

◆人工智能与无线网络◆

基于深度卷积神经网络技术的棉花顶芽探测技术*

张扬虎¹,白琳^{1,2**},陈峰练¹,张茜³,李淘深^{1,2}

(1.广西大学计算机与电子信息学院,广西南宁 530004; 2.广西高校并行与分布式计算技术重点实验室,广西南宁 530004; 3.广西医科大学第一附属医院,广西南宁 530021)

摘要:建立一种改进深度学习模型,用于农业自动化检测和识别棉花顶芽,以提高棉花劳作工作效率。通过把深度网络模型 ResNet-101 融入到基于深度学习(Deep Learning, DL)机制的感兴趣区域的目标检测算法 Faster RCNN 中,得到统一的多结构层次的改进深度学习模型。对比实验验证结果表明,相较于传统 Faster RCNN 模型,该模型在棉花顶芽探测和识别性能上有较大的提升。本研究提出的改进深度学习模型取得了比较好的平均精度,为棉花顶芽的探测和识别提出新的解决方案,为农业生产智能化提供新的思路。

关键词:深度学习 神经网络 目标检测 Faster RCNN 农业智能化 棉花顶芽探测

中图分类号:TP391 文献标识码:A 文章编号:1005-9164(2021)03-0257-08

DOI:10.13656/j.cnki.gxkx.20210830.011

0 引言

棉花生产关系到国家发展的点点滴滴,棉花不仅是人民穿着的重要材料来源,而且在疫情期间,口罩、防护服等医护用品的需求剧增,棉花的供给变得更为重要。棉花打顶作为棉花生产工作中的一个重要环节,整体机械化低下,导致棉花生产的人工成本居高不下。打顶一般在植物的枝条修剪定型期进行,及时打顶既能消除棉花顶芽的生长优势特性,还能调节棉花内部的养分配比,使棉铃获取更多的养分,增加铃重。另外打顶还有控制植株高度,改善生产基地的植

株光照情况,以达到增产增收的作用。目前,我国对棉花的机械打顶主要采用“一刀切”的方法,这种方式对棉株的棉铃、花蕾造成损伤,影响棉花的产量。因此,提高棉花打顶技术,实现棉花顶芽检测和识别的机械化、智能化,具有很强的现实意义。

目前,我国机械打顶常用的机器视觉技术主要有3种:基于BP神经网络的机器视觉技术^[1]、基于机器视觉技术的棉株识别定位算法^[2]、双目视觉技术^[3]。近年来,随着计算机硬件的升级换代及性能大幅提升,机器学习领域得到飞速发展,而机器学习对于改进农业生产具有重大的助力作用。深度学习(Deep

收稿日期:2020-12-15

*国家自然科学基金项目(61966003)和广西自然科学基金项目(2020GXNSFAA159171)资助。

【作者简介】

张扬虎(1998-),男,硕士研究生,主要从事机器视觉、目标检测、图像识别研究。

【**通信作者】

白琳(1985-),男,讲师,硕士生导师,主要从事人工智能、机器学习、生物信息学等研究,E-mail:bailin@gxu.edu.cn。

【引用本文】

张扬虎,白琳,陈峰练,等.基于深度卷积神经网络技术的棉花顶芽探测技术[J].广西科学,2021,28(3):257-264.

ZHANG Y H, BAI L, CHEN F L, et al. Detection of Cotton Top Buds Based on Deep Convolutional Neural Networks Technology [J]. Guangxi Sciences, 2021, 28(3): 257-264.

Learning, DL)是机器学习领域中一个新的研究方向^[4]。2014年, Huo等^[5]提出一种基于区域偏好和深度卷积运算的目标检测算法(Regions with CNN features, RCNN)。这一创新打破了目标检测技术的僵局,掀起深度学习机制下如何实施更优良的目标检测的新研究热潮。感兴趣区域对于目标提取的途径是解析图像中存在的各种信息,如图形纹理、物体边缘、特征大小等,同时标记尽可能少的窗口,来找到所有可能包含所需目标的区域。这不但要保证较高的召回率,还要尽可能地降低时间复杂度。目前基于深度学习的目标检测算法的研究主要分为两种方向:一种是通过感兴趣区域提取特征的算法,例如 RCNN、SPP-net^[6]、Fast RCNN、Mask RCNN^[7]和 R-FCN-3000^[8]等;另一种是基于回归计算的算法,例如 YOLO^[9]、YOLOv2^[10]、YOLOv3^[11]、YOLOv4^[12]和 SSD^[13]。

经过 RCNN 和 Fast RCNN^[14] 的积累, Girshick^[15] 在 2016 年提出新的算法模型 Faster RCNN, 在结构上, Faster RCNN 将特征提取、感兴趣区域提取、边框回归、分类集成到一个网络中, 通过构建一个 RPN 网络, 使得产生候选建议框的速度大幅提升。

本研究将农业生产实践与深度学习算法结合, 使用深度卷积神经网络技术, 通过在 Faster RCNN 模型中融入多种深度网络模型, 提出一种性能更好的改进深度学习模型。旨在将该模型用于农业自动化检测和识别棉花顶芽, 减少人工重复的复杂田间劳动, 提高棉花劳作工作效率, 对促进棉花科学种植, 棉花生产机械化自动化, 提高棉花产量, 提高棉农和相关企业收益, 保证国家棉纺织业原材料稳定来源, 维护国家稳定具有重要意义。

1 改进深度学习模型

1.1 模型架构概述

本研究提出的改进深度学习模型, 以最新的深度卷积神经网络算法为基础, 将深度网络模型 ResNet 融入到 Faster RCNN 网络模型中。改进深度学习模型在网络的高层涵盖多种网络模型的优点, 获得信息量更丰富, 得到对于棉花顶芽检测与识别更为有益的图像特征, 从理论上保证更优异的棉花顶芽的检测与识别结果。

1.1.1 Faster RCNN 模型概述

Faster RCNN 是目标检测算法模型中较早提出来的两阶段模型, 框架整体分为 4 个部分:

① Conv layers 提取特征图。作为一种 CNN 网络系列目标检测方法, Faster RCNN 首先使用一组基础的 conv + relu + pooling 层提取输入图像的图片特征, 用于后续的 RPN 层和全连接层。

② 区域提案网络 (Region Proposal Network, RPN)。RPN 网络主要用于生成候选区域 (Region proposals), 首先生成一堆锚框 (Anchor box), 对其进行裁剪过滤后通过 softmax 函数判断锚框属于前景 (Foreground) 或者后景 (Background), 即是物体或者不是物体, 所以这是一个二分类, 最后形成较精确的候选框 (Proposals)。

③ ROI 池化层。该层利用 RPN 生成的 proposals 和图片特征, 得到固定大小的候选框特征图, 可利用全连接操作来进行目标识别和定位。

④ Classifier。会将 ROI 池化层形成固定大小的特征图进行全连接操作, 利用 softmax 进行具体类别的分类, 同时获得物体的精确位置。

1.1.2 ResNet 模型概述

ResNet 于 2015 年提出, 特别深的神经网络是很难训练的, 因为存在梯度消失和梯度爆炸问题。传统对应的解决方案是数据的初始化 (Normlized initialization) 和正则化 (Batch normlization), 这两种方案虽然解决了梯度的问题, 但同时带来另外的问题, 就是网络性能的退化和错误率上升。而残差设计用来解决退化问题, 同时也解决了梯度问题。ResNet 是由残差块 (Residual block) 构建的, 如公式 (1) (2) 所示。式 (1) 是残差模块中的基本形式, 是恒等映射, F 是网络中的变化, 式 (2) 是对于叠加之后值的变换, 在原始残差模块中是 relu 函数, 网络通过学习 F 的参数来减小损失值。

$$y_l = h(x_l) + F(x_l, W_l), \quad (1)$$

$$x_{l+1} = f(y_l)。 \quad (2)$$

1.2 模型详细解析

改进深度学习模型的整体架构如图 1 所示, 模型基于深度网络架构进行关键区域选取、特征学习, 以及目标识别与分类的过程如 ① - ④ 所示:

① 获取图片特征。使用预训练好的 ResNet-101 网络提取图片特征, 通过网络的进一步处理得到下一

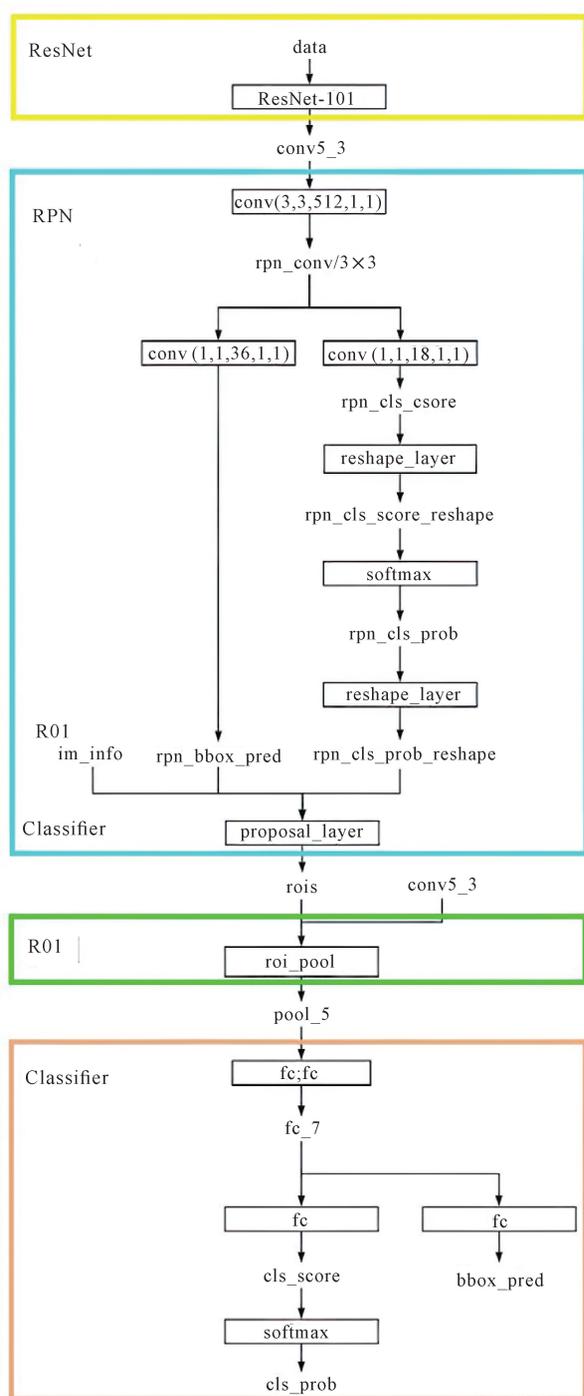


图1 改进深度学习模型框架

Fig.1 Architecture of the improved deep learning model 部分区域提案网络 (Region Proposal Network, RPN)需要的图片特征(conv5_3)。

②使用 ResNet-101 模型与 RPN 网络获取待检测棉花顶芽的候选框 Proposal,算法具体流程如算法 1-1 所示。

算法 1-1 候选框 Proposal 生成算法:

输入:图片特征 conv5_3

输出:候选框 proposals

Step 1:首先将图片特征 conv5_3 输入卷积层 conv(3,3,512,1,1),输出的图片特征 rpn_conv/3×3 尺寸和通道数均保持不变。

Step 2:将图片特征 rpn_conv/3×3 输入给卷积层 conv(1,1,36,1,1)得到 rpn_bbox_pred。

Step 3:将 rpn_conv/3×3 输入给 conv(1,1,18,1,1)得到类别得分 rpn_cls_score。

Step 4:将 rpn_cls_score 输入 reshape_layer, softmax, reshape_layer,得到概率 rpn_cls_prob_reshape。

Step 5:将 rpn_bbox_pred 和 rpn_cls_prob_reshape 以及 im_info 输入给 proposal_layer 得到候选识别区域 rois,即 RPN 网络最终输出的 proposals。

每一个卷积层都能使用经过训练的卷积核,从前面的池化层中学习更高级、不变性更强的特征信息,如下面公式所示:

$$y_j^c = \sum_i k_{ij} \times x_i + b_j, \quad (3)$$

式中, y_j^c 表示第 j 个卷积映射层, k_{ij} 是对应的卷积核,从前面的池化层 x_i 学习到本卷积映射层的数据特征, b_j 是第 j 个卷积映射层的运算偏移参数。每一个卷积层会使用多个卷积核,计算得到多个卷积映射层,从而能提取到广泛有效的各种数据特征。

③通过 ROI 池化层得到综合的 proposals 特征。将 rois 和 conv5_3 输入给 roi_pool 得到 pool_5,关于 roi_pool 的输入,尺寸大小是任意的,但输出的特征都是长度为固定的。

池化层将采用平均运算符,对前一个卷积映射层学习到的数据特征进行聚合收拢,把重要的特征保留加强,噪声和无用特征滤除。计算推理公式为

$$y_j^p = S(\beta \sum x_i^{n \times n} + \alpha), \quad (4)$$

式中, $x_i^{n \times n}$ 是前一个卷积映射层 $n \times n$ 的图像块, β 是可训练参数,表示池化的训练期望权重, α 是模型偏移参数, S 是激发函数。

④根据 proposals 特征进行框回归和物体分类,算法具体流程如算法 1-2 所示。

算法 1-2 类别预测框回归算法:

输入:proposals 特征 pool_5

输出:物体的边框 bbox_pred 和物体的类别 cls_prob

Step 1:将 pool_5 连续输入两个全连接层得到 fc_7。

Step 2: 将 fc_7 输入全连接层得到 bbox_pred, 得到最终的 proposals。

Step 3: 将 fc 输入全连接层得到物体类别得分 cls_score。

Step 4: 将 cls_score 经过 softmax 层得到 cls_prob, 即 proposal 属于各个物体的概率。

在 softmax 层中, 假定训练集如下:

$$\{(x^{(1)}, y^{(1)}), \dots, (x^{(m)}, y^{(m)})\}, \quad (5)$$

y 由 0 或 1 扩大到 $\{1, 2, 3, \dots, k\}$ 共有 k 类。

对于测试输入 x 则需要利用如下计算输入每个类别的 j 的条件概率值为

$$p(y^{(i)} = j | x^{(i)}; \theta) = \frac{e^{\theta_j^T x^{(i)}}}{\sum_{l=1}^k e^{\theta_l^T x^{(i)}}}. \quad (6)$$

假设函数如(7)式输出一个 k 维的向量, 那么每一维的向量分量则代表此类别 j 下的 p 值, 同时全部向量的元素条件概率之和等于 1, 而 θ 是模型训练更新的参数:

$$h_{\theta}(x^{(i)}) = \begin{bmatrix} p(y^{(i)} = 1 | x^{(i)}; \theta) \\ p(y^{(i)} = 2 | x^{(i)}; \theta) \\ \vdots \\ p(y^{(i)} = k | x^{(i)}; \theta) \end{bmatrix} = \frac{1}{\sum_{j=1}^k e^{\theta_j^T x^{(i)}}} \begin{bmatrix} e^{\theta_1^T x^{(i)}} \\ e^{\theta_2^T x^{(i)}} \\ \vdots \\ e^{\theta_k^T x^{(i)}} \end{bmatrix}. \quad (7)$$

Softmax 回归的代价函数在定义示性函数为 $1\{\cdot\}$ (大括号中表达式若真结果则为 1, 若假结果则为 0) 后, 为了防止参数冗余导致计算误差, 还会加入权重衰减策略:

$$J(\theta) = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{j=1}^k 1\{y^{(i)} = j\} \log \frac{e^{\theta_j^T x^{(i)}}}{\sum_{l=1}^k e^{\theta_l^T x^{(i)}}} \right] + \frac{\lambda}{2} \sum_{i=1}^m \sum_{j=0}^k \theta_{ij}^2. \quad (8)$$

而对于式(8)的最小化问题, 通常采用梯度下降求偏导进行迭代优化, 得到一个相对准确的值。那么梯度公式则可表示为

$$\nabla_{\theta_j} j(\theta) = -\frac{1}{m} \sum_{i=1}^m [x^{(i)} (1\{y^{(i)} = j\} -$$

$$p(y^{(i)} = j | x^{(i)}; \theta))] + \lambda \theta_j. \quad (9)$$

由于 RPN 和 Faster RCNN 两个网络独立运行, 所以本研究通过共享卷积特征的方法, 将两种深度学习方法融合构建出改进深度学习模型架构, 训练方式有以下两种:

①交替训练。首先进行网络参数初始化, 接着利用预处理模型训练 RPN 网络, 下一步再把 RPN 网络的输出输入到 Faster RCNN 目标检测网络中, 然后在训练中更新权重参数, 并对 RPN 网络进行更新迭代, 最后不断重复上述步骤, 得到一个训练好的改进网络模型。

②近似联合训练。将 RPN 网络和 Faster RCNN 目标检测网络合二为一, 正向传播时正常进行, 反向传播则合并两个网络在共享层的所有损失。这种方法忽视了感兴趣区域计算出坐标预测梯度值, 所以称作近似联合训练。

2 材料与方法

2.1 棉花顶芽图像数据

本研究所用到的棉花顶芽图片数据, 是由新疆棉花产地的生产员拍摄获取, 部分图片如图 2 所示。棉花顶芽位于棉花主茎的顶端, 周围常生长繁茂的主茎叶, 如图 2 红框所示。顶芽的生长占据优势, 同时抑制邻近侧芽的生长, 使侧芽处于休眠状态, 这种现象也叫做顶端优势。摘除顶芽, 便可消除顶端优势, 以促使侧芽萌发、增加侧枝数目, 达到增产和控制花木株型的目的。

2.2 棉花顶芽探测难点分析

棉花是成行种植的, 但是随着植株的生长, 相邻植株的茎叶会争抢生长空间, 同时由于相邻植株生长态势的差异性, 会造成相邻植株的茎叶高低错落地遮挡、掩盖, 另外还存在着一些杂草和植株缠绕生长。这些因素造成图像空间背景的复杂性, 因此棉花杂质探测模型要有很高的准确率。

本研究获取的 2 000 张棉花开花的图片, 需要进行前期数据预处理, 清除不良模糊的图片; 接着对图片数量进行数据增强增加训练样本, 同时按照 PASCAL VOC2007 所要求的数据集命名存放格式进行整理。数据集训练样本标注通过标签(Labelimg)制作完成, 具体过程如下:



图2 棉花顶芽

Fig.2 Cotton top buds

①进行完数据预处理后对剩余图片进行数据增强,翻转复制。

②对4 000余张图片按照PASCAL VOC2007所要求的命名格式进行批量命名,以便后期对棉花顶芽数据集进行训练。

③利用Labelimg图片标注工具对每张棉花顶芽图片进行目标框标注,同时剔除不良图片,并将标注的棉花顶芽的位置信息以xml数据格式保存

④根据标注生成的xml文件,利用Python语言随机生成棉花顶芽图片数据集的4个测试训练txt后缀文件:test.txt是测试集,train.txt是训练集,val.txt是验证集,trainval.txt是训练和验证集。

⑤将整理好的棉花顶芽数据集图片生成xml文件,同时将txt文件按照PASCAL VOC2007提供文件存放位置,分别放入JPEGImages文件夹、Annotations文件夹和ImagesSets的Main子文件夹中。

2.3 对比实验设计

本研究设计了3组Faster RCNN模型和改进深度学习模型的对比实验。

实验一:在相同迭代次数下,对棉花顶芽数据集的训练时间长短进行对比;

实验二:在相同迭代次数下,对棉花顶芽数据集的平均精度(Average Precision,AP)进行对比;

实验三:在相同数量、相同内容图片的测试中,对单张图片的平均探测识别时间的长短以及检测的具

体验证效果进行对比。

为更系统地评估本研究提出的模型,本实验将使用平均精度进行对比分析。计算公式如式(10)。

$$AP = \int_0^1 \text{Precision}(\text{Recall}) d\text{Recall}, \quad (10)$$

$$\text{其中, Precision} = \frac{TP}{TP + FP}, \quad (11)$$

$$\text{Recall} = \frac{TP}{TP + FN}, \quad (12)$$

式中TP(True Positives)表示真正例,指被标注的棉花顶芽被正确的检测出来;TN(True Negatives)表示真负例,指为正确地识别出的非棉花顶芽候选框;FP(False Positives)表示假正例,指被标注的棉花顶芽未被正确的检测出来;FN(False Negatives)表示假负例,是没有被检测识别出来的非棉花顶芽。

3 结果与分析

3.1 实验一结果与分析

分别在Faster RCNN模型上和改进深度学习模型上进行40 000次迭代,对棉花顶芽数据集的训练时间长短检测结果如图3中蓝色柱所示。虽然改进深度学习模型中的ResNet-101的网络层次是Faster RCNN模型中VGG-16网络深度的6倍左右,但是两种模型的训练花费时间分别是10 h和19 h,这是因为ResNet-101网络引入了跳跃连接,这可以使下一个残差块的信息没有阻碍地流入到下一个残差块,

提高了信息流通。

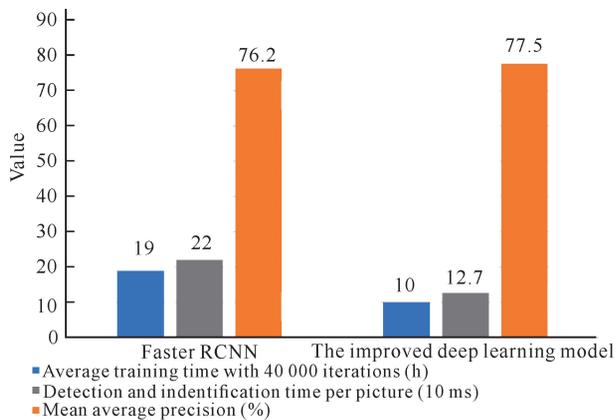


图3 Faster RCNN模型和改进深度学习模型的实验结果对比

Fig. 3 Comparison of experimental results between Faster RCNN and the improved deep learning model

3.2 实验二结果与分析

图4展示两种模型对比的精确度-召回率曲线, 两条曲线直观地展示出两个模型在精确度和召回率统计分析指标上的表现, 具体数值对比如图3中橙色柱所示, 改进深度学习模型和Faster RCNN模型的精确率分别是77.5%和76.2%。从图4可知Faster RCNN模型的精确率很高, 随着召回率的增大, 下滑速率逐渐加快; 而改进深度学习模型, 初始精确度一般, 但是下滑速率却比Faster RCNN模型要小。图4中存在改进深度学习模型曲线随着召回率的增大, 下滑速率逐渐加快的现象, 原因是在数据集预处理阶段没有考虑到其他近似分类项的标记处理, 只进行了单分类标记。改进深度学习模型提高了棉花顶芽数据集的AP值, 保证模型可以达到最优检测和识别性能, 实际生产中, 有利于减少棉花顶芽探测的遗漏, 提

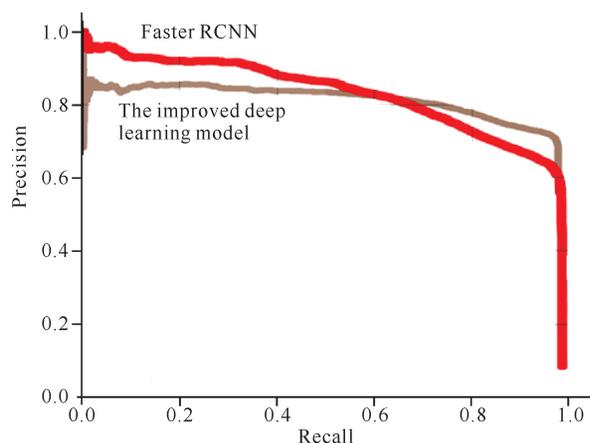


图4 Faster RCNN模型和改进深度学习模型的AP对比

Fig. 4 Comparison of AP between Faster RCNN and the improved deep learning model

高生产效益。

3.3 实验三结果与分析

在提供相同数量、相同内容图片的测试中, 两种模型对于图片的平均探测识别时间的长短对比实验效果如图3中柱状图灰色柱所示。从图3中可以直观地看到改进模型探测时间是127 ms, 而Faster RCNN模型的时间高达220 ms, Faster RCNN模型对于单张图片平均花费的探测识别时间远比改进深度学习模型要长。原因是ResNet网络的跳跃连接提高了信息流通, 这与实验一的结果分析相同。随机选取原始标定框图5, 两种模型对图5的探测具体识别效果如图6和图7所示, 可以发现改进深度学习模型能做到很好的高精度识别, 同时还对原始标定框以外的疑似目标进行框定。实际生产中, 有利于保证棉花顶芽探测的全面性, 提升经济效益。Faster RCNN模型识别精度也挺高, 但还是存在一定的低精度识别。改进深度学习模型通过牺牲大量训练时间和增加识别时间达到更高精度的识别效果。相比于Faster RCNN模型而言, 如果在处理好数据集样本进行更多分类样本标定的情况下, 改进深度学习模型的检测识别效果可以大幅度提高。

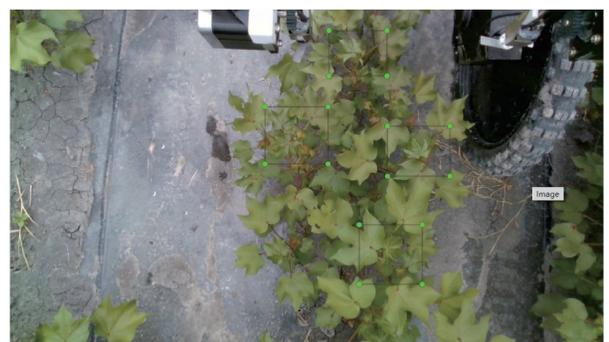


图5 原始标定框图

Fig. 5 Original demarcated chart



图6 Faster RCNN模型检测图

Fig. 6 Faster RCNN model detection chart

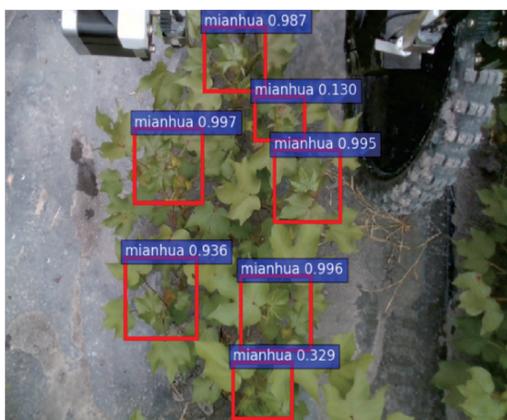


图7 改进深度学习模型检测图

Fig.7 Detection chart of the improved deep learning model

4 结论

本研究借助深度卷积神经网络技术,在分析目标检测国内外相关研究工作的基础上,提出改进深度学习模型,实现对棉花顶芽的精准检测和识别。本研究通过对改进深度学习模型和 Faster RCNN 模型两种网络模型的对比分析实验,验证了本研究的改进深度学习模型基于 Faster RCNN 模型融入 ResNet-101 网络模型改进之后,对整体数据的识别准确率得到明显提高。这是本研究用深度学习和目标检测技术为棉花顶芽检测和识别提供的一个新思路,是推动农业智能化的一次尝试。

参考文献

- [1] 刘俊奇. 棉花株顶识别系统的研究[D]. 石河子:石河子大学,2009:1-4.
- [2] 瞿端阳. 基于机器视觉技术的棉株识别系统研究[D]. 石河子:石河子大学,2013:1-6.
- [3] 魏纯,李明,龙嘉川. 采摘机器人果实识别与定位研究——基于双目视觉和机器学习[J]. 农机化研究,2021,43(11):239-242.
- [4] 员娇娇,胡永利,孙艳丰,等. 基于深度学习的小目标检测方法综述[J]. 北京工业大学学报,2021,47(3):293-302.
- [5] HUO L, BAI L, ZHOU S M. Automatically generating natural language descriptions of images by a deep hier-

archical framework [J]. IEEE Transactions on Cybernetics,2021(99):1-12.

- [6] 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,2014,37(9):1904-1916.
- [7] KAIMING H, GEORGIA G, PIOTR D, et al. Mask R-CNN [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence,2020,42(2):386-397.
- [8] SINGH B, LI H, SHARMA A, et al. R-FCN-3000 at 30fps: Decoupling detection and classification [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2018(6):18-23. DOI:10.1109/CVPR.2018.00119.
- [9] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR),2016,1:779-788.
- [10] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA; IEEE,2017.
- [11] REDMON J, FARHADI A. YOLOv3: An incremental improvement [J]. ArXiv preprint arXiv:1804.02767, 2018.
- [12] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection [J]. ArXiv Preprint ArXiv:2004.10934,2020.
- [13] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]//European Conference on Computer Vision,2016:21-37.
- [14] REN S Q, HE K M, 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.
- [15] REN S Q, HE K M, GIRSHICK R B, 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.

Detection of Cotton Top Buds Based on Deep Convolutional Neural Networks Technology

ZHANG Yanghu¹, BAI Lin^{1,2}, CHEN Fenglian¹, ZHANG Qian³, LI Taoshen^{1,2}

(1. School of Computer, Electronics and Information, Guangxi University, Nanning, Guangxi, 530004, China; 2. Guangxi Colleges and Universities Key Laboratory of Parallel and Distributed Computing Technology, Nanning, Guangxi, 530004, China; 3. The First Affiliated Hospital of Guangxi Medical University, Nanning, Guangxi, 530021, China)

Abstract: An improved deep learning model was established to detect and identify cotton top buds in agricultural automation, so as to improve the work efficiency of cotton. By integrating the deep network model ResNet-101 into the target detection algorithm Faster RCNN based on the deep learning mechanism, a unified multi-structured and improved deep learning model is obtained. The results of comparative experiments show that compared with the traditional Faster RCNN model, this model has greatly improved the detection and recognition performance of cotton top bud. The improved deep learning model proposed in this study has achieved good average accuracy, which provides a new solution for the detection and identification of cotton top buds and a new idea for the intelligent agricultural production.

Key words: deep learning, neural networks, object detection, Faster RCNN, intelligent agriculture, detection of cotton top buds

责任编辑: 陆 雁



微信公众号投稿更便捷

联系电话: 0771-2503923

邮箱: gxkx@gxas.cn

投稿系统网址: <http://gxkx.ijournal.cn/gxkx/ch>