

doi:10.11733/j.issn.1007-0435.2022.06.027

基于深度学习的草坪杂草识别与除草剂喷施区域检测方法

金小俊¹, 孙艳霞², 陈勇^{1*}, 于佳琳^{3*}

(1. 南京林业大学机械电子工程学院, 江苏 南京 210037; 2. 南京交通职业技术学院轨道交通学院, 江苏 南京 211188;
3. 得克萨斯农工大学土壤与作物科学系, 得克萨斯州 学院站 77843)

摘要:本文以狗牙根草坪及其伴生杂草毛花雀稗、白三叶以及莎草为研究对象,提出了一种基于深度学习的草坪杂草识别及除草剂喷施区域检测方法。通过将原图划分为若干格子区域,利用神经网络模型对格子图片进行杂草识别,实现杂草定位并进而确定除草剂喷施区域。为探究不同神经网络模型对杂草识别的效果,选取VGGNet模型、GoogLeNet模型和ShuffleNet模型,分别以 F_1 值、准确率和识别速度进行对比分析。验证集下所有模型的 F_1 值都高于0.97,表明本研究中的三个模型对于杂草都有较好的识别效果。其中,GoogLeNet模型为杂草识别最优模型,拥有最为均衡的识别率和识别速度。其在测试集的平均准确率和识别速度分别为98.75%和36.9 fps,能够用于草坪实时杂草识别应用。结果表明,本研究提出的草坪杂草识别与除草剂喷施区域检测方法具有高度的可行性和较优的应用效果,可用于基于除草剂精准喷施的草坪杂草防控。

关键词:草坪杂草;杂草识别;深度学习;喷施区域;图像处理

中图分类号:TP391.41

文献标识码:A

文章编号:1007-0435(2022)06-1543-07

Weed Recognition and Herbicide Spraying Area Detection in Turf Based on Deep Learning

JIN Xiao-jun¹, SUN Yan-xia², CHEN Yong^{1*}, YU Jia-lin^{3*}

(1. College of Mechanical and Electronic Engineering, Nanjing Forestry University, Nanjing, Jiangsu Province 210037, China;
2. School of Rail Transportation, Nanjing Vocational Institute of Transport Technology, Nanjing, Jiangsu Province 211188, China;
3. Department of Soil and Crop Sciences, Texas A&M University, College Station, Texas 77843, USA)

Abstract: This paper proposed a method of turf weed recognition and accurate spraying based on deep learning. The research targets of this paper are bermudagrass lawn and its associated weeds, including dallisgrass, white clover, and purple nutsedge. By dividing the original image into several grid regions, the convolutional neural network model was used to identify the grid subimages, locate weed position, and determine the precise spraying area of herbicides. In order to explore the effects of different deep learning models on weed recognition, the VGGNet model, the GoogLeNet model, and the ShuffleNet model were selected to compare and analyze in terms of F_1 value, accuracy, and recognition speed. The F_1 value of all models under the verification set was higher than 0.97, indicating that the three models in this study have a good recognition effect on weeds. The GoogLeNet model was the most optimal weed recognition model, with the most balanced recognition rate and recognition speed. Its average accuracy and identification speed in the test set were 98.75% and 36.9 fps, respectively, which can be used in real-time weed recognition applications on turf. The results showed that the turf weed identification and herbicide precision spraying areas detection has highly feasible and excellent application effect, and can be used for turfgrass weed control based on precise herbicide spraying.

Key words: Turf weed; Weed recognition; Deep learning; Site-specific spraying; Image processing

草坪绿化是城市文明程度的重要标志之一^[1]。草坪常见于公园绿化、体育场、高尔夫球场等场所。

收稿日期:2021-11-08;修回日期:2021-12-01

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资金项目(CX(21)3184)资助

作者简介:金小俊(1987-),男,汉族,江苏姜堰人,博士研究生、工程师,主要从事计算机视觉与人工智能技术研究,Email:xiaojun.jin@outlook.com; *通信作者 Author for correspondence, E-mail:chenyongjsnj@163.com; yu.jialin@tamu.edu

草坪对于美化环境、净化空气、保持水土等作用显著^[2]。由于杂草的侵袭,草坪退化严重,造成养护困难^[3]。杂草防控是草坪养护的重要内容,基于除草剂的化学除草是草坪杂草防控的常用方式^[4-5]。我国化学农药用量居世界第一^[6]。其中,农作物的农药利用率仅为 36.6%,远低于欧美发达国家^[7]。提高农药利用率已成为我国农业生产中亟需解决的重要问题^[8]。近年来,我国除草剂的施药量占农药总用量的 48%左右,除草剂的减施是降低农药使用的重中之重^[6,8]。自然环境下,草坪杂草呈不规则生长,分布随机。除草剂通常以地毯式方式喷施^[9],造成除草剂利用率低下。实现除草剂的精准喷施是降低除草剂用量,减少环境污染的关键。要想实现精准喷施,首先需要实现对杂草的识别,并进而确定除草剂的喷施区域^[10-11]。

传统杂草识别方法通常利用植物本身的一些特征,包括颜色、形状、纹理以及多光谱等^[12-14]。但这些特征需要人工提取,且算法设计复杂,存在着稳健性不足,识别速度低等缺陷^[13,15-16]。随着深度学习,特别是深度卷积神经网络的发展,越来越多的研究开始借助于深度学习技术^[17-21]。王璨等^[22]利用改进的双注意力语义分割神经网络模型,基于玉米像素分割结果,生成杂草分割图。试验表明,深度学习模型的平均交并比、平均像素识别准确率分别可达 94.16%和 95.68%。樊湘鹏等^[23]通过改进 Faster R-CNN 模型的锚尺度,并选取最优特征提取网络,可实现对自然条件下新疆棉田棉花幼苗期的 7 种杂草的有效识别与定位,平均识别精确率为 94.21%。Osorio 等^[24]分别采用 YOLO-v3 模型和 Mask R-CNN 模型对生菜田中的杂草进行识别,结果显示两者的 F_1 指数均为 94%。草坪杂草识别方面,Yu 等^[25-28]研究发现,在休

眠期的狗牙根草坪中,VGGNet 模型和 DetectNet 模型均能精准识别各类单子叶和双子叶杂草。而在多年生黑麦草坪中,VGGNet 模型对于不同密度的蒲公英草识别率最高,而 GoogleNet 模型虽然召回率较高,但精度值远低于 VGGNet 模型。

草坪杂草随机分布,且草坪草与杂草生长交错、重叠,增加了识别难度。文献检索显示,对于草坪杂草识别,国内外研究较少,尚处于探索阶段^[27-29]。而针对草坪杂草的除草剂精准喷施,国内外均尚未开展相关研究。本研究拟提出一种可用于除草剂精准喷施的草坪杂草识别与喷施区域检测方法,以期解决草坪杂草精准喷施这一关乎除草剂利用率的关键问题。同时,为相似作物的杂草识别与除草剂喷施区域检测提供技术参考。

1 材料与方法

1.1 图像采集

本研究选取具有代表性的草坪草种狗牙根 [*Cynodon dactylon* (L.) Pers.],并在其伴生杂草中分别选取禾本科毛花雀稗 (*Paspalum dilatatum* Poir.)、豆科白三叶 (*Trifolium repens* L.) 以及莎草科莎草 (*Cyperus rotundus* L.) 为试验对象。毛花雀稗和白三叶图像于 2018 年 10 月采集自美国佐治亚大学格里芬校区 (University of Georgia Griffin Campus) 内的草坪。莎草图像于 2021 年 5 月采集自江苏省南京市江宁区某绿化草坪。采集设备为索尼数码相机 (型号为 DSC-HX1)。图像分辨率为 1920 × 1080 像素。为保证深度学习训练样本的多样性,图像采集在不同时间,以及晴天、阴天不同光线状态下进行。狗牙根草坪伴生杂草如图 1 所示。




图 1 狗牙根草坪伴生杂草原图

Fig. 1 Original images of weeds in bermudagrass lawn

1.2 样本数据集与试验方法

对于采集到的草坪图像,每张按照 5 行 8 列切分成 40 张格子图片,如图 2 所示。切分后每张格子图片的分辨率为 240 × 216 像素。人工查看格子图片并分类,包

含毛花雀稗、白三叶和莎草的格子归为正样本,反之归为负样本(狗牙根草坪)。如此分别得到毛花雀稗样本、白三叶样本、莎草样本各 2 500 张,以及狗牙根样本 7 500 张。样本按照 8 : 2 的比例随机分为训练集和验证集。



图 2 格子切分示例图

Fig. 2 Grid image illustration

测试集选取包含毛花雀稗、白三叶和莎草的完整原图各 10 张,每张原图同样按照 5 行 8 列切分格子图。30 张原图共计获得格子图片 1 200 张。分类后毛花雀稗为 218 张、白三叶为 295 张、莎草为 242 张,不含杂草的狗牙根草坪图为 445 张。试验样本数据集的建立如表 1 所示。

表 1 深度学习样本数据

Table 1 Deep learning dataset

样本类别 Dataset classes	正样本 Positive images			负样本 Negative images	
	毛花雀稗 Dallisgrass	白三叶 White clover	莎草 Purple nutsedge	狗牙根 Bermudagrass	
训练集	2 000	2 000	2 000	6 000	
验证集	500	500	500	1 500	
测试集	218	295	242	445	

1.3 深度学习框架

为探究不同深度学习模型对杂草识别的效果,本研究拟选取不同卷积神经网络模型进行评价分析。试验深度学习平台为 PyTorch 框架^[30]。PyTorch 是由 Facebook 公司开源的神经网络框架,其具有强大的 GPU 加速张量计算能力,并包含深度神经网络的自动求导系统,是目前主流的深度学习平台之一^[31]。本研究中所用模型均在 PyTorch 框架下编程实现,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 @3.60GHZ 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。

1.4 杂草识别与喷施区域检测方法

1.4.1 杂草识别模型 本研究分别选取 VGGNet

模型^[32]、GoogLeNet 模型^[33]和 ShuffleNet 模型^[34]对草坪图像中的杂草进行识别并分类。VGGNet 是由牛津大学视觉几何组 (Visual Geometry Group) 和 Google 公司共同提出的卷积神经网络模型,其证明了使用很小的卷积(3×3)并通过增加网络深度可以有效提升模型的识别精度。GoogLeNet 是由 Google 公司推出的基于 Inception 模块的深度神经网络模型。该模型使用 Inception 结构增加网络宽度,通过提取高维特征以减少参数数量、提高模型的分类性能。ShuffleNet 是旷视科技设计的高效卷积神经网络模型,其通过优化的网络结构实现更轻量级的模型。该模型的特点在于拥有更加均衡的识别性能,利用有限的计算资源获取最佳精度。智能除草装备依赖高性能的实时杂草识别^[35]。本研究将从识别率和识别速度两方面对上述模型进行综合对比,并根据评价结果选取最优模型进行杂草及喷施区域识别研究。表 2 为不同模型的默认超参设置。

表 2 不同模型默认超参设置

Table 2 Default hyperparameters of each model

模型 Model	批尺寸 Batch	初始学习率 Initial learning rate	学习率调整策略 Learning rate policy	优化器 Optimizer	训练周期 Training epochs
VGGNet	16	0.0001	StepLR	Adam	24
GoogLeNet	16	0.0003	StepLR	Adam	24
ShuffleNet	16	0.001	LambdaLR	SGD	24

1.4.2 评价指标 本研究采用精度(precision)、召回率(recall)以及 F_1 值作为验证集评价指标。在本研究场景中,精度表示样本中模型正确分类的杂草

目标与预测为杂草目标的比值。召回率表示样本中所有杂草目标被正确预测的比例。精度和召回率的定义如下:

$$precision = \frac{tp}{tp + fp} \tag{1}$$

$$recall = \frac{tp}{tp + fn} \tag{2}$$

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 值是深度学习中常用的模型综合评价指标，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：

$$F_1 = \frac{2 \times precision \times recall}{precision + recall} \tag{3}$$

对于测试集，本研究使用总体准确率(overall accuracy)和平均准确率(average accuracy)作为评价指标。总体准确率是模型在测试集上预测正确的(包括真正类和真负类)数量与总体数量之间的比值，其计算公式为：

$$OA_{\alpha} = \frac{tp + tn}{tp + fp + fn + tn} \tag{4}$$

平均准确率是取每一类(class)总体准确率的平均值，体现模型对所有类别目标的综合分类能力，其定义如下所示：

$$AA_{\alpha} = \frac{OA_{\alpha}}{N_c} \tag{5}$$

式中： N_c 为分类任务中类别的数量。

1.4.3 除草剂喷施区域检测 本研究拟通过划分格子图片,利用深度学习识别各格子中是否包含杂草,进而实现杂草定位。如图 3 所示,首先将原图按照 5 行 8 列均匀切分成 40 张格子图片。5 行 8 列的选择依据为:本研究中采集的原始图像分辨率为 1920×1080 像素。切分后每个格子的大小为 240×216 像素,该尺寸与一般卷积神经网络模型的输入尺寸(224×224 像素)相近^[36]。对应的物理尺寸与除草剂施药器单个喷头的喷施范围相近(喷头孔径 3.2 mm,摄像头高度 0.65 m,图像区域分辨率 240×240 像素,喷施物理直径 12 cm)。对于切分的格子图片,分别送入深度学习模型进行杂草识别。具体为利用训练完成的神经网络模型对输入的格子图片进行推理,并输出分类标签。若标签为毛花雀稗、白三叶或莎草,则标记图像中该格子的所在区域为喷施区域。如此,统计出图像中所有包含杂草的格子区域,即为需要喷施除草剂的区域,施药器喷头移动到相应区域并完成除草剂喷施。




图 3 杂草识别与除草剂喷施区域检测流程示意图
Fig. 3 Flow chart of weed recognition and site-specific spraying

2 结果与分析

2.1 杂草识别

深度学习模型识别杂草的验证集评价数据如表 3 所示。从表中可知,VGGNet 模型对于白三叶和狗牙根的精度最高,均达到了 1.0。精度越高表明模型对目标的误识别率越低。GoogLeNet 模型和 ShuffleNet 模型对莎草和白三叶的识别率同样高达 1.0。召回率方面,VGGNet 模型识别出了所有莎草目标,而 GoogLeNet 模型和 ShuffleNet 则对狗牙根召回率达到了 1.0。VGGNet 模型识别毛

花雀稗的召回率最高,为 0.99,表明其有 1%的漏检。ShuffleNet 模型能够识别出 99%的白三叶目标,在所有模型中召回率最优。进一步观察 F_1 值,所有模型都高于 0.97,表明本研究所选模型对于杂草都有较好的识别效果。其中,VGGNet 模型对于白三叶、莎草和狗牙根的 F_1 值都高达 0.99,表明 VGGNet 模型对这三种目标均保持了精度和召回率的最佳平衡。GoogleNet 模型对于莎草和狗牙根同样具有较高的识别性能。ShuffleNet 模型则对白三叶和狗牙根能更好的兼顾精度和召回率。

表 3 不同神经网络模型验证集评价数据

Table 3 Evaluation matrix of CNN models in validation dataset

模型	杂草	精度	召回率	F ₁ 值
Model	Weed species	Precision	Recall	F ₁ score
VGGNet	毛花雀稗	0.990	0.994	0.992
	白三叶	0.998	0.990	0.994
	莎草	0.996	0.996	0.996
	狗牙根	0.996	0.997	0.996
GoogLeNet	毛花雀稗	0.990	0.960	0.975
	白三叶	0.990	0.976	0.983
	莎草	0.996	0.984	0.990
	狗牙根	0.978	0.997	0.987
ShuffleNet	毛花雀稗	0.994	0.964	0.979
	白三叶	0.996	0.994	0.995
	莎草	0.986	0.970	0.978
	狗牙根	0.979	0.995	0.987

将训练模型应用于测试集数据,得到表 4 所示的评价数据。由表 4 可知,VGGNet 模型对于所有种类目标的总体准确率均高于 0.99,且其平均准确率高达 99.50%,相较于 GoogLeNet 模型和 ShuffleNet 模型,识别效果最优。GoogLeNet 模型对于不同杂草的识别总体准确率均超过 0.98,平均准确率为 98.75%。ShuffleNet 模型虽然对正样本(毛花雀稗、白三叶和莎草)总体准确率较高,但对于负样本狗牙根的准确率仅有 0.96,且该模型平均准确率低于 VGGNet 模型和 GoogLeNet 模型。综合总体准确率和平均准确率,VGGNet 模型和 GoogLeNet 模型对于不同类型目标的识别均衡性更高,总体识别效果更优。

表 4 不同神经网络模型测试集评价数据

Table 4 Evaluation matrix of CNN models in testing dataset

模型	杂草	总体准确率	平均准确率	整图识别速度
Model	Weed species	Overall accuracy	Average accuracy	Detection speed/40 fps
VGGNet	毛花雀稗	1.00	0.9950	8.9
	白三叶	0.99		
	莎草	1.00		
	狗牙根	0.99		
GoogLeNet	毛花雀稗	0.99	0.9875	36.9
	白三叶	0.99		
	莎草	0.99		
	狗牙根	0.98		
ShuffleNet	毛花雀稗	1.00	0.9825	68.8
	白三叶	0.98		
	莎草	0.99		
	狗牙根	0.96		

表 4 同样列出了 VGGNet 模型、GoogLeNet 模型和 ShuffleNet 模型的识别速度。该速度值取测试集中 1200 张格子图片的平均值,并以 40 张格子

图片为单位(每张原图切分后为 40 张格子图片),计算整图的识别速度。观察可知,ShuffleNet 模型识别速度最快,几乎是 GoogLeNet 模型的两倍。VGGNet 模型性能最低,只有 8.9 fps 的帧率,无法满足实际应用的需要。此结果也证明虽然 VGGNet 模型通过增加网络深度提高了识别率,但同时也消耗了更多的计算资源^[37]。GoogLeNet 模型识别速度为 36.9 fps,表示其每秒钟可以处理 36.9 张图片。通常图像处理速度高于 30 fps 即可认为是实时处理^[38],因而 ShuffleNet 模型和 GoogLeNet 模型均具备实时杂草识别的能力。综合识别率和检测速度,GoogLeNet 模型为本研究中所选模型中的最优模型,其拥有最为均衡的识别率和识别速度。

2.2 除草剂喷施区域

图 4 所示为本研究中所选最优模型 GoogLeNet 的杂草识别及喷施区域标记效果图。分别为图 4a 包含毛花雀稗的图像、图 4b 包含白三叶的图像、图 4c 包含莎草的图像以及图 4 d 同时包含毛花雀稗和白三叶的图像。从效果图可看出,GoogLeNet 模型对于不同杂草类型均能正确识别,展示了其良好的稳健性。其中,图中的淡红色格子表示包含毛花雀稗的区域,淡黄色格子和淡蓝色格子则分别为标记的白三叶和莎草位置区域。在草坪除草应用中,除草机器人根据标记的喷施区域格子坐标,控制施药器喷头移动至相应位置,完成除草剂的精准喷施。

3 讨论

当一张图像中同时包含多种杂草时,切分格子可以将不同杂草划分至不同区域,从而在一定程度上提升杂草识别率。但需要指出的是,单个格子中仍然可能存在多种杂草,该场景下神经网络模型只会给出一个预测标签值。若应用场景为不区分杂草种类的除草剂喷施,则仅需判定有无杂草,而无需确定具体杂草种类。反之,若为区分杂草种类的喷施,由于不同除草剂通常情况下不能混合使用,一次仅能喷施一种除草剂,因此,格子中存在多种杂草也只需识别出一种,通过多次作业完成所有杂草的喷施。

为降低除草剂用量、减少环境污染,研发能够实现除草剂精准喷施的智能除草装备势在必行。要想实现精准喷施,首先需要实现对杂草及喷施区域的精准识别。传统杂草识别方法通常仅在图像中找出

杂草像素,并未与施药器的喷施系统相结合。如何进行选择性的精准喷施?如何关联杂草区域和施药器喷头的喷施范围?本研究通过将图像划格子区

域,每一个格子作为一个喷施单元,通过识别格子中是否包含杂草,从而确定除草剂喷施区域。该方法可直接应用于除草机器人的视觉系统。

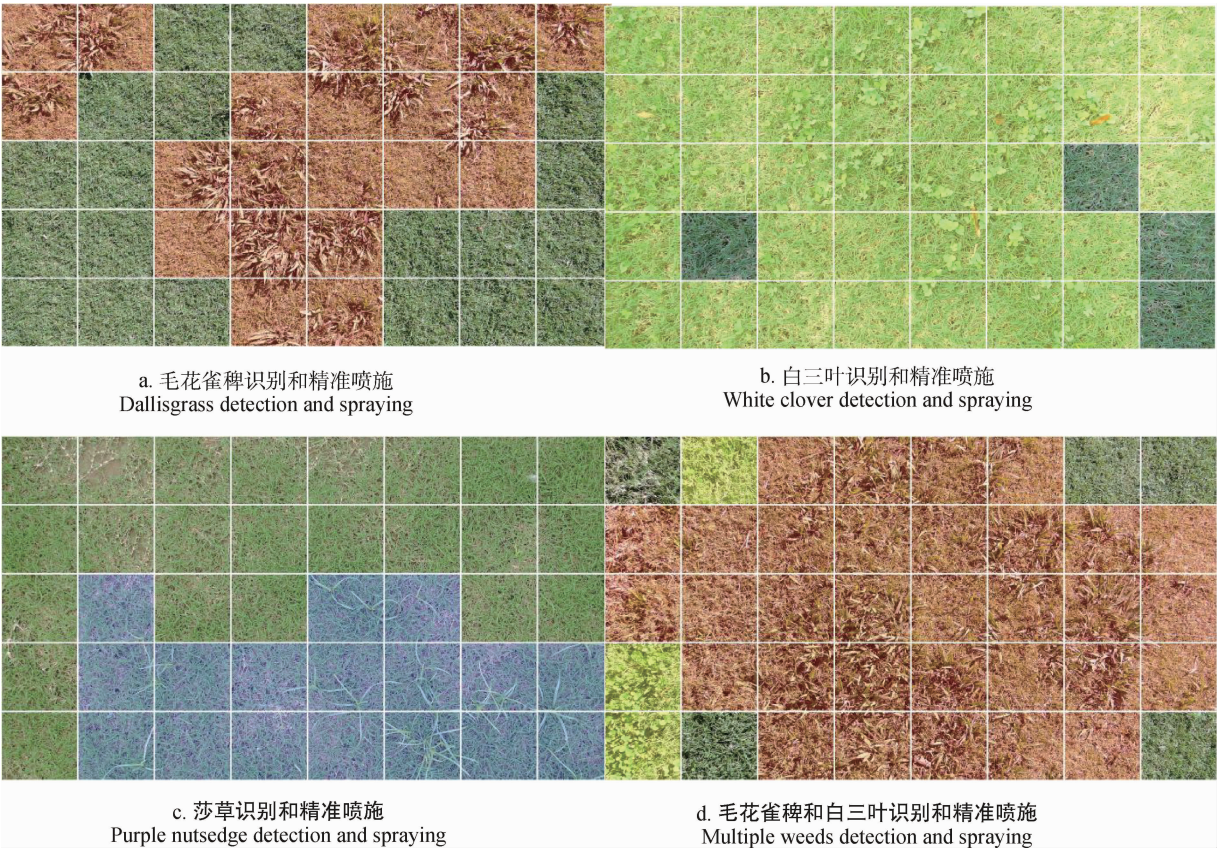


图 4 草坪杂草识别与精准喷施效果图

Fig. 4 Weed detection and site-specific spraying in bermudagrass

4 结论

VGGNet 模型、GoogLeNet 模型和 ShuffleNet 模型均能有效识别草坪杂草目标。其中 GoogLeNet 拥有最为均衡的识别率和识别速度,为本研究试验的最优模型。试验表明,本研究提出的草坪杂草识别与除草剂喷施区域检测方法具有高度的可行性和较优的应用效果,可用于基于除草剂精准喷施的草坪杂草防控。本研究以草坪杂草为试验对象,但本研究所提出的杂草识别与除草剂喷施区域检测方法亦可应用于其他作物,如玉米(*Zea mays* L.)、棉花(*Gossypium* spp.)、水稻(*Oryza sativa* L.)和小麦(*Triticum aestivum* L.)等。本研究后续将针对不同作物展开普适性研究,同时对神经网络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] 李永武,葛应兰. 草坪杂草的主要种类,发生特点与综合防除

[J]. 河南农业,2014(10):47-48

[2] 赵娜,徐庆国,苏鹏,等. 7 个暖季型草坪草品种对低温胁迫的抗性差异研究[J]. 草地学报,2020,28(2):375-382

[3] 赵艳岭,刘志强,邢红华,等. 绿地草坪的管理与养护[J]. 河南科技:上半月,2007(9):65-66

[4] 曹晓会. 草坪杂草的危害及其防治[J]. 现代园艺,2017(11):137-138

[5] 泰尔格力,蔡金宏,崔风超,等. 野牛草草坪除草剂安全施用策略[J]. 草地学报,2021,29(9):1865-1876

[6] 束放,熊延坤,韩梅. 2015 年我国农药生产与使用概况[J]. 农药科学与管理,2016(7):1-6

[7] 吴向辉. 农业部首次公布化肥,农药利用率数据[J]. 江西农业,2015(12):48

[8] 郭利京,王颖. 我国水稻生产中农药过量施用研究:基于社会和个人利益最大化的视角[J]. 生态与农村环境学报,2018,34(5):401-407

[9] 陈海涛,丁伟,许安定,等. 烟田农药减量增效施药技术的关键因素分析[J]. 江苏农业科学,2012(11):125-127

[10] 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

[11] DAI X,XU Y,ZHENG J,et al. Analysis of the variability of

pesticide concentration downstream of inline mixers for direct nozzle injection systems[J]. Biosystems Engineering, 2019 (180):59-69

[12] 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(07):23-7,33

[13] HAMUDA E, GLAVIN M, JONES E. A survey of image processing techniques for plant extraction and segmentation in the field[J]. Computers and Electronics in Agriculture, 2016 (125):184-199

[14] 韩万强,靳瑰丽,岳永寰,等. 基于高光谱成像技术的伊犁绢蒿荒漠草地主要植物识别参数的筛选[J]. 草地学报,2020,28 (4):1153-1163

[15] 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(02):202-206

[16] 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

[17] JORDAN M I, MITCHELL T M. Machine learning: Trends, perspectives, and prospects[J]. Science, 2015, 349(6245):255-260

[18] GU J, WANG Z, KUEN J, et al. Recent advances in convolutional neural networks[J]. Pattern Recognition, 2018 (77): 354-377

[19] SCHMIDHUBER J. Deep learning in neural networks: An overview[J]. Neural Networks, 2015(61):85-117

[20] 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):4398

[21] 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):3106

[22] 王璨,武新慧,张燕青,等. 基于双注意力语义分割网络的田间苗期玉米识别与分割[J]. 农业工程学报, 2021, 37(9):211-221

[23] 樊湘鹏,周建平,许燕,等. 基于优化 Faster R-CNN 的棉花苗期杂草识别与定位[J]. 农业机械学报, 2021, 52(5):26-34

[24] 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

[25] YU J, SCHUMANN A W, CAO Z, et al. Weed Detection in Perennial Ryegrass With Deep Learning Convolutional Neural Network[J]. Frontiers in plant science, 2019(10):1422

[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] YU J, SHARPE S M, SCHUMANN A W, et al. Deep learning for image-based weed detection in turfgrass[J]. European Journal of Agronomy, 2019(104):78-84

[28] YU J, SHARPE S M, SCHUMANN A W, et al. Detection of broadleaf weeds growing in turfgrass with convolutional neural networks[J]. Pest management science, 2019, 75(8):2211-2218

[29] 李春明,逯杉婷,远松灵,等. 基于 Faster R-CNN 的除草机器人杂草识别算法[J]. 中国农机化学报, 2019, 40(12):171-176

[30] PASZKE A, GROSS S, MASSA F, et al. Pytorch: An imperative style, high-performance deep learning library[J]. Advances in neural information processing systems, 2019 (32): 8026-8037

[31] 舒娜,刘波,林伟伟,等. 分布式机器学习平台与算法综述[J]. 计算机科学, 2019, 46(3):9-18

[32] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv preprint arXiv:14091556, 2014

[33] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]//proceedings of the Proceedings of the IEEE conference on computer vision and pattern recognition, 2015, San Juan, PR, USA

[34] ZHANG X, ZHOU X, LIN M, et al. Shufflenet: An extremely efficient convolutional neural network for mobile devices[C]//proceedings of the Proceedings of the IEEE conference on computer vision and pattern recognition, San Juan, PR, USA, 2018

[35] 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(02):32-38

[36] BARBEDO J G A, KOENIGKAN L V, SANTOS T T, et al. A study on the detection of cattle in UAV images using deep learning[J]. Sensors, 2019, 19(24):5436

[37] BIANCO S, CADENE R, CELONA L, et al. Benchmark analysis of representative deep neural network architectures[J]. IEEE Access, 2018(6):64270

[38] LEE R B. Realtime MPEG video via software decompression on a PA-RISC processor[C]//proceedings of the Digest of Papers COMPCON'95 Technologies for the Information Superhighway, San Jose, California, USA, 1995

(责任编辑 郭建鑫)