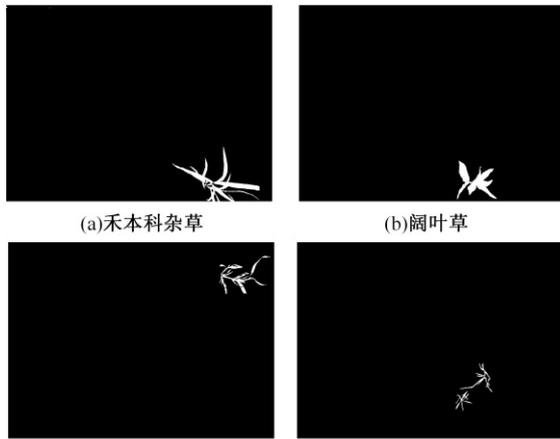
(b) 阔叶草

(c) 复杂背景

(d) 高密度青菜

图 4 杂草分割效果图

Fig. 4 Image of weed segmentation



(a) 禾本科杂草

(b) 阔叶草

(c) 复杂背景

(d) 高密度青菜

图 5 面积滤波及最终杂草识别效果图

Fig. 5 Image of area filter and final weed recognition

杂而且精度较低,极易出现误识别。通过识别蔬菜进而间接识别杂草,可有效降低杂草识别的复杂度,同时提高识别精度。

(2) 轻量样本库

从深度学习角度建立包含各种类杂草的样本数据库是一项及其繁琐的工程,而基于本文思路,仅需针对有限的蔬菜种类进行训练,极大降低了深度学习训练样本库配置的成本和难度。

(3) 识别鲁棒性

本文不直接识别杂草,因而即使遇到未知种类的杂草,通过本方法依然能成功识别。由此,本文方法具有更好的鲁棒性和泛化能力。

5 结 论

(1) SSD 模型、RetinaNet 模型和 FCOS 模型都能有效识别青菜目标。其中,SSD 模型和 Reti-

naNet模型的平均精度高于98%,相较于FCOS模型识别效果更优。SSD模型拥有最快的检测速度。综合识别率和检测速度,SSD模型为识别青菜的最优模型。

(2)改进后的MExG因子能有效识别杂草目标。结合面积滤波,分割后的杂草形态完整且轮廓清晰。

(3)试验表明,本文提出的杂草识别方法具有高度的可行性和极佳的应用效果。同时,具有低复杂度、轻量级训练样本库以及拥有更好的识别鲁棒性三方面的优势。

(4)本文以青菜为试验对象,但所用杂草识别方法亦可应用于其他蔬菜类作物以及条播作物(如玉米、棉花、水稻和小麦等)杂草识别。后续将针对不同作物展开普适性研究,同时对现有深度学习模型进行改进和优化,以进一步提升识别率与性能。

参考文献:

- [1] 金月,肖宏儒,曹光乔,等.我国叶类蔬菜机械化水平现状与评价方法研究[J].中国农机化学报,41(12):196-201.
Jin Yue, Xiao Hong-ru, Cao Guang-qiao, et al. Research on status and evaluation methods of leafy vegetable mechanization production level in China[J]. Journal of Chinese Agricultural Mechanization, 41(12): 196-201.
- [2] Ryder E. World vegetable industry: production, breeding, trends[J]. Horticultural Reviews, 2011, 38: 299-356.
- [3] Han J, Luo Y, Yang L, et al. Acidification and salinization of soils with different initial pH under greenhouse vegetable cultivation[J]. Journal of Soils and Sediments, 2014, 14(10): 1683-1692.
- [4] 陆海涛,吕建强,金伟,等.我国叶类蔬菜机械化收获技术的发展现状[J].农机化研究,2018,40(6):261-268.
Lu Hai-tao, Lv Jian-qiang, Jin Wei, et al. The current situation of the mechanized harvesting technology development of leaf vegetable in China[J]. Journal of Agricultural Mechanization Research, 2018, 40(6): 261-268.
- [5] 徐艳蕾,何润,翟钰婷,等.基于轻量卷积网络的田间自然环境杂草识别方法[J].吉林大学学报:工学版,2021,51(6):2304-2312.
Xu Yan-lei, He Run, Zhai Yu-ting, et al. Weed identification method based on deep transfer learning in field natural environment[J]. Journal of Jilin University (Engineering and Technology Edition), 2021, 51(6): 2304-2312.
- [6] 王刚,刘慧力,贾洪雷,等.触碰定位式玉米行间除草装置的设计与试验[J].吉林大学学报:工学版,2021,51(4):1518-1527.
Wang Gang, Liu Hui-li, Jia Hong-lei, et al. Design and experiment of touching-positioning weeding device for inter-row maize (*Zea Mays* L.)[J]. Journal of Jilin University (Engineering and Technology Edition), 2021, 51(4): 1518-1527.
- [7] 洪晓玮,陈勇,杨超淞,等.有机蔬菜大棚除草机器人研制[J].制造业自动化,2021,43(5):33-36.
Hong Xiao-wei, Chen Yong, Yang Chao-song, et al. Development of a weeding robot for organic vegetable greenhouse[J]. Manufacturing Automation, 2021, 43(5): 33-36.
- [8] Dai X, Xu Y, Zheng J, et al. Comparison of image-based methods for determining the inline mixing uniformity of pesticides in direct nozzle injection systems[J]. Bio-systems Engineering, 2020, 190: 157-175.
- [9] Lanini W, Strange M. Low-input management of weeds in vegetable fields[J]. California Agriculture, 1991, 45(1): 11-13.
- [10] 金小俊,陈勇,孙艳霞.农田杂草识别方法研究进展[J].农机化研究,2011,33(7):23-27,33.
Jin Xiao-jun, Chen Yong, Sun Yan-xia. Research advances of weed identification in agricultural fields [J]. Journal of Agricultural Mechanization Research, 2011, 33(7): 23-27, 33.
- [11] 毛文华,张银桥,王辉,等.杂草信息实时获取技术与设备研究进展[J].农业机械学报,2013,44(1):190-195.
Mao Wen-hua, Zhang Yin-qiao, Wang Hui, et al. Advance techniques and equipments for real-time weed detection[J]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(1): 190-195.
- [12] 金小俊,陈勇,侯学贵,等.基于机器视觉的除草机器人杂草识别[J].山东科技大学学报:自然科学版,2012,31(2):104-108.
Jin Xiao-jun, Chen Yong, Hou Xue-gui, et al. Weed recognition of the machine vision based weeding robot[J]. Journal of Shandong University of Science and Technology (Natural Science), 2012, 31(2): 104-108.
- [13] 陈良宵,王斌.基于形状特征的叶片图像识别算法比较研究[J].计算机工程与应用,2017(9):17-25.

- Chen Liang-xiao, Wang Bin. Comparative study of leaf image recognition algorithm based on shape feature[J]. *Computer Engineering and Applications*, 2017(9): 17-25.
- [14] Rojas C P, Guzmán L, Toledo N V. Weed recognition by SVM texture feature classification in outdoor vegetable crops images[J]. *Ingeniería E Investigación*, 2017, 37(1): 68-74.
- [15] Bakhshipour A, Jafari A, Nassiri S M, et al. Weed segmentation using texture features extracted from wavelet sub-images[J]. *Biosystems Engineering*, 2017, 157: 1-12.
- [16] 仇裕淇, 黄振楠, 阮昭, 等. 机器视觉技术在农业生产智能化中的应用综述[J]. *机械研究与应用*, 2019, 32(16): 202-206.
- Qiu Yu-qi, Huang Zhen-nan, Ruan Zhao, et al. Review on application of machine vision in intelligent agricultural production[J]. *Mechanical Research & Application*, 2019, 32(16): 202-206.
- [17] Liakos K G, Busato P, Moshou D, et al. Machine learning in agriculture: a review[J]. *Sensors*, 2018, 18(8): 18082674.
- [18] Wang A, Zhang W, Wei X. A review on weed detection using ground-based machine vision and image processing techniques[J]. *Computers and Electronics in Agriculture*, 2019, 158: 226-240.
- [19] Jordan M I, Mitchell T M. Machine learning: trends, perspectives, and prospects[J]. *Science*, 2015, 349(6245): 255-260.
- [20] Gu J, Wang Z, Kuen J, et al. Recent advances in convolutional neural networks[J]. *Pattern Recognition*, 2018, 77: 354-377.
- [21] Schmidhuber J. Deep learning in neural networks: an overview[J]. *Neural Networks*, 2015, 61: 85-117.
- [22] Shi J, Li Z, Zhu T, et al. Defect detection of industry wood veneer based on NAS and multi-channel mask R-CNN[J]. *Sensors*, 2020, 20(16): 20164398.
- [23] Yu Y, Liu Y, Chen J, et al. Detection method for bolted connection looseness at small angles of timber structures based on deep learning[J]. *Sensors*, 2021, 21(9): 20193106.
- [24] 孙红, 李松, 李民赞, 等. 农业信息成像感知与深度学习应用研究进展[J]. *农业机械学报*, 2020, 51(5): 1-17.
- Sun Hong, Li Song, Li Min-zan, et al. Research progress of image sensing and deep learning in agriculture[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2020, 51(5): 1-17.
- [25] 邓向武, 马旭, 齐龙, 等. 基于卷积神经网络与迁移学习的稻田苗期杂草识别[J]. *农机化研究*, 2021, 43(10): 167-171.
- Deng Xiang-wu, Ma Xu, Qi Long, et al. Recognition of weeds at seedling stage in paddy fields using convolutional neural network and transfer Learning [J]. *Journal of Agricultural Mechanization Research*, 2021, 43(10): 167-171.
- [26] Yu J, Schumann A W, Sharpe S M, et al. Detection of grassy weeds in bermudagrass with deep convolutional neural networks[J]. *Weed Science*, 2020, 68(5): 545-552.
- [27] Hasan A M, Sohel F, Diepeveen D, et al. A survey of deep learning techniques for weed detection from images[J]. *Computers and Electronics in Agriculture*, 2021, 184: 106067.
- [28] 董亮, 雷良育, 李雪原, 等. 基于改进型人工神经网络的温室大棚蔬菜作物苗期杂草识别技术[J]. *北方园艺*, 2017(22): 79-82.
- Dong Liang, Lei Liang-yu, Li Xue-yuan, et al. Weed identification technology of greenhouse vegetable crops in greenhouse based on improved artificial neural network[J]. *Northern Horticulture*, 2017(22): 79-82.
- [29] 孙俊, 谭文军, 武小红, 等. 多通道深度可分离卷积模型实时识别复杂背景下甜菜与杂草[J]. *农业工程学报*, 2019, 35(12): 184-190.
- Sun Jun, Tan Wen-jun, Wu Xiao-hong, et al. Real-time recognition of sugar beet and weeds in complex backgrounds using multi-channel depth-wise separable convolution model[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2019, 35(12): 184-190.
- [30] Osorio K, Puerto A, Pedraza C, et al. A deep learning approach for weed detection in lettuce crops using multispectral images[J]. *AgriEngineering*, 2020, 2(3): 471-488.
- [31] Elstone L, How K Y, Brodie S, et al. High speed crop and weed identification in lettuce fields for precision weeding[J]. *Sensors*, 2020, 20(2): 455-469.
- [32] Chen K, Wang J, Pang J, et al. MMDetection: open mmlab detection toolbox and benchmark[J]. *arXiv preprint arXiv:1906.07155*.
- [33] 岑海燕, 朱月明, 孙大伟, 等. 深度学习在植物表型研究中的应用现状与展望[J]. *农业工程学报*, 2020, 36(9): 1-16.
- Cen Hai-yan, Zhu Yue-ming, Sun Da-wei, et al. Current status and future perspective of the application of deep learning in plant phenotype research[J].

- Transactions of the Chinese Society of Agricultural Engineering, 2020, 36(9): 1-16.
- [34] 马志艳, 朱熠, 杨磊. 基于视觉的苗期作物株间除草关键技术研究现状[J]. 中国农机化学报, 2020, 41(2): 32-38.
- Ma Zhi-yan, Zhu Yi, Yang Lei. Research status of key techniques of inter-plant weeding in seedling crops based on vision[J]. Journal of Chinese Agricultural Mechanization, 2020, 41(2): 32-38.
- [35] Liu W, Anguelov D, Erhan D, et al. Ssd: single shot multibox detector[C]//Proceedings of the European Conference on Computer Vision, Amsterdam, The Netherlands, 2016:46448.
- [36] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[C]//Proceedings of the Proceedings of the IEEE International Conference on Computer Vision, Venice, Italy, 2017:318-327.
- [37] Tian Z, Shen C, Chen H, et al. Fcos: fully convolutional one-stage object detection[C]//Proceedings of the Proceedings of the IEEE/CVF International Conference on Computer Vision, Seoul, Korea, 2019: 01355.
- [38] Burgos-Artizzu X P, Ribeiro A, Guijarro M, et al. Real-time image processing for crop/weed discrimination in maize fields[J]. Computers and Electronics in Agriculture, 2011, 75(2): 337-346.