

基于 RGB-D 相机的黄瓜苗 3D 表型高通量测量系统研究

徐胜勇^{1,2} 李磊¹ 童辉³ 王成超¹ 别之龙⁴ 黄远^{3,4}

(1. 华中农业大学工学院, 武汉 430070; 2. 华中农业大学深圳营养与健康研究院, 深圳 518000;

3. 中国农业科学院深圳农业基因组研究所, 深圳 518000; 4. 华中农业大学园艺林学学院, 武汉 430070)

摘要: 传统的人工种苗表型测量方式存在效率低、主观性强、误差大、破坏种苗等问题,提出了一种使用 RGB-D 相机的黄瓜苗表型无损测量方法。研制了自动化多视角图像采集平台,布署两台 Azure Kinect 相机同时拍摄俯视和侧视两个视角的彩色、深度、红外和 RGB-D 对齐图像。使用 Mask R-CNN 网络分割近红外图像中的叶片和茎秆,再与对齐图进行掩膜,消除了对齐图中的背景噪声与重影并得到叶片和茎秆器官的对齐图像。网络实例分割结果的类别和数量即为子叶和真叶的数量。使用 CycleGAN 网络处理单个叶片的对齐图,对缺失部分进行修补并转换为 3D 点云,再对点云进行滤波实现保边去噪,最后对点云进行三角化测量叶面积。在 Mask R-CNN 分割得到的茎秆对齐图像中,利用茎秆的近似矩形特征,分别计算茎秆的长和宽,再结合深度信息转换为下胚轴长和茎粗。使用 YOLO v5s 检测对齐图中的黄瓜苗生长点,利用生长点与基质的高度差计算株高。实验结果表明,该系统具有很好的通量和精度,对子叶时期、1 叶 1 心时期和 2 叶 1 心时期的黄瓜苗关键表型测量平均绝对误差均不高于 8.59%、 R^2 不低于 0.83,可以很好地替代人工测量方式,为品种选育、栽培管理、生长建模等研究提供关键基础数据。

关键词: 黄瓜苗; 表型; RGB-D 相机; 深度学习

中图分类号: S24; TP391. 4 文献标识码: A 文章编号: 1000-1298(2023)07-0204-10

OSID:



High-throughput Measurement System for 3D Phenotype of Cucumber Seedlings Using RGB-D Camera

XU Shengyong^{1,2} LI Lei¹ TONG Hui³ WANG Chengchao¹ BIE Zhilong⁴ HUANG Yuan^{3,4}

(1. College of Engineering, Huazhong Agricultural University, Wuhan 430070, China

2. Shenzhen Institute of Nutrition and Health, Huazhong Agricultural University, Shenzhen 518000, China

3. Agricultural Genomics Institute at Shenzhen, Chinese Academy of Agricultural Sciences, Shenzhen 518000, China

4. College of Horticulture and Forestry Sciences, Huazhong Agricultural University, Wuhan 430070, China)

Abstract: The traditional method of artificial seedling phenotype measurement has some problems, such as low efficiency, strong subjectivity, large error and damaged seedlings. A method for nondestructive detection of cucumber seedling phenotype by using the RGB-D camera was proposed. An automated multi-view image acquisition platform was developed, and two Azure Kinect cameras were deployed to simultaneously capture color, depth, NIR, and RGB-D images from the top view and side view. The Mask R-CNN network was used to segment the leaves and stems in the NIR image, and then mask them with the RGB-D image to eliminate the background noise and ghost in the RGB-D images and obtain the RGB-D image of the leaves and stems. The category and number of segmentation results of the Mask R-CNN network were the numbers of cotyledons and true leaves. The CycleGAN network was used to process the RGB-D image of a single leaf, repair the missing and convert it into 3D point clouds, and then filter the point clouds to achieve edge-preserving denoising. Finally, the point clouds were triangulated to measure the leaf area. In the stem RGB-D image obtained by Mask R-CNN segmentation, the approximate rectangular feature of the stem was used to calculate the length and width of the stem respectively, and then the depth information was combined to convert the hypocotyl length and

收稿日期: 2022-10-27 修回日期: 2022-12-02

基金项目: 国家重点研发计划项目(2019YFD1001900)、HZAU-AGIS 交叉基金项目(SZYJY2022006)、湖北省重点研发计划项目(2021BBA239)和中央高校基本科研业务费专项资金项目(2662022YLYJ010)

作者简介: 徐胜勇(1980—),男,副教授,博士,主要从事智能农业装备研究,E-mail: xsy@mail.hzau.edu.cn

通信作者: 黄远(1982—),男,副教授,博士,主要从事工厂化育苗研究,E-mail: huangyuan@mail.hzau.edu.cn

stem diameter. YOLOv5s was used to detect the growing point of cucumber seedlings in the RGB-D image, and the height difference between the growing point and the substrate was used to calculate the plant height. The experimental results showed that the system had good flux and accuracy. The mean absolute errors of key phenotypes of cucumber seedlings at cotyledon, 1 true-leaf and 2 true-leaf stages were all no more than 8.59% and R^2 was no less than 0.83, which can well replace the manual measurement method, and provide key basic data for seed selection and breeding, cultivation management, growth modeling, and other research.

Key words: cucumber seedlings; phenotype; RGB-D camera; deep learning

0 引言

种苗培育是蔬菜生产的重要环节。种苗表型测量是品种选育、栽培管理、生长建模等研究中必需的重要环节。植物叶片大小是监测植物生长及预测植物生长的重要参数^[1-2],而叶面积是衡量叶片大小的重要特征,叶面积对农作物产量构成具有重要作用,是作物栽培和育种实践中常用的指标,对植物的生长发育有着显著影响。真叶数量是判断种苗生长阶段的重要依据,真叶也是植物后期进行光合作用和蒸腾作用的主要器官。下胚轴长、茎粗和株高等茎秆表型参数可以反映种苗的生长状况,是壮苗评价的重要表型参数。当前种苗表型检测方法依赖于传统的人工测量,存在效率低、主观性强、误差大、破坏种苗等问题,限制了数字化育苗的发展^[3]。传统依赖于人工的数据采集方式正面临转型升级。计算机视觉和人工智能等先进技术的应用使得无损测量作物表型成为可能。Kinect 传感器是一种经典的 RGB-D 相机,能够同时获取目标的彩色、红外和深度信息,具有成本低廉、体积小巧的特性和优势,使得该传感器在现代农业信息领域获得了推广和应用。

RGB-D 相机在点云精度、处理速度和可自动化 3 方面表现较为均衡,广泛应用于表型测量^[4]。RGB-D 相机是在 RGB 摄像头的基础上增加了深度测量,主流深度测量方案包括结构光、飞行时间(TOF)和双目视觉等 3 种。①结构光:它的基本原理是通过近红外激光器主动发射一定结构光到被测物体,再由红外相机捕捉被测物体表面的结构光图案,再结合三角测量原理计算被测物体的位置和深度信息。这类深度相机主要包括 Kinect V1、RealSense SR300/D415/D435、DKam 130 和 Asus Xtion Pro。文献[5]基于 RealSense SR300 型深度相机采集褐蘑菇床图像进行原位测量,计算出单体蘑菇的位置、直径、偏向角、倾斜角。文献[6]研究了通过使用 RealSense D415 型相机,基于深度学习的融合二维彩色图像和深度图像的生菜表型参数(湿质量、干质量、株高、直径、叶面积)高精度估算算

法。文献[7]基于 RealSense D435 型相机建立了棉花生长点三维空间坐标的计算模型,有助于实现棉花生长点的检测和定位。②飞行时间(TOF):它的基本原理是根据发射的红外光脉冲被物体反射返回传感器之间的时间差来测量每个像素的距离。基于飞行时间测距的 RGB-D 相机主要包括 Azure Kinect、Kinect V2、PMD 深度相机,文献[8]利用 Azure Kinect 对南瓜砧木根系表型进行无损测量。文献[9]研究了利用 Kinect V2 深度相机基于几何模型测量出绿萝叶片外部表型参数,包括叶长、叶宽和叶面积。文献[10]基于 Kinect V2 相机,通过测量穴盘苗发芽率、株高、叶面积、壮苗指数实现了穴盘苗生长过程的无损监测。③双目视觉:它的基本原理是模拟人眼对周围环境距离的感知,从两部相机拍摄同一景物获得左右两幅视图,进行立体匹配,计算出图像对应点间的位置偏差,从而获取物体的三维信息的方法。基于双目视觉测距的 RGB-D 相机主要包括 ZED、小觅智能 S1030-IR-120 和 Bumblebee2 相机。文献[11]提出了一种双目相机结合改进 YOLO v3 目标检测算法的行人障碍物检测和定位方法。文献[12]将小觅智能 S1030-IR-120 型标准版双目相机部署在拖拉机前方并结合喷雾机前进速度计算冠层体积。文献[13]通过双目立体视觉拍摄不同视角的拟南芥图像,将二维图像信息重建为三维模型,实现了对作物叶片长度、宽度和茎秆长度的测量,测量误差均在 5% 以内。

综上所述,基于结构光的深度相机,易受强光干扰且不适合远距离深度信息采集;基于飞行时间的深度相机的分辨率较低,但其运算速度快能够实时测量且功耗较低;基于双目立体视觉的深度相机重建速度快、结构最简单,但其高精度点云需要高性能的图像和稳定的成像环境^[14]。而以 Kinect 为代表的深度相机(RGB-D)在提供深度信息的同时可以生成深度图像,在机器视觉测量领域得到了广泛应用。目前,对于种苗表型的无损检测技术研究相对较少,已经成为限制种苗相关研究的瓶颈。本文以 Azure Kinect 深度相机为采集设备,以子叶期到 2 叶 1 心期共 3 个生长时期的黄瓜苗为实验对象,开发

一系列种苗表型无损测量算法,并研制自动化图像采集平台。

1 材料与方 法

1.1 实验材料与数据采 集

实验样本为黄瓜,品种为津春 4 号。样本于 2021 年 12 月到 2022 年 1 月在华中农业大学园艺林 学学院人工气候室培育。温汤浸种,处理后放置在 28℃ 恒温箱中催芽,待 90% 种子露白后播种到 50 孔的穴盘,播种前向基质中添加雅苒苗乐复合肥料 (1.0 kg/m³),基质中草炭、蛭石、珍珠岩体积比为 3:1:1。播种完成后将穴盘放置于温室苗床上,昼/夜 温度为 28℃/18℃,相对湿度为 65%~85%。在 1 叶 1 心期后喷施 1 000 倍液莱瑞育苗专用肥 1 号,培 育至 2 叶 1 心期结束。共培育 10 盘黄瓜苗。其中 6 盘黄瓜苗用于算法设计,另 4 盘黄瓜苗共 197 株用 于验证算法,其中对子叶展平时期、1 叶 1 心时期和 2 叶 1 心时期共 150 株黄瓜苗采取破坏性实验进行 表型算法验证。

如图 1 所示,通过使用自动化图像采集平台采 集黄瓜苗图像。为了确保获取到高质量的黄瓜苗的 彩色图和深度图像,一台 Azure Kinect 相机被安装 在距黄瓜苗正上方 25~30 cm,用于获取黄瓜苗的 俯视图像序列;另一台被安装在距黄瓜苗正前方 25~30 cm,用于获取黄瓜苗的侧视图像序列。自动 化采集平台通过机械手夹取分体式苗钵,移动穴盘 苗到旋转平台,对黄瓜苗进行俯视视角和侧视视角 的图像采集。图像采集完成后,机械手夹取苗钵移 动到空穴盘对应位置。本文在 SolidWorks、 LabVIEW、OpenCV 基础上开发了图像处理算法与控 制电路。通过基于 LabVIEW 软件开发的黄瓜苗表 型测量软件调用图像采集与处理算法程序,控制两 台相机拍摄黄瓜苗,得到 4 096 像素×3 072 像素的 彩色图、1 024 像素×1 024 像素的深度图、1 024 像 素×1 024 像素的近红外图和 1 024 像素×1 024 像 素的 RGB-D 对齐图。使用相机提供的 SDK 函数, 将 RGB-D 对齐图和深度图转换为 3D 点云^[4]。

对采集图像后的黄瓜苗,人工使用直尺测量生 长点到基质平面的距离作为株高,测量子叶节点到 基质表面的距离作为下胚轴长(精度 1 mm);采用数 显游标卡尺 3 次测量茎秆取平均值得到茎粗(精度 为 0.01 mm);使用 Epson Expression 12000XL 型扫 描仪(爱普生公司,分辨率 0.01 mm²)扫描人工采摘 并铺平的叶片,得到叶面积数据。

1.2 深度学习使用的训练数据集制作

利用自动化图像采集平台,共拍摄了 281 幅原




图 1 自动化图像采集平台设计图和实物图

Fig. 1 Automatic acquisition platform

1. 电控箱 2. 机械臂 3. RGB-D 相机 4. 机械抓手 5. 旋转 平台 6. 分体式苗钵 7. 导轨 8. 控制界面

始图像数据集。为了提高网络模型的精度和泛化性 能,将训练集通过数据增强的方式进行扩充。分别 通过图像旋转(45°、90°)、亮度调整(0.8 倍和 1.3 倍)、对比度增强至 0.8,数据集扩充到原来的 5 倍, 其中训练集 975 幅,测试集 430 幅。人工使用数据 标注软件对黄瓜苗的近红外图像进行标注,以生成 深度学习需要的训练数据集。使用 LabelMe 软件对 黄瓜苗近红外图像中的叶片和茎秆轮廓进行标注, 只标注未遮挡部分的轮廓,对于一幅图中的同一类 标签用不同的顺序进行标注,标注信息将会保存到 与原图像对应的 json 文件中;使用 LabelImg 软件对 冠层 RGB-D 图像中的生长点用矩形框进行标注, 标注信息将会保存到与原图像对应的 xml 文件中。 共制作了 1 405 幅近红外图、RGB-D 对齐图用于网 络训练。训练数据集的制作如图 2 所示。




图 2 训练数据集制作

Fig. 2 Training datasets production

2 黄瓜苗 3D 表型无损测量方法

本文技术流程图如图 3 所示。使用自动化图像 采集平台拍摄俯视视角和侧视视角下的黄瓜苗。俯 视视角图像用于叶片数、叶面积、株高、生长点等表 型参数测量;侧视视角图像序列用于下胚轴长、茎粗 表型参数测量。为验证无损测量的准确程度,对无 损测量结果与人工测量结果进行了比较分析。

2.1 基于 Mask R-CNN 的黄瓜苗图像分割算法

Mask R-CNN 是在 Faster R-CNN 目标检测模




图 3 黄瓜苗 3D 表型无损测量技术流程图

Fig. 3 Flowchart of research

型的基础上增加了 Mask 分支,并用 ROI Align 改进原有的 ROI Pooling 模块,解决了 Faster R - CNN 区域匹配存在误差的问题^[15]。Mask R - CNN 网络的处理流程如图 4 所示,Mask R - CNN 网络模型由主干网络、区域生成网络、感兴趣区域对齐层和 R - CNN 共 4 个模块构成^[16]。主干网络由残差网络和特征金字塔网络构成,对输入图像进行特征提取并生成多尺度特征图,区域生成网络的作用是生成目标候选区域,完成特征图中前后景目标分类和边界框的回归,并获取前景目标的粗略位置;感兴趣区域对齐层是进一步对特征图进行像素校正,然后分别输入全连接层与全卷积网络层;全连接层输出含叶片边缘边界框位置和分类得分,全卷积网络层输出叶片区域掩膜。最后,R - CNN 模块综合各分支输出信息,得到一幅包含黄瓜苗器官类别、器官定位边界框和器官分割掩膜的图像。Mask R - CNN 深度

学习网络模型是在 Tensorflow - Gpu 1.13.2, Keras 2.1.5 深度学习框架下展开,基于 Windows 10 64 位操作系统,处理器为 Inter Xeon E5 - 2650,显卡为 Nvidia Quadro p4000,训练每次迭代批处理量为 1。

在使用 Azure Kinect 相机时,由于深度摄像头和彩色摄像头相机间的视差导致使用开源函数 Depth_Image_to_Color_Camera 进行 RGB - D 对齐造成明显的颜色映射错误,产生重影。为了解决此问题,本文提出一种改进的 RGB - D 对齐方法,如图 5 所示。先对近红外图像使用实例分割网络 Mask R - CNN 生成预测结果,再对预测结果进行二值化,二值化结果与相机对齐结果进行掩膜,该方法可以得到高质量的对齐结果与器官图像分割结果。

2.2 基于 YOLO v5s 网络的黄瓜苗生长点检测算法

YOLO v5 网络模型共有 YOLO v5s、YOLO v5m、YOLO v5l 和 YOLO v5x 等 4 个版本,其主要区别是




图 4 Mask R - CNN 网络分割叶片和茎秆示意图

Fig. 4 Leaf and stem segmentation by Mask R - CNN network




图 5 改进冠层、侧视角 RGB-D 对齐方法流程图

Fig. 5 Flowchart of improved canopy and side view RGB-D alignment method

网络特征提取模块的宽度和深度不同^[17]。自动化图像采集平台获取的黄瓜苗图像背景相对简单,生长点与周围环境相比特征明显,故选用 YOLO v5 系列中深度最小、速度最快的 YOLO v5s 网络进行黄瓜苗生长点的检测。图 6 为 YOLO v5s 的网络结构示意图。YOLO v5s 在结构上分为 4 部分,分别为:①输入端:将输入图像进行预处理,调整到与网络输入的大小保持一致,进行归一化等操作,通过使用 Mosaic 数据增强提高目标检测的准确性和训练速度。②Backbone:对图像进行卷积和切片操作,用于提取输入图像的特征。③Neck 网络:采用 FPN+PAN 结构进一步提高对图像的检测精度。④预测:采用非极大抑制的方法,消除干扰框,用于对目标位置进行预测。YOLO v5s 网络模型是在 Tensorflow-Gpu 1.13.2, Keras 2.1.5 深度学习框架下展开,基于 Windows 10 64 位操作系统,处理器为 Inter Xeon E5-2650,显卡为 Nvidia Quadro p4000,训练每次迭代批处理量为 1。

2.3 邻域最值滤波改进算法

点云中存在背景、离群和悬浮点这 3 种类型的噪声。对点云进行滤波是提高点云质量和测量准确性的重要环节。背景噪声在上述的改进 RGB-D 对齐方法中已被消除。离群噪声使用统计滤波^[18]去除。悬浮点噪声使用邻域最值滤波方法。然而该方

法在有效去除悬浮点的同时也将部分目标点云错误剔除了,这不仅降低了点云质量还影响了测量的结果。因此,本文提出了一种深度图插值法,对邻域最值滤波^[4]的结果进行进一步处理,以恢复剔除的目标点云。主要算法流程包括:

- (1)首先,利用训练好的 Mask R-CNN 模型对黄瓜苗叶片进行分割。
- (2)然后,通过遍历步骤(1)叶片分割后对应的深度图,检索非 0 像素点的位置坐标 (x_i, y_i) 。
- (3)针对深度图中坐标为 (x_i, y_i) 的像素点,计算其像素距离小于等于 N 的邻域范围内某像素点的深度信息,并计算邻域范围内的最值 Z_m 。
- (4)计算并与给定的阈值 D 比较,若任意一个大于 D 即判断为悬浮点,令像素点的像素值为 0,去除该悬浮点。
- (5)重复上述步骤,遍历整幅深度图。
- (6)在步骤(5)结束后,同时遍历二值图和深度图,检索二值图中像素值为 255、深度图中像素值为 0 的像素点,搜索其像素距离小于等于 M 的邻域范围,将距离该像素点最近的像素点的深度信息进行填充。

通过多次实验发现, N 为 3、 D 为 5、 M 为 5 时对黄瓜苗悬浮点的剔除效果最好,能够实现保边去噪的效果。图 7 展示了改进邻域最值滤波算法的效




图 6 YOLO v5s 网络预测流程图

Fig. 6 YOLO v5s network prediction flowchart

果,可以明显看出叶片和茎秆点云在边缘处的质量得到大幅度的提升。




图 7 改进的邻域最值滤波算法效果

Fig. 7 Effect of improved neighborhood extreme filtering algorithm

2.4 黄瓜苗表型计算方法

2.4.1 叶片表型无损测量

Mask R-CNN 网络属于实例分割网络,它不仅能够分辨图像中每个实例所包含的像素,也能统计每个类别的数量。本文利用 Mask R-CNN 网络预测的结果可同时获取子叶和真叶的叶片数量与分割结果。利用 Mask R-CNN 生成的预测二值图与原图相乘,获得仅包含叶片的图像。再采用本文提出的邻域最值滤波改进算法,获得单片叶片的三维点云。由于本文采用单视角测量黄瓜苗冠层表型,在拍摄时可能会存在叶片的遮挡,叶片遮挡处理有基于点云修复^[19]和二维彩色信息修复。本文使用文献^[20]提出的一种针对无监督图像翻译的循环生成对抗网络 CycleGAN 对叶片的二维图像进行修复。因为同种苗的同种类的叶片形状具有高度的相似性,可以使用 CycleGAN 网络对遮挡叶片进行修复,具体测量流程包括:

(1) Mask R-CNN 分割种苗 RGB-D 图像得到二值图,遍历二值图中像素值为 255 的像素点,计算其平均深度。

(2) 使用 CycleGAN 网络修复叶片 RGB-D 图像。

(3) 将修复结果的二值图与原分割结果的二值图相减,得到叶片被修复的部分。

(4) 将步骤(1)得到的平均深度赋值给步骤(3)的修复部分对应的深度图。

(5) 经过以上步骤得到修复后的 RGB-D 叶片图像和深度图像,叶片的遮挡部分被修复,转换为叶片点云。

将得到的叶片点云进行下采样、点云滤波处理,

再使用最小二乘法平滑点云数据,最后采用贪婪投影三角化对叶片点云进行三角面片化^[21]。经三角面片化后的叶片由若干个三角面片组成,再利用海伦公式,计算叶片包含的所有三角面片,累加求和后得到叶片面积 A ,公式为

$$A = \sum_{i=1}^n A_i \quad (1)$$

其中 $A_i = \sqrt{p_i(p_i - a)(p_i - b)(p_i - c)}$ (2)

$$p_i = \frac{a + b + c}{2} \quad (3)$$

式中 A ——叶片面积, mm^2

A_i ——第 i 个三角形面积, mm^2

$a、b、c$ ——三角形边长, mm

p_i ——第 i 个三角形周长的一半, mm

n ——三角形个数

2.4.2 株高无损测量

株高是幼苗品质判别的关键因子,株高定义为植株基部至主茎顶部即生长点的距离^[10]。单株黄瓜苗株高测量示意图如图 8 所示。利用训练好的 YOLO v5s 网络模型识别黄瓜苗的生长点,然后将生长点像素坐标映射到相应深度图中,可以测量出生长点距离相机平面的深度信息 H_2 。为减小因深度相机成像误差对测量精度造成的影响,本文在拍摄前,使用深度相机测量拍摄平面到相机平面的距离 H_1 ,使用直尺测量苗钵高度 H_3 。株高测量示意图如图 8 所示,黄瓜种苗株高计算公式为

$$H = \frac{H_1 - H_2 - H_3}{\cos\beta} \quad (4)$$

式中 H ——株高, mm

β ——最小外接矩形的倾斜角, $(^\circ)$




图 8 茎秆表型测量示意图

Fig. 8 Schematics of stem phenotype measurement

2.4.3 茎粗无损测量

茎秆与种苗的生长状况密切相关^[22]。黄瓜种苗茎秆较细且在整个生长期粗细不均匀和 Azure Kinect 相机精度影响,茎粗无损测量的准确率一直难以得到较高提升^[23]。本文为提高黄瓜苗茎粗测量的准确性,首先在测量时选择固定的茎粗测量位置作为测量结果。本文茎粗测量方法是先利用 Mask R-CNN 对茎秆的分割图使用 minAreaRect 函

数找到茎秆的最小外接矩形,并得到最小外接矩形的参数,包括倾斜角 β 。之后将茎秆部分4等分并计算等分线 y_1 、 y_2 和 y_3 的 y 轴坐标,通过测量坐标 $((x_i, y_1), (x_{i+1}, y_1), \cdots, (x_{i+n_1}, y_1)); ((x_j, y_2), (x_{j+1}, y_2), \cdots, (x_{j+n_2}, y_2)); ((x_z, y_3), (x_{z+1}, y_3), \cdots, (x_{z+n_3}, y_3))$ 在深度中 x 轴方向上的相邻像素点的实际距离并取其平均值作为相邻两点的实际距离。又因为茎秆在生长过程中并不是直立生长的,会由于环境等因素造成茎秆产生不同程度的倾斜,故在 y_1 、 y_2 和 y_3 处的茎粗只是茎秆在水平方向上的茎粗 P_1 、 P_2 和 P_3 ,再通过结合茎秆的倾斜角 β ,由Mask R-CNN提取出的下胚轴区域,即可测量出茎秆的实际茎粗 d ,茎粗测量示意图如图8所示,茎粗计算公式为

$$d = \frac{d_1 + d_2 + d_3}{3}$$

(5)

其中

$$\begin{cases} d_1 = P_1 d_{\text{exx}} \cos\beta \\ d_2 = P_2 d_{\text{exx}} \cos\beta \\ d_3 = P_3 d_{\text{exx}} \cos\beta \end{cases}$$

式中 d ——茎秆的实际茎粗,mm
 d_1 —— y_1 位置的实际茎粗,mm
 d_2 —— y_2 位置的实际茎粗,mm
 d_3 —— y_3 位置的实际茎粗,mm
 d_{exx} —— x 轴相邻像素点的平均距离,mm

2.4.4 下胚轴长度无损测量

下胚轴长度是地面与子叶节之间的距离^[24]。为准确测量黄瓜苗下胚轴长度,利用Mask R-CNN生成的茎秆的二值图像与原图像进行像素相乘,获得茎秆图像。结合只包含有茎秆的二值图像与深度图像,通过测量 y 轴方向相邻像素点之间的欧氏距离取平均值获得黄瓜苗的胚轴部位在 y 轴方向的平均深度距离,再通过对二值图中的下胚轴区域进行骨架提取,计算出骨架所包含的像素数量,根据计算出的深度图在 y 轴方向上的两点像素之间的平均距离,得到下胚轴长度,下胚轴长度测量示意图如图8所示,下胚轴长度计算公式为

$$L = Nd_{\text{evy}}$$

(6)

式中 L ——下胚轴长度,mm
 N ——骨架所包含的像素数量
 d_{evy} —— y 轴相邻像素点的平均距离,mm

3 实验结果与分析

3.1 实例分割网络检测和分割性能评估

为了更加全面、客观评价分析Mask R-CNN对黄瓜苗器官分割数据处理的可行性,将本文算法与使用场景较多的实例分割算法YOLACT进行实验

对比。YOLACT算法是一阶段实例分割算法,即利用网络自身的平移可变性这一特性,生成对不同实例产生不同响应的特征图,将特征图进行线性组合,进而区分不同实例^[25]。Mask R-CNN是二阶段算法,即先通过锚框产生ROI区域,再对该区域进行分类、边界框回归和掩膜预测。利用已有的黄瓜苗数据集分别对Mask R-CNN、YOLACT网络进行训练,并将训练好的网络模型在测试集上进行了实验分析。本实验采用掩膜交并比、准确率、召回率和F1值作为模型指标评价黄瓜苗器官分割数据处理结果。算法分割结果和真实结果区域面积的交并比,用以衡量模型器官分割精确度;又因为黄瓜苗的叶片检测包括叶片类型和数量,故采用准确率、召回率和F1值作为模型评价指标。准确率表示在预测中正确预测样本占模型认为是正样本的比例;召回率表示正确预测样本占有所有正样本的比例,F1值表示准确率和召回率的调和平均。考虑到真叶对作物生长后续阶段的作用更大,故选用真叶的分割情况作为黄瓜苗真叶分割模型算法性能评估,表1是黄瓜苗真叶分割模型性能评价对比。

表 1 黄瓜苗真叶分割模型性能评价对比

Tab.1 Performance evaluation and comparison of cucumber seedling real leaf segmentation models %

分割模型	掩膜交并比	准确率	F1 值
Mask R-CNN	94	97	96
YOLACT	89	97	96

从表1可以看出,Mask R-CNN和YOLACT在红外图中对真叶识别的准确率、F1值相同,但在掩膜交并比评价指标下,Mask R-CNN高于YOLACT,而掩膜交并比数值越接近于1,该模型的分割性越好。因此,本文选择了Mask R-CNN算法作为叶片分割算法,可以满足后续表型测量的分割要求。

3.2 叶片表型检测结果与分析

图9为3个生长时期黄瓜苗真叶数和子叶数的算法计算与人工测量结果的对比图。测量结果证明Mask R-CNN网络能够有效对黄瓜苗叶片进行分类、识别、计数。随着生长时期的变化,黄瓜苗叶片数测量产生的误差也增大。误差产生的主要原因是黄瓜苗从子叶时期到2叶1心时期,真叶从发芽到变大变多,导致子叶和真叶遮挡情况的发生,从而造成子叶和真叶的误检测。

利用冠层视角测量黄瓜苗叶面积时,会因为视角问题,造成子叶和真叶的遮挡。但在大部分的遮挡情况是只存在于子叶的遮挡,又因为黄瓜苗的子叶近似于椭圆形,故先通过改进IP-basic算法^[26]




图 9 黄瓜苗真叶和子叶数量的测量结果
Fig. 9 Measurement results of number of true leaves and cotyledons of cucumber seedlings

利用叶片未遮挡部分的轮廓对子叶进行拟合,并对发生遮挡的子叶利用临近像素间的深度信息恢复其缺失的深度信息。图 10 为经过改进 IP - basic 算法对子叶进行椭圆拟合后,真叶未处理,每一片叶面积的算法计算结果与人工测量结果拟合图,叶面积测量结果与真实值相比决定系数 R^2 分别为 0.91、0.93、0.96,均方根误差分别为 0.25、1.00、1.14 mm^2 ,平均绝对误差分别为 4.22%、9.62%、11.10%。

但是,仅考虑子叶的遮挡是不恰当的,在 2 叶 1 心时期,黄瓜苗的第 2 片真叶逐渐变大,可能会造成真叶的遮挡。为了解决子叶和真叶在叶面积测量中的遮挡问题,采用 CycleGAN 对抗网络修复子叶和真叶的遮挡。图 11 为经过网络修复的叶面积计算值与人工测量结果拟合图,叶面积测量结果与真实值相比决定系数 R^2 分别为 0.95、0.95、0.83,均方根误差分别为 0.41、1.39、2.71 mm^2 ,平均绝对误差分别为 3.80%、6.23%、7.20%。该测量结果表明,基于 CycleGAN 修复子叶和真叶,在单视角黄瓜苗测量是可行的。叶面积测量产生误差的原因如下:部分叶片表面与相机成像平面成一个陡峭的角度,导致相机无法捕获反射回的深度信息,造成了叶片点云缺失;在对邻域最值滤波后的点云进行矫正修补时,存在误差,造成了无损测量值的增大;在子叶时期和 1 叶 1 心时期,子叶几乎是展平的,但是在 2 叶 1 心时期,子叶逐渐弯,导致利用基于 CycleGAN 叶面积测量时造成较大误差。




图 10 单片叶面积使用改进 IP - basic 算法计算与人工测量的线性拟合结果
Fig. 10 Linear fitting analysis of single leaf area measured with improved IP - basic algorithm and manual measurement




图 11 CycleGAN 修复叶面积与人工测量叶面积的线性拟合分析
Fig. 11 Linear fitting analysis of CycleGAN leaf area repair and manual leaf area measurement

3.3 株高测量结果与分析

本文通过准确率、召回率和F1 值来评价黄瓜苗生长点模型的检测性能,表 2 为不同生长时期黄瓜苗在置信度为 0.7 时生长点模型评价数据。通过表 2 可以看出 YOLO v5s 对子叶、1 叶 1 心、2 叶 1 心时期的黄瓜苗生长点识别具有较为准确的识别精度。

图 12 为 3 个生长期黄瓜苗的株高算法计算与人工测量结果拟合图。株高测量结果与真实值相比决定系数 R^2 分别为 0.90、0.90、0.92,均方根误差

表 2 置信度为 0.7 时生长点检测结果评估

Tab.2 Evaluation of growth point detection results

at confidence level of 0.7			%
生长时期	准确率	召回率	F1 值
子叶时期	98.96	97.49	98
1 叶 1 心时期	98.33	97.72	98
2 叶 1 心时期	97.96	97.64	97

分别为 1.78、1.52、1.73 mm,平均绝对误差分别为 4.72%、3.56%、3.83%。




图 12 黄瓜苗株高算法计算值与人工测量值线性拟合分析

Fig. 12 Linear fitting analysis of algorithmic and manual measurements of cucumber seedling height

株高产生测量误差原因如下:植物在生长过程中具有趋光性,这导致在整盘育苗时位于穴盘边缘的种苗会出现向光源弯曲生长,这造成了株高测量误差较大;在进行人工测量时,穴盘基质平面不平整导致了测量误差。

3.4 茎粗测量结果与分析

图 13 为 3 个生长时期茎粗算法计算和人工测

量结果拟合图。茎粗测量结果与真实值相比决定系数 R^2 为 0.83、0.88、0.91,均方根误差分别为 0.14、0.16、0.12 mm,平均绝对误差分别为 8.59%、6.79%、4.16%。该测量结果表明,算法测量黄瓜苗茎粗误差较大。实验结果虽在误差允许的范围,但仍需要进一步改善,提高表型测量的精度。




图 13 黄瓜苗茎粗算法计算值与人工测量值线性拟合分析

Fig. 13 Linear fitting analysis of algorithmic and manual measurements of cucumber seedling stem thickness

茎粗测量误差主要原因如下:子叶时期的黄瓜苗茎秆部分纤细,一旦获取到的茎秆深度数据缺失一部分,茎粗测量误差就较大;茎秆的横截面类似椭圆,测量结果与相机正对被测苗的方向有关。

3.5 下胚轴长测量结果与分析

图 14 为 3 个生长期黄瓜苗下胚轴长算法计算和人工测量结果拟合图。下胚轴长测量结果与真实值相比决定系数 R^2 为 0.90、0.92、0.92,均方根误差分别为 1.12、0.88、1.02 mm,平均绝对误差分别为 4.61%、2.69%、2.49%。测量结果表明,本研究

提出的测量方法精确度较高,可以较好地替代人工测量。下胚轴长产生误差原因:受子叶时期的黄瓜苗茎秆纤细程度和相机精度影响,深度图可能丢失部分深度信息,造成测量误差。

4 结论

(1)设计了一套自动化的 RGB-D 图像采集平台,可以满足自动化的种苗表型检测需求,不仅减轻了图像数据采集的工作强度,还提高了黄瓜苗表型检测的效率,兼顾测量的全面性、精确性和高通量需求。




图 14 黄瓜苗下胚轴长算法计算值与人工测量值线性拟合分析

Fig. 14 Linear fitting analysis algorithmic and manual measurements of cucumber seedling hypocotyl length

(2)设计了一系列基于黄瓜苗图像的深度学习分割算法。通过 Mask R-CNN 网络分割俯视角度下的黄瓜苗红外图,再将 Mask R-CNN 的分割结果与 RGB-D 对齐图掩膜,得到 RGB-D 图像中真叶、子叶的分割结果,其中真叶分割结果的掩膜交并比在 0.94 以上;使用 YOLO v5s 网络检测 RGB-D 图像中的黄瓜苗生长点,置信度为 0.7 的情况下生长点预测准确率均在 97.96% 以上。

(3)提出了单株黄瓜苗表型参数的计算方法。针对获取的黄瓜苗三维点云,设计了一系列点云计算方法,通过相关的方法计算黄瓜苗叶片数、叶面积、株高、下胚轴长和茎粗等参数。实验结果表明,本文方法满足种苗科研所需的测量精度要求,可较好地替代人工测量方式。

参 考 文 献

[1] 陈小央. 浙江省蔬菜种苗产业发展现状与对策建议[J]. 浙江农业学,2021,62(5):847-850,853.
CHEN Xiaoyang. Current situation and strategies of vegetable seedling industry in Zhejiang Province[J]. Journal of Zhejiang Agricultural Sciences,2021,62(5):847-850,853. (in Chinese)

[2] 韩明阳. 基于立体视觉的虚拟植物生长态势监测仿真[J]. 计算机仿真,2019,36(11):365-369.
HAN Mingyang. Simulation of virtual plant growth situation monitoring based on stereo vision[J]. Computer Simulation,2019,36(11):365-369. (in Chinese)

[3] 蔡和序,薄凯亮,周琪,等. 黄瓜幼苗下胚轴长度 GWAS 分析及候选基因挖掘[J]. 中国农业科学,2020,53(1):122-132.
CAI Hexu,BO Kailiang,ZHOU Qi,et al. GWAS analysis of hypocotyl length and candidate gene mining in cucumber seedlings [J]. Scientia Agricultura Sinica,2020,53(1):122-132. (in Chinese)

[4] TENG Xiaowen,ZHOU Guangsheng,WU Yuxuan,et al. Three-dimensional reconstruction method of rapeseed plants in the whole growth period using RGB-D camera[J]. Sensors,2021,21(14):4628-4648.

[5] 王玲,徐伟,杜开伟,等. 基于 SR300 深度相机的褐蘑菇原位测量技术[J]. 农业机械学报,2018,49(12):13-19,108.
WANG Ling,XU Wei,DU Kaiwei,et al. Portabella mushrooms measurement in situ based on SR300 depth camera[J]. Transactions of the Chinese Society for Agricultural Machinery,2018,49(12):13-19,108. (in Chinese)

[6] 朱逢乐,严霜,孙霖,等. 基于深度学习多源数据融合的生菜表型参数估算方法[J]. 农业工程学报,2022,38(9):195-204.
ZHU Fengle,YAN Shuang,SUN Lin,et al. Estimation method of lettuce phenotypic parameters using deep learning multi-source data fusion[J]. Transactions of the CSAE,2022,38(9):195-204. (in Chinese)

[7] 孙想,吴华瑞,朱华吉,等. 基于 LW-YOLOv3 模型的棉花主茎生长点检测与定位研究[J]. 河北农业大学学报,2021,44(6):106-115.
SUN Xiang,WU Huarui,ZHU Huaji,et al. Research on detection and location of cotton main stem growth point via LW-YOLOv3 model[J]. Journal of Hebei Agricultural University, 2021,44(6):106-115. (in Chinese)

[8] ZHANG M R,XU S Y,HUANG Y,et al. Non-destructive measurement of the pumpkin rootstock root phenotype using Azure Kinect[J]. Plants,2022,11(9):1144.

[9] 徐焕良,马仕航,王浩云,等. 基于几何模型的绿萝叶片外部表型参数三维估测[J]. 农业机械学报,2020,51(12):220-228.
XU Huanliang,MA Shihang,WANG Haoyun,et al. Three-dimensional estimation of money plant leaf external phenotypic parameters based on geometric model[J]. Transactions of the Chinese Society for Agricultural Machinery,2020,51(12):220-228. (in Chinese)

[10] 王纪章,贺通,周静,等. 基于叶绿素荧光传感器的植物 LED 补光测控系统[J]. 农业机械学报,2019,50(增刊):347-352,410.
WANG Jizhang,HE Tong,ZHOU Jing,et al. LED lighting control system for plant based on chlorophyll fluorescence sensor [J]. Transactions of the Chinese Society for Agricultural Machinery,2019,50(Supp.):347-352,410. (in Chinese)

[11] 景亮,王瑞,刘慧,等. 基于双目相机与改进 YOLOv3 算法的果园行人检测与定位[J]. 农业机械学报,2020,51(9):34-39,25.
JING Liang,WANG Rui,LIU Hui,et al. Orchard pedestrian detection and location based on binocular camera and improved YOLOv3 algorithm [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(9):34-39,25. (in Chinese)

[29] 周浩,唐昀超,邹湘军,等. 农业采摘机器人视觉感知关键技术研究[J]. 农机化研究,2023,45(6):68–75.
ZHOU Hao,TANG Yunchao,ZOU Xiangjun,et al. Research on key technologies of visual perception of agricultural picking robot[J]. Journal of Agricultural Mechanization Research,2023,45(6):68–75. (in Chinese)

[30] 朱昌伟. 基于双目视觉的田间甘蔗空间定位及抓取研究[D]. 南宁:广西大学,2022.
ZHU Changwei. Research on spatial location and grab of sugarcane in field based on binocular vision[D]. Nanning:Guangxi University,2022. (in Chinese)

[31] 洪梓嘉,李彦明,林洪振,等. 基于双目视觉的种植前期农田边界距离检测方法[J]. 农业机械学报,2022,53(5):27–33,56.
HONG Zijia,LI Yanming,LIN Hongzhen,et al. Field boundary distance detection method in early stage of planting based on binocular vision[J]. Transactions of the Chinese Society for Agricultural Machinery,2022,53(5):27–33,56. (in Chinese)

[32] 李道亮,杨昊. 农业物联网技术研究进展与发展趋势分析[J]. 农业机械学报,2018,49(1):1–20.
LI Daoliang,YANG Hao. State-of-the-art review for Internet of things in agriculture[J]. Transactions of the Chinese Society for Agricultural Machinery,2018,49(1):1–20. (in Chinese)

(上接第 213 页)

[12] 闫成功,徐丽明,袁全春,等. 基于双目视觉的葡萄园变量喷雾控制系统设计与试验[J]. 农业工程学报,2021,37(11):13–22.
YAN Chenggong,XU Liming,YUAN Quanchun,et al. Design and experiments of vineyard variable spraying control system based on binocular vision[J]. Transactions of the CSAE,2021,37(11):13–22. (in Chinese)

[13] 殷悦,张慧春,郑加强. 基于双目立体视觉的植物三维重建系统[J]. 中国农机化学报,2021,42(3):129–135.
YIN Yue,ZHANG Huichun,ZHENG Jiaqiang. Three dimensional reconstruction system of plant based on binocular stereo vision[J]. Journal of Chinese Agricultural Mechanization,2021,42(3):129–135. (in Chinese)

[14] LI L,ZHANG Q,HUANG D. A review of imaging techniques for plant phenotyping[J]. Sensors,2014,14(11):20079–20111.

[15] 杨攀,郑积仕,冯芝清,等. 基于 Mask R-CNN 的密集木材检测分割方法[J]. 林业工程学报,2022,7(2):135–142.
YANG Pan,ZHENG Jishi,FENG Zhiqing,et al. Research on detection and segmentation methods of dense-stacked logs using Mask R-CNN[J]. Journal of Forestry Engineering,2022,7(2):135–142. (in Chinese)

[16] 龙洁花,赵春江,林森,等. 改进 Mask R-CNN 的温室环境下不同成熟度番茄果实分割方法[J]. 农业工程学报,2021,37(18):100–108.
LONG Jiehua,ZHAO Chunjiang,LIN Sen, et al. Segmentation method of the tomato fruits with differenet maturities under greenhouse environment based on improved Mask R-CNN[J]. Transactions of the CSAE,2021,37(18):100–108. (in Chinese)

[17] ZHANG Z,MA X,GUAN H, et al. A method for calculating the leaf inclination of soybean canopy based on 3D point clouds[J]. International Journal of Remote Sensing,2021(15):5719–5740.

[18] 陈辉,王婷婷,代作晓,等. 基于运动恢复结构的无规则植物叶片面积三维测量方法[J]. 农业机械学报,2021,52(4):230–238.
CHEN Hui,WANG Tingting,DAI Zuoxiao, et al. 3D measurement method for area of irregular plant leaf based on structure from motion[J]. Transactions of the Chinese Society for Agricultural Machinery,2021,52(4):230–238. (in Chinese)

[19] 王向周,杨敏巍,郑成华,等. 基于 YOLOv5s-T 和 RGB-D 相机的螺栓检测与定位系统[J]. 北京理工大学学报,2022,42(11):1159–1166.
WANG Xiangzhou,YANG Minwei,ZHENG Shuhua,et al. Bolt detection and positioning system based on YOLOv5s-T and RGB-D camera[J]. Transactions of Beijing Institute of Technology,2022,42(11):1159–1166. (in Chinese)

[20] FU D, XU L, LI D, et al. Automatic detection and segmentation of stems of potted tomato plant using Kinect[C] // Sixth International Conference on Digital Image Processing (ICDIP 2014). SPIE, 2014.

[21] HAN B,LI Y,BIE Z, et al. MIX-NET: deep learning-based point cloud processing method for segmentation and occlusion leaf restoration of seedlings[J]. Plants,2022,11(23):3342–3363.

[22] JAN E,LEE V,DAN L. Simultaneous measurements of plant structure and chlorophyll content in broadleaf saplings with a terrestrial laser scanner[J]. Remote Sensing of Environment, 2010,114(10):2229–2237.

[23] ZHU J,PARK T,ISOLA P,et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[C] // Proceedings of IEEE International Conference on Computer Vision,2017.

[24] 邵久之,李子恒,肖洒,等. 不同浓度烯效唑对黄瓜幼苗生长及产量的影响[J]. 现代园艺,2022,45(19):3–4.

[25] BOLYA D,ZHOU C,XIAO F, et al. Yolact: real-time instance segmentation[C] // Proceedings of the IEEE International Conference on Computer Vision,2019.

[26] 黄漫,黄勃,高永彬. 引入深度补全与实例分割的三维目标检测[J]. 传感器与微系统,2021,40(1):129–132.
HUANG Man,HUANG Bo,GAO Yongbin. 3D target detection incorporating with depth completion and instance segmestion[J]. Transducer and Microsystem Technologies,2021,40(1):129–132. (in Chinese)