

红树林智能种植机多传感器视觉系统设计与应用

代上杭¹, 余江^{1,2}, 刘敏仪¹, 邓宁熙^{1,2}, 曾敬伟^{1,2}, 罗晓彤¹

¹广东海洋大学机械工程学院, 广东 湛江

²广东海洋大学机器人创新团队, 广东 湛江

收稿日期: 2026年6月23日; 录用日期: 2026年7月17日; 发布日期: 2026年7月28日

摘要

为提升红树林种植作业的智能化水平, 解决滩涂复杂环境下的作业难题, 本方案设计并实现了一套多源感知与边缘决策系统。系统硬件集成多模态传感器, 算法采用轻量化YOLOv10-MHSA模型进行实时目标检测, 并基于LoRaWAN网络构建了远程监控与多机协同机制。田间试验验证了系统的有效性, 实现了92.1%的坑洞检测准确率和96.1%的坑洞定位精度, 结合改进遗传算法使种植空间利用率达到91.7%, 有效种植点位数量提高25%。研究成果为红树林智能修复提供了可靠的技术方案。

关键词

红树林种植机, 多源感知, 边缘计算, 坑洞识别, 精准种植

Design and Application of Multi-Sensor Vision System for Mangrove Intelligent Planter

Shanghang Dai¹, Jiang Yu^{1,2}, Minyi Liu¹, Ningxi Deng^{1,2}, Jingwei Zeng^{1,2}, Xiaotong Luo¹

¹School of Mechanical Engineering, Guangdong Ocean University, Zhanjiang Guangdong

²Robotics Innovation Team, Guangdong Ocean University, Zhanjiang Guangdong

Received: June 23, 2026; accepted: July 17, 2026; published: July 28, 2026

Abstract

To enhance the intelligence of mangrove planting operations and address challenges in complex

文章引用: 代上杭, 余江, 刘敏仪, 邓宁熙, 曾敬伟, 罗晓彤. 红树林智能种植机多传感器视觉系统设计与应用[J]. 传感器技术与应用, 2026, 14(4): 762-773. DOI: 10.12677/jsta.2026.144073

tidal flat environments, this solution designs and implements a multi-source perception and edge decision-making system. The hardware integrates multimodal sensors, employs a lightweight YOLOv10-MHSA model for real-time object detection, and utilizes a LoRaWAN network to establish remote monitoring and multi-device collaboration mechanisms. Field trials demonstrated the system's effectiveness, achieving 92.1% accuracy in hole detection and 96.1% precision in hole localization. Combined with an improved genetic algorithm, it achieved a planting space utilization rate of 91.7% and increased the number of viable planting sites by 25%. These findings provide a robust technical framework for intelligent mangrove restoration.

Keywords

Mangrove Planter, Multi-Source Perception, Edge Computing, Hole Identification, Precision Planting

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

红树林在海岸带生态保护与碳汇平衡中具有不可替代的作用，但其人工管护长期面临劳动强度大、作业效率低、滩涂环境复杂等难题。尤其在种植环节，依赖人工作业不仅成本高，且受潮汐限制，难以满足大规模生态修复需求[1]。近年来智能农机技术快速发展，多传感器融合感知与边缘计算为农业自动化提供了新路径[2]-[4]。

针对这类难题，本方案在已有红树林种植机[5]基础上，集成视觉传感器与边缘计算单元，构建了多源感知与自主决策系统。重点突破了滩涂环境下坑洞识别、障碍物感知及自主导航等关键技术，并通过田间试验验证了系统的实用性。研究旨在实现红树林修复从“人工作业”向“智能装备作业”的转变。

2. 红树林种植机视觉系统总体设计

2.1. 多传感器融合感知系统架构设计

为提升红树林种植作业的智能化水平，本文构建了一套面向滩涂环境的多层级感知与控制系统，系统架构如图1所示。

感知层(看)：由安装在种植机上的 RGB 相机、深度传感器、固态激光雷达阵列组成，实时获取坑洞位置、障碍物分布等信息。

处理层(判)：部署于车载边缘计算单元(Jetson Orin NX)，对多源异构数据进行降噪、配准与融合，运行轻量化 YOLOv10-MHSA 目标检测模型，实现坑洞识别、障碍物检测等任务的实时推理，并基于 SLAM 算法构建局部环境地图。

决策层：根据感知与处理结果，进行路径规划与作业决策，包括种植点位优化、避障策略生成、投苗时机判断等。

执行层(做)：驱动种植机完成自主导航、动态避障与精准投苗作业，并通过 LoRaWAN 无线网络将作业状态回传至云端，支持远程监控与多机协同调度。

2.2. 传感器硬件选型与安装布局

系统核心传感器的选型及安装参数汇总见表1所示。




Figure 1. Architecture of the multi-sensor vision system for the mangrove planter

图 1. 红树林种植机多传感器视觉系统架构

Table 1. Summary of sensor selection and mounting layout

表 1. 传感器选型与安装布局汇总

参数	RGB 相机	深度传感器	激光雷达	超声波雷达
型号	海康 MV-CS200-10GM	Intel RealSense D455	禾赛 FT120	导向超声 KS206
核心功能	坑洞视觉检测	坑洞精细三维测量、近距避障	全局定位、SLAM 建图、环绕避障	履带侧近距离避障
分辨率/FOV	1920 × 1200	深度 1280 × 720	100° × 75°	100° × 50°
防护等级	IP67	IP54 (外加 IP67 防护罩)	IP67	IP67
安装位置	机架	箱体前部上沿	箱体前部 箱体尾部两侧	箱体后侧机架 履带内侧板前后
数量	1	1	3	6
俯仰角	90°(竖直)	-18°(下倾)	-5°(下倾)	0°(水平)

安装布局如图 2 所示。

2.3. 数据处理与融合

种植机搭载的多传感器数据需要经过预处理与融合才能用于后续决策。数据处理流程如图 3 所示。




Figure 2. Sensor layout configuration on the planter
图 2. 传感器布局示例




Figure 3. Data processing pipeline of the vision system
图 3. 种植机视觉数据处理流程

图像预处理：RGB 图像经过畸变校正与色彩增强，深度图像与 RGB 图像进行配准对齐，生成 RGB-D 数据。点云数据经过滤波去噪与降采样处理，减少计算负载。

特征融合：采用多模态特征提取与融合策略，将视觉特征、深度特征与点云特征在特征层面进行融合，提升目标检测的鲁棒性。

实时建图：基于改进的 SLAM 算法[6]，融合深度信息与激光雷达点云，实现低成本快速三维场景重建，为路径规划和避障提供支撑。三向雷达水平 FOV 叠加实现 360°全向感知，左右雷达向后偏转 30°安装确保尾部重叠覆盖。整套处理流程部署于车载边缘计算平台，处理延迟小于 50 ms，检测帧率达 30 FPS，满足滩涂环境下低延迟、高可靠性的作业需求。

3. 视觉感知与边缘决策算法

3.1. 基于 YOLOv10-MHSA 的坑洞识别算法

3.1.1. 算法设计

红树林滩涂环境地表反光强、淤泥纹理复杂、坑洞边缘模糊，传统模型易受背景干扰。本文在 YOLOv10 基础上引入多头自注意力机制(MHSA)，构建 YOLOv10-MHSA [7]模型。YOLOv10 提取局部纹理特征，MHSA 建立特征图空间位置的长距离依赖，增强坑洞整体结构感知能力[8]。改进后的网络结构如图 4 所示。

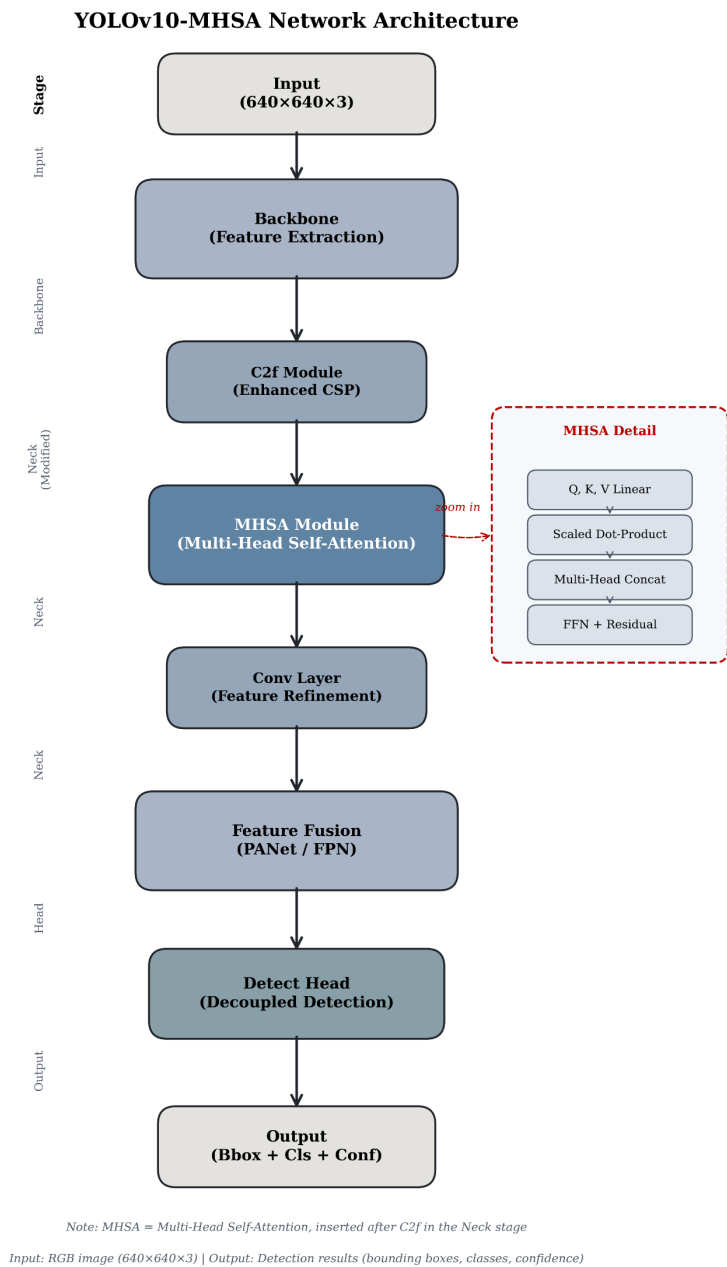


Figure 4. Network architecture of YOLOv10-MHSA and illustration of the MHSA module

图 4. YOLOv10-MHSA 网络结构及 MHSA 模块示意图

如图 4 所示, 本文保留 YOLOv10 原有 Backbone, 在 Neck 阶段 C2f 模块后嵌入 MHSA。MHSA 通过全局依赖关系增强坑洞边缘、积水反光及淤泥背景的特征表达, 经卷积层和 PANet/FPN 多尺度融合后, 由 Detect Head 输出坑洞位置及置信度。

MHSA 模块数学原理:

$$Attention(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V$$

其中 Q, K, V 为查询、键、值矩阵, d_k 为单头维度。

$$MHSA = \text{Concat}(\text{head}_1, \dots, \text{head}_h)W^O$$

$$\text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V)$$

其中 $h=8$ 为头数, W_i^Q, W_i^K, W_i^V 为投影矩阵, W^O 为输出映射。

针对坑洞边缘模糊、淤泥反光等问题, 采用 Focal-EIOU 损失优化边界框回归[9]:

$$\mathcal{L}_{\text{Focal-EIOU}} = \text{IoU}^\gamma \cdot \mathcal{L}_{\text{EIOU}}$$

$$\mathcal{L}_{\text{EIOU}} = 1 - \text{IoU} + \frac{\rho^2(b, b^{gt})}{c^2} + \frac{\rho^2(w, w^{gt})}{C_w^2} + \frac{\rho^2(h, h^{gt})}{C_h^2}$$

其中 $\gamma=0.5$, $\rho(\cdot)$ 为欧氏距离, b, b^{gt} 为框中心, c 为最小外接框对角线, C_w, C_h 为其宽高。

为提升模型在复杂地理环境下的泛化能力, 对实地采集的视觉图像进行了系统性数据增强, 包括 HSV 色彩变换、Mosaic 混合增强、MixUp 混合增强及随机翻转与缩放, 有效增强了样本多样性[10]。

改进前后识别结果对照及可视化如图 5 所示。




Figure 5. Comparison and visualization of recognition results before and after improvement

图 5. 改进前后识别结果对照及可视化

3.1.2. 性能指标定义

$$Precision = \frac{TP}{TP + FP}, \quad Recall = \frac{TP}{TP + FN}$$

精确率，召回率公式

$$mAP@0.5 = \frac{1}{N} \sum_{i=1}^N \int_0^1 p_i(r) dr$$

平均识别精度

$$DA = \frac{TP}{TP + FP + FN} \times 100\%$$

检测准确率

$$HPA = \left(1 - \frac{\sum_{j=1}^M \sqrt{(x_j^{pred} - x_j^{gt})^2 + (y_j^{pred} - y_j^{gt})^2}}{M \cdot d_{threshold}} \right) \times 100\%$$

坑洞定位精度

$$FPS = \frac{N_{frame}}{T_{total}}, \quad T_{delay} = T_{pre} + T_{infer} + T_{post}$$

其中 $d_{threshold} = 1.0 \text{ m}$ 。

YOLOv10-MHSA 模型性能指标汇总见表 2 所示。

Table 2. Performance metrics of the YOLOv10-MHSA model

表 2. YOLOv10-MHSA 模型性能指标

指标	数值
平均识别精度($mAP@0.5$)	96.1%
检测准确率(DA)	92.1%
推理帧率(FPS)	30 FPS
边缘端处理延迟(T_{delay})	<50 ms

该性能满足种植机对坑洞实时识别的精度与速度要求，为后续种植点位优化与精准投苗提供可靠感知输入。

3.2. 改进遗传算法的路径规划

3.2.1. 问题建模

坑洞识别完成后，需在有限作业空间内规划最优种植路径。将识别到的坑洞位置编码为二维坐标序列，以种植空间利用率最大化为适应度函数，约束条件包括：坑洞间距符合红树林种植规范(避免过密竞争)、路径总长度最短(减少履带碾压滩涂面积)、转弯半径满足履带底盘机动限制。

3.2.2. 算法改进

标准遗传算法在滩涂坑洞布局优化中存在早熟收敛、局部最优问题。本方案从三方面改进：

遗传算法的改进见表 3 所示。

Table 3. Improvements to the genetic algorithm
表 3. 遗传算法的改进

改进点	具体措施	作用
编码方式	实数编码二维坐标序列，引入坑洞优先级权重(大坑优先种植)	避免二进制编码空间爆炸，贴合实际作业顺序
适应度函数	多目标加权：空间利用率 + 路径平滑度 + 规范符合度	平衡密度、效率与生态约束
遗传操作	自适应交叉概率(0.6~0.9 动态调整)+ 精英保留策略 + 局部搜索变异	防止早熟，加速后期精细优化

$$F(\pi) = 0.5f_{space} + 0.3f_{smooth} + 0.2f_{norm}$$
$$f_{space} = \frac{kA_{unit}}{A_{total}} \left(1 - \frac{\sum_{i=1}^{k-1} \max(0, d_{min} - d(h_{\pi_i}, h_{\pi_{i+1}}))}{(k-1)d_{min}} \right)$$
$$f_{smooth} = 1 - \frac{\sum_{i=2}^{k-1} |\theta_i - \theta_{i-1}|}{(k-2)\pi}$$
$$f_{norm} = \frac{1}{k} \sum_{i=1}^k \mathbb{I}(d_{min} \leq d_{neighbor}(h_{\pi_i}) \leq d_{max})$$

权重 $w_1 = 0.5$ (空间利用为核心)、 $w_2 = 0.3$ (路径平滑)、 $w_3 = 0.2$ (规范符合)，根据种植作业优先级经验设定。空间利用率直接决定单位面积种植效益，故权重最高；路径平滑度影响机械损耗与生态保护次之；规范符合度为约束性指标，权重最低。

3.2.3. 优化效果

以 100 m × 100 m 标准作业区块为测试场景，种植规范要求株行距 2 m × 2 m。经田间试验验证，改进遗传算法相较顺序种植策略实现以下提升：
优化前后对比指标见表 4 所示。

Table 4. Comparison before and after optimization
表 4. 优化前后对比

指标	改进前(顺序种植)	改进后(遗传优化)	提升幅度
种植空间利用率	73.3%	91.7%	+18.4%
有效种植点位数	2200 株	2750 株	+25.0%
路径总长度	1850 m	1517 m	-18.0%
作业时间(同等面积)	62 min	52.7 min	-15.0%

优化后的种植点位序列驱动种植机自主导航，配合“看 - 判 - 做”闭环控制(见图 6)，实现从坑洞识别到精准投苗的全流程自动化。

3.3. “看 - 判 - 做” 闭环控制流程

种植机的核心工作流程遵循“看 - 判 - 做”闭环控制模式，如图 6 所示。




Figure 6. “See-Judge-Act” closed-loop control workflow of the planter
图 6. 种植机“看-判-做”闭环控制流程

4. 实验与结果

4.1. 实验数据集

4.1.1. 数据采集与标注

坑洞检测数据集采集于广东湛江红树林国家级自然保护区滩涂区域，使用表 1 所列 RGB 相机与深度传感器。采集时段覆盖 2025 年 3 月至 8 月，涵盖晴天、多云、阴天、雨后四种光照条件及干硬滩涂、湿润淤泥、积水镜面、杂草覆盖四种泥泞程度。

采用 LabelImg 工具进行边界框标注，标注规则：矩形框紧密包围坑洞外缘，双人独立标注 + 仲裁机制(一致性 IoU>0.85)。总采集原始图像 1800 张，经筛选(剔除模糊、过曝、遮挡严重样本)，最终构建包含 1200 张标注图像的数据集，按 7:2:1 比例划分为训练集 840 张、验证集 240 张与测试集 120 张，用于模型训练与性能测试。

4.1.2. 训练设置

输入分辨率 640 × 640，批次大小 16，SGD 优化器(动量 0.937，初始学习率 0.01)，训练 300 epoch，硬件平台 NVIDIA Jetson Orin NX，软件使用 Ubuntu 20.04，CUDA 11.8，PyTorch 2.0.1。

4.2. 实验结果

4.2.1. 坑洞识别性能

模型性能对比指标见表 5 所示。

Table 5. Performance comparison of different models
表 5. 模型性能对比

模型	mAP@0.5	DA	HPA	FPS
YOLOv5s	89.3%	85.7%	88.2%	45
YOLOv8n	91.7%	88.4%	90.5%	38
YOLOv10	93.5%	90.2%	92.4%	32
YOLOv10-MHSA	96.1%	92.1%	96.1%	30

MHSA 模块使 mAP 提升 2.6%，HPA 提升 3.7%，参数量增加仅 6.6%，在 Jetson Orin NX 上保持 30FPS 实时推理。

4.2.2. 不同环境条件分析

不同环境条件下性能分析指标见表 6 所示。

Table 6. Performance analysis under different environmental conditions (test set n = 120, stratified statistics)
表 6. 不同环境条件下性能分析(测试集 n = 120, 分层统计)

条件类型	具体条件	测试样本数	mAP@0.5	DA	HPA
光照	晴天强光	30	94.2%	89.5%	94.8%
	多云散射	30	97.3%	93.8%	97.1%
	阴天弱光	30	95.8%	91.2%	95.5%
	雨后低光	30	93.1%	87.6%	92.3%
泥泞	干硬滩涂	30	97.8%	95.1%	97.5%
	湿润淤泥	30	96.5%	93.2%	96.3%
	积水镜面	30	92.4%	86.8%	91.7%
	杂草覆盖	30	94.7%	89.4%	94.2%
潮汐	低潮位	40	97.1%	94.5%	96.8%
	中潮位	40	94.8%	90.3%	94.1%
	高潮位	40	91.2%	85.7%	90.5%

注：测试集共 120 张样本，每张样本同时标注光照、泥泞、潮汐属性。各条件类型样本数按单一维度分层统计，存在样本复用。

关键结论：多云散射光、干硬滩涂、低潮位为最优作业条件；积水镜面和高潮位是主要挑战，优先选择低潮位窗口作业。

4.2.3. 消融实验

消融实验指标见表 7 所示。

Table 7. Ablation study results
表 7. 消融实验

模型配置	mAP@0.5	DA	HPA	参数量(M)
YOLOv10 (基线)	93.5%	90.2%	92.4%	27.3

续表

YOLOv10 + MHSA	95.2%	91.8%	94.9%	29.1
YOLOv10 + Focal-EIOU	94.6%	91.0%	93.7%	27.3
YOLOv10-MHSA (完整)	96.1%	92.1%	96.1%	29.1

MHSA 与 Focal-EIOU 产生协同效应，单独添加分别提升 mAP 1.7%和 1.1%。

4.3. 讨论

与现有方法对比,本文 YOLOv10-MHSA 在坑洞检测精度(mAP@0.5 96.1%)上优于 YOLOv5s (89.3%)、YOLOv8n (91.7%)及 YOLOv10 基线(93.5%), MHSA 模块引入使 mAP 提升 2.6 个百分点。实时性方面, 30 FPS 虽略低于 YOLOv10 基线(32 FPS)和 YOLOv5s (45 FPS), 但仍满足种植机滩涂作业最低 25 FPS 要求。参数量增加 6.6% (27.3 M→29.1 M)未造成显著推理延迟, 在 Jetson Orin NX 上保持实时性能。相较于农业目标检测通用模型, 本文针对滩涂坑洞边缘模糊、淤泥反光等特有问题进行优化, 检测准确率(DA 92.1%)与定位精度(HPA 96.1%)均达到实用水平。

环境适应性分析方面, 系统性能受光照条件影响显著, 多云散射光下 mAP 达 97.3%(最优), 雨后低光降至 93.1%(最差), 降幅 4.2%。强光导致坑洞边缘硬化与反光, 低光则降低信噪比, 两者均削弱 MHSA 模块的全局特征提取能力。泥泞程度中积水镜面条件挑战最大(mAP 92.4%), 水面镜面反射产生虚假边缘, 与坑洞真实轮廓混淆; 干硬滩涂性能最优(97.8%), 地表纹理一致性高。潮汐状态直接决定坑洞可见面积, 高潮位时 mAP 降至 91.2%, 提示实际作业应优先选择低潮位窗口, 或融合深度传感器的水下测量能力补偿视觉盲区。受数据采集条件限制, 当前数据集规模相对有限, 后续将进一步扩充不同季节和潮汐条件下的数据样本。

局限性: (1) 极端天气(暴雨、浓雾)条件下的坑洞识别尚未验证, 需进一步采集数据; (2) 当前实验为单机作业, 多机协同的坑洞分配与防重复种植策略待开展; (3) 29.1 M 参数量对 Jetson Nano 等低算力平台仍有压力, 未来需探索通道剪枝或知识蒸馏轻量化; (4) 高潮位作业性能显著下降, 需融合深度传感器或偏振滤光片提升鲁棒性。

未来方向: 提升模型在极端工况下的可靠性; 优化轻量化程度降低硬件成本; 开展多机协同规模化验证; 探索潮汐自适应作业窗口规划。

5. 结论与展望

本研究提出并验证了面向红树林种植机的多传感器视觉系统, 聚焦种植机“看-判-做”三大核心功能, 其有效性得到田间试验验证。结果表明, 基于多源感知与边缘决策的系统架构, 实现了从环境感知到精准执行的稳定闭环。在数据处理层面实现了低成本、高精度的三维场景重建, 模型在坑洞定位与动态避障等任务上均表现出优越性能, 坑洞检测准确率达 92.1%, 结合优化布局算法, 单位面积有效种植密度提升 25%。

未来工作将聚焦于: 提升系统在暴雨、强淤泥等极端工况下的可靠性; 进一步优化模型轻量化程度, 降低硬件成本; 开展多机协同规模化作业验证, 推动红树林修复从人工作业向智能农机作业转型。

参考文献

[1] Wang, L., Jia, M.M., Yin, D.M., *et al.* (2019) A Review of Remote Sensing for Mangrove Forests: 1956-2018. *Remote Sensing of Environment*, **231**, Article 111223. <https://doi.org/10.1016/j.rse.2019.111223>
[2] Zhang, X., Cao, Z. and Dong, W. (2020) Overview of Edge Computing in the Agricultural Internet of Things: Key

- Technologies, Applications, Challenges. *IEEE Access*, **8**, 141748-141761. <https://doi.org/10.1109/access.2020.3013005>
- [3] Kim, J., Kim, G., Yoshitoshi, R. and Tokuda, K. (2025) Real-Time Object Detection for Edge Computing-Based Agricultural Automation: A Case Study Comparing the YOLOX and YOLOv12 Architectures and Their Performance in Potato Harvesting Systems. *Sensors*, **25**, Article 4586. <https://doi.org/10.3390/s25154586>
- [4] Han, C., Wu, W., Luo, X. and Li, J. (2023) Visual Navigation and Obstacle Avoidance Control for Agricultural Robots via LiDAR and Camera. *Remote Sensing*, **15**, Article 5402. <https://doi.org/10.3390/rs15225402>
- [5] 胡俊泽, 余江, 陈柯良, 等. 一种湿地植被修复机器人设计[J]. 国际机械工程, 2023, 2(4): 1-5.
- [6] Pan, H., Liu, D., Ren, J., Huang, T. and Yang, H. (2024) LiDAR-IMU Tightly-Coupled SLAM Method Based on IEKF and Loop Closure Detection. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **17**, 6986-7001. <https://doi.org/10.1109/jstars.2024.3357536>
- [7] 谢纪元, 张东彦, 牛圳, 等. 基于 YOLOv10-MHSA 的“三北”工程内蒙古地区植树位点精准检测研究[J]. 智慧农业(中英文), 2025, 7(3): 108-119.
- [8] Wang, Y., Liao, M.G., Chu, N., Chen, X., Li, S.N. and Zhou, J.J. (2025) Mangrove Identification Method and Temporal Change Analysis Based on Semantic Segmentation Model in Wenzhou. *Remote Sensing Technology and Application*, **40**, 545-556.
- [9] 陈俊霖, 赵鹏, 曹先林, 等. 基于通道剪枝的轻量化 YOLOv8s 草莓穴盘苗分级检测与定位方法[J]. 智慧农业, 2024, 6(6): 132-143.
- [10] Jiang, S., Ao, J., Yang, H., Xie, F., Liu, Z., Yang, S., *et al.* (2024) Fine-Grained Recognition of Bitter Gourd Maturity Based on Improved YOLOv5-Seg Model. *Scientific Reports*, **14**, Article No. 10856. <https://doi.org/10.1038/s41598-024-61635-w>