

基于3D点云分析的果园行间穿梭机器人路径规划方法

毕松余鑫

(北方工业大学电气与控制工程学院, 北京 100041)

摘要: 针对现有果园导航方法易受冠层密度、光照条件、种植不规整、地面不平整等条件影响,导致用于实现自主导航的树行方向估计方法与行尾识别方法稳定性低的问题,本文提出基于3D点云分析的果园行间穿梭路径规划方法,该路径规划方法包含树行识别定位方法、场景识别方法、路径规划方法,用于密植果园机器人行间自主穿梭的导航系统。首先,设计了基于点云语义分割网络的果树树干点云提取方法,实现了树行的识别与定位;其次,设计了基于卷积神经网络的位置场景识别方法,实现了行头等位置的场景识别;最后,设计了基于有限状态机的行间行进策略管理方法与基于RS曲线的行间路径规划方法,实现了果园多行连续行走。基于本文方法的树干点云分割平均交并比为88.3%,果树平均定位误差为2.04% (x 方向)、1.54% (y 方向),树行方向估计平均误差为1.11°,行尾识别正确率为96%,行内中线行走平均偏差为0.08 m。实验结果表明,本文所提出路径规划方法能够满足果园环境下树行定位与位置场景识别准确性要求,有效规划行间穿梭路径,为果园激光自主导航提供有效参考。

关键词: 果园; 机器人; 路径规划; 树干分割; 场景识别; 树行定位

中图分类号: TP242

文献标识码: A

文章编号: 1000-1298(2024)10-0037-14

OSID:



Path Planning Method for Inter-row Shuttle in Densely Planted Orchards

BI Song YU Xin

(College of Electrical and Control Engineering, North China University of Technology, Beijing 100041, China)

Abstract: Addressing the issues with existing orchard navigation methods, which are susceptible to canopy density, lighting conditions, irregular planting, and uneven ground, leading to low stability in tree row direction estimation and row end identification methods used for autonomous navigation, a 3D point cloud-based method for pathway planning was introduced. The method comprised three primary components, a tree row identification technique, a scene recognition method, and a pathway planning strategy. These formed a system that enabled robots to autonomously shuttle between densely planted rows. Initially, a trunk point cloud extraction method using a semantic segmentation network was developed for tree row identification and positioning. Subsequently, a convolutional neural network-based method was established for location scene recognition to identify various scenarios within rows. Finally, an inter-row movement strategy managed by a finite state machine and a pathway planning method based on RS curves were designed for continuous walking through multiple rows. The trunk point cloud segmentation achieved an average IoU of 88.3%, with tree localization errors of 2.04% in the x -direction and 1.54% in the y -direction. The average error in tree row direction estimation was 1.11°. The row-end recognition accuracy reached 96%, and the average deviation of in-line centerline walking was 0.08 m. These results showed that the proposed methods met the accuracy requirements for tree row positioning and scene recognition in outdoor orchards, which effectively planned pathways between rows and served as a reliable reference for autonomous laser-guided navigation.

Key words: orchard; robot; navigation; trunk segmentation; scene recognition; tree row localization

收稿日期: 2024-03-11 修回日期: 2024-05-10

基金项目: 国家重点研发计划项目(2018YFC1602701)和北方工业大学1138工程项目(110051360022XN108)

作者简介: 毕松(1983—),男,副教授,博士,主要从事智能农机设备研究,E-mail: bisong@163.com

0 引言

目前,我国水果种植面积与产量均位于世界前列^[1-2],随着生产规模的扩大,农业生产的用工量逐年增加,植保、采收是水果生产过程中用工量较大的作业环节^[3],提高我国果园生产的自动化水平符合当前水果产业快速发展的需求。上述作业环节的自主导航技术是提升果园生产作业自动化的关键技术。

目前,果园导航主要分为卫星定位导航与自主感知导航两大类。由于基于卫星定位的自主导航在行间距较窄和冠层遮挡等情况下,定位精度受限,无法实现有效导航^[4]。因此基于局部环境自主感知的果园机器人导航方法受到国内外相关领域学者的关注。完整的果园导航作业任务为在定植的果园中实现行内和行间的连续有序穿梭^[5],一方面,由于果园的结构主要由树行来定义,因此树行的可靠识别和定位对于果园自主导航至关重要。另一方面,由于果园自主行走任务需要机器人有序地经过行内、行间等多个作业场景,因此实时准确识别行内行间作业场景并根据不同作业场景切换对应的规划任务是果园自主导航的关键步骤。

针对树行识别定位问题,现有研究根据识别思路可分为基于区域的方法与基于坐标的方法,基于区域的方法首先估计树行区域,再由区域特征估计树行信息^[6-8]。基于坐标的方法首先检测果树树干中心坐标,再由果树中心坐标估计树行信息^[9-10]。

以上针对树行识别的研究中,基于区域的树行识别定位方法受不同生长阶段枝叶特征变化影响,精度受限。基于坐标的树行识别定位方法通过分离检测树干,提升了冠层特征变化时树行定位的稳定性,但在果园环境下仍存在以下局限性:①户外光照条件变化较大,基于视觉的树干检测方案稳定性受限。②密植果园枝叶遮挡关系复杂,基于点云的传统聚类方法难以有效定位树干。③现有树行方向估计方法依赖当前偏航姿态分割左右树行,当偏航姿态发生变化时树行方向估计方法稳定性受限。

针对行间位置场景识别问题以及行间自主行进路径规划问题的研究^[11-14]在密植果园中仍存在以下2个局限:①行间位置检测依赖于车辆当前偏航姿态以及果园点云分布密度特征,当车辆姿态出现偏差、果树生长导致枝叶点云分布密度发生变化时,行间位置检测将会失效。②行间换行路径为固定轨迹,当地面不平整^[15]导致车身出现大姿态偏差时,缺乏路径修正能力。

针对现有方法的局限性,本文提出基于点云语义分割网络的树行识别定位方法、基于卷积神经网络的场景识别方法、基于 RS(Reeds-shepp)曲线与动态窗口法(Dynamic window approaches, DWA)的行间路径规划方法。首先,对果园 3D 点云进行直通滤波、地面分割、降采样等预处理,再使用点云语义分割网络分割果树树干点云,并对树干点云进行聚类以获得果树中心点坐标;其次,提出一种基于最邻点角度核密度分析的树行方向估计方法,以实现不受偏航姿态影响的鲁棒树行估计;再次,通过 scancontext 特征提取算法提取果园全局场景特征,并提出一种平移不变卷积分类网络完成机器人所处位置的场景识别。最后,基于有限状态机实现机器人行进策略管理,基于 RS 曲线与 DWA 算法实现机器人的行内路径规划与换行路径规划。

1 路径规划方法与模型

1.1 方法整体结构

本文方法主要由树行识别定位、场景识别、路径规划 3 部分组成。整体方法结构如图 1 所示。




图 1 整体方法结构图

Fig. 1 Method overall structure diagram

如图 1 所示,首先,在树行识别定位模块中,为提升定位精度,采用基于坐标的方法进行树行分析,为了在复杂遮挡场景中准确检测树干,基于点云语义分割网络分割树干点云,对树干点云进行聚类以获取树干中心坐标,再由果树中心坐标估计树行信息。其次,在场景识别模块中,为了提升在偏航姿态变化场景识别的稳定性,通过 scancontext 特征提取算法提取果园全局场景特征,并提出一种平移不变卷积分类网络完成机器人所处位置的场景识别。最后,在路径规划模块中,为实现不同场景下的连续有序穿梭,基于有限状态机实现机器人行进状态管理,基于 RS 曲线与 DWA 算法实现机器人行内路径规划与换行路径规划。

1.2 树行识别定位

果园的结构主要由树行来定义,因此树行的可

靠识别和定位对于导航至关重要。本文基于点云语义分割网络,研究果园树行识别定位方法。方法流程图如图 2 所示。




图 2 树行识别定位方法流程图

Fig. 2 Flowchart of tree line identification and localization method

如图 2 所示,首先对点云进行裁剪、滤波等预处理以去除导航无关点。其次,基于点云语义分割网络提取树干点云。再次,对树干点云进行聚类以获取树干中心点坐标。最后,对树干中心点坐标进行分析以获得树行方向信息。

1.2.1 点云预处理

原始点云数据中包含的机器人自身部分点云以及过远距离点云对树行分析无意义,通过坐标筛选过滤上述点,保留满足如下条件的点云。

$$\begin{cases} x^2 + y^2 < R_a^2 \\ -L_a < x < 0 \\ -\frac{W_a}{2} < y < \frac{W_a}{2} \\ -H_a < z < 0 \end{cases} \quad (1)$$

式中 R_a ——保留区域半径

L_a ——车身长

W_a ——车身宽

H_a ——车身高

(x, y, z) ——点云坐标

受环境遮挡、被测物体反射率^[16]的影响,点云中存在离群点噪声,使用统计滤波^[17]予以剔除。为减小后续分割环节计算量,采用最远点采样法^[18]对点云进行降采样。

1.2.2 树干点云分割

在不同季节、天气下,果园的场景特征具备一定差异,如图 3 所示。夏季果园场景枝叶茂盛,树冠表特征反射面积大。秋季果园中,树冠表特征反射面积小,特征区别较大。

为提升自主导航稳定性,机器人在自主作业过程中需要排除上述干扰,并提取不同季节、天气下果园的共性稳定特征,考虑到树冠易受天气、季节影



图 3 果园不同季节场景示意图

Fig. 3 Schematics of different seasonal scenes in orchard

响,提取树干点云作为后续场景分析的数据基础。

果园点云层次结构复杂,果树不同生长阶段点云疏密程度有显著变化,传统的基于单一特征的聚类等方法难以稳定分割果树点云,为满足树干分割任务的准确性要求,基于改进的 PointNet + +^[19] 网络进行树干点云分割。

PointNet + + 网络通过在不同尺度下对邻域点云进行特征提取来编码点云高级特征,并通过插值上采样与跳跃连接逐步将高级特征解码到每个点云像素从而完成语义分割,其基本特征提取模块 Set - Abstraction(SA)简图如图 4 所示。




图 4 Set - Abstraction 模块简图

Fig. 4 Set - Abstraction module sketch

图 4 中, N_1 为输入点数, C_1 为输入通道数, N_2 为采样点数, K 为邻域点数, C_2 、 C_3 为卷积输出通道数。

为了提升分割准确率,增强网络对树干特征的提取能力,本文将 Coord - Attention (CA)^[20] 注意力机制融合到 SA 模块中。CA 注意力机制通过在不同方向上进行平均池化得到空间信息编码,再在不同通道上以加权的方式融合原始特征图,因此能同时对通道、位置信息进行注意。CA 模块的结构简图如图 5 所示,图中 C 、 W 、 H 表示输入张量通道数、宽、高, r 为下采样比例。

融合 CA 注意力机制的改进 SA 模块结构简图如图 6 所示。在 SA 模块的 2 层 1×1 卷积层之间加入 CA 模块以增强特征提取能力,改进 SA 模块以下简称为 CA_SA。

基于 CA_SA 设计 3 层深度 PointNet + + 网络,结构如图 7 所示。




图 5 Coord-Attention 结构简图

Fig. 5 Sketch of Coord-Attention structure




图 6 改进 Set-Abstraction 结构简图

Fig. 6 Improved Set-Abstraction structure sketch




图 7 本文 PointNet++ 网络结构简图

Fig. 7 PointNet++ network structure diagram

图 7 中,CA_SA 为本文改进的特征提取模块,FP 为上采样模块,Point Classify 为像素分类模块,输入为点云 $N \times 3$,输出为所有点的语义信息 $N \times 1$ 。

为提高点云分割模型在位姿变化情况下的分割稳定性,增强模型泛化能力,对训练数据进行齐次变换数据增强。构造空间齐次变换矩阵为

$$T_e = \begin{bmatrix} c_y c_z & -c_y s_z & s_y & t_x \\ s_x s_y c_z + c_x s_z & -s_x s_y s_z + c_x c_z & -s_x c_y & t_y \\ -c_x s_y c_z + c_x s_z & c_x s_y s_z + c_x c_z & c_x s_y & t_z \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (2)$$

式中 T_e ——数据增强变换矩阵

$\theta_{xe}, \theta_{ye}, \theta_{ze}$ ——绕 x, y, z 轴的随机旋转角

t_x, t_y, t_z ——沿 x, y, z 轴的随机位移

其中 s_x 表示 $\sin\theta_{xe}$, c_x 表示 $\cos\theta_{xe}$, s_y 表示 $\sin\theta_{ye}$, c_y 表示 $\cos\theta_{ye}$, s_z 表示 $\sin\theta_{ze}$, c_z 表示 $\cos\theta_{ze}$ 。

对原始点云中的点坐标进行如下变换得到增强数据。

$$\begin{bmatrix} p_{xe} & p_{ye} & p_{ze} & 1 \end{bmatrix}^T = T_e \begin{bmatrix} p_x & p_y & p_z & 1 \end{bmatrix}^T \quad (3)$$

式中 (p_x, p_y, p_z) ——原始坐标

(p_{xe}, p_{ye}, p_{ze}) ——增强坐标

1.2.3 树干中心点聚类

由于机器人在行驶过程中所检测到的果树数量会动态变化,因此选用无需显式给定聚类数量的 DBSCAN^[21] 算法进行果树中心点聚类。

对 DBSCAN 邻域点数量 n_{minPts} 设定为 2,设株间距为 d_{plant} ,行间距为 D_{row} ,邻域半径 ε 设定为 $(d_{plant} + D_{row})/2$,使 DBSCAN 聚类到同一树干点云而不会聚类到相邻树干点云。

应用 DBSCAN 进行树点聚类,聚类效果如图 8 所示,聚类点与树干基本吻合。




图 8 DBSCAN 聚类结果

Fig. 8 DBSCAN clustering results

1.2.4 树行分析

果园结构由树行构成,机器人在作业时需沿行间路径行驶。树行方向是果园导航的关键信息。

由于激光雷达视野的有限性,在机器人位于行边缘时,视野范围内树行信息不完整,而且自然环境下果树种植位置会有随机误差,果树由于老化病死也会产生行内树点的缺失,如图 9 所示,以上果园实际特性增加了树行分析的难度。




图 9 树行分析难点

Fig. 9 Tree row analysis difficulties

在果园中,为了便于行间作业同时尽可能最大化种植密度,行间距 D_{row} 一般大于株间距 d_{plant} ,该特性在密度上表现为,沿树行方向的种植密度分布应最大。基于该特性,本文对相邻果树角度分布进行分析,提出一种与偏航姿态无关的基于最邻点角度

核密度^[22] (Kernel density estimation, KDE) 的树行方向估计方法,方法具体过程如下。

首先对视野范围内的每个树点 $P_i = (x_i, y_i)$ 寻找其最邻近点 $P_{in} = (x_{in}, y_{in})$, 连接点 P_i, P_{in} 计算其方向角度, 并将角度归一化到 $(-90^\circ, 90^\circ)$ 区间。

对所有树点的最邻点方向进行 KDE 核密度估计。KDE 估计公式为

$$K(\theta) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{\theta^2}{2}\right) \quad (4)$$

式中 θ ——输入角度 $K(\theta)$ ——核函数

在 θ 处估计的概率密度函数为

$$\hat{f}(\theta) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{\theta - \theta_i}{h}\right) \quad (5)$$

式中 n ——样本数量 h ——带宽

式(4)为核函数公式,考虑到果树种植具有一定随机误差,采用高斯核函数。

计算 KDE 估计的密度最大角度 θ_l , 即获得树行估计方向。

以行内场景为例,基于最近点角度核密度的树行估计过程如图 10 所示。




图 10 树行分析过程

Fig. 10 Diagrams of tree row analysis process in extreme edge scenario

图 10a 为所有树点的最邻点连线; 图 10b 为对估计树行方向在树点地图中的可视化; 图 10c 为最近点角度 KED 密度分析, 图中绿点为最近点连线的离散分布, 蓝线为估计所得角度密度, 红色虚线为估计密度最大点, 即最终估计的树行方向。

1.3 场景识别

根据经验, 在沿行种植类果园中, 将机器人作业场景分为行外、行头、行内 3 类场景, 如图 11 所示。

果园自主行走任务需要机器人有序地经过行




图 11 果园场景划分示意图

Fig. 11 Schematic of orchard scene division

内、行间等多个作业场景, 因此实时准确识别行内与行间作业场景并根据不同作业场景切换对应的规划任务是实现果园自主导航的关键步骤, 本文研究基于 scancontext^[23] 特征的果园场景识别方法, 方法流程如图 12 所示。




图 12 果园场景识别流程图

Fig. 12 Orchard scene recognition flowchart

首先, 由于点云的无序性, 对原始点云数据的直接识别相对复杂且鲁棒性较低, 因此先通过 scancontext 特征提取算法提取场景全局特征, 将无序的点云转换为有序的特征描述符。其次, 提出一种 x 轴平移不变性卷积神经网络对 scancontext 特征描述符进行识别分类, 得到当前机器人所处场景位置信息。

1.3.1 场景特征提取

为实现不同偏航姿态下位置场景的稳定识别, 采用具备一定旋转不变性的点云特征提取算法 scancontext 进行点云场景特征提取, scancontext 的原理如图 13 所示。

scancontext 以极坐标方式在 ROI 内对点云进行网格分区, 并在每个网格内提取点云最大高度、最大高度差等轴信息作为该网格的特征值, 最终构成一有序二维特征图, 如图 14a 所示。

1.3.2 场景识别

scancontext 特征图是通道数为 C_n 的 $S_n \times R_n$ 矩阵, S 轴为极角轴, 在极坐标物理空间中, 极角具有周期循环的特性, $0, 2\pi$ 表示相同极角位置, 该特性会导致特征图沿 S 轴出现目标切分, 发生切分的目标会离散分布于特征图 S 轴的左右边界, 如图 14a 中红色标注框所示。而实际上, 由于 S 轴 (下称 x 轴) 周期性, 可以将 scancontext 特征图在




图 13 scancontext 原理示意图

Fig. 13 Schematic of principle of scancontext




图 14 目标切片示意图

Fig. 14 Schematics of feature slice

物理上看作一种环形结构,如图 14b 所示。

标准卷积无法越过边界,为实现 x 环形域的卷积特征提取,本文使用对称 x 环形卷积代替普通卷积,卷积公式为

$$O_{i,j} = \sum_{m=-\frac{h}{2}}^{\frac{h}{2}-1} \sum_{n=-\frac{w}{2}}^{\frac{w}{2}-1} k_{m-\frac{h}{2},n-\frac{w}{2}} I_{(\lambda i+m,(\lambda j+n+W)\%W)} \quad (6)$$

式中 I ——高度为 H 、宽度为 W 的输入张量
 k ——高度为 h 、宽度为 w 的卷积核,当 h 为奇数时, $h/2$ 替换为 $(h-1)/2$, w 同理
 λ ——卷积步长
 O ——输出张量
 $\%$ ——取余操作符

以下对称 x 环形卷积记为 cirXConv2d 。

当机器人在同一场景位置发生姿态变化时,scancontext 特征图将会沿 S 轴(x 轴)左右平移,如图 15 所示。




图 15 scancontext 特征提取示意图

Fig. 15 Schematic of scancontext feature extraction

图 15 上下图分别为机器人在同一位置处相对偏航姿态为 0° 、 70° 时的特征图,偏航姿态的变化在特征图上表现为 x 轴的平移,红色箭头所示处为同一特征的平移效果,为了提高场景识别在姿态变化场景下的稳定性,本文提出一种 x 平移不变特征提取结构(Translation-invariant x Flatten, TIxF)替代标准 Flatten 结构,如图 16 所示。




图 16 Translation-invariant x Flatten 结构简图

Fig. 16 Translation-invariant x Flatten structure sketch

首先对输入张量分离通道并进行 cirXConv1d 卷积以提取通道内特征相关信息,输出经通道合并后再次进行 cirXConv1d 卷积以提取通道间特征相关信息, cirXConv1d 的原理为使用大小与输入张量相同的一卷积核在输入张量上沿 x 轴循环滑动卷积形成一维输出张量,能够有效提取环形域张量全局特征,最后进行 X Max Pool 提取 x 轴池化特征,由于 Max Pool 操作具备顺序不变性,因此上述结构能够在有效提取环形域张量特征的同时对任意的 x 轴平移具有相同的输出,具备 x 平移不变性。

应用本文提出的 TLxF 结构设计场景识别卷积神经网络,结构如图 17 所示。scancontext 特征图通过 3 层 cirXConv2d 卷积提取高级特征,再经过 TLxF 提取为一维特征向量,最后经过两层全连接输出场景类别。




图 17 场景识别网络结构

Fig. 17 Scene recognition network architecture

1.4 路径规划

机器人在果园下的行间连续行走任务可以拆分为行内、行头、行外等多个场景下的子任务,在各个子任务下执行不同策略的路径规划,具体流程如图 18 所示。首先,根据果园行走任务的结构化特性,将多行行走任务拆分为 4 个状态,设计果园机器人行进策略状态机管理状态的切换,由 1.3 节的位置场景识别结果作为状态机触发条件。最后基于




图 18 路径规划流程图

Fig. 18 Path planning flowchart

RS 曲线完成路径规划,基于 DWA 完成轨迹规划。

1.4.1 行进状态管理

为实现机器人在行内行间的连续有序行走,设计有限状态机管理机器人行进策略,如图 19 所示。图 19 中各状态定义如表 1 所示,各事件定义如表 2 所示。




图 19 果园行间行走有限状态机示意图

Fig. 19 Schematic of finite state machine for walking between rows in orchard

表 1 果园行间行走状态机状态及子任务

Tab.1 Orchard inter-row walking state machine states and subtasks

状态号	状态名称	对应子任务
S1	行外	沿行外行走至下一行行头
S2	入行	由行头入行
S3	行内	行内沿中线行走
S4	出行	由行头出行

表 2 果园行间行走状态机事件及来源

Tab.2 Orchard inter-row walking state machine events and sources

事件标号	事件描述	事件来源
e1	到达行外	稳定识别到行外场景
e2	到达行头	稳定识别到行头场景
e3	到达行内	稳定识别到行内场景

表 2 中,事件来源即图 12 中的场景识别结果,为提升策略切换稳定性,定义连续识别到相同场景次数 $n_{\text{stab}} \geq 3$ 时为稳定识别。

根据各状态子任务设定规划目标点。入行、行内状态目标点为左右侧树点连线中点,目标姿态与树行方向平行,以实现行中线行走,如图 20a、20b 所示。出行状态目标点为本行行头、行外状态目标点为下一行行头,目标姿态与树行方向垂直,以实现行间换行,如图 20c、20d 所示,图中蓝点为树点,红色箭头为目标规划点。

1.4.2 RS 路径规划

果园导航任务中,需要同时考虑规划路径的运动学可达性、最优性与局部轨迹的动力学安全性,本文将果园导航任务分为两步,先规划当前场景子任务下的全局引导路径,再规划全局路径引导下的局部轨迹。将全局规划与局部规划相结合,能够有效提升机器人路径规划的灵活性与稳定性。

差速轮式机器人的全局引导路径规划需要同时考虑起始点、导航点位置与姿态并符合机器人底盘




图 20 规划目标点示意图

Fig. 20 Schematics of planning target points

运动学约束, Reeds - Shepp^[24] 曲线基于非完整运动模型, 能够根据转向半径约束求解出与起始点、导航点位姿相切的最短平滑曲线, 与轮式机器人运动特性相匹配, 本文基于 Reeds - Shepp 曲线进行全局引导路径规划。

RS 曲线含有 48 类路径模式, 记为集合 $R_s = \{r_{si}\}$, 障碍物区域记为 R_{obs} , 规划全局引导路径的伪代码如下:

输入: P_{tar}^{Si} 导航点位姿, R_{obs} 障碍物区域, R_s 路径模式集合

输出: P_{guide} 最优引导路径

$L_i \leftarrow +\infty$

$P_{guide} \leftarrow []$

for r_{si} in R_s do

$P_i \leftarrow rs_slope(P_{tar}^{Si}, r_{si})$

if P_i not in R_{obs} then

$L_i \leftarrow calc_length(P_i)$

if $L_i < L_{min}$ then

$P_{guide} \leftarrow P_i$

$L_{min} \leftarrow L_i$

end if

end if

end for

return P_{guide}

伪代码中, $rs_slope(P_{tar}^{Si}, r_{si})$ 表示求解 r_{si} 模式下对于导航点 P_{tar}^{Si} 的具体路径。 $calc_length(P_i)$ 表示计算 P_i 路径的长度, P_{guide} 为最终规划的引导路径, 为同时包含位置、姿态的一系列轨迹点集合。 R_{obs} 为障碍物区域, 在果园中, 障碍物区域定义为每个以树

点为圆心, 一定半径内的区域所组成的并集。

以入行、行内缺树场景为例, 绘制引导路径规划示意图如图 21 所示。图中, 蓝色箭头序列为 RS 引导路径(箭头方向表示位姿)。可以看到入行、行内缺树场景下, 均能规划出符合机器人运动学约束的平滑路径。




图 21 RS 引导路径规划示意图

Fig. 21 RS guided path planning schematics

1.4.3 DWA 轨迹规划

由于果园地面凹凸不平, 机器人在行驶过程中, 其实际姿态与控制预期姿态会有偏差, 因此需要实时调整运动轨迹以快速跟踪全局引导路径并避免碰撞, 同时还需要考虑机器人动力学约束。DWA 算法^[25]能够实时根据机器人动力学约束进行避障与路径点跟踪, 适合作为果园环境下的轨迹跟踪方法, 但其无法有效跟踪轨迹姿态, 本文对 DWA 评价函数进行优化设计, 以同时跟踪引导路径的位置与姿态。

设机器人最大加速度为 $\pm a_{max}$, 最大角加速度为 $\pm \alpha_{max}$, 最大速度为 v_{max} , 最大角速度为 ω_{max} , 当前速度为 v_{now} , 当前角速度为 ω_{now} 。则机器人理论速度 V_s 为

$$V_s = \{(v, \omega) \mid v \in [-v_{max}, v_{max}], \omega \in [-\omega_{max}, \omega_{max}]\} \quad (7)$$

在加速度约束下速度 V_a 为

$$V_a = \{(v, \omega) \mid v \in [v_{now} - \Delta v, v_{now} + \Delta v], \omega \in [\omega_{now} - \Delta \omega, \omega_{now} + \Delta \omega]\} \quad (8)$$

其中

$$\Delta v = a_{max} T \quad (9)$$

$$\Delta \omega = \alpha_{max} T \quad (10)$$

式中 T ——窗口时间

受障碍物约束的速度范围 V_b 为

$$V_b = \{(v, \omega) \mid v \leq \sqrt{2D_{obs} a_{max}}, \omega \leq \sqrt{2D_{obs} \alpha_{max}}\} \quad (11)$$

式中 D_{obs} ——机器人与最近障碍物的距离

最终的速度窗口 V_{DWA} 为上述约束条件的交集

$$V_{DWA} = V_s \cap V_a \cap V_b \quad (12)$$

由于需要同时跟踪位置、姿态, 对轨迹的评价需要同时考虑轨迹末端位置与姿态偏差, 构造轨迹评

价函数为

$$J_{DWA} = \alpha J_{Pos} + \beta J_{Att} + \gamma J_{Bar} + \delta J_{Vel} \tag{13}$$

式中 J_{Pos} ——轨迹末端点与目标点位置距离误差评价函数

J_{Att} ——轨迹末端姿态与目标点姿态误差评价函数

J_{Bar} ——轨迹末端与障碍物距离评价函数

J_{Vel} ——轨迹速度评价函数

$\alpha, \beta, \gamma, \delta$ ——各项加权系数

对速度窗口 V_{DWA} 进行离散采样,根据差速轮式机器人运动学公式计算窗口时间 T 内的轨迹,对每条轨迹计算代价 J_{DWA} ,评价最高的轨迹对应的控制量即为最优控制量。

取沿 RS 引导路径,距离机器人当前位置($v_{now} + \Delta v$) T 长度处为局部跟踪点,在入行、行内缺树场景下规划效果如图 22 所示。可以看到轨迹末端点与局部跟踪点位姿跟踪效果较好。




图 22 局部轨迹规划示意图

Fig. 22 Schematics of local trajectory planning

2 实验

为了验证本文提出的果树识别定位方法、树干方向估计方法以及场景识别方法的准确性,基于实际机器人系统进行实验。

2.1 实验条件

以自主研发的四轮差速转向机器人作为实验平台,机器人外形尺寸为 1 185 mm × 1 040 mm × 980 mm,实物图如图 23 所示,采用 RoboSense Helios 32 线激光雷达作为点云采集设备,该雷达水平视场角为 0°~360°,水平角分辨率为 0.2°,垂直视场角为 -55°~15°,垂直角分辨率为 1.33°,点云采集频率 10 Hz。

实验地点位于北京市通州区金果天地庄园桃园,该桃园为沿行种植果园,果树行平均行距为 3.2 m,平均株距为 0.9 m。为充分论证本文方法在不同季节下的鲁棒性,分别于 2023 年 6 月 3 日(盛叶期)、2023 年 11 月 27 日与 2024 年 3 月 29 日(枯叶期)进行了实验,实验现场如图 24 所示。图 24b 所示机器人实验平台为图 24a 的迭代版本,所使用




图 23 实验机器人实物图

Fig. 23 Experimental robot physical diagram

1. 车载计算机 2. 锂电池 3. 差速转向驱动轮 4. 下位机控制器 5. 激光雷达




图 24 实验现场图

Fig. 24 Experimental site photos

传感器、性能参数均一致。

2.2 实验结果

2.2.1 树干分割实验

对果树树干的可靠分割是后续树行定位的基础,本文在自制分割数据集上进行验证,共采集点云 620 帧,其中盛叶期与枯叶期各 310 帧,随机混合后进行预处理,得到 620 组数据样本,随机分配为训练集 500 组,验证集 120 组。数据标签分为树干区域、其他区域 2 类,使用 CloudCompare 软件进行标注,采用平均交并比(mIOU)对结果进行统计分析,消融实验结果如表 3 所示。

表 3 语义分割自制训练集消融实验结果

Tab.3 Ablation experiment of self-made training set

数据增强	CA	mIOU/%
		85.7
✓		86.9
	✓	87.6
✓	✓	88.3

注:表中“✓”表示相较于原始 PointNet++ 模型增加的策略。

由表 3 可知,相较于原始 PointNet++ ,单独加入数据增强策略在自制训练集上的 mIOU 提升 1.2 个百分点,单独加入 CA 模块在自制训练集上的 mIOU 提升 1.9 个百分点,同时加入数据增强策略与 CA 模块在自制训练集上的 mIOU 提升 2.6 个百分点,说明数据增强策略能够增加模型泛化性能,CA 模块能够提升模型特征提取能力,验证了所提方法的有效性。

对验证集内的盛叶期与枯叶期数据分别计算mIOU,对比结果如表4所示。

表 4 不同生长阶段树干分割对比实验结果
Tab.4 Comparative experiments on trunk segmentation at different growth stages

生长阶段	数量	mIOU/%
盛叶期	58	85.7
枯叶期	62	90.8

盛叶期与枯叶期树干分割示意图如图25所示。由图25b红色方框、图25d黑色方框可知,枯叶期枝叶密度较小,树干分割模型能够分割出较为完整的树干,验证集分割准确率达到90.8%,由图25a、25c可知,盛叶期枝叶密度较大,对果树上部树干形成遮挡,但树干分割模型仍能准确分割果树下部树干,验证集分割准确率达到85.7%。本文模型在果树不同生长阶段均能有效分割树干。




图 25 盛叶期与枯叶期树干分割对比图
Fig. 25 Comparison of trunk segmentation at full leaf stage and dead leaf stage

局部放大图如图26所示,从图中可看出错误分类点多数分布在树干边界处,对后续树干中心点聚类分析几乎没有影响,满足应用场景需求。




图 26 树干分割局部示意图
Fig. 26 Localized schematic of trunk segmentation

2.2.2 果树定位实验

果树的相对位置是实现果园自主导航的重要信息,为了验证本文果树定位方法的有效性,在樱桃园内进行果树定位实验,测量前方8棵树相对位置,实

验现场图及实验示意图如图27所示。



图 27 果树定位实验现场图
Fig. 27 Site maps of fruit tree localization experiment

将本文提取的树干中心点相对坐标 $\hat{x}, \hat{y}$ 与人工测量的真值 x, y 进行对比,计算 x, y 方向相对误差 E_x, E_y ,其计算公式为

$$E_x = \frac{|\hat{x} - x|}{|x|} \times 100\% \quad (14)$$

$$E_y = \frac{|\hat{y} - y|}{|y|} \times 100\% \quad (15)$$

实验结果如表5所示。

表 5 果树相对位置定位及其误差
Tab.5 Relative positional localization of fruit trees and its errors

编号	参考值/mm		估计值/mm		误差/%	
	x	y	$\hat{x}$	$\hat{y}$	E_x	E_y
1	-0.66	1.70	-0.65	1.67	1.51	1.76
2	-1.02	-1.15	-1.00	-1.14	1.96	0.87
3	0.32	1.52	0.31	1.54	3.12	1.32
4	-0.06	-1.29	-0.05	-1.26	16.70	2.33
5	0.99	1.55	1.00	1.52	1.01	1.94
6	0.82	-1.47	0.81	-1.44	1.22	2.04
7	1.90	1.61	1.93	1.59	1.58	1.24
8	2.00	-1.48	1.98	-1.50	1.00	1.35

由表5可知, x 方向果树平均定位误差为2.04%, y 方向果树平均定位误差为1.54%,经分析,定位误差主要来源于激光雷达测距误差与果树的垂直生长偏差,定位精度满足实际应用场景需求。

2.2.3 树行方向估计实验

为了充分验证本文树行估计方法在各作业场景下的准确性,分别在行外、行头、行内位置处采集数据,并使用本文方法、RANSAC、最小二乘法分别进行树行角度估计以进行对照,计算各方法估计值 $\hat{\theta}_i$ 与人工标记真值 θ_i 的误差,误差计算公式为

$$e_{\theta_i} = |\hat{\theta}_i - \theta_i| \quad (16)$$

式中 e_{θ_i} ——树行方向估计误差

实验结果如表6所示。方法1为本文方法,方法2为RANSAC方法,方法3为最小二乘法,由表6可知,使用本文方法树行方向估计平均误差为1.11°,使用RANSAC方法树行方向估计平均误差

为 2.42° ，使用最小二乘法树行方向估计平均误差为 7.28° 。对实验结果进行分析，RANSAC 产生较大误差的场景为行外场景，如图 28a ~ 28c 所示，该场景下，树行信息不完整，树行方向不再满足 RANSAC 拟合条件；最小二乘法产生较大误差的场景为行头场景，如图 28d ~ 28f 所示，该场景下车身

偏航姿态产生变化，而最小二乘法依赖于当前偏航姿态对两侧树行的分割，因此误差较大。而本文方法利用全局树点信息进行估计，在树行信息不完整的行外场景以及偏航姿态变化的行头场景下表现出更优的鲁棒性，为自主导航提供稳定数据支撑。

表 6 树行估计误差

Tab. 6 Tree row estimation error

($^{\circ}$)

方法	位置 1			位置 2			位置 3			位置 4			位置 5			位置 6		
	θ_l	$\hat{\theta}_l$	e_{θ_l}	θ_l	$\hat{\theta}_l$	e_{θ_l}	θ_l	$\hat{\theta}_l$	e_{θ_l}	θ_l	$\hat{\theta}_l$	e_{θ_l}	θ_l	$\hat{\theta}_l$	e_{θ_l}	θ_l	$\hat{\theta}_l$	e_{θ_l}
1	-20.4	-21.9	1.5	30.1	28.7	1.4	-0.7	0.3	1.0	0.3	-0.8	1.1	3.2	2.0	1.2	-0.1	0.6	0.7
2	-20.4	66.7	87.1	30.1	27.0	3.1	-0.7	0	0.7	0.3	-1.2	1.5	3.2	3.8	0.6	-0.1	1.1	1.2
3	-20.4	51.5	71.9	30.1	-20.5	50.6	-0.7	1.9	2.6	0.3	1.9	1.6	3.2	0.9	2.3	-0.1	4.2	4.3




图 28 树行估计实验结果

准确率(OA)对验证集进行统计分析,消融实验结果如表 7 所示。

表 7 场景识别自制训练集消融实验结果

Tab. 7 Ablation experiment of self-made training set

cirXConv	TlxF	OA/%
		85.0
✓		88.3
✓	✓	95.0

注:表中“✓”表示相较于 BaseCNN 模型增加的策略。

由表 7 可知,普通 CNN 分类网络对姿态变化场景分类准确率为 85.0%,加入 cirXConv 后提升 3.3 个百分点,加入 TlxF 后提升 10 个百分点,本文方法在姿态变化场景下分类准确率有明显提升,验证了本文所设计的特征提取模块的有效性。

由于现有位置场景算法大多以行尾检测为主,因此从验证集中取 20 组行尾数据与同类算法进行行尾识别准确率对比,基于区域阈值的行尾检测方法^[8,14,26]是目前较为经典的行尾检测方法,实验结果为本文方法行尾识别准确率 96.0%,基于区域阈值的方法行尾识别准确率 75%,本文算法在偏航姿态变化场景下行尾识别鲁棒性更好。对实验结果进行分析,基于区域阈值的传统方法通过检测机器人坐标系下固定区域内的点云数量来判断是否到达行尾,当偏航姿态发生偏差,行尾处的检测区域与果树行点云发生重叠,无法有效检测行尾,因此稳定性受限。

2.3 实际导航测试

为验证果园作业机器人自主导航系统的实际工作效果,2024 年 3 月 29 日在北京市通州区金果天地庄园 1 号地进行了实际导航测试。机载计算机硬件平台为 Intel i7-12700H CPU, Nvidia RTX3060 GPU,软件平台为 Linux 环境下的 ROS2 humble。

针对植保作业沿行内中线行走的需求,在实验

2.2.4 场景识别实验

一般工况下,果园作业机器人的偏航姿态可能无偏差、向左偏差或者向右偏差,为了验证本文场景识别算法在各类场景、不同姿态下的有效性,分别在果园行外、行尾、行内作业场景沿机器人作业路径各均匀采集 40 组位置点,每个位置点各采集 3 种偏航姿态下 (-30° 、 0° 、 30°) 的数据以模拟姿态变化场景,如图 29 所示。共 360 组实验数据,随机划分为训练集 300 组,验证集 60 组。




图 29 场景识别数据采集示意图

Fig. 29 Schematic of scene recognition data acquisition

手动遥控机器人到达预定位置,采集到点云数据后通过前序算法批量生成 scancontext 描述符,使用训练集对位置场景识别模型进行训练,采用平均

地点进行自主行内中线行走与自主行间换行实验，

测量一次中线偏差,行中线偏差定义为机器人坐标系原点与行中线的距离,行中线定义为过行内导航

自主行内中线行走过程如表 8 所示,每间隔 2.5 m

系原点与行中线的距离,行中线定义为过行内导航

表 8 行内行走实验结果

Tab.8 Results of in-row planning experiment

项目	位置1	位置2	位置3	位置4	位置5	位置6	位置7	位置8
航拍图								
偏差/m	0.13	0.10	0.12	0.03	-0.07	0.09	-0.05	-0.11

点(中点)与树行方向平行的直线,示意图如图 30 所示。自主行间换行过程如表 9 所示。

由表 8 可知,机器人在行内运行,相对于行中线偏差最大为 0.13 m,平均偏差 0.08 m,满足中线作业场景需求。由表 9 可知,本文设计方法可以顺利完成行间自主穿梭任务。





图 30 行中线偏差示意图

Fig.30 Schematic of line center deviation

表 9 行间行走实验结果

Tab.9 Results of out-row planning experiment



3 结论

(1)构建了用于密植果园机器人行间穿梭任务的自主导航系统,能够有效完成行内与行间连续穿梭任务。

(2)设计的树干点云语义分割网络平均交并比达到 88.3%,在果园环境下能够有效分割定位果树树干。基于树干点云的果树中心点提取方法方向平均定位误差为 2.04%,y 方向果树平均定位误差为 1.54%。为全季节果园导航工作提供稳定性支撑,并且由于点云数据不受光照条件影响,具备全天候工作的优势。

(3)提出了一种基于最邻点角度核密度估计的树行方向分析方法,对树行方向的估计平均误差达

到 1.11°,在树行信息不完整的行外场景以及偏航姿态变化的行头场景下相比现有算法表现出更优的鲁棒性,为自主导航提供稳定数据支撑。

(4)提出了一种平移不变特征提取模块,并基于该模块设计了果园位置场景识别卷积分类网络,在包含不同偏航姿态的场景数据集中,行尾识别准确率达到 96%,提高了机器人在面对果园地形不平整性、种植不规整性等复杂环境时的导航稳定性。

(5)基于有限状态机设计了机器人行间行进策略状态管理器,基于 RS 曲线与 DWA 实现了机器人的行内路径规划与换行路径规划,使得机器人能够完成连续行内行间行走任务,在实际场景测试中,行内中线行走偏差为 0.08 m,为果园机器人的实际应用提供了重要支持。

参 考 文 献

[1] 国家统计局. 国际统计年鉴[M]. 北京:中国统计出版社,2021.

[2] 师树谦,王亚磊. 农业机器人技术现状与发展趋势[J]. 新疆农机化,2023(3):12-16.
SHI Shuqian, WANG Yalei. Current technical situation and development trend of agricultural robot[J]. Xinjiang Agricultural Mechanization, 2023(3):12-16. (in Chinese)

[3] 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)

[4] XIE B, JIN Y, FAHEEM M, et al. Research progress of autonomous navigation technology for multi-agricultural scenes[J]. Computers and Electronics in Agriculture, 2023, 211: 107963.

[5] 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.

[6] 聂森,王丙龙,郝欢欢,等. 基于机器视觉的果园导航中线提取算法研究[J]. 农机化研究,2016,38(12):86-89.
NIE Sen, WANG Binglong, HAO Huanhuan, et al. Navigation line extraction based on machine vision in orchard[J]. Journal of Agricultural Mechanization Research, 2016, 38(12):86-89. (in Chinese)

[7] 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)

[8] 李会宾,韩伟,史云. 果园作业机器人的自主行间导航系统研究[J]. 中国农业信息,2019,31(4):51-64.
LI Huibin, HAN Wei, SHI Yun. Autonomous inter-line navigation system for orchard robots[J]. China Agricultural Informatics, 2019, 31(4):51-64. (in Chinese)

[9] HUANG P, HUANG P, WANG Z, et al. Deep-Learning-Based Trunk perception with depth estimation and DWA for robust navigation of robotics in orchards[J]. Agronomy, 2023, 13(4): 1084.

[10] 邓贤,李秋洁,高程前,等. 基于激光雷达的果园行间车辆自动导航控制[J]. 农机化研究,2023,45(2):29-35.
DENG Xian, LI Qiujie, GAO Chengqian, et al. Design of intra-row automatic navigation control system of orchard vehicles based on LiDAR[J]. Journal of Agricultural Mechanization Research, 2023, 45(2):29-35. (in Chinese)

[11] 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)

[12] MENGOLI D, EUSEBI A, ROSSI S, et al. Robust autonomous row-change maneuvers for agricultural robotic platform[C]//2021 IEEE International Workshop on Metrology for Agriculture and Forestry (MetroAgriFor). IEEE, 2021: 390-395.

[13] PENG C, FEI Z, VOUGIOUKAS S G. Depth camera based row-end detection and headland maneuvering in orchard navigation without GNSS[C]//2022 30th Mediterranean Conference on Control and Automation (MED). IEEE, 2022: 538-544.

[14] MARTINI M, CERRITO S, SALVETTI F, et al. Position-agnostic autonomous navigation in vineyards with deep reinforcement learning[C]//2022 IEEE 18th International Conference on Automation Science and Engineering (CASE). IEEE, 2022: 477-484.

[15] 赵新,李杰,岳丹丹,等. 三维激光雷达果园路面不平度采集试验与分析[J]. 华中农业大学学报,2022,41(2):227 – 236.
ZHAO Xin,LI Jie,YUE Dandan,et al. The road roughness acquisition test and analysis of three-dimensional LiDAR orchard pavement[J]. Journal of Huazhong Agricultural University, 2022,41(2):227 – 236. (in Chinese)

[16] 张美娜,范道全,雷晓晖,等. 基于插值算法的靶标三维激光点云数据补偿研究[J]. 中国农机化学报,2020,41(8):59 – 64.
ZHANG Meina,FAN Daoquan,LEI Xiaohui,et al. Research on data compensation for target with three-dimensional laser point cloud based on an interpolation algorithm[J]. Journal of Chinese Agricultural Mechanization, 2020,41(8):59 – 64. (in Chinese)

[17] GUO J, FENG W, HAO T, et al. Denoising of a multi-station point cloud and 3D modeling accuracy for substation equipment based on statistical outlier removal[C]//2020 IEEE 4th Conference on Energy Internet and Energy System Integration (EI2). IEEE, 2020: 2793 – 2797.

[18] LI J, ZHOU J, XIONG Y, et al. An adjustable farthest point sampling method for approximately-sorted point cloud data[C]//2022 IEEE Workshop on Signal Processing Systems (SiPS). IEEE, 2022: 1 – 6.

[19] QI C R, YI L, SU H, et al. Pointnet + + : deep hierarchical feature learning on point sets in a metric space[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems, 2017: 5105 – 5114.

[20] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021.

[21] ESTER M, KRIEGEL H P, SANDER J, et al. A density-based algorithm for discovering clusters in large spatial databases with noise[C]//National Conferences on Artificial Intelligence,1999.

[22] SILVERMAN B W. Density estimation for statistics and data analysis[M]. Routledge, 2018.

[23] KIM G, KIM A. Scan context: egocentric spatial descriptor for place recognition within 3D point cloud map[C]//2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2018: 4802 – 4809.

[24] REEDS J, SHEPP L. Optimal paths for a car that goes both forwards and backwards[J]. Pacific Journal of Mathematics, 1990, 145(2): 367 – 393.

[25] FOX D, BURGARD W, THRUN S. The dynamic window approach to collision avoidance[J]. IEEE Robotics & Automation Magazine, 1997, 4(1): 23 – 33.

[26] 吴城,李晓娟. 基于单线激光的果园机器人自主导航方法[J]. 江苏大学学报(自然科学版),2023,44(5):530 – 539.
WU Cheng, LI Xiaojuan. Autonomous navigation method of orchard robot based on single lasel[J]. Journal of Jiangsu University(Natural Science Edition), 2023,44(5):530 – 539. (in Chinese)

(上接第 36 页)

[17] WANG Z, WALSH K B, VERMA B. On-tree mango fruit size estimation using RGB – D images[J]. Sensors, 2017, 17(12): 2738.

[18] THALHEIMER M. A new optoelectronic sensor for monitoring fruit or stem radial growth[J]. Computers and Electronics in Agriculture, 2016, 123: 149 – 153.

[19] SENGUPTA A, MUKHERJEE A, DAS A, et al. GrowFruit: an IoT – based radial growth rate monitoring device for fruit[J]. IEEE Consumer Electronics Magazine, 2022, 11(3): 38 – 43.

[20] MAR F, JAVIER R, EDUARD G, et al. Simultaneous fruit detection and size estimation using multitask deep neural networks [J]. Biosystems Engineering, 2023, 233: 63 – 75.

[21] NEUPANE C, PEREIRA M, KOIRALA A, et al. Fruit sizing in orchard: a review from caliper to machine vision with deep learning[J]. Sensors, 2023, 23: 3868.

[22] MARINI R, SCHUPP J, BAUGHER T, et al. Relationships between fruit weight and diameter at 60 days after bloom and at harvest for three apple cultivars[J]. HortScience, 2019, 54(1): 86 – 91.

[23] JORDI G, MAR F, EDUARD G, et al. Looking behind occlusions: a study on amodal segmentation for robust on-tree apple fruit size estimation[J]. Computers and Electronics in Agriculture, 2023, 209: 107854.

[24] JUAN C M, JORDI G, MANUELA Z, et al. Fruit sizing using AI: a review of methods and challenges[J]. Postharvest Biology and Technology, 2023, 206: 112587.

[25] JUAN C M, JAUME A, JORDI G, et al. Assessing automatic data processing algorithms for RGB – D cameras to predict fruit size and weight in apples[J]. Computers and Electronics in Agriculture, 2023, 214: 108302.