

# 基于改进 DeepLabV3 + 的人采机运协作机器人冠下 导航路径识别方法

苏锐<sup>1</sup> 高磊<sup>1</sup> 朱振涛<sup>1</sup> 刘骋<sup>1</sup> 陈度<sup>1,2</sup>

(1. 中国农业大学工学院, 北京 100083; 2. 智能农业动力装备全国重点实验室, 北京 100083)

**摘要:** 冠下导航是人采机运协作机器人自主转运的关键技术。针对冠下导航路径识别算法在作物叶片遮挡、杂草干扰和植株空间异质性等复杂环境下适应性差、准确性与实时性难以兼顾的问题, 本研究提出一种基于垄间图像语义分割模型 EME-Net 的冠下导航路径识别方法。在 DeepLabV3+ 结构基础上进行轻量化设计, 采用融合高效通道注意力 (Efficient channel attention, ECA) 的 MobileNetV2 (命名 EMNet) 代替主干网络 Xception, 在显著提高检测速度和实时性的同时提升模型在干扰下捕捉垄间路径关键特征的能力。同时, 在模型中引入金字塔分割注意力机制 (Pyramid split attention, PSA) 增强多尺度特征融合能力, 提升被遮挡路径边界表征精度。在 EMNet 输出端和末端嵌入 ECA 机制, 过滤垄作农田图像中不相关的特征, 提升特征利用率。针对前景与背景比例不均衡导致精度下降问题, 设计了基于 BCELoss 和 DiceLoss 的鲁棒损失函数 BCE\_DiceLoss, 有效改善路径分割结果稳定性。基于 EME-Net 模型输出的可行驶区域掩码, 利用最小二乘法重塑分割区域边缘点并提取垄间导航线。模型评估结果显示, EME-Net 平均像素准确率和平均交并比分别为 91.3% 和 88.9%, 较基线模型 DeepLabV3+ 分别提升 7.9、6.1 个百分点, 检测速度为 29.5 f/s, 整体优于 PSPNet、U-Net、HRNet、Segformer 等主流分割模型。烟叶采收作业场景试验结果表明, 模型在冠下不同复杂环境下均能有效实现导航线检测, 航偏角均值为 1.45°~3.80°、平均像素横向距离为 1.46~3.68 像素。提出的冠下导航路径识别方法能满足垄间导航任务的实际需求, 可为人采机运协作机器人自主转运作业提供技术支撑。

**关键词:** 人采机运协作; 冠下导航; 语义分割; 路径识别; 导航线检测

中图分类号: TP242.6 文献标识码: A 文章编号: 1000-1298(2026)06-0001-12

OSID:



## Canopy-under Navigation Path Recognition Method for Human-machine Collaborative Harvesting Robots Based on Improved DeepLabV3 +

SU Rui<sup>1</sup> GAO Lei<sup>1</sup> ZHU Zhentao<sup>1</sup> LIU Cheng<sup>1</sup> CHEN Du<sup>1,2</sup>

(1. College of Engineering, China Agricultural University, Beijing 100083, China

2. State Key Laboratory of Intelligent Agricultural Power Equipment, Beijing 100083, China)

**Abstract:** Canopy-under navigation path recognition in tobacco fields is often hindered by leaf and weed occlusion, as well as significant variations in plant morphology, presenting challenges for the autonomous operation of human-machine collaborative harvesting robots. To address these issues, a novel canopy-under navigation path recognition method was proposed based on the EME-Net, an inter-row image semantic segmentation model. Built upon the DeepLabV3+ architecture, EME-Net featured an encoder that employed the ECA-MobileNetV2 (dubbed EMNet) to replace the original Xception backbone for efficient feature extraction, enabling the model to effectively capture key inter-row path features. The pyramid split attention (PSA) multi-scale feature fusion mechanism was introduced to enhance the representation of inter-row boundary features, particularly under occlusion. Additionally, the ECA mechanism, embedded at both the output and terminal of EMNet, filtered out irrelevant features from tobacco field images, improving feature utilization without reducing the number of channels. To mitigate accuracy degradation caused by foreground-background imbalance, a robust BCE\_DiceLoss function was

收稿日期: 2025-09-27 修回日期: 2025-10-20

基金项目: 中国烟草总公司重点研发计划项目(110202301017)和国家自然科学基金项目(32372592)

作者简介: 苏锐(2000—), 男, 博士生, 主要从事农业机器人导航技术研究, E-mail: surui@cau.edu.cn

通信作者: 高磊(1994—), 男, 讲师, 博士, 主要从事特色经济作物生产机械化和智能化关键技术与装备研究, E-mail: gaol@cau.edu.cn

proposed, combining binary cross entropy (BCE) Loss and DiceLoss. Based on the autonomous traversal region masks outputted by EME - Net, the least squares method was used to reshape edge points and extract inter-row navigation lines. Experimental results showed that EME - Net achieved a mean pixel accuracy (mPA) of 91.3% and a mean intersection over union (mIoU) of 88.9%, surpassing the baseline model DeepLabV3+ by 7.9 and 6.1 percentage points, respectively. The average detection frame rate reached 29.5 frames per second, outperforming mainstream segmentation models such as PSPNet, U - Net, HRNet, and Segformer. In practical tobacco field navigation path recognition experiments, the proposed method effectively extracted navigation lines in canopy-under areas with varying levels of occlusion. The mean heading deviation ranged from  $1.45^\circ$  to  $3.80^\circ$ , and the average lateral pixel distance varied from 1.46 pixels to 3.68 pixels. This method met the practical requirements of inter-row navigation tasks and provides a reliable technical solution for the autonomous transportation operation of human-machine collaborative harvesting robots.

**Key words:** human-machine collaborative; under-canopy navigation; semantic segmentation; path recognition; navigation line detection

## 0 引言

烟草是我国重要的特色经济作物<sup>[1]</sup>,种植面积常年保持在  $1 \times 10^6 \text{ hm}^2$  以上,年产值稳定在 600 亿元左右,已成为烟区农户的重要收入来源,长期以来在乡村产业发展与地方经济建设中发挥重要支撑作用<sup>[2]</sup>。然而,烟草种植存在区域广泛、生产环节繁杂、劳动强度大等特点,尤其在烟叶采收环节,工序繁琐且高度依赖人工<sup>[3-4]</sup>。尽管近年来我国烟叶采收机械化水平有所提升,但在地形复杂的丘陵烟区,由于农机与采收农艺融合度不足,缺乏高适应性的专用设备,采收环节仍以人工为主<sup>[5]</sup>。现有采收设备在丘陵烟区应用均存在一定局限,全自动分层采收机存在烟叶破损率高、烟秆损伤严重等问题;而半自动采收机多采用龙门架式结构,体积大、转向不便,难以适应丘陵小地块、多起伏的作业环境。在此背景下,具备“随采随放、人采机运”功能,且低成本、小体积、转向灵活的人采机运协作机器人,为解决丘陵山区的采收难题提供了潜在的技术路径。

人采机运协作机器人自主作业的关键是实现冠下路径自主导航<sup>[6]</sup>。目前,冠下自主导航技术均存在局限,RTK - GPS 易受植物冠层遮挡产生多路径误差<sup>[7-8]</sup>,即便接入 RTK 校正服务,定位精度仍会显著下降<sup>[9]</sup>;激光雷达导航虽然具有较强的空间感知能力,但其成本高、数据处理复杂,对硬件性能要求较高,且在丘陵地形或杂草干扰严重的环境下稳定性欠佳,限制了其在垄作农田场景下的大规模应用<sup>[10]</sup>。相比之下相机能够提供丰富的场景信息,具备低成本优势,成为更优的技术选择<sup>[11-12]</sup>。

研究学者针对基于机器视觉的导航线检测算法开展了大量研究,相关算法思路大体可分为作物行提取与导航线拟合 2 个步骤<sup>[13-14]</sup>。作物行提取准确性直接影响导航线拟合精度与整体导航效果<sup>[15]</sup>。

传统图像处理方法在复杂环境表现出较大局限性,尤其在光照不足、杂草干扰严重等情况下,作物行提取的鲁棒性和准确性明显下降<sup>[16-18]</sup>。随着深度学习技术发展,许多学者将其引入作物行提取任务,并取得了良好效果。当前主流基于深度学习的作物行提取方法包括作物行语义分割与作物目标检测<sup>[14,19]</sup>。GUO 等<sup>[20]</sup>提出了一种双分支结构的深度神经网络 InstaCropNet,实现了对作物行端到端实例分割,作物行检测准确率达到 96.5%。李秀智等<sup>[21]</sup>基于语义分割网络 ESNet 构建了农田场景下作物行特征提取模型,能够对像素级带状区域进行精确分割。然而此类语义分割模型通常适用于植株高度较低、行距较宽的早期生长阶段,对于植株高度较高、叶片交错遮挡严重的成熟期场景,检测精度显著下降<sup>[22]</sup>。LIU 等<sup>[23]</sup>提出了一种基于改进 YOLO v5 网络的菠萝田导航线提取方法,在晴天与阴天条件下,平均提取准确率分别达 89.13% 与 85.32%。DIAO 等<sup>[24]</sup>采用改进的 YOLO v8s 网络识别玉米生长早期作物冠层,模型平均像素准确率提升至 90.2%。尽管作物目标检测方法在处理高大作物方面具有一定优势,但标注工作量大,且当作物种植间距较小时,易发生目标识别重叠或漏检,从而影响导航线的稳定检测。因此,基于作物行提取导航线检测方法在不同作物类型与生长阶段下存在适应性差异<sup>[22]</sup>。对于收获期冠下垄距窄、植株高、叶片遮挡严重的复杂场景,此类方法适用性较低。

相较于基于作物行提取的导航算法,基于行驶路径检测的语义分割模型在路径识别中不依赖作物具体类别与生长状态,具有更强的通用性,因而在果园等开阔区域得到了较广泛应用。ZHANG 等<sup>[25]</sup>在 Unet 基础上通过剪枝和网络优化,提出了 Fast - Unet 模型,用于果树行间路径识别,在桃树、柑橘与猕猴桃园中分别实现了 97.7%、98.7% 和 95.6% 平

均交并比。饶秀勤等<sup>[26]</sup>保留 U-Net 模型特征跳跃连接的优势,提出了 Fast-U-Net 模型,并在棉花、玉米、甘蔗 3 类作物场景中分别获得 79.10%、77.10% 和 94.00% 平均交并比。侯文慧等<sup>[27]</sup>在 U-Net 基础上构建了轻量化路径识别模型,在提升检测速度的同时,实现了草莓、蓝莓和葡萄果园路径高精度识别,平均交并比分别达 98.06%、97.36% 和 98.50%。然而,目前大多数基于路径检测的语义分割模型多针对路径边界无遮挡、通视条件良好的果园或大田环境进行设计与验证,对于烟叶采收期路径边缘存在大量植株叶片遮挡、行距狭窄、空间异质性强等复杂条件下作业场景,其适用性与鲁棒性尚缺乏系统研究与验证。

以上基于深度学习的导航路径识别研究为本文提供了重要参考。然而面向烟叶采收人采机运协同作业生产场景,机器人在作物冠下自主转运导航任务中仍面临以下难题:①烟叶进入成熟期后,叶片普遍呈下垂状态,易遮挡行驶路径边缘,且两侧叶片常出现交叉重叠现象,加之杂草噪声干扰,导航场景下视觉特征不稳定,导航路径识别算法在此复杂环境下适应性差。②现有多数研究采用的深度网络结构较为复杂,参数量大、计算资源需求高,不利于在人采机运协作机器人视觉导航系统中实施部署。因此,如何兼顾模型准确性和实时性是一个关键问题。

针对上述问题,本文聚焦人采机运协作机器人自主转运环节,提出一种基于 EME-Net 冠下导航路径识别方法。以 DeepLabV3+<sup>[28]</sup>为基础框架,采用轻量化的 EMNet 替代原主干特征提取网络 Xception,在提高算法检测速度和实时性的同时提升

干扰环境下模型捕捉垄间路径关键特征的能力。引入 PSA 多尺度特征融合机制与 ECA 注意力机制,增强模型在不同程度遮挡、杂草干扰和空间异质性等复杂场景的特征表达能力与路径识别鲁棒性。在完成路径分割的基础上,利用 Canny 算子提取路径边缘特征点,采用最小二乘法对道路边界进行拟合并最终确定导航线。最后,通过模型分割性能测试与烟叶实际生产场景的导航路径识别试验,验证本文方法在准确性与实用性方面的性能。

## 1 材料与方法

### 1.1 烟叶采收人采机运协同作业模式

丘陵山区烟叶采收以人工作业为主,在作物适宜成熟期内进行选择采收,并及时完成转运,以保障叶片新鲜度和后续烘烤质量。目前,普遍采用“人工采摘+人工搬运”作业模式,该方式不仅劳动强度大、效率低,且作业连续性差,难以满足大规模、高质量生产的需求。为满足烟叶采收农艺要求,本文提出一种人机协同作业模式,如图 1a 所示。设计一种人采机运协作机器人,如图 1b 所示,主要由履带式底盘、相机、烟叶收集筐、上位机 Jetson Orin NX 和底盘控制器等部分组成。整体作业流程分为烟农采摘烟叶、机器人收集烟叶、机器人自主跟随烟农及机器人自主转运烟叶 4 个环节,如图 1c 所示。在人工采摘基础上,运输机器人需具备对烟农的自主跟随功能,实现烟叶“随采随放”作业任务目标;收集完成后,机器人再将烟叶自主转运至收集站。本研究聚焦于人采机运协同作业模式中机器人转运烟叶环节的自主导航方法。

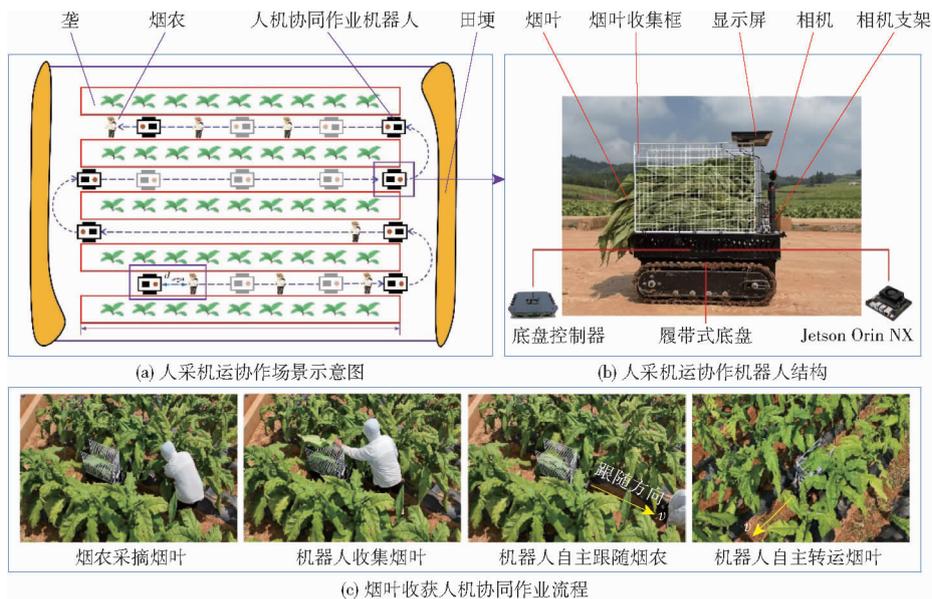


图 1 烟叶收获人机协同作业模式

Fig. 1 Human-machine collaborative operation mode for tobacco leaf harvesting

自主转运环节冠下导航环境具有高度复杂性,如图2所示。成熟期叶片下垂角度较大,严重遮挡垄间行驶路径的边界信息;烟株两侧下垂叶片交叉叠加,在农艺要求的窄垄距条件下,大幅度降低了垄间视觉通视率;植株分布空间异质性,加上杂草进一步引入噪声干扰,多重因素共同影响垄间可视信息的获取,严重制约转运环节冠下导航特征提取的精度和稳定性。



图2 自主转运环节冠下环境

Fig.2 Canopy-under environment in autonomous transfer link

## 1.2 图像采集及数据集构建

烟田垄间图像数据集在2024年8月19日和2025年8月1日采集于云南省曲靖市马龙区旧县街道烟草基地试验田(25°21'28.6"N,103°23'38.1"E)。数据采集平台如图3a所示,拍摄设备为履带底盘上搭载的Intel RealSense D435i型相机,图像数据通过USB3.0接口实时传输并保存至计算机;图像分辨率为1080像素×1920像素,以JPG格式存储,帧率为30 f/s。图像采集时双目相机固定在支架上,高度1.4 m,向下倾斜15°,拍摄方向为垄间道路的正

前方。图像采集环境涵盖无遮挡、杂草遮挡、烟叶遮挡以及烟株空间异质性等多种复杂场景。本文图像采集数据主要聚焦于烟田垄间道路区域,不涉及烟田地头以及株间部分。

模型在训练过程中由于样本数量不足会出现过拟合现象<sup>[29]</sup>。同时,为了提升模型的泛化能力和鲁棒性,在模型训练前对原始数据集进行多种数据增强处理,包括旋转90°、镜像翻转及随机亮度调整等方法。旋转和镜像操作旨在增加烟田垄间道路导航方向的多样性,增强模型对不同路径方向的适应能力;随机亮度调整用于模拟自然环境中光照不均、天气变化等因素对图像的影响,调整幅度控制在亮度变化不超过30%的范围内<sup>[27]</sup>。经过归一化裁剪及上述增强操作,最终构建包含2500幅烟田垄间图像的数据集。利用Labelme软件对图像垄间可行驶区域进行像素级标注,生成可行驶区域与背景2类标签。标签制作过程及结果如图3b所示,数据增强效果如图3c所示。以比例9:1将数据集划分为训练集和验证集,得到训练集2250幅图像,验证集250幅图像。

## 2 基于改进DeepLabV3+的冠下垄间路径识别模型

### 2.1 EME-Net网络结构

为解决冠下导航路径识别算法在作物叶片遮挡、杂草干扰和植株空间异质性等复杂环境下适应性差、准确性与实时性难以兼顾的问题,本文提出一种基于DeepLabV3+架构改进的模型——EME-Net,用于精准识别垄间导航路径。如图4所示,模型沿用

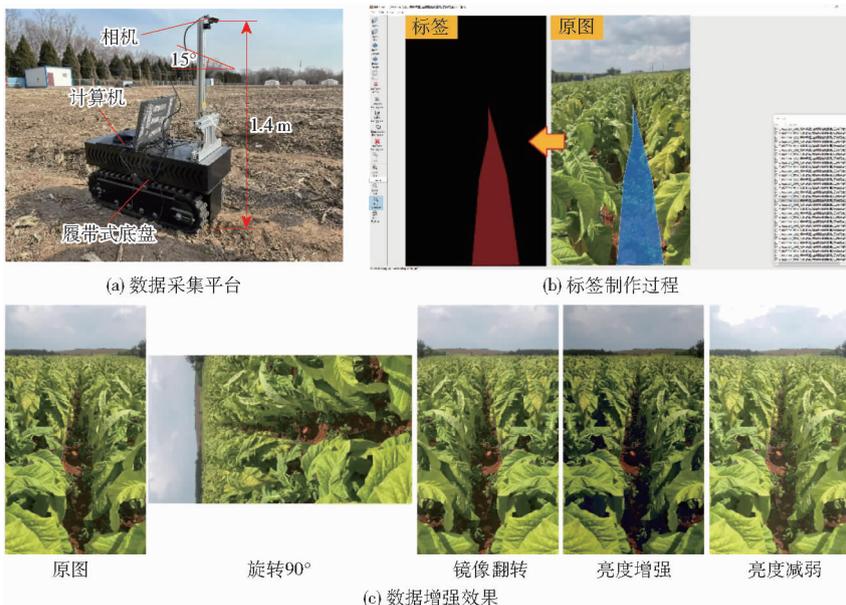


图3 数据集制作

Fig.3 Dataset production

DeepLabV3 + 经典的编码器-解码器结构,通过解码器的特征上采样与编码器输出的浅层特征融合,精确恢复路径细节信息。编码器部分由主干网络、空洞空间金字塔池化 (Atrous spatial pyramid pooling, ASPP) 模块和金字塔分割注意力 (Pyramid split attention, PSA) 机制构成。首先主干网络采用融合轻量级高效通道注意力 (Efficient channel attention, ECA) 的 MobileNetV2 (命名为 EMNet), 替代传统的 Xception 网络, 通过 ECA 自适应通道权重分配, 模型在保证实时性的同时, 优化路径特征的表达, 显

著提升了在叶片遮挡和杂草干扰场景下的特征提取效率<sup>[30]</sup>。为了增强对不同尺度信息的感知能力, EME - Net 保留了 ASPP 模块, 使其能够在烟田垄间提取多尺度目标信息, 提升路径边界在干扰区域的表征能力。PSA 机制进一步聚焦关键路径信息, 兼顾复杂背景下的分割精度与推理速度。此外, 在 EMNet 的输出端与末端额外嵌入 ECA 模块, 有效过滤浅层、深层网络中由叶片、杂草产生的噪声等无关特征, 提升有效特征利用率, 进一步优化模型整体性能。

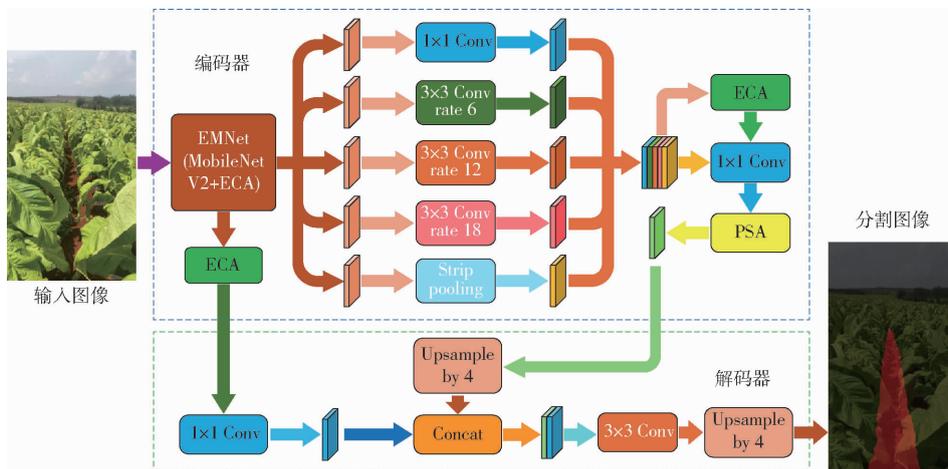


图 4 EME - Net 网络结构

Fig. 4 EME - Net network structure

## 2.2 ECA - MobileNetV2 (EMNet)

DeepLabV3 + 采用 Xception 作为骨干网络, 虽然具备强大的特征提取能力, 但复杂的结构和大量参数降低了检测速度<sup>[30-31]</sup>。为在烟田垄间复杂干扰环境中高效准确地提取导航路径特征, 通过引入 ECA 机制改进 MobileNetV2 的倒残差模块, 构建轻量级 EMNet, 并将其作为 EME - Net 的特征提取网络。EMNet 的改进倒残差模块包括 2 种类型, 如图 5 所示。图 5a 为类型 I, 模块首先通过  $1 \times 1$  卷积提升输入维度, 以便全面提取信息, 然后利用  $3 \times 3$  深度可分卷积进行特征提取, 并结合注意力机制

过滤无关特征, 最后,  $1 \times 1$  卷积用于降维, 并与输入特征进行融合。图 5b 为类型 II, 模块在  $1 \times 1$  卷积后, 采用步长为 2 的  $3 \times 3$  深度可分卷积进行特征提取, 再经过注意力机制和  $1 \times 1$  卷积完成关键特征提取与降维。这些优化措施有效降低计算负担, 同时保持高效的特征提取能力, 可提升网络的检测速度。

## 2.3 PSA 多尺度通道注意力机制

ASPP 通过设置不同膨胀率的空洞卷积扩展感受野, 但容易造成细节信息丢失<sup>[32]</sup>。针对烟田垄间导航对田垄边界检测的高精度需求, 在 EME - Net 中引入 PSA 注意力机制, 以增强多尺度特征提取能力, 尤其在复杂场景下提升长距离依赖特征表达, 从而优化语义分割效果。如图 6 所示, PSA 模块由 SPC (Split-and-concat) 和 SE (Squeeze-and-excitation) 2 部分组成<sup>[32-33]</sup>, SPC 模块沿通道维度对特征图进行分割, 并利用不同尺寸的卷积核提取多尺度空间信息, 再拼接回原始维度, 实现局部与全局信息的融合, 从而提升复杂背景下的分割精度; SE 模块则通过全局平均池化 (Global average pooling, GAP)、全连接网络及 Sigmoid 激活函数计算通道权重, 并与原始特征逐通道相乘, 以突出关键信息表达。该机制可有效强化模型对垄间道路边界细节捕捉能力, 提升复杂田间环境下路径识别效果。

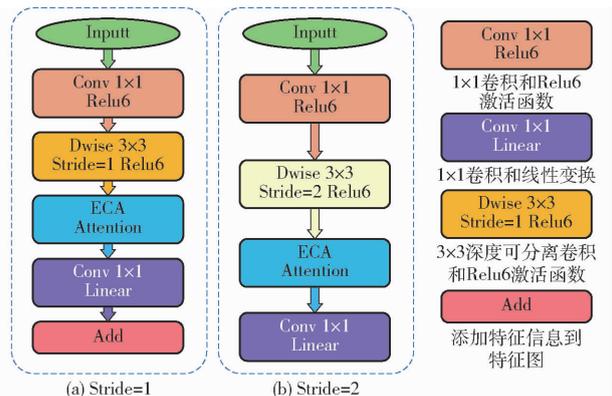


图 5 EMNet 的改进倒残差模块

Fig. 5 Improved inverted residual module in EMNet

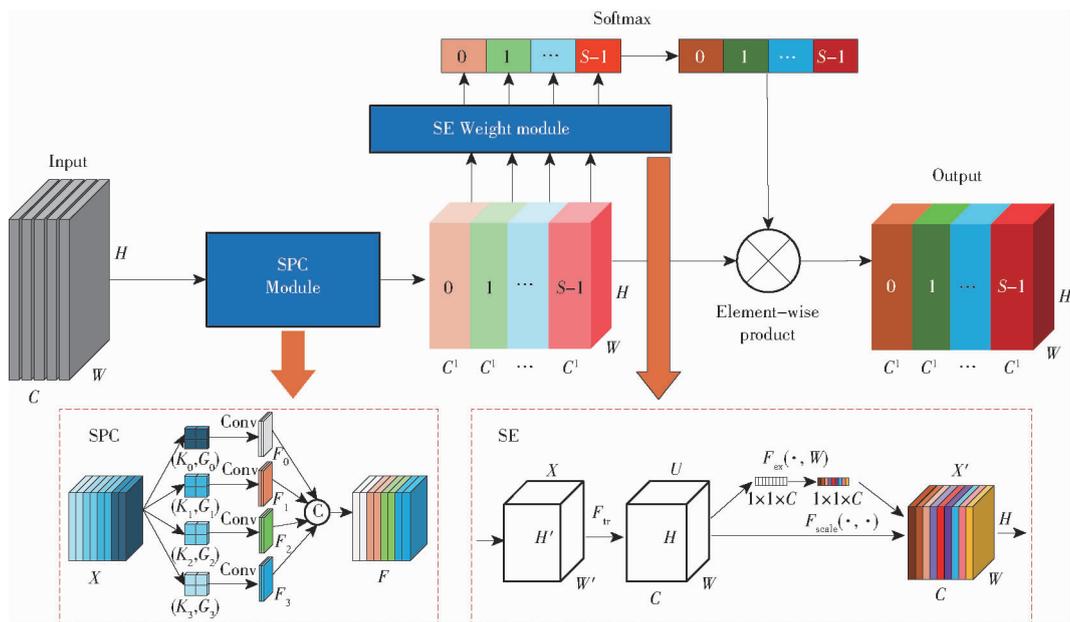


图6 PSA多尺度空间注意力机制结构

Fig. 6 Structure of PSA multi-scale spatial attention mechanism

## 2.4 ECA轻量化通道注意力机制

为了抑制烟田垄间图像中无关特征并增强对垄间道路关键特征的关注,在模型中引入ECA机制。如图7所示,ECA机制通过全局平均池化GAP对各通道特征进行压缩,生成尺寸为 $1 \times 1 \times C$ 的通道描述向量,再通过自适应一维卷积核处理生成对应的注意力权重图,最终,权重图与原始特征图逐通道相乘,实现对垄间关键特征的强化与干扰信息的抑制<sup>[30,34]</sup>。一维卷积核尺寸 $K$ 计算式为

$$K = \left\lfloor \frac{\text{lb}c + b}{\theta_1} \right\rfloor \quad (1)$$

式中  $K$ ——取最邻近奇数

$\theta_1$ 、 $b$ ——调节通道数与卷积核尺寸关系的超参数, $\theta$ 取2, $b$ 取1

$c$ ——输入特征图通道数

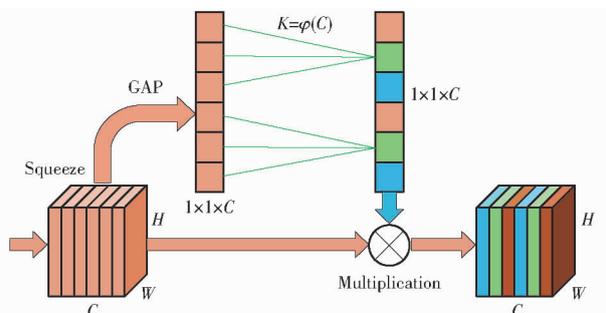


图7 ECA轻量化通道注意力机制结构

Fig. 7 Structure of ECA lightweight channel attention mechanism

## 2.5 网络损失函数

损失函数用于量化模型预测与真实值之间的差异,其值越小则表明模型拟合效果越好。在烟田导

航路径分割任务中,前景(导航路径)与背景的像素比例往往严重不平衡,易导致模型偏向多数类(背景)。为此,采用BCE\_DiceLoss作为损失函数,由二分类交叉熵损失BCELoss和DiceLoss加权组成,计算式为

$$\text{BCE\_DiceLoss} = (1 - \mu) \text{BCELoss} + \mu \text{DiceLoss} \quad (2)$$

其中

$$\text{BCELoss}(y, \hat{y}) = -\frac{1}{m} \sum_{i=1}^m [y_i \ln \sigma(\hat{y}_i) + (1 - y_i) \ln(1 - \sigma(\hat{y}_i))] \quad (3)$$

$$\text{DiceLoss}(Y, \hat{Y}) = 1 - \frac{2 \sum_{i=1}^m Y_i \sigma(\hat{Y}_i) + \varepsilon}{\sum_{i=1}^m Y_i + \sum_{i=1}^m \sigma(\hat{Y}_i) + \varepsilon} \quad (4)$$

式中  $\mu$ ——DiceLoss权重

$y_i$ ——第 $i$ 个像素真实标签

$\hat{y}_i$ ——模型输出的logits值

$\sigma(\cdot)$ ——Sigmoid激活函数

$m$ ——单幅图像像素总数

$\varepsilon$ ——平滑常数,取 $1 \times 10^{-5}$

DiceLoss从全局角度衡量预测图像的分类效果,专注于前景像素的相似度,能够提升模型对导航路径区域的敏感度。而BCELoss从像素级角度度量预测概率与真实标签的误差,为整体训练的稳定性提供保障。烟田垄间导航路径识别既需要全局判断的准确性,又需兼顾局部细节,因此在BCE\_DiceLoss计算中赋予DiceLoss更高的权重,取 $\mu$ 为0.6。该损失函数能够有效缓解前景与背景比例不

均衡带来的精度下降问题,可显著改善冠下导航路径分割效果。

## 2.6 导航线提取

根据分割模型得到的可行驶区域,提取导航线。本文所研究烟田采用较为规范化垄作种植模式,为便于管理并充分利用土地资源,垄间一般都以一定间距平行分布。即使存在规整误差,垄间道路整体上仍呈直线分布<sup>[27]</sup>,因此人采机运协作机器人可将道路中线作为导航路径。常用的直线拟合算法包括霍夫变换、随机采样一致性、最小二乘法等。然而,烟田垄间道路具有非结构化特征,加之烟叶遮挡严

重,道路边缘信息不规则。为此,对模型分割得到的导航路径区域掩码,本文提出一种基于道路边缘拟合的角平分线提取导航路径提取算法,如图8所示。具体步骤为:①利用语义分割模型对输入图像进行预测,获得导航路径分割结果及其二值化图像。②利用Canny算子对导航路径预测区域进行边缘检测,并以30像素间隔提取边缘点。③基于边缘点信息,使用最小二乘法回归拟合出道路边界,通过找到一条最能代表数据分布的直线,使所有点到该直线垂直距离平方和最小。④将道路左右边界线的角平分线作为导航路径。

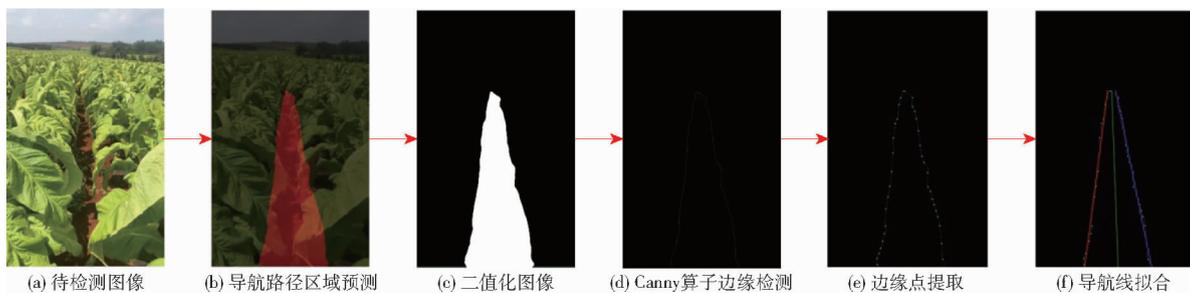


图8 导航线提取

Fig. 8 Navigation line extraction

## 2.7 模型训练

### 2.7.1 试验平台

计算机CPU为Intel(R)Core(TM)i9-13900K,4.90 GHz,内存32 GB 3 200 MHz,GPU为NVIDIA GeForce RTX 4080,显存16 GB,Windows11操作系统。所有程序均基于Python 3.9编写,IDE使用VSCode,深度学习框架为PyTorch 2.0,CUDA版本为11.8。

### 2.7.2 模型训练超参数设置

试验使用带动量的随机梯度下降法(SGD)作为优化器,动量项(momentum)为0.9。初始学习率为0.001,最小学习率为0.000 01,学习率衰减系数为0.1,迭代次数(epoch)为120。训练时输入图像统一调整为512像素×512像素,批次大小(batch\_size)设为32。

### 2.7.3 评价指标

为综合评价网络模型在烟叶收获期垄间分割导航路径任务中的效果,主要从分割性能和部署性能考虑。部署性能评估参考模型内存占用量(Model size)和检测速度;分割性能评估则主要采用平均像素准确率(Mean pixel accuracy, mPA)与平均交并比(Mean intersection over union, MIoU)2个指标。

## 3 结果与分析

### 3.1 模型性能验证

#### 3.1.1 模型训练过程分析

EME-Net模型训练过程曲线如图9所示。由

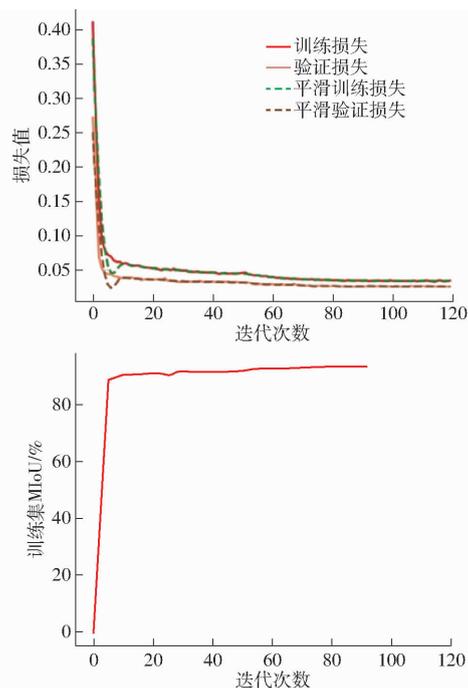


图9 EME-Net模型训练过程

Fig. 9 Training process of EME-Net model

图9可知,EME-Net的MIoU在训练开始后迅速上升到80%,并在60个epoch左右开始快速收敛,最终在多次迭代后达到约89%。此外,EME-Net的损失值在训练开始后迅速下降,开始收敛在0.05左右,并最终在模型训练120次后收敛到0.03。结果表明,EME-Net的训练过程稳定,未出现过拟合或欠拟合的现象。

### 3.1.2 EME - Net 模型消融试验

在测试集上进行消融试验,以验证各种改进模块对烟田垄间路径感知模型 EME - Net 的影响。如表 1 所示,原始 DeepLabV3 + 在测试集上获得平均交并比 MIoU 为 82.8% 和平均像素准确率为 83.4%;通过将 Xception 主干替换为 EMNet,并依次结合 BCE\_DiceLoss、PSA 模块和 ECA 模块后,EME - Net 模型性能显著提升,平均交并比 MIoU 分别增加到 84.5%、84.9%、87.2% 和 88.9%,且平均像素准确率依次增加到 85.3%、86.2%、89.7% 和 91.3%。与基线模型相比,EME - Net 模型平均交并比 MIoU 和平均像素准确率分别提升 6.1、7.9 个

百分点;此外,EME - Net 模型内存占用量减少 85.9%,并实现 29.5 f/s 的检测速度。模型训练结果表明,各模块通过不同机理产生协同效应:EMNet 作为轻量化特征提取主干,有效降低计算成本,同时保持了在复杂垄间场景中的多尺度特征表征能力;BCE\_DiceLoss 函数融合交叉熵的像素级监督与 Dice 系数的结构相似性约束,解决前景与背景比例不均衡导致的精度下降问题;PSA 多尺度特征融合机制增强了垄间边界特征的表征能力。ECA 模块进一步细化特征选择,提高了模型整体分割精度。综合来看,这些改进策略显著提升了 EME - Net 在复杂烟田垄间路径分割任务中的有效性与鲁棒性。

表 1 EME - Net 模型消融试验结果

Tab.1 Ablation experiment results of EME - Net model

网络模型	EMNet	BCE_DiceLoss	PSA	ECA	MIoU/%	平均像素 准确率/%	模型内存占 用量/MB	检测速度/ (f·s <sup>-1</sup> )
DeepLabV3 +					82.8	83.4	202.0	20.9
E - DeepLabV3 +	√				84.5	85.3	26.5	28.6
EB - DeepLabV3 +	√	√			84.9	86.2	26.5	28.6
EBP - DeepLabV3 +	√	√	√		87.2	89.7	27.6	30.2
EME - Net(本文)	√	√	√	√	88.9	91.3	28.5	29.5

注:DeepLabV3 + 在此阶段使用 Xception 作为其主干网络;√表示采用此模块。

### 3.1.3 不同模型分割效果试验

为评估本文 EME - Net 模型的分割性能,选取 PSPNet、U - Net、HRNet、Segformer 主流语义分割模型作为对比对象,并在烟田垄间典型复杂场景(如烟叶遮挡、地面杂草干扰等)上进行测试。模型分割结果如图 10(图中黄色圆圈为分割错误现象;白色圆圈为掩码边缘分割不平滑现象)所示,U - Net、HRNet、Segformer 和 PSPNet 模型都能分割出垄间导航区域,但均存在一定的路径边缘分割不够平滑问题,图中白色圆圈所示,由于导航线提取是基于分割掩码的边缘点提取和拟合,因此不平滑分割掩码会对导航线提取产生不利影响;此外,U - Net 和 Segformer 模型还表现出较大幅度的误检,对背景和导航路径的区分不够精准。相比之下,EME - Net 模型对不同复杂场景均能精准分割出导航路径,且相比其他模型分割掩码区域边缘更加平滑,表现出更强的鲁棒性和适应性,尤其在烟叶高度遮挡和垄间场景杂乱情况下,仍能保持优异的分割效果。表 2 定量分析结果进一步证实了 EME - Net 模型优势,与 PSPNet、U - Net、HRNet 和 Segformer 模型相比,EME - Net 模型平均交并比 MIoU 分别提升 2.1、1.0、1.7、1.4 个百分点;平均像素准确率分别提升 2.1、0.8、1.5、1.2 个百分点;同时实现了 29.5 f/s 的检测速度。尽管其模型内存占用量为 28.5 MB,略

高于部分对比模型,但这一内存占用量仍可满足农业边缘计算部署需求,体现了其在性能和效率之间的良好平衡。

### 3.2 导航路径识别试验

于 2025 年 8 月 1 日在云南省曲靖市马龙区旧县街道马刺塘烟田(25°40'12.3"N, 103°42'70.8"E)开展田间试验,试验场景如图 11 所示。使用人采机运协作机器人进行田间协同收获作业,待机器人集满烟叶后开始自行转运至收集站,转运作业过程中通过搭载的相机采集垄间冠下场景图像,对于采集的图像按照遮挡程度和场景特点进行分类,从中选取冠下垄间代表性场景图像进行导航路径识别和导航线拟合试验,导航线拟合结果如图 12 所示。

从图 12 可看出,本文提出的算法在冠下垄间不同复杂场景下均可识别出完整的导航路径区域并成功拟合导航线,对于植株空间异质性场景,尽管垄间道路分割掩码出现一定程度的边缘不平滑现象,但并不影响导航线拟合,整体仍达到了预期的效果。

为评价本文导航路径识别方法的准确性,将人工标注数据生成的导航线作为评价标准,选用航偏角均值与平均像素横向距离作为评价指标<sup>[22]</sup>,计算方法如图 13 所示。

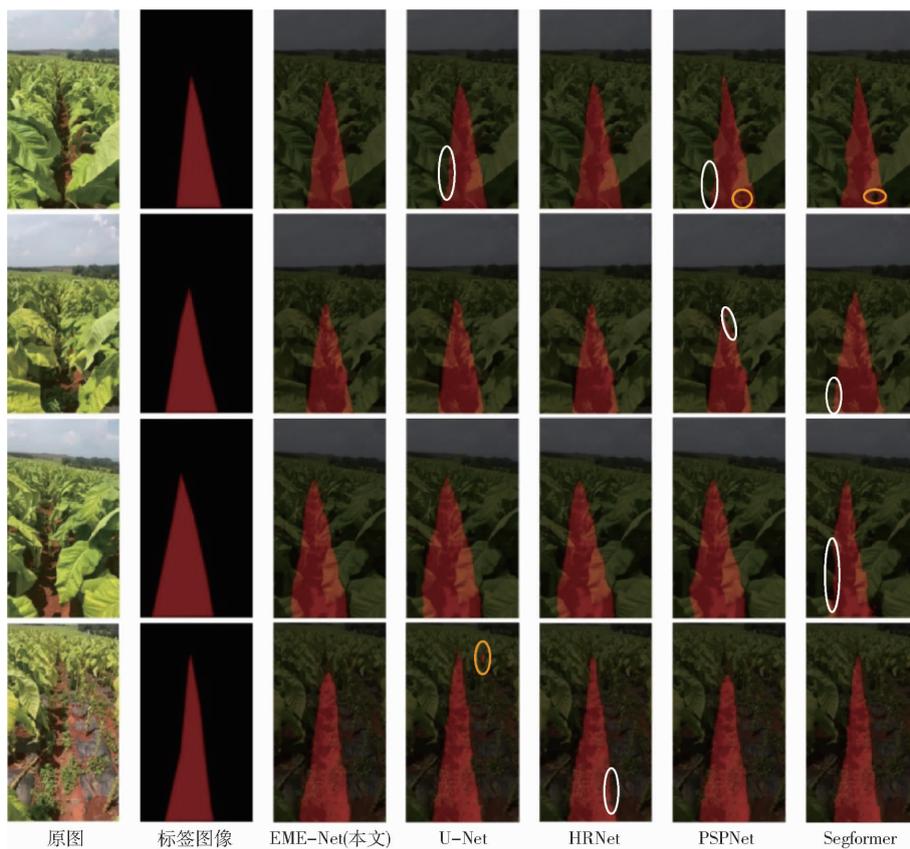


图 10 不同语义分割模型分割效果

Fig. 10 Segmentation effects of different semantic segmentation models

表 2 不同语义分割模型检测结果

Tab. 2 Comparison of detection results of different semantic segmentation models

网络模型	MIoU/ %	平均像素 准确率/%	模型内存占 用量/MB	检测速度/ (f·s <sup>-1</sup> )
PSPNet	86.8	89.2	9.5	24.5
U-Net	87.9	90.5	95.6	26.0
HRNet	87.2	89.8	38.6	20.5
Segformer	87.5	90.1	13.6	18.6
EME-Net(本文)	88.9	91.3	28.5	29.5

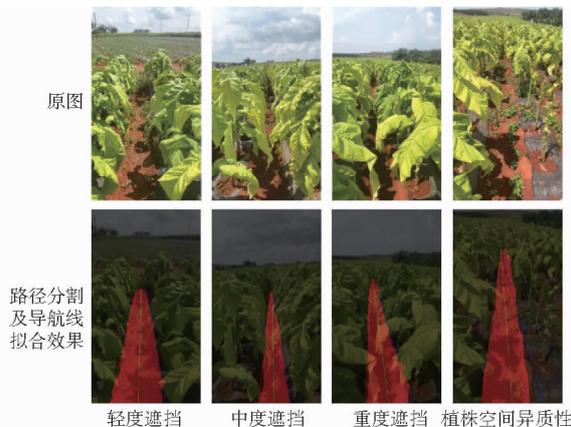


图 12 不同复杂场景图像导航线拟合效果

Fig. 12 Navigation line fitting effects of images in different complex scenarios



图 11 田间试验场景

Fig. 11 Field test scenario

标注导航线与预测导航线航向角差值为航偏角  $\theta$ 。为避免正负偏差相互抵消的影响,先将航偏角求绝对值后计算航偏角均值,计算式为

$$\theta = \arctan \frac{1}{k_1} - \arctan \frac{1}{k_2} \quad (5)$$

$$\bar{\theta} = \frac{1}{n} \sum_{i=1}^n |\theta_i| \quad (6)$$

式中  $k_1, k_2$ ——标注导航线与预测导航线斜率  
 $\bar{\theta}$ ——航偏角均值  
 $n$ ——图像总数量  
 $i$ ——图像编号

像素横向距离定义为在相同纵坐标下,预测导航线与标注导航线横坐标差值的绝对值。为避免两线交叉导致的误差,需沿图像垂直方向(Y轴)选取 2 个间隔较远的参考点,分别计算对应横坐标差值,记为  $d_1$  和  $d_2$ 。像素横向距离  $d_1$  计算式为

$$d_1 = |x_i - x_p| \quad (7)$$

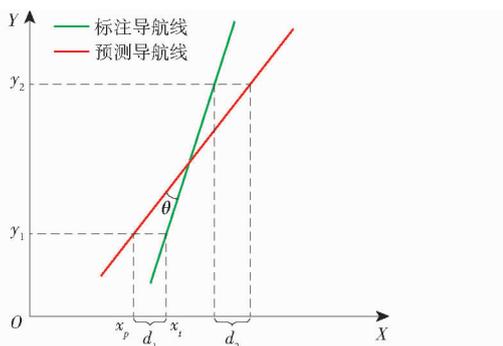


图 13 导航线提取精度评估计算方法

Fig. 13 Calculation method for navigation line extraction accuracy evaluation

式中  $x_i, x_p$ ——标注导航线与预测导航线在相同纵坐标下的横坐标值

将  $d_1$  和  $d_2$  平均后得出像素横向距离平均值, 计算式为

$$\bar{d} = \frac{d_1 + d_2}{2} \quad (8)$$

预测导航线和标注导航线在不同复杂环境下航偏角和平均像素横向距离如表 3 所示, 在不同复杂垄间环境下进行导航线检测试验, 航偏角均值为  $1.45^\circ \sim 3.80^\circ$ 、平均像素横向距离为  $1.46 \sim 3.68$  像素。烟叶轻度遮挡环境下航偏角均值和平均像素横向距离为  $1.50^\circ$  和  $1.46$  像素。在烟叶重度遮挡环境下, 航偏角均值和平均像素横向距离分别增加  $0.63^\circ$  和  $1.04$  像素; 在杂草遮挡的环境下, 导航线检测算法的检测效果与烟叶轻度遮挡环境下相当, 说明烟叶遮挡、杂草遮挡对导航线检测算法并无明显的影响。而在烟垄、烟株空间异质性场景下, 航偏角均值和平均像素横向距离增加  $2.3^\circ$  和  $2.22$  像素, 但此数值仍在合理的范围之内, 算法依旧能够成功检测出导航线。

表 3 导航线的航偏角均值和平均像素横向距离

Tab.3 Mean heading deviation angle and average pixel lateral distance of navigation lines

垄间环境	航偏角均值/ $^\circ$	平均像素横向距离/像素		
		$d_1$	$d_2$	$\bar{d}$
烟叶轻度遮挡	1.50	1.35	1.57	1.46
烟叶中度遮挡	2.05	1.70	2.52	2.11
烟叶重度遮挡	2.13	1.75	3.25	2.50
杂草遮挡	1.45	1.45	1.71	1.58
植株空间异质性	3.80	3.21	4.15	3.68

导航路径识别试验结果表明, 基于 EME-Net 模型的烟叶收获期冠下导航路径识别方法可以有效检测出垄间路径导航线, 同时在不同复杂场景下具有良好的准确性和鲁棒性, 可以满足烟叶收获期机器人自主转运任务冠下导航的实际需求, 为机器人冠下自主转运导航提供一个可行的技术方案。

### 3.3 局限性与展望

尽管本文提出的基于改进 DeepLabV3+ 人采机运协作机器人冠下导航路径识别方法在自主转运作业复杂场景下取得了良好的分割效果, 但仍存在数据集规模有限的局限性, 目前构建的数据集集中于云南产区红壤土环境烟田烟叶采收阶段, 缺乏跨时段跨区域数据样本, 这可能影响模型在不同烟区不同部位烟叶采收场景下的适应能力。

针对上述不足, 未来研究将进一步扩展数据集规模与多样性, 计划在不同产区和多种作业环境下采集冠下垄间图像, 构建场景多样性更强的高质量数据集, 从而提升模型的泛化性与鲁棒性。

## 4 结论

(1) 针对人采机运协作机器人自主转运作业冠下导航路径识别算法在作物叶片遮挡、杂草干扰和植株空间异质性等复杂环境下适应性差、准确性与实时性难以兼顾的问题, 在语义分割模型 DeepLabV3+ 的基础上通过优化模型结构提出了 EME-Net 模型, 利用最小二乘法重塑垄间分割掩码可行驶区域边缘点, 并提取垄间导航线。

(2) 提出了烟叶采收“人采机运”协同作业模式, 基于车载相机构建了烟叶收获期人采机运协作自主转运环节冠下导航图像数据集, 涵盖了烟叶不同程度遮挡、植株空间异质性等不同情形。

(3) 提出了一种可准确分割冠下图像的高效语义分割模型 EME-Net。模型在烟叶遮挡、杂草遮挡、植株空间异质性等场景下的平均像素精确度和平均交并比分别为  $91.3\%$  和  $88.9\%$ , 较基线模型分别提升  $7.9$ 、 $6.1$  个百分点。与 PSPNet、U-Net、HRNet、Segformer 模型相比, EME-Net 模型平均交并比 mIoU 分别增长  $2.1$ 、 $1.0$ 、 $1.7$ 、 $1.4$  个百分点; 平均像素准确率分别增长  $2.1$ 、 $0.8$ 、 $1.5$ 、 $1.2$  个百分点; 同时实现  $29.5$  f/s 的检测速度。结果表明 EME-Net 模型在性能和效率之间的良好平衡, EME-Net 模型能够准确预测人采机运协作机器人自主转运作业垄间路径掩码, 同时对不同干扰的垄间路径环境具有良好的适应性和鲁棒性。

(4) 基于 EME-Net 模型分割的可行驶区域掩码, 通过 Canny 算子检测其边缘信息点, 并利用最小二乘法重塑边缘信息, 进而拟合导航线。在不同复杂垄间环境下进行导航线检测试验, 航偏角均值为  $1.45^\circ \sim 3.80^\circ$ 、平均像素横向距离为  $1.46 \sim 3.68$  像素, 结果表明, 本文提出的路径提取方法在实际场景下具有较好的准确性, 可满足人采机运协作机器人自主转运作业导航的需求。

## 参 考 文 献

- [1] 王晓磊. 现代烟草农业机械化技术体系构建策略分析[J]. 现代农业研究, 2019(7): 31–32.  
WANG Xiaolei. Analysis on the strategy of technical system construction of modern tobacco agricultural mechanization[J]. Modern Agriculture Research, 2019(7): 31–32. (in Chinese)
- [2] 胡颖梅, 王术科, 高明博, 等. 烟草收获技术与装备研究现状及发展[J]. 中国农机化学报, 2025, 46(10): 75–81.  
HU Yingmei, WANG Shuke, GAO Mingbo, et al. Research status and development of tobacco harvesting technology and equipment at home and abroad[J]. Journal of Chinese Agricultural Mechanization, 2025, 46(10): 75–81. (in Chinese)
- [3] 王潇涵, 冉云亮, 葛朝, 等. 旋转包络梳脱式烟叶采收机构设计与试验[J]. 智慧农业(中英文), 2025, 7(3): 210–223.  
WANG Xiaohan, RAN Yunliang, GE Chao, et al. Design and test of rotary envelope combing-type tobacco leaf harvesting mechanism[J]. Smart Agriculture, 2025, 7(3): 210–223. (in Chinese)
- [4] 王新, 唐灿, 朱建新, 等. 基于深度增强与特征抗噪的夜间串番茄成熟度识别方法[J]. 农业机械学报, 2025, 56(4): 363–374.  
WANG Xin, TANG Can, ZHU Jianxin, et al. Tomato cluster ripeness recognition at night based on depth enhancement and feature noise reduction[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(4): 363–374. (in Chinese)
- [5] 夏秀清, 温亮, 程云吉, 等. 烟草与中草药种植模式研究进展[J]. 农业科学, 2024, 14(4): 399–406.  
XIA Xiuqing, WEN Liang, CHENG Yunji, et al. Research progress on planting patterns of tobacco and Chinese herbal medicine[J]. Hans Journal of Agricultural Sciences, 2024, 14(4): 399–406. (in Chinese)
- [6] 张漫, 季宇寒, 李世超, 等. 农业机械导航技术研究进展[J]. 农业机械学报, 2020, 51(4): 1–18.  
ZHANG Man, JI Yuhao, LI Shichao, et al. Research progress of agricultural machinery navigation technology[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(4): 1–18. (in Chinese)
- [7] 刘成良, 贡亮, 苑进, 等. 农业机器人关键技术研究现状与发展趋势[J]. 农业机械学报, 2022, 53(7): 1–22, 55.  
LIU Chengliang, GONG Liang, YUAN Jin, et al. Current status and development trends of agricultural robots[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(7): 1–22, 55. (in Chinese)
- [8] 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)
- [9] AFFONSO F, TOMMASELLI F, CAPEZZUTO G, et al. CROW: a self-supervised crop row navigation algorithm for agricultural fields[J]. Journal of Intelligent & Robotic Systems, 2025, 111(1): 28.
- [10] LI Zhiqiang, XIE Dongbo, LIU Lichao, et al. Inter-row information recognition of maize in the middle and late stages via LiDAR supplementary vision[J]. Frontiers in Plant Science, 2022, 13: 1024360.
- [11] BAI Yuhao, ZHANG Baohua, XU Naimin, et al. Vision-based navigation and guidance for agricultural autonomous vehicles and robots: a review[J]. Computers and Electronics in Agriculture, 2023, 205: 107584.
- [12] 苏筠皓. 复杂环境下中耕除草机器人视觉导航路径识别研究[D]. 天津: 天津理工大学, 2023.  
SU Yunhao. Research on visual navigation path recognition of field tillage weeding robot in complex environment[D]. Tianjin: Tianjin University of Technology, 2023. (in Chinese)
- [13] 杨洋, 张博立, 查家翼, 等. 玉米行间导航线实时提取[J]. 农业工程学报, 2020, 36(12): 162–171.  
YANG Yang, ZHANG Boli, ZHA Jiayi, et al. Real-time extraction of navigation line between corn rows[J]. Transactions of the CSAE, 2020, 36(12): 162–171. (in Chinese)
- [14] 董静, 刘长斌, 王成, 等. 面向大田作物碎散分布场景的田垄导航线检测[J]. 农业工程学报, 2025, 41(10): 1–10.  
DONG Jing, LIU Changbin, WANG Cheng, et al. Detection of crop-free ridge navigation lines for fragmented field crop scenarios[J]. Transactions of the CSAE, 2025, 41(10): 1–10. (in Chinese)
- [15] YANG Yang, ZHOU Yang, YUE Xuan, et al. Real-time detection of crop rows in maize fields based on autonomous extraction of ROI[J]. Expert Systems with Applications, 2023, 213: 118826.
- [16] 江庆, 安东, 韩华宇, 等. 基于激光雷达与 RGB 相机融合的玉米作物行检测算法研究[J]. 农业机械学报, 2024, 55(10): 263–274.  
JIANG Qing, AN Dong, HAN Huayu, et al. Maize crop row detection algorithm based on fusion of LiDAR and RGB camera[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(10): 263–274. (in Chinese)
- [17] 张硕, 刘禹, 熊坤, 等. 基于特征工程的大田作物行中心线识别方法[J]. 农业机械学报, 2023, 54(增刊1): 18–26.  
ZHANG Shuo, LIU Yu, XIONG Kun, et al. Center line detection of field crop rows based on feature engineering[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(Supp.1): 18–26. (in Chinese)
- [18] 韩长杰, 郑康, 赵学观, 等. 大田甘蓝作物行识别与对行喷雾控制系统设计与试验[J]. 农业机械学报, 2022, 53(6):

89 - 101.

HAN Changjie, ZHENG Kang, ZHAO Xueguan, et al. Design and experiment of row identification and row-oriented spray control system for field cabbage crops[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(6): 89 - 101. (in Chinese)

- [19] 俞高红,王一淼,甘帅汇,等. 改进 DeepLabV3 + 算法提取无作物田垄导航线[J]. 农业工程学报, 2024, 40(10): 168 - 175.  
YU Gaohong, WANG Yimiao, GAN Shuaihui, et al. Extracting the navigation lines of crop-free ridges using improved DeepLabV3 + [J]. Transactions of the CSAE, 2024, 40(10): 168 - 175. (in Chinese)
- [20] GUO Zhiming, GENG Yuhang, WANG Chuan, et al. InstaCropNet: an efficient Unet-based architecture for precise crop row detection in agricultural applications[J]. Artificial Intelligence in Agriculture, 2024, 12: 85 - 96.
- [21] 李秀智,方会敏,朱玉垒,等. 基于语义分割网络的植保机器人视觉伺服控制方法[J]. 农业机械学报, 2024, 55(5): 21 - 27, 39.  
LI Xiuzhi, FANG Huimin, ZHU Yulei, et al. Visual servo control of plant protection robot based on semantic segmentation [J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(5): 21 - 27, 39. (in Chinese)
- [22] 苏童,王琳,班超,等. 基于语义分割的中后期玉米行间路径导航线检测[J]. 农业机械学报, 2024, 55(10): 275 - 285.  
SU Tong, WANG Lin, BAN Chao, et al. Interrow path navigation line detection of maize in middle and late period based on semantic segmentation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(10): 275 - 285. (in Chinese)
- [23] LIU Tianhu, ZHENG Yan, LAI Jiashang, et al. Extracting visual navigation line between pineapple field rows based on an enhanced YOLO v5[J]. Computers and Electronics in Agriculture, 2024, 217: 108574.
- [24] DIAO Zhihua, GUO Peiliang, ZHANG Baohua, et al. Navigation line extraction algorithm for corn spraying robot based on improved YOLO v8s network[J]. Computers and Electronics in Agriculture, 2023, 212: 108049.
- [25] ZHANG Liang, LI Ming, ZHU Xinghui, et al. Navigation path recognition between rows of fruit trees based on semantic segmentation[J]. Computers and Electronics in Agriculture, 2024, 216: 108511.
- [26] 饶秀勤,朱逸航,张延宁,等. 基于语义分割的作物垄间导航路径识别[J]. 农业工程学报, 2021, 37(20): 179 - 186.  
RAO Xiuqin, ZHU Yihang, ZHANG Yanning, et al. Navigation path recognition between crop ridges based on semantic segmentation[J]. Transactions of the CSAE, 2021, 37(20): 179 - 186. (in Chinese)
- [27] 侯文慧,周传起,程炎,等. 基于轻量化 U - Net 网络的果园垄间路径识别方法[J]. 农业机械学报, 2024, 55(2): 16 - 27.  
HOU Wenhui, ZHOU Chuanqi, CHENG Yan, et al. Path recognition method of orchard ridges based on lightweight U - Net [J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(2): 16 - 27. (in Chinese)
- [28] CHEN Liang, ZHU Yukun, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]//European Conference on Computer Vision (ECCV), 2018.
- [29] LIU Lei, DU Yuefeng, LI Xiaoyu, et al. Trailer hopper automatic detection method for silage harvesting based improved U - Net[J]. Computers and Electronics in Agriculture, 2022, 198: 107046.
- [30] GUAN Xianlu, WAN Huan, HE Zixuan, et al. Pomelo-net: a lightweight semantic segmentation model for key elements segmentation in honey pomelo orchard for automated navigation[J]. Computers and Electronics in Agriculture, 2025, 229: 109760.
- [31] LIU Hui, LI Kun, MA Luyao, et al. Headland identification and ranging method for autonomous agricultural machines[J]. Agriculture, 2024, 14(2): 243.
- [32] ZHU Lixue, DENG Wenqian, LAI Yingjie, et al. Research on improved road visual navigation recognition method based on DeepLabV3 + in pitaya orchard[J]. Agronomy, 2024, 14(6): 1119.
- [33] DAI Guowei, TIAN Zhimin, FAN Jingchao, et al. DFN - PSAN: multi-level deep information feature fusion extraction network for interpretable plant disease classification[J]. Computers and Electronics in Agriculture, 2024, 216: 108481.
- [34] ZHANG Dongyan, ZHANG Wenhao, CHENG Tao, et al. Detection of wheat scab fungus spores utilizing the YOLO v5 - ECA - ASFF network structure[J]. Computers and Electronics in Agriculture, 2023, 210: 107953.