doi:10.6041/j.issn.1000-1298.2024.12.004

宿根蔗补种机轻量化蔗苗识别与定位技术

李尚平[1,2]　张　超[1,2]　张　彪[3]　文春明[1,2]　李凯华[1,2]

（1.广西民族大学电子信息学院，南宁 530006；2.广西高校智慧无人系统与智能装备重点实验室，南宁 530006；
3.广西大学机械工程学院，南宁 530004）

摘要：宿根蔗补种机是解决甘蔗田间缺苗问题的一种补种装置，对于补种机田间作业，能够精准地识别并定位宿根蔗苗十分重要。针对甘蔗田间宿根蔗苗难以精确检测并定位的问题，提出了一种双目相机结合改进 YOLO v5 目标检测算法的宿根蔗苗识别和定位方法。针对目标检测，提出了一种改进 YOLO v5s 网络模型 YOLO v5s_P234_SGG。首先在不同光照及距离条件下拍摄宿根蔗苗图像，进行数据预处理和标注，构建宿根蔗苗数据集，然后剔除原始 YOLO v5s 网络模型的大目标检测层，新增一个小目标检测层，使模型能够更好地适应对蔗苗这种小目标的识别需求；其次在主干网络引入 SimAM 注意力机制，以增强模型对宿根蔗苗关键特征信息的关注，引入 SlimNeck 代替 Neck 网络，在保持足够精度的同时降低了模型复杂度，并将主干网络中的普通卷积模块替换成 Ghost 模块，显著减小了模型内存占用量。实验结果表明，该方法在宿根蔗苗数据集上精确率达到 95.8%，召回率达到 95.2%，平均精度均值达到 97.1%，相比原始 YOLO v5s 网络，精确率上升 3.1 个百分点，召回率上升 2.6 个百分点，平均精度均值上升 3.1 个百分点，模型内存占用量减小 7.7 MB，参数量减少 4 062 632，浮点运算次数减少 7.8×10^9，单幅图像检测时间减少 3.7 ms。蔗苗定位实验结果表明，双目测距定位算法平均相对误差为 0.97%，最大相对误差为 4.60%。成功实现了对甘蔗苗的精准识别与测距，为后续的农业智能作业提供了重要的实时信息和决策支持。

关键词：宿根蔗补种机；蔗苗识别与定位；YOLO v5s；轻量化；双目相机

中图分类号：TP183　　**文献标识码**：A　　**文章编号**：1000-1298(2024)12-0044-13　　**OSID**：

Lightweight Cane Seedling Identification and Positioning Technology for Root Cane Replanting Machine

LI Shangping[1,2]　ZHANG Chao[1,2]　ZHANG Biao[3]　WEN Chunming[1,2]　LI Kaihua[1,2]

(1. *College of Electronic Information*, *Guangxi Minzu University*, *Nanning* 530006, *China*
2. *Key Laboratory of Intelligent Unmanned System and Intelligent Equipment*, *Nanning* 530006, *China*
3. *College of Mechanical Engineering*, *Guangxi University*, *Nanning* 530004, *China*)

Abstract: The cane replanting machine is a replanting device developed to solve the problem of lack of seedlings in the sugarcane field, and it is very important for the field operation of the replanting machine to accurately identify and locate the cane seedlings. In order to solve the problem that it is difficult to accurately detect and locate cane seedlings in sugarseed field, a method for detecting and locating cane seedlings with binocular camera combined with improved YOLO v5 object detection algorithm was proposed. For object detection, an improved YOLO v5s network model was proposed YOLO v5s_P234_SGG. Firstly, the pictures of cane seedlings were taken under different lighting and near and far conditions, and the data was preprocessed and annotated to construct the dataset of cane seedlings, and then the large target detection layer of the original YOLO v5s network model was eliminated, and a small object detection layer was added to make the model better adapt to the recognition needs of small targets such as cane seedlings. Secondly, the SimAM attention mechanism was introduced into the backbone network to enhance the model's attention to the key feature information of the cane seedlings, and SlimNeck was introduced instead of the Neck network, which reduced the complexity of the model while maintaining sufficient accuracy and replacing the ordinary convolution module in the backbone network with the Ghost module, which significantly reduced the size of the model. Experimental results showed that the accuracy of the proposed method on the root cane seedling dataset reached 95.8%, the recall

收稿日期：2024-02-28　修回日期：2024-06-28

基金项目：国家自然科学基金项目(52165009)和广西科技重大专项(桂科 AA22117008、桂科 AA22117006)

作者简介：李尚平(1956—)，男，教授，博士生导师，主要从事智能制造技术信息化研究，E-mail：spli501@vip.sina.com

rate reached 95.2%, and the average accuracy reached 97.1%, compared with the original YOLO v5s network, the accuracy was increased by 3.1 percentage points, the recall rate was increased by 2.6 percentage points, the average accuracy was increased by 3.1 percentage points, the model volume was decreased by 7.7 MB, the number of parameters were decreased by 4 062 632, the FLOPs was decreased by 7.8×10^9, and the detection time of a single image was decreased by 3.7 ms. The results of the cane seedling positioning test showed that the average relative error of the binocular ranging and positioning algorithm was 0.97%, and the maximum relative error was 4.60%. The accurate identification and ranging of sugarcane seedlings were successfully realized, which provided important real-time information and decision-making support for subsequent agricultural intelligent operations.

Key words: root cane replanting machine; identification and positioning of cane seedlings; YOLO v5s; lightweight; binocular camera

0　引言

甘蔗在我国农业中扮演着关键角色[1]，人工宿根蔗作为生产的核心技术，占据甘蔗总种植面积的60% ~70%。充分利用宿根蔗，生产高产高糖的甘蔗原料，可降低生产成本[2]。但是机械收割的碾压[3]、病虫害、自然灾害以及收获期间的践踏，可能导致宿根蔗分布不均、缺蔸断垄、产量下降等[4-6]问题。在缺苗的甘蔗地中及时有效补种可以显著提高总产量[7]，因此，实施迅速准确的机械化、智能化补种工作，尤其是通过有效识别和定位宿根蔗苗，成为解决这一问题的基础。

目前，农作物领域的识别和定位技术主要涵盖传统机器视觉以及深度学习方法。传统的基于图像处理的机器视觉目标检测方法依赖于人工提取目标特征，对图像质量、图像处理以及特征提取质量的依赖度较高，效率低，准确率低，鲁棒性差[8-9]，不适合于复杂领域[10]。而基于深度学习的目标检测[11-15]有更快的检测速度、更高的检测精度，以及在复杂条件下更强的鲁棒性[16-17]。

本文以宿根蔗苗为研究对象，提出一种基于改进 YOLO v5 的目标检测算法，用于田间宿根蔗苗的检测，对比实验分析改进目标检测算法的有效性，同时引入双目摄像头，结合深度学习和计算机视觉方法对宿根蔗苗进行测距，与采集数据对比验证测距算法的准确性和可靠性。

1　补种机组成及工作原理

宿根蔗补种机[18]结构如图 1 所示，补种机的结构大致由机械臂、挖掘器、排种系统、双目摄像头、驾驶室等组成，在排种系统前端安装有双目摄像头，宿根蔗补种机的操作过程为：在田间作业时，双目摄像头首先对宿根蔗苗进行实时检测和识别，能够计算检测到蔗苗空间坐标和距离信息。根据蔗苗种植的要求，当相邻蔗苗的间距超过 60 cm 时，需要进行一次补种。在需要补种时，补种机通过控制机械臂末端的挖掘器进行破垄挖坑操作，接着排种系统将蔗种段排入沟中，最后进行浇水和覆土操作，一次补种操作完成。

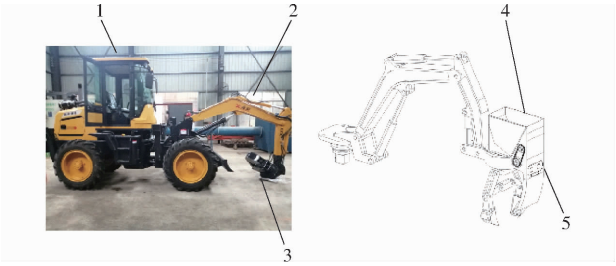

图 1　宿根蔗补种机结构示意图

Fig. 1　Schematic of structure of cane replanting machine

1. 驾驶室　2. 机械臂　3. 挖掘器　4. 排种系统　5. 双目摄像头

本文采用改进的 YOLO v5s 模型，通过对宿根蔗苗的高效识别检测，为宿根蔗苗补种提供可靠的技术支持。在该模型的基础上，引入了双目相机进行距离计算，通过测距技术获取蔗苗与相机的距离信息。如图 2 所示，通过这一过程，可以获得更为全面的宿根蔗苗生长状态的空间信息。通过结合深度学习目标检测和双目视觉测距技术，不仅可实现对农田中宿根蔗苗的精准检测，还可为宿根蔗补种机提供关键的缺苗位置信息。

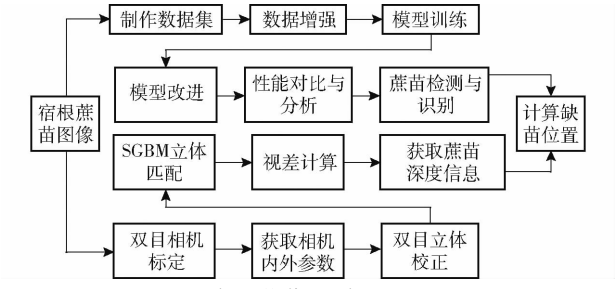

图 2　宿根蔗苗识别测距流程图

Fig. 2　Flowchart of cane seedling identification and ranging

2　材料与方法

2.1　数据采集

实验数据采集于广西壮族自治区崇左市扶绥县

渠黎镇,实验对象为宿根蔗苗,宿根蔗苗垄距平均 1.5 m,株间距平均 0.65 m,蔗苗高度普遍集中在 18 ~ 35 cm。数据采集时间包含 2022 年 7 月中下旬、2022 年 10 月中下旬、2023 年 4 月中上旬,采集设备为 USB 免驱 OV9732 型双目摄像头、OnePlus8 型智能手机,采集时间段为 08:00—20:00,采集场景分为室内大棚和室外露天,共采集 960 幅宿根蔗苗图像,其中包含 10 幅背景图像,图像格式为 JPG,图像分辨率分别为 3 000 像素 ×4 000 像素、1 920 像素 × 1 080 像素。拍摄方式分为近景拍摄和远景拍摄,近景拍摄抓取宿根蔗苗特征细节,远景拍摄模拟机器行进过程。图 3、4 所示为不同光照和拍摄距离下宿根蔗苗的图像。



(a) 顺光 (b) 逆光

图 3 不同光照情况下宿根蔗苗图像

Fig. 3 Photographs of cane seedlings under different lighting conditions



(a) 近景 (b) 远景

图 4 不同拍摄距离下宿根蔗苗图像

Fig. 4 Photographs of cane seedlings under different shooting distances

2.2 数据标注与数据增强

2.2.1 数据标注与划分

为了给模型提供对象位置和类别信息,评估模型的性能,需要对图像中的宿根蔗苗进行标注。使用 LabelImg 工具进行标注,框选图像中宿根蔗苗的根茎部位,标注标签为“sugarcane”,本文目标检测只有一个类别,选择 VOC 标签格式,并保存为 xml 文件。标签文件中包含目标的类别以及位置信息。YOLO v5[19] 训练所需的文件格式为 txt 类型,利用 Python 程序将 xml 格式文件转换成 txt 格式文件,同时将标注完毕的数据集按照比例 8∶1∶1 划分成训练集、验证集、测试集。图像和对应的标签文件将用于模型的训练以及验证推理。数据集划分情况如表 1 所示。

表 1 数据集划分结果

Tab. 1 Dataset partitioning 幅

数据集类型	训练集	验证集	测试集	总数
原始数据集	768	96	96	960
增强数据后	4 608	576	576	5 760

2.2.2 离线数据增强技术

补种机在田间作业时要对宿根蔗苗进行实时识别检测,在田间环境中,光照、角度、遮挡等因素都会对识别结果产生影响,为了提高模型性能和鲁棒性,扩展图像样本丰富度,在网络模型训练前,采用离线数据增强方法对数据进行扩充,通过数据增强,模型可以学习到更广泛的特征和背景,从而提高对不同场景的泛化能力。离线数据增强技术包含翻转变换、噪声扰动、亮度变换、随机角度旋转、平移变换。

图 5a 是检测框中心点的归一化坐标分布图,横轴 x 和纵轴 y 范围从 0 到 1,表示相对于整幅图像检测框中心点的水平和垂直位置。图 5b 是检测框宽度和高度归一化比例分布图,横轴和纵轴范围从 0 到 1,表示检测框的宽度和高度相对于整幅图像尺寸的比例。

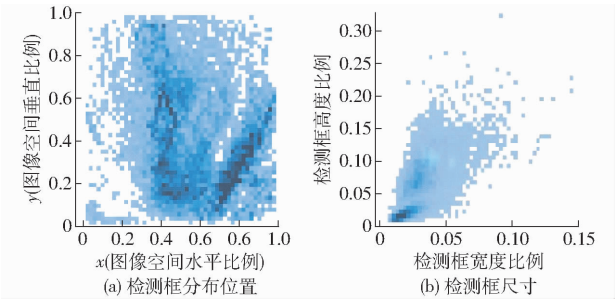

(a) 检测框分布位置 (b) 检测框尺寸

图 5 宿根蔗苗训练结果统计

Fig. 5 Statistics of training results of cane seedlings

经过离线数据增强处理后得到了 5 760 幅图像,其中包含的宿根蔗苗实例共 18 428 个。在图 5a 中,深色区域主要分为 2 部分:一部分位于中心线区域,表示田间的垄线,因为宿根蔗苗通常生长在垄上,所以检测框主要集中在垄线区域;另一部分位于图像右下角,这是数据增强中的角度变换导致的,本文中数据增强时的角度变换均采用顺时针旋转一定角度,使得检测框产生一定的倾斜,一定程度上模拟了在丘陵地带补种机作业时的实际情况。图 5b 展示了检测框的尺寸分布,整体而言,检测框宽度较窄,长度较高,与宿根蔗苗的生长状态相符。其中,一些稍大的检测框模拟了近景情况,表示宿根蔗苗距离补种机摄像头较近;而一些稍小的检测框则模

拟了远景情况，表示宿根蔗苗距离摄像头较远。通过这种综合考虑远近的方式，充分模拟了补种机实际作业时的多种情景。从图中可以明显看出，大多数检测框都属于小目标，因此本文的模型改进主要围绕小目标检测展开。部分数据集数据增强效果如图 6 所示。

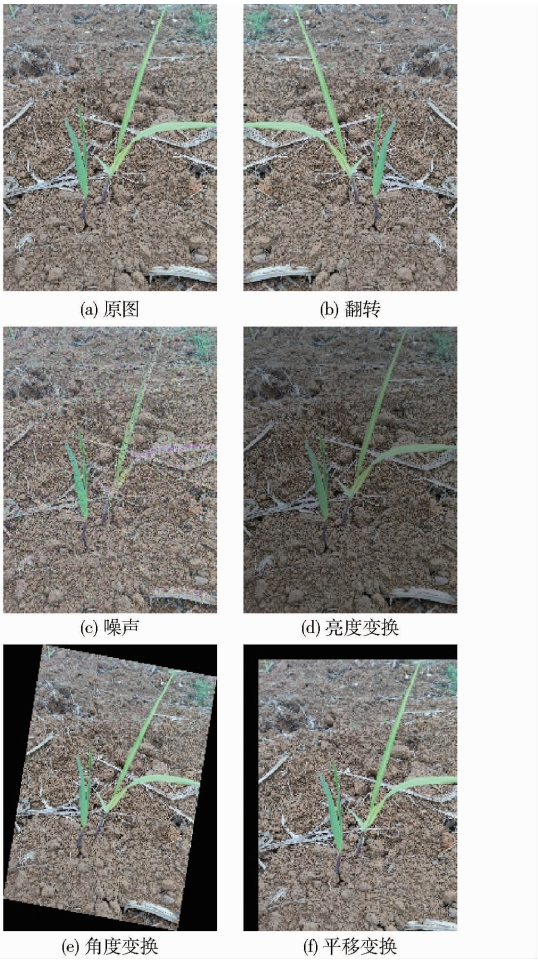

图 6　数据增强效果

Fig. 6　Data augmentation

2.2.3　离线数据增强实验分析

分别采用原始数据集和增强数据集对 YOLO v5s 进行训练和测试，结果如表 2 所示。由表 2 可知，经过离线数据增强后，YOLO v5s 网络模型准确率、召回率和平均精确率均有所提升，其中准确率提高 1.0 个百分点，召回率提高 4.5 个百分点，平均精确率提高 2.0 个百分点。离线数据增强技术引入了更多的样本变化，学习到的特征更具有泛化性，使得模型在不同场景下更具鲁棒性，能够更好地适应新的、未见过的数据，模型更关注于目标物体的各个方面，能够更好地捕捉到目标物体不同的表现形式，这种关注力的提升对于提高召回率很有帮助，因此经离线数据增强后 YOLO v5s 模型召回率提升较多，部分数据集中背景较为复杂，经离线数据增强后关注范围扩大导致模型对一些场景的判别性减弱，导致 YOLO v5s 模型准确率上升较少。总体来说离线数据增强提高了模型对于图像变换的鲁棒性，在补种机实际作业中，摄像头会随着机器行驶上下抖动，在训练阶段引入这些变换，使得 YOLO v5s 模型能够更好地适应不同距离和角度下的图像，提高了模型对实际应用中变异因素的适应性。

表 2　数据增强前后性能对比

Tab. 2　Comparison of performance before and after data enhancement　%

数据集类型	准确率	召回率	平均精确率
原始数据集	91.7	88.1	92.0
数据增强后	92.7	92.6	94.0

3　YOLO v5 算法结构优化

3.1　YOLO v5 网络结构

YOLO 是一种快速而高效的单阶段实时目标检测算法，其核心思想是将目标检测任务视为回归问题，通过单一的前向传播过程同时预测目标的类别和边界框坐标。本文选用了 YOLO v5 7.0 版本，考虑到应用于农机上的智能识别，更注重检测实时性和模型轻量化，因此选择 YOLO v5s 网络模型。模型主要包括输入端（Input）、主干网络（Backbone）、颈部网络（Neck）、头部（Head）。本文主要针对小目标，旨在提升网络模型性能的同时降低模型内存占用量。为满足蔗苗这种小目标物体检测需求，对特征提取模块进行了改进。鉴于对模型轻量化的需求，在主干网络部分，引入 SimAM[20] 注意力机制，而在颈部网络部分，则采用 GSConv 模块和 SlimNeck[21] 结构进行优化。最后，通过对主干网络的 Ghost[22] 操作，保持了改进后模型性能的同时使其更加轻量化。改进后的 YOLO v5s 网络结构如图 7 所示。

3.2　特征提取模块优化

YOLO v5 初始网络模型接收 640×640 的输入图像，随着网络深度增加，在特征信息提取过程中，通过主干网络的连续下采样，Neck 网络的末端生成 3 种不同尺寸的特征图，分别为 20×20、40×40 和 80×80。这 3 种尺寸的特征图针对不同尺寸的目标进行检测，其中，较小尺寸的特征图具有更大的感受野，更注重全局信息，因此更适合检测大目标；而较大尺寸的特征图感受野较小，更专注于局部信息，更适合小目标检测[23]。这样的设计使得模型能够更灵活地适应不同尺寸目标的检测需求。原始的特征提取网络模型结构如图 8 所示。

鉴于宿根蔗苗通常呈现小目标特征，对原始的 YOLO v5s 网络模型进行了调整，引入一种专门用于小目标检测的新层，被命名为 P2 检测层。该层采用

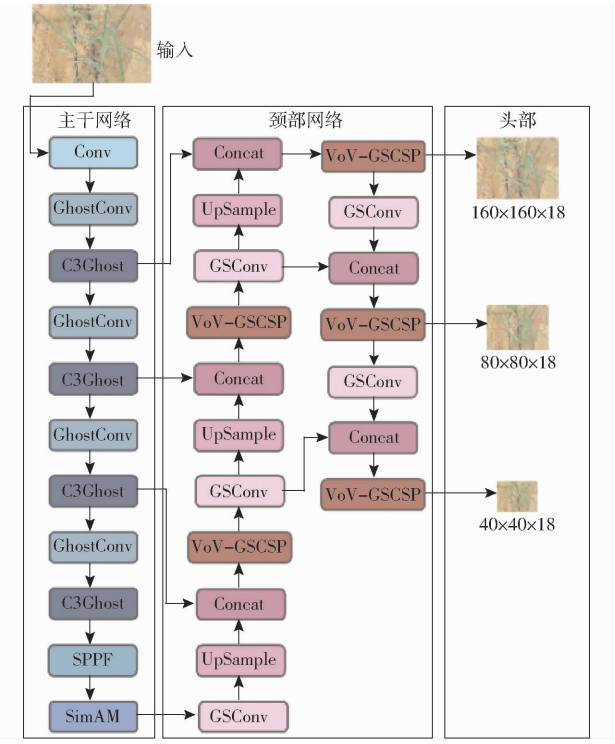

图 7 改进 YOLO v5s 网络结构图

Fig. 7 Improved network structure diagram of YOLO v5s

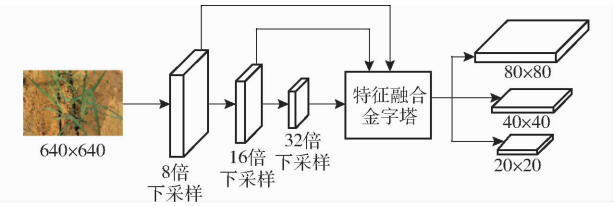

图 8 原始特征提取网络结构图

Fig. 8 Diagram of original feature extraction network structure

4 倍下采样,旨在有效检测极小目标,其输出特征图尺寸为 160×160。通过观察图 5,即使是最大尺寸的检测框也未超出小目标的范围,因此,为进一步优化特征提取网络结构,本文移除了大目标检测层,即 P5 检测层。这一调整的目的是使模型更好地适应宿根蔗苗的小目标检测需求。改进后特征提取网络结构如图 9 所示。

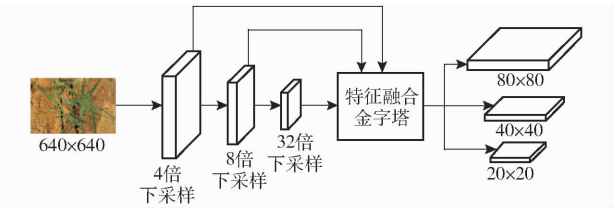

图 9 改进后特征提取网络结构图

Fig. 9 Improved feature extraction network structure diagram

3.3 主干网络优化

针对宿根蔗苗密集、目标小、数量多、在自然环境中容易重叠的特点,在 YOLO v5s 模型的主干网络中加入了注意力机制来提升特征提取能力。使用注意力机制 SimAM,其为一种创新性和高效的注意力机制,如图 10 所示。图中 X 表示输入数据,通常是一个 3 维张量,C 表示图像通道数,H 表示图像高度,W 表示图像宽度。在网络层内生成三维注意力权重的能力使 SimAM 在与传统方法的比较中脱颖而出,而且无需引入额外的参数。传统的注意力机制通常面临 2 个主要问题:①它们受限于在一个方向上进行特征优化,无论是在通道方向还是在空间方向上,这限制了它们适应同时涉及空间和通道变化的动态条件的能力。②它们通常建立在一系列复杂的操作基础上,增加了模型复杂性。

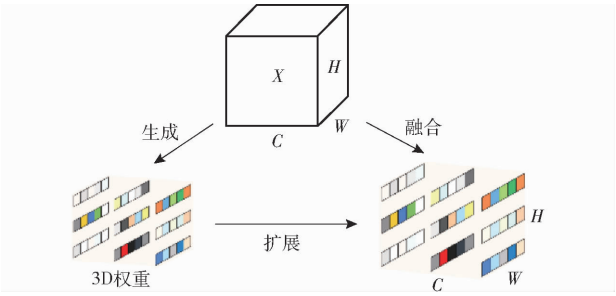

图 10 SimAM 注意力机制

Fig. 10 SimAM attention mechanism

本文将 SimAM 模块放在改进 YOLO v5s 主干网络最后一层,使得 SimAM 注意力机制能够涵盖由主干网络生成的完整特征图,从而提供了全面的全局特征视图。

3.4 颈部网络优化

补种机在田间作业时要对宿根蔗苗进行实时识别检测,进而能够推测出缺苗漏苗的位置,所以对蔗苗检测的实时性和准确性都有较高的要求,为了在补种机上有效部署模型,必须整合轻量级的操作。传统的轻量化操作,如 MobileNet[24] 和 ShuffleNet[25] 这些模块中使用了深度可分离卷积层(Depth-wise separable convlution,DSC)[26-27]。深度可分离卷积通过减少参数数量和计算负担,提高了模型的检测速度,与传统卷积(Conv)相比有所不同。然而,这种提高效率的代价往往是精度降低,许多轻量级模型都是使用类似于 DSC 的操作[24]。本文旨在使模型更轻量化的过程中,保持与精度标准的平衡,利用有限的计算资源实现更好的模型精度。为了实现这种平衡,本文引入 GSConv,这是一种融合传统卷积和深度可分离卷积优势的新型卷积方案。GSConv 的结构如图 11 所示。

由图 11 可知,GSConv 模块将标准卷积与深度可分离卷积合并,并对输入特征图通道进行重新排序。将整个 YOLO v5s 架构中的所有标准卷积都替换为 GSConv 会导致模型推理时间的延长[28],因此,本文选择仅在颈部网络部分添加 GSConv,替代其中

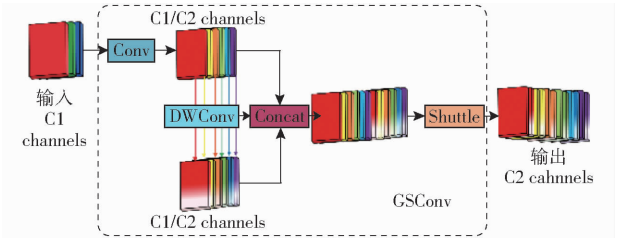

图 11　GSConv 结构图

Fig. 11　GSConv structure diagram

的传统卷积操作。

基于 GSConv，引入 VoV－GSCSP 模块。该模块首先通过组合 2 个 GSConv 模块和 1 个普通卷积模块形成 GSbottleneck，随后采用一次聚合的方式进行构建，VoV－GSCSP 模块在简化网络结构的同时保持了充足的准确性[17]。模块结构如图 12 所示。

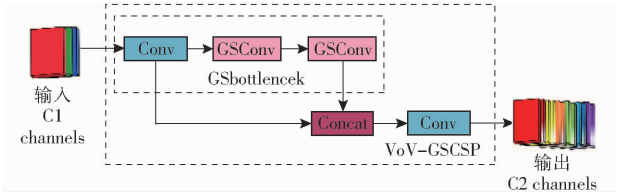

图 12　VoV－GSCSP 结构图

Fig. 12　VoV－GSCSP structure diagram

本文用 VoV－GSCSP 代替 Neck 部分的 C3 模块，用 GSConv 代替普通卷积，二者搭配构成 SlimNeck 结构。

3.5　轻量化设计

为了使改进的网络模型在补种机田间作业时得到有效利用，有必要将模型尺寸尽可能减小，在减小模型尺寸过程中，保持关键性能指标如准确率等也至关重要。为实现这一目标，本文在原始模型的主干部分引入 Ghost 模块，以替代传统标准卷积操作。

Ghost 卷积相较于传统卷积更加精炼，避免了冗余和高计算量问题。通过采用少量卷积核生成部分特征图，再通过线性变换替代生成相似特征图的过程，Ghost 卷积在维持性能的同时，减小了计算和参数开销[22]。Ghost 模块如图 13 所示，图中 $\phi_1,\phi_2,\cdots,\phi_k$ 表示图像中不同的灰度级。

本文对 YOLO v5s 网络模型的主干网络进行了优化，将传统的卷积层替换为 GhostConv 模块，并将原先的 C3 部分替换为 C3Ghost 模块。

4　算法优化实验

4.1　实验环境

使用 Pycharm 对 YOLO v5s 网络模型进行构建与改进，实验与训练所用操作系统为 Windows 11，处理器为 AMD EPYC 7642 48－Core Processor，内存 32 GB，显卡为 Nvidia GeForce RTX 3090，显存 24 GB，编程语言为 Python 3.7。搭建了 PyTorch 深度学习框架实现模型的训练和推理，在模型训练中，将批处理大小设置为 64，将训练轮数设置为 301，初始学习率设置为 0.01。

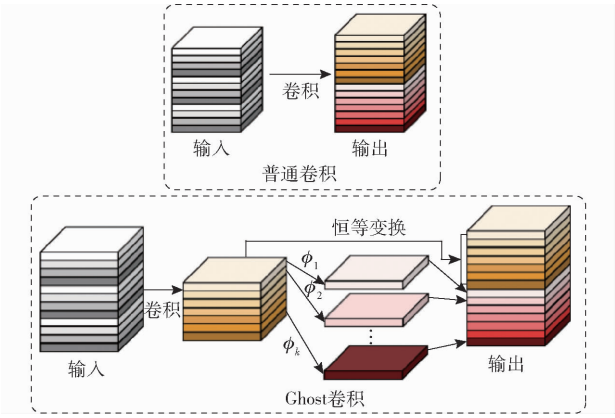

图 13　Ghost 结构图

Fig. 13　Ghost structure diagram

4.2　评价指标

为了深入测试改进模型性能，使用精确率（Precision，P）、召回率（Recall，R）、平均精度均值（Mean average precision，mAP）作为模型的识别精度评价指标，选取检测时间、模型内存占用量、参数量、浮点运算次数作为模型性能评价指标。

4.3　算法优化改进对比

简化改进模型名称如表 3 所示。

表 3　模型名称说明

Tab. 3　Description of model name

模型名称	说明
原始 YOLO v5s	
YOLO v5s_P2345	新增 P2 小目标检测层
YOLO v5s_P234	剔除原始 YOLO v5s 的大检测层，新增 P2 小目标检测层
YOLO v5s_S	单独向 YOLO v5s 模型的主干网络最后一层添加 SimAM 注意力机制
YOLO v5s_G	单独向 YOLO v5s 模型的颈部网络引入 GSConv 模块和 SlimNeck 结构
YOLO v5s_P234_S	保持 YOLO v5s_P234 操作并在主干网络最后一层添加 SimAM 注意力机制
YOLO v5s_P234_G	保持 YOLO v5s_P234 操作，颈部网络引入 GSConv 模块和 SlimNeck 结构
YOLO v5s_P234_SG	保持 YOLO v5s_P234_S 操作，颈部网络引入 GSConv 模块和 SlimNeck 结构
YOLO v5s_P234_SGG	保持 YOLO v5s_P234_SG 的操作，将主干网络进行 Ghost 操作

4.3.1　特征提取网络改进对比

对原始网络模型、新增 P2 检测层网络模型，以及添加 P2 并删除 P5 检测层的网络模型进行了对比，结果如表 4 所示。关键指标包括模型精确率、召回率、检测速度和计算复杂度。

表 4 不同检测层网络模型对比

Tab. 4 Comparison of network models at different detection layers

网络模型	精确率/%	召回率/%	平均精度均值/%	模型内存占用量/MB	参数量	浮点运算次数	检测时间/ms
YOLO v5s	92.7	92.6	94.0	14.4	7 012 822	1.58×10^{10}	18.5
YOLO v5s_P2345	96.0	96.2	97.2	15.1	7 156 008	1.85×10^{10}	15.0
YOLO v5s_P234	96.4	96.3	97.8	11.5	5 375 510	1.71×10^{10}	15.0

由表 4 可知,相比原始模型,仅新增一个小目标检测层,精确率上升 3.3 个百分点,召回率上升 3.6 个百分点,平均精度均值上升 3.2 个百分点,检测时间降低 3.5 ms,模型内存占用量增加 0.7 MB,参数量上升 143 186,浮点运算次数上升 2.7×10^9。新增一个小目标检测层并删掉大目标检测层后,精确率上升 3.7 个百分点,召回率上升 3.7 个百分点,平均精度均值上升 3.8 个百分点,模型内存占用量减小 2.9 MB,参数量下降 1 637 312,检测时间降低 3.5 ms,浮点运算次数上升 1.3×10^9。实验结果显示,P2 检测层更为适应宿根蔗苗的尺寸,其参数和卷积核需求更少。对于宿根蔗苗这类小目标,P5 检测层包含相对较多的冗余信息。因此,引入专为小目标检测设计的新层次结构,以及移除大目标检测层的措施,显著提升了网络模型检测性能。同时,这一调整使网络模型更为轻量化,为其在移动端部署和使用提供了强有力支持。

4.3.2 模型性能消融实验

为了验证模型改进后的效果,将改进的 YOLO v5s 模型和原模型各项指标进行对比,对比结果如表 5 所示。

由表 5 可知,相比于原始 YOLO v5s 模型,YOLO v5s_P234 模型的精确率上升 3.7 个百分点,召回率上升 3.7 个百分点,平均精度均值上升 3.8 个百分点,模型内存占用量减小 2.9 MB,参数量下降 1 637 312,检测时间降低 3.5 ms,浮点运算次数上升 1.3×10^9。唯独在浮点运算次数上面比原始 YOLO v5s 模型多,参数量较少而浮点运算次数增加可能是由于较小尺度特征图的计算负载增加,在调整网络结构以进行小目标检测时,这是正常现象。

表 5 算法优化实验测试集性能评估结果

Tab. 5 Performance evaluation results of algorithm optimization experimental test set

网络模型	精确率/%	召回率/%	平均精度均值/%	模型内存占用量/MB	参数量	浮点运算次数	检测时间/ms
YOLO v5s	92.7	92.6	94.0	14.4	7 012 822	1.58×10^{10}	18.5
YOLO v5s_P234	96.4	96.3	97.8	11.5	5 375 510	1.71×10^{10}	15.0
YOLO v5s_S	93.3	93.5	95.0	14.4	7 012 822	1.58×10^{10}	14.1
YOLO v5s_G	93.5	92.0	94.2	12.1	5 835 702	1.26×10^{10}	14.5
YOLO v5s_P234_S	97.1	97.2	97.9	11.5	5 375 510	1.71×10^{10}	14.6
YOLO v5s_P234_G	97.2	95.7	97.7	10.6	4 884 038	1.32×10^{10}	15.9
YOLO v5s_P234_SG	97.2	96.1	98.3	10.6	4 884 038	1.32×10^{10}	15.9
YOLO v5s_P234_SGG	95.8	95.2	97.1	6.7	2 950 190	8.00×10^9	14.8

相比于 YOLO v5s 模型,单独添加 SimAM 注意力机制精确率上升 0.6 个百分点,召回率上升 0.9 个百分点,平均精度均值上升 1 个百分点,由于 SimAM 注意力机制不会引入额外的参数和计算量,所以参数量、浮点运算次数、模型内存占用量没有变化,单幅图像检测时间加快 4.4 ms,尽管 SimAM 注意力机制对 YOLO v5s 模型的性能提升有限,但其显著加速了检测速度。这使得补种机在田间作业时,网络模型能够更好地满足实时性的需求。

相比于 YOLO v5s 模型,单独向 YOLO v5s 模型的颈部网络中添加 GSConv 模块和 SlimNeck 结构使得网络模型的精确率上升 0.8 个百分点,召回率下降 0.6 个百分点,平均精度均值上升 0.2 个百分点,模型内存占用量减小 2.3 MB,参数量下降 1 177 120,浮点运算次数下降 3.2×10^9,检测时间加快 4 ms,经过实验证明,通过将普通卷积替换为 GSConv 并引入 SlimNeck 结构,成功提高了对宿根蔗苗特征的有效提取,同时改善了计算效率。这一优化不仅保持了模型性能的完整性,还符合更加精简轻量化设计的需求。

在 YOLO v5s_P234 模块的基础上分别单独添

加 SimAM 注意力机制和单独添加 GSConv 模块 + SlimNeck 结构，分别比原始 YOLO v5s 模型的精确率上升 4.4 个百分点和 4.5 个百分点，召回率上升 4.6 个百分点和 3.1 个百分点，平均精度均值上升 3.9 个百分点和 3.7 个百分点。在 YOLO v5s_P234 模块的基础上添加 GSConv 模块 + SlimNeck 结构使得模型的轻量化效果更加明显，相比于原始 YOLO v5s 模型，模型内存占用量减小 3.8 MB，参数量减少 2 128 784，浮点运算次数减少 2.6×10^9，单幅图像检测时间减少 2.6 ms。在 YOLO v5s_P234 模块的基础上同时添加 SimAM 注意力机制和 GSConv 模块 + SlimNeck 结构较单独添加 GSConv 模块 + SlimNeck 结构召回率提升 0.4 个百分点，平均精度均值提升 0.6 个百分点，其余指标没有变化。

最后在模型的主干网络中引入 Ghost 模块，与原始的 YOLO v5s 网络模型相比，精确率上升 3.1 个百分点，召回率上升 2.6 个百分点，平均精度均值上升 3.1 个百分点，模型内存占用量减小 7.7 MB，参数量减少 4 062 632，浮点运算次数减少 7.8×10^9，单幅图像检测时间减少 3.7 ms。添加了 Ghost 模块之后，模型使用更少数量的卷积核来生成蔗苗的特征图，精确率、召回率和平均精度均值均有所降低，尽管这些性能指标略微下降，但模型仍能够满足本文中对宿根蔗苗检测的需求。相反，模型的内存占用量、参数量、浮点运算次数和检测时间都显著减小，尤其对于移动端设备而言，这些方面的优化显得尤为重要。因此，综合考虑，本文的 YOLO v5s_P234_SGG 模型在满足宿根蔗苗目标检测需求的同时，也能够有效应对补种机在田间作业时对实时性的迫切需求。本文对不同改进算法在训练过程中的性能进行了比较，使用的数据集均为相同的蔗苗数据集。不同改进算法在训练过程中的性能表现如图 14 所示。

从图 14 可以看出，相较于原始的 YOLO v5s 模型，经过改进算法的精确率、召回率以及平均精度均值的曲线拟合速度更快，并且最终拟合时数值更高，这表明改进后的算法性能得到了提升。在精确率方面，删除大目标检测层，添加一个小目标检测层并对颈部网络进行优化具有最佳的效果。在召回率和平均精度均值方面，删除大目标检测层，添加一个小目标检测层并添加注意力机制的改进策略取得了最佳的效果。此外，尽管添加了 Ghost 模块后使得模型的精确率、召回率和平均精度均值有所下降，但各项指标仍然优于原始的 YOLO v5s 模型。这一结果表明，尽管 Ghost 模块的引入会对模型的检测精度产生一定影响，但其带来的模型轻量化优势使其在实际应用中仍具有较高的实用价值，满足在兼顾检测精度的情况下实现模型轻量化需求。

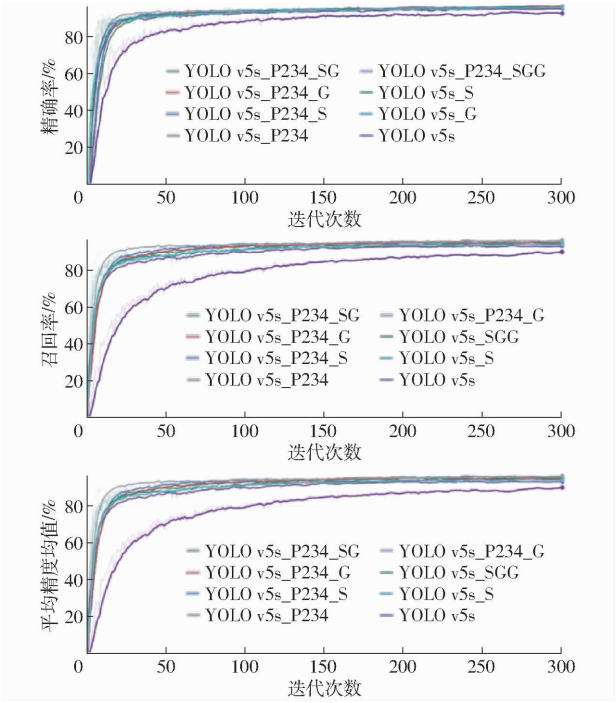

图 14　不同算法性能对比

Fig. 14　Comparison of performance of different algorithms

4.4　不同主流模型性能对比

将本文改进的 YOLO v5s 模型与目前常用的目标检测模型：Faster R－CNN、SSD、YOLO v3－tiny、YOLO v7－tiny、YOLO v8n 进行对比，实验结果如表 6 所示。通过表中各项参数可得，相较于其他主流的目标检测算法，本文提出的改进算法在具有更高的检测精度的同时还具有更小的内存占用量，更适合用于移动端部署。

表 6　不同主流模型检测结果对比

Tab. 6　Comparison of detection results of different main stream models

网络模型	精确率/%	召回率/%	平均精度均值/%	模型内存占用量/MB	检测时间/ms
Faster R－CNN	94.2	89.3	92.3	112.3	90.2
SSD	89.7	83.9	89.9	90.6	29.8
YOLO v3－tiny	87.5	79.4	83.7	17.4	7.4
YOLO v7－tiny	92.5	91.5	93.5	12.3	14.0
YOLO v8n	89.1	85.3	91.9	6.3	16.5
YOLO v5s_P234_SGG	95.8	95.2	97.1	6.7	14.8

4.5　算法优化后宿根蔗苗检测实例

由图 15 发现，原始 YOLO v5s 模型以及 YOLO v5s_G 都存在漏检情况。引入小目标检测层后，成功检测到了更多的蔗苗。进一步加入 SimAM 注意力机制后，检测效果显著改善，更多蔗苗得以被准确

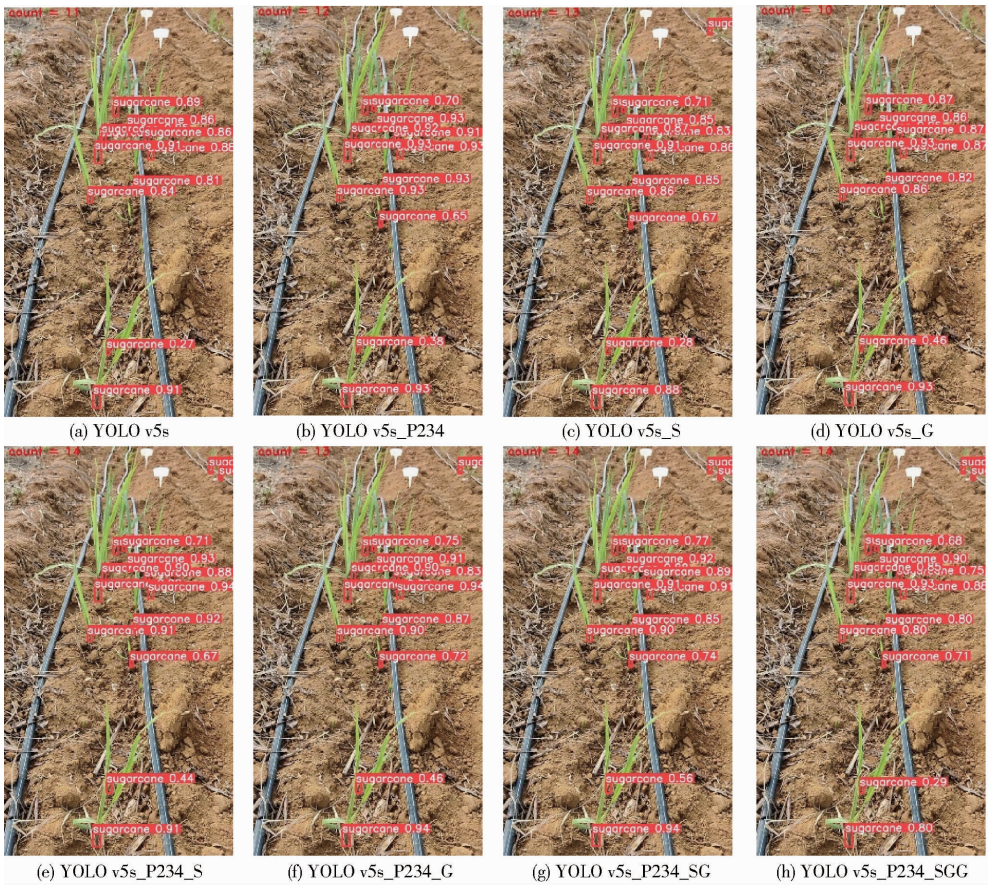

(a) YOLO v5s (b) YOLO v5s_P234 (c) YOLO v5s_S (d) YOLO v5s_G

(e) YOLO v5s_P234_S (f) YOLO v5s_P234_G (g) YOLO v5s_P234_SG (h) YOLO v5s_P234_SGG

图 15 不同算法检测实例对比

Fig. 15 Comparison of detection instances of different algorithms

识别。对于 YOLO v5s_P234_S、YOLO v5s_P234_G、YOLO v5s_P234_SG 3 个模型,它们能够检测出相同数量的蔗苗。在引入 GSConv + SlimNeck 结构的情况下,模型内存占用量得到有效减小,实现了对轻量化需求的满足。最终,YOLO v5s_P234_SGG 模型表现最为出色,检测出最多的蔗苗且效果最佳,同时模型内存占用量大幅减小,成功避免了漏检情况,进一步满足了对轻量化模型的需求。

5 双目定位算法设计

5.1 双目视觉基本理论

采用改进后的 YOLO v5s_P234_SGG 网络模型,通过双目摄像头对田间的宿根蔗苗进行识别和测距,以获取蔗苗的坐标和深度信息,进而计算出缺苗位置。

双目立体视觉测距原理[29-30]是依据人眼视觉系统建立的,通过左右相机观察到的图像差异来判断物体的距离。如图 16 所示,P 是空间中的一点,O_L 为左边摄像头的光心,O_R 为右边摄像头的光心,P 在左、右 2 个摄像机成像平面上的成像点分别为 P_L 与 P_R,x_L 与 x_R 分别为左右成像点的水平距离。根据三角形相似定理,深度计算公式为

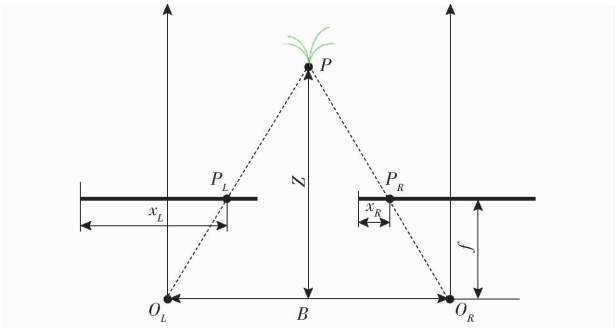

图 16 深度计算原理图

Fig. 16 Schematic of depth calculations

$$Z = \frac{Bf}{D} \tag{1}$$

其中

$$D = x_L - x_R \tag{2}$$

式中 Z——深度

B——2 个摄像头光心间距离,也称基线

f——摄像头焦距

D——左右成像点的水平距离差值

5.2 双目相机标定

在距离测量前,需要使用张正友标定[31]技术确定立体摄像机内外参数。该过程需要从不同方向拍摄棋盘格多幅图像,如图 17 所示,从不同角度拍摄 20 ~ 30 幅图像。最终得到左、右摄像头内参、畸变系数、旋转矩阵和平移向量,见表 7。

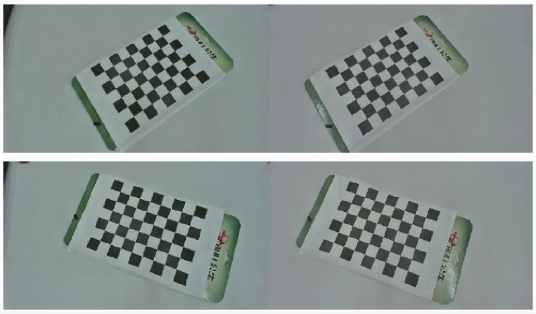

图 17　不同角度拍摄棋盘格标定板

Fig. 17　Photograph checkerboard calibration board from different angles

5.3　双目立体校正

为解决双目相机左右成像平面不共面或不对准的问题，采用了 Bouguet 算法[32]进行立体校正，立体校正原理及效果如图 18、19 所示。

5.4　基于 SGBM 算法的立体匹配

通过立体匹配技术，就可以明确左右图像中点的对应关系，从而得到视差，恢复点的三维信息，本文采用 SGBM[33]算法的立体匹配机制。SGBM 算法介于局部和全局立体匹配技术之间，在匹配效能上超越了局部方法，算法的复杂度没有全局立体匹配高，SGBM 算法协调了局部和全局立体匹配策略性能和精度方面特点[34]。流程如图 20 所示。

表 7　相机内外参数

Tab. 7　Parameters inside and outside camera

相机参数	左相机	右相机
内参	$\begin{bmatrix} 467.165\,2 & 0 & 322.681\,9 \\ 0 & 467.573\,4 & 236.783\,8 \\ 0 & 0 & 1 \end{bmatrix}$	$\begin{bmatrix} 466.734\,8 & 0 & 317.274\,7 \\ 0 & 467.148\,8 & 240.132\,2 \\ 0 & 0 & 1 \end{bmatrix}$
畸变系数	[0.060 2, −0.062 4, 0.002 6, −0.000 5, 0]	[0.058 2, −0.062 7, 0.003 4, −0.000 8, 0]
旋转矩阵	$\begin{bmatrix} 1.000\,0 & -0.000\,3 & -0.008\,5 \\ 0.000\,2 & 1.000\,0 & -0.001\,6 \\ 0.008\,5 & 0.001\,6 & 1.000\,0 \end{bmatrix}$	
平移向量	[−58.263 1　−0.260 2　0.579 6]	

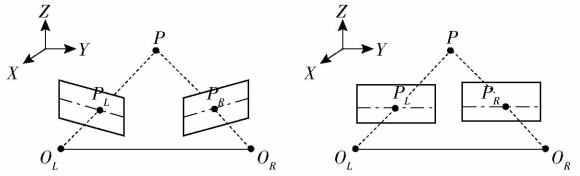

(a) 校正前　(b) 校正后

图 18　立体校正前后对比

Fig. 18　Comparison before and after stereoscopic correction

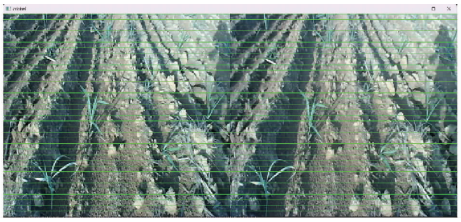

图 19　立体校正效果

Fig. 19　Stereo-corrected effect

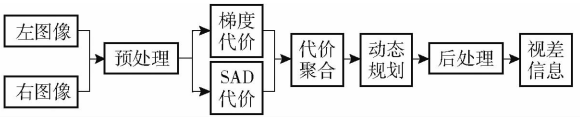

图 20　SGBM 算法流程图

Fig. 20　SGBM algorithm flowchart

使用 OpenCV 库中的 StereoSGBM_create 函数初始化一个 SGBM 立体匹配对象，并利用该对象的 compute 方法来执行立体匹配操作，该方法以 2 个灰度图像作为输入，计算出它们之间的视差从而得到视差图，如图 21 所示。



(a) 左相机拍摄图像　(b) SGBM视差图

图 21　相机拍摄图像与 SGBM 算法视差图

Fig. 21　Camera taken pictures with SGBM algorithm parallax map

5.5　图像深度信息计算

通过 SGBM 算法得到的视差图中每个像素值表示了对应点在左右图之间的位移。深度信息与视差之间的关系可以通过三角测量来建立。由式(2)深度计算公式可知，深度和视差之间存在反比关系，当视差增大时，深度减小，反之亦然。测距效果如图 22 所示。

5.6　双目视觉田间蔗苗定位精度

为了评估双目视觉算法在蔗苗定位中的精度，本文将双目摄像头固定在补种机前端，根据补种机工作机制，本文对前方 3 垄蔗苗进行距离测量。补种机作业示意图如图 23 所示。

根据双目立体视觉测距原理，可以计算出蔗苗至双目相机的深度方向距离，如图 23 中的 D_i 和 D_j，



图 22 双目测距效果图

Fig. 22 Binocular ranging renderings

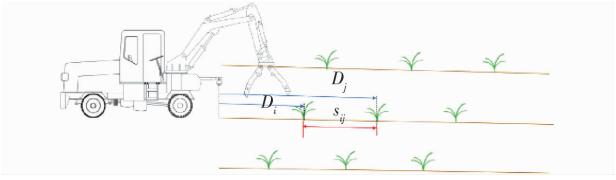

图 23 补种机作业示意图

Fig. 23 Schematic of operation of replanting machine

每组数据测量 3 次后取平均值作为最终的测量值。采用人工方法进行蔗苗与双目相机深度方向距离测量,将其作为实际距离。

将双目视觉算法测得的距离与实际距离进行比较,进而计算实验数据的绝对误差和相对误差等关键指标。实验结果如表 8 所示。

本文方法的测距效果受到物体与相机的距离变化的影响,该方法得到的测量值与实际距离之间存在误差,表明其准确性并非完全可靠。蔗苗距离较近时,实验数据误差较小;随着蔗苗与双目相机的距离增大,测量误差逐渐增加。造成这种现象的原因是当蔗苗距离双目相机较近时,相机对蔗苗的观测角度较大,使得成像平面内的有效像素点较多,因此,算法更容易找到最佳匹配点,从而保证了测距的准确性,此时测量值与实际距离之间的误差较小。然而,随着目标距离的增大,相机对蔗苗的观测角度减小,导致成像平面内的有效像素点逐渐减少,这就增加了匹配点的选择难度,从而使得测距的准确性下降,此时由于匹配点的不确定性增加,测距算法会出现更大的误差。相对误差最小值 0.03%,最大值 4.60%,平均相对误差为 0.97%。在补种机正常作业范围内,本文方法能够满足日常补种作业的误差需求。

6 结论

(1)通过实验测试,离线数据增强技术的应用对目标检测模型性能产生了显著的正面影响。相较于未经过增强的原始模型,精确率提升 1 个百分点,召回率上升 4.5 个百分点,平均精度均值增加 2 个百分点。离线数据增强有效地引入了更多样本的变化,使模型能够更好地学习不同场景、多样的姿态、光照条件以及拍摄距离等变化。这使得模型表现出更强的泛化性和鲁棒性,并在一定程度上缓解了训练时的过拟合问题。

表 8 双目测距定位实验数据与真实数据对比

Tab. 8 Comparison of binocular ranging and positioning test data with real data

蔗苗编号	蔗苗与相机间实际距离/cm	测量值/cm	绝对误差/cm	相对误差/%	平均相对误差/%
1	112.1	110.5	1.6	1.43	
2	113.1	114.5	1.4	1.24	
3	154.7	157.2	2.5	1.62	
4	113.1	114.5	1.4	1.24	
5	251.0	249.7	1.3	0.52	
6	262.1	260.3	1.8	0.69	
7	287.1	286.2	0.9	0.31	
8	303.2	302.3	0.9	2.17	
9	307.1	307.0	0.1	0.03	
10	331.0	326.0	5.0	1.51	
11	348.9	347.1	1.8	0.52	0.97
12	351.5	349.6	1.9	0.54	
13	377.6	375.2	2.4	0.64	
14	391.9	389.8	2.1	0.54	
15	416.0	421.6	5.6	1.35	
16	423.5	420.8	2.7	0.64	
17	439.6	438.5	1.1	0.25	
18	450.6	448.2	2.4	0.53	
19	472.6	470.8	1.8	0.38	
20	486.4	484.0	2.4	0.49	
21	505.7	515.9	10.2	2.02	
22	520.1	544.0	23.9	4.60	

(2)基于对 YOLO v5s 的优化,提出了一种改进的宿根蔗苗识别模型。实验结果表明,本文提出的改进模型相较于原始的 YOLO v5s 网络模型在精确率、召回率和平均精度均值上均有显著提升。模型内存占用量减小 7.7 MB,参数量减少 4 062 632,浮点运算次数减少 7.8×10^9,单幅图像的检测时间也降低 3.7 ms。这表明本文提出的改进模型在检测精度和效率上都取得了更好的性能,为将来在移动端部署该模型以及在宿根蔗苗实时补种方面提供了可靠的基础。

(3)完成了一系列双目测距的关键工作。实验表明,该方法检测到蔗苗与双目相机间距离的平均相对误差为 0.97%,最大相对误差为 4.60%,能够满足日常补种作业的误差需求。

参 考 文 献

[1] XU F, WANG Z, LU G, et al. Sugarcane ratooning ability: research status, shortcomings, and prospects[J]. Biology, 2021, 10(10): 1052.

[2] 杨荣仲,周会,梁强,等. 甘蔗家系宿根性分析[J]. 热带作物学报,2021,42(7):1932 - 1940.
YANG Rongzhong, ZHOU Hui, LIANG Qiang, et al. Analysis of ratooning ability for sugarcane families[J]. Chinese Journal of Tropical Crops, 2021, 42(7): 1932 - 1940. (in Chinese)

[3] 林兆里,张华,阙友雄,等. 甘蔗大型机械化收获模式对蔗地土壤物理性状和宿根蔗产量的影响[J]. 热带作物学报,2022,43(7):1417 - 1430.
LIN Zhaoli, ZHANG Hua, QUE Youxiong, et al. Effects of large scale mechanized sugarcane harvesting mode on soil physical properties of sugarcane fields and ratoon sugarcane yield[J]. Chinese Journal of Tropical Crops, 2022, 43(7): 1417 - 1430. (in Chinese)

[4] ESTEBAN D A A, DE SOUZA Z M, TORMENA C A, et al. Soil compaction, root system and productivity of sugarcane under different row spacing and controlled traffic at harvest[J]. Soil and Tillage Research, 2019, 187: 60 - 71.

[5] BERNACHE L, TEDESCO-OLIVEIRA D, OLIVEIRA L P, et al. Can basal cutting blade wear affect sugarcane regrowth?[J]. Engenharia Agrícola, 2020, 40: 53 - 60.

[6] MELO P L A, CHERUBIN M R, GOMES T C A, et al. Straw removal effects on sugarcane root system and stalk yield[J]. Agronomy, 2020, 10(7): 1048.

[7] 游建华,梁阗,樊保宁,等. 种茎直接补种对甘蔗宿根性的影响——以 2017 年广西融水苗族自治县试验为例[J]. 热带作物学报,2020,41(9):1790 - 1796.
YOU Jianhua, LIANG Tian, FAN Baoning, et al. Effects of direct replanting seed caneon ratoon sugarcane, a case study in Rongshui Miao Autonomous County, Guangxi in 2017[J]. Chinese Journal of Tropical Crops, 2020, 41(9): 1790 - 1796. (in Chinese)

[8] 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)

[9] 岑海燕,朱月明,孙大伟,等. 深度学习在植物表型研究中的应用现状与展望[J]. 农业工程学报,2020,36(9):1 - 16.
CEN Haiyan, ZHU Yueming, SUN Dawei, et al. Current status and future perspective of the application of deep learning in plant phenotype research[J]. Transactions of the CSAE, 2020, 36(9): 1 - 16. (in Chinese)

[10] 周学成,肖明玮,梁英凯,等. 基于改进 DeepLabv3 + 的火龙果园视觉导航路径识别方法[J]. 农业机械学报,2023,54(9):35 - 43.
ZHOU Xuecheng, XIAO Mingwei, LIANG Yingkai, et al. Navigation path recognition between dragon orchard using improved DeepLabv3 + network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(9): 35 - 43. (in Chinese)

[11] WANG J, GAO Z, ZHANG Y, et al. Real-time detection and location of potted flowers based on a ZED camera and a YOLO V4-tiny deep learning algorithm[J]. Horticulturae, 2021, 8(1): 21.

[12] WU T, ZHANG Q, WU J, et al. An improved YOLO v5s model for effectively predict sugarcane seed replenishment positions verified by a field re-seeding robot[J]. Computers and Electronics in Agriculture, 2023, 214: 108280.

[13] 李威,李尚平,潘家枫,等. 基于机器学习的中耕期甘蔗幼苗识别定位[J]. 中国农机化学报,2021,42(11):130 - 137.
LI Wei, LI Shangping, PAN Jiafeng, et al. Recognition and location of sugarcane seedlings in intertillage period based on machine learning[J]. Journal of Chinese Agricultural Mechanization, 2021, 42(11): 130 - 137. (in Chinese)

[14] 景亮,王瑞,刘慧,等. 基于双目相机与改进 YOLO v3 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 YOLO v3 algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(9): 34 - 39,25. (in Chinese)

[15] 李尚平,卞俊析,李凯华,等. 基于改进 YOLO v5s 的复杂环境下蔗梢分叉点识别与定位[J]. 农业机械学报,2023,54(11):247 - 258.
LI Shangping, BIAN Junxi, LI Kaihua, et al. Identification and height localization of sugarcane tip bifurcation points in complex environments based on improved YOLO v5s[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(11): 247 - 258. (in Chinese)

[16] 李柯泉,陈燕,刘佳晨,等. 基于深度学习的目标检测算法综述[J]. 计算机工程,2022,48(7):1 - 12.
LI Kequan, CHEN Yan, LIU Jiachen, et al. Survey of deep learning-based object detection algorithms[J]. Computer Engineering, 2022, 48(7): 1 - 12. (in Chinese)

[17] LI S, LI K, QIAO Y, et al. A multi-scale cucumber disease detection method in natural scenes based on YOLO v5[J]. Computers and Electronics in Agriculture, 2022, 202: 107363.
[18] 李尚平,李洋,张彪,等. 宿根蔗补种机均匀排种控制系统设计与试验[J]. 农业机械学报,2023,54(11):124 - 138.
LI Shangping, LI Yang, ZHANG Biao, et al. Design and experiment on control system of uniform seed seeding of ratoon cane reseeding machine[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(11): 124 - 138. (in Chinese)
[19] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779 - 788.
[20] YANG L, ZHANG R Y, LI L, et al. Simam: a simple, parameter-free attention module for convolutional neural networks[C]// International Conference on Machine Learning. PMLR, 2021: 11863 - 11874.
[21] LI H, LI J, WEI H, et al. Slim-neck by GSConv: a better design paradigm of detector architectures for autonomous vehicles[J]. arXiv Preprint, arXiv:2206.02424, 2022.
[22] HAN K, WANG Y, TIAN Q, et al. Ghostnet: more features from cheap operations[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 1580 - 1589.
[23] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolov4: optimal speed and accuracy of object detection[J]. arXiv Preprint, arXiv:2004.10934, 2020.
[24] HOWARD A G, ZHU M, CHEN B, et al. Mobilenets: efficient convolutional neural networks for mobile vision applications[J]. arXiv Preprint, arXiv:1704.04861, 2017.
[25] ZHANG X, ZHOU X, LIN M, et al. Shufflenet: an extremely efficient convolutional neural network for mobile devices[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 6848 - 6856.
[26] SIFRE L, MALLAT S. Rigid-motion scattering for texture classification[J]. arXiv Preprint, arXiv:1403.1687, 2014.
[27] CHOLLET F. Xception: deep learning with depthwise separable convolutions[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1251 - 1258.
[28] 高英,吴玉虹. 基于 YOLO v5s 的轻量化行人检测算法[J]. 现代电子技术,2023,46(22):151 - 158.
GAO Ying, WU Yuhong. Pedestrian detection algorithm based on YOLO v5s lightweight[J]. Modern Electronics Technique, 2023, 46(22): 151 - 158. (in Chinese)
[29] BAYAR G, BERGERMAN M, KOKU A B, et al. Localization and control of an autonomous orchard vehicle[J]. Computers and Electronics in Agriculture, 2015, 115: 118 - 128.
[30] CHEEIN F A A, CARELLI R. Agricultural robotics: unmanned robotic service units in agricultural tasks[J]. IEEE Industrial Electronics Magazine, 2013, 7(3): 48 - 58.
[31] ZHANG Z. Flexible camera calibration by viewing a plane from unknown orientations[C]// Proceedings of the Seventh IEEE International Conference on Computer Vision. IEEE, 1999: 666 - 673.
[32] TSAI R. A versatile camera calibration technique for high-accuracy 3D machine vision metrology using off-the-shelf TV cameras and lenses[J]. IEEE Journal on Robotics and Automation, 1987, 3(4): 323 - 344.
[33] 乔超,李帅康,洪荣晶,等. 基于 SGBM 算法的可转位刀片几何参数测量[J]. 工具技术,2023,57(9):162 - 165.
QIAO Chao, LI Shuaikang, HONG Rongjing, et al. Geometric parameter measurement of indexable insert based on SGBM algorithm[J]. Tool Engineering, 2023, 57(9): 162 - 165. (in Chinese)
[34] 许宝阳,高延峰,张泽玺,等. 基于双目视觉 SGBM 与 WLS 融合算法的茶叶嫩芽定位研究[J]. 智能计算机与应用,2024,14(1):29 - 34,42.
XU Baoyang, GAO Yanfeng, ZHANG Zexi, et al. Research on tea-buds location based on binocular vision with SGBM - WLS fusion algorithm[J]. Intelligent Computer and Applications, 2024, 14(1): 29 - 34,42. (in Chinese)