doi:10.6041/j.issn.1000-1298.2025.10.042

基于 DCA－YOLO 的受病虫害侵染树木农业无人机低空检测模型

徐相华[1]　周德靖[2]　余超然[3]　熊万杰[2]　熊韵诗[2]　吴柏颖[2]　郑璇珠[2]　区德源[2]

（1.华南农业大学基础实验与实践训练中心，广州 510642；2.华南农业大学人工智能学院，广州 510642；
3.广东省农业科学院蔬菜研究所，广州 510640）

摘要：针对农业无人机在低空环境对受病虫害侵染的树木进行多尺度目标检测与定位时精度、准度不高与计算开销过大等问题，提出了一种适用于低空作业的改进目标检测算法 DCA－YOLO。首先引入 DCA 动态通道注意力机制，与双分支协同注意力一同动态调整特征的学习权重，增强对目标多尺度特征与上下文信息的感知能力；在 P2 层添加小目标增强检测模块，并在 P2、P4 层的检测头处添加 DCA 注意力机制，有效优化中小目标的检测性能；引入 Inner－IoU 损失函数，提高在复杂环境背景下易混淆目标的精细识别能力。为保证模型的流畅运行，使用轻量化的 GhostNetv2 优化主干网络，将模型参数量减少至 2.34×10^6，轻量化效果显著。使用改进的 BiFPN 优化颈部网络以进一步增强特征的重学习能力。实验结果表明：相比于原模型，DCA－YOLO 在增广验证集上的 mAP0.5 提高 5.2 个百分点，检测精度提高 5.6 个百分点，召回率提高 7.1 个百分点，同时参数量降低 6.7×10^5，浮点计算量减少 26.4%，内存占用量减少 16.2%，最终保持 87.6% 的精确率，87.4% 的召回率，93.1% 的平均精度均值，得到 DCA 的通道动态权重分配贡献度（0.41±0.07）与负样本抑制能力（－0.12±0.03），在模型轻量化的条件下有效地优化误检漏检的缺陷。DCA－YOLO 通过多模块协同改进显著提高模型精度，可满足农业无人机对病虫害侵染的树木进行实时高精度检测的应用需求。

关键词：病虫害树木；无人机检测；动态通道注意力；轻量化；GhostNetv2；DCA－YOLO

中图分类号：S763.11；TP391.41　　**文献标识码**：A　　**文章编号**：1000-1298(2025)10-0479-13　　**OSID**：

Improved Model for Low Altitude Detection of Trees Infected by Pests and Diseases Using Agricultural Drones Based on DCA－YOLO

XU Xianghua[1]　ZHOU Dejing[2]　YU Chaoran[3]　XIONG Wanjie[2]　XIONG Yunshi[2]
WU Baiying[2]　ZHENG Xuanzhu[2]　OU Deyuan[2]

(1. *Engineering Fundamental Teaching and Training Center*, *South China Agricultural University*, *Guangzhou* 510642, *China*
2. *College of Artificial Intelligence*, *South China Agricultural University*, *Guangzhou* 510642, *China*
3. *Vegetable Research Institute*, *Guangdong Academy of Agricultural Sciences*, *Guangzhou* 510640, *China*)

Abstract: In view of the problems of low accuracy, precision and high computational cost when agricultural drones conduct multi-scale target detection and positioning of pest-infected trees in low-altitude environments, an improved target detection algorithm named DCA－YOLO suitable for low-altitude operations was proposed. Firstly, the DCA dynamic channel attention mechanism was introduced. It worked together with the dual-branch collaborative attention to dynamically adjust the learning weights of features, enhancing the ability to perceive multi-scale features and context information of targets. A small target enhancement detection module was added at layer P2, and the DCA attention mechanism was added to the detection heads at layers P2 and P4, effectively optimizing the detection performance of small and medium-sized targets. The Inner－IoU loss function was introduced to improve the fine recognition ability of easily confused targets in complex environmental backgrounds. To ensure the smooth operation of the model, the lightweight GhostNetv2 was used to optimize the backbone

收稿日期：2025－04－15　修回日期：2025－05－16

基金项目：广东省重点区域研发计划项目（2023B0202090001）和广州市科技计划项目（2024E04J1243）

作者简介：徐相华（1982—），男，实验师，主要从事智慧农业研究，E-mail：86238154@qq.com

通信作者：熊万杰（1976—），男，副教授，博士，主要从事智慧农业算法研究，E-mail：xxwwjj@scau.edu.cn

network, reducing the number of model parameters to 2.34×10^6, with a remarkable lightweight effect. Finally, the improved BiFPN was used to optimize the neck network to further enhance the feature re-learning ability. The experimental results showed that compared with the original model, DCA - YOLO had 5.2 percentage points increase in mAP0.5 on the augmented validation set, 5.6 percentage points increase in detection accuracy, 7.1 percentage points increase in recall rate, and a reduction of 6.7×10^5 in the number of parameters. The floating-point operations (FLOPs) were reduced by 26.4%, with 16.1% decrease in model weight size. Finally, it maintained an accuracy of 87.6%, a recall rate of 87.4%, and a mean average precision of 93.1%. The dynamic channel attention (DCA) mechanism demonstrated a channel weighting contribution of 0.41 ± 0.07 and negative sample suppression capability of -0.12 ± 0.03. It effectively optimized the defects of false positives and false negatives under the condition of model lightweighting. In conclusion, DCA - YOLO significantly improved the model's accuracy through the collaborative improvement of multiple modules, and can efficiently meet the application requirements of agricultural drones for real-time high-precision detection of pest-infected trees.

Key words: disease and pest trees; detection using drones; dynamic channel attention; lightweight; GhostNetv2; DCA - YOLO

0 引言

随着工业科技发展带来的复合污染,社会生态保护诉求显著升级[1-2]。森林生态系统可通过冠层吸附和根系固碳构成核心净化屏障,其稳定性直接关系人居环境安全[3]。然而病虫害引发的林木死亡率已形成“侵染-抗性下降-二次侵染”的正反馈循环[4-5],制约林业资源的可持续发展,造成不可估量的经济损失与环境损害。为此国家高度重视生态环境安全,大力推动树木病害防治[6-7]。

针对林区或树木的病虫害检测目前主流的做法有人工筛查、农用卫星遥感监测技术[8]与传感器无线信息传输[9]等方法。人工筛查的局限性存在人力成本较高、作业效率较慢,存在主观性漏检与林区危险等问题[10];农用卫星遥感虽可对较大范围的林区进行宏观定位,但无法快速地定位至细小的区域[11];而传感器则存在部署麻烦、易出现故障等问题[12]。对于单棵小区域集群或大规模分布的病虫害侵染的树木,无人机航拍是最能直接反映病害发生区域的手段[13]。无人机操作简便,在进行低空作业时,可快速定位至目标区域进行检测作业,并可灵活地调整分辨率与摄像范围,提高病虫害检测效率的同时降低作业的经济成本,但将高精度模型部署无人机上时往往伴随着推理卡顿、实时性较低等情况。而将图像传输模块部署至无人机端以实现图像实时传输至本地进行推理的迁移方法,存在一些技术瓶颈:网络延迟问题导致图像传输稳定性下降[14];持续数据传输加剧了设备能耗负担;高功耗特性直接缩短了无人机的有效续航时间[15]。

在农业病虫害检测中,机器学习与图像处理技术虽具简便性但存在局限性,文献[16]采用XGBoost 算法有效实现玉米 LAI 反演与病害胁迫分析,文献[17-18]改进损失函数与集成全局注意力,显著提升荔枝果期检测精度,应用于无人机上后增强了对草地空斑的检测定位能力。文献[19]通过无人机图像处理优化向日葵覆盖作物选择,然而传统机器学习与视觉技术存在泛化性弱、多病害识别困难等局限。对此,在深度学习研究领域中,文献[20]构建 MCA - MobileNet 模型,结合 Wasserstein 生成对抗网络解决数据不平衡问题,显著提升番茄病害识别精度;文献[21]则采用 PP - YOLO 方法增强苹果/樱桃树检测性能,验证图像预处理对模型优化的有效性。这些成果为轻量化深度学习模型在农业无人机边缘计算终端的实时推理部署提供了技术支撑。

对比双阶段(two-stage)方法(如 R - CNN[22-23]),单阶段(one-stage)方法(如 YOLO[24]、SSD[25])在精度与速度间更均衡。考虑到 YOLO v8 的 CSPDarknet53 主干网络融合 C2F 模块与 SPPF 结构,兼顾特征融合与计算效率[26],本文选用 YOLO v8n 进行优化研究,针对低空小目标特性,引入 3 阶段优化:检测头添加 P2 层级增强细粒度特征提取,嵌入动态通道注意力机制(Dynamic channel attention,DCA);采用 GhostNetv2 重构卷积核[27]降低参数量;结合改进的 BiFPN 双通道金字塔结构[28]并改进 Inner - Iou 损失函数[29],构建适用于病虫害树木的精确定位模型,在保证实时性的同时,以提升无人机低空视角下多尺度目标检测鲁棒性。

1 材料与方法

1.1 数据集构建与预处理

病虫害图像实验数据集主要来源于中国山东计

算机科学中心、北京大学等高校与机构联合开发的 PDT(Pests and diseases tree)数据集[30]，此数据集收集 4 635 幅无人机低空拍摄的病虫害侵染树木静态航拍图作为训练集，额外收集 567 幅作为测试集和验证集。数据集中的病虫害树木在环境中分布较为复杂，光照条件丰富，既分布于稀疏树林之处，也分布于树木密集的树林环境，部分病虫害树木在林间粘连分布，部分则零星分布，特征多样、密度充足、视角合适，可作为实验验证数据集。

由于存在部分图像模糊、特征重复、无标注等情况，故先对数据集进行数据清洗等预处理，保留特征明显的图像数据，以进一步提升模型的训练质量。在人工筛选后，在原训练集中保留 2 000 幅图像数据，用于后续的处理。

为提高模型的适用性与泛化能力，对 1/4 的图像数据采用随机翻转、亮度变换等方式进行数据增强加以扩充，使用 LabelMe 标注后补进训练数据集，数据集扩充为 2 500 幅。增强与扩充图像示例如图 1 所示。

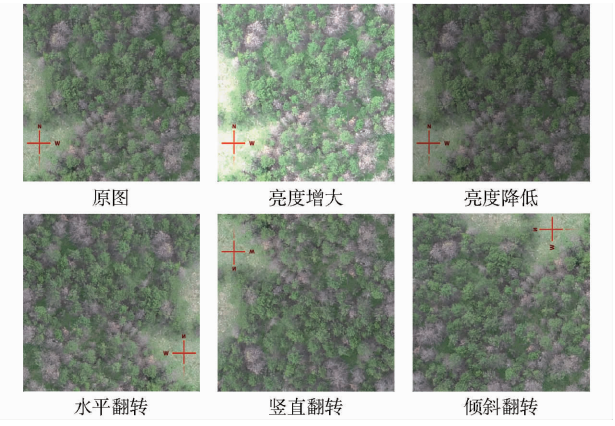


图 1　数据增强与扩充图像示例

Fig. 1　Data enhancement and expansion

通过模拟不同视角、不同光照变化下的拍摄场景来对数据集进行增强与扩充，一定程度上提高了数据集的多样性和泛化性。但现实场景下，农业无人机在拍摄过程中还会面临气候、多样背景、不同植被分布等多种复杂情况，在无人机实际的飞行过程中，还会由于相机抖动、聚焦晃动导致出现多种成像模糊问题。

考虑到上述潜在实际情况，本文对数据集进行数据增广，以提高其抗干扰能力。通过寻找不同低空拍摄环境下的病虫害侵染数据集，提高模型在不同植被分布复杂背景下的泛化性能，也避免模型对于单一 PDT 数据集的过度依赖。通过模拟相机抖动、视角模糊、相机过曝 3 种情况，引入真实拍摄环境下的机器误差与干扰，进一步提高数据集的多样性。

为使得模型适应不同拍摄环境下的色温变换，本文还对数据集进行色温偏移处理，冷色调处理后的数据集更接近于阴天昏暗的拍摄背景，有效提高模型在阴天环境下适用性和鲁棒性。

经过数据增广，数据集扩充为 3 500 幅，收集 700 幅作为测试集和验证集，经增广后的图像数据如图 2 所示。经过增强增广操作后，数据特征的学习难度得到一定程度的上升，DCA－YOLO 虽在数据扩充前后性能指标均较少地下降，可推测其对于小目标或全局特征检测有一定的干扰，但总体较为稳定而非大幅度降低的结果也证明模型有效地将干扰信息纳入学习范畴，提高了模型检测时的适用性，也体现了模型对数据的鲁棒性。

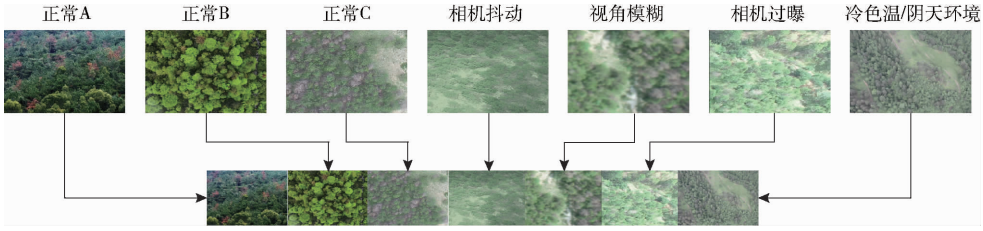


图 2　数据增广

Fig. 2　Data augmentation

1.2　YOLO v8 与改进方法

1.2.1　YOLO v8 模型

YOLO v8 是一款由 Ultralytics 公司开发的无预定义锚框模型，新增一种改进的 C2f 模块。骨干网络中的卷积层、池化层会逐步提取其浅层至深层病虫害侵染的相关语义特征，生成的特征导入快速空间特征金字塔进行全局池化后实现多尺度特征融合与增强，在经过上采样与特征连接后将特征输出到 YOLO 的 3 个检测头中进行推理与检测。YOLO v8 主要沿用 YOLO v5[31] 的骨干网络与整体架构的设计思想，但对于小目标检测和遮挡易混淆的特征时容易产生漏检误检情况。

1.2.2　小目标检测增强

对于空中视角俯拍的病虫害树木，图像存在的特征不明显以及像素点少等问题会影响模型的识别效果，容易产生漏识别与误识别的现象：例如将树丛之间的空斑、枝干、阴影或枯死的树木等识

别成病虫害树木,导致无人机进行作业时误差较大。

为保证无人机进行低空巡检时能有效提高对小目标的检测性能,本文在 YOLO v8 的结构上添加 P2 层并增加额外的卷积层以实现特征信息的加强,同时在检测头接入 DCA 注意力机制。P2 层尺寸为 160 像素×160 像素,具有最丰富的全局细节信息,从 P2 层增强特征提取能力后,再添加注意力机制针对局部精度进行优化以对特征直接学习,更精确地定位小目标所在的位置并抛弃多余的干扰信息或易混淆特征,相比于在骨干网络添加全局注意力,对检测头进行修改可以进一步压缩模型所需的参数并实现特征的针对性增强,最后在 P4 层再添加一次 DCA 注意力,在 P4 丰富的语义环境下,增强模型对多尺度信息(如上下文、形状、边缘)的感知能力,并提升其与无关背景特征的区分度。多检测头可显著地提高检测的精度,由此产生的计算成本由后续模块平衡,改进后的模型结构如图 3 所示。

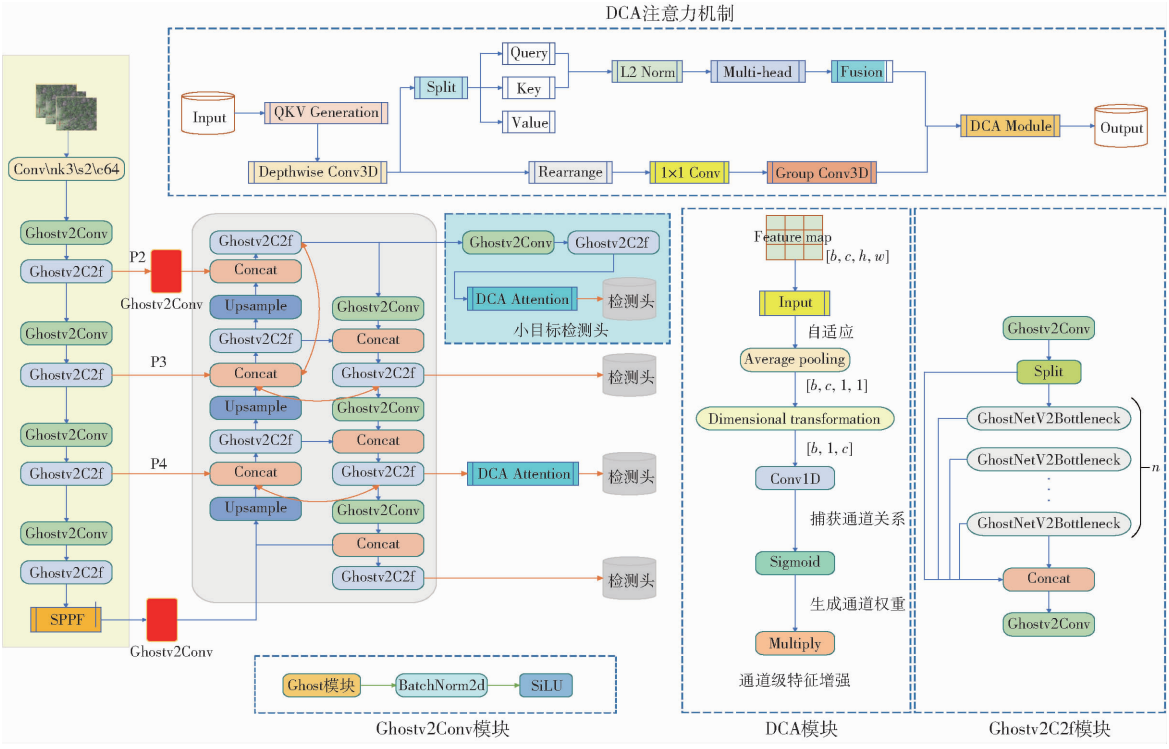


图 3 DCA-YOLO 结构示意图

Fig. 3 Schematic of DCA-YOLO structure

1.2.3 DCA 动态通道注意力机制

通道注意力机制的原始思想源于 SENet[32] 的 Squeeze-and-Excitation(SE)块,其通过建模通道依赖关系自适应校准特征响应。SE 块可堆叠为 SENet,显著提升 CNN(卷积神经网络)性能,且计算成本增加较少。SENet 应用于低空农业任务中,部署在无人机中的 SENet 能够提升对林木检测的性能,通过增强模型对特征图中关键信息的关注强化受虫害树木区域的表达能力,从而优化模型的特征提取能力[33],因此应用于虫害导致的树木病变目标检测具有良好前景。

DCA 引入动态通道注意力模块与双分支协同注意力模块。动态通道注意力模块是一种轻量化的注意力模块,其利用一维卷积动态地捕获不同通道之间的特征信息,自适应地计算通道内的特征传递质量权重,对关键的信息予以更高的探索深度。动态卷积核尺寸 K 由通道数的数量决定:模块引入全局平均自适应池化以压缩空间维度,生成通道描述向量后对卷积核进行自适应计算,动态生成卷积核尺寸 K 公式为

$$K = t + w \tag{1}$$

其中

$$t = \left\lfloor \frac{\lg C + b}{\gamma} \right\rfloor$$

式中 t——中间变量

C——特征图通道数

b——偏移量

γ——缩放因子

当 $t \bmod 2 = 0$ 时 w 取值为 1,否则取值为 0。

此方法产生的卷积核可保证为奇数,从而稳定地以对称填充的方法捕捉通道间的局部关系,最终使用 Sigmoid 函数生成通道权重,乘以输入特征权重,完成特征重标定,通道权重计算公式为

$$y = \mathrm{Sigmoid}(\mathrm{Conv1D}(\mathrm{AvgPool}(\boldsymbol{x}))) \tag{2}$$

式中 $\boldsymbol{x}$——输入特征图,形状为(B,C,H,W)

AvgPool($\boldsymbol{x}$)——全局平均池化函数，输出形状为（B,C,1,1）

Conv1D——一维卷积函数，输入形状和输出形状均为(B,1,C)

Sigmoid——激活函数，主要将权重限制在[0,1]范围内

y——通道注意力权重，形状为(B,C,1,1)

B 为批大小、C 为通道数、H 为高度、W 为宽度。

最终逐通道进行特征重标定，公式为

$$R_{output} = \boldsymbol{x}y \tag{3}$$

式中　R_{output}——重标定输出结果

在卷积核进行卷积计算时，动态自适应技术可有效增强卷积核对不同网络深度的适用性，由于自身仅为一维卷积，故相较于传统注意力，其增强细节特征信息捕获能力的同时可显著降低计算复杂度，避免传统通道注意力机制的固定计算与全连接层上的高复杂计算过程，符合轻量化的需求。

双分支协同注意力模块可以将全局注意力与局部卷积互补，有效地兼顾全局语义信息与局部的细节。同时引入深度可分离卷积，利用其三维特征对空间通道进行卷积，生成查询 $\boldsymbol{Q}$、键 $\boldsymbol{K}$ 和值 $\boldsymbol{V}$，在保证空间通道关联性不丢失的情况下进一步减少计算量。空间通道卷积公式为

$$\boldsymbol{QKV} = \mathrm{Conv3D}(\boldsymbol{x}) \tag{4}$$

其中 Conv3D 为三维卷积，输出形状为(B,3C,H,W)。将 $\boldsymbol{Q}$、$\boldsymbol{K}$ 进行 L2 归一化以避免注意力对某个尺度的特征过分关注导致特征丢失的情况。引入温度系数，在训练中不断学习特征的关注情况，并动态地调节注意力的分布情况，减少相似特征的误识别，使得模型更加灵活，最终定义一个检测头数量 *num_heads*，通过多头自注意力分解特征空间，与动态通道注意力机制加权融合后增强多视角特征的提取能力。多头注意力计算与温度系数的协同作用可以表示为

$$\mathrm{Attention}(Q,K,V) = \mathrm{Softmax}\left(\frac{\boldsymbol{QK}^{\mathrm{T}}}{\sqrt{d_k}\boldsymbol{\tau}}\right)V \tag{5}$$

式中　d_k——key 的维度

Softmax——归一化函数

τ——温度系数

每一个矩阵形状均为(B,num_heads,C/num_heads,HW)，增强后的特征表示有效克服单一注意力机制的局限性与局部最优风险。

相比于其他通道注意力机制，DCA 注意力机制结合温度系数，在树木经受病虫害侵染数据集中动态强化各个特征层对被侵染树木特征信息的传递能力，在不断训练的过程中动态调整对待学习特征的学习权重：如对已取得较高验证结果的病虫害侵染特征可在后续训练中减少学习能力的权重，反之则增加学习能力的权重，令其获取到更多的有效与被忽略的特征；利用 1×1 动态卷积实现轻量化的同时强化其细节信息，利用多通道特征处理方式强化病虫害侵染特征的学习能力，有效减轻过拟合的同时提高对易混淆信息特征（如小目标检测、遮挡和重叠）的学习能力，提高模型性能。

为证明 YOLO v8n 模型加入 DCA 的效果最佳，可以基于 PDT 数据集，在 YOLO v8n 上对不同通道注意力机制的性能进行评估与对比。其中，mAP 表示平均精度均值，50 和 50－95 分别表示 IoU（交并比）阈值为 0.5 和 0.5～0.95 的平均精度。结果如表 1 所示。

表 1　不同通道注意力机制在 YOLO v8n 中性能

Tab.1　Performance of different channel attention mechanisms in YOLO v8n

模型	精准率/%	召回率/%	mAP50/%	mAP50－95/%	参数量	浮点运算量	内存占用量/MB
YOLO v8n	82.7	80.2	88.3	60.8	3.01×10^6	8.7×10^9	6.2
YOLO v8n＋SE	81.5	79.2	87.0	59.2	3.28×10^6	8.8×10^9	6.3
YOLO v8n＋CBAM	83.2	82.4	88.9	61.7	3.43×10^6	9.0×10^9	6.6
YOLO v8n＋ECA	84.6	83.2	89.7	63.5	3.15×10^6	8.7×10^9	6.4
YOLO v8n＋DCA	85.8	85.7	91.1	64.6	3.36×10^6	8.8×10^9	6.3

可见，在 PDT 数据集上，加入 DCA 注意力机制得到的模型效果最佳，其 mAP 的值普遍高于其他模型，模型准确率普遍提升，虽然参数量略微增加，但浮点运算量的增幅较小，说明 DCA 注意力机制在精度和效率取得最佳平衡，是综合下来的最优选择。此外，通过基于 SHAP（Shapley additive explanations）的初步分析[34]，DCA 的通道动态权重分配贡献度（0.41±0.07）与负样本抑制能力（－0.12±0.03）均优于对比模块（其中，贡献度如下：SE，0.32±0.08；CBAM，0.35±0.06；ECA，0.29±0.09），表明其能更精准地聚焦病虫害区域的显著性特征，同时有效抑制复杂背景干扰，从而在可解释性的角度上证实 DCA 注意力模块的合理性。

1.2.4　GhostNetv2 轻量化网络

边缘人工智能设备进行实时部署的关键是平衡模型的轻量化和计算资源，并节省存储需求。由

Ghost 模块改进而来的 GhostNetv2 是目前较为主流的轻量化网络结构,将其代替原 C2f 与 Conv 卷积核时虽会对模型特征的识别精准有轻微的影响,但其复杂程度和模型参数量将大大降低。由于其精度的劣势可通过其他的模块及注意力机制补足,故将其考虑进模型改进设计中。Ghost 模块输出特征时流程如图 4 所示。

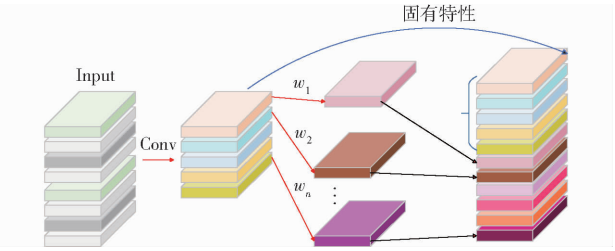


图 4 Ghost 模块特征输出图

Fig. 4 Ghost module feature output diagram

虽然原 Ghost 模块可显著地降低模型的参数与计算量,但对精确性的负面影响仍然较大;而基于 GhostNet 改进的 GhostNetv2 可有效地缓解这些劣势,其提出一种长距离注意力机制模块(Decoipled fully connected, DFC),可提高长距离像素之间的特征信息与联系关系的捕捉效率。将其部署至无人机进行低空病虫害目标检测时可有效地增大全局感受野,实现在较低的内存占有量条件下保持较高的实时性,增强对不易察觉或微小的病虫害像素点的捕捉与定位精度。综上将其部署至无人机后可有效提高其低空作业的效率。DFC 结构如图 5 所示。

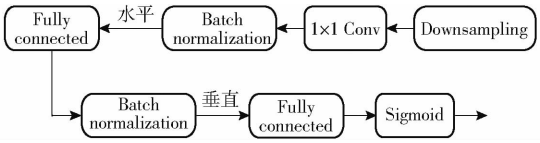


图 5 DFC 注意力机制

Fig. 5 DFC attention mechanism

DFC 使用全连接层进行注意力图的生成,Ghost 分支与 Attention 分支共同参与对特征信息的提取与聚合过程。其中全连接层被划分为水平与垂直两个方向分别依次进行特征的学习与捕获,即分别在水平与垂直方向上进行全连接,并最终合并两个方向上的空间信息,达到扩大全局感受野的目的。不仅聚焦点周围的特征可以得到更多的关注,而且分支连接的方法也有效地降低计算成本。

核心模块 GhostNetv2 Bottleneck 如图 6 所示,其包含两个 Ghost Module,采用先升维与降维的倒置残差结构并以跳跃连接进行信息传输。将 DFC 作用于首个 Ghost Modules 进行并行计算以获取更多的有效特征,在缓解梯度消失的同时增强扩展层的特征表达,使网络层能学习到更多的目标特征。

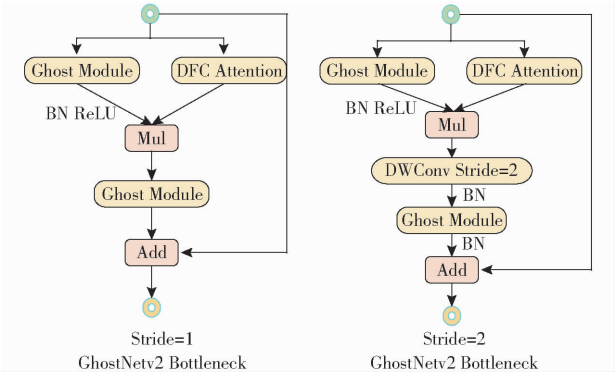


图 6 GhostNetv2 Bottleneck 结构

Fig. 6 GhostNetv2 Bottleneck structure

GhostNetv2 通过针对性优化病害特征的空间分布特性,在病虫害树冠检测中实现高效表征。针对病斑的渐进性变色与树冠稀疏区域,模型采用双路径协同机制,先通过 DFC 全局感知层通过水平-垂直双向全连接层构建超广域感受野,动态捕捉跨像素长程依赖关系,定位叶片边缘渐变变色区域,优化传统网络对低对比度病斑的漏检问题,再利用通道解耦策略,重点强化病斑整体形态的低频轮廓特征(如稀松区域的环境区分性、异色化斑块的环状边缘),实验结果显示其虽非为最轻量化的模块,但其在轻量化与性能抗干扰的平衡表现最佳。

为证明 YOLO v8n 模型加入 GhostNetv2 得到的效果最佳,利用不同轻量化网络在 YOLO v8n 上,对 PDT 数据集实验结果如表 2 所示。

表 2 不同轻量化网络在 YOLO v8n 中的实验结果

Tab. 2 Performance of different lightweight networks in YOLO v8n

模型	精准率/%	召回率/%	mAP50/%	mAP50-95/%	参数量	浮点运算量	内存占用量/MB
YOLO v8n	82.7	80.2	88.3	60.8	3.01×10^6	8.7×10^9	6.2
YOLO v8n + MobileNetv3	77.3	75.5	83.4	57.2	2.35×10^6	5.8×10^9	4.8
YOLO v8n + VanillaNet	78.2	76.3	85.2	58.4	1.82×10^6	5.6×10^9	4.7
YOLO v8n + GhostNetv1	79.3	77.8	86.1	59.2	1.80×10^6	5.3×10^9	4.4
YOLO v8n + GhostNetv2	80.8	79.6	87.6	59.8	1.86×10^6	5.7×10^9	4.5

可见,在 PDT 数据集上,虽然轻量化网络会使准确率下降,但是 GhostNetv2 在轻量化与性能保持度上为最优,综合可得其为最优选择。

1.2.5 BiFPN 结构改进

YOLO v8 的 Neck 层通过特征金字塔网络(FPN)与路径聚合网络(PANet)结合来解决多尺度

目标检测问题，两种网络协同运作，虽然可将特征进行融合叠加，但是无法区分特征的优先性。如无人机在低空作业时，实时捕获图像中病虫害树木特征复杂，存在尺寸形状多变或遮挡等问题。传统的金字塔网络无法有效地区分不同分辨率下的特征细节，容易忽略局部特征且在处理高分辨率数据时模型计算复杂度较大。

为此引入加权双向特征金字塔网络 BiFPN 替换 PANet 网络，以实现对特征数据的自适应调整。通过增加一个自适应权重系数，网络可针对特征重要性自适应调整学习力度，避免过拟合或局部最优。最终，不同分辨率的特征信息均能得到合理的关注度，同时其快速归一化模块也将加快检测的速度。权重融合输出表示为

$$O = \frac{\sum_i \boldsymbol{\omega}_i R_{resize}(P_i)}{\sum_i \boldsymbol{\omega}_i + \boldsymbol{\varepsilon}} \tag{6}$$

式中　$\boldsymbol{\omega}_i$——每个输入特征图

R_{resize}——上采样或下采样操作，用于统一特征图尺寸

$\boldsymbol{\varepsilon}$——极小值，防止分母为零

P_i——第 i 个层级的输入特征图

最终考虑到无人机航拍视角下病虫害树木特征大部分为中小尺度的特点，因此，在只使用 P3、P4、P5 层的基础上，额外增加 P2 层，并增加一个中间卷积操作，通过上采样对 P2 至 P3 的路径进行特征融合，P2 独立作为一个小目标检测头输出，完成特征信息的自顶向下与自底向上的加权融合，构建 PC－BiFPN 网络，网络结构如图 7 所示。

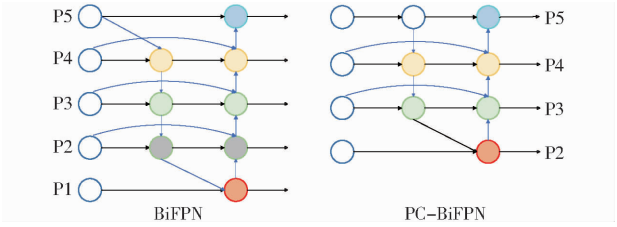


图 7　BiFPN 结构示意图

Fig. 7　Schematic of BiFPN structure

1.2.6　Inner－Iou 损失函数改进

传统 IoU 仅计算预测框与真实框的整体重叠面积，对边界框内部核心区域的细微差异不敏感。对于小目标，其边界框面积较小，IoU 的变化范围有限，导致模型难以捕捉精确的位置信息。

YOLO v8 模型采用的损失函数为边界框损失函数(BBR)，主要包括 GIoU、DIoU、CIoU 这 3 个主流函数。传统损失函数虽能在一定尺度上适宜并优化样本的重叠区域、中心距离和不规则形状，但对小目标等模糊易混淆的目标感知能力较弱，收敛梯度不明显，导致模型泛化能力弱。

Inner－IoU 损失函数采用动态的辅助框增强模型对目标中心区域的敏感性，随着目标对象的规模动态调整辅助框的覆盖范围，设置缩放因子 Ratio，根据样本的 IoU 进行缩放，对于高 IoU 样本使用小比例辅助框加深特征的获取，使用大比例辅助框扩充低 IoU 样本特征的多样性。将 Inner－IoU 损失函数应用到小目标检测时性能出色，可视化得到改善[35]，利用 Inner－IoU 优化小目标检测流程如图 8 所示。

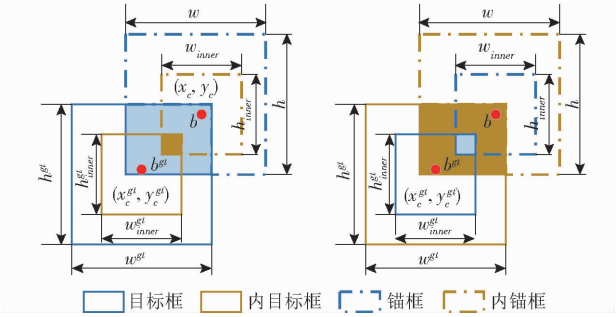


图 8　Inner－IoU 小目标检测

Fig. 8　Inner－IoU small object detection

原始 IoU 计算公式为

$$\mathrm{IoU} = \frac{|B_{pred} \cap B_{gt}|}{|B_{pred} \cup B_{gt}|} \tag{7}$$

其中

$$B_{gt} = (x_{gt}, y_{gt}, w_{gt}, h_{gt}) \tag{8}$$

$$B_{pred} = (x_{pred}, y_{pred}, w_{pred}, h_{pred}) \tag{9}$$

式中　(x_{gt}, y_{gt})——检测目标中心坐标

(w_{gt}, h_{gt})——检测目标宽和高

(x_{pred}, y_{pred})——预测框中心点坐标

w_{pred}、h_{pred}——预测框宽度、高度

缩放因子 R_{ratio} 根据原始 IoU 动态调整，用于生成辅助框，即

$$R_{ratio} = R_{ratio-min} + (R_{ratio-max} - R_{ratio-min})(1 - IoU) \tag{10}$$

式中　$R_{ratio-min}$——最小缩放比

$R_{ratio-max}$——最大缩放比

当 IoU 较高时，R_{ratio} 趋近于 $R_{ratio-min}$，即使用较小尺度的辅助框，聚焦中心；当 IoU 较低时，R_{ratio} 趋近于 $R_{ratio-max}$，即采用较大尺度辅助框，增强特征多样性。此时保持真实框中心不变，按 R_{ratio} 缩放宽高，即

$$B_{inner} = (x_{gt}, y_{gt}, w_{gt}R_{ratio}, h_{gt}R_{ratio}) \tag{11}$$

B_{inner} 是以真实框的中心为中心，宽高由真实框宽高乘以动态缩放因子 R_{ratio} 所构成的辅助框。则预测框与辅助框的 IoU_{inner} 满足公式

$$IoU_{inner} = \frac{|B_{pred} \cap B_{gt}|}{|B_{pred} \cup B_{gt}|} \tag{12}$$

最后,Inner – IoU 损失定义为

$$L_{Inner-IoU}=1-IoU_{inner} \tag{13}$$

Inner – IoU 引入内框机制,使得在目标框中心能够定义较小的内框,并根据预测边框和实际边框的重叠程度动态分配权重,能够更加准确覆盖目标区域,减少其他非目标区域的干扰。应用到所用数据集中,即能准确捕捉小范围到大面积的被侵染树木的目标区域,提高模型对于不同侵染程度下树木检测的敏感性和稳定性[36]。

1.2.7 评价指标

采用精确率、召回率、平均精度均值(mAP50、mAP50 – 95)、参数量与内存占用量等作为指标,在模型进行推理时作为模型性能评价指标。

2 结果与分析

2.1 实验环境与参数配置

本机 GPU 使用 NVIDIA GeForce RTX 2070,模型训练轮次设置为 150 轮,若损失梯度未明显收敛,则再增加 150 轮训练。初始学习率为 0.02,采用 SGD(随机梯度下降)优化,使用 0.001 的权重衰退系数,输入图像尺寸为 640 像素 ×640 像素,启用半精度训练。因分类只有病虫害树木的单一特征,故为防止学习初期出现过拟合现象,采用 warm up 学习率预热 3 轮,最后在训练中随机对数据进行 Mosaic 增强方法、均衡直方图变化等数据增强方法,进一步提升数据集的特征多样性。Mosaic 增强示意图如图 9 所示。

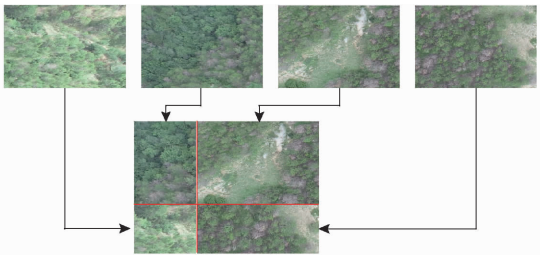


图 9 Mosaic 增强示意图

Fig. 9 Mosaic augmentation diagram

2.2 原始模型改进对比

在本机的相同环境和参数下,分别训练原版的 YOLO v8 与 DCA – YOLO 改进模型。将两个模型损失函数、精确率、召回率、mAP 进行可视化对比,可直观地看出模型改进前后对比结果,并对其进行合理分析。

本研究重点关注 3 种损失函数 BLS(宽度学习系统)、CLS(分类损失函数)、DFL(分布焦点损失)。3 种损失函数总和随训练推进的收敛过程如图 10 所示。由图 10 可知,模型在 150 轮左右时总损失值趋于平稳并收敛,对于病虫害特征的识别与学习能力达到最优。此时模型对于病虫害特征的识别与学习能力达到最优状态。对比两个模型的训练过程,其损失函数在整个训练周期内均保持持续下降趋势,全程未出现过拟合现象,在收敛后达到性能最优。相较于原始模型,DCA – YOLO 模型验证集损失值比原始模型低 0.12。

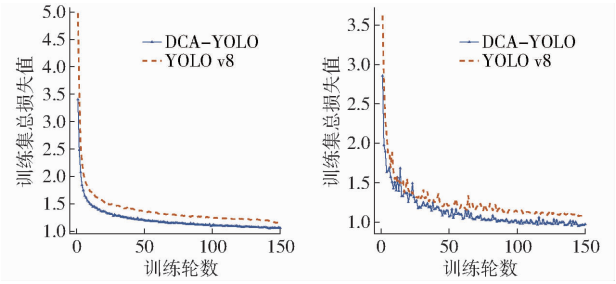


图 10 训练、验证过程损失变化曲线

Fig. 10 Training and validation process loss changes

对 mAP50 与 mAP50 – 95 进行可视化处理,结果如图 11 所示。由图 11 可知,改进后模型 mAP50 提高 4.8 个百分点,mAP50 – 95 提高 6.8 个百分点,目标定位能力提升,在实际环境中部署,可更精准地锁定目标所在的位置与范围。

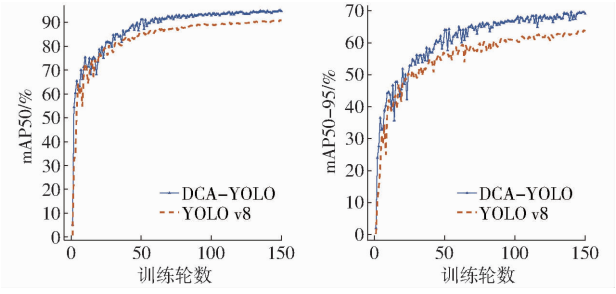


图 11 mAP50 与 mAP50 – 95 的可视化对比

Fig. 11 Visualization andcomparison of mAP50 and mAP50 – 95

精确率和召回率对比结果如图 12 所示。由图 12 可知,改进方案可显著提升模型的精准率与召回率。相较于原始模型,DCA – YOLO 模型召回率与精确率分别提高 6.2 个百分点与 4.9 个百分点。综上所述,DCA – YOLO 改进模型性能得到全面提升。

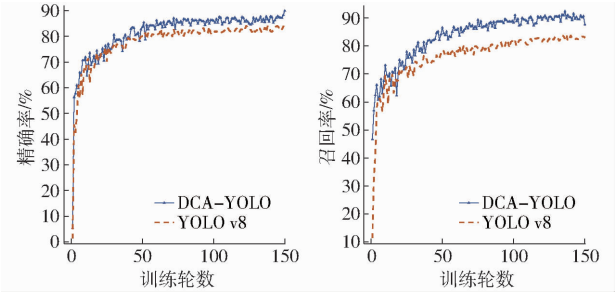


图 12 精确率与召回率对比曲线

Fig. 12 Precision and recall curves

2.3　消融实验

上述对比实验的结果证实改进模型的有效性，为进一步验证模型各个模块对模型整体改进的贡献度，以 Ghostv2Net 为主干网络，对 P2 小目标检测头、PC－BiFPN 颈部网络、DCA 注意力机制、Inner－IoU 损失函数进行消融实验，实现各个模块在与主干网络的协同下对模型提高效果的数据可视化。

由表 3 可看出，对于原始的 YOLO v8 模型来说，初始情况下对病虫害特征的识别精度、召回率与平均精度性能表现良好，但模型内存占用量大。对于部署在低空农业无人机上的边缘设备，参数量是节省计算资源开销的代表参数，故实际应用上 YOLO v8 模型存在较大改进空间。使用 GhostV2Net 网络替换后的 YOLO v8 模型，虽然模型得到显著的轻量化，但由于参数量和计算量的减少，模型检测能力下降，评价指数均有一定程度的下降，牺牲检测的性能表现。为弥补性能的缺失，分别引入 DCA 注意力机制、P2 小目标检测头、PC－BiFPN 颈部网络、Inner－IoU 损失函数。在保持主干网络不变的情况下，改进后模型的各个性能都得到显著的提升，并且模型尺寸均优于 YOLO v8 原模型。最后，加入 4 个模块协同训练：mAP50 可以达到 93.1%，较轻量化模型提高约 5.9 个百分点；检测精确率达到 87.6%，较轻量化模型提高约 7.8 个百分点，召回率达到 87.4%，较轻量化模型提高 8.9 个百分点，而参数量较原始模型下降 6.7×10^5，使得计算资源的损耗显著减小，而最终的浮点运算量和内存占用量相较于原模型分别降低 26.4% 和 16.2%。

表 3　各个模块与主干网络协同下的性能比较

Tab.3　Performance comparison of various modules in collaboration with backbone network

模型	精确率/%	召回率/%	mAP50/%	mAP50－95/%	参数量	浮点运算量	内存占用量/MB
YOLO v8	82.7	81.2	88.3	60.8	3.01×10^6	8.7×10^9	6.2
YOLO v8 + Ghostv2	80.8	79.6	87.6	59.8	1.86×10^6	5.7×10^9	4.5
YOLO v8 + Ghostv2 + P2	84.1	82.3	89.2	61.5	1.93×10^6	6.2×10^9	4.7
YOLO v8 + Ghostv2 + PCBiFPN	82.1	81.9	88.4	61.1	1.92×10^6	5.7×10^9	4.4
YOLO v8 + Ghostv2 + P2 + Inner	84.8	83.1	90.1	61.9	1.92×10^6	6.3×10^9	4.8
YOLO v8 + Ghostv2 + DCA	84.1	83.7	89.4	61.5	2.21×10^6	5.8×10^9	4.7
YOLO v8 + Ghostv2 + PCBiFPN + P2	85.3	85.3	90.5	63.8	1.99×10^6	6.2×10^9	4.7
YOLO v8 + Ghostv2 + PCBiFPN + P2 + DCA	86.2	86.8	91.2	66.2	2.34×10^6	6.3×10^9	5.1
YOLO v8 + ALL	87.6	87.4	93.1	67.6	2.34×10^6	6.4×10^9	5.2

同时 DCA 模块的贡献尤为显著，在主干网络的轻量化下，仍可最大限度提升各参数性能评价指数：mAP50 可以达到 89.4%，较原始模型提高约 1.2 个百分点；检测精确率达到 84.1%，较原始模型提高约 1.7 个百分点，召回率达到 83.7%，较原始模型提高 3.0 个百分点。融合注意力机制的小目标检测头后，改进后模型的性能指数提升效果更为显著，说明小目标对象的特征容易产生过拟合。最后经过多语义信息关注训练，以减少模型对于误识别漏识别的情况。最终结合上述实验证明，对 4 个模块的融合优化模型具有可行性，且 DCA 注意力机制与改进的 Inner－IoU 损失函数可高效适用于低空无人机检测的作业环境。

2.4　主流模型对比

将 DCA－YOLO 模型与其他主流的边缘部署单阶段检测模型在测试集上进行对比，结果如表 4 所示。由表 4 可知，相比于各主流模型，尽管 YOLO v8n 模型的参数量和计算量相比于 YOLO v5n 模型有所增加，但是精确率和召回率在同类基础模型中表现最优。结合各性能表现与实际部署的算力局限

表 4　不同模型性能对比

Tab.4　Performance comparison of different models

模型	精确率/%	召回率/%	mAP50/%	mAP50－95/%	参数量	浮点运算量	内存占用量/MB
YOLO v8n	82.7	81.2	88.3	60.8	3.01×10^6	8.70×10^9	6.2
YOLO v7－Tiny	80.9	80.1	87.1	61.1	6.01×10^6	1.30×10^{10}	11.7
YOLO v6n	81.1	80.7	85.9	61.5	4.70×10^6	5.20×10^9	4.1
YOLO v5n	78.7	78.9	86.3	58.7	1.90×10^6	4.50×10^9	3.8
YOLO v4－Tiny	80.8	78.2	84.7	59.2	9.11×10^6	2.06×10^{10}	17.8
Faster R－CNN	84.7	84.3	90.9	63.4	6.01×10^7	1.09×10^{11}	46.5
Grid R－CNN	86.2	84.6	91.4	64.5	8.23×10^7	1.27×10^{11}	58.2
DCA－YOLO	87.6	87.4	93.1	67.6	2.34×10^6	6.40×10^9	5.2

的情况，对 YOLO v8n 这类初始性能较优的模型进行改进具有可行性，满足实际环境的需求。在比较其他模型时，DCA－YOLO 模型在所有性能指标上都得到有效的提升，其中召回率提高得最为显著，相比于原始模型提高 7.1 个百分点，由此可推测误检和漏检的情况得到有效的缓解。

召回率与模型参数化的可视化数据如图 13 所示，清晰且直观地对比各模型在参数量与召回率维度上的表现：YOLO v8n 改进为 DCA－YOLO 模型后，参数量下降且召回率显著提升，表明漏检误检现象减少。模型位置越靠拢左上方，则表示此模型轻量化与性能平衡性越佳。

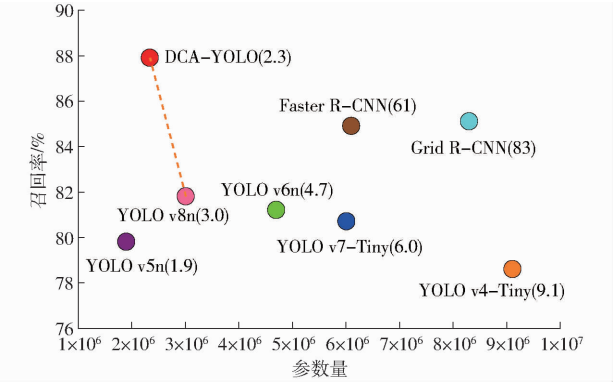


图 13 不同模型参数量与召回率对比

Fig. 13 Comparison of different model parameter quantities and recall rates

2.5 检测结果可视化

当原始模型进行目标检测时，在环境复杂与混淆特征较多的图像上存在一定程度上的漏检、误检现象，如对于相似特征的风沙侵染地面或空斑易产生误识别等。此外，原始模型对中小尺度目标的检测精度一般，模型鲁棒性较低，对于在高曝光环境、树木稀疏环境与树木密集环境进行检测作业时可视化如图 14 所示：在图 14a 高亮环境中，原始模型错误地将树木之间的路径空斑混淆成病害树木，而改进模型进行检测时避免误检现象，准确地将其上方真正的病害树木识别出来，如图 14d 所示。

在图 14b 稀疏环境中，左下角两处风沙侵染地面被错误的识别成病害树木，而在改进模型中有效避免了此类错误识别，如图 14e 所示。

在图 14c 密集环境中，树丛的左半部与上部均出现对于模糊目标、小目标的定位与判别能力局限的情况，而改进模型则能成功检测到漏识别的对象（图 14f）。综上，改进模型可有效地应用于低空无人机，在多种复杂环境下提供高精度和高准确度的检测结果。

在添加注意力机制前后输出的网络特征提取可视化情况如图 15 所示，暖色系越深的地方表示模型

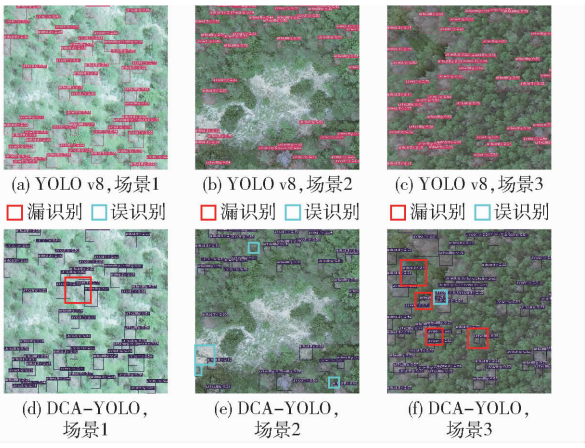


图 14 改进前后检测可视化

Fig. 14 Visualization of detection before and after improvement

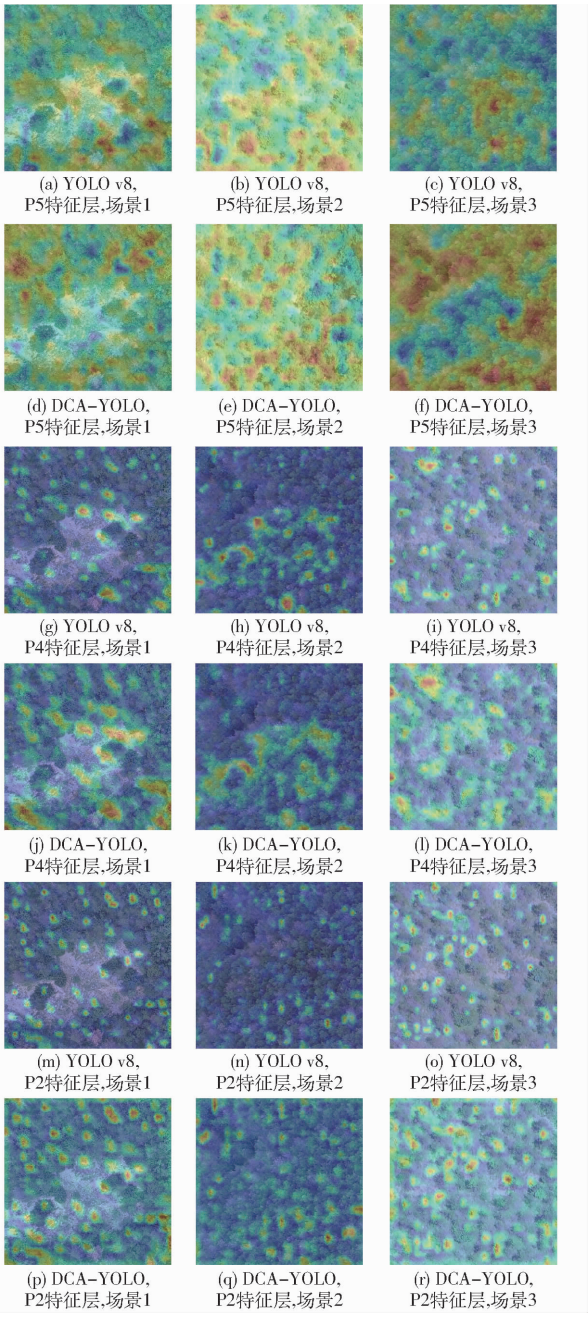


图 15 改进前后特征热力图

Fig. 15 Feature heatmap before and after improvement

关注的重要程度越大。通过对比关注特征的可视化，可以得出模型对图像特征的重点关注情况。由图 15 可得，改进前模型在识别病害树木时，关注的信息较为杂乱，部分情况出现关注方向错误等情况，当树丛间有大片的空斑，风沙侵染地面时，模型会聚焦于易混淆特征上；在目标分布较为密集或光亮较大时，模型的关注范围较为局限，且区分度不明显，背景信息干扰大，易过分强调某类特征，忽略其他特殊特征。

在复杂环境下进行多目标识别时通常存在较大的注意力聚焦干扰，容易陷入局部最优，故尽可能地缩小特征聚焦区域是提升特征多样性学习能力关键所在。在改进后，DCA－YOLO 模型更好地优化特征关注点的分布，提高注意力机制与各模块的协同效率，在背景信息的干扰下加强识别的抗干扰能力并重点聚焦病虫害特征明显分布的地带，更为准确地提取出病害树木的多元特征与背景的上下文信息，以进一步提升模型的识别精度与定位能力。在对颈部网络和检测模块进行改进之后，进一步优化了损失函数，从而缓解了漏检误检的问题。

3　结论

（1）针对低空无人机在病虫害侵染树木检测场景中的精确性与轻量化需求，提出一种基于 YOLO v8 改进的 DCA－YOLO 模型：采用 GhostNetv2 轻量化网络，引入 DCA 动态通道注意力机制，构建 PC－BiFPN 多尺度特征融合颈部网络并改进 Inner－IoU 损失函数，得到改进的 DCA－YOLO 模型。

（2）模型训练实验结果表明，改进的 DCA－YOLO 模型在参数量从 3.01×10^{6} 降至 2.34×10^{6} 的情况下，mAP50 达到 93.1%，mAP50－95 达到 67.6%，分别较原始 YOLO v8 提升 4.8 个百分点和 6.8 个百分点，召回率与精确率达到 87.4% 与 87.6%，分别提升 6.2 个百分点和 4.9 个百分点，而最终的浮点运算量与模型内存占用量相较于原模型分别降低 26.4% 与 16.2%。该结果有效验证改进的 DCA－YOLO 模型在显著降低模型参数量与计算量的同时提升检测精度，成功改善复杂环境下病害特征漏检误检的缺陷。

（3）检测可视化效果和特征热力图结果表明：改进的 DCA－YOLO 模型在多样光照条件、遮挡等非结构化场景中能保持良好稳定检测精度，对小目标敏感，并在各环境下具有较强适应性。综上，搭载改进的 DCA－YOLO 模型的低空农业无人机能提高对病虫害侵染树木的高精度、高时效特征检测效果。

参　考　文　献

[1] 程开明，洪真奕. 城市人口聚集度对空气污染的影响效应——基于双边随机前沿模型[J]. 中国人口·资源与环境，2022，32(2)：51－62.
CHENG Kaiming，HONG Zhenyi. Effect of urban population aggregation index on air pollution：based on the bilateral stochastic frontier model[J]. China Population，Resources and Environment，2022，32(2)：51－62.(in Chinese)

[2] 任保平，杜宇翔. 黄河流域经济增长-产业发展-生态环境的耦合协同关系[J]. 中国人口·资源与环境，2021，31(2)：119－129.
REN Baoping，DU Yuxiang. Coupling coordination of economic growth，industrial development and ecology in the Yellow River basin[J]. China Population，Resources and Environment，2021，31(2)：119－129.(in Chinese)

[3] 朱鹤，刘家明. 旅游导向下自然保护区外围区空间演变——以长白山国家级自然保护区外围区为例[J]. 自然资源学报，2023，38(4)：918－933.
ZHU He，LIU Jiaming. Spatial evolution of the peripheral area of nature reserve under the guidance of tourism：taking the peripheral area of Changbai Mountain National Nature Reserve as an example[J]. Journal of Natural Resources，2023，38(4)：918－933.(in Chinese)

[4] 朱惠斌，王明鹏，白丽珍，等. 基于视觉识别的玉米病虫害检测与精准变量喷药系统研究[J]. 农业机械学报，2024，55(增刊 2)：210－221.
ZHU Huibin，WANG Mingpeng，BAI Lizhen，et al. Maize pest and disease detection and precise variable spraying system based on visual recognition[J]. Transactions of the Chinese Society for Agricultural Machinery，2024，55(Supp. 2)：210－221.(in Chinese)

[5] 赵良平，叶建仁，曹国江，等. 森林健康理论与病虫害可持续控制——对美国林业考察的思考[J]. 南京林业大学学报(自然科学版)，2002，26(1)：5－9.
ZHAO Liangping，YE Jianren，CAO Guojiang，et al. Forest health theory and sustained control of forest disease and pest—thinking about American forestry observation[J]. Journal of Nanjing Forestry University(Natural Sciences Edition)，2002，26(1)：5－9.(in Chinese)

[6] 瞿为民，朱德明. 国家生态安全：加入 WTO 背景下环境保护对策探析[J]. 中国人口·资源与环境，2003，13(2)：60－64.
QU Weimin，ZHU Deming. National ecological security：countermeasures of environmental protection in WTO[J]. China

Population, Resources and Environment, 2003, 13(2): 60 - 64. (in Chinese)
[7] 徐敏,秦顺兴,马乐宽,等. 水生态环境保护回顾与展望:从污染防治到三水统筹[J]. 中国环境管理,2021,13(5):69 - 78.
XU Min, QIN Shunxing, MA Lekuan, et al. Review and prospect of water ecology and environment protection: from pollution prevention and control to overall planning about water environment improvement, water resource security and water ecology protection[J]. Chinese Journal of Environmental Management, 2021, 13(5): 69 - 78. (in Chinese)
[8] 廖娟,陶婉琰,臧英,等. 农作物病虫害遥感监测关键技术研究进展与展望[J]. 农业机械学报,2023,54(11):1 - 19.
LIAO Juan, TAO Wanyan, ZANG Ying, et al. Research progress and prospect of key technologies in crop disease and insect pest monitoring[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(11): 1 - 19. (in Chinese)
[9] 李道亮,赵晔,杜壮壮. 农业领域多模态融合技术方法与应用研究进展[J]. 农业机械学报,2025,56(1):1 - 15.
LI Daoliang, ZHAO Ye, DU Zhuangzhuang. Advances in multi-modal fusion techniques and applications in agricultural field [J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(1): 1 - 15. (in Chinese)
[10] 李俊, 李夏莹, 王颢潜, 等. 转基因油菜筛查阳性质粒分子的研制及应用[J]. 中国农业科学,2020,53(7):1322 - 1337.
LI Jun, LI Xiaying, WANG Haoqian, et al. Development and application of plasmid reference molecule for genetically modified rapeseed screening[J]. Scientia Agricultura Sinica, 2020, 53(7): 1322 - 1337. (in Chinese)
[11] 陈爱莲, 朱玉霞, 孙伟, 等. 遥感技术在农业保险病虫害定损中的应用——以双河农场稻瘟病为例[J]. 遥感信息,2021,36(6):44 - 50.
CHEN Ailian, ZHU Yuxia, SUN Wei, et al. Determination of pests and diseases in agricultural insurance by remote sensing: taking rice blast in shuanghe farm for an example[J]. Remote Sensing Information, 2021, 36(6): 44 - 50. (in Chinese)
[12] 刘昊, 李静, 鲁旭涛. 5G 背景下智慧农业通信节点部署策略[J]. 西安交通大学学报,2020,54(10):45 - 53.
LIU Hao, LI Jing, LU Xutao. A deployment strategy for communication nodes of intelligent agriculture under 5G background [J]. Journal of Xi'an Jiaotong University, 2020, 54(10): 45 - 53. (in Chinese)
[13] 胡丹妮, 吴红玉, 叶振. 基于改进 YOLOv7 的航拍图像下松材线虫病疫木识别[J]. 林业工程学报,2025,10(2):147 - 155.
HU Danni, WU Hongyu, YE Zhen. Improved YOLOv7 based aerial images of pine nematode epidemic wood recognition[J]. Journal of Forestry Engineering[J]. Journal of Forestry Engineering, 2025, 10(2): 147 - 155. (in Chinese)
[14] 黄成龙, 柯宇曦, 华向东, 等. 边缘计算在智慧农业中的应用现状与展望[J]. 农业工程学报,2022,38(16):224 - 234.
HUANG Chenglong, KE Yuxi, HUA Xiangdong, et al. Application status and prospect of edge computing in smart agriculture [J]. Transactions of the CSAE, 2022, 38(16): 224 - 234. (in Chinese)
[15] 曹英丽, 张弘泽, 郭福旭, 等. 基于无人机遥感的农作物病害监测研究进展[J]. 沈阳农业大学学报,2024,55(5):616 - 628.
CAO Yingli, ZHANG Hongze, GUO Fuxu, et al. Research progress of crop disease monitoring based on UAV remote sensing [J]. Journal of Shenyang Agricultural University, 2024, 55(5): 616 - 628. (in Chinese)
[16] 刘帅兵,金秀良,冯海宽,等. 病害胁迫下玉米 LAI 遥感反演研究[J]. 农业机械学报,2023,54(3):246 - 258.
LIU Shuaibing, JIN Xiuliang, FENG Haikuan, et al. Analysis of effect of disease stress on maize LAI remote sensing estimation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(3): 246 - 258. (in Chinese)
[17] 陆健强,袁家俊,余超然,等. 融合多源评价数据的荔枝果期表型特征评估[J]. 农业机械学报,2025,56(3):91 - 100.
LU Jianqiang, YUAN Jiajun, YU Chaoran, et al. Evaluation of phenotypic characteristics in litchi fruiting stage using multi-source evaluation data[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(3): 91 - 100. (in Chinese)
[18] 陆健强,常虎虎,兰玉彬,等. 基于超分辨率重建和 Transformer 的退化草地空斑定位方法[J]. 农业工程学报,2024,40(10): 203 - 212.
LU Jianqiang, CHANG Huhhu, LAN Yubin, et al. Location method of degraded grassland patches based on super-resolution reconstruction and Transformer[J]. Transactions of the CSAE, 2024, 40(10): 203 - 212. (in Chinese)
[19] SOUQUES L, LANGLADE N B, DEBAEKE P, et al. Phenotypic traits of sunflower varieties depend on the composition of cover crops[J]. Field Crops Research, 2025, 321: 109692.
[20] 王志强,于雪莹,杨晓婧,等. 基于 WGAN 和 MCA - MobileNet 的番茄叶片病害识别[J]. 农业机械学报,2023,54(5):244 - 252.
WANG Zhiqiang, YU Xueying, YANG Xiaojing, et al. Tomato leaf diseases recognition based on WGAN and MCA - MobileNet[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(5): 244 - 252. (in Chinese)
[21] SANGAIAH A K, YU F N, LIN Y B. UAV T - YOLO - Rice: an enhanced tiny Yolo networks for rice leaves diseases detection in paddy agronomy[J]. IEEE Transactions on Network Science and Engineering, 2024, 11(6): 5201 - 5216.
[22] REN S, HE K, GIRSHICK R, et al. Phenotypic traits of sunflower varieties depend on the composition of cover crops[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137 - 1149.
[23] HE K, GEORGIA G, DOLLAR P, et al. Mask R - CNN[J]. lEEE Transactions on Pautem Analysis & Machine Intelligence, 2020, 42(2): 386 - 397.
[24] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]// Computer

Vision and Pattern Recognition. IEEE, 2016:779－788.
[25] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[C]// European Conference on Computer Vision,2016:21－37.
[26] REIS D, KUPEC J, HONG J,et al. Real-time flying object detection with YOLOv8[J]. arXiv Preprint,arXiv:2305.09972, 2023.
[27] TANG Yehui, HAN Kai, GUO Jianyuan, et al. GhostNetV2: enhance cheap operation with long-range attention[J]. arXiv preprint arXiv:2211.12905,2022.
[28] TAN Mingxing, PANG Ruoming, QUOC V. Le. EfficientDet: scalable and efficient object detection[J]. arXiv Preprint,arXiv: 1911.09070,2019.
[29] ZHANG Hao, XU Cong, ZHANG Shuaijie. Inner－IoU: more effective intersection over union loss with auxiliary bounding box [J]. arXiv preprint, arXiv:2311.02877,2023.
[30] ZHOU Mingle, XING Rui, HAN Delong, et al. PDT: UAV target detection dataset for pests and diseases tree[J]. arXiv Preprint,arXiv:2409.15679,2024.
[31] HORVAT M, JELEČEVIĆ L, GLEDEC G. A comparative study of YOLOv5 models performance for image localization and classification[C]// Central European Conference on Information and Intelligent Systems. Faculty of Organization and Informatics Varazdin, 2022:349－356.
[32] HU Jie, SHEN Li, ALBANIE S, et al. Squeeze-and-Excitation networks[J]. arXiv Preprint,arXiv:1709.01507,2017.
[33] 林文树,张金生,何乃磊.基于改进 YOLO v4 的落叶松毛虫侵害树木实时检测方法[J].农业机械学报,2023,54(4):304－312,393.
LIN Wenshu, ZHANG Jinsheng, HE Nailei. Real-time detection method of dendrolimus superans-infested *Larix gmelinii* trees based on improved YOLO v4[J]. Transactions of the Chinese Society for Agricultural Machinery,2023,54(4):304－312,393. (in Chinese)
[34] LUNDBERG S M, LEE S I. A unified approach to interpreting model predictions[C]// Proceedings of the 31st International Conference on Neural Information Processing Systems (NeurIPS 2017). New York: Curran Associates Inc., 2017: 4768－4777.
[35] 仝召茂,陈学海,汪本福,等.一种基于改进 YOLOv5s 的麦穗检测计数方法[J].南京农业大学学报,2024,47(6):1202－1211.
TONG Zhaomao, CHEN Xuehai, WANG Benfu, et al. A wheat ear detection and counting method based on improved YOLOv5s[J]. Journal of Nanjing Agricultural University,2024,47(6):1202－1211. (in Chinese)
[36] 罗显志,汪航.跨尺度特征融合的无人机小目标检测算法[J].计算机工程与应用,2025,61(14):135－147.
LUO Xianzhi, WANG Hang. Small target detection algorithm for UAV based on cross-scale feature fusion[J]. Computer Engineering and Applications, 2025,61(14):135－147. (in Chinese)

(上接第 447 页)

[28] 叶沅鑫, 谭鑫, 孙苗苗, 等. 基于增强 DeepLabV3 网络的高分辨率遥感影像分类[J]. 测绘通报, 2021, 5(4): 40－44.
YE Yuanxin, TAN Xin, SUN Miaomiao, et al. High-resolution remote sensing image classification based on improved DeepLabV3 network[J]. Bulletin of Surveying and Mapping, 2021, 5(4): 40－44. (in Chinese)
[29] WANG L, LI R, ZHANG C, et al. UNetFormer: a UNet-like transformer for efficient semantic segmentation of remote sensing urban scene imagery[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2022, 190: 196－214.
[30] WANG X, HU Z, SHI S, et al. A deep learning method for optimizing semantic segmentation accuracy of remote sensing images based on improved UNet[J]. Scientific Reports, 2023, 13(1): 7600.
[31] 冯权泷,牛博文,陈泊安,等.土地利用/覆被深度学习遥感分类研究综述[J]. 农业机械学报,2022,53(3):1－17.
FENG Quanlong, NIU Bowen, CHEN Boan, et al. Review for deep learning in land use and land cover remote sensing classification[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(3): 1－17. (in Chinese)