

分类号：
学号：20232009047

密级：公开
单位代码：10759

石河子大学

硕士学位论文



基于边缘计算的番茄穴盘苗缺苗检测研究

学位申请人	张聪华
指导教师	任玲 教授
申请学位门类级别	工学硕士
学科、专业名称	农业工程
研究方向	农业电气化与自动化
所在学院	机械电气工程学院

中国·新疆·石河子

2026年5月

分类号：
学号：20232009047

密级：公开
单位代码：10759

石河子大学

硕士学位论文



基于边缘计算的番茄穴盘苗缺苗检测研究

学位申请人	张聪华
指导教师	任玲教授
申请学位门类级别	工学硕士
学科、专业名称	农业工程
研究方向	农业电气化与自动化
所在学院	机械电气工程学院

中国·新疆·石河子
2026年5月

**Research on tomato plug seedling missing detection based on edge
computing**

A Dissertation Submitted to
Shihezi University
In Partial Fulfillment of the Requirements
for the Degree of
Master of Engineering

By

Zhang Conghua
(Agricultural Electrification and Automation)

Dissertation Supervisor: Prof. Ren Ling

May,2026

石河子大学学位论文独创性声明及使用授权声明

学位论文独创性声明

本人所提交的学位论文是在我导师的指导下进行的研究工作及取得的研究成果。据我所知，除文中已经注明引用的内容外，本论文不包含其他个人已经发表或撰写过的研究成果。对本文的研究做出重要贡献的个人和集体，均已在文中作了明确的说明并表示谢意。

研究生签名：张聪华

时间：2026年5月25日

使用授权声明

本人完全了解石河子大学有关保留、使用学位论文的规定，学校有权保留学位论文并向国家主管部门或指定机构送交论文的电子版和纸质版。有权将学位论文在学校图书馆保存并允许被查阅。有权自行或许可他人将学位论文编入有关数据库提供检索服务。有权将学位论文的标题和摘要汇编出版。保密的学位论文在解密后适用本规定。

研究生签名：张聪华

时间：2026年5月25日

导师签名：任玲

时间：2026年5月25日

摘要

针对温室番茄穴盘苗缺苗检测任务中存在的小目标识别困难、复杂光照干扰严重以及边缘设备算力受限等问题,本文提出了一种基于边缘计算的轻量化缺苗检测方法。以24穴局部图像为基本检测单元,开展从数据集构建、模型优化、剪枝压缩到边缘部署的全流程研究,实现对缺苗空穴的精准识别与实时检测。本文的主要研究内容和结论如下:

(1) 番茄穴盘苗缺苗数据集构建。针对温室自然光环境,采集涵盖弱光、中光和强光等场景的穴盘苗图像,通过投影法精确定位穴盘行列,采用滑动窗口策略将完整72穴图像裁剪为6300张24穴局部图像,并完成单类别缺苗标注。统计分析表明,缺苗目标在局部图像中像素占比小于3%,宽高比集中于0.9~1.1,数据集光照场景分布均衡,为模型训练奠定数据基础。

(2) YOLO-SFEP 缺苗检测模型构建与验证。以YOLOv8n为基准,提出小目标改进网络(SOIN)增强缺苗空穴的细节特征提取能力;引入高效多尺度注意力机制(EMA)抑制光照干扰;采用FasterNet Block构建轻量化模块(CFNB)降低复杂度;引入PIoU损失函数优化回归精度。在自建数据集上的实验结果表明,YOLO-SFEP模型的精确率达96.7%,召回率达98.8%,平均精度均值(mAP50)达97.9%,且在弱光、中光和强光条件下平均mAP50达97.9%,验证了模型在复杂光照环境下的强鲁棒性。

(3) 多策略融合剪枝与模型轻量化。为适配边缘设备算力约束,提出Slim-L1-LAMP多粒度融合剪枝方案,分阶段从通道、滤波器和权重三个层级剔除冗余。在55%剪枝比例下,模型参数量压缩至1.89M,计算量降至3.5G,模型体积缩减至3.8MB,而mAP50仍保持97.9%,实现了高精度与轻量化的平衡。

(4) 边缘端系统部署与性能测试。将剪枝后的模型部署于树莓派5平台,通过模型转换与NCNN推理引擎集成,构建实时检测系统。测试结果表明,系统单帧推理帧率达16.2FPS,端到端延迟68.1ms,满足实时性要求;精度复测mAP50达96.3%,精度损失控制在2%以内;系统在30分钟连续运行中CPU占用率稳定在50%~60%,内存占用1.1GB,功耗5~7W,且在不同光照条件下均保持稳定检测性能(mAP50 \geq 95.1%),验证了系统在实际生产环境中的可靠性与实用性。

关键词: 缺苗检测; 番茄穴盘苗; YOLO-SFEP; 模型剪枝; 边缘计算; 树莓派5

Abstract

To address the challenges of small object detection, complex illumination interference, and limited computing power of edge devices in the task of missing seedling detection for tomato plug seedlings in greenhouses, this thesis proposes a lightweight missing seedling detection method based on edge computing. Using 24-cell local images as the basic detection unit, a full-process study encompassing dataset construction, model optimization, pruning compression, and edge deployment was conducted to achieve accurate identification and real-time detecting of missing cells. The main research contents and conclusions are as follows:

(1) Construction of a tomato plug seedling missing seedling dataset. Aiming at the natural light environment of greenhouses, images of plug seedlings were collected under various lighting conditions including low, medium, and strong light. The rows and columns of the plug tray were precisely located using the projection method. A sliding window strategy was employed to crop the complete 72-cell images into 6,300 local images of 24 cells, followed by single-class annotation for missing cells. Statistical analysis shows that the pixel ratio of missing targets in the local images is less than 3%, with an aspect ratio concentrated between 0.9 and 1.1. The dataset has a balanced distribution of lighting scenes, providing a solid data foundation for model training.

(2) Construction and validation of the YOLO-SFEP missing seedling detection model. Using YOLOv8n as the baseline, a Small Object Improvement Network (SOIN) was proposed to enhance the detailed feature extraction capability for missing cells. An Efficient Multi-scale Attention mechanism (EMA) was introduced to suppress illumination interference. A lightweight module (CFNB) was constructed using the FasterNet Block to reduce model complexity. The PIoU loss function was adopted to optimize regression accuracy. Experimental results on the self-built dataset show that the YOLO-SFEP model achieves a precision of 96.7%, a recall of 98.8%, and a mean Average Precision (mAP50) of 97.9%. Furthermore, it demonstrates strong robustness under low, medium, and strong light conditions, with an average mAP50 of 97.9%, verifying its adaptability to complex greenhouse lighting environments.

(3) Multi-strategy fusion pruning and model lightweighting. To adapt to the computational constraints of edge devices, a Slim-L1-LAMP multi-granularity fusion pruning scheme was proposed to systematically remove redundancy at the channel, filter, and weight levels in stages. At a 55% pruning ratio, the model's parameters were reduced to 1.89 M (a 27.9% reduction), computational load to 3.5 G (a 59.8% reduction), and model size to 3.8 MB, while maintaining an mAP50 of 97.9%, achieving a balance between high precision and lightweight design.

(4) Edge system deployment and performance testing. The pruned model was deployed on a Raspberry Pi 5 platform. A real-time detection system was built through model conversion and integration with the

NCNN inference engine. Test results show that the system achieves a single-frame inference rate of 16.2 FPS and an end-to-end latency of 68.1 ms, meeting real-time requirements. The replicated accuracy test yields an mAP50 of 96.3%, with a precision loss controlled within 2%. During 30 minutes of continuous operation, the system maintains stable CPU usage between 50% and 60%, memory usage of 1.1 GB, and power consumption of 5~7 W. It also maintains stable detection performance under different lighting conditions (mAP50 \geq 95.1%), validating the system's reliability and practicality in real production environments.

Key words: missing seedling detection; tomato plug seedlings; YOLO-SFEP; model pruning; edge computing; Raspberry Pi 5

主要符号表

缩写	英文全称	中文全称
AP	Average precision	平均精度
BCE	Binary cross-entropy	二元交叉熵
BN	Batch normalization	批量归一化
C2f	Cross-stage partial bottleneck with two convolutions	一种高效特征提取模块
CFNB		结合 FasterNet Block 的轻量化模块
CIoU	Complete intersection over union	一种损失函数计算方法
CNN	Convolutional neural network	卷积神经网络
CPU	Central processing unit	中央处理器
CUDA	Compute unified device architecture	统一计算设备架构
DConv	Depth-wise convolution	深度可分离卷积
DFL	Distribution focal loss	一种损失函数计算方法
ECA	Efficient channel attention	通道注意力机制
EMA	Efficient multi-scale attention	高效多尺度注意力机制
Faster R-CNN		一种两阶段目标检测算法
FCN	Fully convolutional networks	全卷积网络
FFT	Fast fourier transform	快速傅里叶变换
FLOPS	Floating point operations per second	每秒浮点运算次数
FN	False negative	假阴性
FP	False positive	假阳性
FPS	Frames per second	每秒帧数
GAN	Generative adversarial networks	生成式对抗网络
GPU	Graphics processing unit	图形处理器
GSConv	Group shuffle convolution	分组混洗卷积
HWC	Height-width-channel	一种数据布局格式

IFFT	Inverse fast fourier transform	快速傅里叶逆变换
INT8	8-bit integer	8 位整数
IoU	Intersection over union	交并比
LAMP	Layer-adaptive sparsity for the magnitude-based pruning	一种模型剪枝方法
mAP	Mean average precision	平均精度均值
NAS	Neural architecture search	神经架构搜索
NCNN		一种神经网络推理框架
NCHW	Batch-channel-height-width	一种数据布局格式
NMS	Non-maximum suppression	非极大值抑制
NPU	Neural network processing unit	神经网络处理器
ONNX	Open neural network exchange	开放神经网络交换格式
OpenCV	Open source computer vision library	开源计算机视觉库
PANet	Path aggregation network	路径聚合网络
PConv	Partial convolution	部分卷积
PF	Penalty factor	惩罚因子
PIoU	Powerful intersection over union	一种损失函数计算方法
PWConv	Pointwise convolution	逐点卷积
SGD	Stochastic gradient descent	随机梯度下降
SiLU	Sigmoid linear unit	一种激活函数
SOIN	Small object improvement network	小目标改进网络
SPDConv	Space-to-depth convolution	空间到深度卷积
SPP	Spatial pyramid pooling	空间金字塔池化
SPPF	Spatial pyramid pooling - fast	快速空间金字塔池化
SSD	Single shot multibox detector	一种单阶段的目标检测算法
TP	True positive	真阳性（正确检测）
YOLO	You only look once	一种单阶段的目标检测算法

目录

摘要	I
Abstract	II
主要符号表	IV
目录	VI
第 1 章 绪论	1
1.1 研究背景和意义	1
1.2 国内外研究现状	2
1.2.1 穴盘苗缺苗检测研究现状	2
1.2.2 边缘计算研究现状	3
1.3 研究目标与研究内容	4
1.3.1 研究目标	4
1.3.2 研究内容	5
1.3.3 技术路线	5
1.4 本章小结	6
第 2 章 番茄穴盘苗图像采集与数据集构建	7
2.1 需求分析	7
2.1.1 检测场景分析	7
2.1.2 番茄穴盘苗表型特征分析	8
2.1.3 复杂光照影响分析	8
2.1.4 系统性能指标要求	9
2.2 数据采集	10
2.3 番茄穴盘苗缺苗数据集制作	11
2.3.1 图像关键区域提取	12
2.3.2 图像标准化与标注	12
2.3.3 数据增强策略	13
2.3.4 数据集划分与分析	14
2.4 本章小结	15
第 3 章 YOLO-SFEP 番茄穴盘苗缺苗检测模型	16
3.1 基准模型 YOLOv8n	16
3.1.1 模型选取依据	16
3.1.2 模型结构分析	16

3.2 YOLO-SFEP 模型构建	18
3.2.1 小目标改进网络 SOIN	19
3.2.2 基于 FasterNet Block 的轻量化设计	20
3.2.3 引入 EMA 注意力机制的特征融合网络	22
3.2.4 PIoU 损失函数	23
3.3 试验训练环境及方法	24
3.3.1 试验软硬件环境	24
3.3.2 评价指标	25
3.3.3 超参数设置与训练策略	26
3.4 试验与结果分析	27
3.4.1 训练过程收敛性分析	27
3.4.2 消融试验与分析	28
3.4.3 主流模型对比与性能优势分析	29
3.4.4 不同光照条件下的鲁棒性验证	31
3.4.5 可视化分析与模型决策机制	32
3.5 本章小结	33
第 4 章 YOLO-SFEP 模型的剪枝与压缩	35
4.1 模型剪枝必要性分析	35
4.2 结构化剪枝	35
4.3 多粒度剪枝策略	36
4.3.1 Slim 通道剪枝：基于 BN 稀疏化的粗粒度压缩	37
4.3.2 L1 卷积核剪枝：滤波器级的中粒度优化	38
4.3.3 LAMP 剪枝：权重级的细粒度微调	39
4.4 多策略融合剪枝方案	40
4.5 试验及结果分析	41
4.5.1 试验参数配置与评价指标	41
4.5.2 单策略剪枝效果对比分析	42
4.5.3 多策略融合剪枝实验	44
4.5.4 剪枝前后可视化结果分析	45
4.5.5 不同剪枝比例下的性能权衡分析	46
4.6 本章小结	47
第 5 章 模型部署与边缘端实验分析	49
5.1 边缘计算硬件平台选型与配置	49
5.1.1 树莓派 5 硬件特性分析	49

5.1.2 系统软件环境配置	50
5.2 模型部署	51
5.2.1 模型转换与优化	51
5.2.2 推理引擎集成	52
5.3 番茄穴盘苗缺苗检测系统搭建	53
5.4 性能测试与分析	56
5.4.1 边缘端性能测试	57
5.4.2 不同光照环境下的鲁棒性测试	58
5.5 本章小结	59
第 6 章 结论与展望	61
6.1 结论	61
6.2 展望	62
参考文献	63
致谢	67
作者简介	68

第 1 章 绪论

1.1 研究背景和意义

新疆是我国加工番茄的重要生产基地，其番茄制品出口量占全国近 70%，种植面积达 57.36 千公顷以上^[1]。该地区主要采用育苗移栽的种植方式，这一方式能够有效规避倒春寒等恶劣气候对幼苗的影响，显著提升成活率与作物品质，是大规模番茄种植的关键技术保障^[2-3]。然而，在穴盘育苗过程中，受种子发芽率、播种均匀性及环境因素的综合影响，穴盘内常出现缺苗现象，直接制约了后续移栽质量与产量稳定性^[4-6]。因此，在幼苗生长的关键阶段——2 叶 1 心期精准识别缺苗空穴，是实现自动补苗和保障穴盘苗一致性的前置条件^[7-8]。

当前，缺苗检测主要依赖人工目检，该方式劳动强度大、效率低且主观性强，难以适应规模化、标准化的育苗需求^[9-12]。传统机器视觉方法虽实现了初步自动化，但其依赖人工设计的低层特征，对光照变化、阴影干扰及复杂背景的适应能力有限，检测精度与鲁棒性难以满足实际生产要求^[13]。近年来，深度学习技术虽在精度上表现优异，但其庞大的参数量与计算开销使其严重依赖云端服务器^[14-15]。在温室、苗床等农业现场，若将海量图像数据回传云端处理，将面临网络带宽受限、传输延迟高和数据隐私风险等一系列现实问题，难以实现实时反馈与控制^[16-17]。

与此同时，缺苗空穴作为典型小目标，其像素占比低、边缘纹理特征细微，易受叶片遮挡、基质颜色干扰及光照不均等因素影响，进一步加剧了特征提取难度。在自然光照动态变化的温室环境中，这些问题相互交织，对检测算法的鲁棒性与实时性提出了极高要求^[18]。

边缘计算技术的出现，为解决上述问题提供了新的技术路径。通过将计算能力下沉至数据源近端的边缘设备，能够在现场完成图像采集、实时推理与结果反馈，从根本上规避云端依赖带来的延迟与带宽瓶颈^[19]。然而，将高精度的深度学习模型部署于树莓派等资源受限的边缘平台，仍面临严峻挑战：模型需在保持检测精度的前提下，实现参数量、计算量与存储体积的极限压缩，以适应边缘设备的算力与功耗约束^[20]。

针对上述挑战，本研究以 24 穴局部图像为基本检测单元，聚焦于小目标特征增强与模型轻量化两大核心难题，构建面向复杂光照环境的 YOLO-SFEP 检测模型，并通过多策略融合剪枝实现模型深度压缩，最终部署于树莓派 5 边缘平台。该研究策略将边缘计算与深度学习技术深度融合，形成“边缘感知—模型压缩—终端部署”的系统化技术闭环。

本研究不仅为新疆番茄育苗自动化补苗提供关键技术支撑，也在小目标检测与边缘智能融合方面具有明确的理论创新与工程推广价值。研究成果可作为核心算法模块，通过滑动窗口或多视角拼接策略扩展至完整 72 穴盘检测任务，为后续移栽机的自动补苗作业提供精准的缺苗位置信息，推动设施农业装备向轻量化、智能化和边缘化方向发展。

1.2 国内外研究现状

1.2.1 穴盘苗缺苗检测研究现状

在缺苗检测问题研究的早期阶段，国内外学者探索利用基于传统图像处理方法的机器视觉技术，以实现缺苗的自动化识别。张丽娜等^[21]通过深度相机获取黄瓜穴盘幼苗的点云数据，以叶面积和株高的乘积作为分级系数，以整盘穴盘幼苗分级系数的均值与标准差差值作为该穴盘的晚出苗分级阈值，实现对穴盘晚出苗的自动检测。FU 等^[22]利用机器视觉技术检测叶菜苗生长参数，通过对图像进行灰度化、阈值分割等处理得到幼苗叶面积的像素值，并与预定标准值进行比较，提高移栽过程中对幼苗的识别精度。JIN 等^[23]采用深度相机获取单行幼苗的侧面图像，通过基于 OpenCV 的图像分析以及深度图像的对齐，精确获取幼苗的形态信息，提高了移栽的成功率。以上文献均基于传统的图像处理方法进行图像预处理和特征提取，该方法通常采用颜色空间转换和阈值分割，而温室光照强度的变化会导致幼苗叶片颜色特征的改变，固定阈值无法自适应调整，容易导致误检和漏检对检测精度有很大影响，检测稳定性不高。尤其是在自然光条件下，穴盘育苗场景往往伴随光照不均、阴影干扰、基质颜色变化以及幼苗形态差异等复杂因素，传统基于固定阈值和人工设计特征的方法难以保持稳定的检测精度^[24-25]。同时，幼苗早期尺度小、叶片重叠少、目标特征不明显，进一步增加了缺苗检测的难度^[26-27]。

近年来，深度学习相关算法也被广泛应用于农业领域的图像分类、分割和目标检测等任务^[28-31]。王璨等^[32]通过引入双注意力机制改进语义分割模型，有效区分了形态边界高度相似的幼苗期玉米与杂草。宋磊等^[33]利用深度学习中的单目图像深度估计技术，以 ResNeXt 101 网络为深度估计网络主体，通过深度估计网络获取图像的深度信息，计算拍摄点到植株的真实距离，实现了对多种幼苗在不同距离和一定光照强度变化下的精确测量。张秀花等^[34]提出了 YOLOv3-Tiny 目标检测改进模型，通过添加空间金字塔池化 SPP (Spatial pyramid pooling) 和路径聚合网络 PANet (Path aggregation network) 等方法，提高了番茄苗分选移栽分级检测精度。JIN 等^[35]提出了 EBG_YOLOv5 模型，通过在主干网络中集成高效的通道注意力机制 ECA (Efficient channel attention)，在颈部引入双向特征金字塔和分组混洗卷积 GSConv (Group shuffle convolution)，提高了水培生菜残次叶片的检测精度和效率。尽管深度学习模型在检测精度上显著优于传统方法，但仍

面临挑战：一是模型参数量大、计算复杂度高，对硬件资源要求苛刻；二是实验室环境下的优异性能难以在真实育苗场景中稳定复现，复杂背景和光照变化易导致检测性能波动。

总体而言，穴盘苗缺苗检测研究已从传统机器视觉的初步探索，逐步迈向深度学习驱动的精准确检测阶段，正从算法可行性验证向工程化应用转型。针对小目标检测、复杂光照适应性和模型性能优化等核心问题，仍有较大研究空间，这也为深度学习与边缘计算技术的结合提供了现实需求。

1.2.2 边缘计算研究现状

边缘计算（Edge Computing）作为一种将计算能力下沉至数据源近端的架构范式，为深度学习模型在农业现场的实时部署提供了可行路径^[36-39]。在穴盘苗检测等农业视觉任务中，边缘计算的应用主要体现在两条技术路径上：一是设计原生轻量化网络，通过结构创新降低模型复杂度；二是对已有高精度模型进行压缩与加速，适配边缘硬件资源。

在轻量化网络设计方面，研究者通过引入深度可分离卷积、轻量残差模块、注意力机制等手段，在保证检测精度的前提下显著降低模型参数量和计算开销。Lu 等人^[40]提出的 MAR-YOLOv9 网络，通过设计 16 倍下采样结构和创新的特征拼接方式，在多个植物数据集上实现了精度与效率的平衡。针对辣椒穴盘育苗检测难题，孔德航等人^[41]设计了 YOLOv8nSCS 轻量化网络模型。该模型通过 StarNet 轻量骨干网络和网络结构优化，在整盘检测中实现 21 帧/秒的检测速度和 98.2%的准确率，参数量仅 1.2×10^6 ，有效平衡了检测性能与边缘设备算力需求。针对水果检测模型在边缘设备上部署困难的问题，Zhang 等人^[42]设计了一种专为边缘设备优化的轻量级检测算法。该模型基于 Light-CSPNet 骨干网络，通过改进特征提取、下采样和特征融合模块，在保持精度的同时实现了实时检测。

在模型压缩与加速方面，结构化剪枝、权重量化和知识蒸馏等技术被广泛用于将高精度模型适配至嵌入式平台。针对桥梁拉索缺陷检测难题，葛祥等人^[43]设计了 YOLOv7-SP 轻量化模型，该模型通过引入注意力机制和部分卷积优化特征提取，结合自适应剪枝压缩模型，在参数量仅 0.58 M 的情况下，实现了 89.1%的检测精度和 134 FPS 的推理速度，有效平衡了检测性能与边缘部署需求。针对棉花氮素营养诊断模型难以在边缘设备部署的问题，陈沛沛等人^[44]提出基于树莓派 4B 的轻量化诊断方法。该研究采用 ResNet101 构建诊断模型，通过网络瘦身算法剪枝优化，最终将剪枝比例 87%的模型部署于树莓派 4B。试验表明，剪枝后模型参数量 4.37 M、计算量 1.05 G 和存储体积 16.65 MB，精度损失仅 2.55 个百分点，有效提升了边缘设备上的推理速度，为作物营养状况的田间快速诊断和智能终端装备研发提供了技术参考。针对植物幼苗分类模型在边缘设

备部署困难的问题，Fountsop 等人^[45]对 LeNet5、VGG16 和 AlexNet 等卷积神经网络进行了剪枝与量化压缩。研究表明，模型参数可缩减约 38 倍，VGG16 的浮点运算量减少 99%，且精度基本保持不变，验证了结构化剪枝与权重量化技术可将大型模型压缩至树莓派等低功耗设备可接受的规模，为田间实时应用提供了技术支撑。

以上文献中边缘计算在农业视觉任务中展现出广阔前景，但仍面临多重挑战。首先，小目标检测精度与模型轻量化之间的矛盾依然突出。在穴盘小孔幼苗、辣椒种子等小籽粒作物检测中，模型压缩往往导致特征表达能力下降，进而影响召回率与定位精度。其次，复杂光照与背景干扰仍是导致误检、漏检的主要因素，亟需结合鲁棒特征提取与自适应机制进一步优化。最后，边缘硬件平台的多样性也对模型的跨设备适配与性能调优提出更高要求。

综上所述，边缘计算与深度学习技术的融合正从实验室验证向工程化部署稳步推进。轻量化网络设计、模型压缩技术与边缘推理框架的协同优化，为温室育苗场景下的实时、低成本、智能化管理提供了技术支撑，也为本研究基于树莓派 5 平台部署 YOLO-SFEP 模型奠定了理论基础与技术参考。

1.3 研究目标与研究内容

1.3.1 研究目标

本研究旨在针对温室自然光环境下番茄穴盘苗的自动补苗需求，以 24 穴局部图像为基本检测单元，聚焦小目标缺苗检测、复杂光照适应性及边缘端轻量化部署三大核心难题，提出一种基于深度学习的轻量化缺苗检测方法，实现对局部图像中缺苗空穴的精准识别与定位。具体研究目标包括：

(1) 面向小目标缺苗的高精度检测：针对缺苗空穴在图像中像素占比低、边缘纹理特征细微所导致的特征提取困难问题，以 24 穴局部图像为研究对象，构建专注于识别缺苗空穴的单类别检测模型。通过优化小目标特征提取结构，增强模型对穴孔边缘、基质纹理等细节特征的感知能力，提升对局部区域内空穴位置识别的精确率与召回率。

(2) 复杂光照环境下的鲁棒性增强：针对温室自然光照动态变化对检测性能造成的干扰，通过引入高效注意力机制与多尺度特征融合策略，增强模型对缺苗区域的自适应聚焦能力，有效抑制光照过曝、阴影遮挡及基质反光等背景噪声，提升模型在不同光照条件下的检测稳定性与泛化能力。

(3) 边缘端适配的轻量化模型构建：针对农业现场边缘设备算力有限、内存受限的物理约束，在保证检测精度的前提下，通过轻量化算子替换与多策略模型剪枝等技术，显著压缩模型参数量、计算量与存储体积。实现模型在树莓派 5 等边缘计算平台上的实