

基于无人机 RGB 图像与改进 YOLO v5s 的宿根蔗缺苗定位方法

李尚平^{1,2} 郑创锐^{1,2} 文春明^{1,2} 李凯华^{1,2}

(1. 广西民族大学电子信息学院, 南宁 530006;

2. 广西高校智慧无人系统与智能装备重点实验室, 南宁 530006)

摘要: 针对预切种式双芽蔗段横向补种机缺少整体的缺苗数据, 导致补种效率不高等问题, 提出了一种基于无人机 RGB 图像的宿根蔗缺苗定位方法。首先, 通过无人机快速采集实际田间宿根蔗幼苗的高分辨率图像, 将航拍大图 (分辨率为 5 472 像素 × 3 648 像素) 切分成多幅子图并进行数据增强, 从而构建宿根蔗幼苗数据集; 其次, 在 YOLO v5s 的基础上引入 P2 小目标特征层和 DyHead 模块, 提高对幼苗小目标的检测准确性, 并在训练过程引入图像加权策略解决样本数量不平衡问题, 进一步提高被遮挡幼苗的检测精度; 然后, 在切片辅助推理框架中引入改进模型训练权重, 在大尺寸田间图像中实现宿根蔗幼苗的检测; 最后, 构建以改进的 DBSCAN 聚类算法和 PCA 拟合算法为核心的作物行识别算法, 在作物行线上定位缺苗位置。试验结果表明, 改进宿根蔗幼苗检测模型在子图上的平均检测精度为 96.8%, 在大图上的识别精确率和召回率为 94.5% 和 91.8%, 检测时间为 0.32 s。基于检测的位置坐标信息利用作物行识别算法实现分垄, 作物行聚类准确率达到 100%, 拟合的作物行中心线角度平均误差为 0.245 5°, 作物行中心线上缺苗位置识别的精确率和召回率为 91.9% 和 97.1%, 平均定位误差为 9.73 像素。该方法可用于大尺寸复杂田间图像上的宿根蔗智能缺苗定位, 为补种作业提供技术支持, 对延长宿根年限、提高甘蔗产量具有重要意义。

关键词: 宿根蔗幼苗; 缺苗定位; 无人机 RGB 图像; YOLO v5s; 作物行识别; DBSCAN

中图分类号: S24; TP39 **文献标识码:** A **文章编号:** 1000-1298(2024)12-0057-14

OSID:



Method for Locating Missing Ratoon Sugarcane Seedlings Based on RGB Images from Unmanned Aerial Vehicles and Improve YOLO v5s

LI Shangping^{1,2} ZHENG Chuangrui^{1,2} WEN Chunming^{1,2} LI Kaihua^{1,2}

(1. College of Electronic Information, Guangxi Minzu University, Nanning 530006, China

2. Key Laboratory of Intelligent Unmanned System and Intelligent Equipment, Nanning 530006, China)

Abstract: In response to the lack of specific missing seedling data for the transverse replanting machine of pre-cut double bud sugarcane segments, resulting in poor replanting efficiency, a method for locating missing ratoon sugarcane seedlings based on UAV RGB images was proposed. Firstly, high-resolution images of ratoon sugarcane seedlings in the field were rapidly captured by using UAVs, which were then segmented into multiple sub-images and subjected to data augmentation to construct a dataset. Secondly, enhancements to the YOLO v5s model involved the introduction of P2 small target feature layers and DyHead modules to improve the detection accuracy of small seedling targets. Additionally, an image weighting strategy was employed during training to address sample imbalance issues and further improve detection accuracy, especially for occluded seedlings. Subsequently, a framework incorporating sliced-assisted inference facilitated the detection of ratoon sugarcane seedlings in large-scale field images by using the trained model. Finally, a row recognition algorithm based on an improved DBSCAN clustering algorithm and PCA fitting algorithm was developed to locate missing seedling positions along crop rows. Experimental results demonstrated that the improved ratoon sugarcane seedling detection model achieved an average detection accuracy of 96.8% on sub-images and recognition precision and recall rates of

收稿日期: 2024-04-30 修回日期: 2024-05-23

基金项目: 国家自然科学基金项目(52165009)和广西科技重大专项(桂科 AA22117008、桂科 AA22117006)

作者简介: 李尚平(1956—), 男, 教授, 博士生导师, 主要从事智能制造技术信息化研究, E-mail: spli501@vip.sina.com

94.5% and 91.8% , respectively , on large-scale images , with a detection time of 0.32 s . Utilizing the detection coordinates , the row recognition algorithm achieved 100% clustering accuracy , with an average angular error of 0.245 5° for fitted row angles , and precision and recall rates of 91.9% and 97.1% , respectively , for missing seedling detection along rows . This method can be applied to intelligent missing seedling localization in large-scale , complex field images of ratoon sugarcane , providing technical support for replanting operations and holding significant implications for extending ratoon lifespan and increasing sugarcane yield .

Key words: ratoon sugarcane seedlings; missing seedling localization; UAV RGB images; YOLO v5s; crop row detection; DBSCAN

0 引言

甘蔗是我国最重要的糖料作物,在我国国民经济中占有特殊地位。其中保留宿根是甘蔗种植管理过程中非常重要的培育方式,具有免整地、节约种苗、节省劳动力、节约成本、提早熟期、减少种植循环过程等优点,深受世界主要蔗糖生产国重视^[1]。然而,由于蔗种质量差、生长条件变化以及机收操作不当等影响,导致我国甘蔗缺苗率最高可达40%,宿根年限也仅有2~4 a,与国外相比差距较大,严重制约我国甘蔗糖业的发展^[2-5]。因此,国内农民选择在宿根蔗苗期进行人工补种,可以有效延长宿根年限,但是补种效率低下^[6-7]。基于补种需求,课题组自主研发了预切种式双芽蔗段横向补种机,为大规模甘蔗补种应用奠定了基础^[8]。然而,补种机虽然具有更高的补种效率,但是缺乏宏观的补种规划,补种位置判定依赖驾驶员经验,补种质量无法监管。所以亟需一种智能缺苗定位方法,为补种机作业规划提供支持,降低人工劳动强度。

近年来,缺苗定位检测逐步成为智慧农业的一个研究热点。国内外研究团队从穴盘到自然场景均取得了研究成果^[9-11]。在自然环境下,作物检测^[12]和行识别^[13-17]是实现缺苗检测与定位的关键。因为实际田间的宿根蔗经过培土后会一定程度偏离直线,杂乱的田间环境伴生植物丛生,不利于直接准确判断缺苗位置,加大了缺苗位置识别与定位难度。因此,本文运用无人机快速采集田间宿根蔗幼苗高分辨率图像,结合改进 YOLO v5s 网络和切片辅助推理微调框架构建幼苗检测系统,并构建以椭圆形密度聚类 (Density-based spatial clustering of applications with noise, DBSCAN) 和主成分分析 (Principal component analysis, PCA) 算法为核心的作物行识别算法,实现航拍大图上缺苗识别与定位,以期宿根蔗补种设备提供技术支持,促进甘蔗种植可持续发展。

1 数据获取与处理

1.1 数据采集

无人机航拍图像采集地点位于广西壮族自治区崇左市扶绥县广西大学农业科学新城 (22.459 7°N, 107.747 6°E),具体采集时间为2023年4月11日,此时的宿根蔗苗期植株平均高度约35 cm。为了减少无人机采集图像的飞行时间,在该试验田中划分出2块小区域用于低空航拍图像的采集,试验区1采集的图像用于训练宿根蔗幼苗检测模型,试验区2采集的图像用于拼接田间地块的整图。

宿根蔗幼苗图像的采集使用 DJI Phantom 4 pro V2 型无人机(图1),云台拍摄角度为垂直地面,使用 DJI GS Pro 软件自定义航拍区域,飞行方向沿着垄线飞行,飞行高度为10 m,速度为2 m/s,拍摄间隔为3 s,航向重叠率和旁向重叠率都设为80%。最终共采集图像1 090 幅,其中试验区1有610 幅,试验区2有480 幅,分辨率为5 472 像素×3 648 像素,地面采样距离为2.7 mm。




图1 宿根蔗幼苗图像采集

Fig.1 Collection of ratoon sugarcane seedling images

1.2 数据集构建

宿根蔗幼苗数据集的构建主要包括图像切分、图像标注、数据集划分以及图像增强。首先,由于原始航拍图像尺寸较大,宿根蔗幼苗像素占比小,直接输入深度学习网络中训练容易导致特征丢失,因此在试验区1中随机抽取510幅图像进行切分,切分方式按照宽度重叠率为33%(680像素)和高度重叠率为21%(430像素)的比率,共获得4 080幅分

分辨率为 2 048 像素 × 2 048 像素的子图像。为提高标注效率和减少重复图像,采用随机抽选结合人工剔除的方式留下特征质量较高的子图 1 920 幅。

分析宿根蔗幼苗表型特征并使用 Labellmg 工具加以标注,如图 2 所示。通过观察图 2a 的宿根蔗幼苗俯视图发现,宿根蔗幼苗的叶子呈现长条状,由内向外散开,中间有一个聚集向内的蔗心。以此特征作为标注框的中心,向外延伸较短距离,能够有效解决完整植株互相遮挡导致难以标注的问题,而且将该中心坐标用于代表整株幼苗的位置信息在逻辑上更合理。图 2b 是宿根蔗幼苗植株的标注示意图,其中红色标签框“RSS”(Ratoon sugarcane seedlings)表示未遮挡的宿根蔗幼苗;黄色标签框“RSS_O”(Occluded ratoon sugarcane seedlings)表示被遮挡的宿根蔗苗。此方式可以提高整体数据集的质量和可用性,有助于训练出更准确、鲁棒的检测模型。此外,本文将剩下的 100 幅原始图像单独标注,将其作为评估大图的幼苗检测性能、作物行识别和缺苗定位效果的验证集,将其命名为“Large_RSS_Val”。




图 2 宿根蔗幼苗图像的标注方式

Fig. 2 Annotation method for ratoon sugarcane seedling images

将标注好的样本子图与标签数据按照 8: 1: 1 划分为训练集、验证集和测试集。并对训练集和验证集进行 2 倍的数据增强,增强方式包括亮度变换、对比度变换、翻转变换、高斯噪声等,这些增强方式并不是单独进行,而是以一定的顺序和组合方式应用于每幅图像(图 3),最终得到训练集 4 608 幅,验证集 576 幅,测试集 192 幅,有效丰富了数据集。

分析宿根蔗幼苗数据集的边界框特点,如图 4 所示。其中幼苗边界框横坐标和纵坐标皆进行归一

化处理。从图 4a 可知,宿根蔗幼苗边界框中心坐标(坐标采用比例表示)分布较为全面。根据整幅图呈蓝色,可以断定基本每块区域都有可能出现边界框。图 4b 的统计结果显示,宿根蔗幼苗未遮挡状态下的标签数量为 88 273 个,遮挡状态下的标签数量仅为 3 057 个,2 种标签数量存在严重的不平衡问题,导致被遮挡情况下的宿根蔗幼苗检测性能较差。图 4c 是宿根蔗幼苗边界框宽高分布图,从图 4c 可以发现,大多数标签框与样本子图长宽比例皆小于 0.03,满足小目标的相对尺寸定义。基于以上分析的特点,本文宿根蔗幼苗检测模型优化和改进的重点为解决类别不平衡问题以及小目标检测难题。

2 研究方法

首先,通过宿根蔗幼苗检测系统检测宿根蔗幼苗目标,获取位置像素坐标;然后,基于宿根蔗幼苗位置坐标关系,利用椭圆形 DBSCAN 聚类算法将目标分到对应的作物行上,并利用 PCA 算法拟合作物行中心线;最后,根据农艺专家提出的横向补种方式以及结合甘蔗平均簇生间距为 30 ~ 40 cm 的特点,若相邻幼苗间距超过 60 cm,则在这个间距中间确定缺苗位置,实现缺苗定位。具体流程如图 5 所示。

2.1 宿根蔗幼苗检测系统

2.1.1 基于改进 YOLO v5s 的宿根蔗幼苗检测模型

YOLO v5s 是 YOLO v5 中模型复杂度较低且兼具较高检测精度和速度的模型,可以作为检测宿根蔗幼苗的基础网络模型。模型结构主要包括输入端(Input)、骨干网络(Backbone)、颈部网络(Neck)和预测头(Head)。

针对幼苗数据集特点,基于 YOLO v5s 模型提出以下优化改进策略:首先,为了解决类别不平衡问题,在训练过程中引入图像加权策略,以提高被遮挡宿根蔗幼苗的检测精度。其次,在 YOLO v5s 网络颈部和头部增加一个专门针对小目标的 P2 检测层,提高捕获和保留宿根蔗幼苗小目标特征信息的能力。最后,在头部网络中使用带有注意力机制的动态检测头(Dynamic head, DyHead)模块替代原始的




图 3 图像增强结果

Fig. 3 Enhanced image results




图 4 宿根蔗幼苗数据集的边界框统计

Fig. 4 Boundary box statistics of ratoon sugarcane seedling dataset




图 5 缺苗位置识别与定位方法流程图

Fig. 5 Flowchart of missing seedling detection and localization method

检测头,改善了多尺度和多类别目标检测性能,有效增强对宿根蔗幼苗在高分辨率图像中的分类和定位能力。改进后网络结构如图 6 所示。紫色虚线框区域为新增的 P2 小目标检测层,红色模块为引入的带有注意力机制的新检测头 DyHead。

(1) 图像加权策略

图像加权策略是处理数据集中样本数量不平衡问题的方法^[18-19]。通过计算类别权重和图像权重,并在每个轮次的训练过程中使用该权重来调整样本的重要性,使得数量较少的样本可以获得较大的采




图 6 改进的 YOLO v5s 网络结构图

Fig. 6 Improved YOLO v5s network architecture

样概率,提高整体模型检测精度。具体步骤如下:

统计每个类别样本在数据集中所占比例,并计算相应的权重。计算公式为

$$F_c = \frac{N_c}{N} \tag{1}$$

$$W_c = \frac{1}{F_c} \tag{2}$$
$$W_c = \frac{1}{\sum_{c=1}^t \frac{1}{F_c}}$$

式中 N_c ——第 c 个类别数量

N ——所有类别数量

t ——类别数量

F_c ——第 c 个类别频率

W_c ——第 c 个类别权重

根据图像中包含的各个类别的数量以及对应的类别权重,计算图像的权重。公式为

$$M_i = \sum_{c=1}^t W_c n_c \tag{3}$$

式中 n_c ——图像上第 c 个类别数量

M_i ——第 i 幅图像权重

(2)新增 P2 小目标检测层

宿根蔗幼苗小目标的特征信息在 YOLO v5s 的网络传播过程中容易被稀释,造成小目标检测性能不佳。因此,本文新增一层小目标检测层,命名为 P2,旨在捕捉和保留这些小目标的特征信息,从而提高模型对宿根蔗幼苗的定位能力。改进的结构图如图 7 所示,其中红色框表示新增的小目标检测层,黄色线表示上采样操作。从图 7 可以发现,P2 层位于第 2 次上采样之后,使得 P2 层具有更高的分辨率和更丰富的语义信息,可以有效地检测和定位宿根蔗幼苗目标。




图 7 新增小目标特征层

Fig. 7 Addition of small target feature layer

(3)DyHead 模块

YOLO v5 的检测头是一个多层卷积和全连接网络,负责从图像中提取特征并执行目标检测和定位。然而,由于输入图像的视野较大且分辨率较高,YOLO v5 无法有效地检测和定位小目标,导致在检测宿根蔗幼苗时存在漏检等现象。因此,本文在 YOLO v5s 的头部网络中,将所有检测头替换成包含

注意力机制的 DyHead 模块,使得目标检测任务中的定位和分类性能得到改善,并更加专注于宿根蔗幼苗的检测^[20]。DyHead 模块结构如图 8 所示。每个注意力模块分别在 3 个尺度感知维度上执行,并按顺序应用于检测头部,可以多次叠加使用,使检测头具有更强的表示能力,提升宿根蔗幼苗小目标的检测性能。




图 8 DyHead 模块结构图

Fig. 8 Structure of DyHead module

2.1.2 结合 SAHI 框架

切片辅助推理框架 (Slicing aided hyper inference, SAHI)是由 AKYON 等^[21]提出的用于解决小目标检测问题的框架,可与各类目标检测方法集成应用。图 9 展示了 SAHI 框架结合改进的 YOLO v5s 网络模型在航拍大图上的宿根蔗幼苗检测流程图。首先,将航拍大图切分成多个重叠的小图像块 (Patch),每个小图像块在保持纵横比的同时调整尺寸。然后,将改进的 YOLO v5s 宿根蔗幼苗检测模型独立应用于每个重叠的图像块上进行预测。此外,SAHI 还具备可选的全推理 (Full inference, FI) 方法,通过将未切片的原始图像直接进行预测,保留高分辨率图像中的大目标检测功能。最后,使用非极大值抑制 (Non-maximum suppression, NMS) 将重叠的预测结果合并回原始图像上。在 NMS 过程中仅考虑 IoU 比率高于预定义匹配阈值的框,并删除检




图 9 结合 SAHI 框架的大图中宿根蔗幼苗检测流程图

Fig. 9 Detection process of ratoon sugarcane seedlings in large images with SAHI framework

测概率低于该阈值的检测框。

通过以上结合,成功实现了宿根蔗幼苗检测系统,可针对大面积农田高分辨率图像上的宿根蔗幼苗进行检测。同时需要注意,SAHI 的切片数量与计算时间呈线性关系。为了更好地平衡检测时间和精度,在构建数据集时将子图尺寸设置为 2 048 像素 × 2 048 像素,以避免 SAHI 切片数量过多导致检测时间过长的问题。

2.2 缺苗定位算法

2.2.1 基于椭圆形 DBSCAN 算法的作物行聚类方法

DBSCAN 聚类算法是一种经典的基于密度的空间聚类算法,它可以在含有噪声的数据集中识别任意数量和形状的簇^[22]。然而,直接使用原始的 DBSCAN 聚类并无法实现将同一作物行上的宿根蔗幼苗位置坐标聚为一簇,因为该方法的搜索方式是在邻域半径 r 的圆形区域内寻找核心点,在纵向和横向采用相同的像素距离度量标准。因此,在原始 DBSCAN 算法的基础上,将邻域半径 r 的圆形区域修改为以 a 为长半轴长度和 b 为短半轴长度的椭圆形区域,使得聚类方向趋向于作物行线方向。具体的算法步骤如图 10 所示。

首先,设置合适的长半轴长度 a 和短半轴长度 b ,以及指定核心点最小密度数 N_{Minpts} 。当位于椭圆形区域内的节点数量大于 N_{Minpts} 时,该节点则为核心点。然后,从该节点向外循环扩展,直到达到簇类的边缘,不再扩展。最后,按顺序寻找其他簇类,直到遍历完所有节点。

2.2.2 基于 PCA 算法拟合作物行中心线

为了准确获取缺苗位置的坐标,作物行线的拟合十分重要。然而,在实际的宿根蔗生长过程中,存在较多偏离作物行线的幼苗,常规的线性回归方法并不适用。所以本文利用 PCA 算法找到位置坐标变化最显著的方向,进而拟合准确的作物行中心线^[23]。具体步骤如下:

(1)假设给定的任一作物行内的所有坐标集合 $R = \{c_1, c_2, \dots, c_n\}$, R 中任一 c_i 都为宿根蔗幼苗目标框的中心点坐标,记为 $c_i = (x_i, y_i)$ 。然后分别计算作物行内宿根蔗坐标在 x 轴和 y 轴上的均值 $\bar{x}$ 、 $\bar{y}$,并进行数据中心化,计算公式为

$$\begin{cases} \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \\ \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i \end{cases} \quad (4)$$

$$\begin{cases} x'_i = x_i - \bar{x} \\ y'_i = y_i - \bar{y} \end{cases} \quad (5)$$




图 10 改进后的 DBSCAN 算法流程图
Fig. 10 Flowchart of improved DBSCAN algorithm

式中 x'_i, y'_i ——中心化后的 x, y 坐标

(2)计算协方差矩阵,并获得特征值和特征向量,其中特征值表示宿根蔗幼苗坐标在特定方向的方差值,而对应的特征向量方向即宿根蔗作物行中心线方向,计算公式为

$$A V = \lambda V \quad (6)$$

其中
$$A = \begin{bmatrix} \text{cov}(x, x) & \text{cov}(x, y) \\ \text{cov}(y, x) & \text{cov}(y, y) \end{bmatrix} \quad (7)$$

$$\text{cov}(x, y) = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n - 1} = \frac{\sum_{i=1}^n x'_i y'_i}{n - 1} \quad (8)$$

式中 A ——协方差矩阵

$\text{cov}(x, y), \text{cov}(y, x)$ ——协方差

$\text{cov}(x, x), \text{cov}(y, y)$ ——方差

λ ——特征值

V ——特征向量

(3) 通过选择最大特征值 λ_1 所对应特征向量

$V_1 = \begin{bmatrix} v_1 \\ v_2 \end{bmatrix}$, 计算作物行中心线斜率和截距, 计算公式为

$$\begin{cases} w = \frac{v_2}{v_1} \\ b = \bar{y}' - w\bar{x}' \end{cases} \quad (9)$$

式中 w ——作物行中心线斜率

b ——作物行中心线截距

得作物行中心线方程为

$$y = wx + b \quad (10)$$

2.2.3 缺苗定位方法

根据得到的作物行中心线表达式, 将 R 中的宿根蔗坐标投影到线上, 对应的投影坐标计算公式为

$$\begin{cases} x_{pi} = \frac{x_i + w(y_i - b)}{1 + w^2} \\ y_{pi} = wx_{pi} + b \end{cases} \quad (11)$$

式中 x_{pi}, y_{pi} ——投影点横、纵坐标

将投影点记为 $p^{(i)} = (x_{pi}, y_{pi})$, 投影坐标集合记为 $R_p = \{p^{(1)}, p^{(2)}, \dots, p^{(n)}\}$ 。接着, 对任一作物行中心线上的投影点做关于 y 坐标的排序, 计算相邻 2 个投影点距离 d , 如果距离超过补种的像素阈值, 则计算缺苗位置坐标 (x_{si}, y_{si}) 和缺苗数量 N_{no} 。计算公式为

$$d = \sqrt{(x_{pi+1} - x_{pi})^2 + (y_{pi+1} - y_{pi})^2} \quad (12)$$

$$N_{no} = \left\lfloor \frac{d}{d_{sd}} \right\rfloor \quad (13)$$

$$\begin{cases} x_{si} = \frac{i(x_{pi+1} - x_{pi})}{N_{no}} + x_{pi} \\ y_{si} = \frac{i(y_{pi+1} - y_{pi})}{N_{no}} + y_{pi} \end{cases} \quad (14)$$

式中 d_{sd} ——标准苗间距

将缺苗位置坐标记为 $s = (x_{si}, y_{si})$, 其中 i 表示缺苗位置序号, 任一作物行中心线上的补种坐标集合记为 $R_s = \{s_1, s_2, \dots, s_n\}$ 。

3 试验

3.1 试验环境

检测模型在 AutoDL AI 算力云服务器上训练获得, 显卡型号为 RTX4090, 显存 24 GB, 软件环境为 Python 3.8.10, Pytorch 1.9.0, CUDA 11.1, 操作系统为 Linux 5.4.0。模型测试和其他试验在个人计算机进行, 显卡型号为 RTX3060, 显存 6 GB, 软件环境为 Python 3.8.13, Pytorch 1.7.1, CUDA 11.0, 操作

系统为 Windows 10, 编码调试平台在 PyCharm 进行。

3.2 训练参数

在模型训练上, YOLO v5-6.2 源码库是本项目的起点, 并与 2.1.1 节中描述的模型改进一起实现。该训练使用了 SGD 优化器, 初始学习率为 0.01, 最终学习率为 10^{-5} , 权重衰减为 0.005。在前 3 个热身阶段使用 0.8 的动量后, 动量改变为 0.937。训练运行 300 个周期, 批大小为 16。

3.3 评价指标

以精确率 (Precision)、召回率 (Recall)、平均精度均值 (Mean average precision, mAP)、浮点运算量 (FLOPs)、推理时间 (Time) 作为评估宿根蔗幼苗检测模型性能的评价指标。平均精度均值可以分为平均精度均值 1 和平均精度均值 2, 分别表示 mAP@0.5 和 mAP@0.5:0.95。

4 试验结果与分析

4.1 宿根蔗幼苗检测系统性能分析

4.1.1 模型消融试验

为了验证和分析 YOLO v5s 模型中引入的优化改进策略的检测性能, 以 YOLO v5s 原始模型为基准线开展消融试验。表 1 为各个改进优化策略组合后的检测性能结果, 其中, 引入的 DyHead 检测头默认堆叠 2 次 DyHead 结构, 并且本试验中所有模型都没有使用任何预训练权重。从表 1 可以看出, 单独使用图像加权策略 (iw)、新增 P2 小目标特征层或者引入 DyHead 模块, 模型的检测精度均有显著提高。单独使用图像加权策略后, 模型召回率提高 3 个百分点, 平均精度均值 1 和平均精度均值 2 分别提升 2.5 个百分点和 6.7 个百分点, 这是因为有更多的被遮挡宿根蔗幼苗被成功检测; 在网络中新增 P2 小目标特征层, 模型的平均精度均值 1、平均精度均值 2 分别提升 4.4、9.5 个百分点, 计算量仅增加 17%, 推理时间仅增加 2.6 ms, 模型检测精度得到了进一步提升, 而如果单独引入 DyHead 模块, 虽然提升幅度没有新增 P2 小目标特征层的性能提升大, 但是相比于原始模型提升十分明显; 本文将 2 种网络模型改进策略结合应用, 得到最佳的模型检测性能, 平均精度均值 1 和平均精度均值 2 分别达到 96.8% 和 59.0%, 比原始模型提升 6.1 个百分点和 13.7 个百分点, 计算量增加 32.9%, 推理时间仅为 20.2 ms。

由于不同数量的 DyHead 模块堆叠产生的性能提升和计算成本也不同, 为了探究最优的堆叠数量, 本文进行了 DyHead 数量堆叠试验。试验基线模型使用 YOLO v5s-iw-P2 模型, 对基线模型分别叠加

表 1 消融试验结果对比

Tab. 1 Comparison of results from ablation experiments

模型	精确率/%	召回率/%	平均精度均值 1/%	平均精度均值 2/%	浮点运算量	推理时间/ms
YOLO v5s	90. 1	87. 0	90. 7	45. 3	1.58×10^{10}	9. 3
YOLO v5s - iw	90. 1	90. 0	93. 2	52. 0	1.58×10^{10}	9. 3
YOLO v5s - iw - P2	94. 4	93. 2	95. 1	54. 8	1.85×10^{10}	11. 9
YOLO v5s - iw - DyHead	91. 8	92. 4	94. 8	54. 8	1.59×10^{10}	19. 6
YOLO v5s - iw - P2 - DyHead	95. 3	95. 4	96. 8	59. 0	2.10×10^{10}	20. 2

1、2、4、6、8 个 DyHead。其中,叠加个数为 0 的是基线模型,试验结果如表 2 所示。

表 2 DyHead 堆叠数量结果比较

Tab. 2 Comparison of results based on number of DyHead stacks

DyHead 模块数量	精确率/%	召回率/%	平均精度均值 1/%	平均精度均值 2/%	浮点运算量	推理时间/ms
0	94. 4	93. 2	95. 1	54. 8	1.85×10^{10}	11. 9
1	94. 0	94. 3	96. 4	57. 5	2.00×10^{10}	14. 1
2	95. 3	95. 4	96. 8	59. 0	2.10×10^{10}	20. 2
4	95. 4	95. 6	96. 9	59. 4	2.32×10^{10}	29. 6
6	94. 9	95. 5	97. 1	59. 8	2.54×10^{10}	39. 3
8	94. 7	95. 1	96. 4	59. 6	2.76×10^{10}	47. 3

从表 2 中可看出,随着 DyHead 模块叠加个数的增加,精度也随之增加,但是计算成本和参数量也

有小幅度增加,当 DyHead 数量达到 8 个时,其各项性能指标开始下降,这是因为随着深度进一步增加,模型的冗余就会占据主导地位,模型学到了许多不重要的特征,从而导致检测性能下降。因此,本文从算法精度、复杂度和推理速度进行综合考虑,选择以 2 个 DyHead 模块的叠加作为最终的改进模型。

4.1.2 与其他目标检测算法的对比

为了探究本文改进的 YOLO v5s 算法与其他目标检测算法识别性能的优劣性,对比 DETR^[24]、CenterNet^[25]、TPH - YOLO v5s^[26] 以及 YOLO v8s 算法。如表 3 所示,本文方法获得的检测精度最高,检测性能明显优于其他目标检测模型,模型复杂度最小,检测时间略高于 YOLO v8s,但基本满足复杂田间的宿根蔗幼苗检测需求,可以为缺苗定位提供可靠、精准的位置坐标信息。

表 3 与其他目标检测算法的对比

Tab. 3 Comparison with other object detection algorithms

模型	精确率/%	召回率/%	平均精度均值 1/%	平均精度均值 2/%	浮点运算量	推理时间/ms
CenterNet	68. 1	53. 5	60. 5	17. 7		19. 0
DETR			66. 0	20. 9		55. 0
TPH - YOLO v5s	87. 8	79. 3	83. 3	35. 4	2.30×10^{10}	25. 0
YOLO v8s	94. 0	93. 2	94. 5	56. 9	2.84×10^{10}	11. 2
本文方法	95. 3	95. 4	96. 8	59. 0	2.10×10^{10}	20. 2

4.1.3 宿根蔗幼苗检测实例

通过上述优化改进策略,在相同参数条件下对宿根蔗幼苗图像进行了检测,检测结果如图 11 所示。在分布稀疏且无遮挡情况下(图 11a),5 个检测模型都表现出良好的识别效果,其中 YOLO v5s - iw - P2 - DyHead 检测框的置信度最高。然而,在分布较为密集且遮挡较多的情况下(图 11b,其中黄色圆圈为漏检的幼苗位置),原始 YOLO v5s 漏检 5 株幼苗;当引入图像类别加权策略后,遮挡的幼苗(粉色框)基本都能被识别出来;当引入 P2 小目标特征层后,所有幼苗目标皆被检出;当加入 DyHead 模块后,存在一个漏检目标,但是总体置信度更高;结合 2 种模型改进策略后,不仅幼苗目标全部被检测出来,而且置信度达到 0.9 左右。综上所述,通过算法优化得到的 YOLO v5s - iw - P2 - DyHead 模型宿根

蔗幼苗检测性能最佳,满足复杂环境下检测宿根蔗幼苗的需求。

由于杂草在蔗田环境较为常见,所以本文测试了 YOLO v5s - iw - P2 - DyHead 在杂草丛生场景下检测效果(图 12)。从图 12 可见,黄色圈内为杂草,周围幼苗皆被检测出来,可见本文方法可以有效抑制杂草对检测幼苗的影响。

4.1.4 大图中幼苗检测性能

为了评估宿根蔗幼苗检测系统在航拍高分辨率大图上的检测性能,将 Large_RSS_Val 中的 100 幅原始图像输入到检测系统中,宿根蔗幼苗共 18 521 株,准确检测出 17 002 株,误检 979 株,漏检 1 519 株,识别精确率达到 94.5%,召回率为 91.8%,平均每幅图像检测时间为 0.32 s。

图 13 展示了原始图像的误检和漏检情况。其




图 11 宿根蔗幼苗检测实例对比

Fig. 11 Comparison of ratoon sugarcane seedling detection instances




图 12 在杂草丛生场景下的宿根蔗幼苗检测实例

Fig. 12 Detection example of cane seedlings in overgrown scenes

中,绿色框表示正确检测目标,红色框表示漏检目标,蓝色框表示误检目标。从图 13 可以看出,大部分漏检和误检情况主要出现在宿根蔗幼苗相互严重遮挡或者特征非常模糊的情况下,由于本文主要关注缺苗位置,所以只要在密集区域中检测到部分蔗苗就不会影响缺苗定位的计算,有利于提高整体系




图 13 大图中宿根蔗幼苗检测结果

Fig. 13 Detection of ratoon sugarcane seedlings in large-scale images

统的容错率和鲁棒性。

4.2 缺苗定位算法性能

4.2.1 椭圆形 DBSCAN 聚类参数选择

作物行聚类算法主要参数包括短半轴长度 a 、长半轴长度 b 以及核心点的邻域最小样本数 N_{Minpts} 。其中,长半轴长度 b 与垄上幼苗纵向分布的可达距离直接相关,短半轴长度 a 与垄宽长度相关,这 2 个参数的数值选择直接影响作物行聚类的效果。因此,本文开展了以下试验:

首先,根据机械种植的垄宽 1.4 m(约 518 像素),可以先保持短半轴长度 a 不变的情况下,探究长半轴长度 b 的最优选择范围。在 Large_RSS_Val 的基础上,将短半轴长度 a 初始化为 170 像素(约为垄宽的 1/3),记录长半轴长度从 100 像素增加到 2 500 像素的(增量为 50 像素)作物行聚类准确性变化情况,如图 14 所示。从图 14 中可见,当长半轴长度小于 300 像素时,无法完成作物行聚类。随着长半轴长度从 300 像素增加到 1 000 像素,作物行聚类准确性迅速提升,而在 1 000 像素后,准确率提升趋缓,直至长半轴长度达到 2 100 像素时,行距聚类准确率达到 100%。这一变化过程反映了长半轴长度可以根据作物行内宿根蔗缺苗的距离进行合理设置。如果缺苗断垄的距离很大,则需要设置更大的长半轴长度。




图 14 不同长半轴长度作物行聚类准确率变化曲线
Fig. 14 Change in row clustering accuracy with different long axis values

在保持长半轴长度为 2 100 像素的情况下,记录短半轴长度从 50 像素增加到 300 像素的变化过程中作物行聚类准确率的变化情况(增量为 10 像素),如图 15 所示。

从图 15 可见,当短半轴长度从 10 像素增加到 240 像素时,作物行聚类准确性先迅速提升,之后一直保持 100%。然而,当超过 240 像素时,准确率开始下降。这是因为短半轴长度已经超过了正常垄间




图 15 不同短半轴长度作物行聚类准确率变化曲线
Fig. 15 Change in row clustering accuracy with different short axis values

距的范围,将相邻多垄的宿根蔗幼苗坐标聚成一簇,导致准确率下降。综上所述,只要确保短半轴长度保持在合适的垄间距范围内,同时根据断垄情况选择合适的长半轴长度,则可以得到较好作物行聚类效果。

4. 2. 2 聚类效果对比

为了探究所提作物行聚类方法与其他聚类算法性能,与原始 DBSCAN、K-means^[27] 和 BSAS (Basic sequential algorithmic scheme)^[28] 算法进行聚类效果比较,相关超参数设置如下:在原始 DBSCAN 算法中,邻域距离设置为 170 像素,核心点的邻域最小样本数设为 2。根据图像中的作物行数量将 K-means 算法的质心数初始化为 9。BSAS 算法的最大允许分配簇的数量和点之间最大距离的阈值分别设置为 9 和 170 像素。本文椭圆形 DBSCAN 算法的椭圆形搜索区域长半轴长度和短半轴长度分别为 2 100 像素和 170 像素,核心点相邻的样本数为 2。聚类效果如图 16 所示。

在图 16 中,虚线框内的点为同一作物行上的宿根蔗幼苗坐标,所以正确的聚类结果应该是同一种颜色。但是,原始 DBSCAN、K-means、BSAS 算法皆在同一作物行内呈现多种颜色的点,说明它们均出现不同程度的聚类错误,主要原因有 2 点:宿根蔗幼




图 16 本文方法与其他聚类算法的效果对比图

Fig. 16 Comparison of effectiveness of proposed method with other clustering algorithms

苗的位置像素坐标间距在行间和行内略有变化,并且坐标位置之间没有明显的行内间隙。由于坐标位置的稀疏分布特性,植物的缺失严重破坏了属于同一行的坐标位置之间的相似性度量。所以在横向和纵向采用相同的距离和密度度量无法完成作物行聚类。相反,本文提出的算法充分利用作物按照行排列的规律、相邻行有一定间距以及行的斜率变化小这些关键信息,设计了以横向和纵向不相同的距离度量为核心的椭圆形 DBSCAN 聚类算法,实现在不均匀的行内间距和缺失的植物中,都能正确地对所有坐标位置进行聚类,具有较高的鲁棒性。

4.2.3 PCA 拟合作物行中心线效果评估

作物行识别的准确性主要体现在检测的行线与实际作物行线的拟合程度。为了准确评估作物行线拟合算法的拟合效果,本文在 Large_RSS_Val 的基础上,对比拟合的宿根蔗行线与目测的真实行线之间的角度差异,并对差异进行全面统计分析。首先,本文人工记录 Large_RSS_Val 中所有图像的作物行线斜率,并将其斜率转换为角度,作为实际作物行线角度。然后,为了确保数据的一致性以及便于后续的角度差异比较和统计分析,将所有角度取绝对值。最后,将 PCA 拟合作物行中心线的角度与实际的作物行中心线角度进行对比和分析,如图 17 所示,拟合方程式为 $y = 0.983\,91x + 1.398\,6$, 决定系数 R^2 为 0.974 64, 角度平均绝对偏差为 0.245 5°, 可见拟合的作物行线角度与实际作物行线角度高度一致。

与常用的最小二乘法 (Least squares method, LSM)^[29]、随机抽样一致性回归方法 (Random sample consensus regression, RANSAC)^[30] 进行比较,如图 18 所示。PCA 算法拟合的作物行线角度集中在 80°~90°, 这符合本文数据集中宿根蔗行线分布的规律。而 LSM 和 RANSAC 皆出现不同程度的大角度偏差。这是因为 LSM 对离群值非常敏感, 当作物行内的幼苗坐标离群值较多时, LSM 容易出现极大偏差; RANSAC 略优于 LSM, 这是因为它是通过随




图 17 PCA 算法拟合的作物行线角度与实际作物行线角度的拟合误差曲线

Fig. 17 Error plot of fitted row angles by PCA algorithm against actual row angles




图 18 不同算法拟合的作物行线角度分布图

Fig. 18 Distribution of fitted row angles by different algorithms

机采样数据提高的拟合鲁棒性,但是稳定性较差,随机种子难以确定。

拟合效果对比如图 19 所示,在映射到原始图像后,蓝色线代表 LSM,红色线代表 RANSAC,黄色线为本文方法。从图 19 可见本文提出的 PCA 拟合作物行线明显优于前两者,拟合的作物行线基本和真实作物行线位置一致,为缺苗定位奠定了良好基础。

4.2.4 缺苗定位结果分析

为验证缺苗定位算法的性能,在 Large_RSS_Val 上计算并保存了缺苗位置作为实际缺苗位置。然后,利用本文方法将缺苗阈值设为 222 像素(约




图 19 不同算法拟合的作物行线效果对比

Fig. 19 Comparison of crop row line fitting effects by different algorithms

60 cm),标准的正常苗间距为 111 像素(约 30 cm),检测并保存缺苗位置和数量。统计结果为:真实缺苗位置数量为 7 297 个,本文方法寻得缺苗位置数量为 7 709 个,其中正确检测为缺苗位置数量有 7 085 个,误检 624 个,漏检 212 个,精确率和召回率分别为 91.9% 和 97.1%。

为了进一步验证缺苗定位精度的准确性,本文将正确判定为缺苗位置与实际缺苗位置进行定位误差分析(图 20)。图 20a 展示了实际缺苗位置与预测值的分布情况,蓝色圆圈表示真实的缺苗位置,红色三角形表示预测的缺苗位置。从图 20 可见大部分圆圈中间包含部分或完整的三角形,表明缺苗位置的真正值与预测值吻合度较高,这些略微的偏差主要由拟合的作物行线以及幼苗检测框的微小误差导致。图 20b 为缺苗定位误差分布图,误差值通过计算预测值与真实值的欧氏距离获得。结果显示,本文方法缺苗定位平均误差为 9.73 像素,在均值加减 2 个标准差($\pm 2\sigma$)的范围内覆盖大约 95.6% 的数据,说明本文方法在定位缺苗位置上具有较高的准确性和可靠性。




图 20 缺苗位置真实值与预测值的误差统计分布图

Fig. 20 Statistical distribution of errors between true values and predicted values for missing seedling positions

缺苗定位效果如图 21 所示。图 21a 中黑色线为作物行线,黄色点为实际缺苗位置;图 21b 中黄色线为作物行线,黑色点为预测的缺苗位置,红色区域表示误判为缺苗位置。误判原因为部分宿根蔗幼苗过小或者遮挡严重未能检测出来,导致检测的缺苗

位置数量比实际偏大,但总体缺苗定位效果可靠。




图 21 缺苗定位效果

Fig. 21 Demonstration of missing seedling localization effect

4.2.5 航拍拼接整图缺苗位置识别与定位实例

由于本文方法目的是为补种机提供宏观的缺苗定位信息,指导补种机进行补种作业,提高补种效率。所以本文通过一个航拍拼接整图上的缺苗位置识别与定位实例验证所提方法的有效性。首先,利用 PixDmapper 软件对试验区 2 中的航拍大图(分辨率为 5 472 像素 × 3 648 像素)进行拼接,并使用 Photoshop 软件裁剪整图的不完整边缘和调整图像方向。然后将整图输入到宿根蔗幼苗检测系统中进行检测,保存检测框中心坐标。随后,利用作物行识别算法对所有坐标进行行聚类、行线拟合以及缺苗位置的定位,具体流程如图 22 所示。统计结果表明,航拍整图分辨率为 14 205 像素 × 20 067 像素,面




图 22 航拍拼接整图上的缺苗定位实例

Fig. 22 Instance of missing seedling localization on stitched aerial image

积约为 2 066.7 m², 其中共检测出蔗苗 3 008 株, 拟合作物行线 26 条, 缺苗位置为 1 383 个, 该图可用于评估整体的缺苗分布情况和所需种量, 为补种机的高效补种作业提供新的技术支持。

5 结束语

针对宿根蔗补种机缺乏整体的缺苗信息导致补种作业效率不佳的问题, 提出了一种基于无人机 RGB 图像的宿根蔗缺苗定位方法。该方法通过将遥感技术、改进后的 YOLO v5s 模型以及作物行识别算法相结合, 首先定位宿根蔗幼苗目标, 然后将幼苗分配到相应的作物行上并拟合行中心线, 最终实现在作物行

线上准确定位缺苗位置。试验结果显示, 改进后的 YOLO v5s 模型在子图上的幼苗检测平均精度达到 96.8%, 结合 SAHI 后在大图上的识别精确率和召回率分别达到 94.5% 和 91.8%。基于检测的目标位置坐标数据, 本文提出的作物行识别算法行聚类准确率为 100%, 拟合的作物行中心线角度平均误差为 0.245°, 为缺苗定位提供了良好的基础。大图缺苗定位精确率为 91.9%, 召回率为 97.1%, 平均定位误差为 9.73 像素。将本文方法应用于航拍拼接整图上, 验证了其可行性, 为宿根蔗补种机的高效补种提供了技术支持。该研究对延长宿根蔗年限、促进宿根蔗的可持续发展具有重要意义。

参 考 文 献

[1] 张木清, 姚伟. 现代甘蔗栽培育种学[M]. 北京: 科学技术出版社, 2021.

[2] LIN Y, CHEN T, LIU S, et al. Quick and accurate monitoring peanut seedlings emergence rate through UAV video and deep learning[J]. Computers and Electronics in Agriculture, 2022, 197: 106938.

[3] OMOTO G, AUMA E O, OPILE W R. Light interception and productivity of sugarcane as influenced by row spacing, season, cultivar and site in Kenya[J]. International Sugar Journal, 2015, 117(1404): 893–903.

[4] MELO P L A, CHERUBIN M R, GOMES T C A, et al. Straw removal effects on sugarcane root system and stalk yield[J]. Agronomy, 2020, 10(7): 1048.

[5] 林兆里, 张华, 阙友雄, 等. 甘蔗大型机械化收获模式对蔗地土壤物理性状和宿根蔗产量的影响[J]. 热带作物学报, 2022, 43(7): 1417–1430.

LIN Zhaoli, ZHANG Hua, QUE Youxiong, et al. Effects of large scale mechanized sugarcane harvesting mode on soil physical properties of sugarcane fields and ratoon sugarcane yield[J]. Chinese Journal of Tropical Crops, 2022, 43(7): 1417–1430. (in Chinese)

[6] 游建华, 邓智年, 黄全宝, 等. 种茎直接补种宿根蔗延长年限新技术降本增效分析与展望[J]. 甘蔗糖业, 2021, 50(2): 14–22.

YOU Jianhua, DENG Zhinian, HUANG Quanbao, et al. The analysis of cost reduction and efficiency increase and prospect of the new technology of direct replanting seed cane on ratoon sugarcane[J]. Sugarcane and Canesugar, 2021, 50(2): 14–22. (in Chinese)

[7] 游建华, 梁阔, 樊保宁, 等. 种茎直接补种对甘蔗宿根性的影响——以 2017 年广西融水苗族自治县试验为例[J]. 热带作物学报, 2020, 41(9): 1790–1796.

YOU Jianhua, LIANG Tian, FAN Baoning, et al. Effects of direct replanting seed cane on ratoon sugarcane, a case study in Rongshui Miao Autonomous County, Guangxi in 2017[J]. Chinese Journal of Tropical Crops, 2020, 41(9): 1790–1796. (in Chinese)

[8] 张彪, 杨鑫三, 刘家招, 等. 宿根蔗苗精准补种总成装置: CN115067038B[P]. 2023–12–05.

[9] 王永维, 肖玺泽, 梁喜凤, 等. 蔬菜穴盘苗自动补苗试验台穴孔定位与缺苗检测系统[J]. 农业工程学报, 2018, 34(12): 35–41.

WANG Yongwei, XIAO Xize, LIANG Xifeng, et al. Plug hole positioning and seedling shortage detecting system on automatic seedling supplementing test-bed for vegetable plug seedlings[J]. Transactions of the CSAE, 2018, 34(12): 35–41. (in Chinese)

[10] 曹丹丹, 朱玉桃, 王寅初, 等. 基于深度学习的穴盘苗缺苗穴位检测[J]. 农机化研究, 2023, 45(3): 210–215.

CAO Dandan, ZHU Yutao, WANG Yinchu, et al. Detection of missing holes in plug seedlings based on deep learning[J]. Journal of Agricultural Mechanization Research, 2023, 45(3): 210–215. (in Chinese)

[11] YAN Z, ZHAO Y, LUO W, et al. Machine vision-based tomato plug tray missed seeding detection and empty cell replanting[J]. Computers and Electronics in Agriculture, 2023, 208: 107800.

[12] 张宏鸣, 付振宇, 韩文霆, 等. 基于改进 YOLO 的玉米幼苗株数获取方法[J]. 农业机械学报, 2021, 52(4): 221–229.

ZHANG Hongming, FU Zhenyu, HAN Wenting, et al. Detection method of maize seedlings number based on improved YOLO[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(4): 221–229. (in Chinese)

[13] LI D, LI B, LONG S, et al. Rice seedling row detection based on morphological anchor points of rice stems[J]. Biosystems Engineering, 2023, 226: 71–85.

[14] WANG S, YU S, ZHANG W, et al. The identification of straight-curved rice seedling rows for automatic row avoidance and

- weeding system[J]. Biosystems Engineering, 2023, 233: 47–62.
- [15] 张宇,徐浩然,牛家俊,等. 基于 YOLO v4 和双重回归的复杂环境檀香树缺苗定位方法[J]. 农业机械学报, 2022, 53(11):299–305, 340.
ZHANG Yu, XU Haoran, NIU Jiajun, et al. Missing seedling localization method for sandalwood trees in complex environment based on YOLO v4 and double regression strategy[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(11):299–305, 340. (in Chinese)
- [16] YU Y, BAO Y, WANG J, et al. Crop row segmentation and detection in paddy fields based on treble-classification otsu and double-dimensional clustering method[J]. Remote Sensing, 2021, 13(5): 901.
- [17] 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)
- [18] 范馨月,鲍泓,潘卫国. 基于类别不平衡数据集的图像实例分割方法[J]. 计算机工程, 2022,48(12):224–231.
FAN Xinyue, BAO Hong, PAN Weiguo. Image instance segmentation method based on class-imbalanced dataset[J]. Computer Engineering, 2022,48(12):224–231. (in Chinese)
- [19] 柴文光,李嘉怡. 重加权在多类别不平衡医学图像检测中的应用[J]. 计算机工程与应用, 2022,58(8):237–242.
CHAI Wenguang, LI Jiayi. Application of re-weight method in multiple class-imbalance medical images detection[J]. Computer Engineering and Applications, 2022,58(8):237–242. (in Chinese)
- [20] DAI X, CHEN Y, XIAO B, et al. Dynamic head: unifying object detection heads with attentions[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition,2021: 7373–7382.
- [21] AKYON F C, ALTINUC S O, TEMIZEL A. Slicing aided hyper inference and fine-tuning for small object detection[C]//2022 IEEE International Conference on Image Processing (ICIP). IEEE, 2022: 966–970.
- [22] ESTER M, KRIEGLER H P, SANDER J, et al. A density-based algorithm for discovering clusters in large spatial databases with noise[C]//KDD, 2009:836–841.
- [23] WOLD S, ESBENSEN K, GELADI P. Principal component analysis[J]. Chemometrics and Intelligent Laboratory Systems, 1987, 2(1–3): 37–52.
- [24] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers[C]//European Conference on Computer Vision. Cham, 2020: 213–229.
- [25] DUAN K, BAI S, XIE L, et al. Centernet: keypoint triplets for object detection[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 6569–6578.
- [26] ZHU X, LYU S, WANG X, et al. TPH – YOLOv5: improved YOLOv5 based on transformer prediction head for object detection on drone-captured scenarios[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 2778–2788.
- [27] JAIN A K. Data clustering: 50 years beyond K-means[J]. Pattern Recognition Letters, 2010, 31(8): 651–666.
- [28] HALL A V. Methods for demonstrating resemblance in taxonomy and ecology[J]. Nature, 1967, 214(5090): 830–831.
- [29] DEREK Y. Least-squares fitting of a straight line[J]. Canadian Journal of Physics, 1966, 44(5):1079–1086.
- [30] FISCHLER M A, BOLLES R C. Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography[J]. Communications of the ACM, 1981, 24(6): 381–395.