

DOI: 10.13718/j.cnki.xdzk.2026.05.019

张海腾, 陈子文, 杨明金, 等. 基于树干特征的林果园道路重构方法研究 [J]. 西南大学学报(自然科学版), 2026, 48(5): 235-245.

基于树干特征的林果园道路重构方法研究

张海腾, 陈子文, 杨明金, 杨玲, 蒲应俊, 杨仕

西南大学 工程技术学院, 重庆 400715

摘要: 在丘陵山地林果园复杂环境中, 针对基于视觉提取路面导航的传统方法常受邻行路面噪声、地面自然起伏、杂草覆盖等多重因素干扰导致行间道路提取精度低、导航误差大的问题, 提出了一种基于树干特征的林果园道路重构方法。首先, 运用 BiSeNetv2 模型对树干进行精细语义分割, 将树干与地面的交点视为道路边界的关键特征点, 从而有效削弱直接提取路面过程中的诸多干扰因素。然后, 采用 K-Means 聚类算法对左、右两侧道路边界特征点进行分组, 并引入改进的 RANSAC 算法对道路边界线进行拟合, 该算法增强了模型拟合直线斜率的偏好控制, 优化了样本点的选择策略。最后, 将两边边界线之间的区域定义为重构后的道路, 并以青花椒园为试验对象, 构建了包含 400 张青花椒园行间道路图像的样本集, 用于语义分割模型训练与路面重构试验。语义分割结果表明: BiSeNetv2 模型相对于经典的 UNet 和 DeepLabv3+ 模型具有更好的综合性能, 其分割准确性为 92.04%, 推理速度为 231 f/s, 能够准确快速地分割树干。路面重构试验结果表明: 提出的 K-Means 与改进 RANSAC 组合算法的道路重构准确性相较于传统基于路面识别方法、基于 K-Means 与最小二乘法组合算法以及基于 K-Means 与 RANSAC 组合算法分别提高了 59.03、19.98、11.31 个百分点, 道路中心线的平均航向偏差和横向偏差分别为 4.28° 和 24.61 像素, 该算法能够满足林果园中农机导航作业的需求。

关键词: 林果园; 道路重构; 语义分割; BiSeNetv2 模型;

K-Means 聚类; RANSAC 算法

中图分类号: TP242

文献标识码: A

开放科学(资源服务)标识码(OSID):



文章编号: 1673-9868(2026)05-0235-11

Research on Orchard Road Reconstruction Methods Based on Tree Trunk Features

ZHANG Haiteng, CHEN Ziwen, YANG Mingjin,
YANG Ling, PU Yingjun, YANG Shi

College of Engineering and Technology, Southwest University, Chongqing 400715, China

收稿日期: 2025-04-10

基金项目: 重庆市技术创新与应用发展专项重点项目(cstc2021jscx-gksbX0013)。

作者简介: 张海腾, 硕士研究生, 主要从事基于深度学习的车辆导航研究。

通信作者: 杨明金, 博士, 教授, 博士研究生导师。

Abstract: To address the problem of row path extraction accuracy and large navigation errors in conventional vision-based methods for road extraction, which are often hindered by multiple factors such as noise from adjacent rows, natural ground undulations, and weed coverage in the complex environments of hilly and mountainous orchards, an innovative strategy for orchard road reconstruction based on tree trunk features was proposed in this paper. Initially, the BiSeNetv2 model was employed to perform fine-grained semantic segmentation of tree trunks, using the intersections of trunks and the ground as key feature points for road boundary identification. This approach effectively mitigated various interfering factors in direct road surface extraction. Subsequently, the K-Means clustering algorithm was utilized to group the road boundary feature points on both sides, and an improved random sample consensus (RANSAC) algorithm was applied to fit the road boundary lines. This algorithm enhanced the preference control for straight line slope fitting and optimized the sample point selection strategy. Ultimately, the region between the two boundary lines was defined as the reconstructed road. Tests were conducted in a green peppercorn orchard, using a dataset of 400 images of inter-row paths constructed for training the semantic segmentation model and testing road reconstruction. The semantic segmentation results indicated that the BiSeNetv2 model exhibited superior overall performance compared to the classic UNet and DeepLabv3+ models, with a segmentation accuracy of 92.04% and an inference speed of 231 f/s, enabling accurate and rapid segmentation of tree trunks. The road reconstruction experiments showed that the combined algorithm of K-Means and the improved RANSAC proposed in this paper enhanced the road reconstruction accuracy by 59.03, 19.98, and 11.31 percentage points compared to traditional road recognition methods, the K-Means combined with least squares algorithm, and the K-Means combined with RANSAC algorithm, respectively. The average heading deviation and lateral deviation of the road centerline were 4.28° and 24.61 pixels, respectively, demonstrating that this algorithm satisfied the requirements for agricultural machinery navigation operations in orchards.

Key words: orchard; road reconstruction; semantic segmentation; BiSeNetv2 model; K-Means clustering; RANSAC algorithm

我国幅员辽阔,林果作物种类繁多,由国家统计局数据可知,目前我国林果种植面积超过 1.280×10^7 hm^2 ,年总产量高达 2.961 1 亿 t^[1]。然而,林果园的综合机械化率仅为 25.88%,且智能化水平相对较低^[2],在施肥、除草、施药、修剪及采收等生产环节中,对人工的依赖程度较高,导致作业效率低下、成本高昂,同时人工还面临受伤风险。以重庆青花椒园为例,人工采摘成本占鲜椒销售价格的 30%~50%^[3],且人工作业易被树皮刺伤。随着人口老龄化进程的加速以及劳动力成本的增加^[4],提升林果园的农业机械化和智能化水平迫在眉睫。

自动驾驶技术是农业机械智能化发展的重要组成部分^[5-6]。目前,田间导航的实现主要依赖于 2 种技术:卫星定位^[7-8]和机器视觉^[9-11]。相较于卫星定位,机器视觉导航因其成本低、复杂环境适应能力强且能够实现实时监控,故更适用于复杂场景的导航^[12-13]。近年来,深度学习在机器视觉领域迅速发展,卷积神经网络在多种农业场景中的应用取得了较好的效果^[14-16]。其中,基于深度学习的道路识别成为农机自动驾驶的关键环节,目前已有多位学者直接通过路面识别来提取行进道路^[17-19]。李云伍等^[20]针对复杂的山地丘陵环境,使用空洞卷积代替普通卷积,结合 FCN 网络的 VGG-16 模块,构建了田间道路场景的语义分割模型,经试验验证,PA 和 MIoU 指标均优于 FCN-8s。赵岩等^[21]针对模型识别精准度不高的问题,使用 U-Net 网络与 ResNet 优势融合的方式,提出了 UNet-ResNet34,成功应用于茶园垄间道路识别。然而,这

些方法在树冠稀疏、邻行地面干扰的情况下效果不佳。为此, 学者们开始探索利用树干辅助提取道路的方法。Zhang 等^[22]提出一种改进 YOLOv5 模型来检测果树树干、行人等物体, 该模型将瓶颈网络替换为轻量级的 GhostNet V2, 并加入协调注意力机制(CA)以降低背景信息的干扰, 试验结果表明, 模型参数减少了 46.9%, mAP 达到了 97.1%。Jiang 等^[23]使用 R-CNN 深度学习模型来检测树干进而实现不同光照条件下的道路提取, 试验结果表明, 模型的 mAP 为 85.29%。彭书博等^[24]以树干根部中点作为定位基点, 利用改进 YOLOv7 模型得到两侧果树行线的定位参照点, 并实现道路提取。

目前, 针对丘陵山地复杂林果园场景的道路提取研究还相对较少, 本文聚焦重庆丘陵山地典型林果作物——青花椒, 开展青花椒园行间道路提取方法研究。首先, 通过构建青花椒园行间数据集, 利用 BiSeNetv2 网络模型对树干进行语义分割, 并采用 K-Means 算法对左、右两侧树干特征点进行聚类; 然后, 引入改进的 RANSAC 方法, 对聚类后树干特征点进行道路边界拟合, 实现目标行间道路的重构; 最后, 通过树干分割和道路重构试验对本文提出算法的精度和有效性进行验证。

1 基于深度学习的树干语义分割

1.1 数据集采集

青花椒行间样本采集于重庆市江津区现代农业园区的宇隆椒丰农业开发有限公司花椒基地, 采集时间为 2023 年 7 月至 2024 年 7 月, 采集设备为佳能 R100 相机, 采集时相机视角高度为 0.5~1 m, 采集的图像为 1 280×720 像素的 RGB 彩色图像。试验共采集了 400 张图片, 其中包括训练集 300 张、验证集 50 张、测试集 50 张。图 1 为采集到的部分典型青花椒园样本图像, 采集场景包含不同光照条件、不同季节和不同地势 3 种情况。不同光照条件包括强光和弱光, 强光照射导致树干上产生明显的阴影, 同时由于镜面反射, 叶片上会出现明亮的光斑, 对场景识别造成干扰。不同季节包括夏季和冬季, 2 个季节中树形和道路情况差异较大, 夏季树冠茂盛, 枝干裸露少, 道路杂草呈绿色; 冬季树冠稀疏, 枝干裸露多, 道路多处被枯草覆盖。不同地势包括下坡和上坡, 在下坡视角中, 图像远景出现成片青花椒作物, 对道路识别造成干扰。



图 1 青花椒园样本图像

1.2 数据集标注

在数据预处理时, 考虑到语义分割算法对计算机内存资源的消耗, 为提升训练速度, 使用双线性插值方法将原始图像减少到 512×512 像素。使用 Labelme 软件手动对树干进行像素级注释, 将青花椒树干标记为绿色(0, 255, 0), 其余为背景并标记为黑色(0, 0, 0)。

1.3 语义分割模型

语义分割旨在为图像中的每个像素赋予一个语义标签, 以实现图像中对象的精细和准确理解^[25]。语义分割的核心是利用低层细节表示高层语义, 往往需要较大的计算量, 通常有 2 种方法来减少计算量: 减小图像大小和降低模型的复杂度。减小图像大小可以最直接地减少计算量, 但图像会丢失大量的细节, 影响计算精度; 降低模型的复杂度会削弱模型的特征提取能力, 从而影响分割精度。现有的双边分割网络(Bilateral Segment Network, BiSeNet)能够很好地解决这个问题, 将空间细节和分类语义分开处理, 平衡

了速度与精度要求。

本文采用 BiSeNetv2 网络模型对树干进行语义分割,其模型框架如图 2 所示,其核心由 3 大模块构成:紫色虚线框为双路径骨干(Backbone),橙色虚线框为聚合层(Aggregation Layer),黄色虚线框为增强部分(Booster)。模型具体结构为:① 双路径骨干。主要由细节分支(Detail Branch)和语义分支(Semantic Branch)组成。细节分支凭借其较宽的通道数和较浅的层次结构,专注于捕获图像的低层细节,生成高分辨率的特征图,从而精确提取微观信息;语义分支则通过减少通道容量并采用高效的下采样策略,构建了一个轻量级的结构,深入探索高层上下文信息,有效提取宏观特征。② 聚合层。提出了一种双向引导聚合层来融合连接细节分支和语义分支的输出特征。③ 增强部分。在训练时,分别在语义分支的 1/4、1/8、1/16、和 1/32 下采样时增加辅助分割头和辅助损失函数。辅助分割头用于提供额外的监督信号,帮助梯度回流并加速训练,将浅层网络直接向后传递,从而引导中间层特征学习更好的语义信息;辅助损失函数监督语义分支的输出。最后,主分割头和主损失函数监控整个 BiSeNetv2 网络模型的输出。

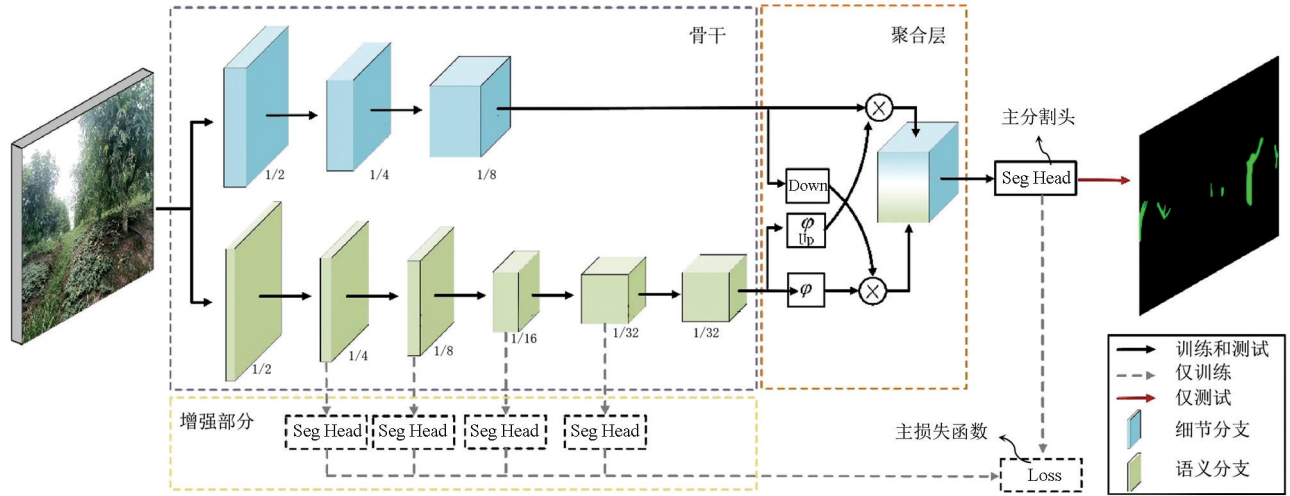


图 2 BiSeNetv2 模型框架

1.4 模型训练

1.4.1 训练环境和超参数设置

本文的训练环境如下:操作系统为 64 位 Windows 10 系统,处理器采用 13 代英特尔酷睿处理器, GPU 为 RTX 4070 Ti。为了充分利用 GPU 的计算能力,使用 NVIDIA 提供的 CUDA 11.1 平台和 cuDNN 8.0.4 GPU 加速库进行训练。训练青花椒树干场景识别模型的超参数设置如下:初始学习率为 0.005,预热迭代次数为 50 次,权重衰减为 0.000 5,迭代次数为 200 次,训练和评估的批处理大小为 4 幅图像。


1.4.2 训练结果

BiSeNetv2 网络模型的主损失函数和辅助损失函数都选用交叉熵损失函数,并采用 OHEM(Online Hard Example Mining)策略提高模型对困难样本的关注度,以改善模型在不平衡数据集上的表现。交叉熵损失函数如式(1)所示:

$$CE(y, \hat{y}) = -\frac{1}{E} \sum_{i=1}^E [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (1)$$

式中: y 为真实标签; \hat{y} 为模型预测的概率; E 为样本总数; i 为样本序号。

模型训练过程中的损失函数曲线如图 3a 所示,4 个辅助损失函数和主损失函数都随着迭代次数的增加呈现协调下降的趋势,表明模型在各损失函数对应位置上的学习相互促进,提升了模型的整体性能。网络的主损失函数曲线在 25 次迭代前后稳定在 0.85 左右,收敛速度较快,同时损失函数整体曲线相对平滑,没有剧烈的波动,表明模型训练良好。训练完成后,模型分割青花椒树干的效果如图 3c 所示。



a. 模型训练过程损失函数



b. 原始图像



c. 树干分割图像

图 3 BiSeNetv2 网络模型训练过程中的损失函数和模型分割结果

2 林果园道路重构

根据相机透视原理,明显的道路在图像中应呈现“近宽远窄”的形态,道路边界在远端交会于一点,该点称为消失点^[26]。丘陵山地青花椒园中的路面存在以下 3 种干扰,增加了道路识别的难度:① 相邻行间路面噪声对目标行道路路的识别产生影响;② 地势起伏造成成像中的道路形态复杂,道路边界不明显;③ 园中路况复杂,包括被杂草、枯草、枝条及石块等物体覆盖,或道路上开设排水沟。考虑到青花椒园行间道路是由两侧成行种植的果树所形成的中间通道,因此识别两侧果树特征可替代道路边界特征,由于青花椒树冠形态随季节因素发生明显的改变,树冠并不适合作为固定生物特征来进行识别。因此,本文提出利用青花椒主干特征来重构道路。

2.1 道路边界特征提取与 K-Means 道路两侧分类

青花椒树干基部与地面相接之处,可以视为界定道路边界的一个显著特征点。语义分割后,针对树干场景识别出的若干个连通区域,将每个区域中的最低点视为树干与地面的交点。遍历所有树干区域并标注最低点作为道路边界特征点。同时,考虑到语义分割模型树干场景的提取误差,设置面积阈值对较小面积的连通区域进行滤波。在图像坐标系下,特征点的选择参照式(2):

$$(u_j, v_{\max}) = \operatorname{argmax}_{(u_i, v_i) \in S_t} v_i \quad (2)$$

式中: S_t 为第 t 个连通域像素点集,它包含了图像中连续分布的一组像素点; (u_i, v_i) 为点集 S_t 中像素点的坐标; v_{\max} 为点集 S_t 中 v_i 的最大值,即 v_{\max} 是点集 S_t 中最低行像素点的 v 坐标值; u_j 为 v_{\max} 对应的 u 坐标值。

考虑到最低行像素点可能存在多个,引入式(3):

$$(u_{FP}, v_{FP}) = \left(\frac{\sum_{j=1}^N u_j}{N}, v_{\max} \right) \quad (3)$$

式中: (u_{FP}, v_{FP}) 为道路边界特征点坐标; u_{FP} 为所有最低行像素点的 u 坐标值的中值; N 为最低行像素点的总数。

获得的道路特征点为道路左、右两侧的全部特征点,不能直接用于道路界线的拟合,需要对道路左、右两侧特征点予以区分。由于左、右特征点存在明显的横向间距,因此可以采用以欧几里得距离作为评价指标的 K-Means 聚类算法来实现道路两侧的分类。K-Means 算法是一种无监督学习算法,广泛应用于各种分类任务,其算法目标是 minimized 簇内数据点与中心点之间的总距。设数据集为 $X = \{x_1, x_2, \dots, x_n\}$, $C = \{c_1, c_2, \dots, c_K\}$ 为簇中心,则目标函数 J 如式(4)所示:

$$J = \min \sum_{i=1}^K \sum_{x_j \in S_i} \|x_j - c_i\|^2 \quad (4)$$

式中: K 为聚类簇的数量; S_i 为第 i 个簇中的数据点集; $\|x_j - c_i\|^2$ 为数据点 x_j 到簇中心 c_i 的欧氏距离。

使用欧几里得距离作为指标来度量数据对象之间的相似性,相似性越大,距离就越小,具体的算法流程为:

步骤 1 随机选择 K 个数据点作为初始簇中心 C , 本文 K 取 2。

步骤 2 把每个数据点 x_j 分配到最近的簇中心,得到 S_i , 如式(5)所示:

$$S_i = \{x_j : \|x_j - c_i\|^2 \leq \|x_j - c_K\|^2, \forall K, 1 \leq K \leq 2\} \quad (5)$$

步骤 3 重新计算每个簇的簇中心 c_i , 如式(6)所示:

$$c_i = \frac{1}{|S_i|} \sum_{x_j \in S_i} x_j \quad (6)$$

步骤 4 重复步骤 2 与步骤 3, 直到簇中心 c_i 不再变化。

为提高算法运行速度,本文将最大迭代次数设置为 30 次。道路左、右边界特征点的提取流程如图 4 所示。




图 4 道路左、右边界特征点的提取流程

2.2 改进 RANSAC 算法的道路边界线拟合与道路重构

青椒园行间道路形态基本为直线,或在近视场内可近似看作直线,故道路边界重构简化为道路边界的直线拟合。语义分割模型的识别结果不仅包含目标行内的树干,还可能包括相邻行的树干,这些额外树干会对道路边界线拟合的准确性造成影响。本文提出采用对异常值不敏感的 RANSAC 算法来拟合边界线,同时基于道路边界的斜率特征改进投票机制以选择更优模型,从而提高边界线拟合的精确度和可靠性。

2.2.1 RANSAC 算法

RANSAC 算法是一种迭代方法,用于从 1 组包含噪声的观测数据中估计数学模型参数。在直线拟合中,RANSAC 算法被用来从包含噪声的数据点中找到最佳的直线。这种方法尤其适用于数据集中存在错误测量或异常值的情况。RANSAC 直线拟合算法流程为:

步骤 1 初始化: 给定数据集 Y , 其中包含 N 个数据点。选择最小的样本数(通常为 2, 2 点确定 1 条直

线), 并随机从数据集 Y 中抽取这样的样本集合, 记为 Y_1 。

步骤 2 模型生成: 使用 Y_1 中的样本点计算得到 1 个直线拟合模型 M 。

步骤 3 数据分类: 计算除 Y_1 外数据集 Y 中所有点到直线模型 M 的距离。设置阈值 T , 当距离小于 T 时, 则将该点判定为内点, 否则判定为外点。将所有内点组成的新数据集记为 Y^* , 它是 Y_1 在当前模型下的一致性集合。

步骤 4 模型评估与更新: 比较当前模型 M 的内点数量与之前迭代中记录的最佳模型的内点数量, 如果当前模型的内点数量更多, 则更新最佳模型的参数以及最佳模型的内点数量。

步骤 5 迭代: 重复步骤 1 至步骤 4, 进行多次迭代。在每次迭代中, 重新随机选择最小样本集 Y_1 , 并尝试拟合新的直线模型 M , 然后评估其一致性集合 Y^* 的大小。

步骤 6 结果输出: 迭代结束后, 输出最佳直线模型的参数以及对应的一致性集合 Y^* , 该模型就是在给定数据集 Y 下, 通过 RANSAC 算法找到的最佳直线拟合。

2.2.2 改进 RANSAC 算法

当图片中的树干总数较少时, 噪声树干会对边界拟合产生严重影响, 并使算法结果出现多个内点数一致的模型。针对以上问题, 考虑到道路边界在透视变换下, 其投影到笛卡尔坐标系时具有特定的斜率特征, 本文提出了一种对 RANSAC 算法中模型评估环节的改进方法。具体而言, 不再仅仅依赖于内点数量的简单对比来评估模型优劣, 而是引入一种综合评分机制, 该机制结合了内点数量与模型拟合出的边界斜率, 共同对候选模型进行打分。通过这种方式, 算法能够更准确地筛选出既符合数据点分布又贴近实际道路边界斜率特性的最佳模型, 从而提高边界拟合的准确性和鲁棒性, 具体的评分方法如式(7)、式(8)所示:

$$S_L = \begin{cases} n(1+p) & p \geq 0 \\ 0 & p < 0 \end{cases} \quad (7)$$

$$S_R = \begin{cases} n(1+|p|) & p \leq 0 \\ 0 & p > 0 \end{cases} \quad (8)$$

其中: S_L 、 S_R 分别为左、右侧模型的得分; n 为内点个数; p 为模型 M 的斜率。

改进的 RANSAC 算法解释如下: 对于左侧边界线拟合, 算法会优先考虑斜率大于 0 的模型, 并在这些模型中进一步选择斜率较大的值。因为在实际道路场景中, 噪声树干通常出现在左侧目标行的左上方, 左侧边界线通常呈现为正斜率且斜率大于加入噪声点模型的斜率。相反, 在拟合右侧边界线时, 算法则偏好选择斜率小于 0 且绝对值较大的模型, 以符合右侧边界线负斜率的特征。


本文内、外点的判断阈值 T 取 50 像素, 为了保障运行速度, 最大迭代次数设为 30 次, 每次拟合的最小样本数量为 2。道路边界线拟合结果如图 5a 中的蓝色线条所示, 边界线之间的区域视为重构的道路。为分析道路重构的效果, 引入道路中心线的航向偏差 θ 和横向偏差 e 作为道路重构精度的衡量指标。道路中心线为边界线的角平分线, θ 为真实道路中心线与重构道路中心线的夹角, e 为距图像底端 L 像素水平位置的真实道路中心线与重构道路中心线的横向偏差距离, 其中真实道路中心线为人工手动标注道路边界线的角平分线, 如图 5b 中的红色线段所示。

3 结果与分析


3.1 树干语义分割试验

3.1.1 语义分割模型评价指标

在语义分割任务中, 一般需要对模型进行准确性和实时性的评估。语义分割的精度直接影响道路重构的质量, 本文采用平均交并比(MIoU)和平均像素准确率(MPA)评估模型精度。平均交并比计算每个类别的交并比(IoU), 然后对所有类别取平均, 能够提供全面的性能评估, 如式(9)所示。平均像素准确率则是对每个类别的像素准确率进行平均, 旨在衡量模型对每个类别的预测性能, 能够反映模型在各个类别上的表现, 如式(10)所示。



a. 道路重构和道路中心线提取



b. 道路中心线参数示意

图 5 道路重构及道路中心线参数提取

$$M_{\text{IoU}} = \frac{1}{k+1} \sum_{i=0}^k \frac{P_{ii}}{\sum_{j=0}^k P_{ij} + \sum_{j=0}^k P_{ij} - P_{ii}} \quad (9)$$

$$A_{\text{MP}} = \frac{1}{k+1} \sum_{i=0}^k \frac{P_{ii}}{\sum_{j=0}^k P_{ij}} \times 100\% \quad (10)$$

其中： M_{IoU} 为平均交并比； A_{MP} 为平均像素准确率； k 为除背景之外的语义分割类别的数量； P_{ii} 为属于第 i 类并被预测为第 i 类的像素点总数； P_{ij} 为属于第 i 类但被预测为第 j 类的像素点总数。

本文用参数量以及模型推理速度来评估模型的实时性。模型参数量是模型在运行时使用的计算机内存资源的实际数量，参数量的大小反映了模型的复杂度和学习能力。推理速度通常定义为模型在一次推理过程中所需的时间，可以表征模型的实时水平。

3.1.2 语义分割结果

为了系统评估 BiSeNetv2 网络模型在语义分割任务中的性能表现，本文在统一的数据集划分(即相同的训练集与测试集)以及一致的训练环境设置下，对 3 种经典的语义分割模型(UNet、DeepLabv3+和本文所采用的 BiSeNetv2 模型)进行性能对比分析，3 种模型的评估结果如表 1 所示。由表 1 可知，所有模型均展现出较高的分割准确性，平均维持在 92%左右，表明模型训练效果良好，但它们在运行效率方面呈现出显著差异。具体而言，相较于 UNet 模型，BiSeNetv2 在平均交并比与整体准确性上略有下降，分别低了 1.01 和 0.13 个百分点，平均像素准确率提升了 2.79 个百分点，显示出在细粒度分割任务上的优势。同时其推理速度约为 UNet 的 8 倍，模型参数量约为 UNet 的 1/5，显著降低了计算资源需求，提高了实际应用中的部署效率。与 DeepLabv3+模型相比，BiSeNetv2 在平均交并比、平均像素准确率以及整体准确性上均有所提升，分别高出 1.22、3.45、0.14 个百分点。尽管两者在参数量上相近，但 BiSeNetv2 的推理速度约为 DeepLabv3+的 1.6 倍。综合来说，BiSeNetv2 网络模型兼顾准确性和实时性，其综合性能在三者中最为优异。图 6 为 3 种网络模型的语义分割结果对比图。

表 1 UNet、DeepLabv3+和 BiSeNetv2 网络模型评估结果

网络模型	平均交并比/ %	平均像素准确率/ %	准确性/ %	推理速度/ ($f \cdot s^{-1}$)	参数量
UNet	75.33	83.28	92.17	29	24.89×10^6
DeepLabv3+	73.10	82.62	91.90	143	5.81×10^6
BiSeNetv2	74.32	86.07	92.04	231	5.20×10^6

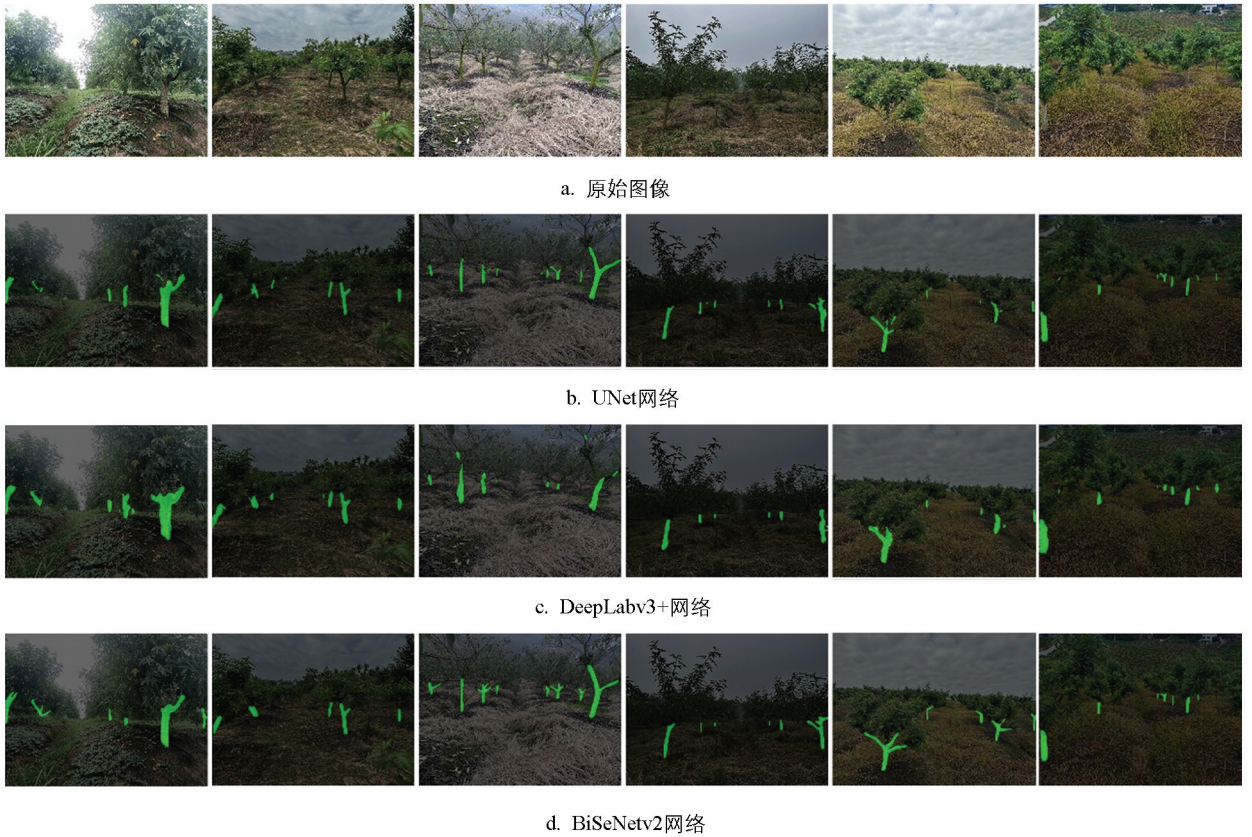


图 6 UNet、DeepLabv3+和 BiSeNetv2 网络模型语义分割结果对比

3.2 道路重构算法试验与分析

采用道路中心线的航向偏差 θ 和横向偏差 e 作为道路重构精度的衡量指标, 同时计算道路重构准确率。参照相关研究内容, 本文将道路准确重构定义为: 道路中心线的航向偏差 $\theta \leq 10^\circ$, 横向偏差 $e \leq 50$ 像素。为了评价本文道路重构算法对青花椒园道路提取的效果, 从训练集、验证集和测试集中随机抽取 160 张图片, 用本文提出的算法(K-Means+改进 RANSAC)与基于路面特征的道路识别算法^[17-19]、基于树干特征的 K-Means+最小二乘法道路重构算法、基于树干特征的 K-Means+RANSAC 道路重构算法进行比较分析。对 4 种道路提取方法进行量化统计, 结果如表 2 所示。

表 2 道路提取评估结果

方法	平均航向 偏差/ $^\circ$	平均横向 偏差/像素	航向偏差 标准差/ $^\circ$	横向偏差 标准差/像素	准确率/ %
基于路面	17.25	46.73	23.12	60.01	27.64
K-Means+最小二乘法	7.26	87.28	12.71	173.48	66.69
K-Means+RANSAC	5.87	36.28	10.51	47.35	75.36
K-Means+改进 RANSAC(本文方法)	4.28	24.61	6.63	36.98	86.67

由表 2 可知, 基于路面的提取效果最不理想, 道路中心线的平均航向偏差为 17.25° , 提取准确率为 27.64%, 其主要原因是青花椒种植环境复杂, 造成提取的路面形状不规则, 直接以提取的路面作为行间道路并不准确。基于 K-Means+最小二乘法的道路中心线横向偏差的平均值和标准差分别为 87.28 像素和 173.48 像素, 由于最小二乘法对邻行树干噪声的敏感性较高, 该方法在重构道路时表现不佳。基于 K-Means+RANSAC 算法重构的道路中心线平均航向偏差为 5.87° , 平均横向偏差为 36.28 像素, 准确率为 75.36%, 重构效果较好。本文方法(K-Means+改进 RANSAC 算法)的道路中心线平均航向偏差为 4.28° , 平均横向偏差为 24.61 像素, 相较于 K-Means+RANSAC 算法的平均航向偏差和横向偏差分

别减少了 1.59° 和 11.67 像素, 算法准确率可达 86.67%, 较前 3 种方法分别提高了 59.03、19.98、11.31 个百分点, 满足青花椒园内道路重构的准确性要求。

图 7 为 4 种方法的道路提取结果对比, 其中, 本文基于 K-Means+改进 RANSAC 算法的提取效果最优。该方法综合考虑了模型拟合的斜率和内点数量, 能有效解决树干较少时 RANSAC 算法模型不稳定的问题, 对算法进行斜率的偏好设置控制了算法对样本点的选择, 使模型能将目标道路边界点准确且稳定地识别为内点, 同时将邻行树干识别为外点, 降低了由邻行树干导致的拟合误差, 提高了道路重构的准确性。

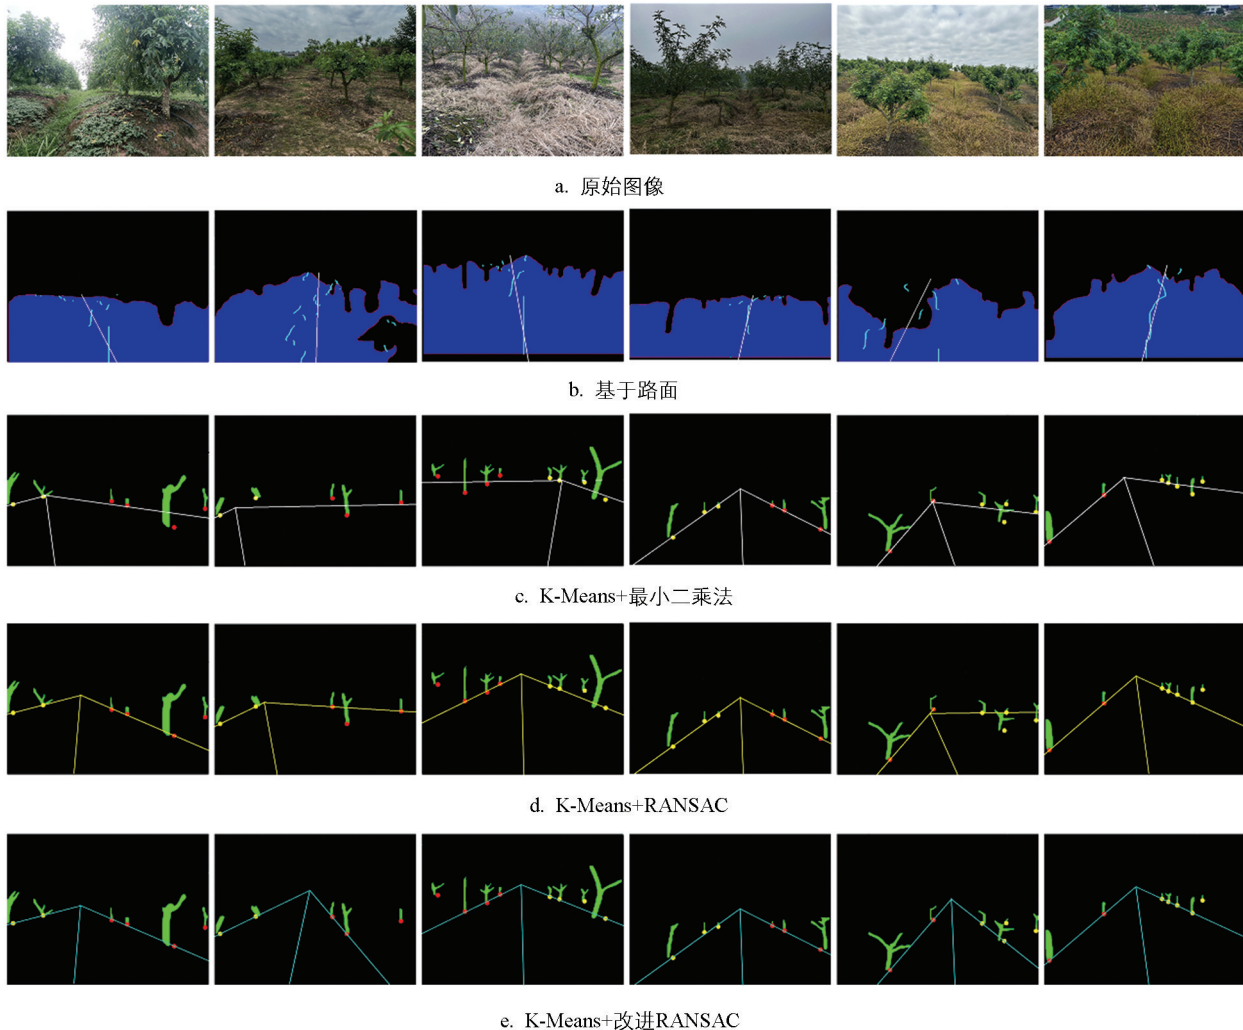


图 7 道路提取结果对比

4 结论

本文提出了一种基于树干特征的道路重构方法, 采用 BiSeNetv2 网络模型对树干进行语义分割, 将树干与地面的交点作为道路边界特征点, 并通过 K-Means 聚类与改进的 RANSAC 算法相结合的方法实现道路边界拟合和道路重构, 显著降低了邻行树干的干扰, 提高了算法的稳健性。试验以青花椒园为对象, 构建了 400 张青花椒园行间道路图像样本集, 在 UNet、DeepLabv3+ 和 BiSeNetv2 网络的语义分割结果对比评估中, BiSeNetv2 网络模型的分割准确性为 92.04%, 推理速度为 231 f/s, 准确性和实时性较高, 综合性能最好。本文的组合算法相较人工观测, 其道路中心线平均航向偏差为 4.28°, 平均横向偏差为 24.61 像素, 较 RANSAC 算法改进前提高了 11.31 个百分点, 比传统基于路面的重构方法提高了 59.03 个百分点, 能够满足青花椒园道路重构的需求, 为林果园中农机视觉导航提供了技术参考。

参考文献:

- [1] 国家统计局. 中国统计年鉴 2021 [EB/OL]. (2021-10-09) [2024-09-30]. <https://www.stats.gov.cn/sj/ndsj/2021/index.htm>.
- [2] 孟志军, 王昊, 付卫强, 等. 农业装备自动驾驶技术研究现状与展望 [J]. 农业机械学报, 2023, 54(10): 1-24.
- [3] 安建军, 杨会光, 鲁维民, 等. 花椒采摘机械的现状与发展趋势 [J]. 农业科技与信息, 2019(6): 57-59.
- [4] 刘成良, 林洪振, 李彦明, 等. 农业装备智能控制技术研究现状与发展趋势分析 [J]. 农业机械学报, 2020, 51(1): 1-18.
- [5] 郭成洋, 范雨杭, 张硕, 等. 果园车辆自动导航技术研究进展 [J]. 东北农业大学学报, 2019, 50(8): 87-96.
- [6] 万欢, 欧媛珍, 管宪鲁, 等. 无人农机作业环境感知技术综述 [J]. 农业工程学报, 2024, 40(8): 1-18.
- [7] 刘兆朋, 张智刚, 罗锡文, 等. 雷沃 ZP9500 高地隙喷雾机的 GNSS 自动导航作业系统设计 [J]. 农业工程学报, 2018, 34(1): 15-21.
- [8] 钟银, 薛梦琦, 袁洪良. 智能农机 GNSS/INS 组合导航系统设计 [J]. 农业工程学报, 2021, 37(9): 40-46.
- [9] 兰玉彬, 闫瑜, 王宝聚, 等. 智能施药机器人关键技术研究现状及发展趋势 [J]. 农业工程学报, 2022, 38(20): 30-40.
- [10] 关卓怀, 陈科尹, 丁幼春, 等. 水稻收获作业视觉导航路径提取方法 [J]. 农业机械学报, 2020, 51(1): 19-28.
- [11] 李霞, 苏筠皓, 岳振超, 等. 基于中值点 Hough 变换玉米行检测的导航线提取方法 [J]. 农业工程学报, 2022, 38(5): 167-174.
- [12] 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.
- [13] 张轩铭. 基于机器视觉的非结构化道路可通过区域检测方法研究 [D]. 重庆: 重庆交通大学, 2024.
- [14] 赵鹏飞. 基于深度学习目标检测算法甜椒分级装置的设计与研究 [D]. 杭州: 浙江农林大学, 2024.
- [15] 慕君林, 马博, 王云飞, 等. 基于深度学习的农作物病虫害检测算法综述 [J]. 农业机械学报, 2023, 54(S2): 301-313.
- [16] 张伟荣, 陈学庚, 齐江涛, 等. 基于深度学习和高斯过程回归的玉米冠下视觉导航路径提取方法 [J]. 农业机械学报, 2024, 55(7): 15-26.
- [17] 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.
- [18] 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.
- [19] 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.
- [20] 李云伍, 徐俊杰, 刘得雄, 等. 基于改进空洞卷积神经网络的丘陵山区田间道路场景识别 [J]. 农业工程学报, 2019, 35(7): 150-159.
- [21] 赵岩, 张人天, 董春旺, 等. 采用改进 Unet 网络的茶园导航路径识别方法 [J]. 农业工程学报, 2022, 38(19): 162-171.
- [22] ZHANG J C, TIAN M M, YANG Z R, et al. An Improved Target Detection Method Based on YOLOv5 in Natural Orchard Environments [J]. Computers and Electronics in Agriculture, 2024, 219: 108780.
- [23] JIANG A L, NOGUCHI R, AHAMED T. Tree Trunk Recognition in Orchard Autonomous Operations under Different Light Conditions Using a Thermal Camera and Faster R-CNN [J]. Sensors, 2022, 22(5): 2065.
- [24] 彭书博, 陈兵旗, 李景彬, 等. 基于改进 YOLOv7 的果园行间导航线检测 [J]. 农业工程学报, 2023, 39(16): 131-138.
- [25] 张鑫, 姚庆安, 赵健, 等. 全卷积神经网络图像语义分割方法综述 [J]. 计算机工程与应用, 2022, 58(8): 45-57.
- [26] 毕松, 王宇豪. 果园机器人视觉导航行间位姿估计与果树目标定位方法 [J]. 农业机械学报, 2021, 52(8): 16-26, 39.