doi:10.6041/j.issn.1000-1298.2025.06.020

基于改进 YOLO v8 的玉米大豆间套复种作物行导航线提取方法

朱惠斌　李　仕　白丽珍　王明鹏　贾宇轩　兰冀贤
（昆明理工大学现代农业工程学院，昆明 650500）

摘要：针对玉米大豆间套复种场景下导航线提取算法在复杂农田环境中精度低和适应性差等问题，提出一种基于改进 YOLO v8 的作物行间导航线提取方法，以提升自主移动底盘在田间作业中的导航精度。针对玉米大豆作物行间专项分割任务，以 YOLO v8 为基础融合 StarNet 网络，并优化检测头构建了 StarNet－YOLO 主干网络。通过自主设计的 ASPPFE 模块、深度可分离卷积和 CSE 结构等策略优化，同时利用 LAMP 剪枝算法对其轻量化。此外，引入 Douglas－Peucker 算法获取逼近作物行间轮廓，并提出评分机制确定轮廓的起始线段和终点线段中点，进而实现作物行导航线的精确拟合。消融试验结果表明，ASPPFE 的 $mAP50_{seg}$（交并比为 0.5 时实例分割的平均精度均值）达到 99.5%，其 $mAP50-95_{seg}$（交并比为 0.5～0.95 时实例分割的平均精度均值）比 SPPELAN、SPPF 和 ASPPF 分别提升 1.0、1.0、0.4 个百分点。经剪枝率 25% 优化后的 StarNet－YOLO 网络，$mAP50-95_{seg}$ 仅降低 0.02 个百分点，而推理速度从 390 f/s 提升至 563 f/s，浮点运算量从 7.2×10^9 降至 4.7×10^9。在同一数据集下对 YOLO v5、YOLO v7、YOLO v8 和改进 YOLO v8 进行对比发现，StarNet－YOLO 网络 $mAP50-95_{seg}$ 比其他 3 种算法分别提升 5.5、4.8、2.8 个百分点。作物行间导航线拟合验证结果表明，平均角度误差和距离误差分别为 2.01°和 23.17 像素。在复杂农田环境下本文导航线提取算法表现出优异性能，实现检测速度与精度平衡，为玉米大豆等农作物田间作业自主机器人视觉导航提供了新的技术思路。

关键词：玉米大豆间套复种；作物行间检测；导航线提取；改进 YOLO v8；多尺度融合
中图分类号：S24　　**文献标识码**：A　　**文章编号**：1000-1298(2025)06-0205-13　　**OSID**：

Extraction Method of Navigation Lines for Maize－Soybean Intercropping Based on Improved YOLO v8

ZHU Huibin　LI Shi　BAI Lizhen　WANG Mingpeng　JIA Yuxuan　LAN Jixian
(*Faculty of Modern Agricultural Engineering*, *Kunming University of Science and Technology*, *Kunming* 650500, *China*)

Abstract: Aiming to addressing challenges of low accuracy and poor adaptability of navigation line extraction algorithms in complex agricultural environments for maize－soybean intercropping scenarios, an improved YOLO v8-based method for extracting crop row navigation lines was proposed to enhance autonomous mobile platform navigation precision during field operations. For the specialized task of segmenting maize and soybean crop rows, a StarNet－YOLO backbone network was constructed by integrating the StarNet network with YOLO v8 and optimizing the detection head. The network was enhanced through strategies, including a custom-designed ASPPFE module, depth-separable convolution, and CSE structure optimization, while also implementing lightweight design by using the LAMP pruning algorithm. Additionally, the Douglas－Peucker algorithm was introduced to approximate crop row contours, and a scoring mechanism was developed to determine the midpoints of contour start and end segments, enabling precise fitting of crop row navigation lines. Ablation experiments showed that ASPPFE achieved an mean average precision for instance segmentation at 0.5 IoU ($mAP50_{seg}$) of 99.5%, with its mAP across IoU thresholds 0.5～0.95 ($mAP50-95_{seg}$) improved by 1.0, 1.0, and 0.4 percentage points compared with that of SPPELAN, SPPF, and ASPPF, respectively. After 25% pruning

收稿日期：2025－03－30　修回日期：2025－04－18
基金项目：国家自然科学基金项目(52265033、51865022)和云南省自然科学基金项目(202401AS070115)
作者简介：朱惠斌(1974—)，男，教授，博士生导师，主要从事山丘区保护性耕作技术与装备研究，E-mail：hbzhu113@163.com
通信作者：白丽珍(1975—)，女，高级实验师，主要从事智慧农业生产技术与装备研究，E-mail：lzhbai@163.com

optimization, the StarNet – YOLO network's mAP50 – 95_{seg} was decreased by only 0.02 percentage points, while inference speed was increased from 390 f/s to 563 f/s, and floating-point operations were reduced from 7.2×10^9 to 4.7×10^9. Comparative testing on the same dataset showed that StarNet – YOLO's mAP50 – 95_{seg} outperformed YOLO v5, YOLO v7, and baseline YOLO v8 by 5.5, 4.8, and 2.8 percentage points, respectively. Validation of crop row navigation line fitting revealed average angular and distance errors of 2.01° and 23.17 pixels. This navigation line extraction algorithm demonstrated excellent performance in complex agricultural environments, balancing detection speed and accuracy, and provided a technical approach for visual navigation of autonomous robots operating in maize, soybean, and other crop fields.

Key words: maize – soybean intercropping; inter-row crop detection; navigation line extraction; improved YOLO v8; multi-scale feature fusion

0 引言

玉米和大豆作为重要的粮食作物,对保障国家粮食安全、促进农村经济发展具有重要意义[1-2]。随着精准农业的发展,自动化农业装备在玉米和大豆生产机械化中占据核心地位。作物行间中心线提取是实现农业机器人自主导航的技术基础[3]。农业机器人导航系统包括全球导航卫星系统(GNSS)、机器视觉系统和激光雷达系统[4],其中 GNSS 易受遮挡且成本高,激光雷达易受农田作物茂密度影响。在西南丘陵山地玉米-大豆间套复种模式下,光照变化、杂草干扰、植株形态差异和地形起伏导致导航系统精度降低[5]。因此,为提高丘陵山区农业机械化水平,亟需开发一种能够适应作物全生育期、抗环境干扰能力强的智能导航算法,实现作物行间导航线的精确提取。

目前,基于机器视觉的农业机器人导航线提取方法主要分为两类:传统色彩空间特征的提取方法和深度卷积神经网络的自动特征学习方法[6]。传统图像处理方法主要通过计算归一化差值植被指数(NDVI)生成作物与背景的二值化特征图,结合 Otsu 阈值分割和粒子群优化算法实现作物与杂草分离[7-8],光照不均、阴影干扰或作物与杂草光谱特性相近时,NDVI 差异模糊,降低二值化效果,阻碍精确分离[9]。导航线定位常用霍夫变换、最小二乘法或水平条带投影法[10],霍夫变换计算量大且多直线场景下准确率降低[11],最小二乘法对误差点敏感[12],水平条带投影法在作物高度不一致时易产生偏差。GONG 等[13]提出基于玉米茎秆特征点的复合定位方法,识别精度达到 93.8%;WANG 等[14]将植被指数和山脊分割融合,用于在生菜农场中稳健、精确地提取导航线。然而,当环境信息复杂、作物与杂草区分不显著时,传统方法的特征提取能力显著降低[15]。深度学习技术在机器视觉领域的突破性进展为解决方案提供了新思路,该方法在农田导航线识别中已成为重要研究内容之一[16]。目前主要采用目标检测和语义分割来预测导航线[17]。目标检测算法主要通过识别作物的显著特征从而生成导航线[18-19]。目标检测方法通过边界框回归获取作物行位置信息,但这种方法仅能提供矩形范围定位,无法精确描述非规则的路径区域轮廓。而语义分割基于像素级分类能够获取完整的作物行区域和精确的边界信息[20]。尽管上述算法在作物行导航线提取中得到广泛应用,但不同作物特征差异显著,同一作物的不同生长阶段也表现出不同表型特征,这给作物行导航线提取造成困难。实例分割技术不仅能获取路径区域的精确轮廓[21-23],还能区分相邻作物行间的多个路径区域实例,为农业机器人导航提供更完整的视觉感知信息[24]。YOLO v8 实例分割模型采用无锚点设计和专为分割任务优化的解耦头架构,能同步并行处理分类、回归及分割任务[25-26]。与传统两阶段模型 Mask R-CNN 相比,YOLO v8 在复杂农业环境中展现出显著的分割速度优势,同时保持较高的准确率和召回率。这些研究成果表明实例分割技术在作物行间导航线预测领域具有显著应用潜力。

针对现有导航线提取方法的局限性,本研究提出一种基于改进 YOLO v8 网络的实例分割方法。通过优化网络结构增强对环境变化的适应性,构建基于 Douglas-Peucker 算法和多特征评分的轮廓中心线后处理结构,有效应对作物行断行等复杂情况,自动、快速、准确地提取玉米和大豆行间导航线,为智慧农业提供关键的视觉感知技术支持。

1 作物行间导航线检测模型构建

1.1 图像采集与数据集构建

以玉米-大豆套种行间作为研究对象,探索复杂农田环境下的自主导航线提取方法。图像数据采集地点为昆明理工大学保护性耕作试验田,种植模式基于《云南省农业农村厅办公室关于印发 2022 年云

南省大豆玉米带状复合种植技术指导意见的通知》，采用“2 +2”带状复合种植模式：玉米双行间距 0.4 m，株距 0.2 m；大豆双行间距 0.17 m，株距 0.3 m；相邻玉米带与大豆带间距离为 0.55 m。种植模式和试验田如图 1 所示。数据采集于 2024 年 5 月中旬—8 月上旬玉米-大豆生长期，在晴天和阴天的天气条件下，利用全天候（08:00—17:00）的自然光照环境下完成。采用 Redmi K60E 型手机进行图像采集，分辨率设定为 3 000 像素 ×4 000 像素，并通过变换俯视角度拍摄，以确保数据集具备充分的多样性和代表性。

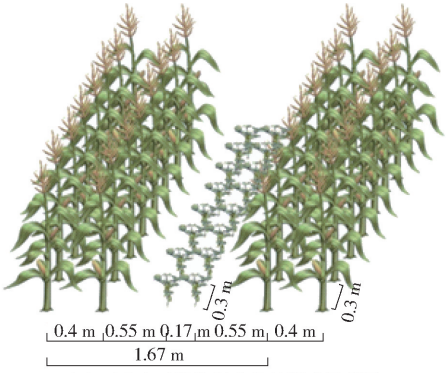

（a）玉米大豆带状复合种植模式示意图



（b）玉米大豆间套复种试验田

图 1　玉米大豆间套复种模式和试验田

Fig. 1　Maize – soybean intercropping and replanting patterns and test plots

采集的玉米-大豆生育期作物行间数据集涵盖 6 种典型场景，如图 2 所示。图 2a 为苗期，作物株高较低，行间轮廓模糊；图 2b 为正常，植株排列整齐，行间结构清晰；图 2c 为遮挡，作物倒伏遮挡，导航线局部不清；图 2d 为杂草，行间杂草干扰，增加识别难度；图 2e 为断行，作物缺株，导航线不连续；图 2f 为光线干扰，光照不足，影响图像质量。累计采集 1 261 幅原始图像。记录了玉米和大豆的生长特征以及多种影响导航线提取的实际干扰因素，为后续算法开发和验证提供可靠数据基础。随后采用 Labelme 标注工具，对玉米-大豆带状复合种植图像进行导航线标注，将玉米大豆植保机器人行驶路径标记为前景（红色），其他区域标记为背景，构建分割数据集。1 261 幅标注图像按 4∶1∶1 随机划分为训练集（757 幅）、验证集（252 幅）和测试集（252 幅），并确保各子集均包含不同场景类型图像。

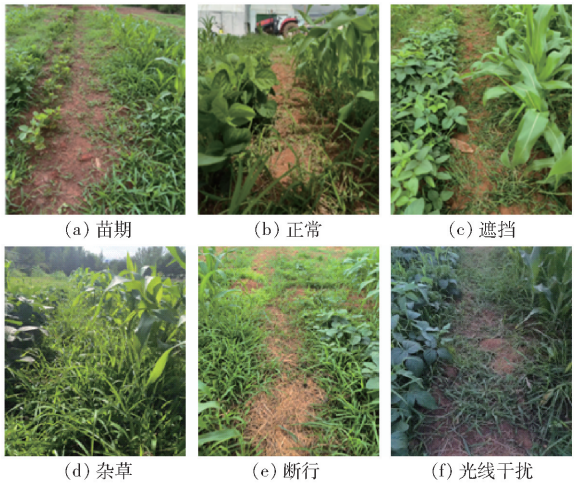

（a）苗期　（b）正常　（c）遮挡

（d）杂草　（e）断行　（f）光线干扰

图 2　玉米-大豆作物行图像数据集示例

Fig. 2　Examples of maize – soybean crop row image dataset

1.2　StarNet – YOLO 网络

农田导航线提取可借助深度学习中的实例分割算法，实现像素级的路径检测与分割。实例分割的端到端处理流程包含特征提取与 mask 生成 2 个阶段：通过编码器提取多尺度特征，解码器上采样生成实例 mask 并回归目标类别与边界框[27]。StarNet 采用 4 级分层架构，通过卷积层实现下采样并利用改进的 demo block 模块提取特征。为提高推理效率，将 Layer Normalization 替换为 Batch Normalization 并置于深度卷积后，实现推理时的运算融合。在各模块末端增加深度卷积层，并在每个阶段将网络宽度增大 1 倍，将 GeLU 激活函数替换为 ReLU6。为平衡精度与效率需求，结合 YOLO v8[28] 的检测性能和 StarNet 的轻量化特点，提出改进型实例分割网络 StarNet – YOLO，结构如图 3 所示，集成深度可分离卷积、降低参数量、批量归一化、提升训练稳定性、全连接层特征交互和 ReLU6 激活函数，通过星形运算实现低维高效的特征融合。首先，融合 StarNet 主干网络和 YOLO v8 网络，采用轻量级检测头 LADH – Head[29] 构建 StarNet – YOLO 网络，以 StarNet – YOLO 网络为基准网络设计空间特征增强结构 ASPPFE，利用空洞卷积、引入最大池化和 CBS（卷积层、批标准化（BN）和 SiLU 激活函数）结合的 Max Pooling – CBS 下采样策略，增强多尺度特征提取，优化特征提取效率，以对玉米大豆作物行检测模型进一步优化。考虑到田间机器人导航线提取的实时性要求，通过引入轻量级检测头 LADH – Head、元素级乘法替代特征拼接架构 C2F_S 模块，增强非线性特征交互，并采用 7 ×7 深度可分离卷积替换 3 ×3 标准卷积，降低计算复杂度。此外，基于 C2F_S 模块，

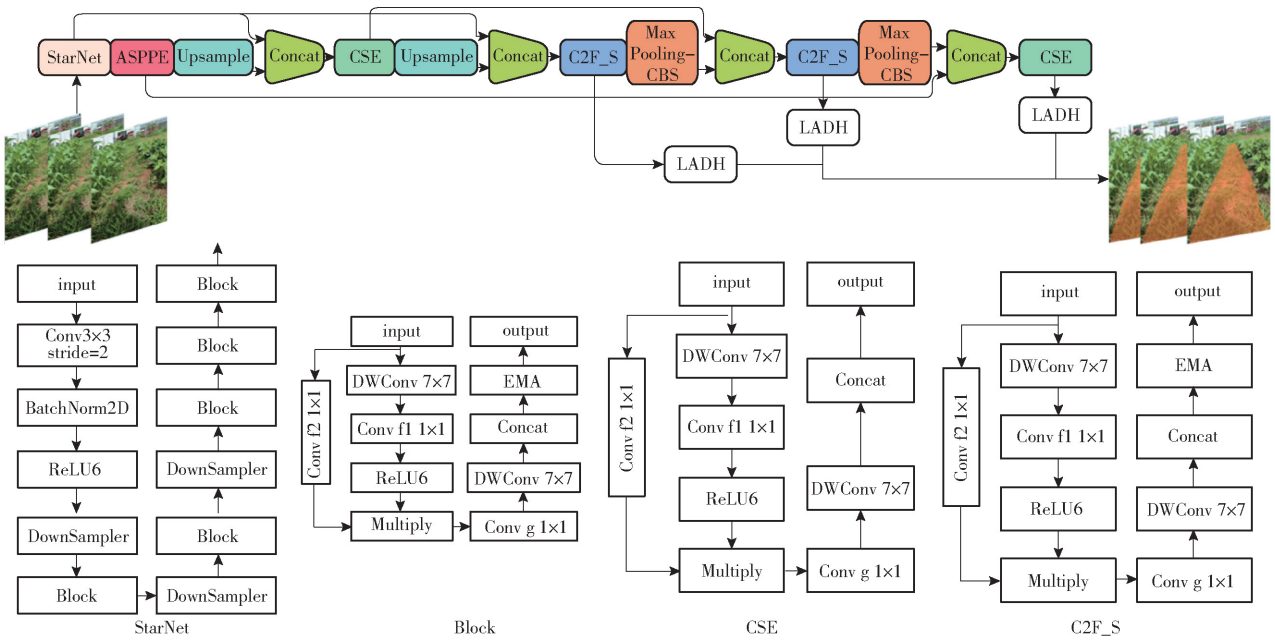

图 3 StarNet－YOLO 网络结构图

Fig. 3 StarNet－YOLO network structure diagram

引入 EMA(Efficient multi-scale attention)注意力机制[30]增强边界特征,设计 CSE 架构,实现通道和空间维度的双重增强,在保持轻量化的同时提升特征学习能力,以提高特征提取效率和降低计算开销为目标,在模型性能和计算复杂度间取得更好的平衡。

1.3 ASPPFE 结构

SPP(Spatial pyramid pooling)是卷积神经网络中的一个重要组成部分,将任意尺寸的特征图转换成固定大小的特征向量,其池化层包含 3 种不同尺度池化核,从而作为全连接层的输入,解决了图像缩放带来的精度损失和计算冗余问题。为进一步提高处理速度和检测效率, SPPF(Spatial pyramid pooling fast)在 SPP 基础上采用多个小型池化层,减小计算量的同时保留多尺度特征融合能力。SPPELAN(Spatial pyramid progressive efficient layer aggregation network)在 SPPF 的基础上设计辅助可逆分支,允许主分支从辅助分支获取可靠梯度信息,扩大池化核增强感受野,如图 4 所示。而 ASPP(Atrous spatial syramid pooling)与前三者不同,ASPP 结构引入不同膨胀率的空洞卷积,通过结合不同采样率的空洞卷积来捕获多尺度上下文语义信息,有效扩大感受野范围[31],适合应用于分割任务中。然而,农田导航场景具有作物密集、导航路径跨度大的特点,在保持局部细节的同时获得足够大的感受野是导航线预测难点。

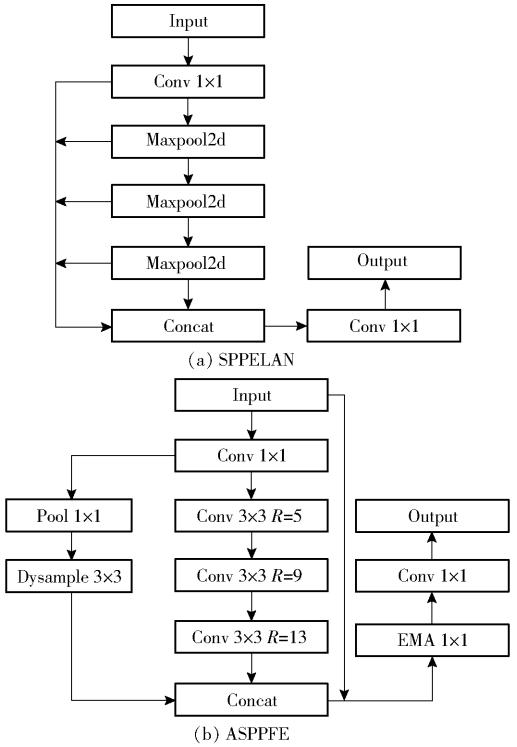

图 4 SPPELAN 和 ASPPFE 结构图

Fig. 4 SPPELAN and ASPPFE structural diagrams

1.4 下采样和轻量级检测头

针对 StarNet－YOLO 检测头存在的计算冗余和特征不一致问题,融合 Max Pooling－CBS 的下采样策略和轻量级检测头(LADH－Head),并通过深度可分离卷积和多尺度特征对齐机制,有效优化网络性能。在特征提取阶段,引入 Max Pooling－CBS 的高效下采样结构,提升网络对不同尺度目标的特征提取能力。改进后检测头结构如图 5 所示,采用 LADH－Head 的空间-通道解耦策略:利用 3×3 深度卷积提取空间特征,配合 1×1 逐点卷积进行通道特征重组。检测头采用双分支结构:回归分支使用

3 层 DSConv(深度可分离卷积)来增强特征表达;分类分支采用双层 1×1 卷积的轻量化设计,通道维度压缩至原始结构的 1/4,有效降低计算量。同时引入 GeLU 激活函数提供非线性变换能力,配合特征归一化结构提升特征融合质量。该改进方案在保持高效特征提取能力的同时,通过 LADH 的轻量化设计实现了检测精度和推理速度的良好平衡。

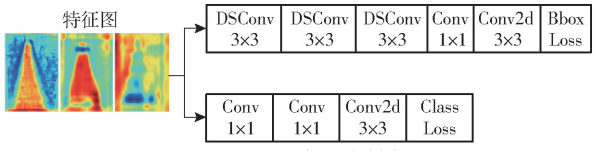

图 5　LADH 检测头结构图

Fig. 5　LADH detection head structure

1.5　模型剪枝

深度学习模型规模不断扩大,导致计算成本和内存需求显著提升。这一问题在资源受限的应用场景中尤为突出。研究表明,在相同内存占用下,经过结构化剪枝的稀疏模型不仅能保持推理精度,还能比同等规模的密集模型获得更快的推理速度。基于这一发现,采用剪枝策略:通过分析并移除卷积层与全连接层中的冗余参数[32],在保持导航线检测精度的同时,显著降低模型计算复杂度。

传统的模型剪枝通常遵循“训练—稀疏化—精调”的基本流程,为网络不同层确定合适的稀疏度始终是一个重要挑战。LAMP (Layer-adaptive magnitude-based pruning) 通过其评分机制来动态评估网络中各连接的重要性[33]。

当判断出权重 u 的评分大于权重 v 时,v 对应的连接可以被剪枝。如图 6 所示,在网络各层的连接中同时存在 u 和 v 的权重连接,经过 LAMP 剪枝后,仅保留了评分较高的 u 连接。

1.6　作物行间导航线提取算法

导航线通过寻求分割图像的中心线进行预测,如图 7 所示。为实现分割轮廓的中心线计算,引入 Douglas－Peucker 算法。作为一种经典的轮廓简化方法,该算法通过对轮廓点的迭代筛选,从而能够将复杂轮廓精确简化为关键特征点序列。这种处理方式保留了目标轮廓的关键特征,同时也提高了后续中心线提取的精确性。

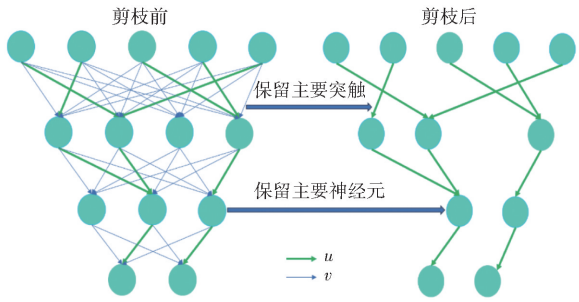

图 6　神经网络权重对比

Fig. 6　Comparison of neural network weights

Douglas－Peucker 算法通过分析轮廓点到直线段的垂直距离来进行简化操作。在图像二值化阶段,通过优化阈值参数来获得更清晰的轮廓边界,减少初始轮廓的噪声和不规则性。对于每条轮廓线段,算法计算线段两端点间所有轮廓点到该线段的垂直距离,将最大垂直距离与预设阈值比较,如果大于阈值,则将该点作为新的分割点。算法递归执行这一过程,直到所有点垂直距离均小于预设阈值为止。

识别作物行间轮廓顶部和底部的线段中点拟合中心线,通过评估顶部和底部边缘线段长度、位置及方向 3 个关键特征,实现对代表性边缘的高精度识别与拟合,如图 8 所示。该方法采用多边形近似法提取轮廓边缘,继而执行系统化流程:应用四分位数法剔除异常值;筛选适合角度范围内的水平边;合并方向与位置相似的边缘以减少冗余;计算多维度综合评分;最终选取评分最优的边作为代表性边缘,并通过连接这些代表边的中点构建物体中心线。在评分体系中,长度得分由边长与局部宽度比值来量化,增强边的结构重要性,优先考虑能代表主体结构而非局部扰动的长边;位置得分基于边中点至轮廓几何中心的水平距离计算,偏好位于轮廓中轴附近的边;方向得分则通过边与水平方向的夹角确定,考虑到代表性顶底边通常呈水平趋势。

引入局部宽度概念作为评估标准,精确表征轮

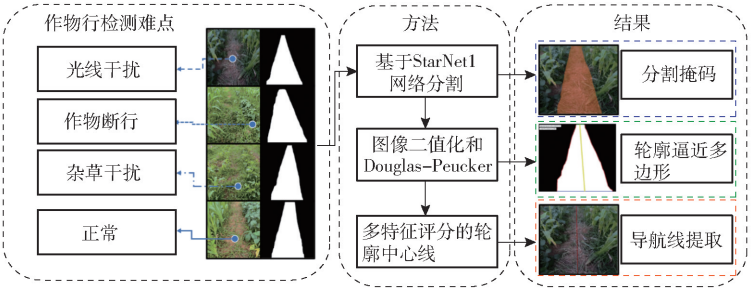

图 7　导航线提取流程图

Fig. 7　Navigation line extraction flowchart

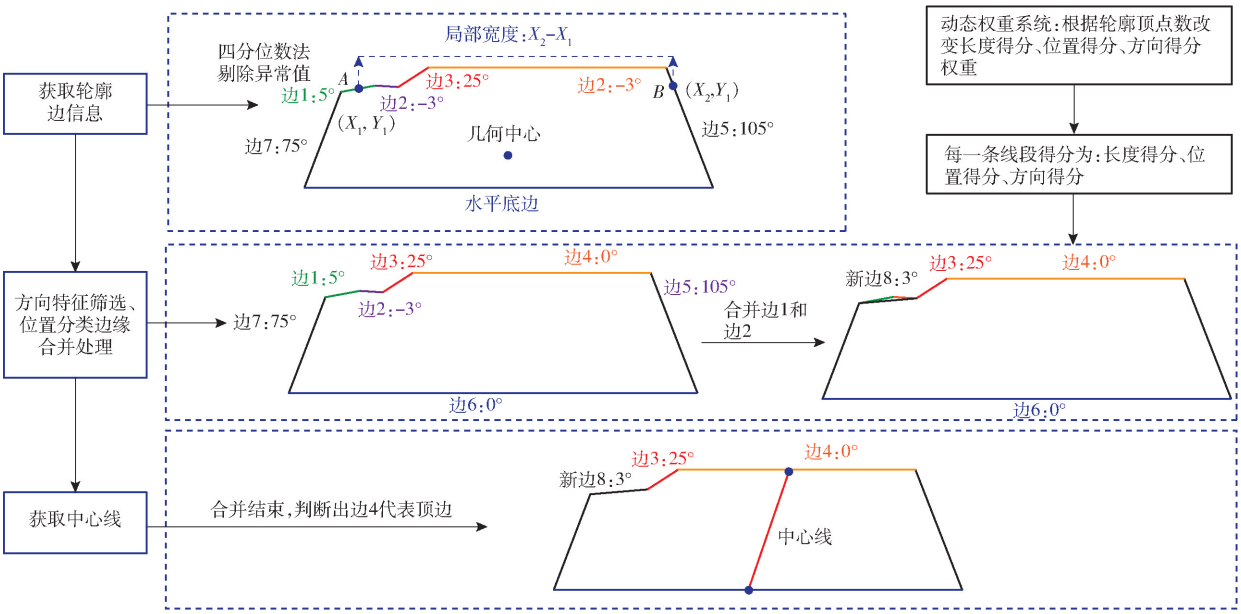

图 8 作物行间中心线检测算法

Fig. 8 Algorithm for crop row centerline detection

廓在特定高度的横向宽度。其计算方法为:确定目标边的中心点(如边 1 的中心点 A)坐标,以目标边的纵坐标作为参考高度平面;识别该平面上的轮廓点(如点 B);计算这些点横坐标的极值差(X_2-X_1)得出局部宽度。采用 IQR 统计方法过滤异常值后计算的局部宽度,有效解决传统全局宽度评估方法对不同位置边缘评价不公平的问题。设计基于轮廓复杂度的动态权重调整机制,根据顶点数自适应优化各评分维度的权重配置:简单轮廓(顶点数小于 10)采用均衡的长度权重(0.3)和位置权重(0.3),同时赋予较高方向权重(0.4);中等复杂轮廓(顶点数为 10~20)提升长度权重(0.4)并降低方向权重(0.3);高复杂度轮廓(顶点数大于等于 20)进一步强化长度权重(0.5)并减弱方向权重(0.2)。此动态权重调整机制充分考虑轮廓复杂度与边缘代表性的内在关联,对复杂轮廓中关键长边给予更高权重。

2 模型评价

2.1 试验配置

本试验在搭载 AMD Ryzen 7 5800X 处理器(8 核心,3.80 GHz)、NVIDIA GeForce RTX 3070 Ti 显卡(8 GB GDDR6X)和 64 GB DDR4 内存的 Windows 10 64 位系统上进行。软件环境采用 Python 3.8 和 PyTorch 2.0 深度学习框架,CUDA 版本为 11.8。训练过程中,采用 AdamW 优化器,输入图像统一缩放至 640 像素×640 像素,批量大小(batch size)设为 20,数据加载线程数(workers)为 12。初始学习率为 0.01,采用线性衰减策略,最终降至 0.001,训练总轮数设置为 100,当验证集性能连续 40 个轮数没有提升时,触发早停机制。为更准确地评估模型在实际场景中的性能,训练过程中关闭了 Mosaic 数据增强功能。

2.2 性能评估

在实例分割任务中,采用平均精度均值(Mean average precision, mAP)[34-35]作为主要评价指标。评估指标包括边界框检测的 $mAP50_{bb}$(交并比阈值为 0.5 时的平均精度均值)和 $mAP50-95_{bb}$(交并比阈值为 0.5~0.95 时的平均精度均值),以及实例分割的 $mAP50_{seg}$和 $mAP50-95_{seg}$。模型性能评估包括分割精度 $mAP50_{seg}$、分割精度均值 $mAP50-95_{seg}$和推理速度。其中,推理速度以每秒处理帧数(Frames per second, FPS)表示,测量范围为模型接收输入图像到输出预测结果的时间间隔,不包含图像预处理时间。

2.3 ASPPFE 改进结果

为分析本文提出的 ASPPFE 对 StarNet-YOLO 网络检测精度的影响,系统比较了 SPPELAN、SPPF、ASPPF 和 ASPPFE 在 StarNet-YOLO 网络中性能表现,如表 1 所示。试验结果表明,SPPELAN 和 SPPF 结构在目标检测和实例分割任务中性能稳定,其 $mAP50_{bb}$均达到 99.5%,$mAP50_{seg}$亦均达到 99.4%,为后续比较提供了基准。相较于 SPPELAN 和 SPPF 结构,ASPPF 在 $mAP50-95_{seg}$上均提升 0.6 个百分点,但 $mAP50_{seg}$均下降 0.8 个百分点。在目标检测任务中,ASPPFE 的 $mAP50-95_{bb}$达到 82.4%,较 SPPELAN 和 SPPF 均提升 2.2 个百分点,比 ASPPF(81.6%)提升 0.8 个百分点。在实例分割任务中,其 $mAP50-95_{seg}$达到 80%,较基准 SPPF 提升 1 个

百分点，同时也克服 ASPPF 在 $mAP50_{seg}$ 上的性能下降问题。ASPPFE 性能提升的原因为在 ASPPF 基础上引入 EMA 注意力机制设计的 ASPPFE 结构，融合 2D 全局平均池化与高斯映射函数，构建了更稳健的长程依赖建模机制，采用 1×1 卷积分支和 3×3 卷积分支双路并行结构，在保证计算效率的同时，增强特征提取的表达能力。其中，1×1 卷积分支通过双通路设计和全局平均池化算子，有效建模了跨通道依赖关系；3×3 卷积分支则通过扩展感受野获取多尺度空间表征。试验结果验证了 ASPPFE 结构在保持计算效率的同时，能够有效提升特征提取的鲁棒性和判别性。

表 1　各特征金字塔结构精度试验结果

Tab. 1　Tests of pyramid structure of each feature

%

结构名称	$mAP50_{bb}$	$mAP50-95_{bb}$	$mAP50_{seg}$	$mAP50-95_{seg}$
SPPELAN	99.5	80.2	99.4	79.0
SPPF	99.5	80.2	99.4	79.0
ASPPF	99.4	81.6	98.6	79.6
ASPPFE	99.5	82.4	99.5	80.0

对 SPPF 和 ASPPFE 的特征感受野进行可视化处理，如图 9 所示。由图 9 可知，ASPPFE 特征图中绿色像素占比明显大于 SPPF，表明其感受野更大，能够捕获更多的视觉信息。这进一步证实了本文提出的 ASPPFE 在增强模型感受野方面的有效性，从而提高了模型对复杂场景的理解能力。

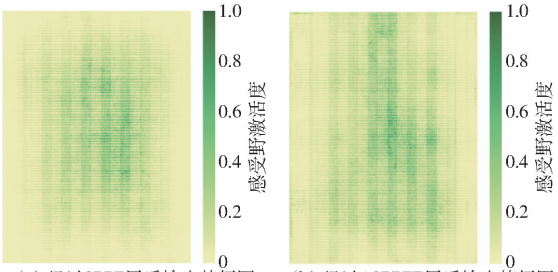

(a) 经过SPPF层后输出特征图　(b) 经过ASPPFE层后输出特征图

图 9　SPPF 和 ASPPFE 感受野对比

Fig. 9　Comparison of SPPF and ASPPFE feeling field

2.4　消融试验

为系统验证各改进结构有效性，进行消融试验。以 StarNet－YOLO 为基准模型（采用轻量化主干网络 StarNet 和检测头 LADH）将改进结构按序叠加，通过逐步引入不同优化组件，量化分析每个结构对模型性能的贡献，如表 2 所示。基于 StarNet－YOLO 的消融试验显示，改进后模型在 $mAP50_{seg}$ 指标上无显著差异，但有效提升了模型在 $mAP50-95_{seg}$ 上的性能。从图 10 可见，引入 ASPPFE 结构后，3 路径特征提取和渐进式空洞率设计加速模型收敛速度，配合 EMA 注意力机制的特征增强，使 $mAP50-95_{seg}$ 指标提升 2.1 个百分点。在此基础上增加的 CSE 结构和串联式 EMA 注意力机制，实现通道维度与空间维度的特征增强，虽略微降低了收敛速度，但精度提升 0.5 个百分点。CSE 由于引入 StarNet 网络中的 block 结构，使得 CSE 结构具有将输入映射到极高维的非线性特征空间的能力，在不同通道上进行成对特征乘法的核函数，通过多层堆叠时，每一层均会带来隐式维度复杂性的指数增长。最后引入的 Max Pooling－CBS 结构采用分层级渐进式下采样策略，在保持较快收敛速度的同时，为模型带来额外 0.2 个百分点的性能提升。通过结构间的协同作用实现了性能的累积提升，充分验证了各改进结构的有效性。

表 2　消融试验结果

Tab. 2　Results of ablation experiment

StarNet－YOLO	ASPPFE	CSE	Max Pooling－CBS	$mAP50_{seg}$/%	$mAP50-95_{seg}$/%
√				99.5	79.0
√	√			99.5	81.1
√	√	√		99.5	81.6
√	√	√	√	99.5	81.8

注：√为采用该模块。

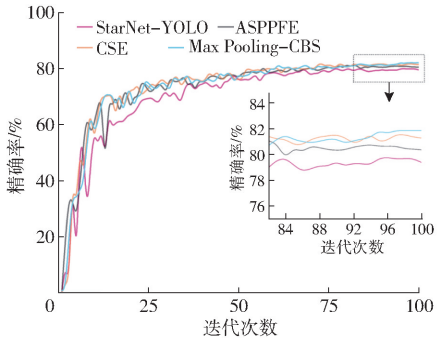

图 10　消融试验精确率变化曲线

Fig. 10　Changes in accuracy of ablation study experiment

2.5　剪枝模型优化

LAMP 剪枝对 StarNet－YOLO 进行轻量化处理。通过试验发现，当剪枝率超过 50% 时，StarNet－YOLO 性能出现显著下降。为系统评估剪枝对模型性能的影响，采用渐进式剪枝策略，以 5% 为步长逐步增加剪枝率，结果如表 3 所示。

根据表 3 可知，随着剪枝率增加，浮点运算量大幅降低，推理速度显著提升，同时 $mAP50-95_{seg}$ 出现了 2 个显著的性能波峰：剪枝率为 5% 时 $mAP50-95_{seg}$ 达到 81.9%，表明适度剪枝有助于抑制过拟合，促进模型获得更优的特征表达；在剪枝率为 25%，$mAP50-95_{seg}$ 仍维持在 81.6%，仅比 5% 剪枝时略低。说明网络在移除大量冗余参数后，通过重新训

表 3 LAMP 剪枝结果

Tab. 3 LAMP pruning results

剪枝率/%	$mAP50_{seg}$/%	$mAP50-95_{seg}$/%	推理速度/(f·s^{-1})	浮点运算量
0	99.5	81.8	390	7.2×10^9
5	99.5	81.9	403	6.5×10^9
10	99.5	81.1	438	5.9×10^9
15	99.5	80.8	467	5.5×10^9
20	99.5	80.8	494	5.1×10^9
25	99.5	81.6	563	4.7×10^9
30	99.5	81.3	600	4.5×10^9
35	99.5	81.3	639	4.2×10^9
40	99.5	81.1	678	4.0×10^9
45	99.5	81.2	775	4.0×10^9
50	99.5	79.4	785	3.6×10^9

练建立了新的特征平衡,保持了较强的表达能力。然而,当剪枝率达到 50% 时,$mAP50-95_{seg}$ 指标下降 2.4 个百分点,表明过度剪枝开始影响模型的基础特征提取能力。

基于模型性能和计算效率的综合考虑,选择剪枝率为 25% 对 StarNet-YOLO 进行优化。剪枝后网络整体通道数降至原来的 25%,其中主干网络承担主要的压缩任务。ASPPFE 结构及其包含的 EMA 注意力层的通道数保持不变。ASPPFE 作为网络的核心特征提取结构,不能进行修剪,EMA 注意力机制对特征识别和判别至关重要。检测头的输出卷积层作为直接影响预测结果的关键层,在剪枝过程中也被完整保留。这种差异化的剪枝策略既保证了模型的特征提取能力,又实现显著的模型压缩。

图 11(图中气泡大小表示模型浮点运算量)为本文提出的 StarNet-YOLO 系列模型的演进过程及其性能表现,这一优化过程体现了网络结构的持续改进。在降低计算成本的同时达到与原模型相当的检测精度;引入 ASPPFE、CSE 和 Max Pooling-CBS 等结构显著提升了特征提取能力;最终通过 25% 的差异化剪枝策略,在保持高精度的同时实现了推理速度提升。

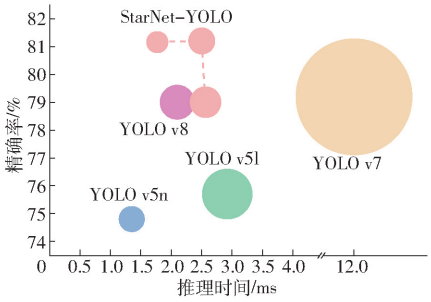

图 11 剪枝后精度对比

Fig. 11 Comparison of accuracy after pruning

2.6 与其他算法对比

为系统评估本文提出模型的性能,选择轻量级网络 YOLO v5n、中等规模网络 YOLO v5s 以及大规模网络 YOLO v5l,最新架构 YOLO v7 和 YOLO v8 作为对比模型。表 4 为试验对比结果,识别效果如图 12 所示。在引入轻量化检测头和 StarNet 的主干网络后,StarNet-YOLO 的 $mAP50_{bb}$ 和 $mAP50_{seg}$ 均达到 99.5%,浮点运算量为 1.01×10^{10}。通过网络结构优化,StarNet-YOLO 的 $mAP50-95_{bb}$ 达到 82.4%,$mAP50-95_{seg}$ 达到 81.8%,将计算开销压缩至 7.2×10^9,$mAP50-95_{seg}$ 相比上述模型分别提升 6.1、7.0、5.5、4.8、2.8 个百分点。经过模型剪枝后的 StarNet-YOLO 在 $mAP50-95_{bb}$ 和 $mAP50-95_{seg}$ 上仅小幅下降,而浮点运算量进一步降至 4.7×10^9,将推理速度提升至 563 f/s。充分证明了本文提出的网络优化策略和剪枝方法的优势。

表 4 模型性能对比

Tab. 4 Model performance comparison

模型	$mAP50_{bb}$/%	$mAP50-95_{bb}$/%	$mAP50_{seg}$/%	$mAP50-95_{seg}$/%	推理速度/(f·s^{-1})	浮点运算量
YOLO v5s	99.4	74.4	99.1	75.7	341	2.570×10^{10}
YOLO v5n	99.3	73.4	99.2	74.8	739	6.700×10^9
YOLO v5l	99.4	76.4	99.2	76.3	90	1.464×10^{11}
YOLO v7	99.5	79.4	99.4	77.0	85	1.419×10^{11}
YOLO v8	99.5	80.2	99.4	79.0	474	1.200×10^{10}
StarNet-YOLO	99.5	82.4	99.5	81.8	563	4.700×10^9

通过多组场景试验对比,各 YOLO 系列模型在农作物行检测中呈现显著差异:YOLO v5 系列在作物行边缘区域存在定位不准确和分割不够平滑的问题,而在第 3 组遮挡场景中,YOLO v7 表现出明显的识别效果下降。YOLO v8 虽然整体检测效果有所提升,但在第 1 组断开场景中出现了将背景误识别为作物行间的问题。StarNet-YOLO 不仅准确定位作物行间的转角和分叉结构,还在检测连续性方面表现优异,有效避免了检测断裂现象。

3 导航线提取与实时性分析

路径分割后进行导航线提取。实例分割后,场

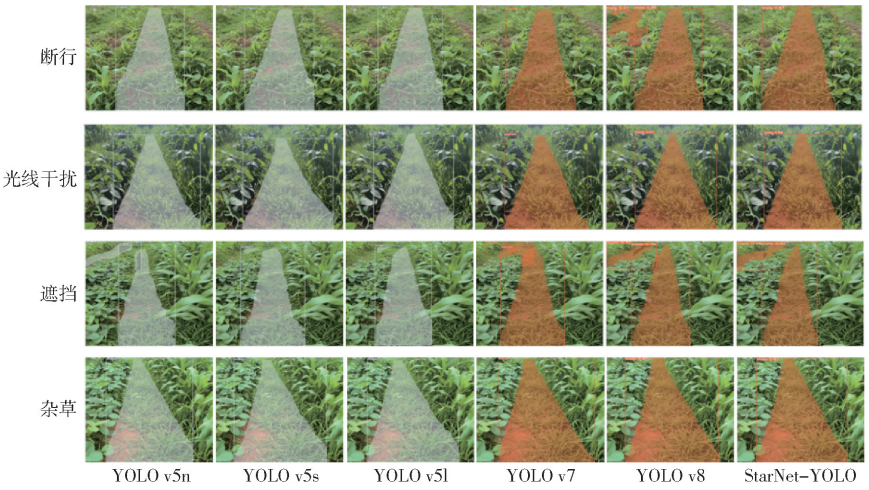

图 12　6 种神经网络在 4 种不同场景路径识别效果

Fig. 12　Path recognition by six neural networks in four different scenarios

景分为前景和背景，将彩色图像转换为灰度图，利用 OpenCV 中 threshold 函数实现全局阈值二值化，通过阈值函数将灰度值 30 以上的区域设置为 255，从而在二值化图中路径显示白色，其余显示黑色。基于 Douglas－Peucker 算法的轮廓简化及中心线提取如图 13 所示。为了获得最佳的轮廓逼近效果，采用一组递减的 epsilon 值（原始轮廓与 Douglas－Peucker 算法逼近轮廓间最大距离）：0.005 0、0.003 0 和 0.001 0，进行轮廓简化试验，图中红色封闭折线表示逼近轮廓，绿色和蓝色线段为该算法找到的顶部和底部线段，而黄色直线表示拟合中心线。较大的 epsilon 值会产生更简化的轮廓表示，而较小值则保留更多的轮廓细节。通过逐步减小 epsilon 值，分析轮廓逼近的精细程度与顶点数量之间关系。

图 13b 为使用最大 epsilon 值（0.005 0）的轮廓逼近结果，此时轮廓仅由 8 个顶点表示。该参数设置下获得了最为简化的轮廓表示，保持了分割区域的主要形状特征。然而，在图像中部和底部等局部区域的拟合精度相对较低，部分细节特征被忽略。图 13c 采用中间值（0.003 0），轮廓顶点数增加到 13 个。相比图 13b，在图像中部和底部等局部区域展现出更好的拟合效果，在保持轮廓精度和计算复杂度间取得较好的平衡。图 13d 使用最小的 epsilon 值（0.001 0），轮廓顶点数达到 29 个。此时轮廓拟合度最高，保留大量细节特征。试验结果表明，epsilon 值选择对轮廓简化的效果具有决定性影响。较大 epsilon 值能显著减少轮廓顶点数量，提高计算效率，但会丢失重要形状特征；较小 epsilon 值则能更好地保持轮廓细节，使导航线提取更加精确。基于试验结果，选择 epsilon 值为 0.001 0 时的简化效果来提取导航线。在所有参数设置下，Douglas－Peucker 算法均保持了作物行间的整体形状特征，同时黄色中心线的稳定提取效果验证了该方法的有效性。这表明 Douglas－Peucker 算法在轮廓简化和特征保持方面具有良好的适应性和稳定性。

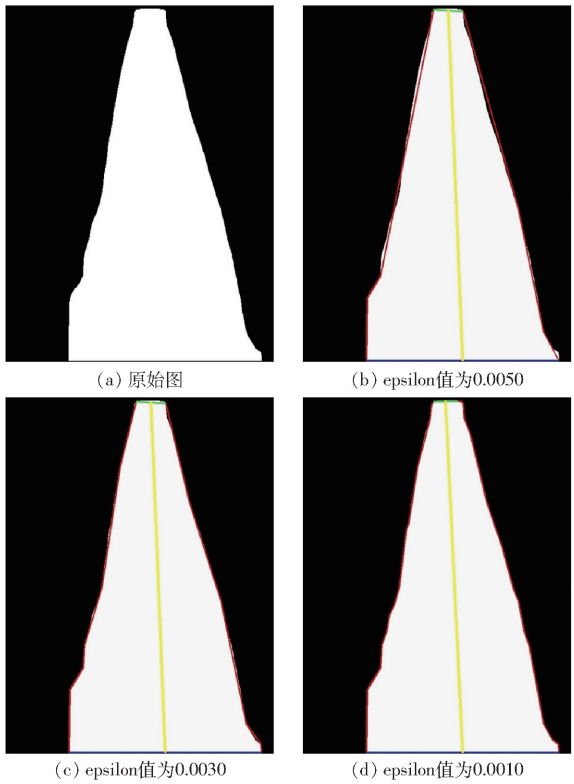

图 13　不同 epsilon 值下的导航线提取效果

Fig. 13　Navigation line extraction effects at different epsilon values

为评估 StarNet－YOLO 网络预测导航线的准确性，进行田间试验。对 6 种田间情况共 120 幅图像进行验证。评价指标为角度误差和距离误差。其中，角度误差是衡量导航线和预测导航线夹角（锐角）的重要指标，而距离误差则是衡量预测导航线的定位精度和导航性能，反映自主移动平台实际行驶路径与规划路径的吻合程度和算法提取导航线的

准确程度。将预测导航轨迹与基准轨迹投影至同一图像平面,以图像左下顶点建立坐标系,绘制基准导航轨迹 L1 和预测导航轨迹 L2,如图 14 所示。在 y 轴选取两个间距较大的采样点,记为坐标$(0,y_1)$与$(0,y_2)$。通过这两个点分别作 y 轴垂线,与 L1、L2 相交。测量这些交点在 x 轴上的坐标差值,分别记为 Δx_1和 Δx_2。为消除轨迹交叉引起的误差抵消效应,取两处坐标差值的绝对值,反映整个导航线的平均像素误差。

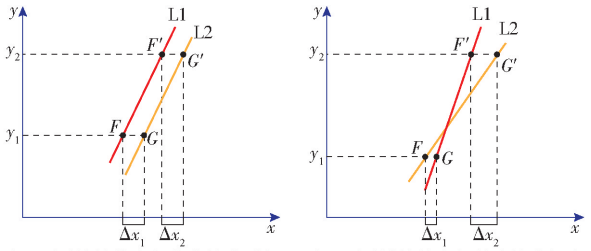

(a) 预测导航轨迹与基准轨迹平行 (b) 预测导航轨迹与基准轨迹相交

图 14 距离误差计算

Fig. 14 Distance error calculation

表 5 为不同分组条件下导航线预测的测试结果。从精确率、角度误差和距离误差 3 方面进行分析。除了有遮挡组的 89.75% 外,其他各组精确率都达到 91% 以上。苗期组与正常组相比,精确率低 1.85 个百分点,表明苗期时,作物行与作物行间特征明显,而存在有遮挡情况时,作物特征会参与到作物行间识别中,造成干扰。本文算法通过深度学习能够掌握作物行的整体形态特征和空间分布规律,即使在出现断行的情况下,算法仍能基于已学习的特征准确推断完整的行线走向。各组平均角度误差均控制在 2.60°以内,其中正常组和断行组表现最好,分别为 1.82°和 1.85°。由于导航线拟合算法是通过寻找分割区域起点和终点的平行线段中点拟合,依赖线段的质量评分,识别效果越好,分割区域轮廓越平滑。有遮挡组的位置偏差最大,平均值达到 29.25 像素,而正常组仅为 20.89 像素。YANG 等[36]在其研究环境下评估的玉米作物行拟合方法中,Hough 变换和最小二乘法的角度误差拟合精度分别为 5.76°和 3.56°,YU 等[37]在特定条件下的导航线距离误差为 14.5 像素。虽然不同研究的试验环境、数据集特性和评价体系各异,不宜直接比较,但可作为参考,本文在当前条件下角度误差和距离误差分别为 2.01°和 23.17 像素。图 15 为本文算法对不同田间情况的导航线提取效果,综合分析表明,本文方法满足作物行检测要求,在多种复杂田间情况下均表现出良好的适应性和准确性。

表 5 预测导航线结果

Tab. 5 Navigation line prediction results

分组	精确率/%	角度误差/(°)	Δx_1/像素	Δx_2/像素	平均值/像素
苗期	92.30	1.90	25.17	1.73	23.44
光线干扰	91.45	2.01	24.28	1.00	23.28
有遮挡	89.75	2.59	35.25	6.00	29.25
正常	94.15	1.82	22.09	1.20	20.89
断行	93.35	1.85	23.18	1.00	22.18
杂草	92.27	1.90	24.46	4.49	19.97

为全面评估模型的实时响应与延时特性,对 6 种典型田间环境下的作物行间识别结果和处理时间

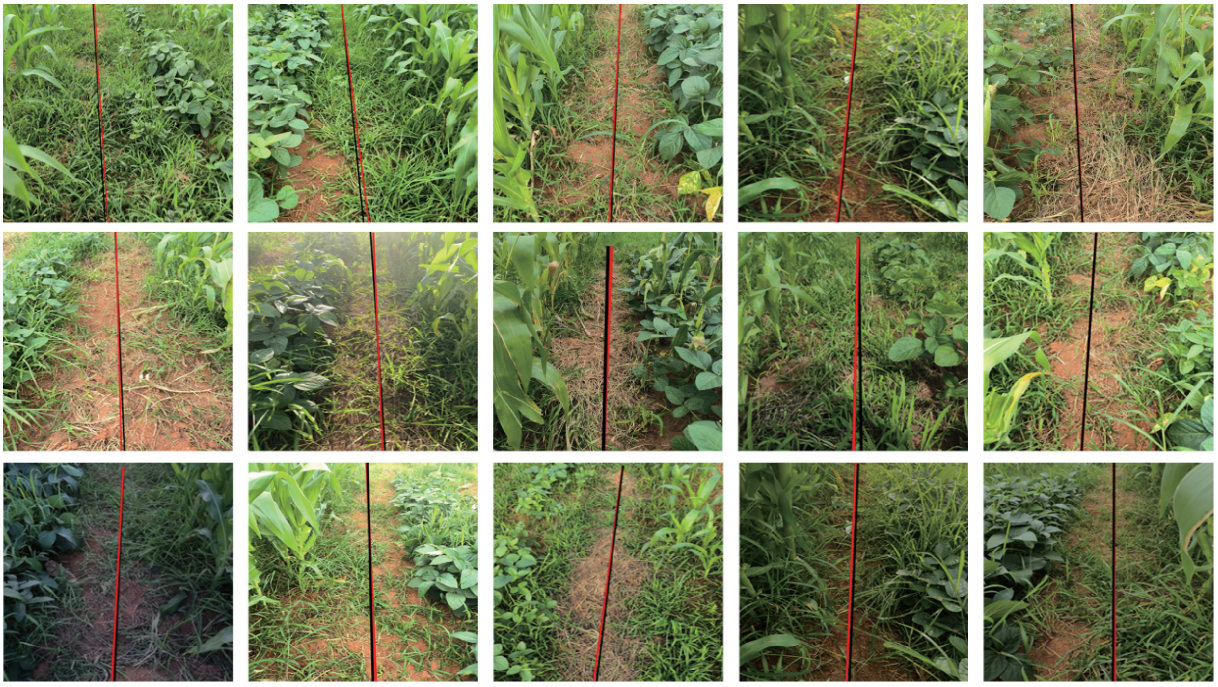

图 15 不同田间情况下导航线提取结果

Fig. 15 Navigation line extraction results for different field situations

进行详细分析。识别结果中图 16a、16e 出现了误识别现象，原因是两侧作物生长状态均匀且部分植被延伸至行间区域，导致行间边界模糊不清；而其他 4 个场景的识别结果均符合表 5 所示的预测导航线效果。

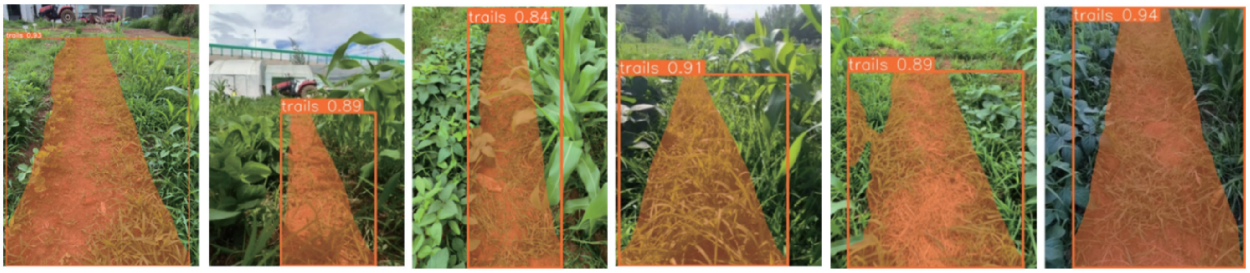

(a) 苗期　(b) 正常　(c) 遮挡　(d) 杂草　(e) 断行　(f) 光线干扰

图 16　6 种典型田间环境下的作物行间识别结果

Fig. 16　Results of crop row identification in six typical field environments

表 6 记录各场景下模型的实时性能表现，采用时间戳记录法，在模型预测过程中为每个处理阶段打上精确的开始和结束时间戳，通过这种微观时间分析方法发现，第 1 幅图像（苗期）处理时间约占总运行时间的 87%，是由于模型载入和 GPU 首次使用导致，因此进行 GPU 预热，并在模型导入和 GPU 预热环节加入时间戳。苗期场景耗时 179.75 ms，正常场景耗时 66.02 ms，遮挡场景耗时 35.01 ms，杂草场景耗时 36.17 ms，断行场景耗时 39.01 ms，光线干扰场景耗时 110.02 ms。基于时间戳的分析表明，苗期和光线干扰情况下的处理时间明显延长，苗期图像中心线拟合阶段耗时 117.74 ms，光线干扰场景下预测图像与中心线拟合分别需 57.01、49.01 ms，因为这两种情况下图像中识别结构轮廓更为复杂，且轮廓顶部产生线段较多，导致判断代表性边需要更多时间，需调用更多的计算资源进行处理。相比之下，正常、遮挡、杂草和断行场景图像处理速度较快，其中图像二值化阶段稳定。

表 6　6 种典型田间环境下模型实时处理性能

Tab. 6　Real-time processing performance of models in six typical field environments

类型	阶段	开始时间戳	结束时间戳	用时/ms
苗期	模型加载	20:22:25.525	20:22:25.631	106.57
	GPU 预热	20:22:25.632	20:22:27.198	1 565.74
	载入图像	20:22:27.200	20:22:27.212	12.00
	预测图像	20:22:27.212	20:22:27.247	35.01
	二值化	20:22:27.247	20:22:27.262	15.00
	中心线拟合	20:22:27.265	20:22:27.383	117.74
正常	载入图像	20:22:27.385	20:22:27.386	1.00
	预测图像	20:22:27.386	20:22:27.412	26.01
	二值化	20:22:27.412	20:22:27.413	1.00
	中心线拟合	20:22:27.414	20:22:27.423	38.01
遮挡	载入图像	20:22:27.423	20:22:27.425	2.00
	预测图像	20:22:27.425	20:22:27.450	25.01
	二值化	20:22:27.450	20:22:27.451	1.00
	中心线拟合	20:22:27.453	20:22:27.460	7.00
杂草	载入图像	20:22:27.460	20:22:27.461	1.00
	预测图像	20:22:27.461	20:22:27.480	19.56
	二值化	20:22:27.480	20:22:27.481	1.00
	中心线拟合	20:22:27.483	20:22:27.498	14.61
断行	载入图像	20:22:27.499	20:22:27.500	1.00
	预测图像	20:22:27.500	20:22:27.529	29.01
	二值化	20:22:27.529	20:22:27.530	1.00
	中心线拟合	20:22:27.531	20:22:27.539	8.00
光线干扰	载入图像	20:22:27.539	20:22:27.569	2.00
	预测图像	20:22:27.569	20:22:27.626	57.01
	二值化	20:22:27.626	20:22:27.628	2.00
	中心线拟合	20:22:27.635	20:22:27.684	49.01

4　结论

（1）空间金字塔改进试验表明，使用多分支特征提取通道设计的 ASPPFE 模块显著扩大了有效特征感受野，使模型 mAP50 − 95_{seg} 达到 80%，较原始模型提高 1 个百分点。消融试验证实了每个新增结构的有效性，与 YOLO v8 模型相比，StarNet − YOLO 在提高精度的同时实现了轻量化。

（2）模型剪枝试验结果表明，通过 LAMP 剪枝方法对 StarNet − YOLO 模型进行优化。在剪枝率 25% 下模型性能达到最优平衡。模型 mAP50 − 95_{seg} 仅下降 0.2 个百分点，为 81.6%，而推理速度提升 44%，为 563 f/s，浮点运算量由 7.2×10^9 降至 4.7×10^9。保持模型精度的同时有效降低了计算资源需求。

（3）本文算法提取导航线试验结果表明，角度误差和距离误差分别为 2.01°和 23.17 像素。在复杂农田场景下，该方法均能准确提取导航线，有效解决了传统方法在复杂农田环境下容易受异常值干扰的问题。测试结果表明，该方法能适应不同生长期和光照条件下的导航需求。

参 考 文 献

[1] ERENSTEIN O, JALETA M, SONDER K, et al. Global maize production, consumption and trade: trends and R&D implications[J]. Food Security, 2022, 14(5): 1295 - 1319.

[2] QIN H, LIAO T F. Labor out-migration and agricultural change in rural China: a systematic review and Meta-analysis[J]. Journal of Rural Studies, 2016, 47: 533 - 541.

[3] YANG S, MEI S, ZHANG Y. Detection of maize navigation centerline based on machine vision[J]. IFAC - PapersOnLine, 2018, 51(17): 570 - 575.

[4] BAN C, WANG L, CHI R, et al. A camera-LiDAR - IMU fusion method for real-time extraction of navigation line between maize field rows[J]. Computers and Electronics in Agriculture, 2024, 223: 109114.

[5] 易诗,李俊杰,贾勇. 基于红外热成像的夜间农田实时语义分割[J]. 农业工程学报,2020,36(18):174 - 180.
YI Shi, LI Junjie, JIA Yong. Real-time semantic segmentation of farmland at night using infrared thermal imaging[J]. Transactions of the CSAE, 2020, 36(18): 174 - 180. (in Chinese)

[6] 肖珂,夏伟光,梁聪哲. 复杂背景下果园视觉导航路径提取算法[J]. 农业机械学报,2023,54(6):197 - 204,252.
XIAO Ke, XIA Weiguang, LIANG Congzhe. Visual navigation path extraction algorithm in orchard under complex background[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(6): 197 - 204,252. (in Chinese)

[7] ZHANG X, LI X, ZHANG B, et al. Automated robust crop-row detection in maize fields based on position clustering algorithm and shortest path method[J]. Computers and Electronics in Agriculture, 2018, 154: 165 - 175.

[8] OSTU N. A threshold selection method from gray-level histograms[J]. IEEE Trans. SMC, 1979, 9: 62.

[9] WU Y, PENG X, RUAN K, et al. Improved image segmentation method based on morphological reconstruction[J]. Multimedia Tools and Applications, 2017, 76: 19781 - 19793.

[10] BAI Y, ZHANG B, XU N, et al. Vision-based navigation and guidance for agricultural autonomous vehicles and robots: a review[J]. Computers and Electronics in Agriculture, 2023, 205: 107584.

[11] CHEN J, QIANG H, WU J, et al. Navigation path extraction for greenhouse cucumber-picking robots using the prediction-point Hough transform[J]. Computers and Electronics in Agriculture, 2021, 180: 105911.

[12] SAPKOTA R, AHMED D, KARKEE M. Comparing YOLOv8 and Mask R - CNN for instance segmentation in complex orchard environments[J]. Artificial Intelligence in Agriculture, 2024, 13: 84 - 99.

[13] GONG J, WANG X, ZHANG Y, et al. Navigation line extraction based on root and stalk composite locating points[J]. Computers & Electrical Engineering, 2021, 92: 107115.

[14] WANG S, SU D, JIANG Y, et al. Fusing vegetation index and ridge segmentation for robust vision based autonomous navigation of agricultural robots in vegetable farms[J]. Computers and Electronics in Agriculture, 2023, 213: 108235.

[15] 傅灯斌,江茜,齐龙,等. 基于区域生长顺序聚类- RANSAC 的水稻苗带中心线检测[J]. 农业工程学报,2023,39(7): 47 - 57.
FU Dengbin, JIANG Qian, QI Long, et al. Detection of the centerline of rice seedling belts based on region growth sequential clustering - RANSAC[J]. Transactions of the CSAE, 2023, 39(7): 47 - 57. (in Chinese)

[16] KONG X, GUO Y, LIANG Z, et al. A method for recognizing inter-row navigation lines of rice heading stage based on improved ENet network[J]. Measurement, 2025, 241: 115677.

[17] 朱立成,韩振浩,赵博,等. 基于 VINS - MONO 和改进 YOLO v4 - Tiny 的果园自主寻筐方法[J]. 农业机械学报,2023, 54(8):97 - 109.
ZHU Licheng, HAN Zhenhao, ZHAO Bo, et al. Autonomous basket searching method for orchards transporter based on VINS - MONO and improved YOLO v4 - Tiny[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(8): 97 - 109. (in Chinese)

[18] LIU T H, ZHENG Y, LAI J S, et al. Extracting visual navigation line between pineapple field rows based on an enhanced YOLOv5[J]. Computers and Electronics in Agriculture, 2024, 217: 108574.

[19] DIAO Z, GUO P, ZHANG B, 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.

[20] 韩振浩,李佳,苑严伟,等. 基于 U - Net 网络的果园视觉导航路径识别方法[J]. 农业机械学报,2021,52(1):30 - 39.
HAN Zhenhao, LI Jia, YUAN Yanwei, et al. Path recognition of orchard visual navigation based on U - Net[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(1): 30 - 39. (in Chinese)

[21] 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)

[22] ZHANG L, LI M, ZHU X, et al. Navigation path recognition between rows of fruit trees based on semantic segmentation[J].

Computers and Electronics in Agriculture, 2024, 216: 108511.

[23] 倪纪鹏,朱立成,董力中,等. 基于 SwinS - YOLACT 的番茄采摘机器人实时实例分割算法研究[J]. 农业机械学报,2024,55(10):18 - 30.
NI Jipeng, ZHU Licheng, DONG Lizhong, et al. Real-time instance segmentation algorithm for tomato picking robot based on SwinS - YOLACT[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(10): 18 - 30. (in Chinese)

[24] 王福顺,王旺,孙小华,等. 基于改进 YOLO v8n-seg 的羊只实例分割方法[J]. 农业机械学报,2024,55(8):322 - 332.
WANG Fushun, WANG Wang, SUN Xiaohua, et al. Sheep instance segmentation method based on improved YOLO v8n-seg [J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(8): 322 - 332. (in Chinese)

[25] XU B, FAN J, CHAO J, et al. Instance segmentation method for weed detection using UAV imagery in soybean fields[J]. Computers and Electronics in Agriculture, 2023, 211: 107994.

[26] LI Y, CAO Z, LU H, et al. In-field cotton detection via region-based semantic image segmentation[J]. Computers and Electronics in Agriculture, 2016, 127: 475 - 486.

[27] 马保建,陈棒棒,李学志,等. 基于实例分割的休眠期枣树修剪枝参数提取方法[J]. 中国农机化学报,2024,45(10):54 - 59,68.
MA Baojian, CHEN Bangbang, LI Xuezhi, et al. Extraction method of pruning parameters of dormant jujube tree based on instance segmentation[J]. Journal of Chinese Agricultural Mechanization, 2024, 45(10): 54 - 59,68. (in Chinese)

[28] 梁秀英,贾学镇,何磊,等. 基于 YOLO v8n-seg 和改进 Strongsort 的多目标小鼠跟踪方法[J]. 农业机械学报,2024,55(2):295 - 305,345.
LIANG Xiuying, JIA Xuezhen, HE Lei, et al. Multi-object mice tracking based on YOLO v8n-seg and improved Strongsort [J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(2): 295 - 305,345. (in Chinese)

[29] ZHANG J, CHEN Z, YAN G, et al. Faster and lightweight: an improved YOLOv5 object detector for remote sensing images [J]. Remote Sensing, 2023, 15(20): 4974.

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

[31] LIU M, CHEN W, CHENG J, et al. Y - HRNet: research on multi-category cherry tomato instance segmentation model based on improved YOLOv7 and HRNet fusion[J]. Computers and Electronics in Agriculture, 2024, 227: 109531.

[32] 罗志聪,何陈涛,陈登捷,等. 基于轻量化 YOLO v8s - GD 的自然环境下百香果快速检测模型[J]. 农业机械学报,2024,55(8):291 - 300.
LUO Zhicong, HE Chentao, CHEN Dengjie, et al. Passion fruit rapid detection model based on lightweight YOLO v8s - GD [J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(8): 291 - 300. (in Chinese)

[33] 王相友,李晏兴,杨振宇,等. 基于改进 YOLO v4 模型的马铃薯中土块石块检测方法[J]. 农业机械学报,2021,52(8):241 - 247,262.
WANG Xiangyou, LI Yanxing, YANG Zhenyu, et al. Detection method of clods and stones from impurified potatoes based on improved YOLO v4 algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(8): 241 - 247, 262. (in Chinese)

[34] 任晶秋,万恩晗,单蜜,等. 基于改进 YOLO v8n 网络的番茄成熟度实时检测算法[J]. 农业机械学报,2025,56(3):374 - 382,450.
REN Jingqiu, WAN Enhan, SHAN Mi, et al. Improved YOLO v8n network for real-time detection of tomato maturity[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(3): 374 - 382,450. (in Chinese)

[35] 奚小波,丁杰源,翁小祥,等. 基于轻量化 YOLO v5s - MCA 的番茄成熟度检测方法[J]. 农业机械学报,2025,56(3):383 - 391,436.
XI Xiaobo, DING Jieyuan, WENG Xiaoxiang, et al. Tomato maturity detection method based on lightweight YOLO v5s - MCA [J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(3): 383 - 391,436. (in Chinese)

[36] YANG Y, ZHOU Y, YUE X, 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.

[37] YU J, ZHANG J, SHU A, et al. Study of convolutional neural network-based semantic segmentation methods on edge intelligence devices for field agricultural robot navigation line extraction[J]. Computers and Electronics in Agriculture, 2023, 209: 107811.