doi:10.6041/j.issn.1000-1298.2024.S1.032

基于深度学习的刺萼龙葵实时识别与计数方法

杜世峰　杨亚帅　程　曼　袁洪波
（河北农业大学机电工程学院，保定 071001）

摘要： 刺萼龙葵（Solanum rostratum Dunal，SrD）作为一种全球性有害入侵杂草，已在多个国家广泛分布，对当地的农业和生态系统安全造成了严重威胁。设计了一种深度学习网络模型（TrackSolanum）进行刺萼龙葵的现场实时检测、定位和计数。TrackSolanum网络模型由检测模块、跟踪模块和定位计数模块3部分构成，检测模块采用YOLO_EMA检测刺萼龙葵，跟踪模块利用DeepSort对连续视频帧中刺萼龙葵进行多目标追踪，定位计数模块通过质心定位和目标ID过线失效实现刺萼龙葵的定位和计数。YOLO_EMA模型在测试集上的精确率（Precision，P）、召回率（Recall，R）、平均精度(Average precision，AP)和帧率(Frame per second，FPS)分别达到93.7%、93.6%、97.8%和91 f/s，证明了其在刺萼龙葵现场实时检测任务中的有效性。为进一步验证YOLO_EMA网络的检测性能，对原始YOLO v8、YOLO_EMA以及本团队前期设计的YOLO_CBAM进行了消融试验。此外，讨论了刺萼龙葵不同生长阶段对检测效果的影响，在刺萼龙葵幼苗期，TrackSolanum模型的精确率、召回率、平均精度和帧率分别为95.9%，96.4%，98.6%和74 f/s。在刺萼龙葵生长期，TrackSolanum模型的精确率、召回率、平均精度和帧率分别为96.3%，95.4%，97.0%和71 f/s，均表现出良好的检测结果。现场试验结果表明，针对无人机飞行在2 m高度获取的视频，TrackSolanum模型的精确率和召回率分别达到94.2%和96.5%，多目标跟踪准确率（Multiple object tracking accuracy，MOTA）和IDF1分别达到80.6%和95.4%，计数失误率仅为3.215%。TrackSolanum模型可以用于刺萼龙葵的现场实时检测，并能够为刺萼龙葵入侵的危害评估和精准治理提供技术支持。

关键词： 入侵植物；刺萼龙葵；深度学习；TrackSolanum模型；实时检测；定位和计数
中图分类号： TP391.4　　**文献标识码：** A　　**文章编号：** 1000-1298(2024)S1-0295-11

Application of Deep Learning for Real-time Detection, Localization and Counting of *Solanum rostratum* Dunal

DU Shifeng　YANG Yashuai　CHENG Man　YUAN Hongbo
(*College of Mechanical and Electrical Engineering*, *Hebei Agricultural University*, *Baoding* 071001, *China*)

Abstract: Solanum rostratum Dunal (SrD) is a globally harmful invasive weed, that has spread widely in many countries, and poses a serious threat to local agriculture and ecosystem security. A deep learning network model, TrackSolunam, was designed to realize real-time detection, localization, and counting for SrD. The TrackSolanum network model consisted of three parts: a detection module, a tracking module, and a localization and counting module. The main body of the detection module consisted of YOLO v8 with the added EMA attention mechanism, which can detect SrD plants in real time. The main body of the tracking module was based on DeepSort, which enabled multi-object tracking based on the output of the detection module. It can identify the same SrD plant in consecutive video frames, avoiding repeated identification and counting. The localization module located the plants of SrD that were detected by searching for their centroids and can output the specific coordinates of the centroids in each frame, facilitating subsequent removal processes. The counting module avoided the issue of repeated counts by specific processing that the target ID was invalid after it crossed the detection line. The YOLO_EMA model achieved precision, recall, AP and FPS of 93.7%, 93.6%, 97.8% and 91 f/s, respectively, demonstrating its effectiveness in real-time detection tasks for SrD in the field. To further validate the detection performance of the YOLO_EMA network, an ablation study comparing the original YOLO v8, YOLO_EMA and the previously

收稿日期：2024－07－23　修回日期：2024－09－29
基金项目： 河北省高层次人才项目(C20231104)
作者简介： 杜世峰(1998—)，男，硕士生，主要从事智能化检测与自动控制研究，E-mail: 1772588070@qq.com
通信作者： 袁洪波(1980—)，男，副教授，博士，主要从事智慧农业及智能农业装备研究，E-mail: yuanhongbo222@163.com

designed YOLO_CBAM was conducted. Additionally, the impact of different growth stages of SrD on detection performance was discussed. During the seedling stage, the TrackSolanum model achieved precision, recall, AP, and FPS of 95.9%, 96.4%, 98.6% and 74 f/s, respectively. In the growth stage, the TrackSolanum model's precision, recall, AP, and FPS were 96.3%, 95.4%, 97.0% and 71 f/s, respectively, all demonstrating good detection results. The field test results showed that for the video acquired by UAV flight at 2 m height, the precision and recall of the TrackSolanum model reached 94.2% and 96.5%, respectively, and the MOTA and IDF1 reached 80.6%and 95.4%, respectively, with the counting error rate of only 3.215%. The TrackSolanum model can be used for real-time detection of SrD in the field, providing crucial technical support for hazard assessment and precise management of SrD invasion.

Key words: invasive alien plants; *Solanum rostratum* Dunal; deep learning; TrackSolanum model; real-time detection; localization and counting

0 引言

外来植物入侵威胁生物多样性、生态系统稳定性和人类健康,需要花费巨额资金去补救和根除植物入侵带来的影响,造成巨大的经济损失[1-3]。刺萼龙葵(Solanum rostratum Dunal,SrD)原产于北美洲,是一种世界性有害入侵杂草,目前已经入侵加拿大、中国、俄罗斯和澳大利亚等多个国家[4-5]。刺萼龙葵的叶子、浆果和根含有胆碱酯酶抑制物质,牲畜误食后会造成中毒和死亡[6]。此外,刺萼龙葵具有很高的抗旱能力,种子成熟后,浆果变干并裂开,散落大量种子。新收获的刺萼龙葵种子会处于休眠状态,在特定条件下会发芽[7],这给刺萼龙葵的防治和清除带来了非常大的困难。因此,对恶性入侵杂草刺萼龙葵进行实时检测、定位和计数研究,对于刺萼龙葵的危害评估和防治具有重要的意义。

杂草会与农田作物竞争阳光、水、营养物质和生存空间,导致作物生长受到阻碍,质量和产量下降。因此对杂草进行即时检测,实时了解杂草入侵程度,为后续的除草工作提供关键的数据是非常重要的[8]。杂草检测是实施杂草控制的重要前提,随着新模型的发展和计算能力的提高,基于深度学习的识别技术正在取代传统的机器学习技术实现实时检测杂草[9-10]。利用深度学习实现目标检测需要构建相应的数据集,地面无人车辆和无人机是2种流行的田间数据收集平台[11]。地面无人车作为农业领域的数据收集平台,具有较强的灵活性和适应性,能够在不同的地形条件下稳定工作[12-15]。相比于地面无人车,无人机平台的使用不仅提高了数据收集的效率,还提供了高质量的图像数据,从而为深度学习模型的训练提供了坚实的基础[16-19]。

对田间植物行计数能够为管理者提供数据支持以便更好制定管理策略。在植物计数方面,深度学习也得到了广泛应用[20-23]。

本团队前期利用U-Net卷积网络进行无人机图像分析,以评估刺萼龙葵入侵的程度[24]。由于无人机飞行高度较高,图像分辨率较低,这使得只有在植株生长到一定程度并已经对生态造成了一定程度破坏时,才能检测到刺萼龙葵。为了在初期阶段精确识别并清除刺萼龙葵,设计了YOLOv5_CBAM网络进行检测[25],并把此模型部署到了田间自主运行车辆上,进行实时检测。利用这些方法对刺萼龙葵进行检测的效果虽然得到了证明,但是无法实现精准计数和定位。因此,为了实现实时检测、定位和计数,本文设计一种深度学习网络模型(TrackSolanum),对无人机或无人车实时获取的视频进行处理,准确检测、跟踪和定位刺萼龙葵植株,并精准计数,以期为评估其入侵危害程度以及精准治理提供技术支持。

1 材料与方法

1.1 数据获取

通过调研,目前还没有针对刺萼龙葵的公开数据集。因此分别在2020年7月、2021年6月和2022年6月进行了刺萼龙葵图像数据采集。数据采集地点为河北省外来入侵植物(刺萼龙葵)监测点,其地理位置分别为监测点1(40°42′27″ N,114°45′6″ E),监测点2(40°39′58″ N,114°46′12″ E),监测点3(40°47′6″ N,114°42′7″ E)和监测点4(40°43′5″ N,114°43′13″ E),所有地址的刺萼龙葵均为自然生长状态。采集刺萼龙葵图像的设备包括NIKON D610型相机(Nikon,日本)和华为Nova3型手机、MAVIC AIR型无人机(DJI),其中相机和手机距离地面约1.2 m进行拍摄,无人机分别从2、3、5 m 3个高度进行拍摄,共获取有效图像513幅,其中NIKON D610型相机图像222幅,手机图像150幅,MAVIC AIR型无人机2 m高度图像45幅,3 m高度图像44幅,5 m高度图像52幅。表1为使用不同设备拍摄的刺萼龙葵分别处于幼苗期、生长期和开花结果期等多个不同生长阶段的图像示例。

1.2 数据预处理及数据集生成

由于拍摄设备、高度和刺萼龙葵生长阶段不同,不同图像中单株刺萼龙葵所占像素比例存在较大差异。无人机图像中幼苗期和生长期刺萼龙葵像素占整幅图

表1　成像设备、分辨率和图像示例

Tab. 1　Imaging devices, resolution and image examples

成像设备	分辨率/(像素×像素)	图像示例
NIKON D610型相机	6 016×4 016	
华为Nova3型手机	4 608×3 456	
MAVIC AIR型无人机	4 056×3 040	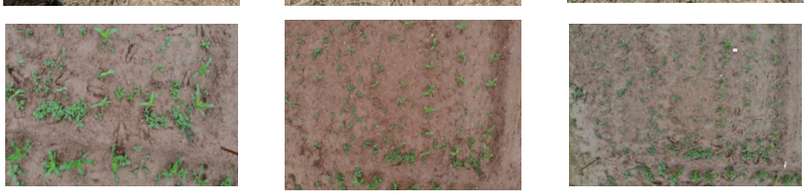

像的0.1%~0.6%，而相机拍摄的图像中生长期刺萼龙葵像素则可能达到93.6%。图像输入深度学习网络后往往会被调整尺寸，一般会被缩小，如YOLO v8会将图像尺寸调整为640像素×640像素。为了避免网络训练时对图像进行压缩从而丢失细节信息，对于刺萼龙葵植株像素占比较小的图像，应用前期设计的一种图像的重叠分割方法[25]，对原始图像进行切割处理。这种分割方法不仅保证了植株的完整性，同时也能增加数据集样本的数量，有助于提高模型的泛化能力和鲁棒性。对于刺萼龙葵像素占比较高的图像，采用数据增强的方式对其进行数据扩增，如图1所示。数据增强不但可以增加数据集中图像的数量，也能够使不同类型图像之间的数量接近，避免出现较大的偏差。经过处理，最终共获得图像10 094幅，图像中刺萼龙葵数量共有51 297株。

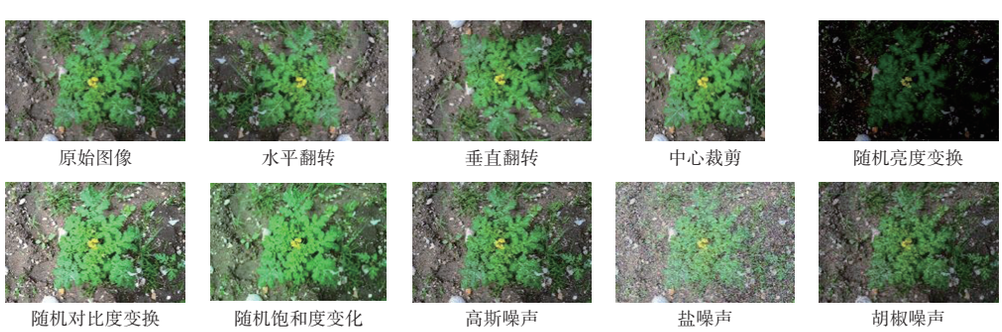

图1　数据增强方法和示例

Fig. 1　Data enhancement methods and examples

1.3　深度学习网络构建

1.3.1　TrackSolanum深度学习网络结构

本文设计了一种TrackSolanum网络用于刺萼龙葵的实时检测、定位和计数，该网络由检测模块、跟踪模块和定位计数模块3部分组成，如图2所示。检测模块的主体由加入了高效多尺度注意力机制(Efficient multi-scale attention module，EMA)的YOLO v8构成，它可以实时检测刺萼龙葵植株。跟踪模块的主体由DeepSort构成，基于检测模块输出的结果可以实现多目标跟踪，能够识别出连续视频帧中的同一刺萼龙葵植株，避免了重复识别和计数。定位模块通过搜索检测出的刺萼龙葵植株的质心来进行定位，并能够输出质心在每帧图像中的具体坐标，便于后续进行清除处理。计数模块基于检测线采用了目标ID过线失效方式进行计数，避免了重复计数问题的出现。

1.3.2　检测模块YOLO_EMA

YOLO(You only look once)将检测任务视为一个回归问题，通过单独的神经网络直接从图像中预测物体的边界框及相应的类别概率[26]。本团队前期基于YOLO v5结合卷积块注意力机制(Convolutional block attention module，CBAM)设计了一种刺萼龙葵幼苗检测网络模型YOLO_CBAM，为了增强模型的适用性使之能够准确检测不同生长阶段的刺萼龙葵植株，本文对该模型进行了改进，基于YOLO v8[27]和EMA[28]设计了TrackSolanum

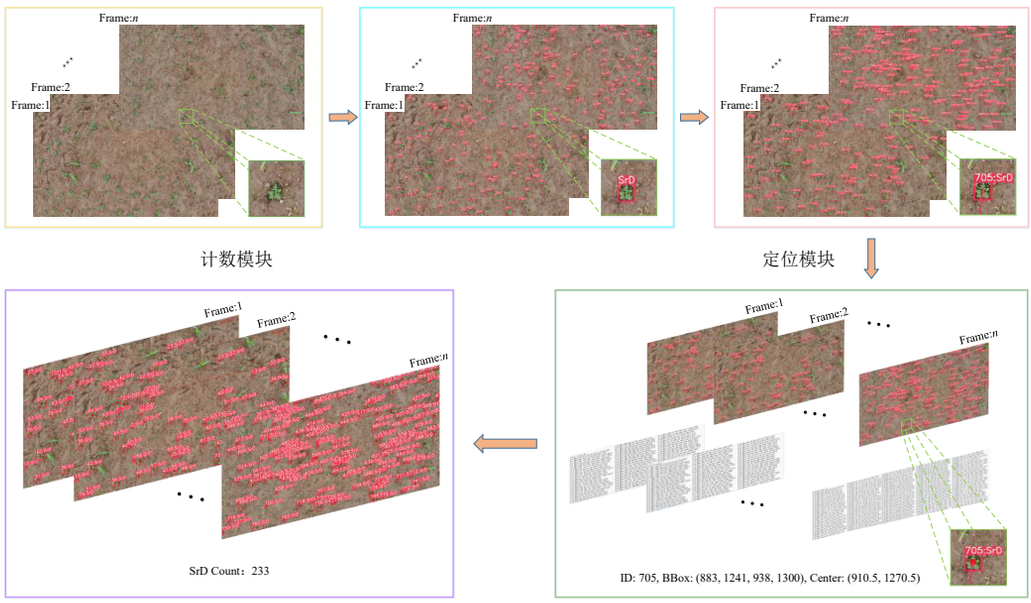

图2 TrackSolanum系统结构框图

Fig. 2 Block Diagram of trackSolanum system architecture

网络模型的检测模块YOLO_EMA，它由Backbone、Neck、Head 3部分组成，如图3所示。Backbone负责从输入图像中提取特征，这些特征是后续网络层进行目标检测的基础。Neck颈部网络位于主干网络和头部网络之间，它的作用是进行特征融合和增强。Head头部网络是目标检测模型的决策部分，负责产生最终的检测结果。

相较于YOLO v8模型，YOLO_EMA在Backbone和Neck部分引入EMA注意力机制，使网络具有更强的特征提取能力。EMA注意力机制可以将部分通道重构为批处理维度，并将通道维度分组为多个子特征，使空间语义特征在每个特征组内均匀分布。它通过编码全局信息来重新校准每个并行分支中的通道权重，并通过跨维度交互来捕获像素级别的关系，这样可以保留每个通道上的信息和减少计算开销。

1.3.3 跟踪模块DeepSort

当利用无人机或无人车等在运动中对刺萼龙葵进

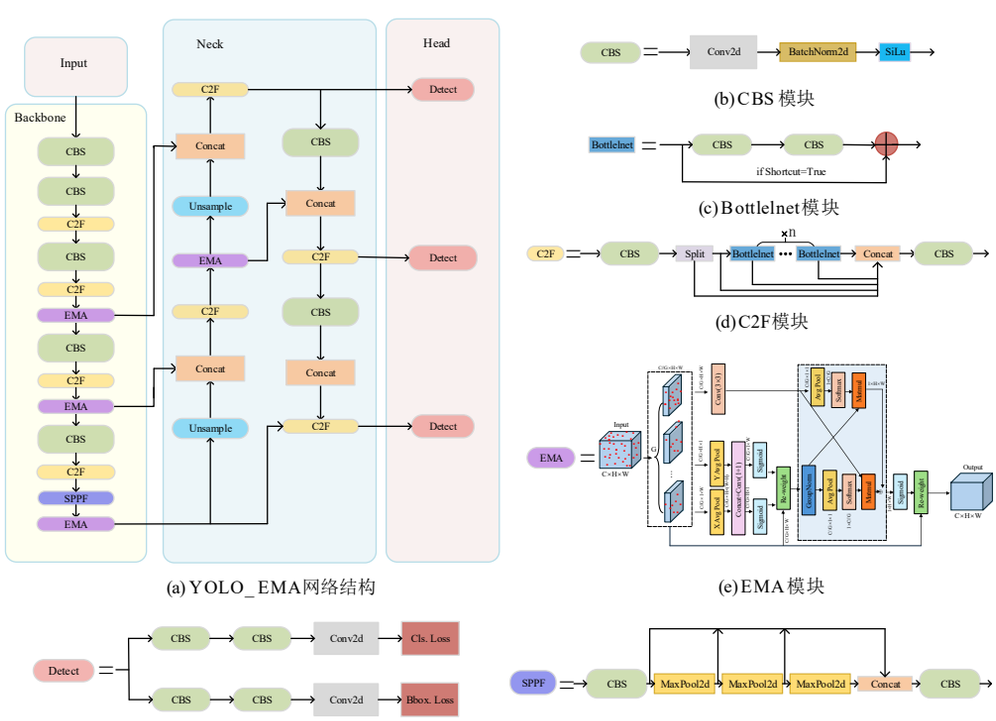

图3 YOLO_EMA网络结构图

Fig. 3 YOLO_EMA network structure diagram

行实时检测时，同一株刺萼龙葵可能会出现在相邻的视频帧中，如果不对个体进行区别就会导致重复计数，影响检测的准确性。为了解决这个问题，在图像中设置检测线，只对通过检测线的目标进行计数是一种常用的方法[29-31]。但是这种方法只能进行计数，不能对被检测的目标进行精准定位，而准确定位是目标清除的关键，如保证不被漏掉或重复喷药。因此，对检测到的刺萼龙葵植株进行精准的个体身份识别是实现准确计数和后期准确处理的关键。对连续视频帧中的同一个刺萼龙葵目标进行追踪是实现上述目标的前提。本文设计的TrackSolanum网络中的跟踪模块DeepSort会对检测模块YOLO_EMA输出的结果进行个体追踪，并为其分配唯一的身份ID。DeepSort是在简单在线实时跟踪（Simple online and realtime tracking，SORT）[32]的基础上发展起来的。SORT是一种简单、高效的多目标跟踪算法，但其关联度量相对简单，主要依赖于卡尔曼滤波和匈牙利算法，无法处理目标重叠和遮挡等复杂场景。为解决这些问题，DeepSort算法在SORT算法的基础上增加了级联匹配和新轨迹的确认，提高了目标关联的准确性，减少ID切换次数。DeepSort通过结合深度学习的外观特征提取和传统的卡尔曼滤波及匈牙利算法，实现了更加鲁棒的多目标跟踪，特别是在目标重叠、遮挡和外观变化的情况下，其结构如图4所示。

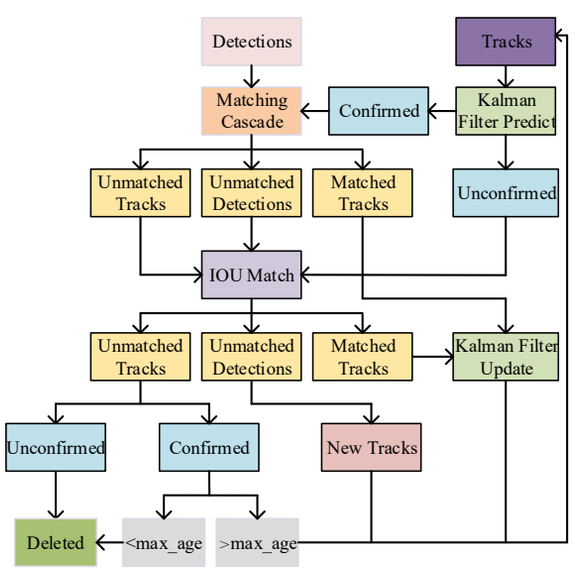

图4　DeepSort网络结构框图

Fig. 4　Diagram of DeepSort network structure

1.3.4　刺萼龙葵定位和计数模块

为了更全面地获取刺萼龙葵入侵的详细信息，TrackSolanum网络模型加入定位和计数功能，可以为后续治理工作提供更准确的数据信息。自然条件下，刺萼龙葵的植株具有对称性，叶片是互生的。前期研究表明，刺萼龙葵植株最小包围矩形的几何中心与其植株中心基本重合，如图5所示。检测模块YOLO_EMA会输出检测到的刺萼龙葵植株的边界框，因此本文采用边界框的几何中心位置作为该株刺萼龙葵在图像中的坐标位置，定位坐标的计算公式为

$$\begin{cases} x_0 = (x_1 + x_2)/2 \\ y_0 = (y_1 + y_2)/2 \end{cases} \tag{1}$$

式中　x_0、y_0——边界框几何中心横、纵坐标

x_1、y_1——边界框左上角横、纵坐标

x_2、y_2——边界框右下角横、纵坐标

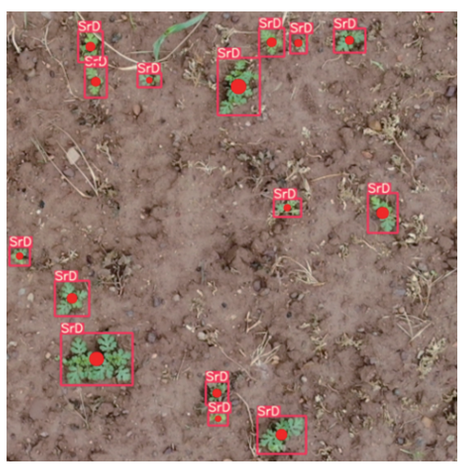

图5　刺萼龙葵定位示例

Fig. 5　Positioning examples of *Solanum rostratum* Dunal

针对视频中每帧图像，检测模块YOLO_EMA会检测出刺萼龙葵植株，跟踪模块DeepSort为检测出的每株刺萼龙葵分配唯一的身份ID。理想情况下，相邻的视频帧中同株刺萼龙葵的身份ID应该保持不变。但是，在检测和跟踪过程中由于视角的变化可能会导致同一个目标在相邻帧中被识别为不同的目标并为其分配新的ID，直接根据ID编号计算刺萼龙葵的数量就会导致计数不准确。因此，本文设计了一种ID过线失效法来进行刺萼龙葵的计数。视频中每帧的相同位置设置有一条检测线，当刺萼龙葵检测框被检测线穿过时进行一次计数，然后使其ID失效，后面的视频帧将不再对其进行计数，计数方法如图6所示。这种计数方式避免了重复计数，也不会受到无人机或地面无人车行进速度变化导致的同一目标的检测框在连续视频帧中重复压线的影响。视频中刺萼龙葵的总数量计算公式为

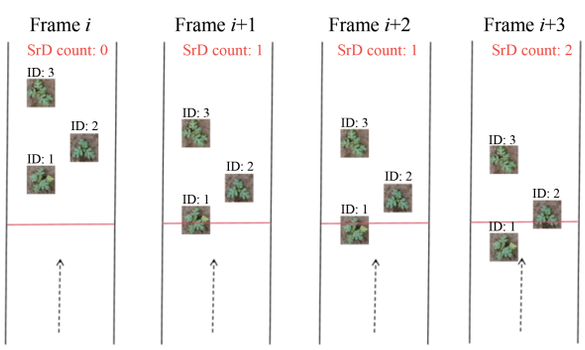

图6　刺萼龙葵株数计算方法示意图

Fig. 6　Schematic of calculating number of *Solanum rostratum* Dunal plants

$$Z = \sum_{i=0}^{n} C_i \tag{2}$$

式中 Z——累计的刺萼龙葵数量

C_i——第i帧中通过检测线的刺萼龙葵数量

n——视频的总帧数

1.4 网络模型运行环境及超参数设定

本文中深度学习模型TrackSolanum基于Pytorch 2.1.2的深度学习框架进行构建，程序代码由Python编写。模型运行的计算机CPU型号为12th Gen Intel(R) Core(TM) i9-12900K，GPU型号为NVIDIA GeForce RTX 4090，CUDA版本为11.8，计算机操作系统为Microsoft Windows 11。

模型训练时批量大小(Batch_size)设置为32，训练数据增强Mosaic设置为10，优化器选择SGD，最大迭代周期(Epoch)设置为300。为了确保试验中模型效果的公平性和可比性，在各个模型训练过程没有使用预训练权重。训练输入图像尺寸设置为640像素×640像素。总数据集共有10 094幅图像，数据集采用8∶1∶1的比例随机划分，其中训练集包含8 077幅图像，验证集包含1 010幅图像，测试集包含1 007幅图像。

1.5 网络模型性能评价指标

1.5.1 检测模块YOLO_EMA评价指标

使用精确率(Precision，P)、召回率(Recall，R)、平均精度(Average precision，AP)和帧率(Frame per second，FPS)作为YOLO_EMA模块性能的评价指标。Precision是模型检测出的刺萼龙葵中，真正刺萼龙葵所占比例。Recall是实际刺萼龙葵总数量中，被正确检查出的比例。AP是不同召回率上的平均精确度，也可以看作Precision-Recall曲线包围区域的面积。AP是目标检测算法的重要评估指标，AP值越高，表明该目标检测模型在当前数据集上检测效果越好。检测速度可以通过FPS来评估，FPS表示每秒能够处理的图像的数量。

1.5.2 追踪模块DeepSort评价指标

追踪模块DeepSort的性能可以用身份切换次数(Identificationswitch，IDSW)、多目标跟踪准确率(Multiple object tracking accuracy，MOTA)和识别平均数比率(Identification F1，IDF1)进行评价。IDSW是指视频跟踪中刺萼龙葵ID切换的次数，其值越小越好。MOTA是一种广泛使用的评价指标，用于衡量多目标跟踪算法的整体性能，它综合考虑3种错误类型：误检、漏检和身份切换，MOTA越接近于1表示跟踪器性能越好。IDF1是评估多目标跟踪中身份保持一致性的重要指标，IDF1代表被检测和跟踪的目标中被分配正确的ID的比例，IDF1数值越接近1表示其跟踪特定目标的精度越高。MOTA和IDF1计算公式为

$$\begin{cases} R_{\mathrm{MOTA}} = 1 - \dfrac{\sum_t (F_{\mathrm{Nt}} + F_{\mathrm{pt}} + I_{\mathrm{DSWt}})}{\sum_t G_{Tt}} \times 100\% \\ N_{\mathrm{IDF1}} = \dfrac{2I_{\mathrm{DTP}}}{2I_{\mathrm{DTP}} + I_{\mathrm{DFN}} + I_{\mathrm{DFP}}} \times 100\% \end{cases} \tag{3}$$

式中 R_{MOTA}——多目标跟踪准确率，%

N_{IDF1}——识别平均数比率，%

t——当前视频帧索引号

F_{Pt}——第t帧中被误识别为刺萼龙葵数量

F_{Nt}——第t帧中未被检测到的刺萼龙葵数量

G_{Tt}——第t帧中被检测到的刺萼龙葵总数

I_{DSWt}——第t帧中刺萼龙葵ID发生切换数量

I_{DTP}——整段视频中正确跟踪的刺萼龙葵数量

I_{DFP}——整段视频中错误跟踪的刺萼龙葵数量

I_{DFN}——整段视频跟踪过程中丢失的刺萼龙葵数量

1.5.3 计数准确性评价指标

刺萼龙葵计数性能可以用失误率(Error rate，ER)进行评价，ER计算公式为

$$Q_{\mathrm{ER}} = \frac{|G - T|}{T} \times 100\% \tag{4}$$

式中 Q_{ER}——失误率，%

G——对视频中刺萼龙葵数量的模型统计结果

T——对视频中刺萼龙葵数量的人工统计结果

1.6 现场试验

为了验证设计的TrackSolanum网络模型在实际应用中的效果，2024年6月23日在河北省张家口市一个刺萼龙葵入侵地点(40°46′57″ N，114°42′04″ E)进行了现场测试。试验场地内刺萼龙葵处于自然生长状态，利用MAVIC AIR型无人机采集了现场视频数据，飞行时摄像头与地面垂直，分别采用2 m和3 m 2种飞行高度。

2 结果

2.1 测试集检测结果

将测试集中1 007幅图像输入训练完成的TrackSolanum网络模型，并输出检测模块YOLO_EMA的检测结果。测试集中共有5 871株刺萼龙葵，模型共检测出5 865株，其中有369株检测错误，Precision为93.7%。所有刺萼龙葵中，模型正确检测出5 496株，Recall为93.6%，AP为97.8%。模型检测1 007幅图像共用时88.56 s，检测速度为91 f/s。图7为部分测试集图像检测效果，可以看出TrackSolanum网络能够适用于不同设备拍摄的图像，并能够用于刺萼龙葵各生长阶段植株的检测。

2.2 现场试验结果

现场试验过程中无人机采集的视频分辨率为3 840像素×2160像素，帧率为30 f/s。现场试验时刺萼龙葵植株大部分属于六叶以上的生长期，也包含少部分

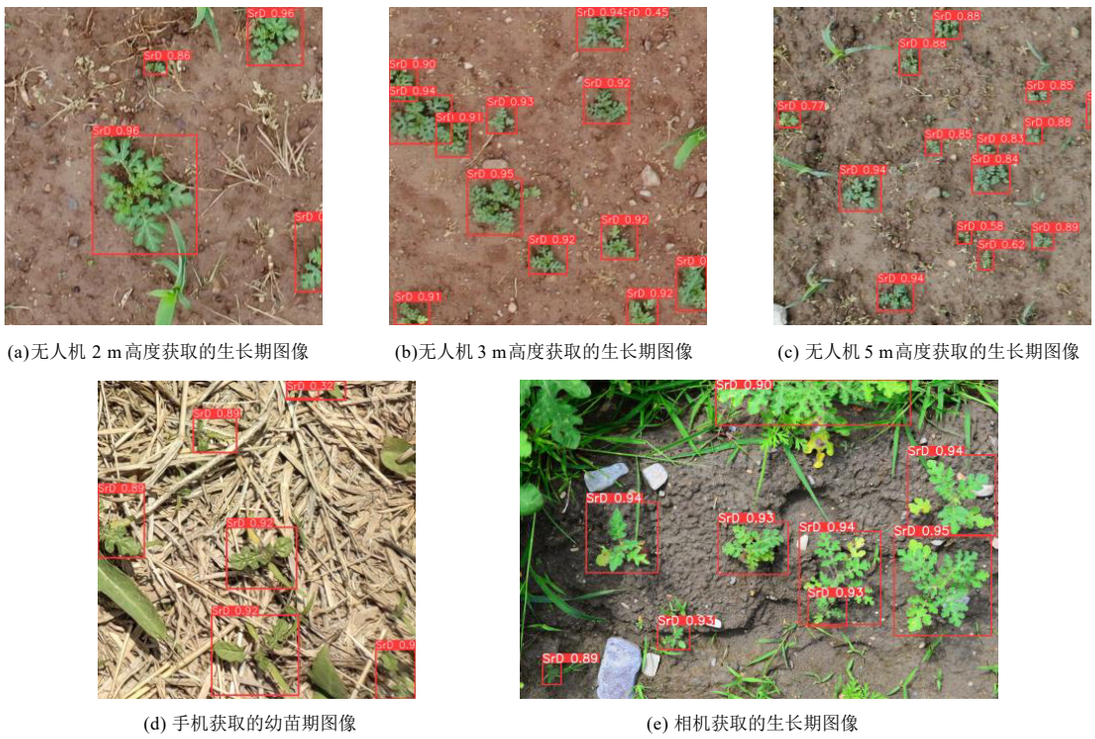

(a)无人机 2 m高度获取的生长期图像　(b)无人机 3 m高度获取的生长期图像　(c) 无人机 5 m高度获取的生长期图像

(d) 手机获取的幼苗期图像　(e) 相机获取的生长期图像

图 7　部分测试集检测结果

Fig. 7　Partial test set detection results

六叶以下的幼苗期。试验过程中分别在 2 m和 3 m高度各获取了 4 段视频，其中 2 m高度视频总时长为 106 s，3 m高度视频总时长为 95 s。表 2 所示为现场视频的测试结果。2 m高度视频中对刺萼龙葵检测的 Precision 和 Recall 分别达到了 94.2% 和 96.5%；在连续视频帧中刺萼龙葵的追踪性能指标 MOTA 和 IDF1 分别达到 80.6% 和 95.4%，IDSW 为 36 次；ER 为 3.215%。3 m高度视频中对刺萼龙葵检测的 Precision 和 Recall 分别为 82.5% 和 92.6%；在连续视频帧中刺萼龙葵的追踪性能指标 MOTA 和 IDF1 分别达到 68.9% 和 87.8%，IDSW 为 10 次；ER 为 5.643%。从对比结果可以看出，针对无人机飞行在 2 m高度时获取视频，利用 TrackSolanum 模型对刺萼龙葵进行检测、定位和计数的结果均优于飞行在 3 m高度时。图 8 所示为现场试验可视化结果，左侧为网络检测和计数结果，右侧为对目标定位的坐标结果，定位结果包含目标 ID，检测框坐标和中心点坐标。

表 2　不同飞行高度视频的试验结果

Tab. 2　Experimental results for videos at different flight altitudes

视频序号	飞行高度/m	用时/s	Precision/%	Recall/%	MOTA/%	IDF1/%	IDSW/次	*T*	*G*	ER/%
1	2	26	92.2	93.0	72.9	92.6	32	229	220	3.930
2	2	25	93.0	97.2	84.6	95.1	29	506	494	2.371
3	2	21	96.8	97.6	80.6	97.2	35	246	233	5.285
4	2	34	94.9	98.3	84.2	96.8	48	471	465	1.274
平均值		26.5	94.2	96.5	80.6	95.4	36	363	353	3.215
5	3	21	87.7	91.4	69.7	89.5	13	70	63	10.000
6	3	50	75.7	95.3	61.6	85.0	15	173	167	3.468
7	3	14	84.8	90.5	75.3	87.6	5	71	74	4.225
8	3	10	81.6	93.0	69.0	88.9	7	41	39	4.878
平均值		23.75	82.5	92.6	68.9	87.8	10	89	86	5.643

3　讨论

3.1　TrackSolanum 网络检测刺萼龙葵性能分析

为了验证本文提出的 TrackSolanum 网络模型中 YOLO_EMA 模块的有效性，进行了消融试验。与原始 YOLO v8n、YOLO_EMA 和本团队之前设计的 YOLO_CBAM 3 个网络基于相同的训练集和测试集进行比较。表 3 为消融试验结果。从表 3 可看出，在 YOLO v8n 网络中加入 EMA 之后，YOLO_EMA 模型 Precision、AP 和 FPS 都有所提升，其中 FPS 提升较为明显，从 72 f/s 提升到 91 f/s。与 YOLO v8n 相比，YOLO_EMA 模型虽然加入了 EMA，但是模型内存占用量并没有增加，Recall 也没有降低。此外，与 YOLO v8n 相比，YOLO_EMA 更加专注于目

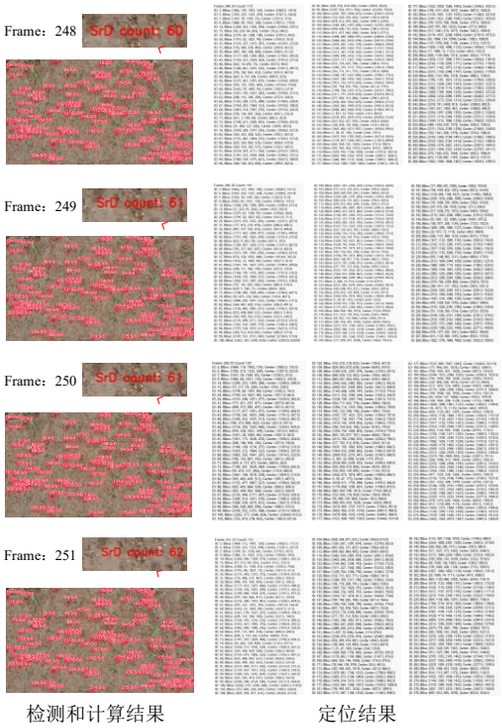

图 8 现场试验检测、定位和计数结果可视化

Fig. 8 Visualization of field test detection, positioning and counting results

标的局部特征，比如对刺萼龙葵叶片边缘的检测更加精准，如图 9 所示。

与 YOLO_CBAM 相比，YOLO_EMA 模型虽然 Recall 有所降低，但是 Precision 和 AP 都有提升，FPS 提升更加明显，达到了 YOLO_CBAM 的 1.72 倍。此外，YOLO_EMA 模型的内存占用量只是 YOLO_CBAM 的 42.28%，它更容易被部署在边缘设备中进行现场检测。

表 3 消融试验结果

Tab. 3 Results of ablation experiments

模型	模型内存占用量/MB	Precision/%	Recall/%	AP/%	FPS/(f·s^{-1})
YOLO v8n	6.3	92.2	92.6	97.2	72
YOLO_EMA	6.3	93.7	93.6	97.8	91
YOLO_CBAM	14.9	92.9	95.6	95.4	53

3.2 刺萼龙葵不同生长阶段对检测效果的影响

刺萼龙葵叶片在幼苗期和生长期叶片形状存在一定的差异，刺萼龙葵幼苗存在 2 片剑型子叶，而生长期叶片已经变成了完全的羽状叶片，如图 10 所示。虽然在训练 TrackSolanum 网络模型时采用了混合训练集，但是在检测幼苗期和生长期的刺萼龙葵时性能是否接近还需进一步分析。因此，将测试集细分为幼苗期和生长期 2 个子集分别进行测试，表 4 为测试结果。从表 4 可以看出，在刺萼龙葵幼苗期，TrackSolanum 模型的 Precision、Recall、AP 和 FPS 分别为 95.9%，96.4%，98.6% 和 74 f/s。在刺萼龙葵生长期，TrackSolanum 模型的 Precision，Recall，AP 和 FPS 分别为 96.3%，95.4%，97.0% 和 71 f/s。结果表明，无论是在幼苗期还是生长期，TrackSolanum 模型的检测性能是一致的，都表现出较高的精确率和召回率。这表明在不同生长期的刺萼龙葵植株的检测中，TrackSolanum 模型都能有效识别目标，显示出其良好的

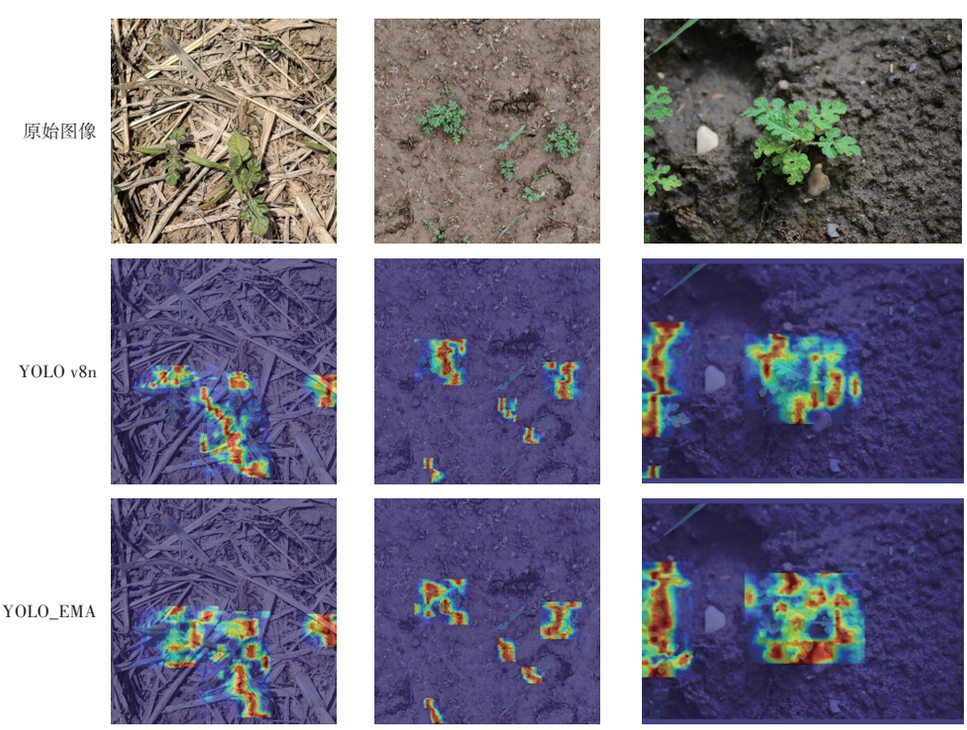

图 9 YOLO_EMA 和 YOLO v8 在检测刺萼龙葵过程中的特征识别热力图

Fig. 9 Heatmaps of feature recognition in detection of *Solanum rostratum* Dunal using YOLO_EMA and YOLO v8

通用性和稳定性。



(a) 幼苗期　　(b) 生长期

图 10　刺萼龙葵幼苗期和生长期

Fig. 10　Seedling stage and growth stage of Solanum rostratum Dunal

表 4　不同生长期的检测结果

Tab. 4　Detection results at different growth stages

生长期	数量/幅	Precision/%	Recall/%	AP/%	FPS/(f·s^{-1})
幼苗期	230	95.9	96.4	98.6	74
生长期	183	96.3	95.4	97.0	71

3.3　现场测试结果分析

现场测试过程中，发现植被密度、植株尺寸和遮挡程度对检测、追踪及计数结果影响较大，如图 11 所示。当刺萼龙葵植株周围没有其它植物时，检测和追踪效果较好，如图 11a 所示。当刺萼龙葵幼苗较小时，部分视频帧中会出现跟踪失效或无法检测的情况，如图 11b 所示。当刺萼龙葵呈现出密集生长状态时，可能会将多株刺萼龙葵识别为一株，甚至产生 ID 切换，如图 11c 所示。当有其他作物遮挡刺萼龙葵时，也会出现跟踪失效或者 ID 切换的情况，如图 11d 所示。

3.4　TrackSolanum 网络模型应用性分析

TrackSolanum 网络对不同高度下无人机拍摄的刺萼龙葵视频进行了检测、定位和计数，取得了不错的成果，体现了 TrackSolanum 网络的实时性和高效性。虽然现场试验利用无人机获取的视频进行了测试，但是 TrackSolanum 网络模型同样可以被部署到无人车上，这对于实现在检测的同时进行清除具有重要的现实意义。在实际场景中应用 TrackSolanum 网络模型需要注意几个方面：①在刺萼龙葵的不同生长阶段，其植株的尺寸和密度都会影响检测效果。尤其是在生长期植株过于密集，虽然能够实现较为准确的检测结果，但是会显著增加跟踪和定位的难度，这不利于危害评估和实时清理。为了获得较好的应用效果，在刺萼龙葵生长至具有明显生理特征且没有完全进入生长期时应用较为合适。②如果采用无人机实时检测的方式，则需要考虑无人机

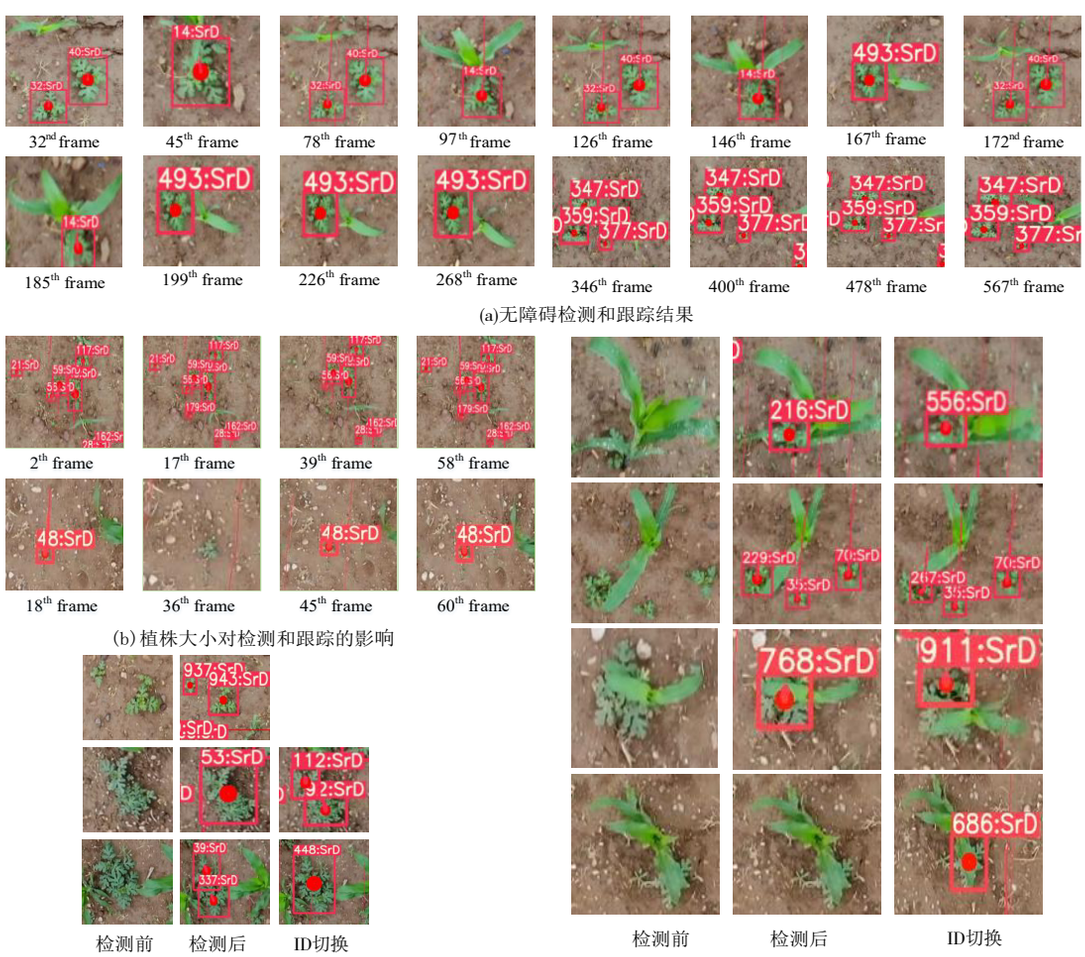

(a)无障碍检测和跟踪结果

(b) 植株大小对检测和跟踪的影响

(c) 植被密度对探测和跟踪的影响

(d) 作物遮挡对检测和跟踪的影响

图 11　刺萼龙葵不同生长情况对现场测试结果的影响

Fig. 11　Effect of different growth conditions of *Solanum rostratum* Dunal on field test results

的飞行高度。无人机飞行高度过高可能导致图像分辨率不足,无法准确检测目标。无人机飞行高度过低则可能导致视野范围过小,影响检测效率。无人机飞行高度控制在2~3 m之间较好,这样能够平衡分辨率和检测效率,并取得较好的检测效果。③搭载平台的行进速度也可能会对检测效果造成影响。平台运动速度过快可能导致图像模糊,影响检测精度;平台速度过慢则可能导致数据采集效率低下,影响实时检测的实用性。在确保时效性的前提下,应控制搭载平台的运行速度,便于后续的图像处理和目标检测。④光照条件可能会影响检测的效果。强光、阴影和不同的光照角度都会对图像质量产生影响,从而影响检测效果。现场应用时应该尽量选择在光照均匀、天气晴朗的条件下进行,避免强光和阴影对图像质量造成影响。

4 结束语

提出了一种深度学习模型TrackSolanum,可以实现恶性入侵杂草刺萼龙葵的实时检测、定位和计数。TrackSolanum模型由检测模块YOLO_EMA、追踪模块DeepSort和定位计数模块构成,能够基于视频流检测刺萼龙葵植株,为其分配唯一的身份ID并输出其在每帧图像中的坐标定位。利用无人机拍摄的现场视频进行了试验验证,试验结果显示TrackSolanum能够检测幼苗期和生长期的刺萼龙葵植株,无人机飞行在2 m高度获取的视频中,刺萼龙葵检测性能指标Precision和Recall分别达到94.2%和96.5%;追踪性能指标IDSW、MOTO和IDF1分别达到36次、80.6%和95.4%。本文设计的TrackSolanum网络不但能够用于刺萼龙葵的现场检测,也能够用于其它杂草或农作物幼苗的实时检测和处理。

参 考 文 献

[1] LARSON E R, GRAHAM B M, ACHURY R, et al. From eDNA to citizen science: emerging tools for the early detection of invasive species[J]. Frontiers in Ecology and the Environment, 2020, 18(4): 194 - 202.

[2] YANG B, CUI M M, DU Y Z, et al. Influence of multiple global change drivers on plant invasion: additive effects are uncommon[J]. Frontiers in Plant Science, 2022, 13: 1020621.

[3] 吕飞南. 外来入侵植物刺萼龙葵潜在分布区预测及化学成分研究[D]. 沈阳:沈阳农业大学, 2020.
LÜ Feinan. Studies on the potential suitable distribution areas and chemical constituents of the invasive plant Solanum rostratum[D]. Shenyang:Shenyang Agricultural University, 2020. (in Chinese)

[4] ZHAO D D, WANG X, CHEN J C, et al. Selection of reference genes for qPCR normalization in buffalobur (Solanum rostratum Dunal)[J]. Scientific Reports, 2019, 9(1): 6948.

[5] ABU-NASSAR J, MATZRAFI M. Effect of herbicides on the management of the invasive weed Solanum rostratum Dunal (Solanaceae)[J]. Plants, 2021, 10(2): 284.

[6] WEI S, ZHANG C, CHEN X, et al. Rapid and effective methods for breaking seed dormancy in Buffalobur (*Solanum rostratum*)[J]. Weed Science, 2010, 58(2): 141 - 146.

[7] ABU-NASSAR J, GAL S, SHTEIN I, et al. Functional leaf anatomy of the invasive weed *Solanum rostratum* Dunal[J]. Weed Research, 2022, 62(2): 172 - 180.

[8] XU K, SHU L, XIE Q, et al. Precision weed detection in wheat fields for agriculture 4.0: a survey of enabling technologies, methods, and research challenges[J]. Computers and Electronics in Agriculture, 2023, 212: 108106.

[9] LIU B, BRUCH R. Weed detection for selective spraying: a review[J]. Current Robotics Reports, 2020(1): 19 - 26.

[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] GAO J, LIAO W, NUYTTENS D, et al. Cross-domain transfer learning for weed segmentation and mapping in precision farming using ground and UAV images[J]. Expert Systems with Applications, 2024, 246: 122980.

[12] KAZMI W, GARCIA-RUIZ F J, NIELSEN J, et al. Detecting creeping thistle in sugar beet fields using vegetation indices[J]. Computers and Electronics in Agriculture, 2015, 112: 10 - 19.

[13] WENDEL A, UNDERWOOD J, WALSH K. Maturity estimation of mangoes using hyperspectral imaging from a ground based mobile platform[J]. Computers and Electronics in Agriculture, 2018, 155: 298 - 313.

[14] KOUNALAKIS T, TRIANTAFYLLIDIS G A, NALPANTIDIS L. Deep learning-based visual recognition of rumex for robotic precision farming[J]. Computers and Electronics in Agriculture, 2019, 165: 104973.

[15] JU J, CHEN G, LV Z, et al. Design and experiment of an adaptive cruise weeding robot for paddy fields based on improved YOLOv5[J]. Computers and Electronics in Agriculture, 2024, 219: 108824.

[16] TORRES-SÁNCHEZ J, MESAS-CARRASCOSA F J, JIMÉNEZ-BRENES F M, et al. Early detection of broad-leaved and grass weeds in wide row crops using artificial neural networks and UAV imagery[J]. Agronomy, 2021, 11(4): 749.

[17] 杨红艳, 杜健民.基于无人机遥感与深度学习的芨芨草识别方法[J].内蒙古工业大学学报(自然科学版), 2024, 43(3): 250 - 256.
YANG Hongyan, DU Jianmin. Achnatherum splendens identification based on uav remote sensing and deep learning[J]. Journal of Inner Mongolia University of Technology(Natural Science Edition), 2024, 43(3): 250 - 256. (in Chinese)

[18] 曹英丽,赵雨薇,杨璐璐,等.基于改进DeepLabv3+的水稻田间杂草识别方法[J].农业机械学报, 2023, 54(12): 242 - 252.
CAO Yingli, ZHAO Yuwei, YANG Lulu, et al. Weed identification method in rice field based on improved DeepLabv3+ [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(12): 242 - 252.(in Chinese)

[19] 王生生, 王顺, 张航, 等. 基于轻量和积网络及无人机遥感图像的大豆田杂草识别[J]. 农业工程学报, 2019, 35(6): 81 - 89.
WANG Shengsheng, WANG Shun, ZHANG Hang, et al. Soybean field weed recognition based on light sum-product networks and UAV remote sensing images[J]. Transactions of the CSAE , 2019, 35(6): 81 - 89.(in Chinese)

[20] CHEN Y, XIN R, JIANG H Y, et al. Refined feature fusion for in-field high-density and multi-scale rice panicle counting in UAV images [J]. Computers and Electronics in Agriculture, 2023, 211: 108032.

[21] 王金鹏,何萌,甄乾广,等.基于改进COF-YOLO v8n的油茶果静态与动态检测计数方法[J].农业机械学报, 2024, 55(4): 193 - 203.
WANG Jinpeng, HE Meng, ZHEN Qianguang, et al. *Camellia oleifera* fruit static and dynamic detection counting based on improved COF-YOLO v8n[J].Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(4): 193 - 203. (in Chinese)

[22] 肖伸平,赵倩颖,曾甲元,等. 基于YOLO-DCL的复杂环境油茶果遮挡检测与计数研究[J]. 农业机械学报, 2024,55(10):318 - 326.
XIAO Shenping, ZHAO Qianying, ZENG Jiayuan, et al. *camellia oleifera* fruits occlusion detection and counting in complex environments based on improved YOLO-DCL[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(10):318 - 326.(in Chinese)

[23] 鲍文霞,苏彪彪,胡根生,等.基于FE-P2Pnel的无人机小麦图像麦穗计数方法[J].农业机械学报, 2024,55(4):155-164.
BAO Wenxia, SU Biaobiao, HU Gensheng, et al. Method for counting wheat ears in UAV images based on FE-P2Pnet[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(4):155-164.(in Chinese)

[24] WANG Q F, CHENG M, XIAO X P, et al. An image segmentation method based on deep learning for damage assessment of the invasive weed *Solanum rostratum* Dunal[J]. Computers and Electronics in Agriculture, 2021, 188: 106320.

[25] WANG Q F, CHENG M, HUANG S, et al. A deep learning approach incorporating YOLO v5 and attention mechanisms for field real-time detection of the invasive weed *Solanum rostratum* Dunal seedlings[J]. Computers and Electronics in Agriculture, 2022, 199: 107194.

[26] 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.

[27] JOCHER G, CHAURASIA A, QIU J. Ultralytics YOLO (Version 8.0.0) [Computer software]. https://github.com/ultralytics/ultralytics.

[28] OUANG D, HE S, ZHANG G, et al. Efficient multi-scale attention module with cross-spatial learning[C]//2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2023: 1 - 5.

[29] 申阳,王冲宇,赵佳怡,等.基于改进YOLOv8和多目标跟踪的鱼苗计数方法[J].农业工程学报, 2024, 40(16): 163 - 170.
SHEN Yang, WANG Chongyu, ZHAO Jiayi, et al. Fry counting method using improved YOLOv8 and multi-target tracking [J]. Transactions of the CSAE, 2024, 40(16): 163 - 170.(in Chinese)

[30] 黄成龙,张忠福,华向东,等.基于改进Faster R-CNN和Deep Sort的棉铃跟踪计数[J].农业机械学报, 2023, 54(6): 205 - 213.
HUANG Chenglong, ZHANG Zhongfu, HUA Xiangdong, et al. Cotton boll tracking and counting based on improved Faster R-CNN and Deep Sort[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(6): 205 - 213.(in chinese)

[31] 赵新龙,顾臻奇,李军.基于YOLO v5s和改进SORT算法的黑水虻幼虫计数方法[J].农业机械学报, 2023, 54(7): 339 - 346.
ZHAO Xinlong, GU Zhenqi, LI Jun. Larvae of black soldier fly counting based on YOLO v5s network and improved SORT algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(7): 339 - 346.(in Chinese)

[32] BEWLEY A, GE Z, OTT L, et al. Simple online and realtime tracking[C]//2016 IEEE International Conference on Image Processing (ICIP), 2016: 3464 - 3468.

(上接第294页)

[23] GOWEN A A, O'DONNELL C P, CULLEN P J, et al. Hyperspectral imaging - an emerging process analytical tool for food quality and safety control[J]. Trends in Food Science & Technology, 2007, 18(12): 590 - 598.

[24] CLARK R N, SWAYZE G A. Mapping minerals, amorphous materials, environmental materials, vegetation, water, ice and snow, and other materials: The USGS tricorder algorithm[C]//Pasadena: Summaries of the Fifth Annual JPL Airborne Earth Science Workshop. Volume 1: AVIRIS Workshop, 1995.

[25] LÓPEZ M, HOFER H, STOCK K D, et al. Spectral reflectance and responsivity of Ge- and InGaAs-photodiodes in the near-infrared: measurement and model[J]. Applied Optics, Optica Publishing Group, 2007, 46(29): 7337 - 7344.

[26] MIAO Y, LIN H, LI B, et al. Review of Ge (GeSn) and InGaAs avalanche diodes operating in the SWIR spectral region [J]. Nanomaterials, Multidisciplinary Digital Publishing Institute, 2023, 13(3): 606.

[27] PRICE J C. On the information content of soil reflectance spectra[J]. Remote Sensing of Environment, 1990, 33(2): 113 - 121.

[28] KOTHARI S, SCHWEIGER A K. Plant spectra as integrative measures of plant phenotypes[J]. Journal of Ecology, 2022, 110(11): 2536 - 2554.