网络首发时间：2026-03-19 14:53:02　网络首发地址：https://link.cnki.net/urlid/11.2047.S.20260318.1657.002

基于深度学习的槟榔黄化病感病植株无人机遥感精准识别

侯　瑞[1,2,3]，张弼尧[1,2※]，徐少雄[1,4]，董莹莹[1]

（1. 遥感与数字地球全国重点实验室，中国科学院空天信息创新研究院，北京 100101；2. 海南省地球观测重点实验室，海南空天信息研究院，文昌 571300；3. 中国科学院大学，北京 100049；4. 中国城市规划设计研究院，北京 100044）

摘　要：槟榔黄化病是一种严重危害槟榔生长的系统性病害，实现感病植株的精准监测对于槟榔产业的可持续发展至关重要。针对当前槟榔黄化病感病植株无人机遥感识别精度较低，易受变色灌木等相似地物目标干扰的问题。该研究基于无人机搭载 RedEdge-M 多光谱相机所获得的 5 波段多光谱遥感影像数据，通过计算欧式距离和 J-M (Jeffreys-Matusita) 距离，结合可分性分析提取敏感光谱指标；基于影像标准化预处理、样本切片及人工核验筛选构建标准化检测数据集，共获取 18 520 个高质量样本，按照 8:1:1 的比例划分训练集、验证集与测试集，之后通过改进 YOLO (You Only Look Once) v10 算法获取感病植株精准识别模型。模型在主干网络中引入 GhostNet 以增强关键波段的有效信息表达并提升对细粒度病征纹理的建模能力，采用双向特征金字塔网络（bidirectional feature pyramid network, BiFPN）强化复杂林分环境下的多尺度特征聚合效果，引入形状感知型 交并比（shape-aware **i**ntersection **o**ver **u**nion, SIoU），通过边界框回归机制提高病株定位精度。结果表明，改进 YOLOv10 模型跨尺度特征融合能力增强使 mAP@0.5 提升至 90.6%，相较于相较于最优基线模型 YOLO v10 提升了 4.5 个百分点；用户精度为 91.2%，召回率为 92.7%，均优于其他经典深度学习模型。该模型实现了对槟榔黄化病感病植株的快速、准确检测，可满足槟榔黄化病巡查与监测的实际应用需求。

关键词：无人机；遥感；多光谱影像；深度学习；特征增强；精准识别；槟榔黄化病

doi：10.11975/j.issn.1002-6819.202512027

中图分类号：S435.122+.2　　**文献标志码：**A　　**文章编号：**1002-6819(2026)-06-0001-09

侯瑞，张弼尧，徐少雄，等. 基于深度学习的槟榔黄化病感病植株无人机遥感精准识别[J]. **农业工程学报**，2026，42(6)：1-9. doi: 10.11975/j.issn.1002-6819.202512027　http://www.tcsae.org

HOU Rui, ZHANG Biyao, XU Shaoxiong, et al. Precision identification of arecanut yellowing disease infected plants using UAV remote sensing and deep learning[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2026, 42(6): 1-9. (in Chinese with English abstract)　doi: 10.11975/j.issn.1002-6819.202512027　http://www.tcsae.org

0　引　言

槟榔主要生长在热带和亚热带地区，是海南省的第一大热带经济作物。槟榔黄化病是一种由植原体感染引起的系统性病害，可致槟榔叶片黄化、枯萎，具有传播快、防治难等突出特点[1]。近年来槟榔黄化病在海南省各地频发和蔓延，导致槟榔产量和品质下降，严重影响了槟榔产业的健康发展和农民增收[2]。因而，如何快速、高效地实现病害发生情况及空间分布的精准监测，对于强化槟榔黄化病的防治及稳定槟榔种植生产具有重要现实意义。

相较于工作效率偏低的传统地面人工调查，遥感技术具有获取地物信息高效快捷，探测范围广等突出优势[3]。其中，无人机遥感可以灵活获取数据，并能够根据需求自主调整时空分辨率，已经在病虫害监测领域得到了广泛的应用[4-5]。由于海南省多云雨天气，显著影响卫星光学遥感成像质量与可用性，因而可将无人机影像作为重要数据源以开展槟榔黄化病监测。

植被在生物或非生物胁迫下会产生形态颜色和生理功能的变化[6]，从而导致一系列的光谱响应，如近红外区域反射率减少以及红边蓝移等表征[7-8]。依据上述理论，相关学者通过分析无人机遥感影像中的冠层光谱特征来区分植被的感染情况。赵晋陵等[9] 基于 3 类感病样本进行对比分析，通过最小冗余最大相关算法提取敏感光谱特征，利用后向传播神经网络分类算法构建了槟榔黄化病严重度监测模型；LEI 等[10] 利用无人机多光谱遥感影像，将经典植被指数融入支持向量机算法以区分不同感病程度槟榔树，研究结果表明整体分类精度可达 86.57%；吉文翰等[11] 基于多时相无人机多光谱遥感影像，选取经典植被指数，基于多元线性回归和随机森林方法构建水稻产量预测模型；ZENG 等[12] 基于无人机多光谱遥感影像进行分析，通过皮尔逊相关分析探究敏感特征波段组合，采用随机森林和支持向量机方法构建橡胶白粉病严重程度模型，总体识别准确率达 88.32%。这些研究证实了光谱特征在植被病虫害监测中的有效性，然而，仅依靠光谱特征无法充分挖掘影像信息，检测结果中往往会混入大量与病害植株光谱特征相似的目标，难以实现感病植株精准识别。

收稿日期：2025-12-03　修订日期：2026-02-24
基金项目：海南省自然科学基金青年基金项目（322QN346）
作者简介：侯瑞，博士生，研究方向为植被病虫害遥感监测。
Email：hourui21@mails.ucas.ac.cn
※通信作者：张弼尧，博士，助理研究员，研究方向为植被病虫害遥感监测。 Email: zhangby@aircas.ac.cn

深度学习在遥感中的应用主要包括像素级分类、目标识别与场景理解等方向，其中槟榔黄化病感病植株检测属于目标识别研究范畴[13]。与单次多框检测器（single shot detector，SSD）、更快速的基于区域的卷积神经网络（faster region-based convolutional neural network，Faster R-CNN）等两阶段目标检测算法相比，YOLO（You Only Look Once）通过单次前向传播即可完成目标定位与分类，具备显著的实时性优势[14]。自 2016 年提出以来，YOLO 系列不断演进。YOLOv5 通过 C3 结构实现轻量化，但由于过于依赖锚框，易产生大量冗余降低识别效率[15]。YOLOv8 采用加速型 C2 模块（Convolution 2 Faster, C2f）增强梯度流，引入无锚策略以提升检测效率，但仍依赖后处理与非极大值抑制[16]。2024 年 WANG 等[17]提出 YOLOv10，通过一致的双重分配策略实现真正的端到端检测，彻底摆脱非极大值抑制（non-maximum suppression，NMS）依赖，大幅提升推理速度。相关学者以 YOLO 系列模型为基础框架，通过引入协同特征融合模块及动态注意力机制显著提升了典型植被病虫害识别性能[18-21]，针对地物目标识别展现出良好的应用潜力。然而，目前鲜有基于深度学习实现槟榔黄化病监测识别的研究，传统机器学习模型对于槟榔黄化病感病植株检测的识别精度及鲁棒性仍有待进一步验证。

因此，本研究利用无人机多光谱遥感数据，基于敏感光谱特征提取构建标准化检测数据集，协同深度学习策略构建槟榔黄化病感病植株精准识别模型，以期为海南省槟榔黄化病大面积快速监测预警与精准防控提供核心技术支撑。

1 数据和方法

1.1 研究区概况

研究区位于海南省万宁市北大镇的一处槟榔林（18°54'41.62" N，110°17'46.03" E）。该地属热带季风气候，年平均气温 24.8 ℃，年降水量约 2 100 mm，区域内以红壤土和沙壤土为主。作为海南省槟榔种植面积最大的地区，万宁市 2024 年种植面积达 236.67 km^2，约占海南全省槟榔种植面积的 50%，槟榔黄化病在万宁市平均发病率高达 41.3%[22]，对当地槟榔产业的可持续发展造成了严重威胁。因而，本研究选取水肥条件良好的试验地开展野外采样及遥感监测工作。此外，通过前期与相关工作人员进行实地核查，确认研究区内的槟榔黄化现象主要由黄化病导致。

1.2 数据获取及处理

1.2.1 地面样点数据采集

地面调查于 2024 年 12 月 13 日 10:30－12:30 进行，结合实地观测情况，共选取 70 株代表性样木进行采样。试验区域总面积为 5.6 km^2，槟榔树高 10～15 m。首先通过目视观察初步评估槟榔感病程度，并通过高精度 GPS 和 RTK 实现试验样株定位；之后在距槟榔树冠层高约 10 m 处进行垂直向下的无人机航拍，基于影像像元分析计算叶片黄化面积占植株冠层面积的百分比。鉴于目前尚无槟榔黄化病划分的行业标准，参照相关研究[9-10]将发生严重度划分为 3 个等级：健康（1%），轻度（1%～10%），重度（≥10%），样本数分别为 21、26、23。

1.2.2 无人机遥感数据获取与预处理

本研究使用大疆 Phantom 4 四旋翼无人机，搭载美国 Micasense 公司的 RedEdge-M 多光谱相机进行无人机航摄。该相机可同时获取可见光波段、近红外波段和红边波段等 5 个波段的数据。无人机航拍试验在晴朗无风的天气下开展，通过地面放置的标准白板以及相关控制点进行后续的反射率校正处理。为获取高质量影像数据，在正式航拍前需进行航线规划，使无人机按照预设航线完成拍摄工作，飞行范围覆盖整个试验区域。飞行航高设定为 60 m，航速为 7 m/s，可见光影像空间分辨率为 4 cm，多光谱影像空间分辨率为 6 cm，旁向重叠率的航向重叠率均设定为 85%。通过多次无人机航拍批量化获取多光谱原始影像数据。之后利用 Pix4D Mapper 软件完成辐射校正、大气校正、几何校正与影像拼接等预处理，并通过锐化滤波器来增强图像中物体的特征点[23]。在剔除异常数据后，共获取 940 张标准化无人机多光谱图像。

将其作为初始数据集，按照 8:1:1 的比例随机分为训练集、验证集和测试集。为进一步增强模型的鲁棒性和泛化能力，采取数据增广以实现样本量扩充。由于无人机影像中树冠的直径小于 256×256 像素，因而本研究通过滑动窗口将现有的图像裁剪为 256×256 大小的标准影像切片。在人工检核数据质量并筛选后，共获取 18 520 张图像，按照 8:1:1 划分训练集、验证集和测试集。该数据集使用开源标注工具进行了标注，通过绘制多矩形框以划定不同感染程度的槟榔黄化病感病植株的树冠边界，针对健康（healthy，H）、轻度黄化（mild，M）、重度黄化（severe，S）3 种类型的槟榔植株进行标注（图 1）。

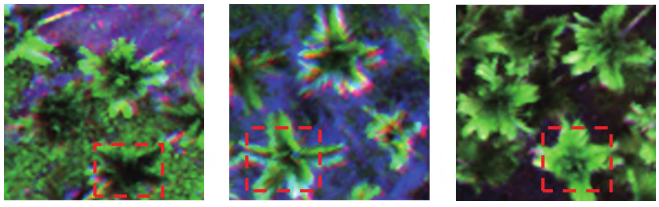

a. 健康 a. Healthy　b. 轻度黄化 b. Mild yellowing　c. 重度黄化 c. Severe yellowing

图 1 不同类型槟榔树标注

Fig.1 Annotation of different type of areca palm

1.3 研究方法

1.3.1 感病植株光谱特征提取方法

1）欧氏距离（Euclidean distance，ED）

本研究采用欧式距离来定量评价多光谱无人机影像各波段识别槟榔黄化病感病植株的能力。光谱曲线如果在某波段范围内出现明显变化，形成了健康槟榔树与感病植株间的光谱差异，该波段范围就可以作为识别槟榔黄化病感病植株的敏感波段。采用距离分析法判断各试验组观测值间的差异大小：相对距离越大，数据差异越大；反之则数据差异越小[24]。

2）J-M（Jeffreys-Matusita）距离

J-M 距离在遥感监测研究中常用于表示地物类别的可分性，它是基于条件概率密度的可分性度量标准。本研究利用 J-M 距离，用于区分健康槟榔树与感病植株的可分性。J-M 距离的标准区间为 [0,2]，若 J-M 距离≤1.0 说明待分类的地物类别之间不具备光谱可分性；若 1.0<J-M 距离<1.9 说明待分类的地物类别之间具备一定的光谱可分性；若 J-M 距离≥1.9 说明待分类的地物类别之间具备较好的光谱可分性[25]。

1.3.2　深度学习样本数据集

无人机多光谱影像预分析结果表明，蓝光、绿光、红光、近红外（NIR）和红边波段在不同变色程度的槟榔黄化病感病植株与健康槟榔树之间均表现出显著差异，典型植被指数归一化差值植被指数（normalized difference vegetation index，NDVI）和归一化红边差值指数（normalized difference red edge，NDRE）对于不同类型样本呈现出良好的分类效果。为进一步探究相应波段和典型植被指数在槟榔黄化病感病植株识别中的实际应用效果，分别构建 4 种用于模型训练的典型数据集（表 1）。

表 1　模型检测数据集

Table 1　Band combinations of the datasets

数据集名称 Dataset name	波段组合 Band combination
数据集 1（RGB）	R, G, B
数据集 2（原始反射率组）	R, G, B, Red edge, NIR
数据集 3（NDRE 组）	R, G, B, Red edge, NIR, NDRE
数据集 4（NDVI 组）	R, G, B, Red edge, NIR, NDVI

1.3.3　基于深度学习的感病植株智能识别

1）改进 YOLOv10 算法模型结构

改进 YOLOv10 网络结构主要分为 Input 输入端、Backbone 骨干神经网络、Neck 混合特征网络层和 Head 预测层网络共 4 个部分[26]，具体如图 2 所示。

针对 YOLOv10 存在误检及漏检率高、目标定位不精确等问题，对 YOLOv10 算法进行改进。具体如下：

ⅰ）Ghostconv 模块

GhostNet 卷积模块通过线性变换生成冗余特征图的创新方式，在显著降低模型参数量和计算量的同时，仍能保持较高的特征表达能力[27]。因而本研究采用 GhostNet 卷积模块替代 YOLOv10 中的基础卷积层，以实现模型轻量化目标。通过特征重参数化技术，在保持输出维度不变的前提下，将计算量降低约 s 倍；通过双路径特征融合机制，既完整保留了原始输入的空间特征细节，又整合了线性变换提取的深层特征；有效实现计算效率与特征表达能力的平衡。

ⅱ）BiFPN 模块

双向特征金字塔网络（bidirectional feature pyramid network，BiFPN）是在传统特征金字塔结构的基础上发展而来的高效多尺度特征融合机制，该结构通过移除仅具单输入的冗余节点、引入同层级的额外连接并将自顶向下与自底向上的双向路径设计为可重复堆叠的特征网络层，实现了更高效的跨尺度信息交互[28]。此外，BiFPN 利用可学习权重区分不同尺度特征对融合结果的贡献，解决了先前不同分辨率特征被无差别处理的问题。

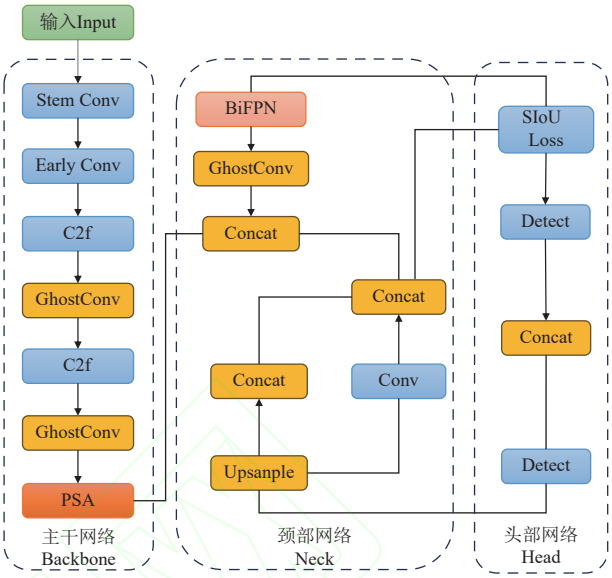

注：Conv 为卷积；Concat 为特征拼接模块；Unsample 为上采样模块；Stem Conv 为起始特征提取模；Early C2f 为高分辨率特征整合层；C2f 为跨阶段部分聚合；GhostConv 为改进的 Ghostconv 模块；PSA 为分通道局部自注意力模块；BiFPN 为改进双向特征金字塔模块；Detect 为检测头；SIoU Loss 为边界框损失函数。

Note: Conv is convolution; Concat is feature concatenation module; Upsample is upsampling module; Stem Conv is initial feature extraction module; Early C2f is high-resolution feature integration layer; C2f is cross-stage partial aggregation; GhostConv is improved GhostConv module; PSA is channel-wise local self-attention module; BiFPN is improved bidirectional feature pyramid network module; Detect is detection head; SIoU Loss is bounding box loss function.

图 2　改进 YOLOv10 结构网

Fig.2　Architecture of the improved YOLOv10 network

ⅲ）SIoU 边界框损失函数

边界框损失函数用于衡量模型预测框与真实目标框之间的几何差异程度，传统损失函数主要依赖交并比及中心距离等信息，对边界框的几何形态约束不足。而形状感知交并比[29]（shape-aware intersection over union，SIoU）损失函数通过综合考虑面积、距离的基础上，引入角度和形状等几何因素，使边界框优化过程更加全面和敏感。

首先，SIoU 通过引入角度损失项来刻画预测框中心相对真实框中心的偏移方向。设预测框与真实框的中心坐标分别为 (x^r,y^r)与 (x^t,y^t)，其中心距离为

$$\sigma = \sqrt{(x^r - x^t)^2 + (y^r - y^t)^2} \tag{1}$$

并以

$$\sin\alpha = \frac{c_i}{\sigma} \tag{2}$$

构建角度权重项，从而得到角度损失 A：

$$A = \sin(2\alpha) \tag{3}$$

通过指数衰减方式构建归一化距离损失 B：

$$B = 2 - e^{-\sigma} \tag{4}$$

所构建损失项能够促使预测框在回归过程中沿正确方向靠近真实目标，提高收敛的方向一致性；同时使得预测框在靠近真实框中心时具有更平滑的下降趋势，有

利于提升训练的稳定性。

式中c_i表示预测框及真实框中心点的垂直距离，σ表示预测框及真实框中心点二维平面的欧几里得距离，α表示预测框中心点与真实框中心点连线形成的夹角。

此外，SIoU 还引入了形状损失项以描述预测框与真实框之间的宽高比例偏差 Ω。具体形式为

$$\Omega = (1-e^{-\tau_w})^{\theta} + (1-e^{-\tau_h})^{\theta} \quad (5)$$

式中θ表示控制形状损失在总损失中的关注程度，τ_w和τ_h分别表示预测框与真实框在宽度和高度上的归一化差异。它们具体的表达式为

$$\tau_w = \frac{|w^{GT}-w|}{\max(w^{GT},w)}, \tau_h = \frac{|h^{GT}-h|}{\max(h^{GT},h)} \quad (6)$$

式中w^{GT}表示真实框宽度，w表示预测框宽度，h^{GT}表示真实框高度，h表示预测框宽度。

2）评价指标

本研究选用 IoU 评估目标检测模型的性能，以确定模型的精准率和召回率等关键指标[30]。IoU 的取值范围为 [0,1]，IoU 值大于 0.5，就表示预测框和真实框重合程度较高，检测算法的准确度也越高，在检测任务中，IoU 不仅用于评估单个目标的检测质量，还可以帮助筛选预测框。其余精度评价指标包括准确率（accuracy）、用户精度（precision，P）、召回率（recall，R）和平均精度（mean average precision，mAP@0.5）[30]。其中，P 是真实目标占网络预测目标总数的比例，表示该网络的分类准确率；R 是网络成功预测真目标数与实际真目标数的比值[30]。

2 结果与分析

2.1 槟榔黄化病感病植株敏感光谱特征提取

本研究的多光谱数据波段范围为 475 nm（蓝）、560 nm（绿）、668n（红）、717 nm（红边）、840 nm（近红外）。定量分析 3 条曲线在各波段范围内的变化差异，以健康槟榔叶片的光谱曲线为基准，通过欧氏距离公式计算 2 种不同变色染病程度的槟榔叶片光谱曲线与健康槟榔叶片光谱曲线的相对距离。如表 2 所示，在区分健康槟榔叶片和 2 种不同黄化程度槟榔叶片的表现上，红边波段最为敏感，其次是近红外波段、绿波段和红波段，最不敏感的为蓝波段。

表 2 健康与不同黄化槟榔叶片光谱曲线的欧氏距离

Table 2 Euclidean distance (ED) between the spectral signatures of healthy and yellowing arecanut leaves

波段 Band	ED（H-M）	ED（H-S）	可分性 Separability
蓝 Blue	0.85	1.38	中等可分性
绿 Grenn	1.23	1.67	较好可分性
红 Red	1.02	1.62	较好可分性
近红 Near infrared	1.53	1.68	无可分性
红边 Red edge	1.22	1.83	最优可分性

注：H、M、S 分别代表健康、轻度黄化、重度黄化槟榔叶片。下同。

Note: H, M, S represent healthy, mild yellowing, severe yellowing arecanut leave,respectively. Same below.

同时，本研究还利用典型光谱指数计算健康槟榔叶片与不同变色程度槟榔叶片的可分性。以健康槟榔叶片光谱数据计算得到的指标为基准，使用 J-M 距离公式计算光谱指数识别不同变色程度的槟榔叶片可分性（表 3）。

表 3 典型光谱指数及其区分健康与不同黄化槟榔叶片的 J-M 距离

Table 3 Typical spectral indices and their J-M(Jeffreys-Matusita) distances for healthy and yellowing arecanut leaves

植被指数 Vegetation index	公式 Formula	来源 Source	JM（H-M）	JM（H-S）
归一化差分植被指数 Normalized difference vegetation index (NDVI)	R_{nir} - R_{red} / R_{nir} + R_{red}	[31]	2.00	2.00
红色植被指数 Normalized green–red difference index (NGRDI)	R_{gre} - R_{red} / R_{gre} + R_{red}	[31]	2.00	1.82
重归一植被指数 Renormalized difference iegetation index（RDVI）	$(R_{nir}-R_{red})-(\sqrt{R_{nir}+R_{red}})$	[32]	1.85	2.00
改进型比值植被指数 Modified ratio vegetation index (MRVI)	$(R_{nir}/R_{red}-1)/\sqrt{R_{nir}/R_{red}+1}$	[33]	1.65	1.23
优化土壤调节植被指数 Optimized soil adjusted vegetation index (OSAVI)	$1.16[(R_{nir}_R_{red})/(R_{nir}+R_{red}+0.16)]$	[33]	1.57	1.32
归一化差分红边植被指数 Normalized difference red-edge vegetation index（NDRE）	$(R_{nir}-R_{red\ edge})$ / $(R_{nir}+R_{red\ edge})$	[34]	2.00	1.97
红边叶绿素植被指数 Red-edge chlorophyll vegetation index（RECl）	$(R_{nir}/R_{red\ edge})$ - 1	[35]	1.98	1.97

注：R_{gre} 为绿光波段反射率，R_{red} 为红光波段反射率，$R_{red\ edge}$ 为红边波段反射率，R_{nir} 为近红外波段反射率。

Note: R_{gre} is the green band reflectance, R_{red} is the red band reflectance, $R_{red\ edge}$ is the red edge band reflectance, R_{nir} is the near-infrared band reflectance.

研究结果表明，NDVI、NDRE2 项光谱指数在区分健康槟榔叶片与轻度黄化槟榔叶片、重度黄化槟榔叶片时均呈现出良好效果，J-M 距离均大于 1.95，光谱可分性出色。因而选取这两项典型指标与相关敏感波段共同构建样本数据集，应用于后续的模型训练及识别检测中。

2.2 试验环境与评价指标分析

利用所构建的 4 组模型检测数据集，将本研究所构建的改进 YOLOv10 模型与代表性两阶段目标检测模型 Faster R-CNN 及一阶段目标检测模型 YOLOv8、YOLOv10 检测算法进行对比分析，以验证改进模型的优化效果。研究结果表明（表 4），基于数据集 4 训练模型可获得显著优于其他数据集的识别平均精度，同时改进 YOLOv10 模型针对全部数据集均呈现出了最佳识别效果，其在数据 4 上的 mAP@0.5 值为 90.6%，相较于仅使用原始反射率数据训练提升了 10.6 个百分点;改进 YOLOv10 模型在数据集 4 的收敛次数相较于其他模型显

著减少。这也证实了结合敏感光谱特征与改进 YOLOv10 算法，能够构建出对于槟榔黄化病感病植株识别效果良好的智能检测模型。

为进一步探究各功能模块对于感病植株识别的具体贡献，使用数据集 4 进行改进 YOLOv10 模型的消融试验。表 5 的试验结果表明，Ghostconv 模块基于特有的双路径特征融合机制有效提升了检测精度（*P*、*R*、mAP@0.5 分别提升至 88.4%、89.1%、89.1%）。BiFPN 模块则通过引入更强的注意力机制，增强了对关键病害特征的聚焦能力，使模型的召回率提升至 89.8%。SIoU 损失函数主要优化了边界框的几何回归，使定位更稳定。进一步地，当 Ghostconv、BiFPN 与 SIoU 模块组合使用时，模型的多尺度特征融合能力和全局特征提取能力均得到增强。其中，最终的改进 YOLOv10 模型，*P* 达到 91.2%，*R* 达到 92.7%，mAP@0.5 达到 90.6%，相较于最优基线模型 YOLOv10 分别提升 4.0、4.2、4.5 个百分点。这充分验证了本研究提出的改进策略在提高模型稳定性、特征提取能力以及综合检测性能方面的有效性。

表 4　不同模型试验结果对比

Table 4　Comparison of experimental results across different models

模型 Model	数据集 Dataset	*P*/%	*R*/%	mAP@0.5/%	收敛次数 Convergence speed (Epochs)
Faster RCNN	1	81.5	69.7	65.2	98
	2	82.9	83.6	85.3	92
	3	85.7	86.8	87.9	85
	4	86.2	87.7	89.4	81
YOLOv8	1	61.1	69.5	61.0	85
	2	70.0	72.3	70.2	83
	3	70.1	67.8	71.2	80
	4	80.0	75.1	73.1	76
YOLOv10	1	84.8	80.4	78.3	72
	2	83.1	80.3	82.1	65
	3	85.2	87.2	85.3	60
	4	87.2	88.5	86.1	57
改进 YOLOv10 Improved YOLOv10	1	85.7	80.3	79.2	66
	2	84.4	85.8	80.0	60
	3	89.6	90.1	88.5	56
	4	91.2	92.7	90.6	51

注：*P* 为用户精度；*R* 为召回率；mAP@0.5 为平均交并比 IoU 为 0.5 的平均精度均值，下同。
Note: P is the precision (user's accuracy); R is the recall; mAP@0.5 represents the mean average precision at an intersection over union (IoU) threshold of 0.5; the same applies hereafter.

表 5　对最优模型（改进 YOLOv10）进行不同改进消融的试验结果

Table 5　Ablation experiments for different modifications to the optimal model (improved YOLOv10)

Ghostconv	BiFPN	SIoU	*P*/%	*R*/%	mAP@0.5/%
			87.2	88.5	86.1
√			88.4	89.1	89.1
	√		87.8	89.8	86.6
		√	88.2	88.7	86.4
√		√	89.6	89.9	87.3
√	√		90.5	91.6	90.1
	√	√	88.7	90.1	87.2
√	√	√	91.2	92.7	90.6

注：√代表使用该策略，空白为不使用该策略。
Note: √ indicates the inclusion of the strategy, while a blank indicates its absence.

在此基础之上，基于测试数据集对于不同模型的识别效果进行检验。表 6 的试验结果表明，改进 YOLOv10 在预测数据集上的识别效果最为优异。在重度黄化感病植株识别中，改进 YOLOv10 共检测到 94 株疑似病树，其中 82 株为正确识别，错检 12 株，漏检 16 株。精确率为 87.23%，召回率为 83.67%，mAP@0.5 为 88.90%，均优于其他模型。在轻度黄化感病植株识别中，模型共检测出 78 株，其中 62 株正确识别，错检 16 株，漏检 21 株。在该类型感病植株中模型检测的精确率为 79.49%，召回率为 74.7%，mAP@0.5 为 69.52%，相较于 YOLOv10 和 YOLOv8 也表现出更高的稳定性。试验结果表明，针对 YOLOv10 架构的优化（如 Ghostconv、BiFPN 与 SIoU 模块的融合）有效提升了特征提取能力和多尺度融合效果，从而带来了更高的检测精度和更稳健的识别性能。

表 6　不同模型在预测数据集上的识别精度分析

Table 6　Identification accuracy analysis of different models on the prediction dataset

模型 Model	识别类型 Type of infection	*P*/%	*R*/%	mAP@0.5/%
Faster RCNN	轻度感病	70.49	53.75	65.8
	重度感病	76%	61.29	68.36
YOLOv8	轻度感病	74.07	53.33	62.85
	重度感病	77.78	59.76	64.7
YOLOv10	轻度感病	73.61	63.86	66.94
	重度感病	79.22	63.54	68.89
改进 YOLOv10 Improved YOLOv10	轻度感病	79.49	74.7	69.52
	重度感病	87.23	83.67	88.9

值得注意的是，改进 YOLOv10 模型可能是由于新增的注意力模块增加了模型的结构复杂性与参数量，导致其推理时延增加，从而在一定程度上影响了整体检测工作的效率。因而，在未来的研究中，应当更加深入地探究 YOLOv10 的架构，以便根据特定应用需求实现模型定制以提升实际工作效率。

为了进一步验证改进 YOLOv10 模型的识别效果，将其与最优基线模型 YOLOv10 进行可视化对比，结果如图 3 所示。对比分析识别效果后可以看出，基线模型由于缺乏 Ghostconv 及 BiFPN 模块独有的深层次空间特征提取及多尺度特征融合能力，其整体识别性能有限，易受到相似光谱特征地表覆盖物影响而导致错检实例偏多（如图 3 中圆圈所示），同时其相较于改进 YOLOv10 模型更容易混淆健康及轻度感病植株。改进 YOLOv10 模型相较于原模型总体的置信度有所提高，同时针对感病植株的识别更加高效和准确，这也充分说明了本研究改进策略在提升模型鲁棒性和识别性能方面的有效性。

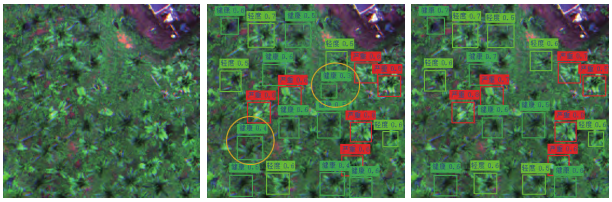

a. 原图　b. YOLOv10模型　c. 改进YOLOv10 模型
a. Original image　b. YOLOv10 model　c. Improved YOLOv10 model

注：圆圈代表误检区域。
Note: Circles denote false detection areas.

图 3　模型识别对比结果

Fig.3　Comparison of model identification results

3 讨 论

当前针对槟榔黄化病感病植株监测的研究方法依赖于通过人工构建特征集，基于经典机器学习算法完成目标分类判识[9-10]。然而这种分类模式存在较强的主观性，同时仅仅依据浅层光谱特征构建分类规则，没有充分利用待检测目标的深层次空间结构特征，整体检测识别精度仍有很大的提升空间。本研究以深度学习算法YOLOv10为基础，通过在网络结构中引入Ghostconv特征提取模块与BiFPN机制，使其能够更精确地挖掘提取槟榔黄化病病株的细粒度纹理与光谱特征；同时，使用SIoU边界框损失函数提升预测边界框的稳定性和低冗余性，进一步提升模型运行效率及回归精度。改进YOLOv10模型相较于最优基线模型YOLOv10的mAP@0.5提升约4.5个百分点，同时用户精度提升至91.2%，召回率提升至92.7%。对于感病植株的检测精度优于其他应用YOLOv10模型进行农林病虫害遥感检测的研究[36-37]，这也充分说明了改进YOLOv10模型在槟榔黄化病感病植株识别中的有效性，为实现快速、准确的感病植株检测提供了技术支撑。

此外，本研究也针对深度学习模型所使用的训练数据集进行了优化。基于J-M距离公式计算了典型光谱指数的地物类别可分性，发现NDRE及NDVI能够进一步增强感病植株与其他地物间的差异性，这与LEI等[10]和ZENG等[12]的研究结果相吻合。利用上述植被指数对于原始训练数据集进行光谱特征增强后，将优化数据集作为输入应用于模型训练，相较于未优化的原始反射率数据，模型识别的mAP@0.5提升了10.6个百分点。典型植被指数进一步丰富了深度学习模型的深层次特征提取信息，模型通过融合光谱-空间特征，对于待检测目标具有了更为全面的认知，从而有效提升了模型的识别性能。

然而，YOLOv10模型在槟榔树黄化病实际监测中仍存在一些不足。首先，无人机影像获取受天气与光照影响显著，模糊或过亮的图像会降低模型对病害细节的识别准确性。其次，槟榔树出现叶片泛黄还可能受到如营养缺乏、干旱胁迫或虫害等影响，这些都会干扰模型对黄化病的判断[38]。因此，为削弱光照与大气变化对光谱真实性的影响，在进行严格的辐射校正基础之上，未来还应当进一步探索采用双通道或多角度观测技术以归一化双向反射分布函数效应[39]，或在模型中引入光照不变性特征[40]，以增强识别模型的鲁棒性，同时结合系统性地面调查明确病因，从而减少辨识干扰。

在后续研究中，为实现对槟榔黄化病不同程度感病植株的精细化分类，有必要进一步结合高光谱数据，以捕捉更多病叶生理与光谱细节。为进一步强化模型在实际应用中的泛化性，未来的研究还可以从以下方面进行：1）探究Transformer或状态空间模型架构[41]，以提升模型对上下文信息的理解能力；2）补充建立包含干旱、缺素等其他胁迫症状的综合样本数据集，通过迭代自适应训练优化模型，以强化模型的鲁棒性和特异性；3）通过在不同地域开展多点验证，检验并提升模型跨区域、跨生育期的适应性，以全面提升槟榔黄化病监测的智能化与业务化水平。

4 结 论

1) 本研究通过定量分析，以健康槟榔叶片光谱曲线为基准，利用欧氏距离计算轻度与重度黄化槟榔叶片相对距离。结果表明，用于区分不同病害程度的最敏感波段为红边波段（717 nm），其次为近红外波段（840 nm）、绿光波段（560 nm）和红光波段（668 nm），最不敏感的是蓝光波段。这说明红边与近红外区是识别槟榔黄化病的关键波段，具有显著特征差异，从而强化了不同感病程度槟榔树的可区分性。

2) 本研究基于槟榔黄化病敏感波段与具有良好可分性的植被指数构建了4组训练数据集，并分别比较深度学习模型在相应数据集上呈现出的识别性能。结果表明，相较于仅使用原始波段的数据集而言，改进YOLOv10模型在引入敏感植被指数NDRE后，对于槟榔树识别的P、R、mAP@0.5分别提升了6.8、6.9、10.6个百分点，略优于模型在数据集3（NDVI）的识别效果。这也证实了在构建数据集中引入高可分性的敏感植被指数，能够进一步强化模型对于不同类别识别目标的特异性特征提取能力，从而有效提升识别精度。

3）本研究基于改进YOLOv10模型实现不同感病程度槟榔识别。试验结果表明，使用改进YOLOv10模型具有最优识别效果。该模型P、R、mAP@0.5分别提升至91.2%、92.7%、90.6%，相较于最优基线模型YOLOv10分别提升了4.0、4.2、4.5个百分点。改进YOLOv10模型通过降低冗余参量显著提升了模型运行效率，同时基于自身强大的多尺度特征融合机制实现了感病植株多维度特征的深层次提取，优化了模型的识别能力。

[参 考 文 献]

[1] 车海彦，罗大全. 槟榔黄化病研究进展[J]. 中国热带农业，2022(2)：36-42.
CHE Haiyan, LUO Daquan. Progress in research on areca yellow leaf disease[J]. China Tropical Agriculture, 2022(2): 36-42. (in Chinese with English abstract)

[2] 何玉生. 槟榔黄化病防控的生态地球化学研究[J]. 热带地理，2024，44(1)：188-194.
HE Yusheng. Eco-geochemical research on the prevention and control of areca yellowing disease[J]. Tropical Geography, 2024, 44(1): 188-194. (in Chinese with English abstract)

[3] AZIZ D, RAFIQ S, SAINI P, et al. Remote sensing and artificial intelligence: revolutionizing pest management in agriculture[J]. Frontiers in Sustainable Food Systems, 2025, 9: 1551460.

[4] CHOOSUMRONG S, HATAITARA R, SUJIPULI K, et al. Bananas diseases and insect infestations monitoring using multi-spectral camera RTK UAV images[J]. Spatial Information

Research, 2023, 31(4): 371-380.

[5] HE Ya S, HUANG X, ZHOU D, et al. Identification of larch caterpillar infestation severity based on unmanned aerial vehicle multispectral and LiDAR features[J]. Forests, 2024, 15(1): 191.

[6] 张竞成，袁琳，王纪华，等. 作物病虫害遥感监测研究进展[J]. 农业工程学报，2012，28(20)：1-11.
ZHANG Jingcheng, YUAN Lin, WANG Jihua, et al. Progress of crop disease and insect pest monitoring by remote sensing[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2012, 28(20): 1-11. (in Chinese with English abstract)

[7] 黄文江，张竞成，黄林生，等. 植被病虫害遥感监测预警研究进展与展望[J]. 遥感学报，2025，29(6)：2065-2082.
HUANG Wenjiang, ZHANG Jingcheng, HUANG Linsheng, et al. Progress and prospects of remote sensing monitoring and early warning for vegetation pests and diseases[J]. Journal of Remote Sensing, 2025, 29(6): 2065-2082. (in Chinese with English abstract)

[8] 王宇唯，马旭，谭穗妍，等. 无人机遥感与地面观测的多模态数据融合反演水稻氮含量[J]. 农业工程学报，2024，40(18)：100-109.
WANG Yuwei, MA Xu, TAN Suiyan, et al. Inversion of rice nitrogen content by multi-modal data fusion of UAV remote sensing and ground observation[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2024, 40(18): 100-109. (in Chinese with English abstract)

[9] 赵晋陵，金玉，叶回春，等. 基于无人机多光谱影像的槟榔黄化病遥感监测[J]. 农业工程学报，2020，36(8)：54-61.
ZHAO Jinling, JIN Yu, YE Huichun, et al. Remote sensing monitoring of areca-nut yellowing disease based on UAV multispectral imagery[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2020, 36(8): 54-61. (in Chinese with English abstract)

[10] LEI S, LUO J, TAO X, et al. Remote sensing detecting of yellow leaf disease of arecanut based on UAV multisource sensors[J]. Remote Sensing, 2021, 13(22): 4562.

[11] 吉文翰，郑恒彪，王迪，等. 基于无人机影像和卷积神经网络的水稻育种材料产量预测研究[J]. 南京农业大学学报，2025，48(5)：1001-1012.
JI Wenhan, ZHENG Hengbiao, WANG Di, et al. Research on yield prediction of rice breeding materials based on UAV images and convolutional neural networks[J]. Journal of Nanjing Agricultural University, 2025, 48(5): 1001-1012. (in Chinese with English abstract)

[12] ZENG T, ZHANG H, LI Y, et al. Monitoring the severity of rubber tree infected with powdery mildew based on UAV multispectral remote sensing[J]. Forests, 2023, 14(4): 717.

[13] HUANG W, XIAO L, WEI Z, et al. A new pan-sharpening method with deep neural networks[J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(5): 1037-1041.

[14] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.

[15] LIU W, QUIJANO K, CRAWFORD M M. YOLOv5-Tassel: Detecting tassels in RGB UAV imagery with improved YOLOv5 based on transfer learning[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2022, 15: 8085-8094.

[16] CHITRANINGRUM N, BANOWATI L, HERDIANA D, et al. Comparison study of corn leaf disease detection based on deep learning YOLO-v5 and YOLO-v8[J]. Journal of Engineering and Technological Sciences, 2024, 56(1): 61-70.

[17] WANG C Y, LIAO H Y M. YOLOv1 to YOLOv10: The fastest and most accurate real-time object detection systems[J]. APSIPA Transactions on Signal and Information Processing, 2024, 13(1): e20.

[18] 贾雪莹，赵春江，周娟，等. 基于改进 YOLOv7 模型的柑橘表面缺陷在线检测[J]. 农业工程学报，2023，39(23)：142-151.
JIA Xueying, ZHAO Chunjiang, ZHOU Juan, et al. Online detection of citrus surface defects based on improved YOLOv7 model[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2023, 39(23): 142-151. (in Chinese with English abstract)

[19] 王娟，李斯睿，王春山，等. 基于改进 YOLOv8n 的轻量级番茄虫害检测模型[J]. 农业工程学报，2025，41(19)：185-195.
WANG Juan, LI Sirui, WANG Chunshan, et al. Lightweight tomato pest detection model based on improved YOLOv8n[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2025, 41(19): 185-195. (in Chinese with English abstract)

[20] CHANG W, YANG S, XI X, et al. Classification of seed maize using deep learning and transfer learning based on times series spectral feature reconstruction of remote sensing[J]. Computers and Electronics in Agriculture, 2025, 237: 110738.

[21] 叶秉良，丰睿，唐涛，等. 基于改进 YOLOv10n 的自然环境下莲蓬成熟度检测方法[J]. 农业工程学报，2025，41(22)：145-153.
YE Bingliang, FENG Rui, TANG Tao, et al. Detection method for lotus seedpod maturity in natural environment based on improved YOLOv10n[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2025, 41(22): 145-153. (in Chinese with English abstract)

[22] 牛晓庆，林兆威，杨德洁，等. 海南万宁槟榔黄叶病毒病发生情况和症状分析[J]. 热带作物学报，2021，42(11)：3073-3078.
NIU Xiaoqing, LIN Zhaowei, YANG Dejie, et al. Occurrence and symptom analysis of areca yellow leaf virus disease in Wanning, Hainan[J]. Chinese Journal of Tropical Crops, 2021,

42(11): 3073-3078. (in Chinese with English abstract)

[23] 龙开源，龙江平，林辉，等. 基于树冠精准分割和多源特征融合的无人机单木材积估测[J]. 农业工程学报，2025，41(16)：221-230.
LONG Kaiyuan, LONG Jiangping, LIN Hui, et al. UAV-based single tree volume estimation based on precise crown segmentation and multi-source feature fusion[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2025, 41(16): 221-230. (in Chinese with English abstract)

[24] 周正大，李如荣，贲智勤，等. 基于残差网络的遥感影像松材线虫病变色立木自动识别[J]. 林业工程学报，2022，7(5)：185-191.
ZHOU Z D, LI R R, BEN Z Q, et al. Automatic identification of Bursaphelenchus xylophilus from remote sensing imagery using residual network[J]. Journal of Forestry Engineering, 2022, 7(5): 185-191. (in Chinese with English abstract)

[25] 马娜，胡玉福，庄大方，等. 基于最佳指数和 J-M 距离的东莞市 HJ-1A 高光谱数据最佳波段组合研究[J]. 遥感技术与应用，2010，25(3)：358-365.
MA Na, HU Yufu, ZHUANG Dafang, et al. Determination on the optimum band combination of HJ-1A hyperspectral data in the case region of Dongguan based on optimum index factor and J-M distance[J]. Remote Sensing Technology and Application, 2010, 25(3): 358-365. (in Chinese with English abstract)

[26] 黄毅，周纯，刘欣军，等. 基于 YOLOv10 的无人机复杂背景下多尺度检测模型[J]. 光通信研究，2025(5)：45-52.
HUANG Y, ZHOU C, LIU X J, et al. Multi-scale detection model for UAVs in complex backgrounds based on YOLOv10[J]. Optical Communication Research, 2025(5): 45-52. (in Chinese with English abstract)

[27] HAN K, WANG Y, TIAN Q, et al. GhostNet: More features from cheap operations[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA: IEEE, 2020: 1580-1589.

[28] TAN M, PANG R, LE Q. Efficientdet: Scalable and efficientobject detection[C]//Proceedings of the IEEE/CVF Conferenceon Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA: IEEE, 2020: 10781-10790.

[29] REZATOFIGHI H, TSOI N, GWAK J, et al. Generalized intersection over union: A metric and a loss for bounding box regression[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach, CA, USA: IEEE, 2019: 658-666.

[30] ZHANG Z Z, LI J W, SU C W, et al. A method for counting fish based on improved YOLOv8[J]. Aquacultural Engineering, 2024, 107: 102450.

[31] 奥登，杨家辉，丁维婷，等. 54 种常用植被指数研究进展综述[J]. 安徽农业科学，2023，51(1)：13-21，28.
AODEN, YANG J H, DING W T, et al. A review of research progress on 54 vegetation indices[J]. Journal of Anhui Agricultural Sciences, 2023, 51(1): 13-21,28. (in Chinese with English abstract)

[32] DIYKH M, ALI M, JAMEI M, et al. Empirical curvelet transform based deep DenseNet model to predict NDVI using RGB drone imagery data[J]. Computers and Electronics in Agriculture, 2024, 221: 108964.

[33] DONG C, ZHAO G, MENG Y, et al. The effect of topographic correction on forest tree species classification accuracy[J]. Remote Sensing, 2020, 12(5): 787.

[34] RONDEAUX G, STEVEN M, BARET F. Optimization of soil-adjusted vegetation indices[J]. Remote Sensing of Environment, 1996, 55(2): 95-107.

[35] ROUJEAN J L, BREON F M. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements[J]. Remote Sensing of Environment, 1995, 51(3): 375-384.

[36] GUO X, YANG C, WANG Z, et al. Research on the Yunnan large-leaf tea tree disease detection model based on the improved YOLOv10 network and UAV remote sensing[J]. Applied Sciences, 2025, 15(10): 5301.

[37] QUE H, GAO H, SHAN W, et al. FM-SAM: individual tree crown delineation and classification based on segmentation anything model (SAM) and YOLOv10 in UAV imagery for forest monitoring[J]. Computers and Electronics in Agriculture, 2026, 240: 111162.

[38] PREMALATHA K. Exploring yellow leaf disease patterns in areca plantations in Chikkamagaluru District of Karnataka[J]. Saudi Journal of Pathology and Microbiology, 2024, 9(3): 63-70.

[39] ZHANG X, BI P, ZHOU Q, et al. Monitoring of yellow leaf disease (YLD) damage based on ground-based LiDAR and UAV multispectral data[J]. Computers and Electronics in Agriculture, 2025, 236: 110461.

[40] DEWANGAN U, TALWEKAR R H, BERA S. Illumination-invariant morphology-aware dual-branch segmentation with CNN feature fusion for robust cotton weed classification[J]. International Journal of Intelligent Engineering and Systems, 2025, 18(11).

[41] YEH C, CHEN Y, WU A, et al. Attentionviz: A global view of transformer attention[J]. IEEE Transactions on Visualization and Computer Graphics, 2023, 30(1): 262-272.

Precision identification of arecanut yellowing disease infected plants using UAV remote sensing and deep learning

HOU Rui[1,2,3] , ZHANG Biyao[1,2※] , XU Shaoxiong[1,4] , DONG Yingying[1]

(1. *State Key Laboratory of Remote Sensing and Digital Earth*, *Aerospace Information Research Institute*, *Chinese Academy of Sciences*, *Beijing* 100101, *China*;　2. *Key Laboratory of Earth Observation of Hainan Province*, *Hainan Aerospace Information Research Institute*, *Wenchang* 571300, *China*;　3. *University of Chinese Academy of Sciences*, *Beijing* 100049, *China*;　4. *China Academy of Urban Planning and Design*, *Beijing* 100044)

Abstract: Arecanut yellowing disease is a systemic disease that severely compromises the growth of *Areca catechu* palms, and the precise monitoring of infected plants is crucial for the sustainable development of the areca nut industry. Traditional monitoring methods, which primarily rely on visual inspection and manual surveys, are often inefficient and have a limited operational scope. Unmanned aerial vehicle (UAV) remote sensing, with its distinct advantages of high spatial resolution, flexible response capabilities, and low operational costs, offers an effective solution to the challenges posed by the frequent cloudy and rainy weather in Hainan, which often degrades the quality and availability of satellite optical imagery. However, current UAV-based remote sensing approaches for monitoring Areca yellowing disease still suffer from several limitations, including low identification accuracy and significant interference from similar ground objects, such as discolored shrubs. To address these challenges, this study began with field sampling to assess the disease severity of *A. catechu* palms. Based on the observed disease characteristics and the separability in remote sensing imagery. Subsequently, we employed a MicaSense RedEdge-M multispectral camera mounted on a DJI Phantom 4 Pro V2.0 UAV to acquire 5-band multispectral imagery, encompassing the blue, green, red, near-infrared, and red-edge bands. We then calculated the Euclidean and Jeffreys-Matusita (J-M) distances to extract sensitive spectral indices with high separability, which were subsequently used to construct four distinct datasets for training typical models. A comprehensive and standardized detection dataset was then established through a rigorous process of image preprocessing, sample slicing, and manual verification, resulting in a total of 18,520 high-quality samples. This final dataset was partitioned into training, validation, and test sets at a ratio of 8:1:1. A precise identification model for infected plants was developed by implementing a series of targeted improvements to the YOLO (You Only Look Once) v10 algorithm. First, GhostNet was incorporated into the backbone network. This lightweight feature generation mechanism enhances the representation of effective information from key multispectral bands, reduces redundant feature computations, and improves the modeling capability for fine-grained disease textures. Second, in the feature fusion stage, a bidirectional feature pyramid network (BiFPN) was employed to replace parts of the original feature pyramid structure. This modification, with its learnable weights and bidirectional cross-scale fusion, strengthens the multi-scale feature aggregation capabilities, particularly in complex forest stand environments. Finally, the Shape-aware Intersection over Union (SIoU) Loss function was introduced into the regression branch of the detection head. This provides a more stable and geometrically constrained bounding box regression mechanism, which not only improves the localization accuracy of infected plants but also accelerates the model's convergence. The results indicated that the enhanced cross-scale feature fusion capability of the improved YOLOv10 model increased the mAP@0.5 to 90.6%, representing a 4.5 percentage point improvement over the optimal baseline (YOLOv10). Furthermore, the precision (user's accuracy) and recall reached 91.2% and 92.7%, respectively, outperforming other classic deep learning models. The proposed model achieves rapid and accurate detection of arecanut palms infected with Arecanut Yellowing Disease (AYD), fulfilling the practical requirements for field surveillance and monitoring.

Keywords: UAV; remote sensing; multispectral imagery; deep learning; feature enhancement; precision identification; areca nut yellowing disease