

基于 Faster R-CNN 深度网络的油菜田间 杂草识别方法

张乐, 金秀, 傅雷扬, 李绍稳*

安徽农业大学信息与计算机学院智慧农业技术与装备安徽省重点实验室, 安徽 合肥 230036

摘要 为自动识别油菜田间的杂草, 提出基于 Faster R-CNN 深度网络的油菜田间杂草识别方法, 利用 COCO 数据集的深度网络模型进行迁移训练。首先, 以自然环境条件下的油菜与杂草图像为样本, 利用 Faster R-CNN 深度网络模型共享卷积特征, 对比 VGG-16、ResNet-50 和 ResNet-101 这 3 种特征提取网络的结果; 该方法还与采用 3 种相同特征提取网络的 SSD 深度网络模型进行对比。结果表明, 基于 VGG-16 的 Faster R-CNN 深度网络模型在油菜与杂草目标识别中具有明显的优势, 其油菜与杂草的目标识别精确度可达 83.90%, 召回率达到 78.86%, F_1 值为 81.30%。该深度学习方法能够有效实现油菜与杂草目标的准确、高效识别, 为多类型杂草目标识别的研究提供了参考。

关键词 机器视觉; 深度学习; Faster R-CNN 深度网络; 目标识别; 油菜与杂草图像

中图分类号 TP391.41

文献标志码 A

doi: 10.3788/LOP57.021508

Recognition Method for Weeds in Rapeseed Field Based on Faster R-CNN Deep Network

Zhang Le, Jin Xiu, Fu Leiyang, Li Shaowen*

Anhui Provincial Key Laboratory of Smart Agricultural Technology and Equipment,

School of Information & Computer, Anhui Agricultural University, Hefei, Anhui 230036, China

Abstract The purpose of this study is to develop a method for automatically identifying weeds in a rapeseed field. We propose a weed-recognition method based on a Faster R-CNN (region-convolution neural network) deep network and use the deep network model of the COCO dataset for migration training. First, by obtaining images of rapeseed and weed samples under natural environment, the Faster R-CNN deep network model is utilized to share the convolution characteristics and the results of three feature extraction networks: VGG-16, ResNet-50, and ResNet-101, are compared. At the same time, the method is also compared with a single shot multibox detector (SSD) deep network model, which includes the three identical feature extraction networks. The results show that the Faster R-CNN deep network model based on VGG-16 has obvious advantages in rapeseed and weed target recognition. The accuracy of target recognition and recall rate of the rapeseed and weeds are 83.90% and 78.86%, respectively, whereas the F_1 value is 81.30%. The proposed deep learning method can effectively and rapidly identify rapeseed and weed targets, providing a reference for further research into multi-type weed target recognition.

Key words machine vision; deep learning; Faster R-CNN deep network; target recognition; images of rapeseed and weed

OCIS codes 150.1135; 110.2970; 110.3000

1 引言

随着我国农业现代化智能程度的不断加快, 在自

然生长环境条件下, 准确高效地识别田间农作物的杂草目标对于实现田间智能化管理起到重要作用, 一方面有助于智能设备的自动化除草作业和自动水肥变

收稿日期: 2019-06-12; 修回日期: 2019-07-02; 录用日期: 2019-07-09

基金项目: 农业部引进国际先进农业科学技术 948 项目(2015-Z44, 2016-X34)

* E-mail: shwli@ahau.edu.cn

量喷施,另一方面有助于减少田间农药化肥的使用^[1]。因此,如何准确、快速、高效地识别田间农作物的杂草具有十分重要的意义,对推进现代信息技术与农业深度的跨界融合具有实际理论意义。

目前,国内许多学者对油菜与杂草的目标识别开展了相关研究,并且取得了一定的研究成果。白敬等^[2]利用光谱分析技术,以冬油菜苗和冬油菜苗期杂草以及土壤为研究对象,实现了冬油菜苗期杂草的快速识别。潘冉冉等^[3]运用近红外高光谱成像技术,同时结合化学计量学方法,对油菜中的杂草进行了准确分类识别。但是,传统的基于机器学习^[4-5]或者机器视觉^[6-8]的农作物与杂草目标识别方式,依赖于人工的设计与制造检测特征,设计过程中易受主观因素影响,需要理论的指导,会耗费大量的时间,因此要求研发人员具有扎实的专业素养和大量的成熟经验,最终形成的检测特征也是参差不齐,难以适应自然环境因素的变化,泛化能力较差^[9]。随着人工智能革命浪潮的来临,深度学习方法的出现有效地解决了这一问题,深度学习中的卷积神经网络^[10](CNN)具有目标特征自动提取功能,无需人工干预设计,能够有效、自动地对多任务需求学习目标特征,从而在目标检测与识别方面表现出强大的能力。

近年来,随着深度卷积神经网络^[11-12](DCNN)的应用与发展,越来越多的研究人员开始将其应用于目标检测与识别领域。Girshick 等^[13]提出基于区域卷积神经网络(R-CNN)的目标检测方法,该方法利用选择性搜索(SS)算法生成候选区域,用于提取目标特征,虽然能解决少量有限标注数据训练,生成较高质量模型,但是在提取特征效率和占用内存方面表现欠佳。随后,为了解决 R-CNN 中出现大量冗余特征提取的问题,Girshick^[14]又提出 Fast R-CNN 模型,该模型采用自适应尺度池化操作,极大地提高了目标检测与识别的性能。He 等^[15]提出基于深度卷积网络的空间金字塔池化层视觉识别方法,该方法放宽了对输入图片数据尺寸大小的限制,从而显著提高了识别的准确率。Ren 等^[16]提出 Faster R-CNN 模型,该模型由区域建议网络(RPN)和 Fast R-CNN 构成,用区域建议网络替代 SS 算法,解决了计算区域建议时间开销大的瓶颈问题,使实时目标检测与识别成为可能,于此同时,Faster R-CNN 模型被广泛应用于车辆检测领域^[9]、遥感影像地物目标识别领域^[17-18]、外观缺陷检测领域^[19]、行人检测与识别领域^[20-21]以及田间图像检测领域^[22]等。

为实现油菜与杂草目标的准确高效识别,利用深度学习方法克服传统机器学习方法中存在易受复杂环境背景、农作物与杂草遮挡以及光线等的干扰,以及目标识别效率低下且泛化能力差的问题,本文将 Faster R-CNN 深度网络模型方法运用到油菜与杂草目标识别中,通过对比 3 种特征提取网络的性能,同时对比 SSD 深度网络模型方法^[23],结果可知,基于 VGG-16 特征提取网络的 Faster R-CNN 深度网络模型在油菜与杂草目标识别中表现出巨大的潜力,为智能除草机器人前期的除草作业以及多类型杂草目标识别的研究提供了参考。

2 实验数据

2.1 图像数据采集

此次实验的油菜与杂草图像数据采集于安徽农业大学庐江农业科技园,采集时间为 2018 年 12 月 16 日—17 日,时间段为每日的上午 9:00—12:00,下午 13:00—16:00,此时油菜目标处于幼苗期,并且该时间段太阳光线充足。采集过程分别以平视、俯视和 45°斜视 3 个方向采集自然条件下生长的油菜与杂草图像,严格地按照采集步骤进行采集。图像数据采集设备采用高清数码相机,型号为佳能 EOS 6D Mark II 相机,图像分辨率为 5472 pixel×3648 pixel,所有图像均为 JPEG 格式。

2.2 数据集分析

本次实验共采集油菜与杂草图像 2826 张,其中采集单株油菜 786 张、采集单株杂草 813 张、采集油菜与杂草混合 1227 张。为了训练后续模型以及减少训练所占用的内存与显存,需要将图像分辨率为 5472 pixel×3648 pixel 的图像进行压缩处理,压缩为 500 pixel×400 pixel。然后需要从采集的 2826 张油菜与杂草图像中随机选取 295 张图像作为测试集,其余 2531 张图像用于后续的图像数据增强以及网络模型训练。采用人工标注的方式进行图像标注,利用最小外接矩形法对图像中的油菜与杂草目标进行标注,保证每个标注矩形框内有且仅有一个油菜或者杂草目标,并且尽可能少地包含背景信息。

为了实现图像数据增强,以增加样本的多样性,本文对压缩过后的原始图像进行水平翻转、垂直翻转、水平垂直翻转、亮度增强与减弱、饱和度增强与减弱 7 种处理操作,如图 1 所示,其中亮度增强为原来的 1.1 倍,减弱为原来的 1/2,饱和度增强为原来的 1.5 倍,减弱为原来的 1/2,经过图像亮度增强与减弱、饱和度增强与减弱的原始图像标注依旧有效。



图1 图像数据增强结果。(a)油菜与杂草混合图像;(b)水平翻转图像;(c)垂直翻转图像;(d)水平垂直翻转图像;
(e)亮度增强图像;(f)亮度减弱图像;(g)饱和度增强图像;(h)饱和度减弱图像

Fig. 1 Results of image data enhancement. (a) Mixed image of rapeseed and weeds; (b) horizontally flipped image; (c) vertically flipped image; (d) horizontally and vertically flipped image; (e) brightness-enhanced image; (f) brightness-reduced image; (g) saturation-enhanced image; (h) saturation reduced image

图像数据增强旨在扩充实验样本数据,更好地提取图像的敏感区域,能够有效降低过拟合的风险。经过图像数据增强,训练样本数据由 2531 张图像扩充为 20248 张图像。训练集与验证集的比例按照4:1设置,从图像扩充后的 20248 张图像中随机选取16198 张图像作为训练集,其余 4050 张图像作为验证集。

3 基于 Faster R-CNN 的油菜与杂草目标识别网络

Faster R-CNN 深度网络模型通过对 R-CNN

和 Fast R-CNN 模型的分析与优化,形成了一种更优的目标检测网络模型。Faster R-CNN 深度网络模型是 RPN 和 Fast R-CNN 模型两者的深度结合。其中 RPN 替换了原有的 SS 等方法,用于生成高质量的区域建议框,实现了与 VGG-16 特征提取网络的卷积层共享,有效降低了区域建议检测所需的时间成本;而 Fast R-CNN 模型负责学习 RPN 所生成的建议区域特征,处理后续的分类得分与边框回归工作。本文具体的油菜与杂草目标识别网络如图 2 所示。

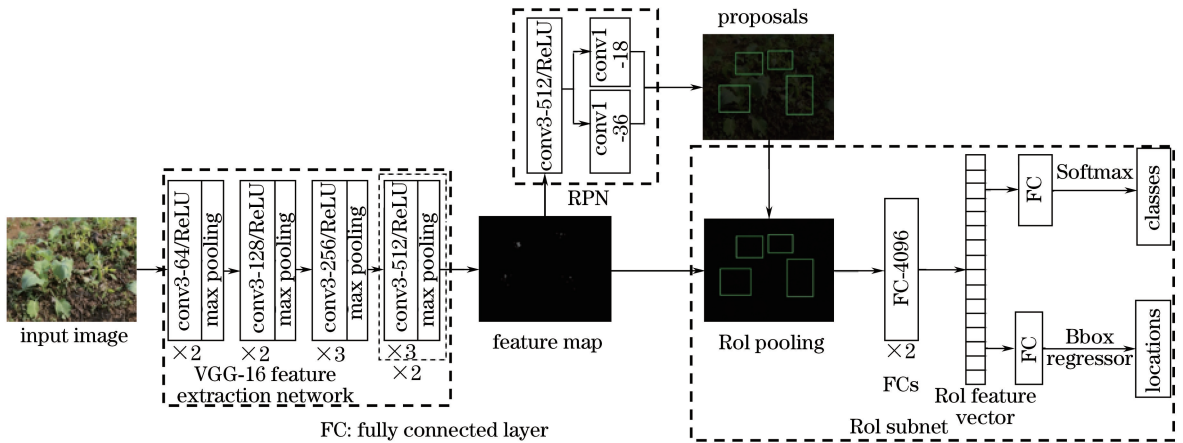


图2 Faster R-CNN 深度网络结构图

Fig. 2 Framework of Faster R-CNN deep network

3.1 模型算法

Faster R-CNN 深度网络由特征提取网络、RPN 和 RoI(region of interest)子网组成。其中特征提取网络采用 VGG-16 卷积神经网络用于提取输入图像的特征,进而形成特征图,与 RPN 共享卷积特征。该特征提取网络包括 13 个卷积层和 5 个池化层,每个卷积层均采用非线性 ReLU 作为激活

函数,卷积核的大小均为 3×3 ,每个池化层均采用最大池化层(max pooling)的形式,最终将该特征提取网络分为 5 个部分,每个部分之间通过池化层连接。以其中第 1 个部分为例,该部分按照卷积层(convolution)+激活函数(ReLU)+池化层(max pooling)的组合方式形成,卷积层有 2 层,由 3×3 的卷积核和 64 个通道数组成。

RPN 作为目前最先进的区域建议框提取算法, 是一个全卷积神经网络 (FCN), 采用滑动窗口机制实现区域建议框的生成, 具体的 RPN 结构如图 3 所示。RPN 包含一个卷积层和两个全连接层, 卷积层添加于卷积特征图之后, 与 VGG-16 特征提取网络的最后一个卷积层相同, 两个全连接层采用并行的方式与卷积层连接, 其中一个全连接层采用 1×1 的卷积核和 18 个通道数, 另一个全连接层采用 1×1 的卷积核和 36 个通道数。RPN 将特征提取网络所提取的卷积特征图作为输入, 然后在共享卷积特征图上添加一个小的滑动窗口进行滑动, 该滑动窗口经过中间层 (intermediate layer) 将卷积特征图中 d 个大小为 $n \times n (n=3)$ 的空间窗口映射到一个低

维向量 (512 维) 上, 最后这个低维向量被输入到两个并行的全连接层——边框分类层 (Cls layer) 和边框回归层 (Reg layer), 用于输出滑动窗口中的区域特征以及该区域位置的位置坐标。当滑动窗口在共享卷积特征图上滑动时, 每个滑动的位置都会预测出 k 个区域建议框, 因此边框分类层会输出 $2k$ 个得分 (k 个目标的分数、 k 个背景分数), 用于预测每个区域建议框是目标或者不是目标的概率, 边框回归层会输出 $4k$ 个变换参数, 用于编码 k 个区域建议框的位置坐标。另外, 采用非极大值抑制 (NMS) 法使 RPN 所提取的候选框更加精确, 同时每个区域建议框的中心实质是当前滑动窗口的中心。

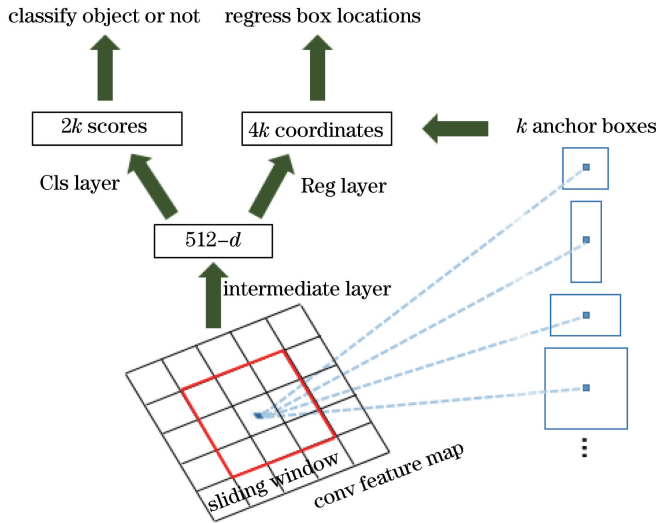


图 3 RPN 结构

Fig. 3 Framework of RPN

对于 RPN 总体的损失函数定义为^[24]

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

式中: i 表示批处理一次中选取锚点的索引; p_i 表示锚点 i 是目标的预测概率; p_i^* 表示对应真实区域标签的预测值; t_i 表示预测边框的 4 个参数化坐标向量; t_i^* 表示对应真实区域边框的坐标向量。

(1) 式中的 L_{cls} 表示分类损失, 实质是两个类别 (目标/非目标) 的对数损失, 定义为

$$L_{\text{cls}}(p_i, p_i^*) = -\text{lb}[p_i p_i^* + (1 - p_i)(1 - p_i^*)], \quad (2)$$

(1) 式中的 L_{reg} 表示回归损失, 定义为

$$L_{\text{reg}}(t_i, t_i^*) = R(t_i - t_i^*), \quad (3)$$

式中: $N_{\text{cls}} (N_{\text{cls}} = 256)$ 和 $N_{\text{reg}} (N_{\text{reg}} = 2400)$ 表示归

一化参数, 分别对分类项和回归项两项进行归一化, 并通过平衡参数 $\lambda (\lambda = 10)$ 进行加权, 从而使这两项权重大致相同; lb 表示对数损失函数; R 表示稳健损失函数 (smooth L_1)。

对于边框回归, 采用 4 个坐标的参数化, 即

$$\begin{cases} t_x = (x - x_a) / w_a, & t_y = (y - y_a) / h_a \\ t_w = \text{lb}(w / w_a), & t_h = \text{lb}(h / h_a) \\ t_x^* = (x^* - x_a) / w_a, & t_y^* = (y^* - y_a) / h_a \\ t_w^* = \text{lb}(w^* / w_a), & t_h^* = \text{lb}(h^* / h_a) \end{cases}, \quad (4)$$

式中: x, y, w, h 表示预测边框的中心坐标及其宽和高; 变量 x, x_a, x^* 分别表示预测边框、锚点、真实区域边框的 x 坐标 (y, w, h 同样适用)。

RoI 子网连接在 VGG-16 特征提取网络之后, 用于准确提取目标的 RoI, 进而可以对目标区域的位置进行参数回归修正, 最终准确实现油菜与杂草的目标识别。将 RPN 提取的 proposals 和特征提

取网络提取的特征图作为输入,输入感兴趣区域池化层(RoI pooling)用于将大小不同的RoI通过池化操作固定为 7×7 的RoI特征池化图;然后再通过连接的两个全连接层将RoI特征池化图转化为一个RoI特征向量(4096维),该向量包含RoI最终特征;最后将该向量输入一个对应的全连接层,利用Softmax计算分类得分,输出预测的类别概率,再将该向量输入到另一个对应的全连接层中,利用边框回归(Bbox regressor)获得位置偏移量,进而输出更加准确的目标检测框。

3.2 评价指标

为评价本模型对解决油菜与杂草目标识别时的有效性,采用精确度与召回率两项指标进行模型评价,两者的取值范围均为 $[0, 1]$,同时引入 F_1 值^[12]进行调和平均评价,具体评价计算公式为

$$P = \frac{n_{TP}}{n_{TP} + n_{FP}} \times 100\%, \quad (5)$$

$$R = \frac{n_{TP}}{n_{TP} + n_{FN}} \times 100\%, \quad (6)$$

$$F_1 = \frac{2PR}{P + R} \times 100\%, \quad (7)$$

式中: P 表示精确度; R 表示召回率; F_1 表示精确度和召回率的调和平均; n_{TP} 表示正确识别油菜与杂草目标的数目; n_{FP} 表示错误识别油菜与杂草目标的数目; n_{FN} 表示未识别油菜与杂草目标的数目。

4 结果与讨论

4.1 实验平台及训练设置

本实验在Windows 10企业版操作系统下,基于Intel(R) Core(TM) i5-8400 CPU, 2.80 GHz (16 GB运行内存)和NVIDIA GeForce GTX 1080 Ti GPU (11 GB运行显存)的硬件设备搭建TensorFlow深度学习框架,利用Python编程语言实现油菜与杂草目标识别网络模型的训练与测试。

本文以端到端的训练方式共享卷积特征,利用COCO数据集^[25]的预训练模型进行初始化参数设置。模型的优化器选择随机梯度下降(SGD)算法,整体学习率设置为0.001,动量因子设置为0.9,最大迭代次数设置为100000步。当迭代次数达到40000步时,学习率进一步调整为0.0001,当迭代次数达到80000步时,学习率再进一步调整为0.00001,用以加速训练模型的收敛。同时,每1000步输出在验证集上测试的平均精度与召回率,当损失函数收敛且迭代次数达到100000步时停止训练。

训练结束后需保存训练好的模型,利用测试集对模型效果进一步验证,保留置信度大于0.8的油菜与杂草目标,最后在测试集的图像数据中输出识别情况。

4.2 模型训练结果分析

为了选取更优的深度网络模型以及适宜的特征提取网络,本实验在SSD深度网络模型和Faster R-CNN深度网络模型上,分别利用3种特征提取网络(VGG-16、ResNet-50、ResNet-101)进行各自模型的训练。随着模型训练迭代次数(iterations)的增加,对3种特征提取网络在各自深度网络模型中实时的整体损失函数的损失情况进行对比,具体的对比情况如图4和图5所示。图4为3种特征提取网络在SSD深度网络模型上的整体损失函数的损失情况,显然基于VGG-16特征提取网络的SSD深度网络模型能迅速收敛,明显优于另外2种SSD深度网络模型,而基于ResNet-50和ResNet-101特征提取网络的SSD深度网络模型收敛趋势情况基本相同。图5为3种特征提取网络在Faster R-CNN深度网络模型上的整体损失函数的损失情况,基于VGG-16特征提取网络的Faster R-CNN深度网络模型能以更快速度进行收敛,明显优于其余2种Faster R-CNN深度网络模型,而基于ResNet-50和ResNet-101特征提取网络的Faster R-CNN深度网络模型分别出现了不同程度的振荡,40000步以后才基本趋于稳定。

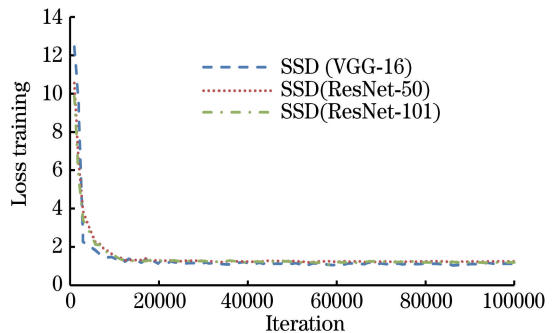


图4 SSD上的整体损失对比

Fig. 4 Comparison of total losses on SSD

为进一步选取更优的深度网络模型以及适宜的特征提取网络,本实验根据上述各自深度网络模型对比的结果选取性能相对较优的2种模型进行进一步对比,因此选取的模型为均采用VGG-16卷积神经网络作为特征提取网络的SSD深度网络模型与Faster R-CNN深度网络模型。分别对他们的迭代次数与模型训练时的整体损失、模型验证时的精确

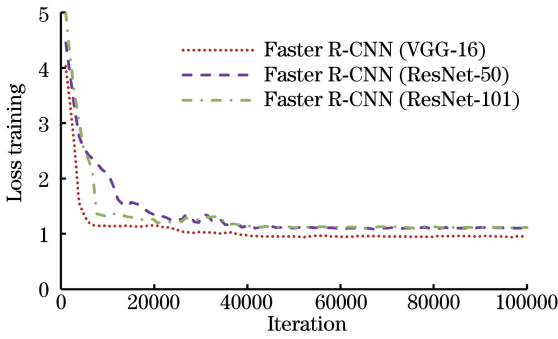


图 5 Faster R-CNN 模型上的整体损失对比

Fig. 5 Comparison of total losses on faster R-CNN model

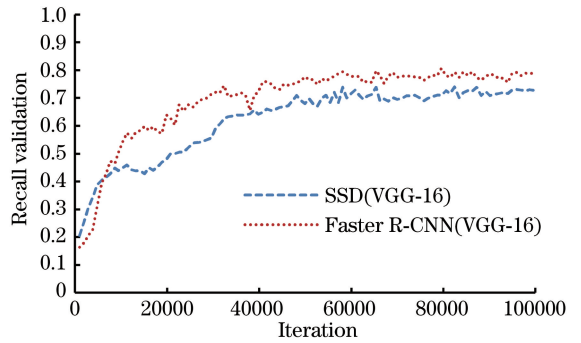


图 8 模型召回率对比

Fig. 8 Comparison of recall rates for two models

度和召回率进行探究,具体的对比结果如图 6~8 所示。图 6 为随着训练迭代次数的增加,2 种深度网络模型在训练时实时的整体损失函数的损失情况,虽然 2 种深度网络模型均在 20000 步之后趋于稳定,但是明显能够看出 Faster R-CNN 深度网络模型比 SSD 深度网络模型能更快地趋于稳定,甚至在 5000 步之内就趋于稳定。两者对比结果表明,基于 VGG-16 特征提取网络的 Faster R-CNN 深度网络模型在训练过程中能够迅速地完成收敛,从而能大大降低模型训练时间。图 7 和图 8 分别为随着训练迭代次数的增加,2 种深度网络模型在验

证集上的精确度与召回率情况,虽然 Faster R-CNN 深度网络模型在模型训练开始时,在验证集上精确度与召回率低于 SSD 深度网络模型,但是随着训练迭代次数的增加,Faster R-CNN 深度网络模型的精确度与召回率始终高于 SSD 深度网络模型,表现出一定的优势,最高精确度达到 83.90%,最高召回率达到 78.86%。

根据模型评价,本实验对精确度与召回率两项指标以及 F_1 值与检测时间(单张图像)进行了详细对比,深度网络模型的对比结果如表 1 所示。基于 VGG-16、ResNet-50 和 ResNet-101 特征提取网络,SSD 深度网络模型和 Faster R-CNN 深度网络模型分别对油菜与杂草图像数据集进行目标识别。通过对比可知,相较于其余两种特征提取网络,在单张图像检测时间相差不大的情况下,VGG-16 特征提取网络在 SSD 深度网络模型和 Faster R-CNN 深度网络模型上均表现出优良性能。特别是,基于 VGG-16 特征提取网络的 Faster R-CNN 深度网络模型对油菜与杂草目标的识别精确度达到 83.90%,召回率达到 78.86%,明显优于其余两种特征提取网络。通过对 SSD 深度网络模型和 Faster R-CNN 深度网络模型进一步对比,在采用相同的特征提取网络(VGG-16)的条件下,虽然 SSD 深度网络模型在检测时间上表现出优势,但是在精确度与召回率两项指标上,Faster R-CNN 深度网络模型依旧表现出优良的性能。




图 6 SSD 与 Faster R-CNN 模型整体损失对比

Fig. 6 Comparison of total losses for SSD and Faster R-CNN models

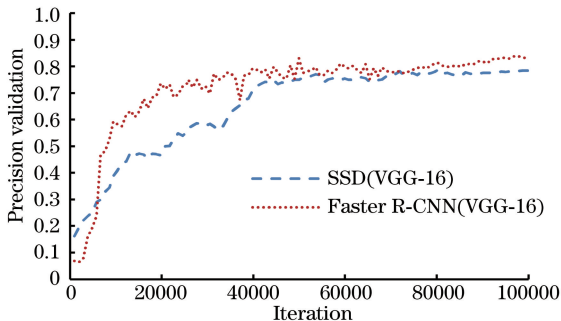


图 7 模型精确度对比

Fig. 7 Comparison of accuracy for two models

4.3 模型识别结果

本实验的 Faster R-CNN 深度网络模型采用 VGG-16 特征提取网络,利用 RPN 生成高质量的区域建议框,实现了与 VGG-16 特征提取网络的卷积层共享,降低了区域建议检测所需的时间成本,有效提高了油菜与杂草目标的识别精度。具体的油菜与杂草目标识别结果如图 9 所示。

表 1 深度网络模型对比

Table 1 Comparison of deep network models

Model	Extraction network	Accuracy /%	Recall /%	F_1 value /%	Detection time /ms
SSD	VGG-16	78.47	72.64	75.44	178
SSD	ResNet-50	62.76	58.24	60.42	189
SSD	ResNet-101	51.68	46.12	48.74	196
Faster R-CNN	VGG-16	83.90	78.86	81.30	295
Faster R-CNN	ResNet-50	60.96	54.50	57.55	308
Faster R-CNN	ResNet-101	55.37	49.33	52.18	310

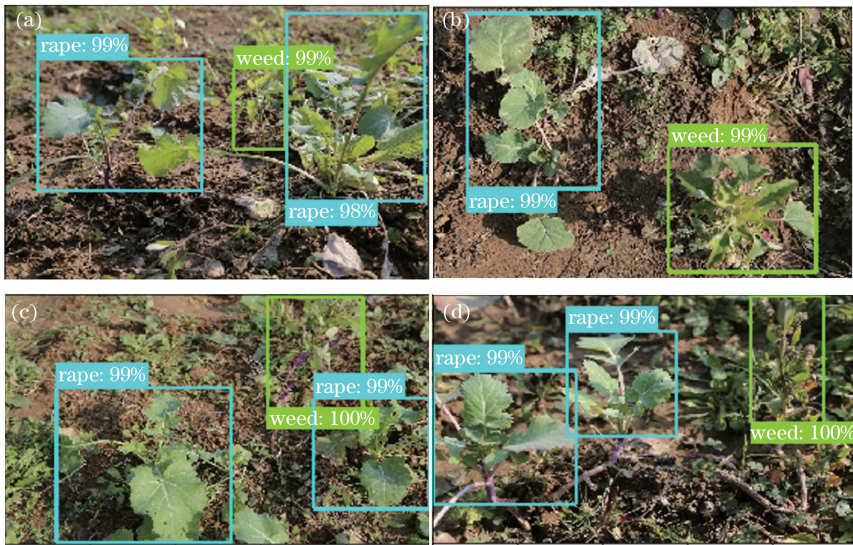


图 9 油菜与杂草目标识别结果。(a)有遮挡识别结果;(b)无遮挡识别结果;(c)复杂背景识别结果;(d)简单背景识别结果
Fig. 9 Results of target recognition for rapeseed and weeds. (a) Results of recognition with occlusion; (b) results of recognition without occlusion; (c) results of recognition with complex background; (d) results of recognition with simple background

4.4 讨论

本文利用深度学习的方法能够自动识别自然环境条件下油菜与杂草目标,目的在于以智能除草机器人视觉角度捕捉识别目标,这对后续油菜与杂草目标定位奠定了研究基础,有望顺利应用于智能除草机器人的除草作业,减少了化学农药的使用。

由上述模型训练结果分析可知,相较于 Faster R-CNN 深度网络模型,SSD 深度网络模型在油菜与杂草目标识别精确度上稍逊一筹,但是在检测速度上却表现出明显的优势。原因如下:第一,SSD 深度网络模型采用将整个检测网络作为单个神经网络,根据自动提取多尺度的特征图,利用不同尺度和长宽比的先验框,可以较为准确地预测目标类别概率和边框位置,因此在检测速度上表现出优势;第二,在所研究的野外自然环境中,油菜与杂草目标所处的实验环境背景复杂,背景干扰因素相对较多,另外在野外的油菜与杂草实验田杂草的种类不唯一,存在其他次要杂草目标的干扰,加之采集的目标图像数据多角度,存在严重的覆盖与

遮挡问题,从而导致 SSD 深度网络模型的先验框不能很好地发挥作用,进而影响了模型的准确率。

对比分析 VGG-16、ResNet-50 和 ResNet-101 这 3 种特征提取网络在油菜与杂草目标识别领域的优缺点,发现随着特征提取网络层数的不断加深,深度网络模型性能并没有表现出期望的结果。实验结果表明,基于 VGG-16 特征提取网络的 Faster R-CNN 深度网络模型,用于油菜与杂草目标识别具有明显优势。其原因为:第一,采用 COCO 数据集预训练模型进行初始化参数设置,对深度网络模型进行迁移训练,同时利用 Faster R-CNN 深度网络模型共享卷积特征;第二,随着特征提取网络卷积层数的不断加深,油菜与杂草目标识别准确率并没有提高,原因主要是过深的卷积层更具有个性化特征,不具有普适性,且会导致模型效果更差。

5 结 论

以幼苗期的油菜与杂草图像数据为研究对象,

在 TensorFlow 深度学习框架上构建基于 VGG-16 特征提取网络的 Faster R-CNN 深度网络模型。通过 COCO 数据集的深度网络模型进行迁移训练,对 Faster R-CNN 深度网络模型在油菜与杂草混合场景下的目标快速准确识别进行分析研究,对比分析 3 种特征提取网络的实际作用效果。另外,为解决深度学习模型训练时所需数据量大的问题,特别是农业领域中季节性作物存在数据量严重不足的问题,本文通过 7 种数据增强方式进行数据增强,极大地丰富了训练数据集,有效解决了油菜与杂草图像数据不足问题,从而降低模型训练时的过拟合风险,这也为后续有效解决农业许多领域面临数据匮乏的问题提供了思路。实验结果表明,Faster R-CNN 深度网络模型通过采用 VGG-16 特征提取网络,相较于其余两种特征提取网络表现出明显的优势,实现了快速有效的目标识别,体现出深度学习方法在目标识别领域的强大效率。然而,通过进一步的对比与观察,不难发现,特征提取网络卷积层数的不断加深,并没有在油菜与杂草目标识别上表现出很好的效果,因此,面对复杂环境条件下农作物与杂草混合场景中的目标识别,合理的选择与设计特征提取网络具有十分重要的现实意义。由于该模型依然较为庞大,目标识别准确率仍待提高,故今后需要继续深入研究如何简化网络模型,研发轻量型深度网络模型,设计高识别率的目标识别方法,扩大深度网络模型在农作物其他除草领域的应用。

参 考 文 献

- [1] Sabzi S, Abbaspour-Gilandeh Y. Using video processing to classify potato plant and three types of weed using hybrid of artificial neural network and particle swarm algorithm [J]. *Measurement*, 2018, 126: 22-36.
- [2] Bai J, Xu Y, Wei X H, et al. Weed identification from winter rape at seedling stage based on spectrum characteristics analysis [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2013, 29(20): 128-134.
白敬, 徐友, 魏新华, 等. 基于光谱特性分析的冬油菜苗期田间杂草识别 [J]. *农业工程学报*, 2013, 29(20): 128-134.
- [3] Pan R R, Luo Y F, Wang C, et al. Classifications of oilseed rape and weeds based on hyperspectral imaging [J]. *Spectroscopy and Spectral Analysis*, 2017, 37(11): 3567-3572.

潘冉冉, 骆一凡, 王昌, 等. 高光谱成像的油菜和杂草分类方法 [J]. *光谱学与光谱分析*, 2017, 37(11): 3567-3572.

- [4] Zhai R F, Fang Y H, Lin C D, et al. Segmentation of field rapeseed plant image based on Gaussian HI color algorithm [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2016, 32(8): 142-147.
翟瑞芳, 方益杭, 林承达, 等. 基于高斯 HI 颜色算法的大田油菜图像分割 [J]. *农业工程学报*, 2016, 32(8): 142-147.
- [5] Bakhshipour A, Jafari A. Evaluation of support vector machine and artificial neural networks in weed detection using shape features [J]. *Computers and Electronics in Agriculture*, 2018, 145: 153-160.
- [6] Hu L, Luo X W, Zeng S, et al. Plant recognition and localization for intra-row mechanical weeding device based on machine vision [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2013, 29(10): 12-18.
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.
- [7] Wu L L, Xu K, Xiong L R. Detecting weed in seedling rapeseed oil field based on visual-attention model [J]. *Journal of Huazhong Agricultural University*, 2018, 37(2): 96-102.
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.
- [8] Chang C L, Lin K M. Smart agricultural machine with a computer vision-based weeding and variable-rate irrigation scheme [J]. *Robotics*, 2018, 7(3): 38.
- [9] Wang L, Zhang H H. Application of Faster R-CNN model in vehicle detection [J]. *Journal of Computer Applications*, 2018, 38(3): 666-670.
王林, 张鹤鹤. Faster R-CNN 模型在车辆检测中的应用 [J]. *计算机应用*, 2018, 38(3): 666-670.
- [10] Wang C, Wu X H, Li Z W. Recognition of maize and weed based on multi-scale hierarchical features extracted by convolutional neural network [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2018, 34(5): 144-151.
王璨, 武新慧, 李志伟. 基于卷积神经网络提取多尺度分层特征识别玉米杂草 [J]. *农业工程学报*, 2018, 34(5): 144-151.
- [11] Zhou Y C, Xu T Y, Zheng W, et al. Classification

- and recognition approaches of tomato main organs based on DCNN [J]. Transactions of the Chinese Society of Agricultural Engineering, 2017, 33(15): 219-226.
- 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.
- [12] Wang D D, He D J. Recognition of apple targets before fruits thinning by robot based on R-FCN deep convolution neural network [J]. Transactions of the Chinese Society of Agricultural Engineering, 2019, 35(3): 156-163.
- 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.
- [13] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C] // Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2014, Columbus, Ohio, USA. New York: IEEE, 2014: 580-587.
- [14] Girshick R. Fast R-CNN [C] // Proceedings of the 2015 IEEE Conference on Computer Vision, December 11-18, 2015, Santiago, Chile. New York: IEEE, 2015: 1440-1448.
- [15] He K M, Zhang X Y, Ren S Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2015, 37(9): 1904-1916.
- [16] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [C] // Advances in Neural Information Processing Systems (NIPS 2015), December 7-12, 2015, Montreal, Quebec, Canada. Canada: NIPS, 2015: 91-99.
- [17] Wang J C, Tan X C, Wang Z H, et al. Faster R-CNN deep learning network based object recognition of remote sensing image [J]. Journal of Geo-Information Science, 2018, 20(10): 1500-1508.
- 王金传, 谭喜成, 王召海, 等. 基于 Faster R-CNN 深度网络的遥感影像目标识别方法研究[J]. 地球信息科学学报, 2018, 20(10): 1500-1508.
- [18] Cao Y J, Xu G M, Shi G C. Low altitude armored target detection based on rotation invariant Faster R-CNN[J]. Laser & Optoelectronics Progress, 2018, 55(10): 101501.
- 曹宇剑, 徐国明, 史国川. 基于旋转不变 Faster R-CNN 的低空装甲目标检测[J]. 激光与光电子学进展, 2018, 55(10): 101501.
- [19] Ma X Y, Zhu D, Jin C, et al. Bullet appearance defect detection based on improved faster region-convolutional neural network [J]. Laser & Optoelectronics Progress, 2019, 56(15): 151202.
- 马晓云, 朱丹, 金晨, 等. 基于改进 Faster R-CNN 的子弹外观缺陷检测[J]. 激光与光电子学进展, 2019, 56(15): 151202.
- [20] Chen E J, Tang X H, Fu B W. Pedestrian search method based on Faster R-CNN with the integration of pedestrian detection and re-identification [J]. Journal of Computer-Aided Design & Computer Graphics, 2019, 31(2): 332-339.
- 陈恩加, 唐向宏, 傅博文. Faster R-CNN 行人检测与再识别为一体的行人检索算法[J]. 计算机辅助设计与图形学学报, 2019, 31(2): 332-339.
- [21] Tian Q, Yuan T Y, Yang D, et al. A pedestrian detection method based on dark channel defogging and deep learning [J]. Laser & Optoelectronics Progress, 2018, 55(11): 111007.
- 田青, 袁瞳阳, 杨丹, 等. 基于暗通道去雾和深度学习的行人检测方法[J]. 激光与光电子学进展, 2018, 55(11): 111007.
- [22] Sun Z, Zhang C L, Ge L Z, et al. Image detection method for broccoli seedlings in field based on Faster R-CNN[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(7): 216-221.
- 孙哲, 张春龙, 葛鲁镇, 等. 基于 Faster R-CNN 的田间西兰花幼苗图像检测方法[J]. 农业机械学报, 2019, 50(7): 216-221.
- [23] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector[M] // Leibe B, Matas J, Sebe N, et al. Computer vision-ECCV 2016. Lecture notes in computer science. Cham: Springer, 2016, 9905: 21-37.
- [24] Feng X Y, Mei W, Hu D S. Aerial target detection based on improved Faster R-CNN[J]. Acta Optica Sinica, 2018, 38(6): 0615004.
- 冯小雨, 梅卫, 胡大帅. 基于改进 Faster R-CNN 的空中目标检测[J]. 光学学报, 2018, 38(6): 0615004.
- [25] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection [C] // The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, Hawaii, USA. New York: IEEE, 2017: 2117-2125.