doi:10.6041/j.issn.1000-1298.2026.09.031

基于 SCW - YOLO v8 的红脂大小蠹变色疫木小目标检测方法

崔树强[1]　王　晗[1]　刘文萍[1]　宗世祥[2]

(1.北京林业大学信息学院, 北京 100083; 2.北京林业大学林学院, 北京 100083)

摘要: 针对无人机于高空监测松林红脂大小蠹受灾情况时,变色疫木尺寸较小,分布密集且不规律所导致的漏检与误检等问题,本文提出了一种基于深度学习的 SCW - YOLO v8(Small object CoordAtt WIoU YOLO v8)模型。其在 YOLO v8 目标检测网络的 Backbone 部分的第 2 个 C2f 层加入小目标检测层,增加对小目标变色疫木检测精度;在 Backbone 部分的第 4 个 C2f 层与 SPPF 模块之间加入 CoordAtt 注意力机制,降低误检率;将 YOLO v8 原有的 CIoU 损失函数替换为 WIoU 损失函数,进一步提高检测精度。本文以无人机在高度 190 ~ 240 m 拍摄的红脂大小蠹受灾林图像为试验数据源,构建小目标变色疫木数据集。试验结果表明,该方法的平均精度均值(mAP)为 91.6%,F1 分数为 86.8%,相比改进前的 YOLO v8n 模型,分别提高 3.5、3.9 个百分点,且优于 YOLO v5n、YOLO v9t 与 YOLO v10n 等深度学习网络模型。试验结果表明,该模型可提高针对小目标变色疫木的检测精度,为遭受红脂大小蠹侵害的松林灾情防治提供技术支持。

关键词: 红脂大小蠹; 深度学习; YOLO v8; 小目标检测

中图分类号: TP391　　**文献标识码**: A　　**文章编号**: 1000-1298(2026)09-0329-10　　**OSID**:

Small Object Detection for *Dendroctonus valens* Infected Trees Based on SCW - YOLO v8

CUI Shuqiang[1]　WANG Han[1]　LIU Wenping[1]　ZONG Shixiang[2]

(1. *School of Information Science and Technology*, *Beijing Forestry University*, *Beijing* 100083, *China*
2. *College of Forestry*, *Beijing Forestry University*, *Beijing* 100083, *China*)

Abstract: *Dendroctonus valens* is a harmful forest pest that could cause major economic and environmental damage without effective control. Recently, combining UAV remote sensing with deep learning-based object detection has become an effective way to monitor large forest areas. However, due to the small size and uneven distribution of infected trees, there are issues of missed and false detection during the target detection process. To address these challenges, an SCW - YOLO v8 model based on deep learning which included three improvements was proposed. Firstly, a small object detection layer was added after the second C2f layer in the YOLO v8 Backbone structure to increase the detection accuracy for smaller-sized objects. Then, to reduce the false detection rate and improve detection accuracy, a coordinate attention (CoordAtt) mechanism was integrated into the backbone structure of YOLO v8. Finally, the WIoU loss function was introduced to improve detection accuracy. The dataset was constructed based on the infected forest of *Dendroctonus valens*, which were photographed at a height range of 190 m to 240 m. In this dataset, most of the infected trees to be detected were small objects. The experiment consisted of four parts. Firstly, a comparative analysis was conducted between YOLO v8n, YOLO v5n, YOLO v9n, YOLO v10n, and YOLO 11n algorithms, through experiment chose the optimal base network model. The experimental results showed that the YOLO v8 model outperformed other object detection algorithms in both mAP and F1-scores, and its model size was relatively suitable. Therefore, the YOLO v8 model was more appropriate to serve as the base object detection model. Then, the detection results of the CoordAtt were compared with that of CBAM, GAM, and SE attention

收稿日期: 2024 - 12 - 01　修回日期: 2024 - 12 - 17

基金项目: 国家重点研发计划项目(2022YFD1400403、2021YFD1400900)和中央高校优秀青年团队项目(QNTD202308)

作者简介: 崔树强(1996—),男,博士生,主要从事林业智能信息处理技术研究,E-mail: 18222576142@163.com

通信作者: 刘文萍(1971—),女,教授,博士生导师,主要从事计算机图像及视频分析与处理研究,E-mail: wendyl@vip.163.com

mechanisms, demonstrated the effectiveness of CoordAtt, its mAP and F1 scores were 88.8% and 83.9%. The third part of the experiment focused on the selection of the loss function. Three versions of the WIoU loss function were compared with CIoU, DIoU, and EIoU loss functions. The results showed that WIoUv3 achieved the best mAP (90.0%) and F1-scores (85.1%). Therefore, this loss function was selected as one of the improvements. Finally, ablation experiments were conducted to verify the effectiveness of each improvement method. Among them, adding small object detection layer increased the mAP to 90.4% and the F1 scores to 86.5%. The final SCW - YOLO v8 model, which integrated all improvement methods, achieved a maximum mAP of 91.6% and a maximum F1-scores of 86.8%. The analysis of the detection results demonstrated that small object detection layer could improve the detection accuracy for small objects. On this basis, CoordAtt attention mechanism could reduce false detections of incorrect targets, and the WIoUv3 loss function could further enhance detection accuracy. In summary, the SCW - YOLO v8 model proposed offered an efficient and reliable solution for forest pest detection, especially for the detection of small object *Dendroctonus valens* infected trees.

Key words: *Dendroctonus valens*; deep learning; YOLO v8; small object detection

0 引言

红脂大小蠹(*Dendroctonus valens* LeConte)是造成中国松林资源损失最为严重的虫害之一[1]。受红脂大小蠹危害的松树,其针叶首先褪色变黄,然后逐渐转为红褐色,最终凋落枯死[2]。红脂大小蠹暴发成灾后,可导致松林大面积死亡,如果不采取有效措施控制其扩散,将严重破坏各地松林,导致难以估量的经济和环境损失[3]。为了及时应对这一问题,必须随时监测红脂大小蠹适生区,发现染病变色木后,立刻采取焚烧、就地砍伐等方法进行清理,避免疫情蔓延至整个林区[4]。以往的红脂大小蠹监测手段主要为人工地面调查,或借助望远镜瞭望监测辖区内松林健康状况,监测范围小,工作量较大[5]。而借助无人机的遥感监测技术,因其易操作、成本低、时效性强等优点,对变色疫木的监测具有一定优势[6]。近年来兴起的深度学习技术利用卷积神经网络,能够自动从数据中学习到多层次的抽象特征,从而能够捕捉到更为复杂和高阶的特征关系,无需人工提取图像特征,仅凭无人机拍摄所得图像即可自动实现图像分类、目标检测、图像分割等计算机视觉任务[7]。相较于人工地面调查或瞭望,利用深度学习目标检测结合无人机监测技术,对红脂大小蠹变色疫木进行目标检测的方式,效率及稳定性更高,可实现对林区变色疫木现场实时检测[8-9]。

基于深度学习的目标检测方法可分为一阶段目标检测与两阶段目标检测方法。其中,两阶段方法的主要原理为首先由算法生成一系列作为样本的候选框,再通过卷积神经网络进行分类。常用的两阶段深度学习目标检测方法包括区域卷积神经网络(Region-based convolutional neural network, R - CNN)、Fast R - CNN、Faster R - CNN 与 Mask R - CNN 等[10-12]。黄华毅等[13]采用 Fast R - CNN 目标检测网络对松材线虫受害木进行检测,其准确率可达 90%,初步证明了深度学习方法在森林病虫害检测领域的有效性。徐信罗等[14]对 Faster R - CNN 的锚框进行了修改,对松材线虫受害木的检测精度相比改进前提升了 6.78 个百分点。YU 等[15]以遭受松材线虫侵害的变色疫木为研究对象,基于无人机拍摄的受灾林区图像与 Resnet50 方法,提出了 SPW - FEN(Shallow pooled weighted feature enhancement network)网络模型,相比改进前的 Faster R - CNN 方法,平均精度提升了 3.8 个百分点。王晓婷等[16]基于迁移学习和特征金字塔网络(Feature pyramid network, FPN)对 Mask R - CNN 网络进行改进,并用于对植物表型的检测研究,其精度提高约 2.2 个百分点。两阶段方法的主要缺陷在于计算复杂度高,运行设备要求高,内存占用量大,检测速度慢,参数调整困难[17]。

一阶段目标检测方法无需产生候选框,直接将目标定位的问题转换为回归问题进行处理,模型参数少,运算速度快。一阶段深度学习方法中,YOLO(You only live once)系列是较为主流的算法,其主要方法包括 YOLO v5、YOLO v6、YOLO v7、YOLO v8、YOLO v9 等[18-22]。在目标检测领域,针对不同的研究目标,YOLO 系列有着广泛的应用和改进[23-25]。其中,在植被虫害检测方面,黄丽明等[26]利用深度可分离卷积和倒残差结构改进 YOLO v4 算法,用于检测松材线虫变色疫木,改进后的平均精度为 80.85%,模型大小为 44.2 MB,优于 Faster R - CNN 等方法。ZHANG 等[27]在 YOLO v4 模型的基础上采用了注意力机制与特征增强作为改进方法,将变色疫木的平均检测精度由改进前的 77.81% 提升至 79.39%。DU 等[28]在 YOLO v5 目标检测网络结构中引入了自适应尺度选择融合模块(Adaptively

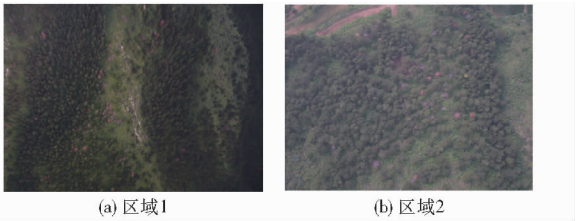
spatial feature fusion，ASSF）、Shufflev2 网络和简单注意力模块（Simple attention module，SimAM），对于松材线虫受害木的检测精度可达 95.64%。ZHU 等[29]在基础 YOLO v7 网络结构中添加了 SE 注意力机制（Squeeze-and-excitation attention mechanism，SE），针对松材线虫变色疫木的召回率为 89.58%，检测准确率为 92.81%，相比改进前分别提高 4.72、1.99 个百分点。YAO 等[30]在 YOLO v8 网络中添加了深度可分离卷积（Dynamic snake convolution，DSConv）、多维协同注意力机制（Multidimensional collaborative attention mechanism，MCA），并与 WIoU 损失函数（Wise intersection over union）相结合，对于松材线虫受害木的最高检测精度为 90.69%。

综上所述，目前针对松林变色疫木目标检测的研究，主要以松材线虫为研究对象，针对红脂大小蠹较少。同时，YOLO v8 在小目标检测方面仍存在不足，在森林变色疫木检测领域仍有提升空间[31－32]。因此，增强 YOLO v8 模型对红脂大小蠹小目标变色疫木的检测能力，具有重要的现实意义，不仅能够提升林业部门对森林病虫害的监测和预防效率，还将为森林资源保护提供更有效的技术支持。对此，本文在 YOLO v8 网络结构的基础上进行改进，提出一种 SCW－YOLO v8 检测方法，分别从网络结构与损失函数等方面进行改进，以提高对小目标变色疫木的检测精度。

1　材料与方法

1.1　研究区域

本文研究区位于辽宁省凌源县大河北镇的试验林，该地区森林植被类型丰富，以油松等针叶林为主。该地区过去面临较为严重的虫害威胁，截至本文数据采集工作时已有多株疫木呈现树冠变红，乃至褪色枯死的特征。其中红脂大小蠹是造成油松死亡的主要虫害。依据地理位置与受害变色疫木的主要分布（118°55′～118°58′E，40°52′～40°53′N），该区域有区域 1 与区域 2 共计 2 片样地，样地受灾林区部分区域外观如图 1 所示。本文数据集所用原始图像均来自区域 1 与区域 2。



(a) 区域1　　(b) 区域2

图 1　研究样地

Fig. 1　Study plots

1.2　数据集构建及目标检测流程

图像数据拍摄所用设备为大疆精灵 4 型航拍无人机。进行数据采集工作时，其飞行高度为 190～240 m，飞行速度为 5 m/s，采用扫描航线的方式进行拍摄。航拍图像为 JPG 格式，包含地理坐标和飞行高度信息，图像分辨率为 5 280 像素×3 956 像素。同时，采用人工验证对树木的健康状况进行分析，确定树木的变色是否由红脂大小蠹危害引起。

本文使用开源标注软件 LabelImg 构建数据集，通过该软件对原始图像中的红脂大小蠹变色疫木（树冠呈现红色或大部分为红色）进行标注，记录边界框位置，形成［类别，中心坐标，宽度，高度］格式的数据集标签。其中，宽度与高度为边界框与图像整体宽度与高度的比例。

本文采集的原始图像分辨率为 5 280 像素×3 956 像素，无法直接用于训练目标检测框架。因此，为减小运算量、加快训练速度，在构建数据集阶段，以 512 像素为裁剪步长，将原始图像裁剪为若干幅 640 像素×640 像素的图像，并清除其中不包含受灾林区信息的无效图像，得可用图像 1 984 幅。其中训练集 980 幅，验证集 502 幅，测试集 502 幅。

在此基础上，进一步统计了数据集中不同尺寸变色疫木的占比。依据目标面积所占图像整体面积的比例，将目标划分为小目标（占比小于等于 0.002 5）、中目标（占比大于 0.002 5，小于 0.022 5）与大目标（占比大于等于 0.022 5）[33]。统计方法为依据数据集标签中的宽度与高度信息，使用 Python 程序计算不同类别目标的占比。

计算结果小目标变色疫木所占比例最大为 84.3%，中目标次之为 15.4%，大目标变色疫木所占比例最低，为 0.3%。因此，小目标变色疫木的检测将是本文的重点与难点。

本文变色疫木检测的流程如图 2 所示。首先，使用无人机采集图像，依据前文的方法采用 LabelImg 软件标注并构建数据集。在此基础上，将标定后的训练集图像送入改进后的深度学习目标检测网络中，在计算机设备上进行模型训练，得到检测模型。由检测模型对测试集图像进行检测，得到检测结果。依据不同的深度学习目标检测方法的检测结果，基于平均精度选取最佳的检测算法与模型。

1.3　基于 SCW－YOLO v8 的红脂大小蠹变色疫木检测模型构建

1.3.1　YOLO v8 模型

YOLO v8 是一种深度学习目标检测模型[34]，具有模型参数少、运算速度快、准确率高的优点。YOLO v8 的结构如图 3 所示，其架构包括 3 部分：

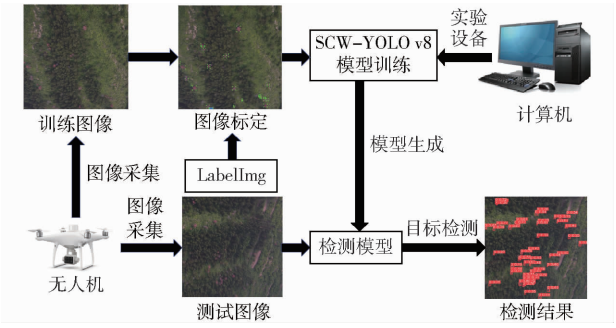


图 2 目标检测流程

Fig. 2 Object detection process

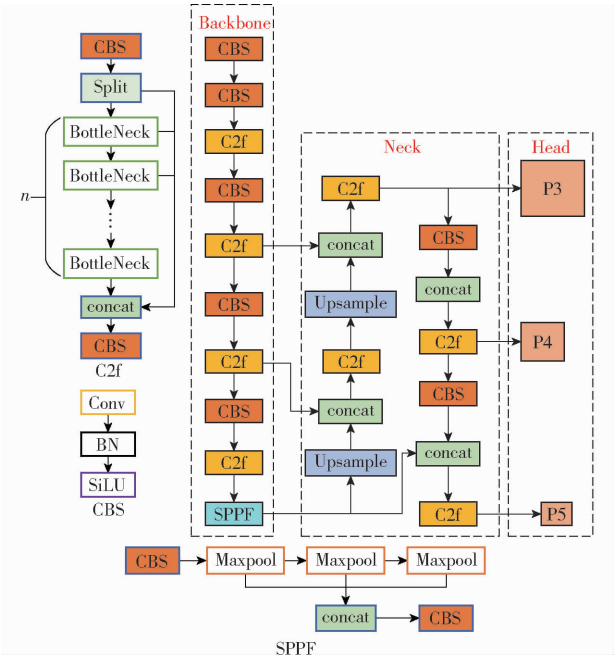


图 3 YOLO v8 结构图

Fig. 3 System of YOLO v8

Backbone、Neck 和 Head。

其中,Backbone 部分采用了一系列卷积和反卷积层进行特征图提取。Neck 网络负责对从骨干网络中提取的不同阶段特征图进行语义信息与定位信息融合,以增强目标检测的准确性和鲁棒性,该部分采用路径聚合网络(Path aggregation network, PANet)结构。Head 采用了解耦封头结构,对分类和检测探头进行了分离,并将 YOLO 系列以往基于锚点的方法替换为无锚点方法。该结构使用 2 个卷积层来执行分类和回归操作,提高了准确率与检测速度。

1.3.2 小目标检测层

改进前的 YOLO v8 网络仅对 P3、P4、P5 层输出进行检测,其输出特征尺寸分别为输入特征的 1/8、1/16 和 1/32。若输入目标尺寸极小,则该目标输出特征尺寸将难以检测,因此目标尺寸越小,检测能力越弱。而在高空检测红脂大小蠹变色疫木时,需要对大量的小目标进行检测。

因此,为增强对图像中小目标变色疫木的检测精度,在 YOLO v8 的 Backbone 部分添加了小目标检测层,其结构如图 4 中红色方框内所示,在第 2 层 C2f 后新添加一个包含上采样的输出分支。其输出特征为输入特征尺寸的 1/4。相比改进前的 YOLO v8 网络模型,减少了微小特征的信息丢失。

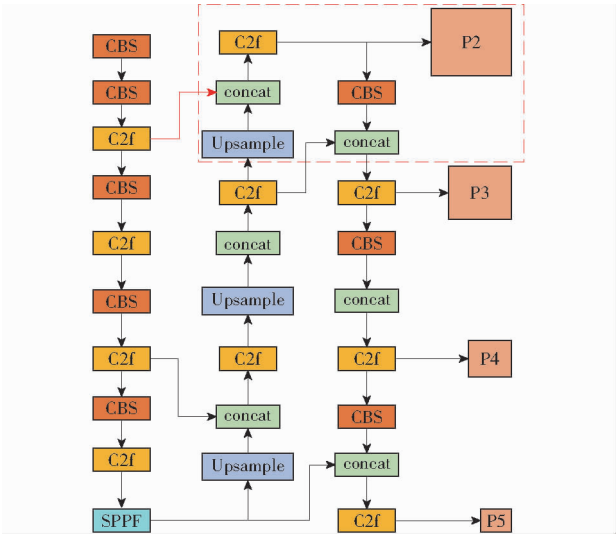


图 4 添加小目标检测层后 YOLO v8 结构图

Fig. 4 Structure of YOLO v8 after adding small detection layer

1.3.3 CoordAtt 注意力机制

添加小目标检测层虽然提升了对小目标的检测精度,但对于部分错误目标,如形状类似小目标变色木的地面区域等,会将其错误识别为变色木,其示例如图 5 所示。而注意力机制可通过权重计算与加权求和等操作,为输入特征分配不同的权重,突出关键特征的影响,同时抑制不重要的部分,从而提高模型的特征表达能力和性能。应用在本文中,可提高深度学习目标检测网络对变色木的特征关注度,减少对非变色木目标的错误检测情况,提高检测精度。



图 5 错误检测示例

Fig. 5 Error detection example

常用的注意力机制包括卷积块注意力机制(Convolutional block attention module, CBAM)、SE 注意力机制、全局注意力机制(Global attention mechanism, GAM)等。坐标注意力机制(Coordinate attention, CoordAtt)[35]是一种较新的注意力机制,相对于 CBAM 和 SE 等传统注意力机制,其特点在

于引入了水平和垂直方向的空间信息，可以更精确地捕获特征中的位置分布，增强网络对目标物体的空间感知能力。同时，CoordAtt 将空间信息编码进通道注意力中，使得网络能够更准确地区分目标区域和背景区域。CoordAtt 注意力机制的结构如图 6 所示。

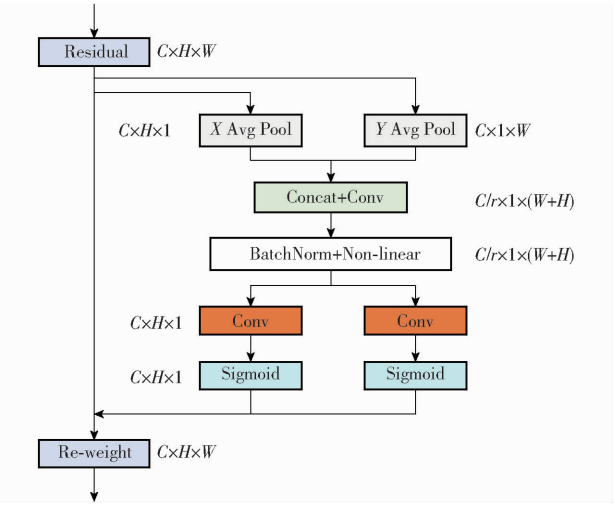


图 6　CoordAtt 注意力机制结构

Fig. 6　Structure of CoordAtt attention mechanism

其计算过程的第 1 步为：对于输入的特征图 $\boldsymbol{X}\in\mathbf{R}^{C\times H\times W}$，将其分别从水平和垂直 2 个方向进行平均池化，得到 2 个方向的特征 z_h 与 z_w，该计算过程为

$$z_h(C,H)=\frac{1}{W}\sum_{i=1}^{W}\boldsymbol{X}(C,H,i)\quad(z_h\in\mathbf{R}^{C\times H\times 1}) \tag{1}$$

$$z_w(C,W)=\frac{1}{H}\sum_{j=1}^{H}\boldsymbol{X}(C,j,W)\quad(z_w\in\mathbf{R}^{C\times 1\times H}) \tag{2}$$

式中　W——特征图宽度

H——特征图高度

C——通道数

在此基础上，将 2 个方向的特征 z_h 与 z_w 拼接形成联合特征 $\boldsymbol{F}$，并对其用卷积进行降维操作，计算公式为

$$\boldsymbol{F}=\mathrm{ConvD}([z_h,z_w])\quad(\boldsymbol{F}\in\mathbf{R}^{C/r\times(H+W)}) \tag{3}$$

式中　r——通道压缩率

ConvD——卷积操作

对于降维后的特征 $\boldsymbol{F}$，通过 ReLU 非线性激活函数进行处理，并从 2 个方向生成注意力权重 $\boldsymbol{W}_h$ 和 $\boldsymbol{W}_w$，其计算公式为

$$\boldsymbol{F}'=\mathrm{Conv1}D(\mathrm{ReLU}(\boldsymbol{F}))\quad(\boldsymbol{F}'\in\mathbf{R}^{C\times(H+W)}) \tag{4}$$

$$\boldsymbol{W}_h=\boldsymbol{\sigma}(\boldsymbol{F}_h')\quad(\boldsymbol{W}_h\in\mathbf{R}^{C\times H\times 1}) \tag{5}$$

$$\boldsymbol{W}_w=\boldsymbol{\sigma}(\boldsymbol{F}_w')\quad(\boldsymbol{W}_w\in\mathbf{R}^{C\times 1\times H}) \tag{6}$$

式中　$\boldsymbol{\sigma}$——Sigmoid 激活函数，用于归一化权重

最后，将生成的注意力权重 $\boldsymbol{W}_h$ 和 $\boldsymbol{W}_w$ 作用于输入特征图 $\boldsymbol{X}\in\mathbf{R}^{C\times H\times W}$，生成增强后的输出特征图 $\boldsymbol{Y}\in\mathbf{R}^{C\times H\times W}$，其计算公式为

$$\boldsymbol{Y}(C,H,W)=\boldsymbol{X}(C,H,W)\boldsymbol{W}_h(C,H)\boldsymbol{W}_w(C,W) \tag{7}$$

图 7 为结合 CoordAtt 注意力机制与小目标检测层的 YOLO v8 网络模型结构图，改进之处如红色虚线框与红色线条所示。在添加了小目标检测层的基础上，经过多次试验对比，选择在 SPPF 模块与第 4 个 C2f 模块之间加入 CoordAtt 注意力机制。

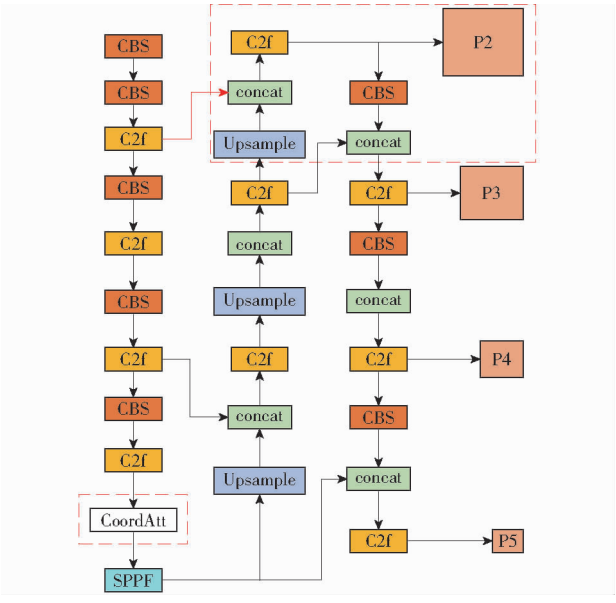


图 7　改进后的 YOLO v8 网络结构

Fig. 7　Structure of improved YOLO v8 network

1.3.4　WIoU 损失函数

损失函数是衡量预测结果与真实结果之间差异的函数。在深度学习训练过程中，模型会通过前向传播得到预测值，然后使用损失函数计算出模型的误差值，用于调整模型参数，如偏置和权重等，以便模型在下次预测中能够得到更准确的结果。传统的 IoU 损失函数，采用的方法是计算预测框与真实框的交并比，即预测框与真实框的交集与并集的比值，该比值与 1 的差即为目标检测的损失，其计算公式为

$$L_{\mathrm{IoU}}=1-IoU \tag{8}$$

其中

$$IoU=\frac{|A\cap B|}{|A\cup B|} \tag{9}$$

式中　A——预测框　　B——真实框

L_{IoU}——目标检测损失

传统 IoU 损失函数的局限性在于如果不同预测框与真实框交并比相同，但是位置不同时，无法进行区分。

CIoU 损失函数（Complete intersection over union）[36] 是 YOLO v8 的基础损失函数，它考虑了重叠面积、中心点距离和宽高比 3 个重要的几何因素，

相对于传统的 IoU 损失函数有所改进。其公式为

$$L_{\mathrm{CIoU}} = 1 - IoU + \rho^2(A_{ctr}, B_{ctr})/d^2 + \alpha\upsilon \quad (10)$$

其中

$$\upsilon = \frac{4}{\pi^2}\left(\arctan\frac{w_{gt}}{h_{gt}} - \arctan\frac{w_t}{h_t}\right)^2 \quad (11)$$

$$\alpha = \frac{\upsilon}{1 - IoU + \upsilon} \quad (12)$$

式中 L_{CIoU}——CIoU 损失函数目标损失

A_{ctr}——预测框中心点

B_{ctr}——真实框中心点

$\rho(A_{ctr}, B_{ctr})$——A_{ctr}、B_{ctr}两点间的欧氏距离

d——包含预测框与真实框的最小框的对角线距离

w_{gt}——预测框宽度

h_{gt}——预测框高度

w_t——真实框宽度

h_t——真实框高度

CIoU 损失函数的局限性在于如果预测框和真实框的长宽比相同,则 υ 恒为 0。此外,由于 CIoU 损失函数对 IoU 的依赖性,在预测框与真实框之间几乎无重叠时,梯度较小,难以为极小目标提供有效的优化信号。同时,面对细长目标时,由于过度强调形状优化,会产生忽视物体实际尺寸的情况,导致预测框的形状调整并不能有效提升检测精度。

与 CIoU 损失函数相比,WIoU 损失函数[37]综合考虑了目标框的位置和形状信息,更适用于低质量数据集,如目标尺寸过小,物体标注不够准确、目标长宽比较大等情况。其主要运算思路为计算预测框与真实框之间的交集面积和并集面积,引入权重因子,对不同类别的目标进行不同程度的加权,最后计算加权后的交并比,并将其补集取负数作为损失函数的值。目前 WIoU 存在 v1、v2、v3 共计 3 种版本。其中 v1 版本计算式为

$$L_{\mathrm{WIoUv1}} = R_{\mathrm{WIoU}} L_{\mathrm{IoU}} \quad (13)$$

$$R_{\mathrm{WIoU}} = \exp\left(\frac{(x_t - x_{gt})^2 + (y_t - y_{gt})^2}{W_g^2 + H_g^2}\right) \quad (14)$$

式中 L_{WIoUv1}——v1 版本的目标损失

R_{WIoU}——权重因子

W_g——包含预测框与真实框的最小框宽度

H_g——包含预测框与真实框的最小框高度

(x_{gt}, y_{gt})——预测框的中心点坐标

(x_t, y_t)——真实框的中心点坐标

WIoUv3 版本计算公式为

$$L_{\mathrm{WIoUv3}} = sL_{\mathrm{WIoUv1}} \quad (15)$$

其中

$$s = \frac{\beta}{\delta\alpha^{\beta-\delta}} \quad (16)$$

$$\beta = \frac{L_{\mathrm{IoU}}}{\overline{L}_{\mathrm{IoU}}} \quad (\beta \in [0, +\infty)) \quad (17)$$

式中 L_{WIoUv3}——v3 版本的目标损失

α——聚集参数

β——预测框的离群度

δ——平衡参数

$\overline{L}_{\mathrm{IoU}}$——$L_{\mathrm{IoU}}$均值

s——梯度增益

1.4 试验环境与评价指标

本文使用 PyTorch 深度学习开源框架,服务器搭载 NVIDIA GeForce GTX 1080Ti GPU,显存容量为 11 GB,代码运行与编译 IDE 环境为 Pycharm。训练轮数为 250,设置 batch size 为 8。

在本文的试验中,使用平均精度均值(mean Average Precision, mAP)和 F1 分数(F1-scores)来评估检测模型对红脂大小蠹变色疫木目标检测的结果。2 种指标由精确率和召回率计算所得。

AP 是精确率-召回率(Precision - recall)曲线下的面积。用于评估单个类的目标检测性能。mAP 是所有类别 AP 值的平均值,它考虑了不同类别之间的差异,更全面地反映了模型的性能。F1 分数是精确率与召回率的调和平均值。F1 分数越高,目标检测效果越好。

2 试验结果与分析

2.1 基础模型选择

首先,为确定本文深度学习目标检测网络所用基础模型,将 YOLO v8n 与 YOLO v5n、YOLO v9t、YOLO v10n,以及 YOLO 11n 的检测结果进行对比,其结果如表 1 所示。

表 1 不同基础模型检测结果对比

Tab.1 Detection results of different foundation methods

%

模型	mAP	F1 分数
YOLO v5n	83.8	81.4
YOLO v8n	88.1	82.9
YOLO v9t	86.3	82.9
YOLO v10n	85.3	81.1
YOLO 11n	86.9	82.3

由表 1 可知,YOLO v8n 的精度高于 YOLO 系列的其它算法,其 mAP 与 F1 分数最高,分别为 88.1%与 82.9%。YOLO v5n 的 mAP 与 F1 分数最低,分别为 83.8%与 81.4%。YOLO v9t 模型的 F1 分数与 YOLO v8n 模型相等,为 82.9%,且其 mAP 值低于 YOLO v8n。因此,综合各个模型的精度,本文针对红脂大小蠹小目标变色疫木目标检测的研究,以 YOLO v8 作为基础改进算法。

2.2　注意力机制比较

如图 7 所示，本文在 SPPF 模块与第 4 个 C2f 模块之间加入 CoordAtt 注意力机制。为证明该区域为注意力机制最佳添加位置，进行了对比试验，其结果如表 2 所示。其中，N0 为不添加注意力机制的模型，N1 至 N4 为分别在 YOLO v8 网络结构中的第 1、2、3、4 个 C2f 模块后添加注意力机制的模型。

表 2　注意力机制在不同位置检测结果

Tab. 2　Attention mechanism detection results at different locations

模型	CoordAtt	放置层数	mAP/%	F1 分数/%
N0			88.1	82.9
N1	√	1	87.7	83.2
N2	√	2	88.3	83.3
N3	√	3	88.3	83.4
N4	√	4	88.8	83.9

注：√表示使用该方法，下同。

由表 2 可以看出，在第 4 个 C2f 模块后添加注意力机制的 N4 模型精度最高，其 mAP 与 F1 分数分别为 88.8% 与 83.9%。在第 1 个 C2f 模块后添加注意力机制的 N1 模型精度最低，其 mAP 为 87.7%，低于不添加注意力机制的 N0 模型。因此，YOLO v8 的第 4 个 C2f 模块与 SPPF 模块之间为注意力机制的最佳添加位置。

在此基础上，为验证 CoordAtt 注意力机制的有效性，选择了 GAM、CBAM 与 SE 3 种注意力机制与其作对比试验，其结果如表 3 所示。4 种注意力机制均依照图 7 的方式引入 YOLO v8 深度学习目标检测网络结构中。

表 3　不同注意力机制检测结果

Tab. 3　Detection results for different attention mechanisms　%

模型	mAP	F1 分数
GAM	88.6	83.5
CBAM	88.7	83.6
SE	88.2	83.7
CoordAtt	88.8	83.9

由表 3 可以看出，4 种注意力机制当中，CoordAtt 注意力机制的 mAP 与 F1 分数最高，分别为 88.8% 与 83.9%。GAM 注意力机制的 F1 分数最低，为 83.5%，SE 注意力机制的 mAP 最低，为 88.2%。相对于传统的通道注意力机制，CoordAtt 注意力机制可在一定程度上克服对空间信息捕获不足的局限。综上所述，本文选择引入 CoordAtt 注意力机制对 YOLO v8 深度学习目标检测网络进行改进。

2.3　损失函数比较

为确定本文深度学习目标检测网络所用损失函数，将 WIoU 的 3 种版本，与 YOLO v8 基础的 CIoU 损失函数，以及常用的 DIoU（Distance intersection over union）与 EIoU（Efficient intersection over union）损失函数的检测效果进行对比，其结果如表 4 所示。

表 4　不同损失函数精度评估

Tab. 4　Accuracy evaluation of different loss functions　%

模型	mAP	F1 分数
CIoU	88.1	82.9
DIoU	89.2	84.9
EIoU	88.8	84.0
WIoUv1	89.5	85.1
WIoUv2	89.3	84.4
WIoUv3	90.0	85.1

由表 4 可知，WIoUv3 的 mAP 值最高，为 90.0%，远高于 CIoU 损失函数的 88.1%。相对来说，WIoUv1 与 WIoUv2 的 mAP 值均略低于 WIoUv3 版本。DIoU 损失函数的 mAP 为 89.2%，高于 CIoU 与 EIoU 损失函数，低于 WIoU 损失函数。

对于 F1 分数，WIoUv3 最高，为 85.1%，与 WIoUv2 相同。DIoU 损失函数的 F1 分数为 84.9%，低于 WIoUv3 与 WIoUv2，但高于其它损失函数。CIoU 损失函数的 F1 分数最低，为 82.9%，远低于其它种类损失函数。综上所述，选择 WIoUv3 作为本文所用的损失函数。

2.4　消融试验

在前文的基础上，为确定本文目标检测方法的有效性，进行了消融试验，其结果如表 5 与图 8 所示。其中表 5 为不同模型的 mAP 与 F1 分数值，其值越大，则模型精度越高。图 8 为不同模型的精确率-召回率曲线，其与横轴、竖轴所包围面积越大，则模型的精度越高。K0 模型为基础的 YOLO v8n 模型，K1 ~ K3 为分别加入小目标检测层，引入 CoordAtt 注意力机制，修改损失函数为 WIoUv3 的模型，K4 为结合小目标检测层与 CoordAtt 注意力机制方法的模型，K5 为加入全部改进方法的模型。

表 5　消融试验结果

Tab. 5　Ablation experiment results　%

模型	YOLO v8n	小目标检测层	CoordAtt	WIoUv3	mAP	F1 分数
K0	√				88.1	82.9
K1	√	√			90.4	86.5
K2	√		√		88.8	83.9
K3	√			√	90.0	85.1
K4	√	√	√		91.1	86.5
K5	√	√	√	√	91.6	86.8

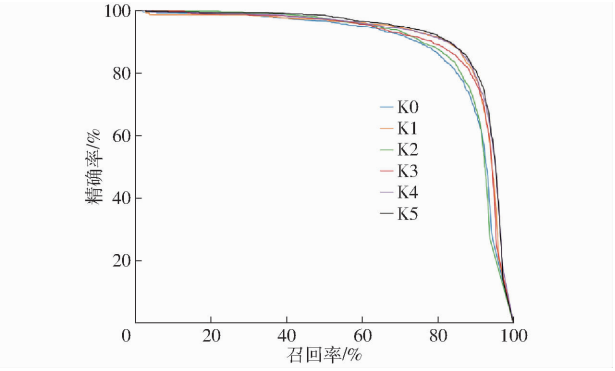


图 8 不同模型精确率-召回率曲线

Fig. 8 Precision - recall curves of different models

由表 5 和图 8 可知,3 种改进方法均可以提高目标检测的精度。其中,由 K1 模型可以看出,加入小目标检测层提升效果最为显著,其 mAP 与 F1 分数分别提高了 2.3、3.6 个百分点。引入 CoordAtt 注意力机制与 WIoUv3 损失函数均可以提高目标检测网络的检测精度。其中,引入 WIoUv3 损失函数的提升效果相对 CoordAtt 注意力机制较为明显。此外,由 K4 模型的 mAP 与 F1 分数可以看出,结合小目标检测层与 CoordAtt 注意力机制的模型,其 mAP 与 F1 分数分别为 91.1% 与 86.5%,高于单独使用 2 种方法。而由 K5 模型的 mAP 与 F1 分数,及精确率-召回率曲线可以看出,结合 3 种方法改进后的 SCW-YOLO v8 模型在精度方面提升最明显,其 mAP 与 F1 分数最高,分别为 91.6% 与 86.8%,相比 YOLO v8n 模型分别提升 3.5、3.9 个百分点,远高于 K1、K2 和 K3 模型,略高于 K4 模型。CoordAtt 注意力机制与 WIoUv3 损失函数可在加入小目标检测层的基础上,进一步提升 YOLO v8 深度学习目标检测网络的检测效果。

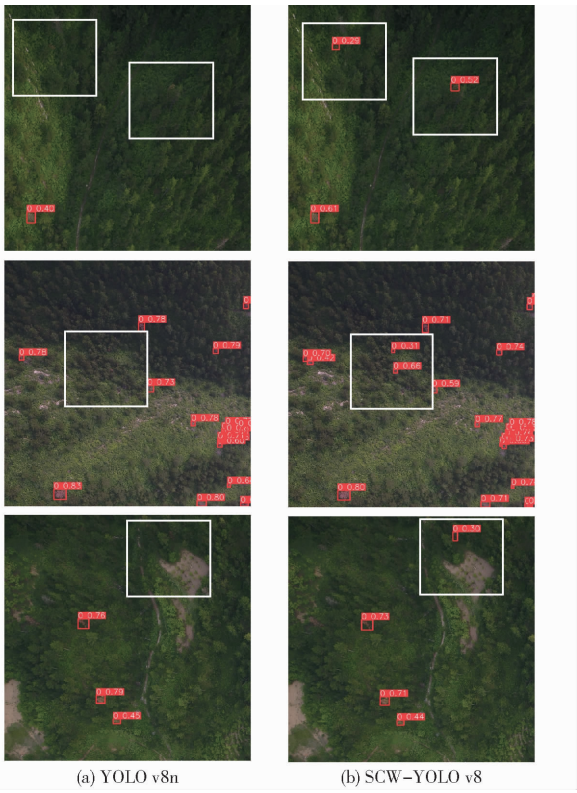
2.5 检测结果分析

基于 YOLO v8 目标检测网络改进前后的模型对红脂大小蠹变色疫木数据集的整体检测结果示例对比如图 9 所示。

可以看出,基础 YOLO v8n 模型可以检测出多数较为明显的红脂大小蠹变色疫木,但对图像中不明显、尺寸极小的小目标变色疫木,如白色方框内所示,容易出现漏检的情况。而改进后的 SCW-YOLO v8 模型可相对精确地检测出尺寸极小的目标,降低针对小目标的漏检率,而数据集中小目标占比最大,因此,整体检测精度也随之提升。

在此基础上,为进一步分析本文改进方法的有效性,分别对比分析了 3 种改进方法的精度提升效果,其示例如图 10 所示。

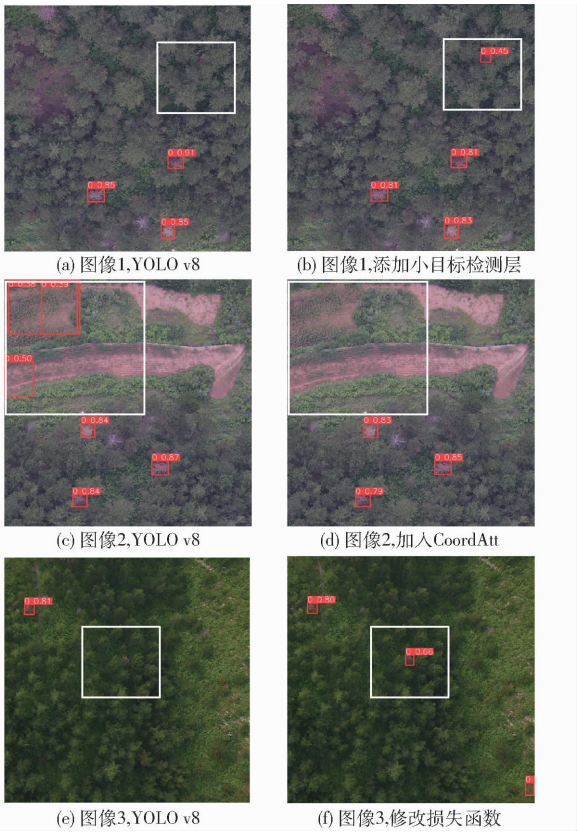
其中,由图 10a、10b、10e 和图 10f 的白色方框内所示区域可以看出,添加小目标检测层与修改损失函数为 WIoUv3 均可以减少因树木遮挡、目标尺寸过小造成的漏检情况。结合表 5 消融试验的结果



(a) YOLO v8n (b) SCW-YOLO v8

图 9 检测结果对比示例

Fig. 9 Detection result comparison example



(a) 图像1,YOLO v8 (b) 图像1,添加小目标检测层

(c) 图像2,YOLO v8 (d) 图像2,加入CoordAtt

(e) 图像3,YOLO v8 (f) 图像3,修改损失函数

图 10 不同方法检测结果对比示例

Fig. 10 Comparison examples of results by different methods

可知，添加小目标检测层的 mAP 为 90.4%，添加 WIoUv3 损失函数的为 90.0%，前者相比后者对于目标检测的精度提升效果更为明显。而加入 CoordAtt 注意力机制可提高对变色疫木特征的关注度，对于非变色疫木区域被错误识别造成的误检情况，如图 10c、10d 方框内所示，有一定程度的改善。3 种改进方法中，主要以添加小目标检测层的效果提升最为明显，但是 CoordAtt 注意力机制与 WIoUv3 损失函数可作为小目标检测层的补充，进一步提高检测精度。

2.6　讨论

本文采用基于 YOLO v8 深度学习目标检测网络改进的 SCW－YOLO v8 模型，对自建的红脂大小蠹变色疫木数据集进行了目标检测试验。相比基础的 YOLO v8n 模型，改进后的 SCW－YOLO v8 深度学习目标检测网络在针对尺寸较小的变色疫木检测任务中表现出显著优势。该模型改进方法的不同模块可针对不同的错误检测情况，提高鲁棒性和准确性。

当前，国内外相关研究多聚焦于松材线虫，针对红脂大小蠹相对较少。同时，相关研究的基础改进算法仍主要以 YOLO v4、YOLO v5 等较早研发的深度学习目标检测模型为主[38－39]。因此，本文构建红脂大小蠹变色疫木数据集，并基于小目标变色疫木检测的应用展开研究，以 YOLO v8 作为基础改进算法，可在一定程度上填补该领域的研究空白。

此外，本文研究局限性在于，该方法主要针对树冠呈现红色或者大部分呈现红色的重度变色疫木，对于特征不明显的轻度变色疫木检测效果不佳。因此，未来研究应进一步优化模型结构，加强对轻度变色疫木的检测性能，以应对多样化的实际应用需求。

3　结论

（1）为实现红脂大小蠹变色疫木精确检测，将无人机图像与深度学习相结合，针对在无人机航拍图像中变色疫木尺度小，分布密集，分布不均匀，导致 YOLO v8 网络对变色疫木尤其是小目标检测精度较低的问题，提出了一种 SCW－YOLO v8 目标检测网络方法。

（2）首先，在 YOLO v8 结构中的 Backbone 部分添加小目标检测层，以提高对小目标的检测精度。在此基础上，加入 CoordAtt 注意力机制，减少误检情况。最后，引入了 WIoU v3 损失函数，相比 YOLO v8 基础的 CIoU 损失函数，进一步提升了模型的检测精度。

（3）试验结果表明，该检测模型在红脂大小蠹变色疫木数据集上显著优于现有的其他目标检测网络，mAP 与 F1 分数最高可达 91.6% 与 86.8%，相较基础的 YOLO v8n 模型，分别提升 3.5、3.9 个百分点。综上所述，本文的 SCW－YOLO v8 模型对红脂大小蠹小目标变色疫木有较高的检测精度，对其监测和防控有重要意义。

参　考　文　献

[1] GAO B, YU L, REN L, et al. Early detection of *Dendroctonus valens* infestation at tree level with a hyperspectral UAV image [J]. Remote Sensing, 2023, 15:407.

[2] 吴建功，赵明梅，张长明，等. 红脂大小蠹对油松的危害及越冬前后干、根部分布调查[J]. 中国森林病虫，2002, 21(3): 38－41.
WU Jiangong, ZHAO Mingmei, ZHANG Changming, et al. Damage of *Dendroctonus valens* on *Pinus tabulaeformis* and its distribution on trunk and root before and after overwintering period[J]. Forest Pest and Disease, 2002, 21(3): 38－41. (in Chinese)

[3] 孙钰，张冬月，袁明帅，等. 基于深度学习的诱捕器内红脂大小蠹检测模型[J]. 农业机械学报，2018，49(12)：180－187.
SUN Yu, ZHANG Dongyue, YUAN Mingshuai, et al. Detection model of in-trap red turpentine beetle based on deep learning [J]. Transactions of the Chinese Society for Agricultural Machinery，2018，49(12)：180－187. (in Chinese)

[4] 李菊. 红脂大小蠹在辽宁地区的防控必要性及对策分析[J]. 中国森林病虫，2020, 39(4): 6－10.
LI Ju. Necessity and countermeasures for prevention and control of *Dendroctonus valens* in Liaoning area[J]. Forest Pest and Disease, 2020, 39(4): 6－10. (in Chinese)

[5] HALL R J, CASTILLA G, WHITE J C, et al. Remote sensing of forest pest damage: a review and lessons learned from a Canadian perspective[J]. The Canadian Entomologist, 2016, 148(Supp.): S296－S356.

[6] NAGENDRA H, LUCAS R, HONRADO J P, et al. Remote sensing for conservation monitoring: assessing protected areas, habitat extent, habitat condition, species diversity, and threats[J]. Ecological Indicators, 2013, 33: 45－59.

[7] SARKER I H. Deep learning: a comprehensive overview on techniques, taxonomy, applications and research directions[J]. SN Computer Science, 2021, 2(6):1－20.

[8] ZHANG Xiaorong, XU Yong, LIAO Han. BiFusionNet: a lightweight model for detecting Red Turpentine Beetle infestation in pine trees[J]. Ecological Informatics, 2025, 91: 103403.

[9] DONG S, WANG P, ABBAS K. A survey on deep learning and its applications[J]. Computer Science Review, 2021, 40(1):

100379.

[10] KRIZHEVSKY A, SUTSKEVER I, HINTON G. Imagenet classification with deep convolutional neural networks[J]. Advances in Neural Information Processing Systems, 2012, 25(2):1097 – 1105.

[11] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2014:580 – 587.

[12] 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 & Machine Intelligence, 2017, 39(6):1137 – 1149.

[13] 黄华毅,马晓航,扈丽丽,等. Fast R – CNN 深度学习和无人机遥感相结合在松材线虫病监测中的初步应用研究[J]. 环境昆虫学报,2021,43(5):1295 – 1303.
HUANG Huayi, MA Xiaohang, HU Lili, et al. The preliminary application of the combination of Fast R – CNN deep learning and UAV remote sensing in the monitoring of pine wilt disease[J]. Journal of Environmental Entomology, 2021, 43(5): 1295 – 1303. (in Chinese)

[14] 徐信罗,陶欢,李存军,等. 基于 Faster R – CNN 的松材线虫病受害木识别与定位[J]. 农业机械学报,2020,51(7):228 – 236.
XU Xinluo, TAO Haun, LI Cunjun, et al. Detection and location of pine wilt disease induced dead pine trees based on Faster R – CNN[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(7):228 – 236. (in Chinese)

[15] YU M, YE S, ZHENG Y, et al. A shallow pooled weighted feature enhancement network for small-sized pine wilt diseased tree detection[J]. Electronics, 2023, 12(11): 2463.

[16] 王晓婷,赵展,王阳,等. 基于改进 Mask R – CNN 的植物表型智能检测算法[J]. 中国农机化学报, 2022, 43(8): 151 – 157.
WANG Xiaoting, ZHAO Zhan, WANG Yang, et al. Intelligent detection algorithm of plant phenotype based on improved Mask R – CNN[J]. Journal of Chinese Agricultural Mechanization, 2022, 43(8): 151 – 157. (in Chinese)

[17] 陈憶恂,李万益,翁汉锐,等. 基于深度学习的两阶段目标检测算法综述[J]. 信息与电脑(理论版),2023,35(14):112 – 114.
CHEN Yimin, LI Wanyi, WENG Hanrui, et al. Overview of two-stage object detection algorithms based on deep learning[J]. Information & Computer, 2023, 35(14):112 – 114. (in Chinese)

[18] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779 – 788.

[19] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: optimal speed and accuracy of object detection[J]. arXiv Preprint, arXiv: 2004.10934, 2020.

[20] ZHU X, LYU S, WANG X, et al. TPH – YOLO v5: improved YOLO v5 based on transformer prediction head for object detection on drone-captured scenarios[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2021: 2788.

[21] LI C, LI L, JIANG H, et al. YOLOv6: a single-stage object detection framework for industrial applications[J]. arXiv Preprint, arXiv: 2209.02976, 2022.

[22] HUSSAIN M. YOLO – v1 to YOLO – v8, the rise of YOLO and its complementary nature toward digital manufacturing and industrial defect detection[J]. Machines, 2023, 11(7): 677.

[23] ALY, HAMEDMAREY G, SAYED M, et al. YOLO based breast masses detection and classification in full-field digital mammo-grams[J]. Computer Methods and Programs in Biomedicine, 2021, 200: 105823.

[24] ROY AM, BOSE R, BHADURI J. A fast accurate fine-grain object detection model based on YOLO v4 deep neural network [J]. Neural Computing and Applications, 2022, 34(5):3895 – 3921.

[25] LI R, WU Y. Improved YOLO v5 wheat ear detection algorithm based on attention mechanism[J]. Electronics, 2022, 11(11):1673.

[26] 黄丽明,王懿祥,徐琪,等. 采用 YOLO 算法和无人机影像的松材线虫病异常变色疫木识别[J]. 农业工程学报,2021, 37(14):197 – 203.
HUANG Liming, WANG Yixiang, XU Qi, et al. Recognition of abnormally discolored trees caused by pine wilt disease using YOLO algorithm and UAV images[J]. Transactions of the CSAE, 2021, 37(14): 197 – 203. (in Chinese)

[27] ZHANG Z, HAN C, WANG X, et al. Large field-of-view pine wilt disease tree detection based on improved YOLO v4 model with UAV images[J]. Frontiers in Plant Science, 2024, 15: 1381367.

[28] DU Z, WU S, WEN Q, et al. Pine wilt disease detection algorithm based on improved YOLO v5[J]. Frontiers in Plant Science, 2024, 15: 1302361.

[29] ZHU X, WANG R, SHI W, et al. Detection of pine-wilt-disease-affected trees based on improved YOLO v7[J]. Forests. 2024; 15(4):691.

[30] YAO J, SONG B, CHEN X, et al. Pine – YOLO: a method for detecting pine wilt disease in unmanned aerial vehicle remote sensing images[J]. Forests, 2024, 15(5):737.

(下转第 357 页)

44(4)：1114－1124.
HU Guigui, YANG Fenli, YANG Lianan, et al. Spatial prediction modeling of soil organic matter content based on principal components and machine learning[J]. Arid Land Geography, 2021, 44(4): 1114－1124. (in Chinese)
[25] KARRAY E, ELMANNAI H, TOUMI E, et al. Evaluating the potentials of PLSR and SVR models for soil properties prediction using field imaging, laboratory VNIR spectroscopy and their combination[J]. Computer Modeling in Engineering & Sciences, 2023, 136(2): 1399－1425.
[26] LI X Y, FAN P P, LIU Y, et al. Prediction results of different modeling methods in soil nutrient concentrations based on spectral technology[J]. Journal of Applied Spectroscopy, 2019, 86(4): 765－770.
[27] MONSALVE M O, CERÓN-MUÑOZ M, GALEANO-VASCO L, et al. Use of machine learning models for prediction of organic carbon and nitrogen in soil from hyperspectral imagery in laboratory[J]. Journal of Spectroscopy, 2023, 2023(1): 4389885.
[28] 崔玉露，杨玮，王炜超，等. 基于光谱学原理的便携式土壤有机质检测仪设计与实验[J]. 农业机械学报,2021,52(增刊)：323－328,350.
CUI Yulu, YANG Wei, WANG Weichao, et al. Design and experiment of portable soil organic matter detector based on spectroscopy[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(Supp.): 323－328,350. (in Chinese)
[29] 陈强，杨劲松，姚荣江，等. 河套平原典型县域耕地土壤养分空间变异特征研究[J]. 中国农学通报，2020，36(10)：102－108.
CHEN Qiang, YANG Jingsong, YAO Rongjiang, et al. Spatial variability of soil nutrients in cultivated land in typical county of Hetao Plain[J]. Chinese Agriculture Science Bulletin, 2020, 36(10): 102－108. (in Chinese)
[30] 牛雅亮. 基于 LED 的便携式土壤有机质检测仪的研制[D]. 晋中：山西农业大学，2015.
NIU Yaliang. Develop of a portable SOM detector based on LED[D]. Jinzhong: Shanxi Agricultural University, 2015. (in Chinese)

(上接第 338 页)

[31] LOU H, DUAN X, GUO J, et al. DC－YOLO v8: small-size object detection algorithm based on camera sensor[J]. Electronics, 2023, 12(10): 2323.
[32] JIANG T, CHEN S. A lightweight forest pest image recognition model based on improved YOLO v8[J]. Applied Sciences, 2024, 14(5): 1941.
[33] LIN Tsung-Yi, MICHAEL M, SERGE B, et al. Microsoft COCO: common objects in context[C]// European Conference on Computer Vision, 2014: 740－755.
[34] 张宏建,孙智霖,亓新春,等.基于改进 YOLO v8 的苹果树树干精准识别方法[J].农业机械学报,2024,55(增刊 1)：246－255,262.
ZHANG Hongjian, SUN Zhilin, QI Xinchun, et al. Accurate apple tree trunk recognition method based on improved YOLO v8[J]. Transactions of the Chinese Society for Agricultural Machinery,2024,55(Supp. 1):246－255,262. (in Chinese)
[35] HOU Qibin, ZHOU Daquan, FENG Jiashi. Coordinate attention for efficient mobile network design[C]// IEEE Conference on Computer Vision and Pattern Recognition, 2021:13713－13722.
[36] ZHENG Z H, WANG P, LIU W, et al. Distance-IoU Loss: faster and better learning for bounding box regression[C]// Proceedings of the AAAI Conference on Artificial Intelligence, 2020: 12993－13000.
[37] TONG Z, CHEN Y, XU Z, et al. Wise-IoU: bounding box regression loss with dynamic focusing mechanism[J]. arXiv Preprint, arXiv: 2301.10051, 2023.
[38] ZHU X, WANG R, SHI W, et al. Automatic detection and classification of dead nematode-infested pine wood in stages based on YOLO v4 and GoogLeNet[J]. Forests, 2023, 14: 601.
[39] LI Q, CHEN W, CHEN X, et al. Object detection in remote sensing images of pine wilt disease based on adversarial attacks and defenses[J]. Forests, 2024, 15: 1623.