

考虑全生长周期的吊蔓西瓜表型识别方法研究

刘泽^{1,2} 赵泽川^{1,3} 许彤^{1,2} 刘韬¹ 朱德兰^{1,2} 季子涵^{1,2}

(1. 西北农林科技大学水利与建筑工程学院, 陕西杨凌 712100;

2. 西北农林科技大学旱区农业水土工程教育部重点实验室, 陕西杨凌 712100;

3. 中国电建集团成都勘测设计研究院有限公司, 成都 610072)

摘要: 针对当前作物表型研究大多关注单一生长阶段表型特征, 无法准确监测植物全生长周期长势等问题, 以吊蔓西瓜为研究对象, 提出了结合多种深度学习方法及机器视觉技术的吊蔓西瓜全生长周期关键表型参数高精度识别方法。其中, 在幼苗期, 分别建立了基于 Leaf SAM 的叶面积计算模型和基于 Xception 的叶片数计算模型, 试验结果表明, 叶面积、叶片数计算模型决定系数分别为 0.96、0.98, 均方根误差分别为 2.98 cm²、0.14; 在伸蔓期, 分别建立了基于 YOLO v5 和双目视觉原理的株高计算模型和基于 OpenCV 的茎粗计算模型, 试验结果表明, 株高、茎粗计算模型决定系数分别为 0.94、0.92, 均方根误差分别为 4.18 cm、0.17 mm; 在坐果期和成熟期, 构建了基于 UNet 的果实投影面积计算模型, 试验结果表明, 果实面积投影模型决定系数和均方根误差分别为 0.99、9.85 cm²。上述结果表明模型计算值与人工测量值间的线性关系显著, 综合误差较低, 能够有效计算吊蔓西瓜全生长周期的关键表型参数。

关键词: 吊蔓西瓜; 全生长周期; 表型; 深度学习; 机器视觉

中图分类号: S24 文献标识码: A 文章编号: 1000-1298(2025)03-0119-10

OSID:



Phenotypic Identification Method for Whole Growth Cycle of Hanging Watermelon

LIU Ze^{1,2} ZHAO Zechuan^{1,3} XU Tong^{1,2} LIU Tao¹ ZHU Delan^{1,2} JI Zihan^{1,2}

(1. College of Water Resources and Architectural Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China

2. Key Laboratory of Agricultural Soil and Water Engineering in Arid and Semiarid Area, Ministry of Education,

Northwest A&F University, Yangling, Shaanxi 712100, China

3. POWERCHINA Chengdu Engineering Co., Ltd., Chengdu 610072, China)

Abstract: In response to the current focus on single growth stage phenotype characteristics in most phenotype research, which makes it difficult to accurately monitor plant growth throughout whole growth cycle, a high-accuracy identification method for key phenotypic parameters of hanging watermelon throughout whole growth cycle was proposed by combining multiple deep learning methods and machine vision technologies. In the seedling stage, leaf area calculation model based on Leaf SAM and leaf count model based on Xception were established, and the experiments results showed that the R^2 of the leaf area and leaf count models were 0.96 and 0.98, and the root mean square error (RMSE) was 2.98 cm² and 0.14, respectively. During the elongation period, plant height measurement model based on YOLO v5 and binocular vision principles, as well as stem thickness calculation model based on OpenCV, were established separately, and the experiment results showed that the R^2 of the plant height and stem thickness measurement model were 0.94 and 0.92, and the RMSE was 4.18 cm and 0.17 mm, respectively. In the fruiting and ripening stages, a fruit projection area calculation model based on UNet was established, and the experiment results showed that the R^2 of the fruit projection model and the RMSE were 0.99 and 9.85 cm², respectively. The above results showed that the linear relationship between the calculated and manually measured values was significant, and the comprehensive error was low, which can effectively calculate the key phenotypic parameters throughout the whole growth cycle of hanging watermelon.

Key words: hanging watermelon; whole growth cycle; phenotype; deep learning; machine vision

收稿日期: 2024-10-18 修回日期: 2025-01-09

基金项目: 国家自然科学基金联合基金项目(U2243235)和宁夏回族自治区重点研发计划项目(2022BBF02026)

作者简介: 刘泽(1989—),男,副教授,博士,主要从事机器学习与智慧农业水利研究, E-mail: zeliu@nwfau.edu.cn

0 引言

西瓜因其适应性强、栽培周期短、市场需求量大和增收效果显著等特点,已成为我国重要园艺作物之一^[1]。我国是西瓜生产和消费大国,其产业发展对保障城乡居民鲜果消费和带动农户增收至关重要^[2]。近年来,得益于西瓜市场需求激增、种植技术不断进步及相关政策扶持,西瓜种植面积持续扩大。然而,随着种植规模扩大和人力成本增加,西瓜大面积自动化管理成为一大挑战。

植物表型分析是对生长、发育、抗性、产量等复杂植物性状的综合评估方法^[3]。西瓜叶面积、叶片数、株高、茎粗及果实投影面积等表型参数与西瓜生长和产量直接或间接相关。定量提取和分析株高、茎粗及叶面积等性状,并进一步探讨表型与产量间联系,已成为作物育种和表型组学研究的重要内容^[4]。西瓜表型识别有助于实现品种鉴别、种苗选育、病虫害防治及生长状态监测。建立精确西瓜表型计算模型,是了解西瓜生长状态的前提,也是培育良种、提高生产效益及提升现代农业生产精准管控的关键^[5]。

传统植物表型参数信息获取主要通过手工测量,但该方法存在规模有限、效率低及主观性强等局限性。近年来,更加精确和自动化的机器学习和图像处理技术已被用于获取植物表型参数^[6]。尽管该方法已初见成效,但仍存在需要手动设计特征和依靠经验选择参数的缺点^[7]。近几年,基于三维点云的植物表型计算方法得到广泛应用^[8-9],该方法虽然能获得高精度作物点云信息,但可能受到数据质量、处理复杂度、遮挡和计算效率等方面的限制。最近,深度学习已成为植物表型研究的新兴热点方向,该方法能自动从植物图像中提取表型关键特征,极大提高作物表型研究效率和准确性,已被广泛用于杂草识别^[10]、果实采摘^[11]及病虫害识别^[12]等方面。

全面监测植物整个生长周期变化在作物育种、

基因-环境互动、胁迫分析和产量预测中具有潜在应用^[13]。西瓜在不同生长阶段具有不同特性,幼苗期表现为根系生长迅速且叶片数增加;伸蔓期表现为植株节间伸长,根、茎、叶加速生长;结果期和成熟期则表现为主根和侧根停止发育,蔓叶生长达到高峰,果实体积和重量不断增加。这些特性使得实现西瓜全生长周期关键表型动态检测面临数据获取、处理、连续监测及环境因素等方面挑战。

目前,针对西瓜表型识别的研究较少,ABBASZADEH等^[14]通过激光多普勒测振仪将振动信号从时域变换到频域,通过快速傅里叶变换提取29个特征,并构建基于K近邻的西瓜成熟度模型;LI等^[15]使用Mask-RCNN对西瓜穴盘苗的冠层叶片进行分类、分割及计数,有效解决了西瓜穴盘苗的冠层表型无损测量问题;张毅^[16]提出一种基于机器学习技术的西瓜弱苗判别方法;刘明琦^[17]结合试验测定的各生长阶段缺水临界含水率数据建立了西瓜苗缺水诊断系统,为温室西瓜苗在线灌溉提供决策依据。但上述研究大多集中于西瓜单一生长阶段或单个特征分析,不能实现对西瓜进行全生长周期关键表型参数精准计算,阻碍其在智慧农业生产中应用。因此,本文结合多种深度学习方法和机器视觉技术,搭建全生长周期吊蔓西瓜表型参数计算模型,用于西瓜全生长周期监测,以实现西瓜生长动态管理。

1 材料与方 法

1.1 方法概述

技术研究框架如图1所示,主要包含3个步骤:

(1)数据获取:采集西瓜不同生长周期(幼苗期、伸蔓期、坐果期、成熟期)各个关键表型器官(叶片、茎、植株、果实)数据,并进行预处理。

(2)表型模型建立:在幼苗期,分别建立基于Leaf SAM的叶面积计算模型和基于Xception的叶片数计算模型。在伸蔓期,分别建立基于YOLO v5及双目视觉的西瓜株高计算模型和基于OpenCV的

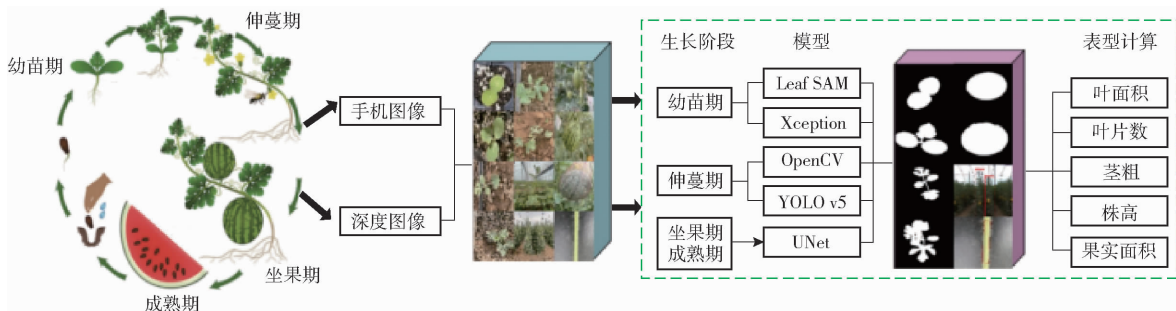


图1 吊蔓西瓜全生长周期表型性状识别技术流程

Fig.1 Technical process of phenotypic trait identification throughout whole growth cycle of hanging watermelon

茎粗计算模型。在坐果期和成熟期,建立基于 UNet 的西瓜果实投影面积计算模型。

(3)关键表型参数计算:提出西瓜各生长阶段关键表型参数的计算方法,与各关键表型参数人工测量值进行分析对比。

1.2 数据获取

选择西瓜品种为“黄晶一号”和“金玉玲珑”,数据采集时间为2023年3—7月,地点位于陕西省咸阳市杨陵区。西瓜植株图像采用 Stereolabs 公司生产的 Zed 2i 型相机拍摄,配置 2.1 mm 镜头,拍摄距离范围为 0.2 ~ 20 m。图像分辨率为 1 280 像素 × 720 像素。其余图像采用 iPhone12 型相机拍摄,图像分辨率为 4 032 像素 × 3 024 像素。为确保光照环境稳定性,以避免光线变化对图像质量的影响,数据采集时间为 09:00—10:00 和 15:00—16:00。在数据采集过程中,固定相机与植株间距离,按不同生长周期分别拍摄吊蔓西瓜各器官图像,共计 15 600 幅。为进行模型训练,在数据标记过程中,通过目视计数确定西瓜幼苗叶片数,通过 Labelme 标记幼苗期叶面积和果实面积。最后,收集 150 个人工测量株高、茎粗、叶面积及果实面积人工测量数据用于模型准确性验证。数据采集分布情况如表 1 所示。

表 1 西瓜生长特性及自建数据集信息

Tab. 1 Watermelon growth characteristics and information of self-constructed dataset

生长阶段	生长特性	表型器官	数量/幅
幼苗期	真叶显露到 5 片或 6 片叶为幼苗期,一般需要 25 ~ 30 d。幼苗期干物质增长最快,生长的中心为根系和叶片	叶片	8 000
伸蔓期	由 5 片或 6 片叶抽蔓开始到留瓜节位的雌花开放为伸蔓期,一般需要 16 ~ 25 d。伸蔓期西瓜根、茎、叶生长速度显著增加	茎 植株	100 1 500
坐果期	由留瓜节雌花开放到果实开始旺盛生长为止,一般需要 4 ~ 6 d。该阶段茎叶的光呼吸达最大值	植株 果实	1 500 2 000
成熟期	由果实迅速生长到果实大小基本固定为止,一般需要 22 ~ 36 d。成熟期西瓜果实体积迅速膨大,重量剧增,吸肥吸水量多	果实	2 500

2 模型构建与试验

2.1 幼苗期西瓜叶面积计算模型

传统叶片分割模型存在训练数据量大、训练成本高以及对数据变化敏感等问题,因此无法有效处理西瓜在不同生长周期下的叶片形状变化。

KIRILLOV 等^[18]提出的 SAM (Segment anything model)模型建立在视觉 Transformer 基础上,包括图像编码器、提示编码器和快速掩码解码器等 3 个组件。其在包含 1×10^9 个掩码的 1.1×10^7 幅图像的大型数据集上进行训练,在叶片分割任务中表现出色。其最大优点是能在无标记样本情况下取得较好分割性能,不需要传统深度模型训练所需的大量标记信息。为减少西瓜叶面积标记工作量,提出了基于 SAM 的零样本西瓜叶片分割方法 (Leaf SAM)。

2.1.1 Leaf SAM 算法

在 SAM 分割前对西瓜叶片进行颜色提取,将平均色调设置在 35 ~ 75 之间,筛选出饱和度超过 35 的像素,从而提取出绿色叶片^[19]。该步骤称为“Color check”,目的是从图像中分离出可能是叶片的区域,为后续 SAM 分割提供更准确叶片检测基础。

在 SAM 分割时,SAM 为整个图像中所有潜在对象生成分割掩码,且无需任何先验信息。基于均匀采样网格点,编码器将生成点嵌入,并将其与图像嵌入相结合。然后,掩码解码器将该组合作为输入,输出整个图像的多个潜在二进制掩码,该步骤称为“SAM auto”。

经过“Color check”和 SAM 分割后,仍可能检测到一些其他物体,以及分割不完整叶片掩码。为去除这些掩码,采用“Shape check”方法,将每个掩码面积与输入图像中绿色像素面积进行比较,最终选择面积最接近掩码作为预测叶片掩码。Leaf SAM 模型结构如图 2 所示。

2.1.2 西瓜叶片面积计算

为计算西瓜叶片面积,选取 1 cm^2 正方形作为参照物,并对正方形进行二值化处理。分别统计该图像中白色像素点数量(即目标叶片和参照物像素点数量),计算叶片和标签像素点数量,并求出叶片真实面积 S 为

$$S = S_0 S_1 / S_2 \quad (1)$$

式中 S_0 ——参照物真实叶片面积

S_1 ——叶片像素点数量

S_2 ——参照物像素点数量

2.2 幼苗期西瓜叶片数计算模型

为解决西瓜叶片计数问题,选择 4 种不同架构卷积神经网络 (Convolutional neural networks, CNN) 进行对比: Xception^[20]、ResNet^[21]、Inception^[22] 和 NasNet^[23]。Xception 将 36 个卷积层按一定结构和顺序组织,其中包括深度可分离卷积、逐点卷积及扩张卷积等不同类型的卷积层及激活函数、残差连接等

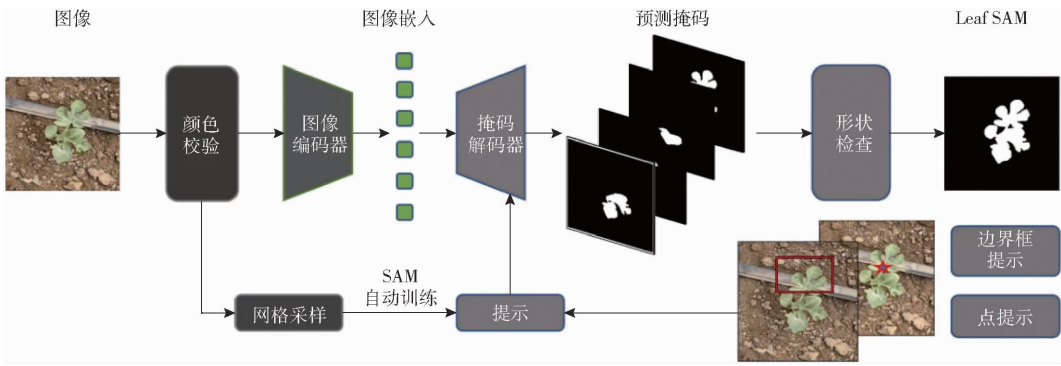


图2 Leaf SAM 基本结构图

Fig.2 Basic structure diagram of Leaf SAM

结构。ResNet 是一种深度卷积神经网络,旨在解决梯度消失问题和训练深度网络,该架构利用残差学习结构,通过一系列卷积操作后,由最后一个全连接层确定叶片数计算值。Inception 是为降低 CNN 复杂度提出的,由一系列并行组合的卷积层构成。通过这种并行结构,Inception 可同时捕获不同尺度特征信息。NasNet 是一种基于神经网络架构搜索

(Neural architecture search, NAS) 的卷积神经网络。NasNet 通过自动搜索最优网络结构,解决 NAS 无法应用到大数据集上的问题。在试验中,将每个架构最后一个全连接层改为单个神经元,对输入图像中叶片数量进行计算。该神经网络模型结构如图 3 所示。最终将模型预测计算值与人工测量值进行比较,评估模型性能。




图3 叶片计数神经网络模型结构图

Fig.3 Structure diagram of leaf counting neural network model

2.3 伸蔓期西瓜茎粗计算模型

在西瓜等茎较细的作物中,采用深度学习方法存在检测难度大且精度不高的问题。因此,提出一种基于 OpenCV 的西瓜茎粗测量方法。使用黑色背景板对西瓜茎背景进行遮挡,采用 iPhone12 型相机对西瓜茎进行固定距离拍摄,将拍摄的西瓜茎粗图像转至 HSV 颜色空间,并使用超绿特征值 (Excess green, ExG) 将其转为灰度图像。然后,使用大津法 (Otsu) 将超绿灰度图像转为黑白二值图像,以提取图像中茎部分。对提取图像进行轮廓检测,找到最大轮廓并提取。将提取图像转为灰度图像,对其进行 Canny 边缘检测,以找到最符合西瓜茎形状轮廓,为西瓜茎粗计算做准备。

为计算西瓜茎粗,同样选取 1 cm^2 正方形作为参考物,并定义单位像素长为物体像素宽与真实宽比值。通过统计西瓜茎轮廓的像素点数量,由公式计算西瓜真实茎粗。西瓜茎在生长过程中存在粗细不均匀现象,针对该问题,将原茎粗图像等分为 5 段,

并求取茎粗平均值以降低测量过程中误差,茎粗计算式为

$$L = L_1 / L_0 \quad (2)$$

式中 L ——西瓜茎粗测量值

L_1 ——茎像素宽 L_0 ——单位像素长

2.4 伸蔓期西瓜株高计算模型

2.4.1 双目视觉原理

双目视觉模型原理是通过左右目相机获得图像信息,计算双目图像中视差,从而进行三维重建。通过计算西瓜植株视差,获取西瓜植株深度信息和关键点坐标,实现西瓜株高计算。双目视觉原理如图 4 所示。左右目相机投影中心 Q_L 和 Q_R 间距离为基线距离 b ,测距点 P 在左右相机的成像点分别为 P_L 和 P_R 。 f 为相机焦距, X_L 和 X_R 分别为左右相机成像点到左成像面距离,则点 P 在左右相机的视差为

$$d = |X_L - X_R| \quad (3)$$

两个成像点 P_L 和 P_R 之间距离为

$$L_{P_L P_R} = b - (X_L - X_R) \quad (4)$$

根据相似三角形理论可以得出点 P 到投影中心平面的距离 Z 为

$$Z = \frac{bf}{X_L - X_R} \quad (5)$$




图 4 双目测距原理图

Fig. 4 Principle of binocular distance measurement

2.4.2 西瓜株高计算

株高是一个关键农艺性状,影响作物结构、光合作用,从而影响最终产量和种子质量。西瓜株高是指地面到植株顶端之间距离,是衡量植物垂直生长指标之一。图 5 为双目视觉测量西瓜株高示意图,提取西瓜植株上顶点二维坐标 (X_{\max}, Y_{\max}) 和植株下顶点二维坐标 (X_{\min}, Y_{\min}) , 并利用经 SGBM (Semi global block matching) 算法计算后的视差图深度信息,将其转换为空间世界三维坐标 $(X_{\max}, Y_{\max}, Z_{\max})$ 和 $(X_{\min}, Y_{\min}, Z_{\min})$ 。则西瓜植株高度 H 为

$$H = \sqrt{(X_{\max} - X_{\min})^2 + (Y_{\max} - Y_{\min})^2 + (Z_{\max} - Z_{\min})^2} \quad (6)$$




图 5 双目视觉测量西瓜株高示意图

Fig. 5 Schematic of binocular visual measurement of watermelon plant height

利用 Matlab 平台进行双目相机标定,共拍摄 32 组标定图像,并将其分为左目图像和右目图像。通过运行 Matlab 工具箱中的“Stereo camera calibration”程序,对左右目相机内部参数进行优化,以降低测量误差。采用 YOLO v5 算法对西瓜植株进行识别,将其与深度信息结合实现对西瓜株高实时计算。在此基础上,将模型计算结果与使用卷尺实际测量值比较,评估西瓜株高模型的计算效果。

2.5 坐果期和成熟期西瓜果实投影面积计算模型

果实大小可直观反映西瓜品质和产量,由 2.1

节可知原始 SAM 模型虽然可以实现零样本分割,但必须经过改进才能得到较好分割性能。由于西瓜果实呈椭圆形,其规则形状易于标记。可选择 UNet^[24] 进行西瓜果实分割。UNet 是传统卷积神经网络 FCN^[25] 的一种变体,其采用对称 U 形编码和解码结构。其中,编码器部分可提取输入图像的高层次特征表示,通过连续卷积和池化操作逐渐减少特征图尺寸和通道数。解码器部分则通过上采样操作将编码器提取的低分辨率特征图还原为输入图像分辨率,并结合编码器相应层特征进行特征融合,最终产生密集像素级别分割结果。西瓜果实投影面积计算方法参考 2.1.2 节中西瓜叶片面积计算方法。

2.6 评价指标

使用交并比 (Intersection over union, IoU)、召回率 (Recall, R)、精确率 (Precision, P)、F1 值和平均精度均值 (Mean average precision, mAP) 5 个指标评价西瓜植株检测准确率,通过比较模型计算值与人工测量值间的决定系数 R^2 、均方根误差 (Root mean square error, RMSE)、平均绝对百分误差 (Mean absolute percentage error, MAPE)、平均绝对误差 (Mean absolute error, MAE) 和均方误差 (Mean square error, MSE) 量化西瓜各表型参数计算精度与误差。

3 结果与分析

3.1 幼苗期表型模型建立

西瓜幼苗期地上部生长较为缓慢,根系生长较为迅速,且具有旺盛吸收功能。本阶段建立了西瓜叶面积和叶片数 2 个表型计算模型来检测西瓜幼苗生长状况。

3.1.1 叶面积计算结果

在不同生长阶段,西瓜叶片呈现不同形态结构,从而影响图像分割难度。为评估 Leaf SAM 在西瓜叶片数据集上的分割性能,按照叶片数量将数据集划分为 2 叶片、3 叶片、4 叶片和 5 叶片数据子集,并在这些不同子数据集上使用 UNet、DeepLabV3、HrNet、PspNet 和 Leaf SAM 进行对比试验。其中 UNet 模型分别采用 ResNet 和 Vgg 作为主干网络; DeepLabV3 分别采用 MobilNet 和 Xception 作为主干网络。将自建数据集中西瓜叶片图像调整为 512 像素 \times 512 像素。各模型训练周期 (Epochs) 均设为 500, 单次批量训练图像数量 (Batch size) 设为 8, 选择随机梯度下降法 (Stochastic gradient descent, SGD) 作为优化算法,学习率下降方式为余弦衰减,初始学习率设为 0.01, 每训练 5 个周期保存一次权重。各项评价指标结果如表 2 所示,各模型分割结果对比如图 6 所示。

表2 各模型评价指标对比

Tab.2 Comparison of evaluating indicator of various models

类别	指标	UNet	UNet	DeepLabV3	DeepLabV3	PspNet	HrNet	SAM	Leaf SAM
		(Vgg)	(ResNet)	(MobilNet)	(Xception)				Leaf SAM
2 叶片	IoU	99.23	97.40	98.19	97.53	95.81	98.03	29.55	98.62
	精确率	99.60	99.16	99.41	99.50	98.52	99.33	74.96	99.65
	召回率	99.60	99.87	98.76	98.00	97.21	98.68	32.79	99.43
3 叶片	IoU	95.02	96.33	94.65	94.12	89.82	95.59	30.97	94.23
	精确率	99.13	99.31	99.04	97.66	93.80	98.83	79.48	98.38
	召回率	95.82	96.98	95.53	96.29	95.49	96.69	33.67	99.84
4 叶片	IoU	93.07	93.14	91.00	90.42	40.54	90.99	10.11	87.01
	精确率	98.73	98.67	97.04	96.39	41.72	97.03	70.92	98.71
	召回率	94.19	94.33	93.60	93.61	93.48	93.60	10.55	88.02
5 叶片	IoU	78.85	72.51	76.52	75.10	30.99	76.52	8.16	85.79
	精确率	87.96	82.03	87.28	83.28	32.14	85.12	79.03	98.66
	召回率	88.39	86.21	86.12	88.44	89.69	88.33	8.34	87.82

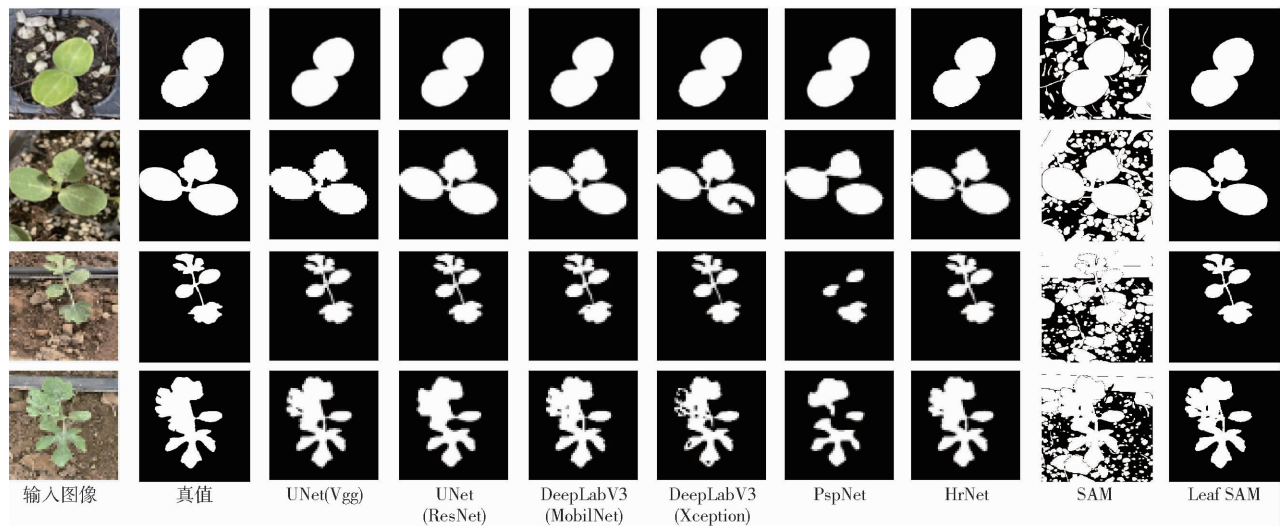


图6 分割结果对比

Fig.6 Comparison chart of segmentation results

从表2可看出,传统分割模型在处理2叶片图像时具有较好分割性能,其IoU在95%以上,召回率和精确率在98%以上。原始SAM对于处理2叶片图像的分割结果较差,出现大量假阳性结果,其IoU仅为29.55%。加入“Color check”和“Shape check”模块的Leaf SAM分割性能大幅提升,其IoU达98.62%,精确率和召回率分别为99.65%和99.43%。这说明Leaf SAM可以提高SAM模型对未知叶片数据集的分割能力。随着西瓜叶片数量增加,西瓜叶片形状变得更加复杂,传统语义分割模型分割性能下降。在处理5叶片图像时,传统模型IoU都在80%以下。而Leaf SAM在处理复杂形状叶片时表现较好的分割性能。在5叶片数据集中,Leaf SAM模型IoU为85.79%,精确率和召回率分别为98.66%和87.82%。结果表明,Leaf SAM模型可较好地实现西瓜叶片分割,且可有效解决传统模型处理复杂叶片时分割性能大幅下降

问题。

为进一步验证Leaf SAM的分割效果,随机选取30个西瓜叶片样本,利用Leaf SAM分割叶片,并采用像素统计法计算西瓜叶片面积,将结果与人工测量值进行对比,结果如图7所示。测得的叶片面积与人工测量值之间 R^2 为0.96, RMSE为2.98 cm², MAPE为7.84%,表明所建立模型能够更好地进行西瓜叶片分割,并完成西瓜叶片面积测量。

3.1.2 叶片计数模型

根据不同架构要求调整西瓜叶片图像分辨率为: Xception(299像素×299像素)、ResNet(224像素×299像素)、Inception(299像素×299像素)和NasNet(331像素×331像素)。随机划分数据集,其中60%用于训练,20%用于验证,20%用于测试。Epochs为500, Batch size为8,选择Adma(Adaptive moment estimation)作为优化算法,均方差函数作为损失函数,初始学习率为0.0001。结果如表3所示。




图 7 西瓜叶面积测量结果对比

Fig. 7 Comparison of watermelon leaf area measurements

表 3 不同架构对比结果

Tab. 3 Comparison results of different architectures

模型	R^2	RMSE	MAPE/%	MAE	MSE
ResNet	0.90	0.33	6.91	0.26	0.11
Inception	0.93	0.28	6.87	0.24	0.08
Xception	0.98	0.14	2.28	0.08	0.02
NasNet	0.80	0.47	12.33	0.43	0.22

由表 3 可知, Xception 架构表现最好, 其 R^2 、RMSE、MAPE、MAE 和 MSE 分别为 0.98、0.14、2.28%、0.08 和 0.02。相比之下, NasNet 架构性能最差, 其 R^2 、RMSE、MAPE、MAE 和 MSE 分别为 0.80、0.47、12.33%、0.43 和 0.22。从图 8 可以看出, 使用 Xception 架构的叶片计数模型在 4 种架构中总标准偏差和误差最小, 相关性最强。基于这些结果, 最终选取 Xception 为西瓜叶片数计算模型。




图 8 叶片数计算模型架构泰勒图

Fig. 8 Taylor diagram of blade number calculation model architecture

3.2 伸蔓期表型模型建立

在西瓜伸蔓期, 西瓜植株节间伸长, 叶片数迅速增加, 但单株叶面积较小, 侧枝出现并孕育花蕾。此阶段西瓜根系扩展基本完成, 生长趋缓; 而植株根、茎、叶旺盛生长。本阶段主要通过叶面积、叶片数、茎粗和株高 4 个表型参数检测西瓜长势。其中, 幼苗期叶面积计算模型和叶片数计算模型在伸蔓期继

续适用。

3.2.1 西瓜茎粗计算结果

将西瓜茎图像进行 ExG 超绿灰度转换和 Otsu 二值化前处理, 并利用西瓜茎黑白二值图像进行西瓜茎轮廓提取, 最终完成西瓜茎粗计算。图 9a 为拍摄的西瓜茎原图, 经 ExG 处理后的超绿灰度图像如图 9b 所示, 使用 Otsu 二值化方法处理的西瓜茎黑白二值图像如图 9c 所示。




图 9 西瓜茎粗计算前处理结果

Fig. 9 Preprocessing of watermelon stem diameter calculation

图 10a 为经 Canny 算子提取的西瓜茎轮廓, 图 10b 为西瓜茎粗计算结果。为评估西瓜茎粗计算模型准确性, 随机选取 30 个西瓜茎粗样本, 评估西瓜表型参数计算结果。对比结果表明, 西瓜茎粗模型计算值与人工测量值之间均有较强相关性, 决定系数 R^2 为 0.92, RMSE 为 0.17 mm, MAPE 为 3.40%。图 11 为模型计算值与人工测量值对比结果。




图 10 西瓜茎粗计算结果

Fig. 10 Watermelon stem diameter calculation




图 11 西瓜茎粗测量结果对比

Fig. 11 Comparison of watermelon stem diameter measurements

3.2.2 西瓜株高计算结果

通过 Matlab 对双目相机左右目镜头进行标定, 并分别获取参数, 使用 Remap 函数实现图像校正,

然后使用 SGBM 算法进行立体匹配和加权最小二乘滤波处理,生成视差深度图像。处理后的深度图像如图 12 所示。同时,使用 YOLO v5 模型进行西瓜植株检测。训练过程中,将自建数据集中西瓜植株图像分辨率调为 640 像素 × 640 像素,随机将数据集按比例 6:2:2 划分为训练集、验证集和测试集。Epochs 设为 500, Batch size 设为 16,选择随机梯度下降法作为优化算法,学习率设为 0.01,权重衰退系数设为 0.0005。



图 12 西瓜植株深度图像

Fig. 12 Depth image of watermelon plants

YOLO v5 模型在验证集中召回率、精确率、F1 值、mAP@0.5 和 mAP@0.95 分别为 96%、94%、92%、91% 和 86%,表明该模型能够有效地进行西瓜植株检测和识别,并提供西瓜株高计算所需关键点二维坐标。图 13 为西瓜植株检测结果。



图 13 双目图像中目标检测结果

Fig. 13 Object detection results in binocular images

为验证西瓜株高测量模型的准确性,随机选取 30 个西瓜株高样本,将模型计算值与人工测量值进行对比。对比结果如图 14 所示,西瓜株高计算模型 R^2 为 0.94, RMSE 为 4.18 cm, MAPE 为 2.39%,结果表明,该模型可以精确地实现西瓜株高测量。

3.3 坐果期和成熟期表型模型建立

在结果期和成熟期阶段,西瓜主根和侧根停止发育,蔓叶生长达到高峰,果实体积和重量不断增加。本阶段主要建立西瓜株高和果实投影面积 2 个表型特征进行西瓜长势监测。其中,西瓜株高计算方法同 2.4.2 节。

同时训练 6 种预训练模型进行对比,包括 UNet (ResNet)、UNet (Vgg)、DeepLabV3 (MobilNet)、DeepLabV3 (Xception)、HrNet 和 PspNet。将自建数据集中西瓜果实图像分辨率调整为 512 像素 ×




图 14 西瓜株高测量结果对比

Fig. 14 Comparison of watermelon plant height measurements

512 像素,随机将数据集按比例 6:2:2 划分为训练集、验证集和测试集。训练部分参数:各模型迭代次数均设为 500, Batch size 设为 8,选择随机梯度下降法 (SGD) 优化网络参数,学习率下降方式为余弦衰减,初始学习率设为 0.01,每训练 5 个周期保存一次权值。分割试验结果如表 4 所示,可以看出,UNet (Vgg) 在西瓜果实图像分割问题中表现较好,其 IoU 为 97.53%,召回率为 99.23%,精确率为 98.27%。在后续试验中,以 UNet (Vgg) 模型为西瓜果实分割模型,为果实投影面积计算提供掩膜,西瓜果实分割结果对比如图 15 所示。

表 4 不同模型分割指标对比

Tab. 4 Comparison of segmentation indicators among different models

指标	among different models				%	
	UNet (Vgg)	UNet (ResNet)	DeepLabV3 (MobilNet)	DeepLabV3 (Xception)	HrNet	PspNet
IoU	97.53	97.48	97.09	96.25	97.05	62.5
召回率	99.23	99.27	99.05	98.90	99.07	80.04
精确率	98.27	98.19	98.01	97.29	97.94	74.05

为验证 UNet (Vgg) 在西瓜果实投影面积计算中的表现,随机选择 30 个西瓜果实样本,评估西瓜果实投影面积计算结果。采用像素统计法计算西瓜果实的投影面积,并将其与人工测量值进行对比,结果如图 16 所示。西瓜果实投影面积计算值与人工测量值之间 R^2 为 0.99, RMSE 为 9.85 cm², MAPE 为 4.89%,表明所建立模型能够准确地进行西瓜果实分割,并完成西瓜果实投影面积测量。

4 结论

(1) 建立了全生长周期吊蔓西瓜表型识别模型,该生长周期模型对西瓜表型参数计算能力较强,模型计算值与人工测量值间线性关系显著,综合误差较低。其中叶片面积、果实投影面积、株高、茎粗和叶片计数模型计算值与人工测量值之间 R^2 分别为

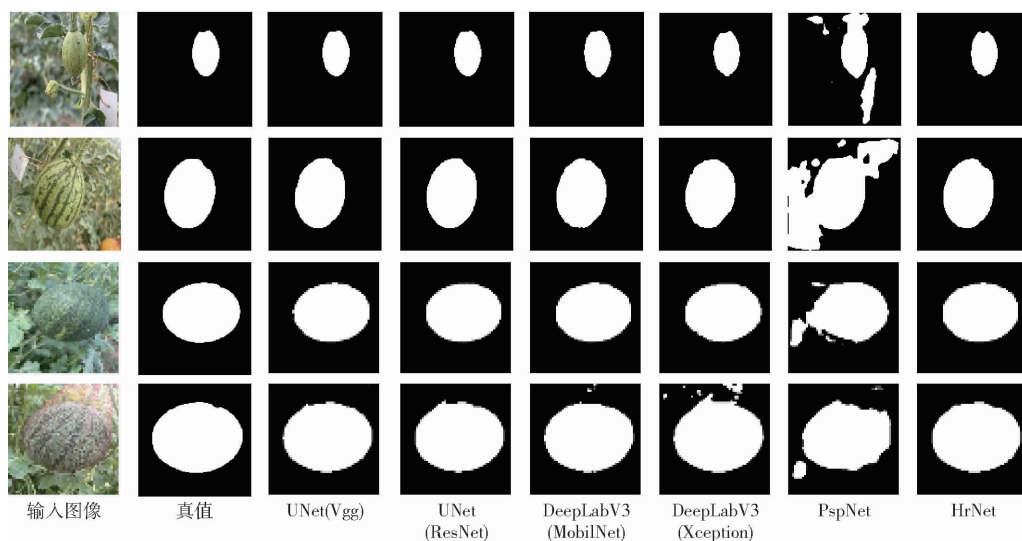


图 15 不同模型分割结果对比

Fig. 15 Comparison of segmentation results between different models

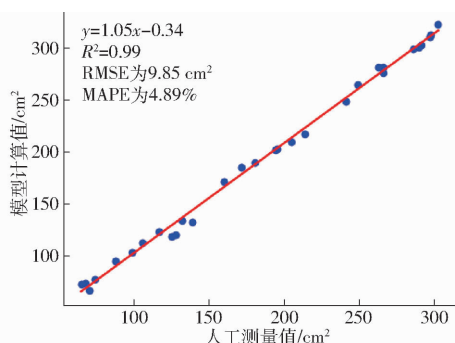


图 16 西瓜果实面积结果对比

Fig. 16 Comparison of watermelon fruit area results

0.96、0.99、0.94、0.92、0.98, RMSE 分别为 2.98 cm²、9.85 cm²、4.18 cm、0.17 mm、0.14。各表型参数模

型计算值与人工测量值均有较强相关性,可用于西瓜全生长周期监测,实现西瓜生长动态管理。

(2)在自建西瓜数据集上的试验结果表明,提出的叶片分割模型(Leaf SAM)实现了西瓜叶片零样本分割,并表现出较好分割性能。在处理简单叶片形状时,其分割能力与传统语义分割模型相近。而在处理复杂形状叶片时,Leaf SAM 模型的 IoU 在 85% 以上,优于传统分割模型。

(3)主要完成了对西瓜典型表型特征计算。在未来研究中,可以进一步结合西瓜生长环境的温度、湿度、施肥量、灌溉量等变量建立相关模型,为水肥管理提供决策依据,以实现精准水肥智能化调控目标。

参 考 文 献

- [1] 孟祥志,刘小林,苏海滨. 中外西瓜产业发展现状及国际竞争力比较[J]. 北方园艺, 2024(18):145-153. MENG Xiangzhi, LIU Xiaolin, SU Haibin. Comparison of development status and international competitiveness of watermelon industry between China and foreign countries[J]. Northern Horticulture, 2024(18):145-153. (in Chinese)
- [2] 孙立新,王晓君,吴敬学,等. 中国西瓜甜瓜生产区域布局变迁及驱动因素研究[J]. 中国农业资源与区划, 2023, 44(8):42-51. SUN Lixin, WANG Xiaojun, WU Jingxue, et al. Research on regional distribution changes and driving factors of watermelon and melon production in China[J]. Agricultural Resources and Zoning in China, 2023, 44(8):42-51. (in Chinese)
- [3] SUN Jian, REN Zhengwei, CUI Jiale, et al. A high-throughput method for accurate extraction of intact rice panicle traits[J]. Plant Phenomics, 2024(6):0213.
- [4] ZHU Tianyu, MA Xiaodan, GUAN Haiou, et al. A method for detecting tomato canopies' phenotypic traits based on improved skeleton extraction algorithm[J]. Computers and Electronics in Agriculture, 2023, 214: 108285.
- [5] 翟肇裕,张梓涵,徐焕良,等. YOLO 算法在动植物表型研究中应用综述[J]. 农业机械学报, 2024, 55(11):1-20. ZHAI Zhaoyu, ZHANG Zihan, XU Huanliang, et al. Review of applying YOLO family algorithms to analyze animal and plant phenotype[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11):1-20. (in Chinese)
- [6] LI Zhenbo, GUO Ruohao, LI Meng, et al. A review of computer vision technologies for plant phenotyping[J]. Computers and Electronics in Agriculture, 2020, 176: 105672.
- [7] QIU Ruicheng, MIAO Yanlong, ZHANG Man, et al. Detection of the 3D temperature characteristics of maize under water stress using thermal and RGB-D cameras[J]. Computers and Electronics in Agriculture, 2021, 191: 106551.
- [8] 梁秀英,周风燃,陈欢,等. 基于运动恢复结构的玉米植株三维重建与性状获取[J]. 农业机械学报, 2020, 51(6):209-219. LIANG Xiuying, ZHOU Fengran, CHEN Huan, et al. Three-dimensional maize plants reconstruction and traits extraction based on structure from motion[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(6): 209-219. (in Chinese)
- [9] GUO Ruichao, XIE Jilong, ZHU Jiayi, et al. Improved 3D point cloud segmentation for accurate phenotypic analysis of cabbage

- plants using deep learning and clustering algorithms[J]. *Computers and Electronics in Agriculture*, 2023, 211: 108014.
- [10] 王秀红,王庆杰,李洪文,等. 基于 YOLO v5 - Jetson TX2 的秸秆覆盖农田杂草检测方法[J]. *农业机械学报*, 2023, 54(11): 39 - 48.
WANG Xiuhong, WANG Qingjie, LI Hongwen, et al. Weed detection method of straw-covered farmland based on YOLO v5 - Jetson TX2[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(11): 39 - 48. (in Chinese)
- [11] 倪纪鹏,朱立成,董力中,等. 基于 SwinS - YOLACT 的番茄采摘机器人实时实例分割算法研究[J]. *农业机械学报*, 2024, 55(10): 18 - 30.
NI Jipeng, ZHU Licheng, DONG Lizhong, et al. Real-time instance segmentation algorithm for tomato picking robot based on SwinS - YOLACT[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(10): 18 - 30. (in Chinese)
- [12] 马铁民,曲浩,高雅,等. 基于超分辨率生成对抗网络的玉米病害分类识别方法[J]. *农业机械学报*, 2024, 55(11): 49 - 56, 67.
MA Tiemin, QU Hao, GAO Ya, et al. Maize disease classification and recognition method based on super-resolution generative adversarial networks[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(11): 49 - 56, 67. (in Chinese)
- [13] JANGRA S, CHAUDHARY V, YADAV R, et al. High-throughput phenotyping: a platform to accelerate crop improvement [J]. *Phenomics*, 2021(1): 31 - 53.
- [14] ABBASZADEH R, MOOSAVIAN A, RAJABIPOUR A, et al. An intelligent procedure for watermelon ripeness detection based on vibration signals[J]. *Journal of Food Science and Technology*, 2013, 52: 1075 - 1081.
- [15] LI Lei, BIE Zhilong, ZHANG Yi, et al. Nondestructive detection of key phenotypes for the canopy of the watermelon plug seedlings based on deep learning[J/OL]. *Horticultural Plant Journal*, 2023. <https://doi.org/10.1016/j.hpj.2022.09.013>.
- [16] 张毅. 基于表型检测与机器学习的西瓜幼苗弱苗早期识别研究[D]. 武汉: 华中农业大学, 2023.
ZHANG Yi. Early identification of weak watermelon seedlings based on phenotype detection and machine learning[D]. Wuhan: Huazhong Agricultural University, 2023. (in Chinese)
- [17] 刘明琦. 基于多源信息融合的西瓜苗缺水诊断研究[D]. 武汉: 华中农业大学, 2022.
LIU Mingqi. Research on watermelon seedling water deficiency diagnosis based on multi source information fusion[D]. Wuhan: Huazhong Agricultural University, 2022. (in Chinese)
- [18] KIRILLOV A, MINTUN E, RAVI N, et al. Segment anything[J]. *arXiv:2304.02643*, 2023.
- [19] WILLIAMS D, MACFARLANE F, BRITTEN A. Leaf only SAM: a segment anything pipeline for zero-shot automated leaf segmentation[J]. *arXiv:2305.09418*, 2023.
- [20] CHOLLET F. Xception: deep learning with depthwise separable convolutions[C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017.
- [21] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016.
- [22] SZEGEDY C, IOFFE S, VANHOUCKE V, et al. Inception - v4, inception-resnet and the impact of residual connections on learning[C] // *Proceedings of the AAAI Conference on Artificial Intelligence*, 2017.
- [23] ZOPH B, VASUDEVAN V, SHLENS J, et al. Learning transferable architectures for scalable image recognition[C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018.
- [24] RONNEBERGER O, FISCHER P, BROX T. U - net: convolutional networks for biomedical image segmentation[C] // *Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015; 18th International Conference*, 2015.
- [25] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2015.

(上接第 118 页)

- [22] 韩宏琪,江自真,周俊,等. 基于法向量夹角的果树点云配准与枝叶分割方法研究[J]. *农业机械学报*, 2024, 55(9): 327 - 336.
HAN Hongqi, JIANG Zizhen, ZHOU Jun, et al. Fruit tree point cloud registration based on normal vector angles and branch-leaf segmentation method[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(9): 327 - 336. (in Chinese)
- [23] 尹令,陈招达,蓝善贵,等. 基于神经辐射场的 RGB 图像点云重建多肉植物及尺寸测量研究[J]. *农业机械学报*, 2024, 55(9): 316 - 326.
YIN Ling, CHEN Zhaoda, LAN Shangui, et al. Point cloud reconstruction of succulent plants based on neural radiance fields RGB image and dimensional measurement[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(9): 316 - 326. (in Chinese)
- [24] BOUKHANA M, RAVAGLIA J, WHEELER F, et al. Geometric models for plant leaf area estimation from 3D point clouds: a comparative study[J]. *Graphics and Visual Computing*, 2022, 7: 200057.
- [25] YANG D, QIAO D, XIA C. Curved light surface model for calibration of a structured light 3D modeling system based on striped patterns[J]. *Optics Express*, 2020, 28(22): 33240 - 33253.
- [26] NASA. SSI reference spectra[Z/OL]. 2024. <https://sunclimate.gsfc.nasa.gov/ssi-reference-spectra>.