

基于 Mask R-CNN 的玉米田间杂草检测方法

姜红花¹ 张传银¹ 张 昭² 毛文华³ 王 东⁴ 王东伟⁵

(1. 山东农业大学信息科学与工程学院, 泰安 271018; 2. 宝鸡文理学院电子电气工程学院, 宝鸡 721016;
3. 中国农业机械化科学研究院, 北京 100083; 4. 山东农业大学农学院, 泰安 271018;
5. 青岛农业大学机电工程学院, 青岛 266109)

摘要: 针对田间复杂环境下杂草分割精度低的问题,提出了基于 Mask R-CNN 的杂草检测方法。该方法采用残差神经网络 ResNet-101 提取涵盖杂草语义、空间信息的特征图;采用区域建议网络对特征图进行杂草与背景的初步二分类、预选框回归训练,利用非极大值抑制算法筛选出感兴趣区域;采用区域特征聚集方法(RoIAlign),取消量化操作带来的边框位置偏差,并将感兴趣区域(RoI)特征图转换为固定尺寸的特征图;输出模块针对每个 RoI 计算分类、回归、分割损失,通过训练预测候选区域的类别、位置、轮廓,实现杂草检测及轮廓分割。在玉米、杂草数据集上进行测试,当交并比(IoU)为 0.5 时,本文方法均值平均精度(mAP)为 0.853,优于 SharpMask、DeepMask 的 0.816、0.795,本文方法的单样本耗时为 280 ms,说明本文方法可快速、准确检测分割出杂草类别、位置和轮廓,优于 SharpMask、DeepMask 实例分割算法。在复杂背景下对玉米、杂草图像进行测试,在 IoU 为 0.5 时,本文方法 mAP 为 0.785,单样本耗时为 285 ms,说明本文方法可实现复杂背景下的农田作物杂草分割。在田间变量喷洒试验中,杂草识别准确率为 91%,识别出杂草并准确喷雾的准确率为 85%,准确喷药的杂草雾滴覆盖密度为 55 个/cm²,装置对每幅图像的平均处理时间为 0.98 s,满足农药变量喷洒的控制要求。

关键词: 杂草;变量喷药;特征提取;图像分割;残差神经网络

中图分类号: TP391.4 文献标识码: A 文章编号: 1000-1298(2020)06-0220-09

OSID:



Detection Method of Corn Weed Based on Mask R-CNN

JIANG Honghua¹ ZHANG Chuanyin¹ ZHANG Zhao² MAO Wenhua³ WANG Dong⁴ WANG Dongwei⁵

(1. College of Information Science and Engineering, Shandong Agricultural University, Taian 271018, China
2. College of Electron and Electricity Engineering, Baoji University of Arts and Sciences, Baoji 721016, China
3. Chinese Academy of Agricultural Mechanization Sciences, Beijing 100083, China
4. College of Agronomy, Shandong Agricultural University, Taian 271018, China
5. College of Mechanical and Electrical Engineering, Qingdao Agricultural University, Qingdao 266109, China)

Abstract: Accurate detection and identification of weeds is a prerequisite for weed control. Aiming at the problem of low accuracy of weed segmentation in complex field environment, an intelligent weed detection and segmentation method based on Mask R-CNN was proposed. The ResNet-101 network was used to extract the feature map of weed semantic and spatial information. The characteristic map was classified by the regional suggestion network, and the pre-selection box regression was trained. The pre-selection area was screened by the non-maximum suppression algorithm. RoIAlign was used to cancel the border position deviation caused by quantization, and the region of interest (RoI) feature map was transformed into a fixed-size feature map. The output module calculated the classification, regression and segmentation loss for each RoI, predicted the category, location and contour of the candidate area through training, and realized weed detection and contour segmentation. When IoU (intersection over union) was 0.5, the mean accuracy precision (mAP) value was 0.853, which was better than that of SharpMask and DeepMask with 0.816 and 0.795, respectively. The single sample time of the three methods was 280 ms, 256 ms and 248 ms respectively. The results showed that the method can quickly and accurately detect and segment the category, location and contour of weeds, and it can be better than SharpMask and DeepMask. When IoU was 0.5, the mAP value of the proposed method was 0.785, and the time for a

收稿日期: 2019-10-08 修回日期: 2019-12-23

基金项目: 国家重点研发计划项目(2017YFD0700500)、山东省重大科技创新工程项目(2019JZZY010716)、山东省农业重大应用技术创新项目(SD2019NJ001)、山东省重点研发计划项目(2015GNC112004)和山东省自然科学基金项目(ZR2018MC017)

作者简介: 姜红花(1971—),女,副教授,主要从事物联网与自动控制研究,E-mail: j_honghua@sdau.edu.cn

通信作者: 毛文华(1975—),女,研究员,主要从事农业电气化与自动化研究,E-mail: mwh-924@163.com

single sample was 285 ms, indicating that this method can realize the field operation in the complex background and meet the real-time control requirements of field pesticide variable spraying. In the field variable spraying test, the accuracy rate of identifying weeds was 91%, the accuracy rate of identifying weeds and spraying them accurately was 85%, the spray density of pesticide spray droplets was 55 per square centimetre, and the average processing time of the device was 0.98 s. It can meet the control standard of pesticide variable spraying.

Key words: weeds; variable spraying pesticide; feature extraction; image segmentation; residual neural network

0 引言

杂草与作物争夺养分、阳光、空间和水^[1],是作物生长的最大威胁之一。目前,杂草的防治清理以传统的全淋式喷洒农药为主,即使用相同剂量的除草剂对杂草进行均匀处理。这种均匀喷洒除草剂的方法不能区分作物和杂草,不但造成大量农药的浪费,还对土壤和水源造成污染,甚至影响农田生产力和作物生长。为了减少农药浪费,提高农药的利用率,基于杂草检测的农药精准变量喷洒^[2]研究十分必要。

杂草的准确定位与识别是实现精准除草的重要环节^[3],对此,国内外学者已经进行了广泛研究^[4-19]。但这些研究存在以下不足:①单纯的杂草定位识别只能确定杂草的具体方位,并进行识别,却忽略了杂草的轮廓面积,使用相同剂量除草剂可能造成过喷或少喷,既浪费了除草剂,也达不到防治效果。②在实际应用中,作物跟杂草可能会互相遮掩并一同出现,普通的分类很难准确识别复杂背景下的杂草。③简单的作物杂草语义分割,只能区分不同类别的作物杂草,当多幅相同类别的作物杂草一同出现时,不能对每个作物杂草进行实例化的分割定位,这不利于确定每幅作物杂草的具体方位,对变量喷雾造成一定困扰。基于此,本文提出基于 Mask R-CNN^[20]的杂草检测分割方法,该方法结合目标检测和语义分割,可使用 ResNet-101^[21]网络提取复杂背景下的杂草图像特征,利用区域建议网络(Region proposal network, RPN)提取区域坐标特征,再利用区域特征聚集方法(RoIAlign)得到固定尺寸的特征图,使用输出模块对特征图进行分类回归分割计算,完成复杂背景下杂草的具体方位、类别及轮廓的计算,根据杂草的轮廓面积和具体方位进行定位、定量的农药喷洒,以解决上述问题。

1 数据材料

1.1 数据采集

本文使用的杂草数据采集自陕西省自然环境下的玉米田间。采用 Intel RealSense Depth Camera

D435 型相机距地面 1 m 处垂直拍摄,可以减少太阳光反射的影响。如图 1 所示,在不同的日照强度、土壤背景(如湿度、麦秆残茬)条件下,采集 4 种不同杂草(刺儿草、莎草、灰菜、早熟禾)和玉米幼苗图像。共采集到 6 000 幅图像,每种图像为 1 200 幅。试验中,将原始图像调整为 224 像素×224 像素,使用 4 200 幅图像(每种为 840 幅)作为训练数据集,剩下的 1800 幅图像作为测试数据集。

1.2 数据集标记

为实现杂草分割网络模型的训练,本文使用图像标注工具 LabelMe^[22]对杂草数据集样本进行分割掩码标记,完成图像中杂草的标注,标注生成的 json 文件转换为 8 位灰度图作为样本标签,标注后的杂草及玉米掩码图像如图 2 所示。

2 杂草检测分割模型

将 Mask R-CNN 模型与目标检测算法、FCN^[23]分割算法相结合,可以在检测目标的同时分割出目标轮廓。为了满足精准农业变量喷药的需要,实现杂草的实时精准检测识别,本文提出了基于 Mask R-CNN 的玉米田间杂草检测分割方法,实现对复杂背景下杂草的识别、检测、分割。该模型的框架如图 3 所示。该模型由卷积神经网络(Convolutional neural networks, CNN)、区域建议网络(RPN)、RoIAlign、输出模块 4 部分组成。①CNN:利用基层卷积神经网络提取包含杂草语义空间信息的特征图。②RPN:将特征图按比例映射到原图像,并根据锚点在相应区域产生预选框(Bounding box, BBox),根据 BBox 与真实值的交并比(Intersection over union, IoU)^[24]选出正、负样本,进行分类回归训练,使用非极大值抑制(Non maximum suppression, NMS)^[25]方法筛选 BBox,选出杂草的预选区域。③RoIAlign:取消量化操作造成坐标值的偏差,使用双线性内插法获得坐标为浮点数的像素图像,根据预选区域的坐标位置,将特征图的相应预选区域池化为固定尺寸的特征图。④输出模块:由分类回归模块和 FCN 模块构成,分类回归模块负责特征图目标的类别分类及目标框回归,FCN 模块负责计算目



图 1 杂草和玉米图像
Fig. 1 Images of weeds and corns




图 2 杂草及玉米手工分割掩码示例

Fig. 2 Examples of weeds and corns manual segmentation masks

标的像素,进行目标轮廓的分割。

2.1 杂草 CNN 特征提取

ResNet-101 网络结构有 101 层网络,可以充分获取杂草图像的语义、空间信息,本文基层卷积神经网络采用含有 5 个网络模块层的 ResNet-101 网络结构,进行杂草样本图像的特征提取。其网络结构

如表 1 所示。

2.2 区域建议网络

RPN 的功能是计算图像目标区域的预选框,2.1 节中已经用卷积神经网络获得了杂草图像的特征图,RPN 在杂草特征图上用 3×3 滑动窗口进行全图的滑动生成,然后生成 2 个 1×1 的卷积层。①边




图 3 Mask R-CNN 杂草检测分割模型框架

Fig. 3 Mask R-CNN weed detection and segmentation model framework

表 1 ResNet-101 网络结构

Tab. 1 ResNet-101 network architecture

卷积层	输入图像尺寸/ (像素 × 像素)	卷积核
Conv1	224 × 224	7 × 7, 64, 步长为 2 3 × 3 max pool, 步长为 2
Conv2	112 × 112	$\begin{bmatrix} 1 \times 1 & 64 \\ 3 \times 3 & 64 \\ 1 \times 1 & 256 \end{bmatrix} \times 3$, 步长为 2
Conv3	56 × 56	$\begin{bmatrix} 1 \times 1 & 128 \\ 3 \times 3 & 128 \\ 1 \times 1 & 256 \end{bmatrix} \times 4$, 步长为 2
Conv4	28 × 28	$\begin{bmatrix} 1 \times 1 & 256 \\ 3 \times 3 & 256 \\ 1 \times 1 & 1024 \end{bmatrix} \times 23$, 步长为 2
Conv5	14 × 14	$\begin{bmatrix} 1 \times 1 & 512 \\ 3 \times 3 & 512 \\ 1 \times 1 & 2048 \end{bmatrix} \times 3$, 步长为 2

框回归层 (reg-layer): 用于计算 BBox 的中心坐标值 x 、 y 以及宽 w 、高 h (BBox 坐标是指原图的坐标偏移)。
②目标分类层 (cls-layer): 用于判断该区域是否包含目标。将特征图的锚点映射到原图像, 计算锚点跟期望区域的 IoU, IoU 大于 0.7 时为正样本, IoU 小于 0.3 时为负样本, 其余不计算, 经过迭代训练产生一定数量的 BBox, 使用非极大值抑制方法去除重叠的 BBox, 得出杂草的预选区域。其中 RPN 的损失函数为

$$L(p_i, t_i) = \frac{1}{N_{cls}} \sum_i L_{cls}(p_i, p_i^*) + \lambda \frac{1}{N_{reg}} \sum_i p_i^* L_{reg}(t_i, t_i^*) \tag{1}$$

其中

$$\begin{cases} t_i = (t_x, t_y, t_w, t_h) \\ t_i^* = (t_x^*, t_y^*, t_w^*, t_h^*) \end{cases} \tag{2}$$

$$\begin{cases} t_x = \frac{x - x_a}{w_a} \\ t_y = \frac{y - y_a}{h_a} \\ t_w = \lg \frac{w}{w_a} \\ t_h = \lg \frac{h}{h_a} \end{cases} \tag{3}$$

$$\begin{cases} t_x^* = \frac{x^* - x_a}{w_a} \\ t_y^* = \frac{y^* - y_a}{h_a} \\ t_w^* = \lg \frac{w^*}{w_a} \\ t_h^* = \lg \frac{h^*}{h_a} \end{cases} \tag{4}$$

$$L_{cls}(p_i, p_i^*) = -\lg p_u \tag{5}$$

$$L_{reg}(t_i, t_i^*) = \sum \text{smooth}_{L1}(t_i, t_i^*) \tag{6}$$

$$\text{smooth}_{L1}(x) = \begin{cases} 0.5x^2 & (|x| < 1) \\ |x| - 0.5 & (|x| \geq 1) \end{cases} \tag{7}$$

- 式中
- i ——锚点的序号
- N_{cls} ——分类层数
- N_{reg} ——回归层数
- p_i ——样本被预测为包括目标的概率
- p_i^* ——样本包括目标的概率, 取值为 0 或 1, 分别表示该样本为负或正
- t_i ——预测边界框的 4 个参数化坐标
- t_i^* ——与锚点相关联的真值边界框坐标
- L_{cls} ——样本分类中的损失函数
- L_{reg} ——样本回归损失函数
- λ ——平衡参数
- x_a, y_a, w_a, h_a ——锚点边界框的中心坐标值及宽、高
- x^*, y^*, w^*, h^* ——真值边界框的中心坐标值及宽、高
- p_u ——真值类别 u 的预测概率
- smooth_{L1} ——鲁棒范式损失函数, 比范式损失函数具有更强的适应性

2.3 RoIAlign 层

在 Fast R-CNN^[26]、Faster R-CNN^[27]、R-FCN^[28] 检测框架中, 使用 RoI Pooling 根据候选区域的坐标位置将特征图的相应预选区域池化为固定尺寸的特征图, 便于进行后续分类和预选框回归操作。RoI Pooling 运算过程中存在两次量化, 导致得出的预选框与第一次回归产生的预选框不匹配, 影响检测与分割精度。为了解决上述问题, 提高检测与分割的

精度,本文提出了 RoIAlign 方法。RoIAlign 取消量化操作,遍历各个预选区域,保持边界浮点数不做量化,将预选区域分割成 $f \times f$ 个单元,每个单元的边界不做量化,用双线性内插法计算每个单元 4 个位置的值,然后进行最大池化操作。结果表明, RoIAlign 可以在小误差下将 RPN 产生的预选区域调整为固定尺寸的特征图。

2.4 输出模块

输出模块由分类、回归、FCN 等部分组成, RoIAlign 层输出的每一个感兴趣区域 (Region of interest, RoI) 经过卷积核为 1×1 的两个卷积层、FCN 层后划分为 3 个分支,前两个分支用于分类回归运算,分类分支计算目标与真实标签的分类损失,回归分支计算预测框与真实框的回归损失,FCN 分支用于 RoI 像素计算。FCN 层通过反卷积层对 RoI 进行上采样计算,使其恢复到原图像尺寸,并计算 RoI 区域像素值与原图像区域像素值的平均二进制交叉熵。输出模块的 RoI 损失函数为

$$L = L_{cls} + L_{reg} + L_{mask} \tag{8}$$

其中
$$L_{mask} = -\frac{1}{s} \sum_i [s_i^* \lg p(s_i) - (1 - s_i^*) \lg (1 - p(s_i))] \tag{9}$$

式中 L ——模型总代价损失函数
 L_{mask} ——平均二进制交叉熵损失函数
 s ——像素数量
 s_i^* ——像素所在的类别标签
 $p(s_i)$ —— s_i 预测类别的概率

针对每个 RoI,Mask 分支有 Ks^2 个输出,并对 K 个尺寸为 s^2 的 Mask 编码,每个 Mask 有 K 个类别,然后使用 sigmoid 函数对每个像素进行分类。

最终,分类分支计算出候选区域的类别,回归分支计算出候选区域的位置边界框,FCN 模块计算出候选区域的像素。从而准确地检测分割出杂草的类

别、位置和轮廓。

3 杂草分割模型的构建与评估指标

3.1 杂草分割模型的构建

使用 TensorFlow-GPU 构建了基于 Mask R-CNN 的杂草检测分割模型,硬件环境为 GeForce GTX1080Ti GPU, Intel Xeon E5-2630 @ 2.20 GHz $\times$ 20 CPU,使用训练集对该模型进行训练。学习率设为 0.001,每次迭代的批处理量 (Batch size) 设为 32,模型一共迭代 20 000 次。

3.2 分割评估指标

使用均值平均精度 (Mean average precision, mAP) 作为杂草分割的评估指标,每一个类别都可以根据召回率 (Recall) 和精确率 (Precision) 绘制一条曲线,平均精度 (Average precision, AP) 是该曲线与坐标轴围成的面积。mAP 是由对全部类别的 AP 值求平均值得到,其计算公式为

$$P = \frac{T_p}{T_p + F_p} \times 100\% \tag{10}$$

$$R = \frac{T_p}{T_p + F_N} \times 100\% \tag{11}$$

$$A_p = \int_0^1 P(R) dR \tag{12}$$

$$m_{AP} = \frac{\sum A_p}{n} \tag{13}$$

式中 P ——精确率 R ——召回率
 T_p ——被正确预测为正样本的数量
 F_p ——负样本被预测为正样本的样本数量
 F_N ——正样本被预测为负样本的样本数量
 n ——类别数目 A_p ——平均精度
 m_{AP} ——均值平均精度

在模型训练过程中记录各个类别的 AP 值并计算 mAP,统计结果如图 4 所示,随着模型训练的不




图 4 玉米及杂草的 AP 与 mAP 值随迭代次数的变化曲线

Fig. 4 AP and mAP values change curves of corn and associated weeds with iterations

断深入,各类别的 AP 值逐步提高并达到较高的稳定值。

4 试验结果与分析

4.1 杂草分割结果

为了验证所提出的基于 Mask R-CNN 的杂草检测分割方法的有效性,本文将 DeepMask^[29]、SharpMask^[30]方法与本文方法进行试验对比,DeepMask 首先输出一个与类别无关的分割掩码,然后再输出该图像补丁在完整对象上居中的概率,DeepMask 通过学习实例嵌入,将粗形状细化为实例级掩码。SharpMask 是 DeepMask 的扩展,首先在前馈传递中生成粗略掩码编码,然后使用连续较低层的特征在自上而下的传递中细化此掩码编码,让掩码更好地粘附到对象边界。选用 1 800 幅玉米、杂草图像对 3 个方法进行测试比较,其中刺儿草、莎草、灰菜、早熟禾、玉米各 360 幅,在 IoU 为 0.5 时,3 种方法的 AP、mAP 如表 2 所示,可以得知,本文方法在玉米杂草数据集上 mAP 可达到 0.853,优于 SharpMask、DeepMask 的 0.816、0.795,3 种方法的单样本耗时分别为 280、256、248 ms,可满足实时田间农药变量喷洒的控制要求。图 5 为玉米、杂草数据分割样例。由表 2、图 5 可知,3 种方法对刺儿草、灰

菜的分割效果最好,对玉米、莎草的分割效果较差,原因可能是刺儿草、灰菜的圆形叶片比玉米、莎草的条形叶片更易区分。由图 5 可知,本文方法相对于 DeepMask、SharpMask,不会出现欠分割、过分割的情况。综上所述,本文方法的分割效果优于 DeepMask、SharpMask 方法。

表 2 3 种方法在玉米、杂草数据集上的测试结果
Tab.2 Results of three methods on datasets of corn weeds

方法	单样本 耗时/ms	mAP	AP				
			玉米	刺儿草	灰菜	早熟禾	莎草
本文方法	280	0.853	0.856	0.878	0.861	0.838	0.831
SharpMask	256	0.816	0.811	0.845	0.832	0.792	0.801
DeepMask	248	0.795	0.771	0.839	0.826	0.783	0.756

4.2 其他数据集验证

为测试本文方法在复杂背景下的分割效果,共采集 300 幅复杂背景下的玉米、杂草图像进行分割测试,同时,与 DeepMask、SharpMask 方法进行对比,3 种方法的分割测试结果如图 6 所示,图中橙色表示玉米,绿色表示杂草。在 IoU 为 0.5 时,3 种方法的 AP、mAP 如表 3 所示,Mask R-CNN 的 mAP 为 0.785,远高于 SharpMask、DeepMask 的 0.684、0.462,3 种方法在复杂背景下的单样本耗时分别为 285、260、252 ms。由图 6、表 3 可知,3 种方法对玉



图 5 3 种方法对杂草和玉米数据集的分割样例
Fig.5 Weed dataset segmentation sample of three methods

米的分割效果优于杂草,主要原因可能是杂草不够明显。由图6可知,SharpMask方法对玉米及杂草都出现了欠分割现象,DeepMask方法分割效果更差,而本文方法仍有很好的分割效果。因此,本文方法可用于复杂背景下的玉米杂草分割。




图6 分割样例

Fig.6 Segmentation samples

表3 3种方法在复杂背景数据集上的测试结果

Tab.3 Test results of three methods on complex background datasets

方法	单样本 耗时/ms	mAP	AP	
			玉米	杂草
本文方法	285	0.785	0.826	0.743
SharpMask	260	0.684	0.712	0.656
DeepMask	252	0.462	0.528	0.396

5 田间试验

为了验证本文方法的可行性,采用如图7所示的变量喷洒装置进行试验验证。该设备主要由驱动系统、支架系统、喷药系统3部分组成。驱动系统由发动机、传动系统、驱动轮、变速箱等组成。支架系统由方向机、地盘架、药箱、横梁、橡胶轮及橡胶轮支撑架组成。喷药系统由驱动液压马达、高压喷药泵、过滤器、电磁阀、喷管支架、摄像头等组成。

田间喷药流程如图8所示。试验中,喷洒装置行走速度为0.2 m/s,共前进25 m,摄像头每0.5 s采集一幅视场内含玉米植株行间隙与玉米植株行的图像,图像经过本文方法处理,获取图像中玉米、杂草目标的位置、标签和像素。单片机根据图像的位置




图7 变量喷洒装置

Fig.7 Spraying device

- 1.电磁阀喷头 2.左横向喷杆 3.左桁架 4.中间桁架 5.中间横向喷杆 6.喷杆折叠机构 7.右桁架 8.喷药管 9.右横向喷杆 10.横向喷杆喷头 11.摄像头

置标签信息,计算出距离杂草最近的喷头。根据分割像素,单片机控制电压,调节电磁阀开度,对杂草进行变量喷雾,从获取图像到电磁阀喷洒的平均时间为0.98 s。田间试验如图9所示。

田间试验于2019年4月29日(天气晴、微风、空气相对湿度78%)在山东省泰安市山东农业大学南校区玉米试验田中进行。试验田玉米植株行间距50 cm,株距10 cm,植株高度20 cm。方案1:在玉米植株行间放置3个电磁阀喷头,摄像头在电磁阀喷头前方30 cm处居中放置,如图9c所示。根据模型分割检测得出玉米植株行间杂草位置,相应的电磁阀喷头打开进行喷雾,喷雾效果如图9e所示。方案2:在玉米植株间及行间各放置一个电磁阀喷头,摄像头在电磁阀喷头前方30 cm处居中放置,如图9d所示,杂草处于玉米植株行间时,相应的电磁阀喷头打开喷雾,杂草处于玉米植株行间时,控制玉米植株间的电磁阀喷头打开喷雾,喷雾效果如图9f~9h所示。考虑到控制系统响应时间造成的延迟喷雾,将摄像头置于电磁阀喷头前方30cm处提前探测,摄像头与地面垂直距离50 cm,视场角30°,摄像头与单片机连接,单片机连接电磁阀喷头,用于控制电磁阀的开启,如图9a所示。单片机通过WiFi与计算机连接,将获取的图像信息通过WiFi传给单片机,传输过程如图9b所示。试验同时,在玉米、杂草叶片一侧覆盖水敏纸,进行喷雾测试,喷洒后的水敏纸如图9i所示。方案1喷洒靠近玉米一侧的杂草时,容易造成对玉米的误喷,因此本次试验采用方案2。

试验喷洒过程耗时312 s,共采集玉米、杂草现场图像608幅,其中包括1728株玉米,936株杂草,本文方法对图像的识别结果如表4所示。由表4可知,本文方法对田间杂草的识别准确率为91%,识别出杂草并准确喷雾的准确率为85%,识别出杂草但没有喷雾的主要原因是田间地面颠簸、风力、电磁阀喷头等因素的影响,电磁阀喷头对识别的杂草喷洒农药时不能完全覆盖(雾滴漂移导致部




图8 工作流程图
Fig. 8 Working process chart




图9 田间试验
Fig. 9 Field experiment

表4 本文方法对现场图像的识别结果
Tab. 4 Identification results of field images by proposed method

类别	总数	成功检测数	T_P	F_N	F_P	准确喷雾数	误喷数
玉米	1 728	1 724	1 624	100	4		120
杂草	936	908	852	56	16	796	

分杂草区域没有喷洒)。对玉米的误喷率为 3%,在喷洒过程中玉米被识别为杂草的概率为 6%,玉米被识别为杂草并喷雾的概率为 4%,在无杂草、无玉米情况下,被误识别为杂草的概率为 2%,喷雾的概率为 1%。造成被误喷的主要原因是某些杂草靠近玉米根部,喷洒时玉米叶片遮盖了杂草,从而导致玉米被误喷。

雾滴覆盖密度是判断雾滴变量喷洒效果的重要参数,是指雾滴收集装置单位面积上所收集的雾滴个数,采用文献[31]相同的软件及方法获取水敏纸上的总雾滴个数。雾滴覆盖密度计算公式为

$$D = \frac{N}{M}$$

(14)

式中 N ——雾滴总数,个
 M ——水敏纸试纸总面积,cm²

根据田间实际喷洒的统计结果,本试验准确喷雾的杂草农药雾滴覆盖密度为 55 个/cm²,根据袁会珠等^[32]关于雾滴覆盖密度与农药防治效果的关系研究可知,农药雾滴覆盖密度大于 28 个/cm² 时即可达到理想的防治效果。

6 结论

(1)在 IoU 为 0.5 时,本文方法在玉米、杂草数据集上的 mAP 为 0.853,优于 SharpMask、DeepMask 的 0.816、0.795。本文方法相比 SharpMask、DeepMask 具有更好的分割效果,本文方法的单样本耗时为 280 ms,满足田间杂草变量喷洒的实时控制要求。

(2)在玉米、杂草数据集上进行分割测试,结果表明,本文方法可准确检测出图像中杂草目标的类别、位置和轮廓,对复杂背景下的杂草仍有良好的分割效果,单样本耗时 285 ms,满足复杂背景下的杂草识别检测。

(3)在田间变量喷药试验中,杂草识别准确率

为91%,识别出杂草并准确喷雾的准确率为85%, 置对每幅图像的平均处理时间为0.98 s,满足农药准确喷雾的杂草农药雾滴覆盖密度为55个/cm²,装 变量喷洒的控制要求。

参 考 文 献

- [1] 汤雷雷,万开元,陈防. 养分管理与农田杂草生物多样性和遗传进化的关系研究进展[J]. 生态环境学报,2010,19(7): 1744 – 1749.
TANG Leilei, WAN Kaiyuan, CHEN Fang. Advances in studies on weeds biodiversity and genetic evolution in farmland in relation to nutrient [J]. Ecology and Environmental Sciences, 2010, 19(7): 1744 – 1749. (in Chinese)
- [2] 张小龙,谢正春,张念生,等. 豌豆苗期田间杂草识别与变量喷洒控制系统[J/OL]. 农业机械学报,2012,43(11): 220 – 225, 73.
ZHANG Xiaolong, XIE Zhengchun, ZHANG Niansheng, et al. Weed recognition from pea seedling images and variable spraying control system[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2012, 43(11): 220 – 225, 73. http://www.j-csam.org/ch/reader/view_abstract.aspx?file_no=20121141&flag=1&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2012.11.041. (in Chinese)
- [3] FRANCO C, PEDERSEN S M, PAPA HARALAMPOS H, et al. The value of precision for image-based decision support in weed management[J]. Precision Agriculture, 2017, 18(3): 366 – 382.
- [4] COLLINGS L V, GINSBURG D, CLARKE J H, et al. WMSS: improving the precision and prediction of weed management strategies in winter dominant rotations[C]// BCPC International Congress: Crop Science & Technology, 2003.
- [5] SLAUGHTER D C, GILES D K, DOWNEY D. Autonomous robotic weed control systems: a review[J]. Computers and Electronics in Agriculture, 2008, 61(1): 63 – 78.
- [6] THORP K R, TIAN L F. A review on remote sensing of weeds in agriculture[J]. Precision Agriculture, 2004, 5(5): 477 – 508.
- [7] KOUNALAKIS T, TRIANTAFYLIDIS G A, NALPANTIDIS L. Weed recognition framework for robotic precision farming[C]//IEEE International Conference on Imaging Systems & Techniques, 2016.
- [8] LOTTES P, BEHLEY J, CHEBROLU N, et al. Joint stem detection and crop-weed classification for plant-specific treatment in precision farming[C]//2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2018: 8233 – 8238.
- [9] BURGOS-ARTIZU 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.
- [10] PANTAZI X E, MOSHOUD, BRAVO C. Active learning system for weed species recognition based on hyperspectral sensing [J]. Biosystems Engineering, 2016, 146: 193 – 202.
- [11] WENDEL A, UNDERWOOD J. Self-supervised weed detection in vegetable crops using ground based hyperspectral imaging [C]//2016 IEEE International Conference on Robotics and Automation (ICRA). Stockholm, Sweden, 2016: 5128 – 5135.
- [12] 邓向武,齐龙,马旭,等. 基于多特征融合和深度置信网络的稻田苗期杂草识别[J]. 农业工程学报,2018,34(14): 165 – 172.
DENG Xiangwu, QI Long, MA Xu, et al. Recognition of weeds at seedling stage in paddy fields using multi-feature fusion and deep belief networks[J]. Transactions of the CSAE, 2018, 34(14): 165 – 172. (in Chinese)
- [13] 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?file_no=20181104&flag=1&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2018.11.004. (in Chinese)
- [14] 吴兰兰,徐恺,熊利荣. 基于视觉注意模型的苗期油菜田间杂草检测[J]. 华中农业大学学报,2018,37(2): 96 – 102.
WU Lanlan, XU Kai, XIONG Lirong. Detecting weed in seedling rapeseed oil field based on visual-attention model[J]. Journal of Huazhong Agricultural University, 2018, 37(2): 96 – 102. (in Chinese)
- [15] BAKHSHIPOUR A, JAFARI A. Evaluation of support vector machine and artificial neural networks in weed detection using Sharp features[J]. Computers and Electronics in Agriculture, 2018, 145: 153 – 160.
- [16] WU X, XU W, SONG Y, et al. A detection method of weed in wheat field on machine vision[J]. Procedia Engineering, 2011, 15: 1998 – 2003.
- [17] 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.
- [18] MILIOTO A, LOTTES P, STACHNISS C. Real-time semantic segmentation of crop and weed for precision agriculture robots leveraging background knowledge in CNNs[C]//2018 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2018: 2229 – 2235.
- [19] MA X, DENG X, QI L, et al. Fully convolutional network for rice seedling and weed image segmentation at the seedling stage in paddy fields[J]. PloS one, 2019, 14(4): e0215676 – e0215676.
- [20] HE K, GKIOXARI G, DOLLAR P, et al. Mask R-CNN[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017(99): 2961 – 2969.
- [21] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770 – 778.

- csam.org/jcsam/ch/reader/view_abstract.aspx? file_no = 20140521&flag = 1&journal_id = jcsam. DOI: 10. 6041/j. issn. 1000-1298. 2014. 05. 021. (in Chinese)
- [21] 史嵩,周纪磊,刘虎,等. 驱动辅助种气吸式精量排种器设计与试验[J/OL]. 农业机械学报,2019,50(5):61–70. SHI Song, ZHOU Jilei, LIU Hu, et al. Design and experiment of pneumatic precision seed-metering device with guided assistant seed-filling[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(5):61–70. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? file_no = 20190507&flag = 1&journal_id = jcsam. DOI: 10. 6041/j. issn. 1000-1298. 2019. 05. 007. (in Chinese)
- [22] 韩瑞珍. 基于机器视觉的农田害虫快速检测与识别研究[D]. 杭州:浙江大学,2014. HAN Ruizhen. Research on fast detection and identification of field pests based on machine vision[D]. Hangzhou: Zhejiang University, 2014. (in Chinese)
- [23] 许永华,吴敏,何勇,等. 一种基于经验知识和信息熵的阈值选择策略[J]. 化工学报,2008,59(7):1803–1807. XU Yonghua, WU Min, HE Yong, et al. A threshold selection strategy based on empirical knowledge and information entropy [J]. CIESC Journal, 2008, 59(7):1803–1807. (in Chinese)
- [24] 刘慧,刘加林,沈跃,等. 植株点云超体聚类分割方法[J/OL]. 农业机械学报,2018,49(12):172–179. LIU Hui, LIU Jialin, SHEN Yue, et al. Segmentation method of supervoxel clusterings and salient map[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(12):172–179. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? file_no = 20181222&flag = 1&journal_id = jcsam. DOI: 10. 6041/j. issn. 1000-1298. 2018. 12. 022. (in Chinese)
- [25] 程玉柱,陈勇,张浩. 基于MMC与CV模型的苗期玉米图像分割算法[J/OL]. 农业机械学报,2013,44(11):266–270. CHENG Yuzhu, CHEN Yong, ZHANG Hao. Color image segmentation algorithm of corn based on MMC and CV model[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(11):266–270. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? file_no = 20131145&flag = 1&journal_id = jcsam. DOI: 10. 6041/j. issn. 1000-1298. 2013. 11. 045. (in Chinese)
- [26] 刘春燕. 图像分割评价方法研究[D]. 西安:西安电子科技大学,2011. LIU Chunyan. Survey on evaluation methods of image segmentation algorithms[D]. Xi'an: Xidian University, 2011. (in Chinese)
- [27] 陈进,顾琰,练毅,等. 基于机器视觉的水稻杂质及破碎籽粒在线识别方法[J]. 农业工程学报,2018,34(13):187–194. CHEN Jin, GU Yan, LIAN Yi, et al. Online recognition method of impurities and broken paddy grains based on machine vision[J]. Transactions of the CSAE, 2018, 34(13):187–194. (in Chinese)

(上接第 228 页)

- [22] RUSSELL B C, TORRALBA A, MURPHY K P, et al. LabelMe: a database and web-based tool for image annotation[J]. International Journal of Computer Vision, 2008, 77(1–3):157–173.
- [23] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2014, 39(4):640–651.
- [24] RAHMAN M A, WANG Y. Optimizing intersection-over-union in deep neural networks for image segmentation[M]//Advances in visual computing. Springer International Publishing, 2016.
- [25] NEUBECK A, GOOL L V. Efficient non-maximum suppression[C]//International Conference on Pattern Recognition, 2006.
- [26] GIRSHICK R. Fast R-CNN[C]//Proceedings of the IEEE International Conference on Computer Vision, 2015: 1440–1448.
- [27] REN S, GIRSHICK R, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6):1137–1149.
- [28] DAI J, LI Y, HE K, et al. R-FCN: object detection via region-based fully convolutional networks[C]//Advances in Neural Information Processing Systems, 2016: 379–387.
- [29] NGUYEN T D, SHINYA A, HARADA T, et al. Segmentation mask refinement using image transformations[J]. IEEE Access, 2017, 5:26409–26418.
- [30] TRULLO D, PETITJEAN S, RUAN S, et al. Segmentation of organs at risk in thoracic ct images using a sharpmask architecture and conditional random fields[C]//Proc. IEEE Int. Symp. Biomed. Imaging, 2017:1003–1006.
- [31] 姜红花,刘理民,柳平增,等. 面向精准喷雾的果树冠层体积在线计算方法[J/OL]. 农业机械学报,2019,50(7):120–129. JIANG Honghua, LIU Limin, LIU Pingzeng, et al. Online calculation method of fruit trees canopy volume for precision spray[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(7):120–129. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 20190712&journal_id = jcsam. DOI:10. 6041/j. issn. 1000-1298. 2019. 07. 012. (in Chinese)
- [32] 袁会珠,王国宾. 雾滴大小和覆盖密度与农药防治效果的关系[J]. 植物保护, 2015, 41(6):15–22. YUAN Huizhu, WANG Guobin. Effects of droplet size and deposition density on field efficacy of pesticides[J]. Journal of Plant Protection, 2015, 41(6):15–22. (in Chinese)