

doi:10.6041/j.issn.1000-1298.2024.07.002

# 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

张伟荣<sup>1,2</sup> 陈学庚<sup>3</sup> 齐江涛<sup>1,2</sup> 周俊博<sup>1,2</sup> 李宁<sup>1,2</sup> 王硕<sup>1,2</sup>(1. 吉林大学工程仿生教育部重点实验室, 长春 130022; 2. 吉林大学生物与农业工程学院, 长春 130022;  
3. 石河子大学机械电气工程学院, 石河子 832003)

**摘要:** 面对田间作业过程中大型机器机动性差及复杂场景下导航路径拟合精度差的问题, 提出一种基于深度学习和高斯过程回归的玉米冠下导航路径提取方法。首先, 基于四足机器人采集玉米冠下作物行图像, 对 Mask R-CNN 实例分割方法进行改进, 在特征融合网络引入简化路径增强特征金字塔网络 (Simple path aggregation network, Simple-PAN), 通过增加自底向上的路径增强模块和特征融合操作模块, 提高图像上下文特征的融合能力。其次, 以模型识别的冠下作物行目标为基础构建两侧区域分界线, 计算可通行区域两侧下垂叶片的分布情况, 优化基于加权平均的导航路径算法。对高斯过程回归 (Gaussian process regression, GPR) 算法进行改进, 添加 DotProduct 线性核对曲线拟合进行优化, 优化 GPR 方法的直线拟合效果。最后, 在验证集上进行导航路径识别, 计算不同方法拟合导航路径的平均偏差。试验结果表明, 该算法能够适应玉米田中叶片遮挡根茎的情况, 优化的 Mask R-CNN 模型具备更高的冠下目标分割精度, 基于改进 GPR 算法拟合的导航线平均偏差为 0.7 像素, 处理一帧分辨率为 1280 像素 × 720 像素的图像平均耗时为 227 ms, 该算法能提供在玉米冠层下具备一定避障能力的导航路径, 满足导航实时性和准确性的要求。结果可为田间智能农业装备的导航算法研究提供技术与理论支撑。

**关键词:** 玉米冠下作物行; 深度学习; 视觉导航; 路径识别; 避障; 高斯过程回归

中图分类号: TP391.4; S24 文献标识码: A 文章编号: 1000-1298(2024)07-0015-12

OSID: 

## Deep Learning and Gaussian Process Regression Based Path Extraction for Visual Navigation under Canopy

ZHANG Weirong<sup>1,2</sup> CHEN Xuegeng<sup>3</sup> QI Jiangtao<sup>1,2</sup> ZHOU Junbo<sup>1,2</sup> LI Ning<sup>1,2</sup> WANG Shuo<sup>1,2</sup>(1. Key Laboratory of Bionic Engineering, Ministry of Education, Jilin University, Changchun 130022, China  
2. College of Biological and Agricultural Engineering, Jilin University, Changchun 130022, China  
3. College of Mechanical and Electrical Engineering, Shihezi University, Shihezi 832003, China)

**Abstract:** Facing the problem of difficult maneuvering of large machines during field operations and poor fitting accuracy of navigation paths in complex scenarios, a method of extracting navigation paths under the maize canopy was proposed based on deep learning and Gaussian process regression. Firstly, based on the quadruped robot collecting images of crop rows under the corn canopy, the Mask R-CNN instance segmentation method was improved, and the simple path aggregation network (Simple-PAN) was introduced into the feature fusion network, and the bottom-up path augmentation module and the feature fusion operation module were increased to improve the image context feature extraction module and the fusion capability of image context features. Secondly, the dividing line between the two sides of the area was constructed on the basis of the crop row target under the crown identified by the model, the distribution of the drooping leaves on both sides of the passable area was calculated, and the navigation path algorithm was optimized based on weighted average. The Gaussian process regression (GPR) algorithm was improved, and the DotProduct linear kernel was added to optimize the curve fitting and

收稿日期: 2024-03-27 修回日期: 2024-05-10

基金项目: 国家重点研发计划项目(2021YFD2000201)、国家自然科学基金项目(32271988)、吉林省重点研发计划项目(20220202028NC)和吉林省科技发展计划项目(20230508032RC)

作者简介: 张伟荣(1994—), 男, 博士生, 主要从事精准农业与仿生智能农机装备研究, E-mail: zhangwr21@mails.jlu.edu.cn

通信作者: 齐江涛(1981—), 男, 教授, 博士生导师, 主要从事精准农业与仿生智能农机装备研究, E-mail: qijiangtao@jlu.edu.cn

improve the straight line fitting effect of the GPR method. Finally, the navigation path recognition was performed on the validation set, and the average pixel deviation of the navigation paths fitted by different methods was calculated. The experimental results showed that the algorithm was able to adapt to the situation of leaf-obscuring rhizomes in corn fields, the optimized Mask R-CNN model possessed higher target segmentation accuracy under the canopy, the average deviation of the navigation line fitted based on the improved GPR algorithm was 0.7 pixels, and the average time consumed for processing a frame with a resolution of 1 280 pixels  $\times$  720 pixels was 227 ms. The algorithm can provide navigation paths with some obstacle avoidance capability under the maize canopy to meet the requirements of real-time and accuracy of navigation. The research results can provide a technical and theoretical support for the research of navigation algorithms for intelligent agricultural equipment in the field.

**Key words:** crop rows under the maize canopy; deep learning; visual navigation; path recognition; obstacle avoidance; Gaussian process regression

## 0 引言

玉米是我国的主要粮食作物之一,是保障我国粮食安全的基石。随着现代农业的发展,信息技术与装备的高度融合可提高粮食生产力<sup>[1]</sup>。利用农业机器人进行田间作物监测与病虫害防治,是玉米生长中后期植保的良好解决方案,其中行间导航是实现玉米生产智能化的关键<sup>[2-3]</sup>。玉米生长中后期枝叶交错,机器人行走空间变得狭窄且难以通行,存在机器人通过性差的问题,因此,行间作业对机器人导航技术有着较高的要求。目前,农业领域中导航技术应用最为广泛的有:北斗卫星导航系统(Beidou navigation satellite system, BDS)、全球导航卫星系统(Global navigation satellite system, GNSS)、激光雷达导航和机器视觉导航<sup>[4-8]</sup>。

BDS 和 GNSS 能提供绝对位置测量,是农业机器人自主导航和作业任务中常见的导航系统。许多商业化的田间机器人使用导航系统数据作为全球定位源,并使用由无人机遥感成像建立的田间地图进行全局规划导航<sup>[9]</sup>。POTENA 等<sup>[10]</sup>提出了一种利用无人机和地面无人车的新型地图配准算法。但卫星导航系统的性能在很大程度上取决于卫星信号的质量,在玉米和高粱等高秆作物田中,导航信号可能会被冠层阻挡,导致机器人在行进中与作物发生碰撞,因此 BDS 或 GPS 可能无法有效地应用于某些田间的定位和导航作业<sup>[11-12]</sup>。

相比于卫星导航,测距激光雷达因具有不依赖卫星信号、抗外部光源干扰等优点从而被广泛使用。BENET 等<sup>[13]</sup>利用二维激光雷达传感器实时检测葡萄果园的作物行,轨迹的横向偏差在 10 cm 左右,能实现稳定的自主导航。周海燕等<sup>[14]</sup>提出一种基于激光雷达的作物收获导航线实时提取方法,利用三维激光雷达扫描收获机前方作物的点云数据,试验表明,该方法能在作物稀缺、杂草较多等情况下保持较高的导航准确性。但高秆玉米冠层下的作物行狭窄

且环境复杂,杂草、延伸出来的枝叶等对采集点云的干扰较大,激光雷达易受到障碍信息的干扰,在非结构化环境下的雷达导航适用性需要进一步研究<sup>[15-18]</sup>。

与卫星导航系统和激光雷达导航相比,机器视觉导航具有实时性强、价格低廉、适用范围广等优点,有部分研究使用 RGB 相机在冠层上部采集图像进行目标识别或作物行检测<sup>[19-23]</sup>,主要依赖农作物与背景间的反射率差异进行导航路径的识别。然而,在实际应用中,杂草的存在以及作物生长中后期行间冠层的紧密性使算法无法准确区分作物行,影响导航线拟合的准确性。随着深度学习技术在图像识别领域的发展,视觉导航成为目前农业机器人的研究热点。有研究学者采用小型机器人在玉米、高粱等高秆作物的冠层下方采集图像数据,宫金良等<sup>[24-25]</sup>基于玉米根茎图像信息,于 2020 年和 2022 年分别提出基于玉米根茎识别的最小二乘法与随机采样一致算法的导航线提取方法,实时性好,在缺苗、杂草较多和株距不标准的情况下仍具有较强的鲁棒性。但上述研究仅限在玉米植株根茎可见的情况下,在杂草或下垂的叶片对根茎遮挡情况时的适用性需要验证。针对田间复杂环境,GAI 等<sup>[26]</sup>使用作物冠层下拍摄的深度图像中拟合导航路径,将过滤后的深度图像转换为 3D 点云,采用线性规划方法拟合平行作物行,但深度图像在不同光照下的稳定性有待优化。LIU 等<sup>[27]</sup>利用边缘检测和去噪技术对图像进行分割,提取图像中的秸秆并采用简化的径向基函数(RBF)算法进行路径规划,提高了秸秆坐标提取的容错性。然而,当机器人在冠层下狭窄的作物行移动时,高密度的作物冠层、杂草和叶片等因素都会对机器人的传感器造成干扰,降低其导航的准确性和可靠性。

综上所述,基于深度学习的视觉导航方法在玉米作物中后期冠下机器人中的应用具有广阔前景。卷积神经网络(Convolutional neural network, CNN)提升了算法智能性和鲁棒性,广泛应用于农业

场景目标识别、分割和分类。但仍存在以下问题:①深度学习语义分割算法对于图像浅层特征的提取能力需要优化,可有效提高目标分割精度。②当前大多研究关注大田冠上场景的导航线识别算法,需要考虑一种能够适用于玉米高秆作物的冠下导航路径拟合算法。③当前研究多以无障碍物情景的导航线直线拟合为主,对于存在障碍物情景时可实现避障作用的曲线导航线拟合方法研究较少。

针对以上问题,本文提出一种基于 Mask R-CNN 的玉米冠下图像实时分割网络模型,基于 RGB 图像根据识别的作物区域和叶片障碍物进行导航路径拟合。定期采集玉米生长中后期的冠下行图像,建立玉米冠下数据库,然后利用 Mask R-CNN 算法对标记后的数据进行训练,识别和拟合具备一定避障能力的玉米行间行走路径,最后验证机器人导航线在冠层下的拟合精度,以满足冠下作物行场景的路径导航需求。

## 1 图像采集与数据集制作

### 1.1 图像采集设备

相比传统的轮式和履带式机器人,四足机器人具备高效的移动能力,凭借其独特的腿部多关节构造和先进的稳定控制策略,在复杂环境中具有较高的适应性和稳定性,因此在非结构化的农业环境中作业具备独特优势<sup>[28]</sup>。

本研究使用 Unitree Robotics 公司的 A1 四足机器人平台及搭载的图像系统进行数据采集。机器人长度、宽度和高度分别为 620、300、340 mm。每条腿由 3 个电机驱动,可实现前进、后退、左右横移及改变抬腿高度等仿生动作,具备良好的野外越障能力。机器人体内安装了一块嵌入式板 (NVIDIA Jetson TX2),用于控制运动和处理数据。如图 1 所示,机器人上安装了 Realsense D435i 型深度相机,用来采集田间冠下作物行的 RGB 图像,相机中内嵌 IMU 传感器,用于采集机器人在 xyz 方向上的加速度,以保持躯体稳定性控制。

四足机器人平台的数据采集系统核心架构如图 2 所示,该系统基于 Unitree Robotics 提供的软件开发工具包(SDK)进行开发,具备丰富的控制功能和算法库。机载计算机通过以太网电缆与网络交换机建立连接,网络交换机通过用户数据报协议(UDP)与控制板进行通信,控制板与电机相连。当机器人需要移动、改变姿势及相机数据采集时,可通过远程遥控实现精准控制,使机器人能够在田间稳定运行。四足机器人的设计使其能够在复杂地形中灵活行走,同时具有较高的稳定性和适应性。在玉

米冠层下,四足机器人能够轻松穿越行间,实现数据快速采集和处理,其高效的移动能力和灵活的操作方式也为农业领域的数据采集工作提供了有力支持。因此,本研究选择四足机器人作为玉米冠层下作物行环境的试验行走平台。



图 1 四足机器人图像采集设备

Fig. 1 Image acquisition equipment of quadruped robot

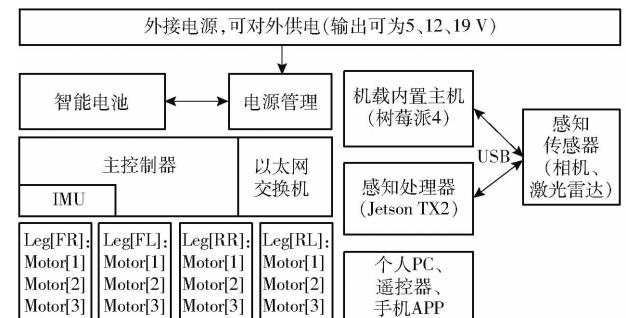


图 2 数据采集系统结构框图

Fig. 2 Block diagram of the data acquisition system

### 1.2 数据集制作

试验在吉林省长春市吉林大学农业试验基地进行,图像采集时间为 2023 年 9 月 1 日—10 月 15 日,采集玉米生长中后期冠层下作物行图像。在图像采集过程中,手动遥控四足机器人在玉米田冠层下沿作物行前进,如图 3 所示,机器人行进速度为



(a) 四足机器人图像采集过程



(b) 前端相机图像

图 3 四足机器人田间图像采集

Fig. 3 Quadruped robot field image acquisition

0.1~0.3 m/s。Realsense D435i 型深度相机距地面 300 mm, 拍摄方向为机器人正前方。数据图像通过 USB3.0 接口传输并存储在机身自带的控制器中。

在图像采集过程中共采集 1 200 幅玉米冠下行间图像, 采集的图像分辨率为 1 280 像素  $\times$  720 像素。对于深度学习模型, 样本标注的精确度越高, CNN 在训练过程中更能提取到准确、丰富的特征信息, 从而提升其识别、分类和预测等能力。因此, 一个标注准确、高相关性的数据集对本文模型算法的训练和测试准确性有着重要的作用<sup>[29]</sup>。对采集的图像进行筛选, 去除运动过程导致的部分模糊图像, 最终筛选出 500 幅清晰的田间冠下行间图像进行目

标边界的标注, 保证深度学习模型输入训练样本的图像质量。

在玉米作物行图像预处理方面, 首先使用 Labelme 软件进行标注, 为了扩大样本量, 提高训练样本复杂程度, 提高训练检测模型泛化能力, 采用 imgaug 库对图像进行增强, imgaug 是一个用于机器学习试验中图像增强的库。支持以随机顺序和组合方式执行多种图像增强方式。本文使用像素随机添加、高斯模糊、运动模糊、锐化处理、裁剪缩放、对比度增强等方法的随机组合扩充样本库, 数据增强效果如图 4 所示。图像库扩展为 2 000 幅图像, 原始玉米作物行图像与经过增强的图像组成训练图像数据库。



图 4 数据增强后的数据集图像示例

Fig. 4 Example of data-enhanced dataset image

## 2 玉米冠下作物行路径提取方法

### 2.1 特征融合网络改进

Mask R-CNN<sup>[30]</sup> 是一种经典的图像分割算法, 对图像中的目标物体进行识别并对目标区域轮廓进行分割, 并可提取相关像素进行面积计算, 该模型适用于背景干扰因素小、有明显差异的情况, 对具有复杂信息且包含相似物体的行间图像中边界模糊、形状各异的目标, 预测结果易受到干扰, 丢失部分细节信息。

在多层卷积神经网络中, 浅层的特征通常更能代表作物区域及叶片的边缘形态, 对于作物行区域像素分类和叶片像素面积计算至关重要。采用 Simple-PAN<sup>[31]</sup>, 在保证精度提升的同时, 控制了参数的增加量, 通过增加自底向上的路径增强模块和特征融合操作模块, 丰富底层特征的提取层次。图 5 为改进的 Mask R-CNN 模型结构。

### 2.2 导航线拟合方法

#### 2.2.1 两侧区域分界线

在确定机器人前进方向导航线时, 首先基于作物行两侧区域的识别分割线进行拟合处理, 以生成作物行两侧区域分界线。本文采用加权平均法对作物行两侧作物区域的边界线坐标信息进行处理, 解析坐标数据, 对相应像素行上的左右边缘信息点的像素坐标进行加权平均。

在数据采集期间, 相机固定在机器人头部中心位置。如图 6a 所示, 以采集的图像左上角为坐标原点, 沿图像向右为 X 轴正方向, 沿图像向下为图像 Y 轴正方向。在图像坐标系中, 如图 6 中的点 T, 为简便计算, 取图像底边中心坐标  $(x_{L,s}, y_{L,s})$  为机器人当前位置点, 其中

$$\begin{cases} x_{L,s} = \frac{w_{\text{img}}}{2} \\ y_{L,s} = h_{\text{img}} \end{cases} \quad (1)$$

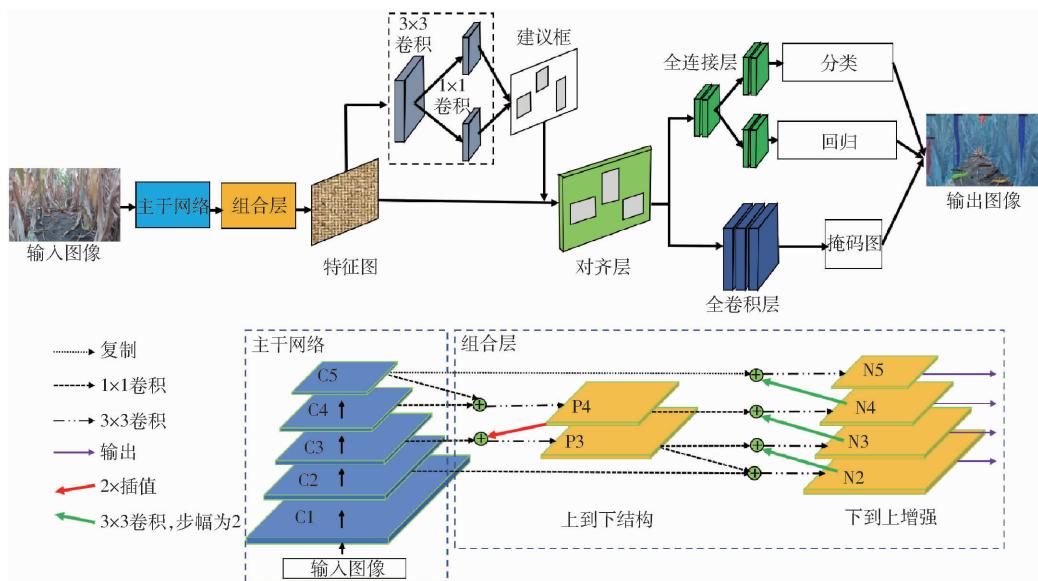


图 5 改进的 Mask R-CNN 模型结构

Fig. 5 Improved Mask R-CNN model structure

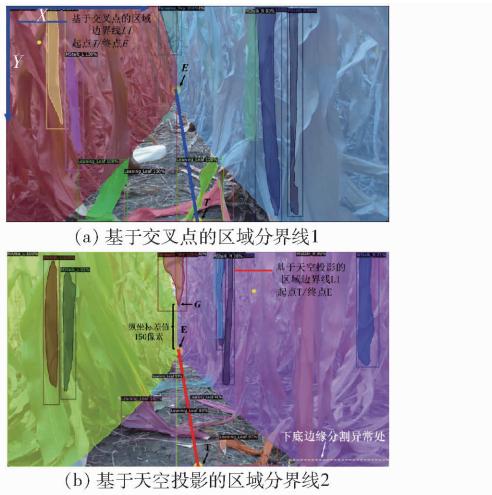


图 6 基于交叉点和天空投影的区域分界线

Fig. 6 Regional boundaries based on intersections and sky projections

式中  $w_{\text{img}}$  —— 图像宽, 为 1 280 像素

$h_{\text{img}}$  —— 图像高, 为 720 像素

考虑到田间冠层下环境复杂, 作物行两侧玉米植株下垂的叶片会对作物行间机器人行走产生影响, 为减少机器人与两侧叶片的直接接触导致的行走效率低问题, 机器人前进过程中要对作物行间的下垂叶片进行避让。采用机器人位置与导航线终点连接的直线作为左右两侧植株下垂叶片的分界线, 在分界线基础上对左右区域的行间叶片进行划分。取机器人所在位置作为区域分界线的起点, 对于分界线的终点, 基于上节作物行间的图像分割信息, 当图像 MArea\_L 和 MArea\_R 标签存在区域交叉点时, 如图 6a 所示, 对图像红色作物行左侧区域 MArea\_L 标签和蓝色作物行右侧区域的 MArea\_R 标签的所有边界点坐标信息进行处理, 找出两个区域边缘线

交叉点坐标中  $y$  最大的点作为区域分界线的终点, 坐标设为  $(x_{L,e}, y_{L,e})$ , 以黄色导航起点和导航终点画蓝色直线作为作物行两侧区域边界线。

在拟合区域分界线时, 需要分界线的起点和终点坐标信息。在对测试图像的区域分界线拟合情况进行梳理时, 发现大部分测试图像都成功拟合了区域分界线, 说明这些图像中存在作物两侧区域的交叉点及分界线终点。对于测试图像不存在作物两侧区域的交叉点及分界线终点的情况, 图像无法拟合出区域分界线。取区域分界线终点为点  $E$ , 天空分割区域的最低点为点  $G$ , 本文随机选取 8 幅拟合出区域分界线的测试图像进行分析, 分析图像分割模型得到的点  $E$  与点  $G$  之间横纵坐标的平均差值。表 1 为相应的点  $E$  和点  $G$  的坐标关系。

表 1 点  $E$ 、 $G$  的坐标偏差Tab. 1 Deviation of coordinates of points  $E$  and  $G$ 

图序号	横坐标			纵坐标		
	点 $E$	点 $G$	横坐标差	点 $E$	点 $G$	纵坐标差
1	567	562	5	281	155	126
2	613	615	-2	322	172	150
3	602	604	-2	301	199	102
4	638	640	-2	324	198	126
5	549	552	-3	274	116	158
6	498	492	6	356	126	230
7	623	622	1	310	124	186
8	568	564	4	280	155	125
坐标平均差值				0.875		150.38

由表 1 可知, 对于横坐标, 点  $E$  与点  $G$  的最大差值绝对值为 6 像素, 最小差值绝对值为 1 像素, 横

坐标平均差值为 0.875 像素；对于纵坐标，点 E 与 G 的最大差值绝对值为 230 像素，最小差值绝对值为 102 像素，纵坐标平均差值为 150.38 像素。因此，在图像中点 E 与点 G 存在位置相关关系，两点在横坐标上几乎相同，在纵坐标上相差接近 150 像素。当测试图像不存在作物两侧区域的交叉点及分界线终点时，本文由天空分割区域的最低点 G 推算区域分界线终点 E 的位置。选取以点 G 为基准点，为简化计算，采用横坐标与点 G 相同，纵坐标增加 150 像素的点作为导航终点 E，如图 6b 所示，以黄色导航起点和导航终点画红色直线作为作物行两侧区域边界线。

## 2.2.2 基于加权平均的导航路径算法

为了实现农业机器人的自主导航，保持正确的前进路线十分重要。冠下作物行中，下垂的叶片分布于左右区域的两侧，倾斜的长叶片会侵占机器人的行走区域，导致冠下作物行机器人前进效率下降。因此，通过区域分界线划分两侧作业区域，结合 MArea\_L 和 MArea\_R 区域的边缘线，通过计算倾斜叶片 Leaning\_Leaf 标签的像素数量，以此表示叶片面积，结合区域分界线，得到图像中可通行区域中区域分界线两侧的叶片面积。

在图 7 中，Leaning\_Leaf 的全部像素数量以 Mask\_Area( $M_A$ ) 表示，计算区域分界线  $L_i$  (蓝线、红线) 两侧 Leaning\_Leaf 的像素点数量，取  $L_i$  左侧像素点数量为 Mask\_AreaL( $M_L$ )，取  $L_i$  右侧像素点数量为 Mask\_AreaR( $M_R$ )。通过两侧 Leaning\_Leaf 像素点占比不同来拟合导航参考线，拟合导航参考线的

点坐标表示为  $(x_{i,m}, y_{i,m})$ ，设定左侧作物区域边界线点坐标为  $(x_{i,L}, y_{i,L})$ ，右侧作物区域边界线坐标为  $(x_{i,R}, y_{i,R})$ ，根据两侧区域坐标拟合导航线的点坐标。图 7 中，以黄线上白色圆圈表示拟合中点坐标，第  $i$  次拟合点坐标的公式为

$$\begin{cases} x_{i,m} = I_1 x_{i,L} + I_2 x_{i,R} \\ y_{i,m} = K_1 y_{i,L} + K_2 y_{i,R} \\ I_1 = \frac{M_R}{M_A} \\ I_2 = \frac{M_L}{M_A} \end{cases} \quad (2)$$

式中  $x_{i,m}$  —— 第  $i$  个拟合点横坐标，像素  
 $y_{i,m}$  —— 第  $i$  个拟合点纵坐标，像素  
 $I_1, I_2, K_1, K_2$  —— 权值系数， $K_1 = K_2 = 0.5$

首先保存所有拟合点的坐标，然后将横坐标作为自变量，纵坐标作为因变量。最后使用绘图程序，在原始图像上绘制直线，连接所有拟合点作为提取出的导航参考线。由于部分靠近图像下底边缘分割区域存在异常情况，如图 6b 中黄色虚线边框所示，为避免边缘分割不精确对导航参考线拟合产生的不利影响，去除图像邻近下底边缘的 20 像素，即去除图像纵坐标 700 ~ 720 像素范围的点，取  $y_{i,m}$  为 700 像素时的点坐标  $(x_{i,m}, 700)$  作为导航起点。作为对比，图 7a、7c、7e 中展示了当权值系数  $I_1, I_2$  为 0.5，即只对左右区域边界线坐标进行平均而不考虑左右区域叶片面积差异，以此拟合导航路径参考线。图 7b、7d、7f 展示了基于加权平均值法针对横坐标

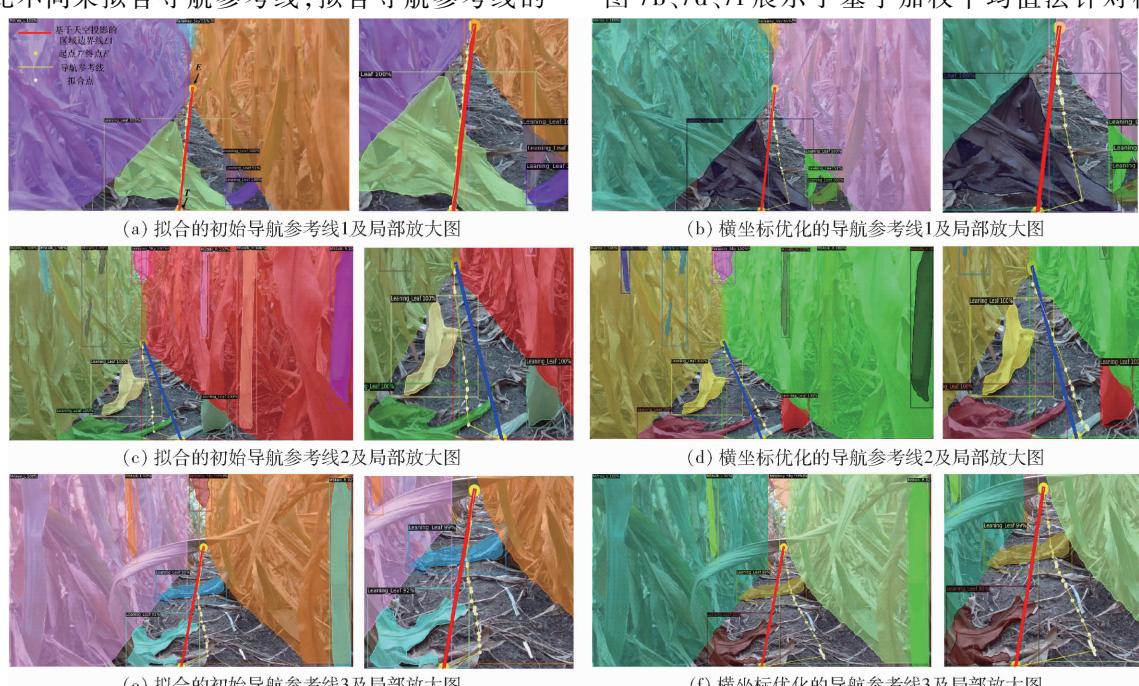


图 7 针对横坐标的基于加权平均值法拟合的导航路径

Fig. 7 Navigation paths fitted by weighted average-based method for transverse coordinates

拟合的田间冠下作物行导航路径拟合参考线。

如图 7 所示,当区域两侧的下垂叶片像素分布不均时,基于加权平均值法拟合的导航路径具备对区域分界线两侧叶片面积的计算能力,通过计算两侧区域分布障碍物面积,使导航参考线发生一定程度的偏折,此时导航参考线具备一定的避障能力。因此,本文提出的改进加权平均值法拟合导航路径信息提取方法具有较好的适应性,能够准确地生成结合叶片信息的田间冠下拟合导航路径,避免机器人行进过程中与叶片的接触,有利于增加通行效率。

由图 7a、7e 与图 7b、7f 的对比可知,由于导航参考线偏折引起导航路径的起点与机器人当前位置的横向距离也发生变化,导致在机器人沿导航线行走的前段可能会出现更大横向偏移,对机器人通行效率产生影响,因此本文在以上基于加权平均值法的基础上进一步优化。考虑到实际机器人当前位置与导航线起始点的偏移距离,对导航线起始点进行纵向方位的调整,优化机器人当前位置与导航线起始点的纵向坐标偏差,从而间接优化起始阶段机器人行进过程中偏转角度,提高机器人行走顺滑性。

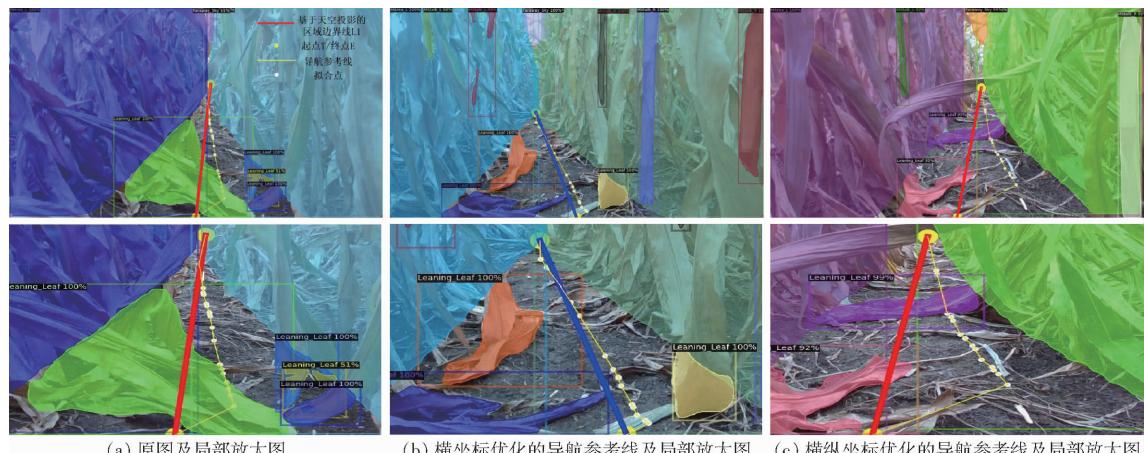


图 8 优化的导航路径

Fig. 8 Optimized navigation paths

当机器人初始位置不处于作物行中心附近时,若依旧按照区域分界线  $L_1$  计算两侧 Leaning\_Leaf 标签的像素点数量,则拟合的导航参考线与作物区域过近或交叉,此时拟合的导航参考线不满足机器人通行条件,故区域分界线  $L_1$  不适合作为 Leaning\_Leaf 像素点两侧分割的参考线。

本文针对以上情况,如图 9 所示,设计了图像横向辅助线  $K$ (橘黄色),其始末点坐标分别为  $(0, 700)$ 、 $(1280, 720)$ 。取  $K$  与  $M_L$  及  $M_R$  作物区域边界线的交点分别为点  $M$ 、点  $N$ ,辅助线  $K$  与区域边界线  $L_1$  的交点为  $V$ 。计算线段  $MV$ 、 $NV$  的长度分别占线段  $MN$  长度的比例  $S$ ,公式为

导航线起始点位置  $(x_{i,m}, 700)$  与机器人所在位置  $(x_{L,s}, y_{L,s})$  的横向距离  $E_i$  为

$$E_i = \text{abs} |(x_i - x_{L,s})| \quad (3)$$

式中 abs——绝对值函数

其中,  $x_{L,s}$  为 640 像素,  $x_{i,m}$  为  $y_{i,m} = 700$  像素时的  $x$  坐标。设定线性拟合函数  $F$  为

$$F = aE_i + b \quad (4)$$

式中  $a, b$ ——常数

将优化的导航线起点纵坐标  $y_{i,m}$  范围限制为 600 ~ 720 像素,即当横向距离  $E_0$  为 0 时,将  $F = 720$  像素代入式(4);当横向距离最大,即  $E_0 = 300$  像素时,把  $F = 600$  像素代入式(4),得到参数为:  $a = -0.4, b = 720$ 。

式(2)中  $y_{i,m}$  有了范围限制,即当  $y_{i,m} = 700$  像素时,计算  $D_i$ 。当  $aE_i < -20$  时,赋值式(4)中  $F = 700$  像素,保证起始阶段机器人行进过程中适当的转弯角度;当  $aE_i < -120$  时,赋值式(4)中  $F = 600$  像素,保证机器人行进过程中与作物区域边缘保持适当距离。基于图 7b、7d、7f 进一步优化的导航路径如图 8 所示。

$$S = \frac{R_{MV}}{R_{MN}} \quad (5)$$

式中  $R_{MV}$ ——线段  $MV$  长度

$R_{MN}$ ——线段  $MN$  长度

此处设定阈值:若  $0 \leq S \leq 0.1$ ,则认为区域边界线  $L_1$  偏左;若  $0.9 \leq S \leq 1$ ,则认为区域边界线  $L_1$  偏右。计算线段  $MN$  的中点  $P$  作为新区域边界线  $L_2$  的起点,连接起点  $P$  与终点  $E$  作为新区域边界线  $L_2$ (图 9 中浅蓝线)。针对横向坐标拟合的导航参考线以区域边界线  $L_2$  计算两侧 Leaning\_Leaf 标签的像素点数量,而针对纵坐标拟合的导航参考线仍以区域边界线  $L_1$  为基准,计算机器人当前位置与导航线起始点  $T$  的偏移距离。图 9 分别展示了权值系数

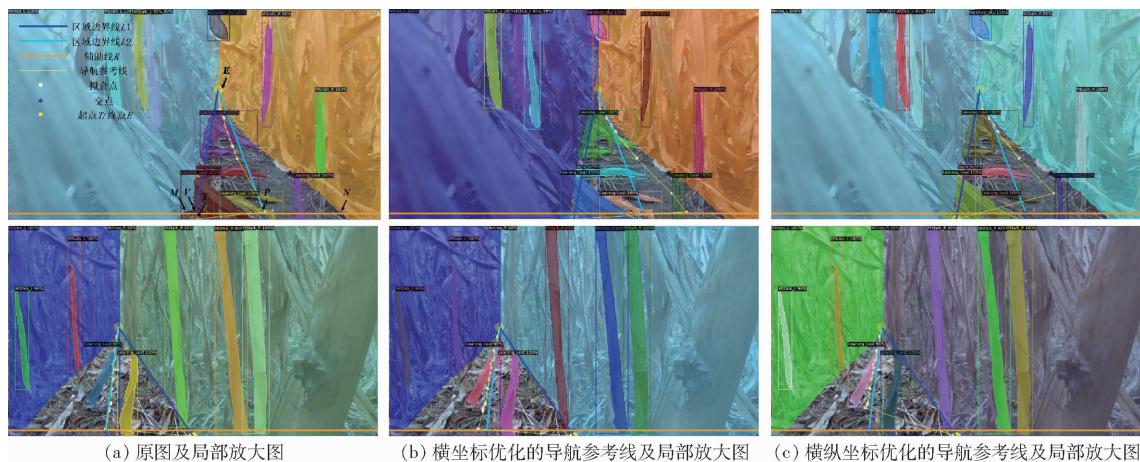


图 9 机器人异常初始位置的优化导航路径

Fig. 9 Optimized navigation paths for robot abnormal initial positions

$I_1, I_2$  为 0.5 时导航路径拟合参考线、针对横向坐标拟合的田间冠下作物行导航路径拟合参考线及横纵坐标优化的导航参考线。

### 2.2.3 高斯过程回归

由于拟合的导航参考线存在较多转折,不利于机器人在前进过程中作为导航线使用。本文采用高斯过程方法对导航线进行拟合。

高斯过程回归(GPR)是一种基于严格统计学原理的机器学习训练方法,可以用于解决回归和分类问题<sup>[32]</sup>。由于不依赖具体函数形式,可以适应各种复杂的数据分布和关系,用来描述数据之间的关系和不确定性。高斯过程模型的优势主要体现在处理非线性和小数据问题上,回归的特性主要取决于均值函数和协方差函数。

GPR 随机变量  $f(x)$  由其均值函数  $m(x)$  和协方差函数  $k(x, x')$  唯一确定,高斯过程定义为

$$\begin{cases} f(x) = \text{GPR}(m(x), k(x, x')) \\ m(x) = E(f(x)) \\ k(x, x') = E(f(x) - m(x)(f(x') - m(x'))) \end{cases} \quad (6)$$

式中  $x, x'$  ——输入样本

$E$  ——均值算子

$\text{GPR}(\cdot)$  ——函数空间高斯过程分布

对于高斯过程训练,考虑到一般的函数观测值都含噪声,所以加入噪声后的观测值  $y$  为

$$y = f(x) + \varepsilon \quad (7)$$

式中  $\varepsilon$  ——噪声,方差为  $\sigma_n^2$

噪声为 0 表示高斯过程回归对原样本完全插值,  $\sigma_n^2$  能够防止回归出现过拟合。

由式(7)可得  $y$  服从  $N(0, K_f(x, x') + \sigma_n^2 I_n)$  先验分布,其中  $K_f(x, x')$  为输入样本  $x$  的协方差矩阵。由此可以得到任意一点处的高斯过程训练集,观测集  $y$  与预测集  $y^*$  的联合先验分布可以表示为

$$\begin{bmatrix} y \\ y^* \end{bmatrix} \sim N\left(0, \begin{bmatrix} K_f(x, x) + \sigma_n^2 I_n & K_f(x, x^*) \\ K_f(x, x^*)^T & K_f(x^*, x^*) \end{bmatrix}\right) \quad (8)$$

式中  $x^*$  ——输入样本预测值

$K_f(x, x)$  —— $x$  与  $x$  之间的协方差矩阵

$K_f(x, x^*)$  —— $x$  与  $x^*$  之间的协方差矩阵

$K_f(x^*, x^*)$  —— $x^*$  与  $x^*$  之间的协方差矩阵

$I_n$  —— $N \times N$  维单位矩阵

根据式(6),可以得到后验分布  $p(y|y, x, x^*)$

$$p(y|y, x, x^*) = N(y|y^*, \text{cov}(y^*)) \quad (9)$$

式中  $\text{cov}(y^*)$  —— $y^*$  的协方差

$y^*$  ——预测均值

预测模型不确定性由预测协方差  $\text{cov}(y^*)$  反映,具体为

$$\begin{cases} y^* = K_f(x, x^*)^T [K_f(x, x) + \sigma_n^2 I_n]^{-1} y \\ \text{cov}(y^*) = K_f(x^*, x^*) - K_f(x, x^*)^T \cdot \\ \quad (K_f(x, x) + \sigma_n^2 I_n)^{-1} K_f(x, x^*) \end{cases} \quad (10)$$

最优超参数可通过共轭梯度法求得训练数据对数似然函数的最大值。获取最优超参数后,计算得到协方差矩阵。将协方差矩阵代入式(9),得到最优预测值以及方差。

针对传统 GPR 模型针对直线段拟合结果不理想、预测效果差等问题,本文采用 DotProduct 线性核对曲线拟合进行优化的方法,解决传统 GPR 模型对于直线拟合效果差的问题。通过添加 DotProduct 线性核,使模型更好地拟合直线段。 $\text{sigma\_0}$  是 DotProduct 核的 1 个参数,控制了线性核的偏置项。在 DotProduct 核中,若  $\text{sigma\_0}$  的取值比较大,那么线性核的偏置项会更大,这可能会导致模型更加关注数据的线性趋势。反之,如果  $\text{sigma\_0}$  的值比较小,线性核的偏置项会更小,使高斯过程回归模型拟

合过程中对数据的非线性特征提取更加有效。常量核 C、高斯核 RBF 与白噪声核 WhiteKernel 设置为默认值, 分别为 0.1、1.0 和 1.0。为确保模型的性能较好, 采用交叉验证方法,  $\sigma_0$  的值设置为 5.0。

### 3 试验结果与分析

#### 3.1 试验平台

试验选用的处理器为 Intel (R) Core (TM) i7 - 12900K, 内存为 16 GB, 在装有 NVIDIA GeForceRTX1050ti GPU 的 Ubuntu 操作系统的计算机上进行。试验中所有程序基于 Python 3.7 语言, 在 PyTorch 深度学习框架下实现。

#### 3.2 模型训练与性能对比

为了比较模型性能, 基于玉米冠下数据集分别训练 ResNeXt101\_FPN\_Mask\_R-CNN 和 ResNeXt101\_Simple-PAN\_Mask\_R-CNN 网络模型, 损失值曲线和 Mask R-CNN 准确率曲线如图 10 所示。结果表明, Simple-PAN 对模型的改进有显著作用, 减少了总体损失, 提高了分割网络准确率。采用 Simple-PAN 的 Mask R-CNN 网络模型总体损失值更低, 总体训练损失值减小 0.05, 准确率更高, 提高 0.014。这说明 Simple-PAN 对 Mask R-CNN 模型有较好的改进效果。

利用训练好的各个网络模型分割区域, 并进行可视化检测效果对比, 如图 11 所示。结合 ResNeXt101\_Simple-PAN 的网络模型对目标物的识别和分割优于 Mask R-CNN。例如, 原始图像分割网络 Mask R-CNN 遗漏了部分叶片目标, 错误地将整片叶片分割为多个叶片区域, 对叶片边缘分割也不佳, 识别面积小于叶片实际面积。识别精度下降会影响导航线的拟合效果, 与原始网络分割轮廓

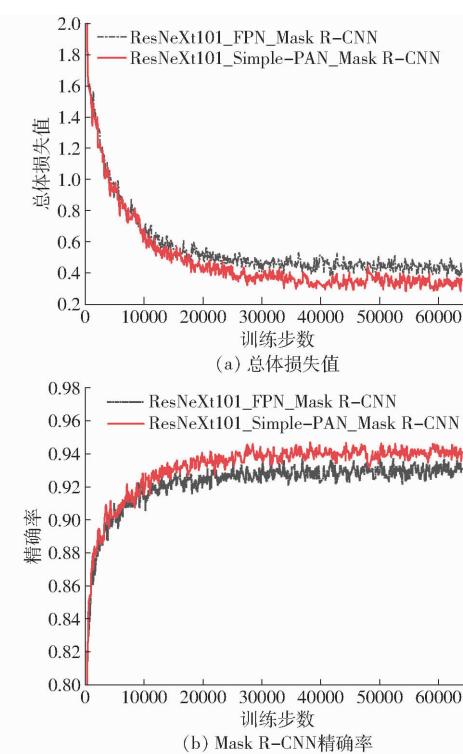


图 10 模型训练结果曲线

Fig. 10 Model training result curves

不同, 改进网络分割轮廓更加明确。

#### 3.3 导航线提取结果评价

随机选取 20 组图像结果进行试验结果对比, 部分图像样本的导航线提取效果如图 12 所示。经过检测试验, 结合 GPR 优化的 ResNeXt101\_Simple-PAN\_Mask\_R-CNN 分割网络从获取图像到完成路径导航提取, 单帧图像平均耗时为 227 ms, 基本满足作物行冠下机器人实时性处理要求。

获得拟合导航路径后, 利用 ImageJ 软件计算像素误差。取图 12 中的拟合点作为导航线提取结果评价图像的关键点, 如图 12 中黄线上白色圆圈所

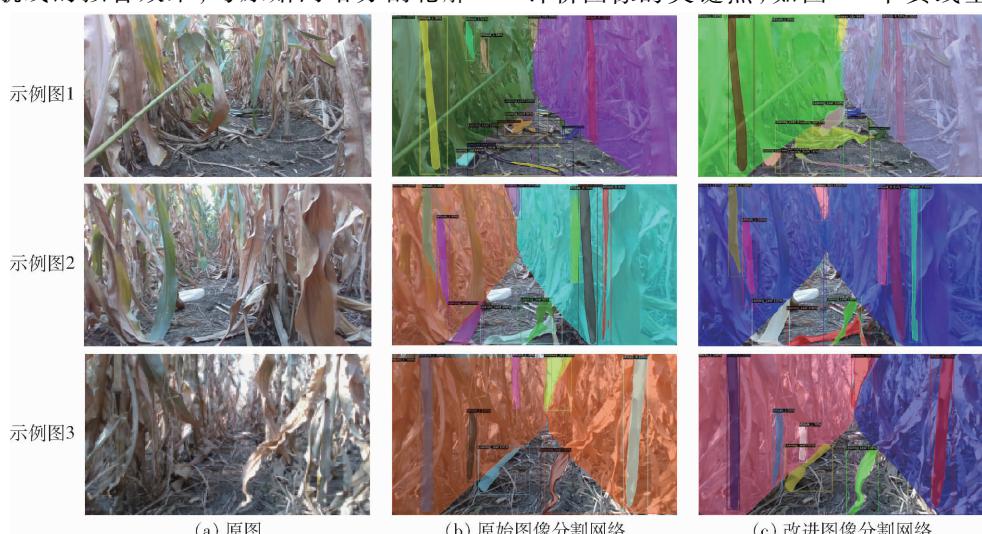


图 11 玉米冠下作物行图像分割结果

Fig. 11 Target segmentation of crop rows under corn canopy

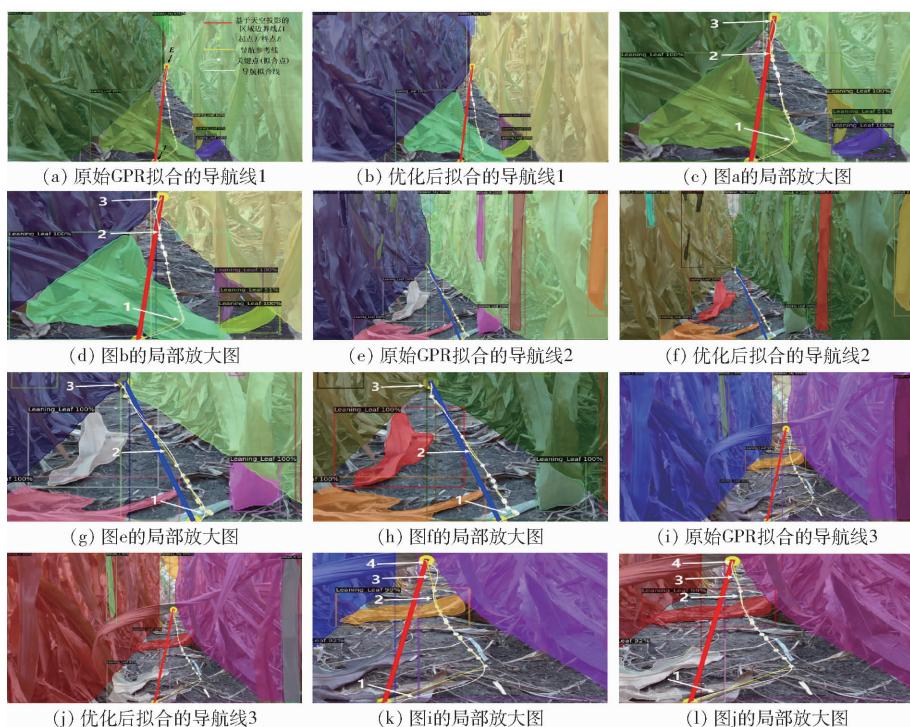


图 12 基于高斯过程回归拟合的导航线

Fig. 12 Navigational lines based on Gaussian fitted regression

示。对每幅图像上关键点的横坐标与相同纵坐标的拟合导航路径点的横坐标差, 取绝对值得到像素误差。计算公式为

$$\Delta_d = |D_i - d_i| \quad (11)$$

式中  $\Delta_d$ ——像素误差

$D_i$ ——导航线参考线关键点横坐标

$d_i$ ——拟合的导航线上相同纵坐标路径点横坐标

由图 12d、12h、12l 与图 12c、12g、12k 对比可知, 当机器人由当前位置到导航路径的大偏角转折处, 相比于原始 GPR 算法, 优化后的图 12d、12h、12l 在标线 1 处与转折处的关键点拟合精度更高, 具有更顺滑的行走方向, 路径更加符合机器人前进方向的行走逻辑。在标线 2 处的导航路径直线拟合段中, 图 12d、12h、12l 对于直线段的拟合效果更好, 路径与导航参考线更加接近, 说明添加的 DotProduct 线性核使模型更好地拟合了直线段。在图 12k、12l 的标线 3 处, GPR 优化算法拟合路径距离更短。最后, 如图 12d、12h 的标线 3, 改进后的算法对于终点的拟合精度更好。

表 2 为两种 GPR 算法相应的导航线拟合偏差结果。由表 2 可知, 原始算法的导航线偏差基本处于 0~13 像素之间, 而优化方法的导航线偏差均得到了有效改善, 拟合的导航线更接近导航参考线。由测试的 3 幅图像可知, 原始 GPR 算法的导航线平均偏差分别为 1.53、4.2、1.35 像素, 而优化后导航

表 2 导航线拟合偏差结果

Tab. 2 Navigation line fitting deviation result

关键点 序号	导航线 1		导航线 2		导航线 3		像素
	原始 GPR 拟合线	优化后 拟合线	原始 GPR 拟合线	优化后 拟合线	原始 GPR 拟合线	优化后 拟合线	
1	0	0	0	0	0	0	0
2	2	1	13	4	2	1	1
3	7	1	7	1	1	1	1
4	1	0	5	1	2	1	1
5	2	1	5	0	1	0	0
6	1	0	4	0	3	1	1
7	1	0	1	2	0	0	0
8	2	2	3	1	1	0	0
9	1	1	2	0	1	0	0
10	1	0	1	1	0	1	1
11	0	0	2	0	0	2	2
12	0	1	2	0	2	2	2
13	1	0	2	2	2	2	2
14	0	0	7	1	1	0	0
15	0	1	9	0	1	1	1
16	1	0			3	0	0
17	0	1			3	0	0
18	2	0					0
19	8	1					0

线平均偏差显著变低, 分别为 0.53、0.87、0.71 像素。

综上所述, 本文提出的导航路径拟合方法导

航线平均偏差更低,可以有效地识别导航路径,在复杂环境下具备良好的鲁棒性和检测精度,导航线精度满足路径导航任务对准确性和实时性的需求。

## 4 结论

(1) 针对玉米生长中后期病虫害冠下监测对行自主行走的需求,提出一种基于深度学习和高斯过程回归的玉米冠层下导航路径提取方法。在 Mask R-CNN 模型的基础上,对特征融合网络改进以充分利用浅层的特征,采用简化路径增强特征金字塔网络,通过增加自底向上的路径增强模块和特征融合操作模块,总体训练损失值减小 0.05,准确率提高 0.014。

(2) 基于作物行分割信息,对导航路径进行拟

合。首先通过作物区域边界线的坐标信息,基于加权平均值构建作物区域拟合导航线,结合作物行的叶片像素数据分布及面积信息,优化导航线的横向偏差,实现更好的避障;结合机器人位置与导航参考线出发点的距离信息,优化导航参考线偏转角度,更顺滑的转折有利于机器人行进效率。

(3) 基于导航参考线,引入高斯过程回归方法对导航线进行曲线拟合,进而得到机器人前进导航线。对复杂环境下采集的图像进行试验,基于改进 GPR 算法拟合的导航线平均偏差为 0.7 像素,处理 1 帧分辨率为 1 280 像素  $\times$  720 像素的图像平均耗时为 227 ms。结果表明,本文提出的路径提取方法具有较好的准确性和实时性,可为玉米冠下作物行路径导航提供参考,为玉米生长中后期冠下信息监测与自主作业等任务提供导航方案。

## 参 考 文 献

- [1] 陈学庚,温浩军,张伟荣,等.农业机械与信息技术融合发展现状与方向[J].智慧农业(中英文),2020,2(4):1–16.  
CHEN Xuegeng, WEN Haojun, ZHANG Weirong, et al. Advances and progress of agricultural machinery and sensing technology fusion[J]. Smart Agriculture, 2020, 2(4):1–16. (in Chinese)
- [2] 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.  
ZHANG Man, JI Yuhan, LI Shichao, et al. Research progress of agricultural machinery navigation technology[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(4):1–18. (in Chinese)
- [3] 李志强.履带式玉米植保机械自动导航与驱动控制方法研究[D].合肥:安徽农业大学,2023.  
LI Zhiqiang. Research on automatic navigation and drive control method for tracked maize plant protection machinery [D]. Hefei: Anhui Agriculture University, 2023. (in Chinese)
- [4] 赵岩,陈学庚,温浩军.新疆兵团精准农业发展与北斗卫星导航技术的应用[J].石河子大学学报(自然科学版),2018,36(4):397–404.  
ZHAO Yan, CHEN Xuegeng, WEN Haojun. Application of the development of precision agriculture and the China's Beidou satellite navigation system in agricultural production in the Xinjiang Production and Construction Corps[J]. Journal of Shihezi University(Natural Science Edition), 2018, 36(4):397–404. (in Chinese)
- [5] 杨文超,何进,周靖凯,等.基于机器视觉和北斗定位的小麦变量喷雾系统研究[J].农业机械学报,2022,53(7):150–161.  
YANG Wenchao, HE Jin, ZHOU Jingkai, et al. Design of wheat variable spray system based on machine vision and Beidou positioning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(7):150–161. (in Chinese)
- [6] 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.  
MENG Zhijun, WANG Hao, FU Weiqiang, et al. Research status and prospects of agricultural machinery autonomous driving [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(10):1–24. (in Chinese)
- [7] LIU Xiangnan, QI Jiangtao, ZHANG Weirong, et al. Recognition method of maize crop rows at the seedling stage based on MS-ERFNet model[J]. Computers and Electronics in Agriculture, 2023, 211: 107964.
- [8] 翟长远,张焱龙,邹伟,等.基于农药喷施溯源的精准变量喷药监控系统设计与试验[J].农业机械学报,2024,55(2):160–169.  
Zhai Changyuan, Zhang Yanlong, Zou Wei, et al. Design and test of precision variable-rate spray monitoring and control system based on pesticide spraying traceability[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(2):160–169. (in Chinese)
- [9] BONADIES S, GADSSEN S. An overview of autonomous crop row navigation strategies for unmanned ground vehicles[J]. Engineering in Agriculture, Environment and Food, 2019, 12(1): 24–31.
- [10] POTENA C, KHANNA R, NIETO J, et al. AgriColMap: aerial-ground collaborative 3D mapping for precision farming[J]. IEEE Robotics and Automation Letters, 2019, 4(2): 1085–1092.
- [11] LI M, IMOU K, WAKABAYASHI K, et al. Review of research on agricultural vehicle autonomous guidance[J]. International Journal of Agricultural and Biological Engineering, 2009, 2(3): 1–16.
- [12] NIEWOLKA A. Mobile robot 6-D localization using 3-D Gaussian mixture maps in GPS-denied environments[J]. IEEE Intelligent Systems, 2022, 37(1): 79–88.

- [13] BENET B, LENAIN R, ROUSSEAU V. Development of a sensor fusion method for crop row tracking operations [J]. Advances in Animal Biosciences, 2017, 8(2): 583–589.
- [14] 周海燕, 杨悦, 刘阳春, 等. 基于激光雷达的作物收获导航线实时提取方法研究 [J]. 农业机械学报, 2023, 54(增刊1): 9–17.  
ZHOU Haiyan, YANG Yue, LIU Yangchun, et al. Real-time extraction of navigation line based on LiDAR [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(Supp. 1): 9–17. (in Chinese)
- [15] LI Y, IBANEZ-GUZMAN J. LiDAR for autonomous driving: the principles, challenges, and trends for automotive LiDAR and perception systems [J]. IEEE Signal Processing Magazine, 2020, 37(4): 50–61.
- [16] 刘路, 潘艳娟, 陈志健, 等. 高遮挡环境下玉米植保机器人作物行间导航研究 [J]. 农业机械学报, 2020, 51(10): 11–17.  
LIU Lu, PAN Yanjuan, CHEN Zhijian, et al. Inter-rows navigation method for corn crop protection vehicles under high occlusion environment [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(10): 11–17. (in Chinese)
- [17] 范永祥, 冯仲科, 申朝永, 等. 基于改进 LOAM 的森林样地调查系统设计与试验 [J]. 农业机械学报, 2022, 53(7): 291–300.  
FAN Yongxiang, FENG Zhongke, SHEN Chaoyong, et al. Design and experiment of forest plot survey system based on improved LOAM [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(7): 291–300. (in Chinese)
- [18] 刘庆运, 杨华阳, 刘涛, 等. 基于激光雷达与深度相机融合的 SLAM 算法 [J]. 农业机械学报, 2023, 54(11): 29–38.  
LIU Qingyun, YANG Huayang, LIU Tao, et al. SLAM algorithm based on fusion of LiDAR and depth camera [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(11): 29–38. (in Chinese)
- [19] LI N, ZHANG X G, ZHANG G L, et al. Review of machine-vision-based plant detection technologies for robotic weeding [C] // 2019 IEEE International Conference on Robotics and Biomimetics (ROBIO), 2019: 2370–2377.
- [20] LI S, ZHANG Z B, DU F, et al. A new automatic real-time crop row recognition based on SoC – FPGA [J]. IEEE Access, 2020, 8: 37440–37452.
- [21] 杨洋, 张博立, 查家翼, 等. 玉米行间导航线实时提取 [J]. 农业工程学报, 2020, 36(12): 162–171.  
YANG Yang, ZHANG Boli, ZHA Jiayi, et al. Real-time extraction of navigation line between corn rows [J]. Transactions of the CSAE, 2020, 36(12): 162–171. (in Chinese)
- [22] 王侨, 孟志军, 付卫强, 等. 基于机器视觉的玉米苗期多条作物行线检测算法 [J]. 农业机械学报, 2021, 52(4): 208–220.  
WANG Qiao, MENG Zhijun, FU Weiqiang, et al. Detection algorithm of multiple crop row lines based on machine vision in maize seedling stage [J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(4): 208–220. (in Chinese)
- [23] ZHANG W R, CHEN X G, QI J T. Automatic instance segmentation of orchard canopy in unmanned aerial vehicle imagery using deep learning [J]. Frontiers in Plant Science, 2022, 13: 1041791.
- [24] 宫金良, 王祥祥, 张彦斐, 等. 基于边缘检测和区域定位的玉米根茎导航线提取方法 [J]. 农业机械学报, 2020, 51(10): 26–33.  
GONG Jinliang, WANG Xiangxiang, ZHANG Yanfei, et al. Extraction method of corn rhizome navigation lines based on edge detection and area localization [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(10): 26–33. (in Chinese)
- [25] 宫金良, 孙科, 张彦斐, 等. 基于梯度下降和角点检测的玉米根茎定位导航线提取方法 [J]. 农业工程学报, 2022, 38(13): 177–183.  
GONG Jinliang, SUN Ke, ZHANG Yanfei, et al. Extracting navigation line for rhizome location using gradient descent and corner detection [J]. Transactions of the CSAE, 2022, 38(13): 177–183. (in Chinese)
- [26] GAI J Y, XIANG L R, TANG L. Using a depth camera for crop row detection and mapping for under-canopy navigation of agricultural robotic vehicle [J]. Computers and Electronics in Agriculture, 2021, 188: 106301.
- [27] LIU L, MEI T, NIU R X, et al. RBF-based monocular vision navigation for small vehicles in narrow space below maize canopy [J]. Applied Sciences, 2016, 6(6): 182.
- [28] 张良安, 唐锴, 赵永杰, 等. 四足激光除草机器人腿部结构参数优化 [J]. 农业工程学报, 2020, 36(2): 7–15.  
ZHANG Liang'an, TANG Kai, ZHAO Yongjie, et al. Optimization of leg structure parameter of quadruped laser weeding robot [J]. Transactions of the CSAE, 2020, 36(2): 7–15. (in Chinese)
- [29] ARSENOVIC M, KARANOVIC M, SLADOJEVIC S, et al. Solving current limitations of deep learning based approaches for plant disease detection [J]. Symmetry, 2019, 11(7): ID 939.
- [30] HE K M, GKIOXARI G, DOLLAR P, et al. Mask R – CNN [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 99: 2961–2969.
- [31] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 8759–8768.
- [32] RASMUSSEN C E, WILLIMAS C K I. Gaussian processes for machine learning [M]. MIT Press, 2005.